

多重尺度殘差網路演算法於雨量降尺度之應用

江宙君、朱容練、徐理寰、于宜強

國家災害防救科技中心氣象組

摘要

本文應用人工智慧中的超解析度重建技術----多重尺度殘差網路 (Multi Scale Residual Network, 簡稱 MSRN) 演算法, 開發氣象降尺度法, 藉以提高全球模式雨量預警資料的空間解析度, 以符合臺灣局部小尺度區域災害之需求。研究結果顯示, MSRN 具有提高模式降雨預警資料解析度 20 倍的潛力, 其中又以兩段式提高解析度(先提高 4 倍再提高 5 倍)的二階段 MSRN 模組表現優於一階段 MSRN 模組(直接提高 20 倍解析度)。整體而言, MSRN 降尺度模組除了忠實呈現出原始氣候模式資料的雨量空間分布外, 對於不同天氣類型之臺灣局部降雨特徵也有一定程度的掌握, 於提高降雨資料的空間解析度課題上, 有其正面助益。

一、前言

氣象模式是防災工作中不可或缺的重要工具。災害發生的過程中，舉凡天氣系統的變化、災害規模的預估乃至於預警資訊的發布等，都需仰賴氣象模式的模擬結果。其中，在短期氣候預測上(例如未來六周的降雨預測)，全球環流模式扮演著舉足輕重的角色。透過模式的預測，可了解未來雙週到一個月的降雨趨勢，以及天氣系統變化的訊號，不論是在水資源操作或是颱風災害預警上，皆有其參考價值。然而受限於運算資源與模擬效能，模式所能提供的預警結果，其空間解析度約為 25 公里左右，對於臺灣小尺度局部區域災害分析應用的需求上，仍有其極限。

為了克服全球環流模式間解析度不足的問題，氣象上發展了許多提高解析度的方法，統稱為降尺度技術(Downscaling, Wilby et al., 1997)。大致分成二類，即動力降尺度與統計降尺度。動力降尺度是將全球環流模式的預測資料，導入一個以物理方程為運算核心的區域模式，利用此區域模式進行區域氣象預測資訊的細緻化工作；統計降尺度則是將粗解析度的模式預測因子(Predictor)與高解析度的觀測預報變量(Predictand)，透過統計模組建立二者長期且穩定的關聯，該模組建置完成後，只需導入全球環流模式所提供的未來粗解析度預測因子，便可獲得高解析度的預報變量。此二類的降尺度技術各有其優勢，大

致而言，動力降尺度一般較能掌握環流與地形的交互作用，在極端天氣系統的模擬上有較佳的表現；統計降尺度則是以運算快，低耗能與高效率著稱。氣象上，則會考量當下的運算資源與使用需求，選擇合適的降尺度技術來細緻化預測資料。

圖像超解析度重建是人工智能(Artificial Intelligence，簡稱 AI)圖像判識中，用來提高照片解析度的一種技術，其主要功用在於透過 AI 演算法，將原本模糊的圖像清晰化。此項技術已廣泛應用於許多領域，例如視訊會議的圖像壓縮、醫學圖像的重建、遙測影像的清晰化、公共安全監測影像的重建以及遊戲與視覺圖像的高畫質呈現等。本文將超解析度重建技術中的多重尺度殘差網路(Multi Scale Residual Network，簡稱 MSRN)演算法應用於開發氣象降尺度技術，藉以提高全球環流模式預報資料的解析度。第一部分為前言，第二部分為 MSRN 簡介，第三部分為技術落實應用，第四部份為結語。

二、 MSRN 簡介

機器學習目前已大量運用於電腦視覺的研究領域中，進行影像辨識、物件追蹤、或是圖像處理等工作。其中影像的特徵擷取不管在影像辨識、或是圖像處理中皆為一重要環節，受益於近年來 GPU 發展，利用大量的計算量能來解決問題已屢見不鮮，卷積神經網路

(Convolutional Neural Networks, CNN)即為一個被廣泛應用且成熟的關鍵技術，CNN 首先產生數組隨機的濾波器(filter)去掃描圖片，認識圖片的「局部特徵」，並利用卷積運算來強化並提取這些特徵。透過大量圖片的訓練，CNN 以類神經的方式學習，建立它認為對目標辨識最優異有效的特徵。超解析度(super resolution)為影像處理中一支發展多年的技術，是指將影像從低解析度重建為對應的高解析度影像，對於衛星觀測、醫學等領域皆有重要的應用價值。從 2014 年 SRCNN(Super-Resolution Using Deep Convolutional Networks) (Dong et al., 2014)模型提出以後，CNN 被廣泛利用於處理超解析度的問題上。殘差網路概念(He et al., 2016; Kim et al., 2016)提出以後，即被大量應用於超解析度的 CNN 深度學習模型上，低解析度圖像跟高解析度圖像在低頻的訊息是類似的，訓練時若只讓模型學習低解析度圖像跟高解析度圖像在高頻部分的殘差，可使模型的性能獲得進一步提升。Li et al. (2018)提出了多尺度殘差網路模型(Multi-scale residual network, MSRN)(如圖 1)，MSRN 利用了多尺度殘差塊的結構，引用不同大小的卷積核，獲得不同尺寸的圖片特徵，最後將不同尺度的特徵進行特徵融合，與其它深度學習模型相比，MSRN 具有簡單高效的訓練結構，能適用於任何放大解析度比例，並充分利用低解析度圖片局部多尺度的分層特徵來重建高解析度的圖片，圖 2 為其重建高解析度圖片之範

例。




圖 1、多尺度殘差網路模型(MSRN)架構圖，其中 LR 為低解析度資料，HR 為高解析度資料，橘色方塊為多尺度殘差塊，藍色方塊為卷積層，灰色方塊為瓶頸層，綠色方塊為像素混合層(摘自 Li et al., 2018)。

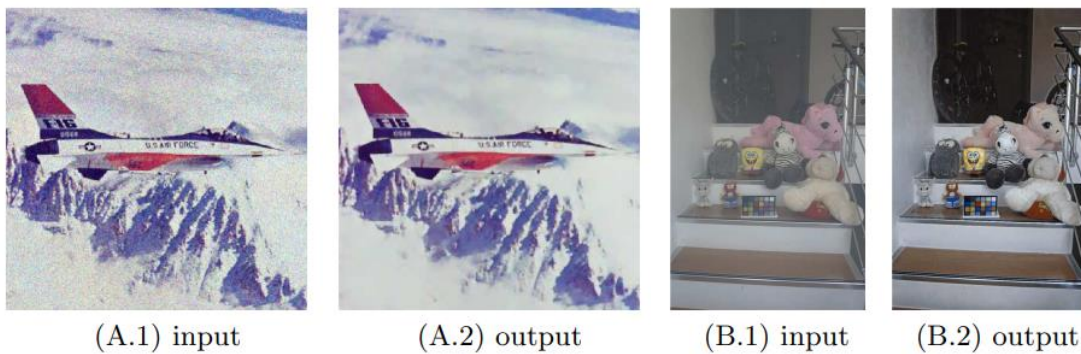


圖 2、應用 MSRN 之範例圖片(摘自 Li et al., 2018)。

三、 技術落實應用

目前國際間所提供的全球模式預報降雨資料相對於臺灣各地的災防使用者需求來說，大多屬於低解析度資料。本研究嘗試將 MSRN 模型應用於氣象全球模式，將臺灣附近的低解析度降雨資料重建為高

解析度降雨資料，以過去 15 年的中央氣象局 QPESUMS 高解析度雷達反演降雨資料為訓練資料，讓 MSRN 模型學習臺灣附近高解析度網格上的降雨特徵，訓練完後輸入全球模式低解析度降雨($0.25^{\circ} \times 0.25^{\circ}$ 解析度)，重建為網格化高解析度降雨資料($0.0125^{\circ} \times 0.0125^{\circ}$ 解析度)。

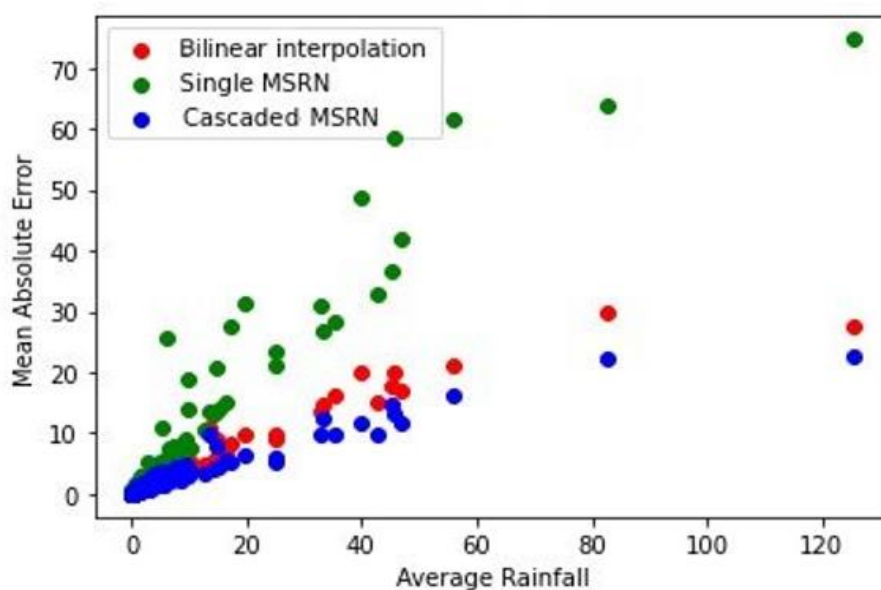


圖 3、線性內插與 MSRN 方法之平均絕對誤差比較圖。圖中紅色點為線性內插結果；綠色點與藍色點分別為一階段與二階段 MSRN 結果。

圖 3 為將過去 15 年(2006~2019)雷達估計降雨，以不同方式(線性內插、一階段 MSRN 與二階段 MSRN)提高解析度後與實測資料之平均絕對誤差比較結果，解析度皆由 0.25° 提高 20 倍至 0.0125° 。平均

絕對誤差越小，代表越接近實測值，反之，若平均絕對誤差越大，則代表越偏離實測值。其中一階段 MSRN 為直接將 0.25° 之雨圖資料解析度提高為 0.0125° ；二階段 MSRN 則是先將 0.25° 之雨圖建立第一階段模組提高 4 倍解析度成為中解析度雨圖，再由中解析度雨圖建立第二階段模組提高 5 倍解析度為高解析度雨圖。圖 3 結果顯示，在不同降雨門檻中，二階段 MSRN 有最小的平均絕對誤差，線性內插的表現次之，一階段 MSRN 的誤差結果則相對偏高。

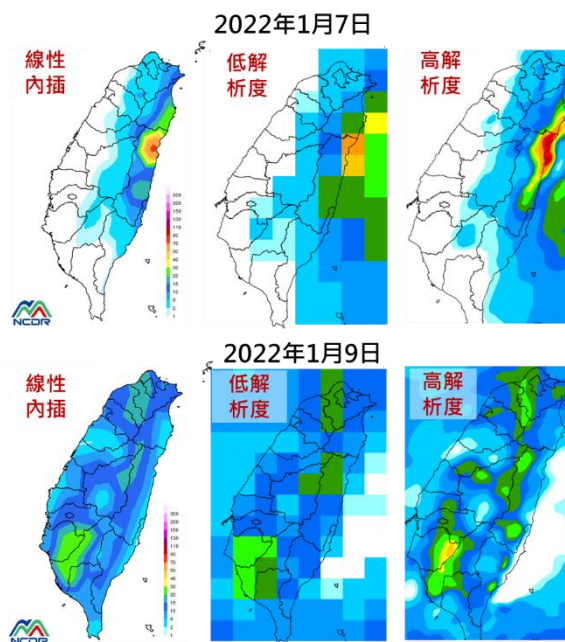


圖 4、2022 年 1 月 7 日、9 日，二階段 MSRN 降尺度、原始解析度以及線性內插結果之雨量空間分布比較圖。

另一方面，圖 4 比較線性內差及二階段 MSRN 計算後之高解析

度雨量空間分布差異，以 2022 年 1 月 7 日、9 日降雨為例，圖 4 左、中、右分別為線性內插、原始解析度以及二階段 MSRN 的雨量空間分布。圖 4 中顯示，線性內插與二階段 MSRN 均提高降雨的解析度，其中二階段 MSRN 則是進一步強化了降雨中心極值，除此以外，二階段 MSRN 的降雨空間分布也較線性內插狹長，反映了一定程度的地形效應，使得降雨分布與地形走向較為一致，在東部(圖 4 上排)或是西南部降雨(圖 4 下排)的天氣中，皆有出現此特性。

在經過模組建置以及校驗之後，國家災害防救科技中心氣象組將此二階段 MSRN 降尺度模組應用於 45 天雨量預警資料中。將模式降雨預警資料從原本 30 公里解析度提高至 1.25 公里。相較於動力降尺度需要執行大約 4 小時的時間，二階段 MSRN 降尺度可於數分鐘內完成。該模組目前已作業化，並於 WATCH 網站中呈現，每日更新二次。如圖 5 所示，二階段 MSRN 降尺度模組對於不同天氣類型之臺灣局部降雨特徵，如西南風影響(7 月 14 日)以及午後對流(7 月 31 日)等，均有一定程度的掌握能力。至於雨量分布與實際觀測的吻合度，則與原生模式的預報度有關。

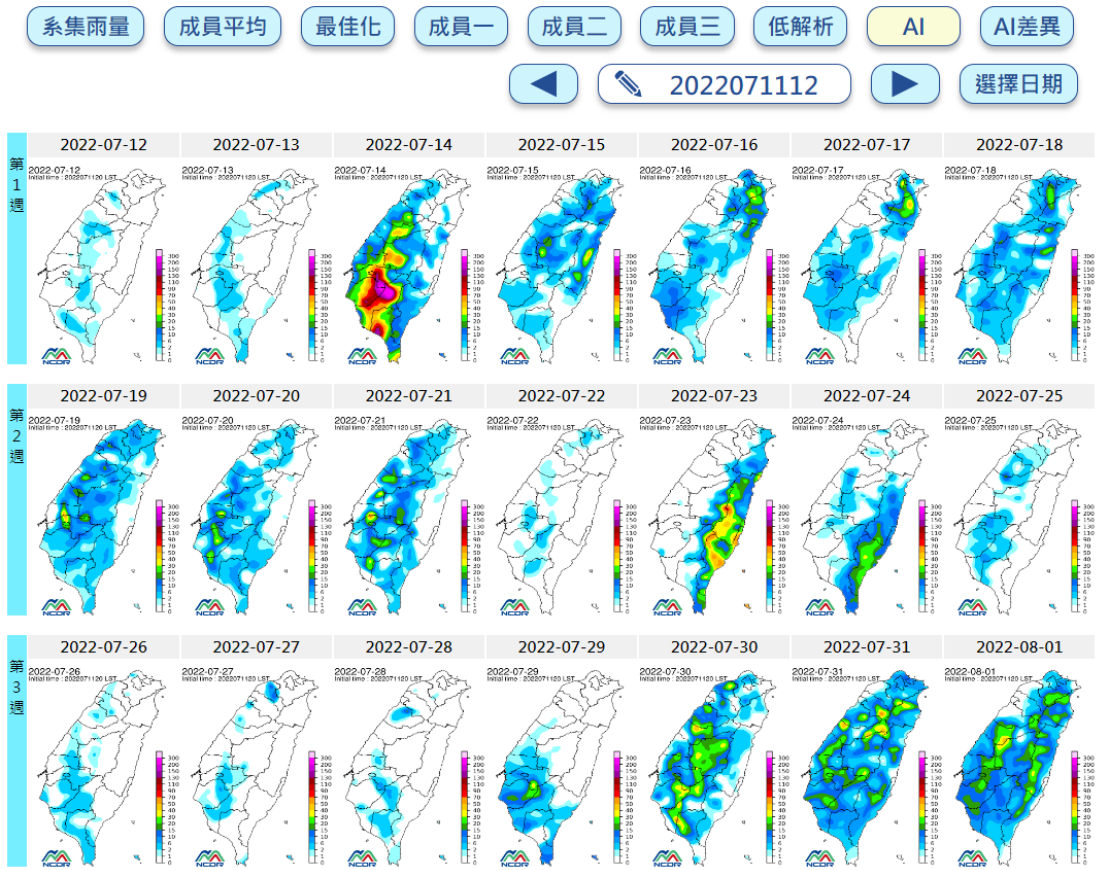


圖 5、二階段 MSRN 降尺度技術作業化圖層。

(https://watch.ncdr.nat.gov.tw/watch_rain_6weeks)。

四、 結語

過去的氣象研究中，鮮少聽聞利用影像處理的演算法來提高降雨空間解析度的應用。本文利用 MSRN 的 AI 演算法，進行降雨統計降尺度的研發工作，是國內氣象防災的新嘗試。從初步的研究成果可知，MSRN 於提高降雨空間解析度的課題上，有其正面助益。不僅可快速且準確地細緻化空間雨量分布，更可節省大量的電腦運算資源，使節

省下來的電腦資源能做更有效率的分配在其他防災課題中。目前的MSRN降尺度模組應用於氣候物理模式中，能忠實呈現原始氣候模式資料的雨量空間分布型態，並提高其解析度，增加臺灣局地降雨特徵。目前所設計的模組，為單純將原始氣候模式資料細緻化，並不改變該資料的預警結果。如何在提高解析度的同時，也能兼顧修正原始模式預估誤差的部分，則是後續持續進行的研發課題。

五、 參考文獻

- Wilby, R. L. & Wigley, T. M. L. (1997). Downscaling general circulation model output: a review of methods and limitations, *Progress in Physical Geography: Earth and Environment*, 21(4), 530–548. <https://doi.org/10.1177/030913339702100403>.
- Dong, C., Loy, C. C., He, K., & Tang, X. (2014). Learning a deep convolutional network for image super-resolution. In: Fleet, D., Pajdla, T., Schiele, B., Tuytelaars, T. (eds) *Computer Vision – ECCV 2014*. ECCV 2014. Lecture Notes in Computer Science, vol 8692. Springer, Cham. https://doi.org/10.1007/978-3-319-10593-2_13.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770–778. <https://doi.org/10.1109/CVPR.2016.90>.
- Kim, J., Lee, J. K., & Lee, K. M. (2016). Accurate Image Super-Resolution Using Very Deep Convolutional Networks. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 1646–1654. <https://doi.org/10.1109/CVPR.2016.182>.
- Li, J., Fang, F., Mei, K., & Zhang, G. (2018). Multi-scale Residual Network for Image Super-Resolution. In: Ferrari, V., Hebert, M., Sminchisescu, C., Weiss, Y. (eds) *Computer Vision – ECCV 2018*. ECCV 2018. Lecture Notes in Computer Science(), vol 11212. Springer, Cham. https://doi.org/10.1007/978-3-030-01237-3_32.