

以人工智慧方法進行系集溫度預報增加預報延時預報場研究

羅世軒¹ 薛宏宇¹ 劉家豪¹ 張庭槐²

麗臺科技股份有限公司¹ 中央氣象局氣象科技研究中心²

摘要

近年來人工智慧(Artificial Intelligence)研究與應用活躍發展,在各領域中也有相當不錯的應用實例,例如:自駕車、人臉識別...等等。人工智慧方法對於大量且高維度的氣象資料,有相當優越的處理分析能力。而全球數值預報模式需要龐大計算資源,並且為搭配天氣預報資訊的發布時程,須在有限的時間內完成預報作業。如何將時間解析度較小的預報資料提高(例如將逐 6 小時預報提升至逐時),是本研究研究方向。本研究旨在藉由人工智慧方法對大量複雜的預報資料進行後處理,藉此提高數值預報的精準度與降低計算所花費的時間成本。本研究提出深度學習(deep learning)之畫風轉移技術(Fast Super-Resolution Convolutional Neural Networks - FSRCNN)對東亞地區 24 小時逐時預報的系集資料提取預轉移欲的特徵資料,再藉由多層神經網路推估各系集成員溫度預報場之推估,以減少數值預報天氣資料儲存之成本。

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 2019 年 10 月到 2020 年 01 月的 21 系集成員逐時預報場(解析度 0.5 度)資料,並以 00Z 分析場及 24Z 預報場作為輸入,透過深度學 FSRCNN 模型建置逐時系集成員逐時預報場之推估模型,並分析秋季(10 月~11 月)及冬季(12 月~11 月)東亞與台灣地區推估結果。其中,秋季台灣地區最佳 RMSE(root mean square error)誤差值為 1.29°C,平均誤差為 1.3°C。冬季台灣地區最佳誤差值為 1.52°C,平均誤差為 1.53°C。並且依據研究結果發現,使用 NVIDIA QUADRO RTX 6000 進行 21 組系集成員的 01Z 至 23Z 預報場(共 483 筆),其預測計算時間約是使用 CPU 效能之 3.5 倍。

關鍵字:人工智慧、深度學習、FSRCNN、系集預報、GPU

一、前言

近年來人工智慧術伴隨著圖形處理器(Graphics Processing Unit, GPU)硬體革新計算成本大幅下降,在各學術領域研究與應用蓬勃發展,越來越多的人工智慧方法被應用到不同的產業領域中,例如:自駕車,人臉識別.....等等。人工智慧方法對於大量且高維度的資料,有著相當優越的處理分析能力。

全球數值預報系統的主要任務為針對短期(1-2 週)及展期(2-4 週)全球大氣變化進行數值預報,做為氣象局天氣預報作業之參考,此外模式結果並提供側邊界條件給區域預報模式,提供臺灣附近區域進行更細緻的區域數值預報。然而全球數值天氣預報模式所需的計算機資源龐大,為搭配天氣預報資訊的發布時程,必須在有限的時間內完成預報作業,因此作業模式的解析度無法太精細,另亦須採用簡化的物理參數化方法、有效率的數值方法及適合的資料同化方法。這些簡化的方法必然會犧牲部分預報精確度,以致模式的預測結果產生若干誤差。

因此本文提出一套應用 GPU 加速之人工智慧方法的動態時空降尺度預報系統,以數值天氣預報模式

的時空稀疏(空間解析度約 50 公里、預報產出時間間隔 12 或 24 小時)的 UTC 00 與 UTC 24 預報資料,進行高時空密度(非模式網格的單點、預報每小時間隔)的預報系統,希望藉此補足因計算成本有限所缺失的預報時間,以及修正因缺失預報時間所導致預報產生的誤差。

本文將說明人工智慧技術實現「以人工智慧方法進行系集溫度預報增加預報延時預報場研究」與「人工智慧方法使用 CPU 與 GPU 效能差異」。

二、資料來源與格式

採用全球數值模式系集預報資料,成員為 0 到 20,共 21 個系集輸出,輸出格式為等經緯網格資料,詳細內容如表 1 說明,(每天資料為一筆分析場 tau=00 和兩筆預報資料 tau=12 和 24,使用的資料長度為 2019 年 10 月 1 日至 2020 年 1 月 31 日。

表 1 系集預報數值氣象模式資料規格

名稱	內容
氣象變數	距地面 2 公尺高的溫度(K) (T2M)
變數單位	K

資料格式	GRIB2
資料時間	2019年10月1日至2020年1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 00Z
預報時	UTC 000、001、002、003、004、005、006、007、008、009、010、011、012、013、014、015、016、017、018、019、020、021、022、023、024

「以人工智慧方法進行系集溫度預報增加預報延時預報場研究」採用東亞區域解析度，東經 100° 至 140° 北緯 15° 至 40°，網格點為 81x51，分布範圍如圖 1 所示。資料處理方式為將數值氣象資料透過 grib2 工具解碼提取上述設定之範圍，再排列為 81x51 的矩陣。為配合觀測值時間，轉為臺灣當地時間及攝氏溫度(°C)輸出。觀測資料採用氣象局人工觀測站排列成測站代碼與溫度資料輸出，共 32 筆資料。




圖 1 東亞區域分析資料擷取範圍示意

最終將 UTC 00 和 UTC24 整成一個 2×81×51 的三維矩陣當作放入人工智慧模型的訓練資料，其他 UTC 時間保持原本 81×51 的矩陣形狀，用於校驗模型預測結果資料。

三、研究方法

本次研究聚焦於「以人工智慧方法進行系集溫度預報增加預報延時預報場」之研究。首先將處理好的訓練資料放入 Fast Super-Resolution Convolutional

Neural Network (FSRCNN)模型分別從 UTC00 和 UTC24 的資料上提取抽象特徵後，產生了 frame0 與 frame2 的特徵集，再各別乘上不同的時間常數 t1、t2 兩個時間單位的資料後，再透過 Long Short-Term Memory(LSTM)模型將提取出來特徵資訊整合輸出成預測結果。

「時間常數」是一個可以變動的常數(0~1)，會依據預測的時間點做調整(如圖 2)。以 UTC12 為中心，各自的時間常數為 1，若預測的時間點偏向 UTC24，則 UTC24 的時間常數保持 1，UTC00 的時間常數則為 $1 - \frac{|12 - \text{預測 UTC}|}{12}$ 。例如預測 UTC08 的結果(如圖 3)，若 UTC08 靠近 UTC00，那 T0 就保持為 1，而 T2 則為 0.66。




圖 2 時間常數資料前處理架構




圖 3 預測 UTC08 的系集結果示意

FSRCNN 模型由 Super-Resolution Convolutional Neural Network(SRCNN)模型改進而來(圖 4)，主要改進了三個部分:1.在網絡末端加入反卷積層，向 HR 的映射直接從原始 LR(未經插值)學得。2.在映射和擴展反饋之前通過收縮輸入特徵維度來重新製作映射層。3.使用了更小的濾波器和更多的映射層[1]。




圖 4 SRCNN 與 FSRCNN 模型比較圖

FSRCNN 模型主要分成五個階段，分別是:特徵提取、崩塌、非線性映射、轉置卷積、激活函數[2]。透過上述的流程後，分別從兩個時間點(UTC00 和 UTC24)提取出 81×51 的抽象特徵(圖 5)，再依據預測的時間點，分別乘上時間常數，最後再透過 LSTM 模型將不同的抽象特徵整合輸出成預測結果。




圖 5 FSRCNN 模型提取特徵流程

長短期記憶網路(Long Short-Term Memory Network, LSTM)以 RNN 為基礎，並改善了 RNN 無法長期記憶的問題。當 RNN 在運算時，輸入資料的特徵會隨著新資料的輸入逐漸被弱化，越新的輸入資料所產生的認知對 RNN 運算的影響越大。為了改善此問題，LSTM 在 RNN 產生新認知的時候，設計了一個遺忘機制，可決定是否將該特徵認知傳到下去或是選擇遺忘[3]。

LSTM 的遺忘機制中有三個開關，分別是 Input gate、Forget gate、Output gate。其運作機制示意圖如圖 6。Input gate 用來控制資料是否寫入記憶區；Forget gate 用來控制是否保留先前記憶區的內容；Output gate 則用來控制記憶區的內容是否要輸出。




圖 6 LSTM 運作流程圖

圖 6 LSTM 的運作機制，其中 Z_i 、 Z_f 、 Z_o 為神經網路自主學習參數， $f()$ 函數為激活函數，通常為 Sigmoid function。圖 6 的運作機制可以公式表達如下：

令原本在記憶區中的內容為 C ，欲放入記憶區的數值為 C' ，則

$$C' = g(X) * f(Z_i) + C * f(Z_f)$$

其中 Forget gate 機制的計算公式為 $C * f(Z_f)$ ，得

到的結果如果是 0，則記憶區中的數字會被新的認知覆寫，反之為 1 則不會。提取值(Y)的計算如公式下。

$$Y = f(C') * f(Z_o)$$

當計算提取值 Y 時，方可得到最後新的認知是否傳遞下去還是遺忘。

將 FSRCNN 模型提取出來的抽象特徵分別乘上時間常數後，在兩個時間點的抽象特徵串接成一個三維矩陣，再透過 LSTM 模型輸出成一個 81×51 的預測結果。

四、研究結果

依據秋季與冬季與不同系集成員分開訓練模型，除了計算東亞地區的 RMSE 結果外，還會特別針對台灣地區計算 RMSE 結果。

圖 7 至圖 11 為秋季時間常數 FSRCNN 東亞地區 RMSE 的整合結果，此部分為將 21 組系集成員逐 1 時預測 UTC01 至 UTC23，一次五個預報時作圖，21 組系集成員 RMSE 東亞地區介於 1.4 度至 3.76 度。




圖 7 秋季 FSRCNN 東亞地區 RMSE 整合圖 (UTC01~05)




圖 8 秋季 FSRCNN 東亞地區 RMSE 整合圖 (UTC06~10)




圖 9 秋季 FSRCNN 東亞地區 RMSE 整合圖 (UTC11~15)




圖 10 秋季 FSRCNN 東亞地區 RMSE 整合圖 (UTC16~20)




圖 14 秋季 FSRCNN 台灣地區 RMSE 整合圖 (UTC11~15)




圖 11 秋季 FSRCNN 東亞地區 RMSE 整合圖 (UTC21~23)




圖 15 秋季 FSRCNN 台灣地區 RMSE 整合圖 (UTC16~20)

圖 12 至圖 16 為秋季時間常數 FSRCNN 台灣地區 RMSE 的整合結果，此部分為將 21 組系集成員逐 1 時預測 UTC01 至 UTC23，一次五個預報時作圖，21 組系集成員 RMSE 台灣地區介於 1.2 度至 1.9 度。




圖 12 秋季 FSRCNN 台灣地區 RMSE 整合圖 (UTC01~05)




圖 16 秋季 FSRCNN 台灣地區 RMSE 整合圖 (UTC21~23)

圖 17 至圖 21 為冬季時間常數 FSRCNN 東亞地區 RMSE 的整合結果，此部分為將 21 組系集成員逐 1 時預測 UTC01 至 UTC23，一次五個預報時作圖，21 組系集成員 RMSE 東亞地區介於 1.8 度至 3.3 度。




圖 13 秋季 FSRCNN 台灣地區 RMSE 整合圖 (UTC06~10)




圖 17 冬季 FSRCNN 東亞地區 RMSE 整合圖 (UTC01~05)




圖 18 冬季 FSRCNN 東亞地區 RMSE 整合圖 (UTC06~10)




圖 22 冬季 FSRCNN 台灣地區 RMSE 整合圖 (UTC01~05)




圖 19 冬季 FSRCNN 東亞地區 RMSE 整合圖 (UTC11~15)




圖 23 冬季 FSRCNN 台灣地區 RMSE 整合圖 (UTC06~10)




圖 20 冬季 FSRCNN 東亞地區 RMSE 整合圖 (UTC16~20)




圖 24 冬季 FSRCNN 台灣地區 RMSE 整合圖 (UTC11~15)




圖 21 冬季 FSRCNN 東亞地區 RMSE 整合圖 (UTC21~23)




圖 25 冬季 FSRCNN 台灣地區 RMSE 整合圖 (UTC16~20)

圖 22 至圖 26 為冬季時間常數 FSRCNN 台灣地區 RMSE 的整合結果，此部分為將 21 組系集成員逐 1 時預測 UTC01 至 UTC23，一次五個預報時作圖，21 組系集成員 RMSE 台灣地區介於 0.7 度至 1.7 度。




圖 26 冬季 FSRCNN 台灣地區 RMSE 整合圖 (UTC21~23)

秋季 21 個系集成員台灣地區平均 RMSE 皆介於 1.29 至 1.35 之間。冬季 21 個系集成員台灣地區平均 RMSE 皆介於 1.53 至 1.59 之間。

五、結論與展望

依據研究結果可以發現人工智慧模型，在使用 GPU 加速的情況下，在增加時間解析度精準度上有相當成效，同時也大幅降低的時間與成本。

由上述的研究也發現，人工智慧技術可以對原來的氣象研究起到協助與加速研究的效果，大幅度降低氣象計算所需要成本。

六、參考文獻

Chao D., Chen C. L., and Xiaoou, 2016:” Accelerating the Super-Resolution”, arXiv:1608.00367v1.

Larissa H., John A. B., Stephan S., 2017:” Deep Learning for Isotropic Super-Resolution from Non-Isotropic 3D Electron Microscopy”, arXiv:1706.03142

Wikipedia, 2020:”Deep Learning”.