

# 應用卷積長短期神經網路進行溫度與風速之數值天氣預報誤差修正

## Correction of Temperature and Wind Speed Prediction Errors in Numerical Weather Prediction Based on Convolutional LSTM Network

邱冠禎<sup>1</sup> 吳宛穎<sup>1</sup> 陳怡儒<sup>2</sup> 林冠成<sup>1</sup>  
國立中興大學資訊管理學系<sup>1</sup> 中央氣象局<sup>2</sup>

### 摘要

中央氣象局採用數值模式預報方法對溫度和風速進行預報，數值模式預報中的誤差則採用 Decaying Average 方法來修正。Decaying Average 方法用簡單的統計模型修正誤差，效果受到侷限。近年來，專家學者開始使用人工智慧進行複雜天氣變化的大數據分析，已經得到不錯的結果。因此，本研究嘗試使用深度學習中結合卷積神經網路（Convolutional Neural Network, CNN）和長短期記憶網路（Long Short-Term Memory, LSTM）的卷積長短期記憶網路（Convolutional LSTM, ConvLSTM）建立預報誤差的時空資料序列後，對數值模式預報的誤差進行建模與修正，並與 Decaying Average 修正方法比較。

本研究針對台灣本土的二十個地點，預報時間為 24 小時預報的 2017、2018、2019 三年的溫度和風速資料，進行建模後修正數值模式預報。實驗結果在溫度誤差修正方面，ConvLSTM 誤差修正模型修正後的平均絕對誤差分別為 0.7092、0.7215 及 0.7032，均優於 Decaying Average 修正後的 0.9717、0.9938 及 0.9882。在風速誤差修正方面，ConvLSTM 誤差修正模型修正後的均方根誤差分別為 1.9466、1.9815 及 1.9024，均優於 Decaying Average 修正後的 2.3444、2.1879 及 2.1709。顯示以深度學習演算法對氣象資料進行大數據分析，應用在數值預報模式中溫度和風速預報誤差修正的可行性。

關鍵字：數值天氣預報、誤差修正、卷積長短期記憶網路、Decaying Average

## 一、前言

世界各國主要都是使用數值天氣預報系統進行天氣預報，然而，數值預報系統會有預報誤差。(張蘭慧, 2011)認為數值模式難以精確描述大氣運動的所有物理過程，主要原因為(1)大氣動力方程式無法完全描述大氣中的物理現象和規律;(2)次網格過程參數化問題難以精確處理，有些小於網格的大氣運動無法被反映;(3)初始場誤差，數值天氣預報的初始場是藉由同化技術將不同類型的觀測資料（如衛星、雷達）結合在一起，初始場與實際值之間的差異會影響數值預報的準確度；(4)計算過程中的小數點誤差，電腦只能使用

固定的位元長度儲存小數點，因此小數點的長度也會影響到運算結果。(AiMei Shao et al. 2009)認為預報模式誤差可分為系統性誤差和非系統性誤差。系統性誤差指的是一個季節或一段時間內不隨時間變化；非系統性誤差則是會隨著大氣狀態而變化。為了使預報值更貼近真實值，如何修正預報誤差就成了數值天氣預報(Numerical Weather Forecast, NWP)很大的挑戰。

目前中央氣象局使用 Decaying Average 方法(陳怡儒, 洪景山, 2017)修正溫度及風速的預報誤差，修正方法即是將原始預報值減去系統性偏差得出修正後的預報場。Decaying Average 方法使用數學方法經由權重控制過去一段時間的系統性偏差和預報誤差所占

的比例以計算目前的系統性誤差。其公式如(1)所示：以權重係數控制前一個時間系統性誤差( $B_{t-1}$ )和當下預報誤差所占比重(b)

$$B = (1 - w)B_{t-1} + w * b \quad (1)$$

**Decaying Average** 方法的優點是在計算模式系統性偏差時可以有效節省資料儲存空間。然而，**Decaying Average** 方法的權重為超參數，氣象局實驗結果將權重固定為修正溫度時權重為 0.04，修正風速時權重為 0.07。所以，**Decaying Average** 方法修正會有以下缺點：

1. 需要一定時間學習，在開始階段修正表現不佳
2. 權重固定，大氣現象隨時間變化，修正效果有限
3. 修正時僅做單一格點修正，沒有通盤考慮周圍格點，無法捕捉天氣的空間特性

(Xingjian Sh et al. 2015)將降水臨近預報化為時空序列預測問題，並提出了一種結合卷積神經網路(Convolution Neural Network, CNN)及長期短期記憶(Long-Short Term Memory, LSTM)的卷積長期短期記憶神經網路(Convolutional LSTM, ConvLSTM)演算法為降水模型臨近預報建立了一個序列對序列的模型，結果顯示 ConvLSTM 的預測能力比 ROVER 及 FC-LSTM 好，驗證 ConvLSTM 較適用於分析時空序列資料。(Mohamed Akram Zaytar and Chaker El Amrani, 2016)使用摩洛哥 9 個城市 2000~2015 年的溫度、濕度及風速資料建立 LSTM 的序列對序列預測模型，結果顯示深度學習預測模型有很好的預測效果。(Solichatus Zahroh et al. 2019)利用 LSTM 預測印尼爪哇島萬隆市的每日溫度。(Qin Zhang et al. 2017)將海面溫度的預測當作時間序列問題，使用 LSTM 建立預測模型，相較於淺層機器學習的預測結果，LSTM 表現較佳。

(Chang-Jiang Zhang et al. 2019)使用 K-mean 聚類算法對模型預測數據進行分類，然後使用 LSTM 對不同類型的降雨數據進行後續建模有效地校正降雨的預報，結果顯示 LSTM 在小雨、中雨、傾盆大雨和暴雨的表現皆優於逐步線性回歸，由此可知，LSTM 是較適用於降雨修正的方法。(Chanjong Yu et al. 2018)驗證了數值天氣預報系統的誤差具有時間及空間的特性，同時，使用 RNN 進行誤差的修正，(Hong Lin et al. 2019)基於 ConvLSTM 建立時空溫度偏差預測模型(PredTemp)，將預測結果用於 NWP 的溫度預報修正，

此文獻使用兩個數據集建模，分別為溫度預報誤差及降水預報的數據集，與單純使用溫度預報誤差相比，將溫度預報誤差結合降水預報資料所訓練的模型其準確性較高。

在風速誤差修正方面，由於風速預測模型會受到計算成本，資源需求大，模型較複雜度等局限性，所以深度學習方法在風速預測上相當有潛力，目前各種預測模型結合使用具有 LSTM 的深度學習方法都達到相當不錯的成效，(Min Ding, 2019)將預報風速誤差的標準偏差整理風速時間序列做權重時間序列。並提出了一種基於雙向門控遞歸單元神經網路 Bidirectional Gated Recurrent Unit Neural Networks (GRUNNs)的誤差校正模型，將誤差權重序列作為輸入對數值天氣預報風速的誤差進行校正。誤差權重序列是根據風速誤差標準差進行權重，然而標準差是一組數自身的離散程度，未考慮實際值與預測值差距。(Wilms, Cupelli, Monti, & Gross, 2019)認為風機地理上的分布會影響風機的風速和風向，因此提出 ConvLSTM 改善風電預測，然而風電場資料缺乏實際地理位置，僅能證明風速和風向具有時空特性。

考慮溫度及風速的預報誤差可以做為時間序列來建模。本研究透過 ConvLSTM 建立預測模型，輸入原始預報誤差並根據模型資料量以及模型複雜度調整目的找到模型最佳化，考慮模型的泛化能力，以現有模型預測不同年度誤差，模型預測結果與原始預報場做修正得到新溫度、風速預報，新的溫度、風速預報修正效果與現有 Decaying Average 做比較修正效果。

## 二、研究方法

### (一) 資料來源及實驗架構

本研究使用的觀測資料及預報資料皆獲取自中央氣象局，預報值為數值天氣預報系統 WRF 的產出，涵蓋北緯 20°~北緯 27°，東經 118°~東經 123.5°的範圍，距離地面 2 公尺高的溫度場與 10 公尺高的風場，網格解析度為 0.0125°\*0.0125°，共 441 \* 561 (247,401) 個網格點，每日 00、06、12、18 點會產生一個 120 小時的預報場，時間顆粒度為每小時一筆資料，本研究選用 00 預報場第 1~24 小時資料進行建模及測試。

由於模型上線使用時須建立全台的誤差修正模型，台灣的地形組成複雜，主要地形包括山地、丘陵、平原、盆地、台地，因此本研究使用遍布全台 20 個地點（包括板橋、臺北、基隆、花蓮、新屋、嘉義、大武、恆春、成功、日月潭、臺東、梧棲、北斗、褒忠、潮州、新埤、員山、玉里、雪嶺、上德文）的 2017~2019 三年的資料進行實驗。

根據前言所述，深度學習演算法 LSTM 在解決時間序列的問題上有非常好的成效，加入 CNN 所形成的 ConvLSTM 則是廣泛被應用於同時具有時間及空間特性的數據，氣象領域的資料如雷達回波、降水、溫度、濕度即是其中一種具代表性的分析目標，因此本研究以 ConvLSTM 深度學習演算法建立溫度及風速預報誤差修正的模型，由於 1~24 個模型與 25~48、49~72 個模型的測試誤差差異不大，因此本研究以 1~24 小時預報場的平均測試誤差為比較基準。將溫度與風速預報誤差當作輸入及輸出，以 ConvLSTM 建立能夠同時捕捉空間和時間特性的模型，將原始溫度與風速的預報值與預測結果相減即可得到經過深度學習修正後的溫度與風速預報值。

## (二) 卷積長短期記憶網路

卷積長短期記憶網路主要利用 LSTM 捕獲時間序列動態以及卷積神經網路（Convolutional Neural Networks work, CNN）捕獲不同空間或空間集組合中的結構和關係，ConvLSTM 的內部結構如圖 1 所示，運作方式如公式(2)~公式(6)，「\*」符號代表卷積運算，「。」符號代表對應相乘。

$$i_t = \sigma(w_{xi} * x_t + w_{hi} * H_{t-1} + w_{ci} \circ C_{t-1} + b_i) \quad (2)$$

$$f_t = \sigma(w_{xf} * x_t + w_{hf} * H_{t-1} + w_{cf} \circ C_{t-1} + b_f) \quad (3)$$

$$C_t = f_t \circ C_{t-1} + i_t \cdot \tanh(w_{xc} * x_t + w_{hc} * H_{t-1} + b_c) \quad (4)$$

$$O_t = \sigma(w_{xo} * x_t + w_{ho} * H_{t-1} + w_{co} \circ C_t + b_o) \quad (5)$$

$$H_t = O_t \cdot \tanh(C_t) \quad (6)$$




圖 1 卷積長短期記憶模型 (Li, 2020)

## (三) 實驗設計

本研究使用之模型架構如表 24 所示，測試集為 20 個地點 2017 年 1~12 逐月 15~19 號預報場、2018 年 1~12 逐月 15~19 號預報場及 2019 年 1~12 逐月 15~19 號預報場，2017~2019 三年資料扣除測試集做為訓練集，訓練集中的 20% 做為驗證集建立誤差預測模型，時間序列長度為 72 小時，Kernel size 為 3\*3，輸入矩陣之中心網格點做為輸出，溫度誤差修正模型架構為 2 層 32 個 Filter 數量的 ConvLSTM，輸入為 5\*5 矩陣，風速誤差修正模型架構為 2 層 128 個 Filter 數量的 ConvLSTM，輸入為 3\*3 矩陣。

## (四) 模型評估方法

在資料分析領域，通常會使用 MAE、MSE、RMSE 做為回歸問題的模型評估標準，由於 MSE 和 RMSE 會受到離群值的影響，對測試集中預測誤差較大的值給予較大的權重，導致整體預測誤差變大，因此本研究在溫度預報誤差修正模型使用 MAE(如公式 7)評估模型的預測誤差。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (7)$$

風速隨機性非常大，屬於非穩定時間序列，本研究模型皆為預測誤差，原始預報需將對模型預測結果做修正，然而，模型預測誤差可能預測過大，風速預報會修正過頭，風速呈現為負值，所以必須對修正過頭的風速進行二次修正，風速為負值改為風速為 0(km/s)，修正後風速預報與 GT 做模型驗證。模型驗證評估標準為均方根誤差(Root Mean Square Error, RMSE)，RMSE 會對異常值敏感即有一個預測值與真實值相差很大，那麼 RMSE 就會很大，因此風速預報 RMSE 過高，有可能表示預報過高，修正效果表現不佳。

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (8)$$

表 1 模型架構

訓練集	20 個地點 2017~2019 三年資料扣除測試集	
測試集	20 個地點 2017 年 6~12 逐月 15~19 號預報場	
	20 個地點 2018 年 6~12 逐月 15~19 號預報場	
	20 個地點 2019 年 6~12 逐月 15~19 號預報場	
地點	板橋、臺北、基隆、花蓮、新屋、嘉義、大武、恆春、成功、日月潭、臺東、梧棲、北斗、褒忠、潮州、新埤、員山、玉里、雪嶺、上德文	
時間序列長度	72	
層數	2	
Filter 數量	溫度：32	風速：128
輸入矩陣	溫度：5*5	風速：3*3
Kernel size	3*3	
輸出矩陣	1*1	

### 三、實驗結果

#### (一)溫度預報誤差修正

圖 2 為 2017 年預報前 24 小時 20 個地點 Decaying Average 及 ConvLSTM 平均預測誤差趨勢比較圖，Decaying Average 誤差介於 0.8~1.3，ConvLSTM 誤差介於 0.5~1.0，在 1~24 小時預報時間，ConvLSTM 皆優於 Decaying Average。




圖 2 溫度 2017 年 20 個地點平均預測誤差

圖 3 為 2018 年預報前 24 小時 20 個地點 Decaying Average 及 ConvLSTM 平均預測誤差趨勢比較圖，Decaying Average 誤差介於 0.8~1.3，深度學習預測模型 ConvLSTM 誤差介於 0.5~1.0，在 1~24 小時預報時間，ConvLSTM 皆優於 Decaying Average。




圖 3 溫度 2018 年 20 個地點平均預測誤差

圖 4 為 2019 年預報前 24 小時 20 個地點 Decaying Average 及 ConvLSTM 平均預測誤差趨勢比較圖，Decaying Average 誤差介於 0.8~1.4，深度學習預測模型 ConvLSTM 誤差介於 0.5~0.9，在 1~24 小時預報時間，ConvLSTM 皆優於 Decaying Average。

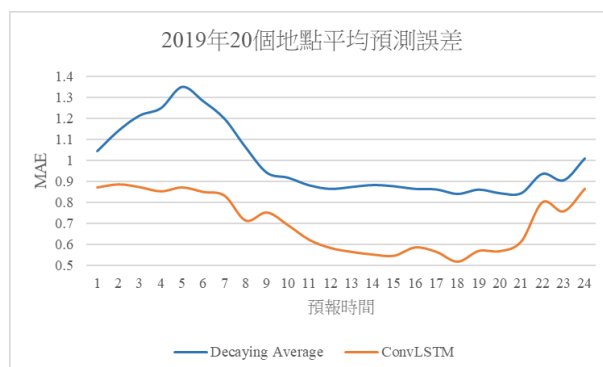


圖 4 溫度 2019 年 20 個地點平均預測誤差

從表 2 中 20 個地點 Decaying Average 及 ConvLSTM 的 2017、2018、2019 年前 24 小時平均誤差可知，在 2017 年 Decaying Average 的誤差為 0.9717，ConvLSTM 為 0.7092，2018 年 Decaying Average 的誤

差為 0.9938，ConvLSTM 為 0.7215，2019 年 Decaying Average 的誤差為 0.9882，ConvLSTM 為 0.7032，2017、2018 及 2019 三年 ConvLSTM 的 20 個地點 24 小時平均誤差皆較 Decaying Average 佳。

表 2 溫度預報誤差修正 20 個地點 Decaying Average 及 ConvLSTM 三年前 24 小時平均預測誤差

測試年份	Decaying Average			ConvLSTM		
	2017	2018	2019	2017	2018	2019
MAE	0.9717	0.9938	0.9882	0.7092	0.7215	0.7032

## (二)風速預報誤差修正

圖 5 為不同修正方法 2017 年 20 個點 24 小時 RMSE，ConvLSTM 整體表現優於 Decaying average。

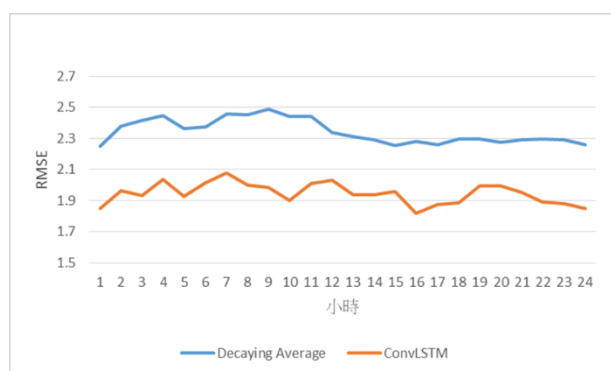


圖 5 風速 2017 年 20 個地點平均預測誤差

圖 6 為不同修正方法 2018 年 20 個點 24 小時 RMSE，ConvLSTM 整體表現優於 Decaying average。




圖 6 風速 2018 年 20 個地點平均預測誤差

圖 7 為不同修正方法 2019 年 20 個點 24 小時 RMSE，ConvLSTM 整體表現優於 Decaying average。




圖 7 風速 2019 年 20 個地點平均預測誤差

從表 3 中 20 個地點 Decaying Average 及 ConvLSTM 的 2017、2018、2019 年前 24 小時平均誤差可知，在 2017 年 Decaying Average 的誤差為 2.3444，ConvLSTM 為 1.9466，2018 年 Decaying Average 的誤差為 2.1879，ConvLSTM 為 1.9815，2019 年 Decaying Average 的誤差為 2.1709，ConvLSTM 為 1.9024，2017、2018 及 2019 三年 ConvLSTM 的 20 個地點 24 小時平均誤差皆較 Decaying Average 佳。

表 3 風速預報誤差修正 20 個地點 Decaying Average 及 ConvLSTM 三年前 24 小時平均預測誤差

測試年份	Decaying Average			ConvLSTM		
	2017	2018	2019	2017	2018	2019
RMSE	2.3444	2.1879	2.1709	1.9466	1.9815	1.9024

## 四、結論

氣象局現有技術權重固定，在修正溫度時權重為 0.04，修正風速時權重為 0.07，然而修正效果有限，需要一定時間學習，並且修正時做單一格點修正，沒考慮周圍點，缺乏考慮空間特性。ConvLSTM 會捕捉時間序列動態以及空間的結構和關係，使用 ConvLSTM 模型建立修正模型改善現有技術權重固定修正效果有限問題，以及修正缺乏考慮時空特性問題。本研究修正三年(2017、2018、2019 年)20 個的地點初始時間 00 UTC 之 1 至 24 小時預報。

在 2017 年 Decaying Average 的溫度誤差為 1.0116，風速誤差為 2.3444，ConvLSTM 可將溫度誤差修正至 0.7203，風速誤差修正至 1.9466。2018 年 Decaying Average 的溫度誤差為 1.0903，風速誤差為 2.1879，ConvLSTM 溫度誤差修正至 0.7330，風速誤差修正至 1.9815。2019 年 Decaying Average 的溫度誤差為 1.0275，風速誤差為 2.1709，ConvLSTM 溫度誤差修正至 0.7373，風速誤差修正至 1.9024，結果可知，2017、2018 及 2019 三年 ConvLSTM 的 20 個地點 24 小時平均誤差皆較 Decaying Average 低。三年 Decaying Average 的平均溫度誤差為 1.0~1.1，平均風速誤差為 2.0~2.3，ConvLSTM 將溫度誤差修正比 Decaying Average 少 0.3，風速誤差修正比 Decaying Average 少 0.2。結果顯示 ConvLSTM 誤差修正模型模式預報能力。

## 參考文獻

- AiMei Shao, Shuang Xi, & ChongJian Qiu . (2009). A variational method for correcting non-systematic errors in numerical weather prediction.
- Chang-Jiang Zhang, Jing Zeng, Hui-Yuan Wang, Lei-Ming Ma, & Hai Chu. (2019). Correction model for rainfall forecasts using the LSTM with multiple meteorological factors.
- Chanjong Yu, Heewoong Ahn, & Junhee Seok.

(2018). Coordinate-RNN for error correction on numerical weather prediction.

- Hong Lin, Yunzi Hua, Leiming Ma, & Lei Chen. (2019). Application of ConvLSTM Network in Numerical Temperature Prediction Interpretation.
- Li & Xu, Huahu & Bian, Minjie & Xiao, Junsheng Yang. (2020). Attention Based CNN-ConvLSTM for Pedestrian Attribute Recognition. Sensors .
- Min Ding Zhou, Hua Xie, Min Wu, Yosuke Nakanishi, Ryuichi Yokoyama Hao. (2019). A gated recurrent unit neural networks based wind speed error correction model for short-term wind power forecasting. Neurocomputing.
- Mohamed Akram Zaytar, & Chaker El Amrani. (2016). Sequence to Sequence Weather Forecasting with Long Short-Term Memory Recurrent Neural Networks.
- Qin Zhang, Hui Wang, Junyu Dong, Guoqiang Zhong, & Xin Sun. (2017). Prediction of Sea Surface Temperature Using Long Short-Term Memory.
- Solichatus Zahroh, Yuyun Hidayat, & Resa Septiani Po. (2019). Modeling and Forecasting Daily Temperature in Bandung.
- Vidushi Chaudhary, Anand Deshbhratar, Vijayanand Kumar, Dibyendu Paul, & Samsung. (2018). Time Series Based LSTM Model to Predict Air Pollutant's Concentration for Prominent Cities in India.
- Wilms, H., Cupelli, M., Monti, A., & Gross, T. (2019). Exploiting Spatio-Temporal Dependencies for RNN-based Wind Power Forecasts. 2019 IEEE PES GTD

*Grand International Conference and  
Exposition Asia (GTD Asia).*

- Xingjian Shi, Zhourong Chen, Hao Wang, & Dit-Yan Yeu. (2015). Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting.
- Yuanyuan Wang, Jian Zhou, Kejia Chen, Yunyun Wang, & Linfeng Liu. (2017). Water Quality Prediction Method Based on IGRA.
- 李虎超, 邵愛梅, 何鄧新, & 王越亞. (2015). BP 神經網絡在估算模式非系統性預報誤差中的應用.
- 張蘭慧. (2011). 數值天氣預報產品的即時誤差訂正方法研究及應用.
- 陳怡儒, 洪景山. (2017). 應用 decaying average 方法進行地面溫度預報偏差修之研究. 大氣科學.