

擴散式深度學習模型應用於臺灣地區降雨預報 之降尺度研究

Application of a Diffusion-Based Deep Learning Model for Downscaling Precipitation Forecasts in Taiwan

國立中興大學土木工程學系

研究生

馬亞珩

Ya-Heng Ma

教授

陳佳正

Chia-Jeng Chen

摘要

近年來，AI 氣象模型在全球天氣預報展現高度潛力，其中 Google DeepMind 開發的 GraphCast 模型，具中短期預報能力與低運算成本等優勢。然而，其空間解析度僅 0.25° (~25 km)，對於地形複雜、局部強降雨頻繁的臺灣，預報精度仍顯不足。本研究基於監督式深度學習架構(Supervised Deep Learning)，應用生成式擴散模型(Diffusion-based Generative Model)對臺灣地區進行 0.25° 至 0.0125° (~1.25 km) 之降雨空間降尺度處理。擴散模型是透過條件輸入學習粗細解析數據之對應關係，產生高解析預報結果；其低解析度條件圖像，來自美國國家海洋暨大氣總署(National Oceanic and Atmospheric Administration, NOAA)提供之全球預報系統(Global Forecast System, GFS)作為初始場輸入，所產之 GraphCast 12 小時、 0.25° 累積降雨預報；目標輸出則為同期 0.0125° 解析度之多重感測器定量降雨估計資料(Quantitative Precipitation Estimation and Segregation Using Multiple Sensors, QPESUMS)。模型訓練資料取自 2022 至 2023 年，2024 年資料則作為測試；以均方根誤差(Root Mean Square Error, RMSE)、相關係數(Correlation Coefficient, CC)等指標，量化模型於 2024 年預測結果與 QPESUMS 資料之差異，評估其在降雨強度與空間分布重建上的準確性。未來可整合其他變量，拓展降尺度於防災應用，提供更具時效與解析度之決策支援。

關鍵詞：降雨預報、深度學習、空間降尺度、生成式擴散模型

Abstract

In recent years, AI-based weather models have demonstrated significant potential in global weather forecasting. Among them, GraphCast, developed by Google DeepMind, offers advantages in medium- to short-range forecasting and low computational cost. However, its spatial resolution of only 0.25° (~25 km) remains insufficient for accurately capturing the complex terrain and frequent localized heavy rainfall in Taiwan. This study employs a supervised deep learning framework and applies a diffusion-based generative model to perform spatial downscaling of rainfall forecasts from 0.25° to 0.0125° (~1.25 km) over Taiwan. The

diffusion model learns the correspondence between low- and high-resolution data through conditional inputs to generate high-resolution forecasts. The low-resolution conditional input is derived from the 12-hour accumulated rainfall forecast at 0.25° resolution produced by GraphCast, which uses initial fields from the Global Forecast System (GFS) provided by the National Oceanic and Atmospheric Administration (NOAA). The target output is the Quantitative Precipitation Estimation and Segregation Using Multiple Sensors (QPESUMS) data at 0.0125° resolution for the same period. The model is trained using data from 2022 to 2023, with 2024 data reserved for testing. Metrics such as Root Mean Square Error (RMSE) and Correlation Coefficient (CC) are used to quantify the difference between the model's predictions for 2024 and the QPESUMS data, thereby assessing the accuracy of the model in reconstructing rainfall intensity and spatial distribution. Future work may integrate additional variables and extend the downscaling framework to disaster prevention applications, providing more timely and high-resolution decision-making support.

Keywords: Precipitation forecasting, Deep learning, Spatial downscaling, Diffusion-based generative model

一、前言

降雨預報對防災與水資源管理至關重要，但傳統數值模式受限於解析度，難以直接滿足區域尺度需求。降尺度方法因此成為關鍵途徑，而人工智慧 (AI) 的引入，為突破降雨降尺度的精度與效率限制提供了新契機。本研究採用以擴散模型為核心之降尺度架構，利用 GraphCast 0.25° 解析度的 12 小時降雨預報場作為條件輸入，生成 0.0125° 的高解析度預報圖。此模型的運作流程可分為訓練與測試兩階段：

在訓練階段，模型的目標是學習如何從不同雜訊程度的數據中，還原出降雨的殘差 (Residual) 細節。我們首先將 GraphCast 預報經雙線性插值放大後，與高解析度的 QPESUMS 真值計算出真實殘差，以此作為模型的學習目標。隨後，我們逐步向真實殘差添加隨機雜訊，從而生成一系列帶有不同雜訊程度的訓練樣本。條件式擴散模型會接收這些帶有隨機雜訊的殘差圖，並參考放大後的預報場，學習還原出真實殘差。模型的損失函數採用加權均方誤差 (Weighted Mean Squared Error, WMSE)，以最小化去噪後預測與真實殘差之間的差異，從而逐步提升模型的預測能力。

於測試階段，模型會將訓練時所學得的最佳參數 (即模型權重) 應用於預測任務。本研究從一張隨機雜訊圖作為起點，並以 GraphCast 預報為條件，讓模型逐步將雜訊圖轉化為一張高解析度的預測殘差圖。最終，將此預測殘差圖與放大後的預報場結合，即可產出精細的高解析度降雨預報。

這種方法大幅提升了預報的實用價值。它能產出高於傳統數值模式的空間解析度，使預報能夠捕捉到小尺度、高強度的降雨細節。儘管推論起始於隨機性，但此特性使模型能在預測中引入合理的多樣性，從而用於評估預報的不確定性及全面的風險評估。

二、研究區域與資料

2.1 研究區域

本研究以經度 119°E 至 123°E、緯度 21.5°N 至 25.5°N 之臺灣本島作為研究區域。選取 2022 至 2023 年之 12 小時累積降雨資料用於模型訓練以及 2024 年資料進行測試與驗證。其中，GraphCast 之 0.25°解析度的降雨預報場作為條件輸入、QPESUMS 之 0.0125°解析度的定量降雨估計資料則作為模型學習的真實值(Ground Truth)同時也作為研究成果的驗證對象。

2.2 多重感測器定量降雨估計資料(Quantitative Precipitation Estimation and Segregation Using Multiple Sensors, QPESUMS)

本研究採用由中央氣象署(Central Weather Administration, CWA)與美國國家風暴實驗室(National Severe Storms Laboratory, NSSL)共同開發的多重感測器定量降雨估計與分離系統(Quantitative Precipitation Estimation and Segregation Using Multiple Sensors, QPESUMS)所提供的資料。此系統整合了氣象雷達、地面雨量站及地理資訊系統(GIS)等多重觀測資料，提供高準確度與高時空解析度的降雨資訊，其解析度為 0.0125°之每十分鐘降雨資料，其高解析度能有效捕捉降雨系統的小尺度空間變異性，故成為本研究用於訓練模型與驗證成果的真實值。

2.3 GraphCast 降雨預報資料

本研究採用的氣象預測資料，來自 NOAA 的 GraphCast 模型。這個模型使用的 GFS 數據作為其初始場輸入。所有數據皆以 Amazon S3 開放數據儲存桶的形式提供，方便全球研究人員下載與分析。GraphCast 是基於圖神經網絡(Graph Neural Network, GNN)的深度學習氣象預測模型，由 NOAA 與 Google DeepMind 合作開發，主要用於全球中短期天氣預測；其中，GraphCast 每日於 0 時與 12 時進行預報初始化，每次預報提供 40 筆 6 小時累積降雨資料(共 10 天)，全球格網解析度為 0.25°。在此基礎上，本研究以降尺度方法將 GraphCast 之 0.25°、6 小時累積降雨預報轉換為 0.0125°的高解析度資料，提升對臺灣區域降雨分布的預測能力。

2.4 降雨資料前處理方法

本研究首先將 GraphCast 預報資料與 QPESUMS 資料進行整合。由於 GraphCast、QPESUMS 原始提供的分別是 6 小時與 10 分鐘累積降雨量，因此本研究將時間加總為 12 小時累積降雨。接著進行數據載入與配對、空間插值與殘差計算、特徵標準化、時間資訊處理，四大前處理步驟。數據載入與配對是將處理後的 GraphCast 與 QPESUMS 檔案，根據其時間軸進行配對，確保每筆低解析度的條件輸入資料都有對應的高解析度真實值；空間插值與殘差計算是透過雙線性插值將 GraphCast 資料的空間解析度從 0.25°提升至 0.0125°，使其與 QPESUMS 數據的維度一致，接著計算兩者間的殘差，其代表模型需要學習的降雨細節；特徵標準化是對插值後的 GraphCast 資料和計算出的殘差數據進行標準化(Normalization)處理，這一步是將不同降雨數值縮放到 0 至 1 之範圍，從而提升訓練穩定性與收斂速度；時間資訊處理是從檔案時間標記中提取年、日、小時資訊，並將其轉換為正規化數值，這些正規化數值將幫助模型捕捉降雨模式的時間變化。

三、研究方法

本研究旨在建立一個條件式擴散模型 $p(x | y)$ ，其中 x 代表預測目標—高解析度的降雨場，而 y 則是條件輸入—低解析預報數據。因此，本研究目標是利用低解析度數據來生成高解析度數據。研究方法核心基於擴散模型，其工作原理可分為正向擴散過程 (Forward Diffusion)、反向去噪過程 (Reverse Denoising) 與定義最佳參數 (θ^*) 三個階段。

3.1 正向擴散與反向去噪

正向擴散過程:此過程會將資料從時間 $t=0$ 時之真實的殘差分佈 $x(0) \sim p(x)$ ，逐步添加高斯雜訊，最終達擴散終點 $t=T$ 時變成完全雜訊 $x(T) \sim N(0, \sigma I)$ 。其中， σI 是一個共變異數矩陣，它確保了最終的雜訊分佈是各個維度相互獨立且具有相同變異數的高斯雜訊。具體來說， I 代表單位矩陣，其對角線上的元素為 1，其餘為 0，這能使各個維度是獨立；而 σ 是純量，它與 I 相乘後，能確保所有維度之變異數皆相同。此過程可由以下隨機微分方程式 (SDE) 如 3-1 所示：

$$dx = f(x, t)dt + g(t)dw \quad (3-1)$$

式中， dx 表示隨機變數 x 在時間 t 上的微小變化量； $f(x, t)dt$ 代表漂移項 (Drift Term)：這是方程式中確定性的部分，類似於傳統微分方程中的變化率。它描述了系統在沒有隨機干擾下的預期演變方向； $g(t)dw$ 代表擴散項 (Diffusion Term)，這是方程式中隨機性的部分； $g(t)$ 為擴散係數 (Diffusion Coefficient)，控制了隨機波動的強度； dw 代表布朗運動 (Brownian Motion) 的微小變化量-布朗運動是一種隨機過程，其特性是每個微小時間間隔內變化量是獨立且服從常態分布。

反向去噪過程為擴散模型的核心，其目標是從純粹雜訊中逐步還原出結構化資料，方向上與正向過程相反。但不同於正向過程，其擴散項並非已知，而需透過神經網路加以學習。模型的訓練即在於掌握此逐步去噪的還原機制，經由學習逆向去噪的軌跡，模型在推論階段便能將任意服從高斯雜訊分布的隨機圖像，轉換為與訓練資料集同類型之高解析度且具物理意涵的降雨場。此過程亦可由 SDE 描述：

$$dx = [f(x, t) - g(t)^2 \nabla_x \log p_t(x)]dt + g(t)dw \quad (3-2)$$

其與正向擴散差異在於函數修正項 (Correction Term)： $-g(t)^2 dt \nabla_x \log p_t(x)$ ，它能指出更接近真實資料分布之方向；負號表示這個修正方向與正向 SDE 漸近擴散的方向相反；而擴散係數 $g(t)$ 之平方加強了隨機波動的強度，補償正向 SDE 中擴散造成的變化； $p_t(x)$ 表示在時間 t 下，隨機變數 x 出現的機率，透過對 X 的導數，讓逆向過程指向真實的殘差分布。透過上述過程模型能夠從高斯雜訊出發，逐步將隨機樣本轉化為與訓練資料分布一致的結構化樣本，實現從噪聲生成高解析度且具物理意義的降雨場或其他目標資料。該機制使擴散模型能同時兼具隨機性與精確的資料重建能力，為生成模型提供穩定而可靠的樣本生成方法。

3.2 最佳參數 θ^*

在訓練過程中，模型透過反覆最小化損失函數以逐步更新參數，最終收斂至能夠逼近真實數據分布的最佳參數集合。損失函數的設計以均方誤差 (Mean Squared Error, MSE) 為基礎，用以衡量模型預測殘差與真實殘差之間的差異。其公式如下：

$$MSE = \frac{1}{n} \sum_{i=1}^n (x - x')^2 \quad (3-3)$$

$$\theta^* = \underset{\theta}{\operatorname{argmin}} \mathbb{E}_t [\lambda(t) \mathbb{E}_x(0) \mathbb{E}_{x(t)|x(0)} [\|s_{\theta}(x, t) - \nabla_{x(t)} \log p_t(x(t)|x(0))\|_2^2]] \quad (3-4)$$

式(3-3)， x' 為真實殘差； x 為擴散模型 12 小時累積預測殘差； n 為某一時段資料總數。式(3-4)，公式的目標是找到一組最佳的參數 θ^* ； $\underset{\theta}{\operatorname{argmin}}$ 是要讓等式右邊之值最小化，以達最佳化； \mathbb{E}_t 是對時間 t 的期望值，期望所有時間點都能準確地去噪； $\lambda(t)$ 為時間 t 之權重函數； $\mathbb{E}_x(0)$ 對原始資料 $x(0)$ 的期望值； $\mathbb{E}_{x(t)|x(0)}$ 給定原始資料 $x(0)$ 後，對雜訊化後的資料 $x(t)$ 的期望值；最後一段是取參數 θ 所定義的神經網路 $s_{\theta}(x, t)$ 減去真實的分數函數 $\nabla_{x(t)} \log p_t(x(t)|x(0))$ 的平方差。

總之，訓練一個擴散模型是最佳化神經網路 $s_{\theta}(x, t)$ ，使其能夠在所有時間 t 與所有資料 $x(0)$ ，都準確估計真實去噪方向，使估計殘差與真實殘差之間的平方差最小化。

3.3 研究成果評估

為進行研究成果之評估，本研究以 2024 年之 QPESUMS 12 小時累積降雨資料作為真值依據，對擴散模型產出之降尺度預測結果以相關係數 CC、偏差(Bias)、RMSE 三評估指標進行驗證，其方程式如式 3-15 至 3-17 所示。

$$\text{Correlation Coefficient} = \frac{\operatorname{cov}(x, x')}{\sigma_x \sigma_{x'}} \quad (3-5)$$

$$\text{Bias} = \frac{1}{n} \sum_{i=1}^n (x - x') \quad (3-6)$$

$$\text{RMSE} = \sqrt{\sum_{i=1}^n (x - x')^2 / n} \quad (3-7)$$

式中， x' 為 QPESUMS 各點位之 12 小時累積降雨觀測數據； x 為 Diffusion model 降尺度後各點位之 12 小時累積降雨預測數據； σ_x 與 $\sigma_{x'}$ 為 x 與 x' 之標準差； $\operatorname{cov}(x, x')$ 為 x 與 x' 之共變異數； n 為資料總數。

四、初步成果

為全面評估本研究開發的條件式擴散模型效能，我們採用雙重比對策略：首先，Graphcast 之 0.25° 12 小時累積降雨數據數據，進行雙線性插值放大至 0.0125 度解析度，並將其與 QPESUMS 進行比對，作為基準參考組。其次，將擴散模型降尺度後的累積預測數據與 QPESUMS 進行比對，藉此量化擴散模型在降尺度過程中所帶來的變化效果。

本研究結果，圖 4-1 是最佳化參數結果，以 2024 年 11 月 15 日 12 時 Usagi 颱風為例。圖 4-2，(a)至(f)呈現降尺度前後在 CC、Bias 和 RMSE 三項指標的空間分佈差異。

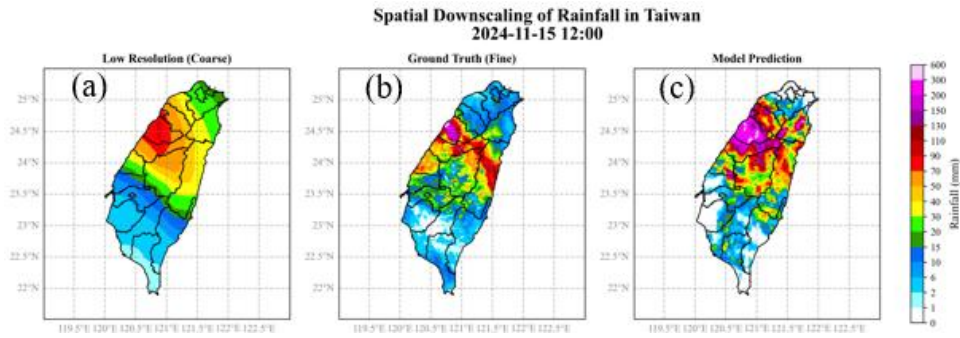


圖 4-1 Diffusion Model 降尺度後之 Usagi 颱風結果；
(a)Graphcast、(b)QPESUMS、(c)Diffusion Model 降尺結果

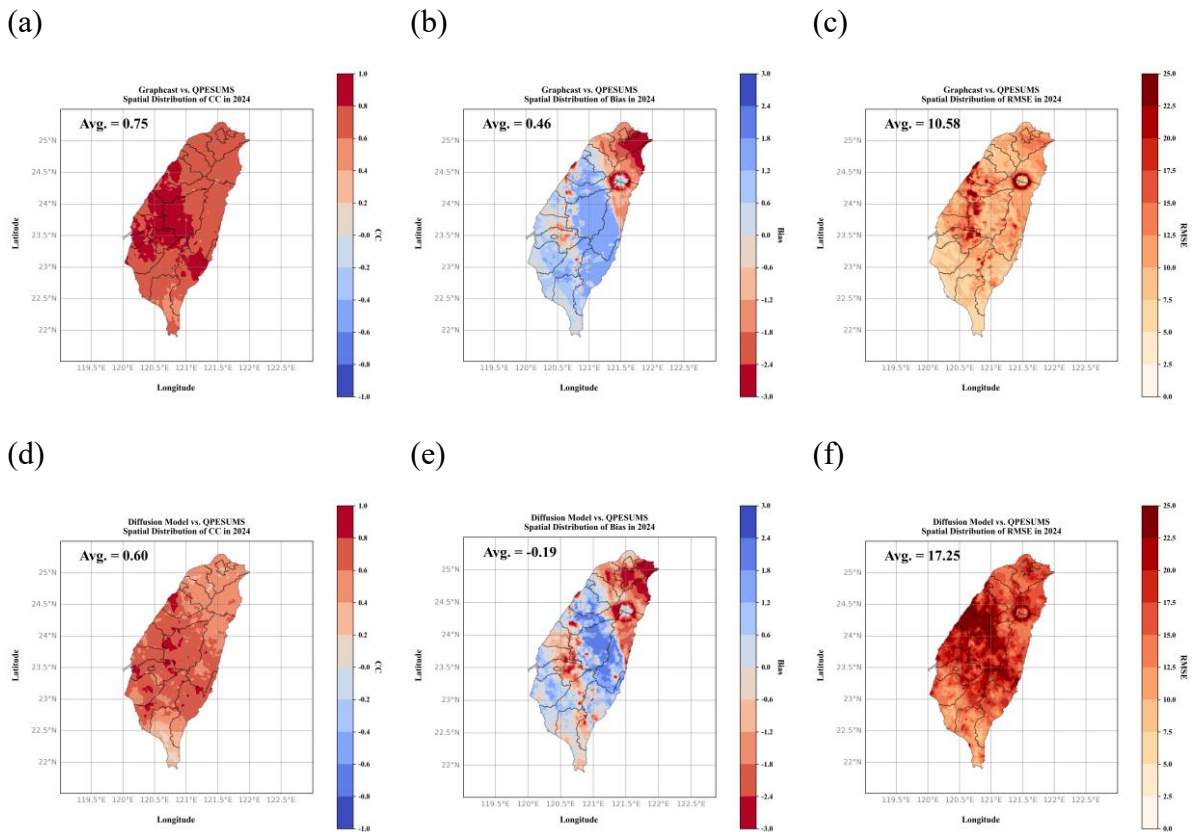


圖 4-2 CC、Bias、RMSE 三項指標上於 2024 年之各項指標空間分佈圖；

(a)-(c)分別為 Graphcast vs. QPESUM 之 CC、Bias、RMSE；

(d)-(f)分別為 Diffusion Model vs. QPESUM 之 CC、Bias、RMSE

研究發現，在時間相關性方面，原始 GraphCast 表現優於擴散模型，與 QPESUMS 之平均 CC 達 0.75，而擴散模型降尺後僅 0.60。顯示模型於生成高解析細節時，可能引入不符實際的時間結構，導致相關性降低。Bias 方面，擴散模型展現優勢。GraphCast 平均偏差為 0.46，顯示系統性高估，而擴散模型將其修正為 -0.19，降低偏差。但模型整體有低估傾向，對微弱降雨捕捉力不足，進而影響空間分佈精準。至於 RMSE，原始數據平均值為 10.58，擴散模型增加至 17.25，顯示雖然能修正總體偏差，但細節有待加強。

總結，條件式擴散模型在修正系統性偏差上具潛力，但須提升空間精度與降低誤差。未來將引入海陸遮罩等約束條件，以兼顧準確度與空間相關性。

六、參考文獻

1. Watt, Robbie A., and Laura A. Mansfield. "Generative diffusion-based downscaling for climate." arXiv preprint arXiv:2404.17752 (2024).
2. Chia-Jeng Chen, Liao-Fan Lin, Hsiang-En Tsou. "Evaluation of FV3-LAM-Based Forecasts over Taiwan: A Focus on 2 Extreme Precipitation"(2025)
3. Manshausen, Peter, et al. "Generative data assimilation of sparse weather station observations at kilometer scales." arXiv preprint arXiv:2406.16947 (2024).
4. Croitoru, Florinel-Alin, et al. "Diffusion models in vision: A survey." IEEE transactions on pattern analysis and machine intelligence 45.9 (2023): 10850-10869.
5. Luo, Calvin. "Understanding diffusion models: A unified perspective." arXiv preprint arXiv:2208.11970 (2022).
6. Mardani, Morteza, et al. "Residual diffusion modeling for km-scale atmospheric downscaling." (2024).