

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

張鶴齡¹ 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

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，由於一種天氣變量的預報，其影響因子往往是多種不同天氣變量的組成，在測站預報上也常透過統計方法進行多天氣變量的模型建置，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，將一種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 2019 年 10 月到 2020 年 01 月的逐時 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 人工觀測站進行溫度推估。深度學習模型分別使用在資料維度處理上有些許不同的 1D-CNN、2D-CNN 與 3D-CNN(1D,2D,3D-Convolutional Neural Network)。整體結果以 2D-CNN 表現最為穩定，2D-CNN 即先將資料轉為二維向量型態輸入模型再使用二維卷積層和池化層取得更明確的資料特性。各項模型最後皆會推估出臺灣 28 站測站溫度並計算與實際臺灣 28 站測站溫度 RMSE(root mean square error)結果。結果顯示冬季、秋季平均誤差值分別為 1.49°C 與 0.92°C，觀測站方面似乎受到海拔高度影響，最大誤差常落於玉山觀測站與阿里山觀測站。1D-CNN、3D-CNN 模型也有相似結果，說明深度學習方法可有效取得該天氣變量特徵，進而推估觀測站之溫度。

關鍵字:人工智慧、深度學習、1D,2D,3D-CNN、系集資料

一、前言

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，由於一種天氣變量的預報，其影響因子往往是多種不同天氣變量的組成，在測站預報上也常透過統計方法進行多天氣變量的模型建置，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空間降尺度及數值模式資料後處理等技術。

本文透過 CNN 深度學習方法進行測站氣象推估，此方法和一般常見的迴歸模型類似，會將一組數值天氣預報模式的輸出值作為 x 數值，建置一個模型可估計天氣變量之 y 值，不過 CNN 方法相較於傳統的線性回歸分析多新增了非線性特性，可較線性模型更能估計真實觀測的數值，也能解決線性模式常無法解決之離群值(outlier)。

此外，迴歸模型容易隨著變數增加進而增加模型建立時所花費的時間，CNN 模型中可加入激活函數

(activation function)中的線性整流函數 (rectified linear unit, ReLU)以及退出(dropout)功能，除了可以加速模型計算流程外，更可以避免非線性模型建置流程常出現的過度擬合(overfitting)情況。

CNN 模型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

「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」採用台灣區域解析度，東經 119 至 123 北緯 21 至 26，網格點為 9x11，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 工具提取上述設定之範圍，再排列為 9x11 的矩陣。並且，為配合觀測值時間，轉為臺灣當地時間及攝氏溫度輸出。觀測資料則是使用氣象局人工測站輸出成測站代碼與溫度資料，共輸出 32 筆攝氏單位資料。




圖 1 台灣區域分析資料擷取範圍示意

另外，由於系集模式擷取之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			

系集資料與測站資料預報延時皆為 1 小時，收集的資料長度皆為 2019 年 10 月 1 日至 2020 年 1 月 31 日。詳細內容如表 2 說明，且由於台灣四季天氣型態有很大的不同，並且不同地形及位置測站，可能受到植被或熱輻射等其他因素影響，造成早晚的溫差不同，資料取樣以 10 月至 11 月為秋季、12 月至 1 月為冬季使用預報延時為 1 小時進行分析。

表 2 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($^{\circ}\text{K}$) (T2M)
變數單位	$^{\circ}\text{K}$
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

三、研究方法

本次研究聚焦於「以人工智慧方法進行系集成員溫度預報推估測站溫度方法評估」之研究，將系集預報資料以月份 10 至 11 月、12 至 1 月分為秋季與冬季共兩季，針對每一季系集預報資料使用三種深度模型 1D,2D,3D-CNN(1D,2D,3D-Convolutional Neural Network)進行五次訓練，再與對應的測站資料計算出 RMSE(Root-Mean-Square Error)與 PCCS(Pearson PCCselation Coefficient)。

具體做法為以氣象局的全球數值天氣預報模式為輸入資料，使用空間降尺度(downscaling)方法將 21 系集成員資料從東亞區域解析度降至台灣區域解析度後，再將系集資料的維度轉換成與 1D,2D,3D -CNN 模型匹配的輸入維度，如圖 2，2D-CNN 的輸入維度為為 (21,11,9)，如圖 3，1D-CNN 的輸入維度為(21,11*9)，3D-CNN 的輸入維度為(1,21,11,9)，將轉換後的系集資料輸入至模型得到的模型輸出為 28 個觀測站溫度推估值，最後計算推估的測站溫度與實際的測站溫度之 RMSE 與 PCCS 做為此技術的校準依據。




圖 2 2D-CNN 的資料輸入維度




圖 3 1D-CNN 的資料輸入維度

CNN 模型架構主要由卷積層、池化層與全連接層等三種隱藏層搭配激活函數組成，如圖 4，卷積層與池化層的組合及數量會依模型設計有所不同，而全連接層通常會接在模型的最後一層，以下進行簡單說明。




圖 4 基本 CNN 模型架構圖

1D、2D、3D-CNN 主要差別在於使用不同維度(1D、2D、3D)的卷積層，而卷積層為影像處理中最基本的操作之一，就是將影像內容與卷積核(kernel)做內積，本文以同樣概念將數值內容與卷積核做內積，其功用在於掃描辨識數值中的某些規律或特徵，經由卷積核與輸入的數值做內積運算，可增強數值的特徵並降低雜訊，此過程又稱過濾器(filter)，運算後產生的多個向量稱為特徵映射(feature maps)，卷積層的計算過程如圖 5，而卷積核的數量可以由使用者來決定，理論上設定的數量越多取出的特徵也越多，但是也會增加神經網路的運算時間。

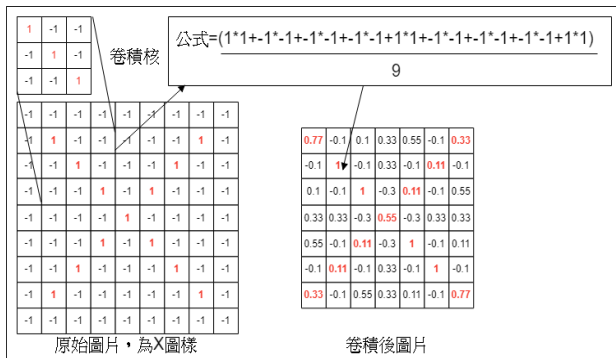


圖 5 卷積層計算過程

而 CNN 模型中加入激活函數(activation function)中的線性整流函數 (rectified linear unit, ReLU)，主要目的是用來增加類神經網路模型的非線性，讓我們定義的類神經網路可以更加活化學習，只要輸入值大於零，輸入值就會被傳遞。

池化層利用影像局部相關性對影像進行降維採樣以減少空間維度，經過池化層後，更能突顯有用的特徵資訊，實際應用上，卷積神經網路模型可能會沒有

池化層或是只有少許幾個池化層，主要的原因是池化層會大幅減少細微數值資訊，但其優點在於可降低模型過度擬合(over fitting)的發生，運作的過程依序為(1)使用固定矩陣纏繞在圖像上(2)挑選出在該範圍中最大(max pooling)像素值(3)移動固定步幅進行選擇。圖 6 展示運用以進行 2x2 池化計算，每次移動 2 個像素，可得右方結果。




圖 6 以 2x2 池化層進行池化計算結果

全連接層為將該層之前的幾個特徵抽取層獲得的特徵表達向量映射到下一層，將前面經過卷積層與池化層的特徵向量壓縮成一維陣列後輸入至全連接網路再輸出 28 個觀測站的溫度推估值，最後將模型推估的觀測站溫度結果與實際觀測站溫度計算 RMSE 與 PCCS，如圖 7 為全連接層運作的示意圖。




圖 7 全連接層運作示意圖

RMSE 公式如下:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - x_i)^2}{n}}$$

RMSE 可了解模型推估的觀測站溫度與實際觀測站的溫度差距。

PCCS 公式如下

$$PCCS = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

PCCS 可了解模型推估和實際觀測是否有相近的趨勢。

四、研究結果

此項研究分別以二維卷積神經網路、一維卷積神經網路、三維卷積神經網路等三種不同方法進行評估。不同方法皆會分別以 UTC00、UTC01 至 UTC24 二十五個時間點分別建立兩組推估模型，並將每個時間點

的 150 筆資料隨機分配 80% 作為訓練數據集(training set)及 20% 作為校驗數據集(validation set)。每次訓練都會隨機取樣訓練數據集及校驗數據集，使用訓練數據集做 5 次的訓練再使用校驗數據集做五次推估，最後保留其中有最低 RMSE 表現的權重用於日後推估。

秋季 2D-CNN 模型訓練分析結果如表 3，AVG 為每一次計算的 UTC00 至 UTC24 的平均結果。最低的 RMSE 結果再 count1 為 0.915。

表 3 秋季 2D-CNN 推估結果 RMSE

預報時	Count 1	Count 2	Count 3	Count 4	Count 5	Average
AVG	0.915	0.933	0.934	0.922	0.944	0.929

秋季 2D-CNN 整合結果如圖 8 至圖 9，RMSE 平均落在 1.0 度，除阿里山與玉山誤差較大外，其餘測站誤差介於 0.6 至 1.3 之間。PCCS 則除阿里山站與玉山站外，其他皆在 0.8 以上甚至高於 0.9。




圖 8 秋季 2D-CNN RMSE 整合圖




圖 9 秋季 2D-CNN PCCS 整合圖

冬季 2D-CNN 模型訓練分析結果如表 4，AVG 為每一次計算的 UTC00 至 UTC24 的平均結果。最低的 RMSE 結果再 count4 為 1.497。

表 4 冬季 2D-CNN 推估結果 RMSE

預報時	Count 1	Count 2	Count 3	Count 4	Count 5	Average
AVG	1.551	1.56	1.535	1.497	1.522	1.533

冬季 2D-CNN 整合結果如圖 10 至圖 11，RMSE 平均落在 1.53 度，玉山觀測站最大誤差，其餘測站誤差介於 0.9 至 2.0 之間。PCCS 最低值落於玉山觀測站，其餘測站則介於 0.5 度至 0.8 度之間。




圖 10 冬季 2D-CNN RMSE 整合圖




圖 11 冬季 2D-CNN PCCS 整合圖

秋季 1D-CNN 模型訓練分析結果如表 5，AVG 為每一次計算的 UTC00 至 UTC24 的平均結果。最低的 RMSE 結果再 count2 為 0.89。

表 5 秋季 1D-CNN 推估結果 RMSE

預報時	Count 1	Count 2	Count 3	Count 4	Count 5	Average
AVG	0.932	0.89	0.935	0.932	0.962	0.93

秋季 1D-CNN 整合結果如圖 12 至圖 13，RMSE 平均落在 0.99 度，除阿里山與玉山誤差較大外，其餘測站誤差介於 0.6 至 1.2 之間。PCCS 則除阿里山站與玉山站外，其他皆在 0.8 以上甚至高於 0.9。




圖 12 秋季 1D-CNN RMSE 整合圖




圖 13 秋季 1D-CNN PCCS 整合圖

冬季 1D-CNN 模型訓練分析結果如表 6，AVG 為每一次計算的 UTC00 至 UTC24 的平均結果。最低的 RMSE 結果再 count1 為 1.578。

表 6 冬季 1D-CNN 推估結果 RMSE

預報時	Count 1	Count 2	Count 3	Count 4	Count 5	Average
AVG	1.578	1.714	1.66	1.697	1.634	1.656

冬季 1D-CNN 整合結果如圖 14 至圖 15，RMSE 平均落在 1.66 度，玉山觀測站最大誤差，其餘測站誤差介於 0.9 至 2.4 之間。PCCS 則介於 0.5 度至 0.8 度之間。




圖 14 冬季 1D-CNN RMSE 整合圖




圖 15 冬季 1D-CNN PCCS 整合圖

秋季 3D-CNN 模型訓練分析結果如表 7，AVG 為每一次計算的 UTC00 至 UTC24 的平均結果。最低的 RMSE 結果再 count1 為 0.964。

表 7 秋季 3D-CNN 推估結果 RMSE

預報時	Count 1	Count 2	Count 3	Count 4	Count 5	Average
AVG	0.964	0.99	1.108	1.142	1.18	1.077

秋季 3D-CNN 整合結果如圖 16 至圖 17，RMSE 平均落在 1.41 度，除玉山誤差較大外，其餘測站誤差介於 0.6 至 1.2 之間。PCCS 則除阿里山站與玉山站外，其他皆在 0.6 以上甚至高於 2.2。




圖 16 秋季 3D-CNN RMSE 整合圖




圖 17 秋季 3D-CNN PCCS 整合圖

冬季 3D-CNN 模型訓練分析結果如表 8，AVG 為每一次計算的 UTC00 至 UTC24 的平均結果。最低的 RMSE 結果再 count1 為 1.602。

表 8 冬季 3D-CNN 推估結果 RMSE

預報時	Count 1	Count 2	Count 3	Count 4	Count 5	Average
AVG	1.602	1.844	1.856	1.826	1.791	1.784

冬季 3D-CNN 整合結果如圖 18 至圖 19，RMSE 平均落在 1.78 度，前二大誤差落於阿里山與玉山觀測站，其餘測站誤差介於 1.1 至 2.3 之間。PCCS 則介於 0.4 至 0.7 之間。




圖 18 冬季 3D-CNN RMSE 整合圖




圖 19 冬季 3D-CNN PCCS 整合圖

五、結論與展望

經過實際推估後三種 CNN 的誤差表現差異不大，其中以 2D-CNN 有最低的平均誤差值，並且觀測站結果似乎受到海拔高度的影響，最大誤差常落於海拔高度較高的玉山觀測站其次為阿里山觀測站。

由上述的研究也發現，由於以數值分析的方法進行天氣預報時，需要將連續的方程式網格式化，而網格式化後的網格式系統空間解析度會大幅影響數值模式的精確度。並且網格式空間解析度越高就越有機會描述更精

細的大氣過程，推測的精確度也可能相對提高。

實際上線若要在時效內提升推測的精準度或加大推測範圍勢必需要更強的計算成本與更大的儲存空間，由本文研究過程中也可以發現在資料量越大與解析度越大進行深度學習模型建置時，使用 GPU 加速後的運算速度會有更明顯的提升，如此便有機會達成更高的預報精準度。

六、參考文獻

Wan J. L., Shih H. L., Hong T. Y. and Che L. H., 2019:” Evaluation of Deep Learning Neural Networks for Surface Roughness Prediction Using Vibration Signal Analysis”, Applied Sciences, 9(7), 1462

Wikipedia, 2020:”Deep Learning”.