

# 以人工智慧方法進行多天氣變數系集預報場推估至測站降水研究

羅世軒<sup>1</sup> 張鶴齡<sup>1</sup> 薛宏宇<sup>1</sup> 劉家豪<sup>1</sup> 張庭槐<sup>2</sup> 江晉孝<sup>3</sup>

<sup>1</sup>麗臺科技股份有限公司 <sup>2</sup>中央氣象局氣象資訊中心 <sup>3</sup>中央氣象局氣象科技研究中心

## 摘要

全球數值天氣預報模式所需的計算機資源龐大，其產出為等距離或等經緯的固定網格點資料，為了能提供一般大眾生活場域之預報時，必須透過額外空間降尺度(downscaling)方法，將空間解析度較粗的預報資料轉化到次網格點位置上。然而，影響天氣變化的因子往往是多種不同的參數，因此本次研究採用了 8 種變數資料(850200、850210、850510、925500、500000、850000、SSL010、B02100)，在測站預報上也常透過統計方法進行多氣象變數的模型建置，作為修正數值模式的預報誤差使用。本研究導入深度學習(deep learning)模型，透過深度學習特徵提取及多層類神經網路的概念，運用深度學習模型中整合了空間降尺度及數值模式資料後處理等技術。

本研究使用中央氣象局提供全球數值模式系集預報資料，取 2018 年 06 月到 2020 年 01 月的逐 6 時 8 種變數 21 系集成員預報場(解析度 0.5 度)，並透過人工智慧模型針對此兩個季節資料進行臺灣 28 人工觀測站進行累積 12 小時降雨量推估。在深度學習模型使用上採用具備時間解析能力的 3D Resnet 模型 - slow R50 版本。模型推估出臺灣 28 站測站降水量並計算與實際臺灣 28 站測站降水量 RMSE(root mean square error)結果。結果顯示冬季、梅雨季平均誤差值分別為 5.4 mm 與 5.6 mm。推估結果優劣除了受到 8 種參數的影響外，各個觀測站的降水事件次數也不同，導致模型對於不同觀測站的降水量推估效果都不盡相同，整體的推估結果均優於使用 2D Resnet 模型的結果，由此可以知道，具備時間解析能力的 3D Resnet 模型能抓出不同時間點的抽象特徵，進而推估出較佳的降水量，因此該模型更適合分析累積降水量資料。本次研究採用了 RTX A6000 進行模型運算加速，與純 CPU 計算相比，GPU 運算比 CPU 快了 25 倍左右。

關鍵字:人工智慧、深度學習、3D - Resnet、系集資料、降水量

## 前言

全球數值天氣預報模式所需的計算機資源龐大，能產出等距離或等經緯的網格點資料，為了快速且不耗費太多運算資源的條件下，提供一般大眾生活場域之預報，必須透過額外空間降尺度(downscaling)方法，以產出更精細的預報結果。然而，降水氣象變數預報，往往受到多種氣象變數因子影響，在測站預報上也常透過統計方法進行多氣象變數的模型建置，作為修正數值模式的預報誤差使用。本研究導入深度學習(deep learning)模型，透過深度學習特徵提取和多層類神經網路的概念，在深度學習模型中整合了時間、空間降尺度及數值模式資料後處理等技術。

本文主要透過 CNN 架構中的 3D Resnet[1]深度學習方法進行各測站降水推估，該方法原本用於影片物件偵測辨識技術[2]，而模型具有納入不同時間點之間的差異的特性，應該處理如天氣預測這類時間序列資料的問題。因此，本研究也比較了不考慮時間點差異的 2D Resnet 模型的分析結果。兩種模型所使用的輸入資料皆相同，主要差異在於模型輸入

資料的排列形狀不同。透過更換輸出層神經網路，使得模型之輸出數值如同迴歸分析產出之數值型態，本篇降雨預測之輸出即為預測降水量。本研究使用系集全球模式預報的多組氣象變數產出之預報場作為輸入資料，每個變數使用逐 6 小時預報場，並將每 12 小時合併成一筆輸入資料作為 x 數值，建置一個模型可推估 12 小時累積降水氣象變數。3D Resnet 方法相較於傳統的線性迴歸分析有著更高的神經網路層數與殘差網路架構[3]，同時加入了時間卷積[5]的概念，相較於一般的深度迴歸模型可以提取更高維度抽象特徵，同時又可以評估不同時間點間提取出來的抽象特徵影響程度，進而估計更真實觀測的數值，也能解決線性模式常無法解決之離群值(outlier)。

CNN 模型架構都有另一項優勢在於具有遷移式學習的特性，例如當完成第一版深度學習模型後，後續若欲持續加入新圖型優化模型，可不需重頭訓練，僅需於第一版模型加入新圖型訓練即可。這樣可增加模型更新的效率，未來在應用於不同區域(如東亞或全球)時，也可以此模型為基礎進行模型開發。

## 二、資料來源與格式

本研究使用系集全球模式預報輸出中的 8 種氣象變數(850hPa 的 U 分量風、850 hPa 的 V 分量風、850hPa 相對濕度、925hPa 水氣通量、500hPa 重力位高度、850 hPa 重力位高度、海平面氣壓、地面 2 公尺高的溫度)，採用東亞區域 0.5° 解析度，東經 100° 至 140° 北緯 15° 至 40°，網格點為 81 × 51，分布範圍如圖 1 所示，包含北方、南方和東方海面的影響因素範圍。




圖 1 台灣區域分析資料擷取範圍示意

研究觀測資料使用降水資料為 12 小時的累積降水量，累積的時間採用與數值模式相對應的時間，中央氣象局人工觀測站的數量為 32 站資料。

另外，由於研究分析的範圍未包含金門及馬祖，以及五分山及墾丁二雷達站觀測值皆為缺值，故實際模型建置分析之人工測站數量為 28 站，如表 1 所示為實際模型建置分析之人工測站列表。

表 1 深度學習模型分析目標觀測站列表

#	代號	名稱	#	代號	名稱	#	代號	名稱
1	466880	板橋	11	467080	宜蘭	21	467550	玉山
2	466900	淡水	12	467300	東吉島	22	467571	新竹
3	466910	鞍部	13	467350	澎湖	23	467590	恆春
4	466920	臺北	14	467410	臺南	24	467610	成功
5	466930	竹子湖	15	467420	永康	25	467620	蘭嶼
6	466940	基隆	16	467440	高雄	26	467650	日月潭
7	466950	彭佳嶼	17	467480	嘉義	27	467660	臺東
8	466990	花蓮	18	467490	臺中	28	467770	梧棲
9	467050	新屋	19	467530	阿里山			
10	467060	蘇澳	20	467540	大武			

數值系集資料為逐 6 小時預報資料與測站資料為 1 小時觀測資料，收集的資料長度皆為 2018 年 6 月 1 日至 2020 年 12 月 31 日。詳細內容如表 2 說明，各地區的降水事件不同且並非連續發生，降水氣象變數受到季節、地形和緯度分布的影響相當大，所以各個測站的實際雨量與可推估的情況都有不同程度的影響。本次研究使用的梅雨季 5、6 月資料，這段時間的各測站地區降水的事件發生次數較多且分布面積較廣。

表 2 系集預報數值氣象模式資料規格

名稱	內容
氣象變數	850 hPa U、850hPa V、850Pa RH、925hPa Q、500hPa H、850hPa H、海平面氣壓、T2m
資料格式	GRIB2
資料時間	2018 年 6 月 1 日至 2020 年 12 月 31 日
經度	0° 至 359.5°
緯度	-90° 至 90°
網格解析度	0.5°
格點數	720 x 361
系集成員數	21
初始時間	UTC 012、024

經上述表格說明，有 21 組系集預報，每個逐 6 小時預報時資料的矩陣形狀為 8 × 21 × 81 × 51，研究為分析 12 小時累積降水量，預報長度為一天，12 小時預報之輸入資料包含 00 時分析場及 06 時與相對應的 12 時預報場三組時間點資料，同樣 24 小時預報之輸入資料包含 12 時、18 時及 24 時預報場資料，因每筆輸入資料 x 包含三個時間點的資料，輸入資料形狀為 3 × 8 × 21 × 81 × 51。

## 三、研究方法

本次研究將系集預報模式之輸出作為輸入資料，再經由人工智慧方法進行測站點的降水預測，採用 8 種氣象變數逐 6 小時每 12 小時(0012 和 12~18)組合成一筆輸入資料，搭配測站實際降水觀測資料，建構數學模型，推估測站逐時累積 12 小時降水量。

由於使用的輸入資料為多變量形態，所以在分析前必須先對輸入資料進行正規化處理。再將正規化後的輸入資料放入 2D、3D Resnet 模型中訓練並且用測試資料驗證(如圖 2)，並且使用 RMSE (Root-Mean-Square Error)方法進行誤差校驗。



圖 2 研究分析流程

使用的分析資料為 8 種不同的氣象變數並且推估 12 小時累積降水量，在放入 2D、3D Resnet 模型分析前先做數據正規化，以確保模型在訓練過程中，不會受到不同氣象變數單位的影響。正規化的方式為採用全年點資料依據各別種氣象變數，各個系集模型的各個網格點，各點做 0 ~ 1 之間的正規化處理。

研究中採用深度學習中 CNN 架構的 2D、3D

Resnet 作為推論分析的工具。2D 與 3D Resnet 模型最大的差異在於卷積運算的維度，其餘部分依然沿用了 2D Resnet 的殘差網路的技術(如圖 3)。透過殘差網路技術確保模型輸出結果不會因層神經網路的增加，而在傳遞過程後，發生梯度消失的問題，使得模型可以體提取出更高層次的抽象特徵。2D 和 3D Resnet 模型輸入的資料形狀大致相同，主要的差異在於是否要將所有氣象變數攤平。2D Resnet 模型輸入資料形狀為  $(B \times C \times W \times H)$ ， $B$  表示資料筆數， $C$  表示為通道數，在研究中為時間點，最後的  $W$  和  $H$  為同一時間點所有系集成員攤平成二為矩陣的結果， $W$  是  $2 \times 7 \times 51 = 714$ ， $H$  是  $4 \times 3 \times 81 = 972$ (如圖 4a)。3D Resnet 模型輸入資料形狀為  $(B \times C \times L \times W \times H)$ ， $B$  表示資料筆數， $C$  表示為通道數，在研究中為時間點， $L$  表示資料長度，在研究中為變數種類，最後的  $W$  和  $H$  為所有系集成員攤平成二為矩陣的結果， $W$  是  $7 \times 51 = 357$ ， $H$  是  $3 \times 81 = 243$ (如圖 4b)。




圖 3 殘差網路架構圖，每過兩層神經網路後，輸入值重新加上輸出值。




圖 4a 2D Resnet 系集成員資料攤平示意圖




圖 4b 3D Resnet 系集成員資料攤平示意圖

再依據 8:2 的比例隨機抽取 8 成的資料當訓練資料集，剩下 2 成為測試資料集。

再放入 3D Resnet 模型中，使用了 3D Resnet 架構中的 SlowFast Networks[2]的 slow R50 版本的模型。為符合研究輸入輸出資料格式與結果，修改第一層卷積神經網路的輸入通道(Channels)換成輸入的時間點數，同時將最後一層的輸出層(Linear)結果修改成推估的測站數量。

最後在使用 RMSE 數值顯示測試資料集推估結果。為了方便查閱，本次研究將 RMSE 數值依據 10 倍數分級距，並且使用排列圖法[4]表示推估結果坐落的 RMSE 級距百分比與各個 RMSE 級距的累積百分比。

## 四、研究結果

使用 2018 年到 2020 年梅雨季資料，隨機抽 10% 當測試資料集，大約為 22 筆資料，反覆重抽 5 次，產生 5 組訓練與測試資料集。2D 和 3D Resnet 反覆對這 5 組資料訓練測試，並且統計兩種模型 5 次測試資料集結果(如圖 5)與各測站 RMSE 級距百分比結果(如圖 6 到圖 24)。

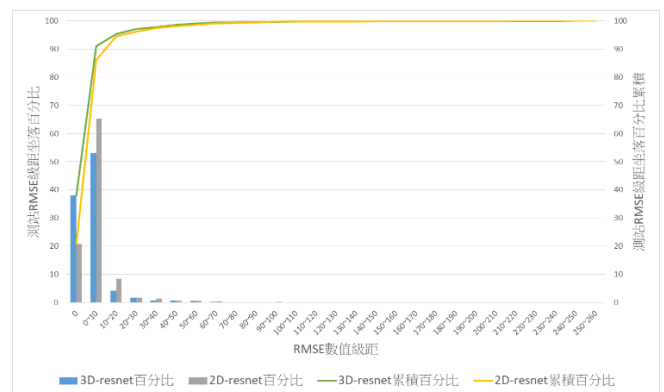


圖 5 2D 和 3D Resnet 比較分析結果。




圖 6 板橋站比較結果




圖 10 花蓮站比較結果




圖 7 淡水站比較結果




圖 11 新屋站比較結果




圖 8 台北站比較結果




圖 12 蘇澳站比較結果

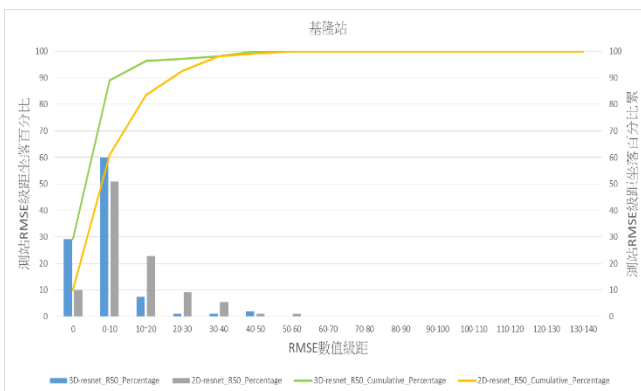


圖 9 基隆站比較結果




圖 13 宜蘭站比較結果




圖 14 台南站比較結果




圖 18 台中站比較結果




圖 15 永康站比較結果




圖 19 大武站比較結果




圖 16 高雄站比較結果




圖 20 新竹站比較結果




圖 17 嘉義站比較結果




圖 21 恆春站比較結果

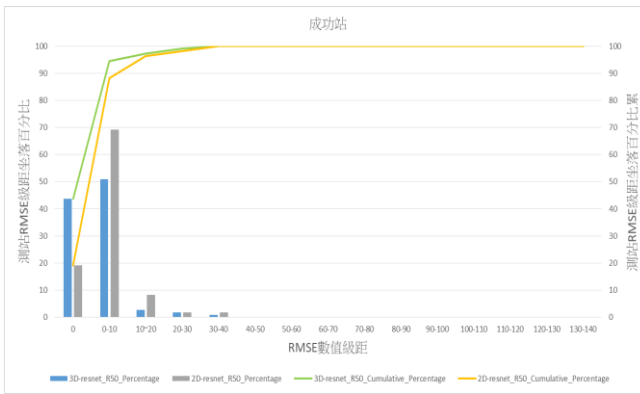


圖 22 成功站比較結果





圖 23 台東站比較結果



圖二十四 梧棲站比較結果

依據研究結果在 0~10 之間的級距可以發現 3D Resnet 的 RMSE 級距坐落百分比累積斜率大多優於 2D Resnet，只有在少部分測站 RMSE 級距略低於 2D Resnet。從上述這點可以認定 3D Resnet 在多時間點資料上的分析能力優於 2D Resnet 模型。

同時也有其他文影像相關的獻可以佐證在多時間點的分析下，3D CNN 架構是優於 2D CNN[5]。

## 五、結論與展望

本次研究所使用的資料量整體不多，分析的過程將降水與非降水事件納入做分析，為了提高模型

的推估能力，採用訓練與測試的資料比為 9:1，實際作為驗證的資料數量有限，以各測站的 RMSE 級距分布進行分析，在研究中經分析發現 3D Resnet 的推估能力較高，分布的級距較為集中，2D Resnet 依各測站的狀況，RMSE 的級距分布較廣，說明推估的雨量值好壞程度參差不齊。另一個問題在於數值模式資料的空間解析度為  $0.5^\circ$ ，在台灣地區可以呈現的圖像特徵為幾個色塊組成的圖像，所以局部地區的細節特徵難以表現出來，在分析上先天就存在一定誤差。同時發現與「以人工智慧方法進行系集溫度預報場推估至測站溫度研究」[6]之研究相比，降水的分析更加困難，主要在於溫度本身帶有地理資訊，不同測站的都有不同的基礎溫度，但是降水分布不連續，受影響的因素多，測站沒有降水，降水量都為 0，在初期分析的時候，自訂淺層結構的模型收斂效果都不好，無法推估出一個精準的結果。目前以梅雨事件作為分析，以有限的資料做出的結果，無法判定在颱風期間或是午後熱對流強降雨事件上 3D Resnet 的推估能力能否有顯著的結果，在此引用這方法作為深度學習的演算法在降水的應用。

本次研究採用了高層樹的 3D Resnet 模型作為分析的工具，相較於 2D Resnet 模型計算量大幅上升，本次研究使用 RTX A6000 GPU 作為加速平台與純 CPU 計算相比，GPU 加速提高了 25 倍左右。

## 六、參考文獻

- [1]. Learning Spatio-Temporal Features with 3D Residual Networks for Action Recognition  
[https://openaccess.thecvf.com/content\\_ICCV\\_2017\\_workshops/papers/w44/Hara\\_Learning\\_Spatio-Temporal\\_Features\\_ICCV\\_2017\\_paper.pdf](https://openaccess.thecvf.com/content_ICCV_2017_workshops/papers/w44/Hara_Learning_Spatio-Temporal_Features_ICCV_2017_paper.pdf)
- [2]. SlowFast Networks for Video Recognition,  
<https://arxiv.org/pdf/1812.03982.pdf>
- [3]. Deep Residual Learning for Image Recognition,  
[https://openaccess.thecvf.com/content\\_cvpr\\_2016/papers/He\\_Deep\\_Residual\\_Learning\\_CVPR\\_2016\\_paper.pdf](https://openaccess.thecvf.com/content_cvpr_2016/papers/He_Deep_Residual_Learning_CVPR_2016_paper.pdf)
- [4]. Pareto chart,  
[https://en.wikipedia.org/wiki/Pareto\\_chart](https://en.wikipedia.org/wiki/Pareto_chart)
- [5]. Can Spatiotemporal 3D CNNs Retrace the History of 2D CNNs and ImageNet?,  
<https://arxiv.org/pdf/1711.09577v2.pdf>
- [6]. 以人工智慧方法進行系集溫度預報場推估至測站溫度研究,  
[http://conf.cwb.gov.tw/media/cwb\\_past\\_conferences/109/A7%E4%BA%BA%E5%B7%A5%E6%99%BA%E6%85%A7\(AD\)%E4%B9%8B%E6%B0%A3%E8%B1%A1%E6%87%89%E7%94%A8/A7\\_O\\_N05\\_%E5%BC%B5%E9%B6%B4%E9%BD%A1.pdf](http://conf.cwb.gov.tw/media/cwb_past_conferences/109/A7%E4%BA%BA%E5%B7%A5%E6%99%BA%E6%85%A7(AD)%E4%B9%8B%E6%B0%A3%E8%B1%A1%E6%87%89%E7%94%A8/A7_O_N05_%E5%BC%B5%E9%B6%B4%E9%BD%A1.pdf)