

# 深度學習於極短時雨量預報的應用

陳品璇<sup>1</sup> 張保亮<sup>1</sup> 林冠成<sup>2</sup>

中央氣象局氣象資訊中心<sup>1</sup>

國立中興大學資訊管理學系<sup>2</sup>

## 摘要

本研究將利用劇烈天氣監測系統(QPESUMS)輸出之1小時定量降雨估計及外延預報資料，利用深度學習技術，進行雨量預報誤差修正技術的研發。本研究使用深度學習的卷積長短期記憶網路(Conventional LSTM; ConvLSTM)演算法來掌握降雨預報誤差在空間分佈及時間的變化特性，並建立降雨誤差的修正模型。

在資料預處理方面，首先從資料中選取研究所需的範圍及地點，形成雨量預報誤差資料樣本，再將資料轉換成具有時空關係的資料型態。其次，將深度學習技術結合降雨資料，以過去1小時的相關資料，建立未來1小時短延時降雨誤差修正模型，最後對於誤差修正模型進行分析與評估。實驗結果顯示，經由短延時降雨誤差修正模型修正後，可有效提升現有雷達外延雨量預報的準確度。

關鍵字：劇烈天氣監測系統、深度學習、雨量預報誤差修正、卷積長短期記憶網路

## 一、前言

中央氣象局所發展的劇烈天氣監測系統(Quantitative Precipitation Estimation and Segregation Using Multiple Sensor; QPESUMS) (唐等 2015)，除提供定量降水估計(Quantitative Precipitation Estimation, QPE) (Zhang et al. 2008)外，並利用外延法，產生 0-1 小時定量降水預報(Quantitative Precipitation Forecasting, QPF)產品，QPF 示意圖如圖 1 所示(唐等 2015)。由於回波外延法會因為天氣系統的快速變化，而無法有效掌握，進而產生降水的估計偏差。因此，希望透過人工智慧的方法，捕捉 QPF 的誤差，並對 QPF 進行誤差修正。

本研究主要先針對結構較穩定的梅雨型態進行誤差修正的研究，並使用深度學習的卷積長短期記憶網路(Conventional LSTM; ConvLSTM)演算法來捕捉 QPF 預報誤差在空間分佈及時間的變化特徵，建立未來 1 小時降水誤差的修正模型。

## 二、資料與方法

### (一) 雨量資料

為建立網格的降水誤差資料，本研究使用

QPESUMS 中的 1 小時累積 QPF 及 1 小時累積 QPE，並將其資料相減取得誤差值，此資料集每 10 分鐘產生一筆資料，1 天會產生 144 筆資料。其中，資料集當中包含部分遺失值及缺少日期，皆以 0 取代之。另外，由於資料的涵蓋範圍過大，考量電腦運算資源的限制，並保留台灣的區域特性，採取區域性切割的處理方式。

### (二) ConvLSTM 演算法

此模型是由 Xingjian et al. (2015)所提出，主要是利用卷積神經網路(Convolutional Neural Network; CNN) (Krizhevsky et al. 2012)架構探討空間特徵的相依性，以及利用長短記憶網路(Long Short Term Memory; LSTM) (Hochreiter and Schmidhuber. 1997)模型架構探討時間序列的相依性，而作者也在論文中證明此模型應用在雷達回波的降水預測上，比 LSTM 有更好的結果。而以下公式 1 為 ConvLSTM 的方程式：

$$\begin{aligned}i_t &= \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + W_{ci} \circ C_{t-1} + b_i) \\f_t &= \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{cf} \circ C_{t-1} + b_f) \\o_t &= \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{co} \circ C_{t-1} + b_o) \\ \tilde{C}_t &= \tanh(x_t W_{xc} + H_{t-1} W_{hc}) \\C_t &= f_t \circ C_{t-1} + i_t \circ \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c) \\h_t &= o_t \circ \tanh(C_t)\end{aligned}$$

公式 1、ConvLSTM 公式

公式 1 中的  $i_t$ 、 $o_t$ 、 $f_t$  分別為 ConvLSTM 的輸

入閥、遺忘閥以及輸出閥，公式裡的「\*」符號代表「卷積」運算。圖 2 為 ConvLSTM 的流程圖，圖參考 Hu et al (2019)之內容製作。圖中可以看到，由「 $\sigma$ 」控制三個門閥是否要開啟，並且透過激發函數計算更新的資訊量，且可以透過時間序列將資訊量串聯在一起，再經由卷積計算捕捉特徵關係。

### 三、 個案評估

本研究利用 QPF 與 QPE 所產生的降水誤差建立資料集。其次，輸入過去 1 小時誤差資料，透過 ConvLSTM 所建立的短延時降水誤差修正模型，輸出未來 1 小時的降水誤差，並針對 QPF 進行誤差修正及評估。

本文中，僅以以下三個梅雨個案進行分析，分別描述其誤差分布及表現能力。以下三個個案皆使用了 2017 年至 2019 年的 4 月至 9 月的資料做為訓練集，其訓練集不包含個案的日期。原始資料當中包含遺失值-999.0、0 值-998.0、缺少日期，此三種特殊狀況，目前皆以 0 取代之，以避免干擾模型權重的訓練過程。在(一)有提到，為了避免電腦記憶體無法負荷，因此選了 6 個台灣測站，測站名稱分別為：五分山、阿里山、清泉崗、七股、墾丁、花蓮。

而本研究的實驗流程為，輸入的資料範圍分別以 6 個測站為中心，各選取 55×55 的方框大小，並連續輸入不包含當下的前六筆資料，輸出未來第六筆資料，其輸出資料大小同輸入大小，圖 3 為上述描述的實驗流程圖。由於輸出的矩陣大小為 55×55，為能夠預測整個台灣(385×385)的一小時累積降水誤差，本研究採移動的方式進行預測，圖 3 的測試流程，移動方向是由左往右，由上往下的方式。

#### (一) 梅雨之驗證個案：2020 年 5 月 20 日至 2020 年 5 月 22 日

觀察 QPE 的一小時累積雨量，此個案主要於 21 日及 22 日的降水，對台灣的西半部造成較大影響，其中又以西南部更為嚴重。此個案的誤差具有大面積的移動，有完整誤差結構，圖 5 為 2020 年 5 月 21 日 09:30 ~ 10:20 之誤差分布。經過模型修正 bias 之後，可以看圖 4(a)的臨界成功指數(Critical Success Index, CSI)結果，CSI 值越高，則預報表現越好。藍色線為 AI 修正後的 1-h QPF，紫色線為氣象局現有 1-h QPF 作業，橫軸為雨量門檻(mm/1h)，縱軸為 CSI 值。AI 修正後的 CSI 值可以由 0.13 提升至 0.2(以門檻 40 為例)，提升了約 35%的準確度。圖 6 為修正後的 QPF(AI\_QPF)及原始 QPF 的比較，時間為 2020 年 5 月 22 日 09:30~10:20，可以看到圖片左下角的海域，AI\_QPF 可以提升被低報的降水。

#### (二) 梅雨之驗證個案：2019 年 5 月 17 日至 2019 年 5 月 20 日

觀察 QPE 的 1 小時累積雨量，此個案的降水主要對於台灣中部山區及西北部有較大的影響，雖然個案的誤差同樣具有大面積的移動，不過有雨量過於低報的情況發生，圖 7 為 2019 年 5 月 20 日 03:00 ~ 03:50 之誤差分布。由圖 4(b)結果來看，AI 修正後的 CSI 值可以由 0.2 提升至 0.25(以門檻 40 為例)，提升了約 20%的準確度，由於此個案的低報程度大於個案一，因此 CSI 提升的程度沒有個案一好。圖 8 為修正後的 QPF(AI\_QPF)及原始 QPF 的比較，時間為 2019 年 5 月 20 日 06:00~06:50，可以看到台灣嘉義地區跟東部地區，AI\_QPF 可以提升被低報的降水。

#### (三) 梅雨之驗證個案：2017 年 6 月 1 日至 2017 年 6 月 4 日

觀察 QPE 的 1 小時累積雨量，此個案的降雨雖然一開始從北部開始降水，但從 6 月 2 日開始，降雨開始往中部逐漸增加，直至 6 月 4 日才結束，導致中南部的山區較有嚴重的災情，此個案的誤差分布是三個個案中最零散的，導致修正結果不如預期，圖 9 為 2017 年 6 月 1 日 00:00 ~ 00:50 之誤差分布。

從圖 4(c)的結果來看，修正後的 QPF(藍線)，只有微小的提升，表示零散的 bias 無法掌握其結構，導致限制其修正的效能。圖 10 為修正後的 QPF(AI\_QPF)及原始 QPF 的比較，時間為 2017 年 6 月 3 日 12:00 ~ 12:50，AI\_QPF 與原始的 QPF 比較不出明顯的差別。

### 四、 結論

此研究目的為建立降雨誤差修正模型，藉由 ConvLSTM 演算法所建立的降雨誤差修正模型，可有效修正 1-h QPF 的誤差。如第三節所示，透過深度學習所訓練出的誤差修正模型對於具有大面積誤差的累積降水，有不錯的修正效果。然而，對於較零散的降水誤差，修正能力較為有限。

由於目前研究針對需要預處理的數值，皆採用補 0 的方式，這樣對於這些數值的代表性不高，會影響模型的權重的計算。因此，未來會針對-999.0 及-998.0 進行新的處理方式，以增強誤差修正的能力。另外，再針對不同的天氣型態的降水(如：西南氣流)進行分析，建立一個較全面性的降雨誤差修正模型。

### 參考文獻

唐玉霜，黃葳芃，張保亮，陳嘉榮，2015：劇烈天氣系統(QPESUMS) 發展與客製化服務。104 年天氣分析與預報 研討會論文彙編，中央氣象局，A6-9，

6 頁。

- Zhang, J., K. Howard, P.-L. Chang, P. T.-K. Chiu, C.-R. Chen, C. Langston, W.-W. Xia, B. Kaney, and P.-F. Lin, 2008: High-Resolution QPE System for Taiwan, Data Assimilation for Atmospheric, Oceanic, and Hydrologic Applications. S. K. Park, L. Xu, Ed(s), Springer-Verlag, 147 - 162.
- Xingjian, S. H. I., Chen, Z., Wang, H., Yeung, D. Y., Wong, W. K., & Woo, W. C. , 2015: Convolutional LSTM network: A machine learning approach for precipitation nowcasting. In *Advances in neural information processing systems* , 802-810.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. , 2012: Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems*, 1097-1105.
- Hochreiter, S., & Schmidhuber, J. ,1997: Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Hu, W. S., Li, H. C., Pan, L., Li, W., Tao, R., & Du, Q. , 2019: Feature extraction and classification based on spatial-spectral convlstm neural network for hyperspectral images. *arXiv preprint arXiv:1905.03577*

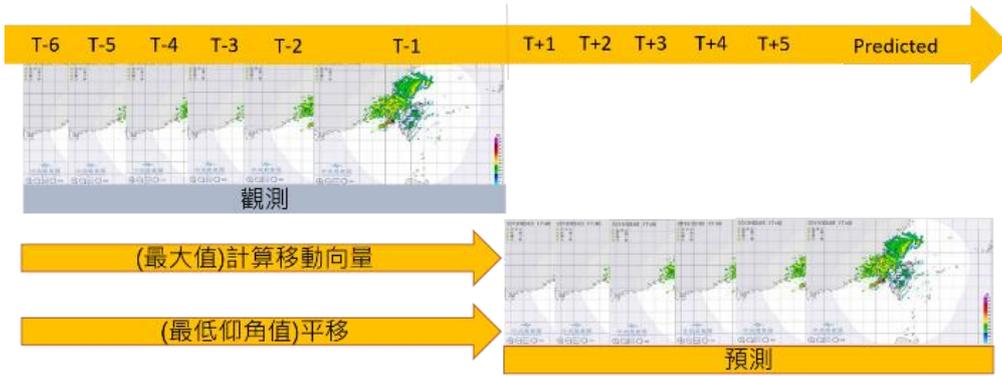


圖 1、QPF 示意圖。利用過去幾筆時間之最低可用仰角，透過回波外延進行平移。

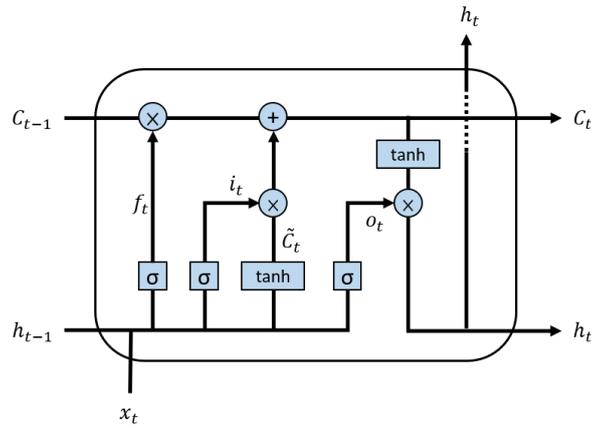


圖 2、ConvLSTM 架構圖。

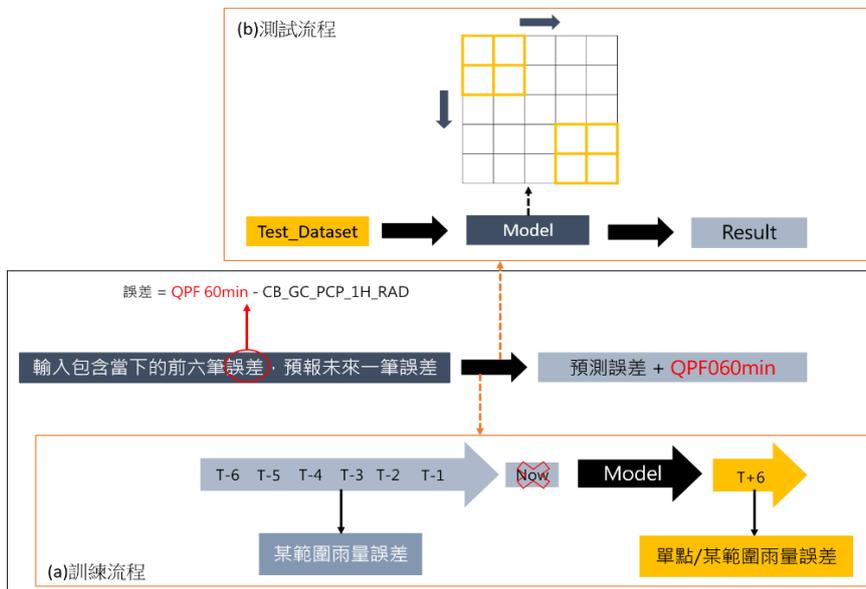


圖 3、實驗流程圖。(a)為訓練流程，透過 ConvLSTM 演算法，建立模型；(b)為測試流程，使用不包含在訓練流程的資料，並透過訓練好的模型測試之。

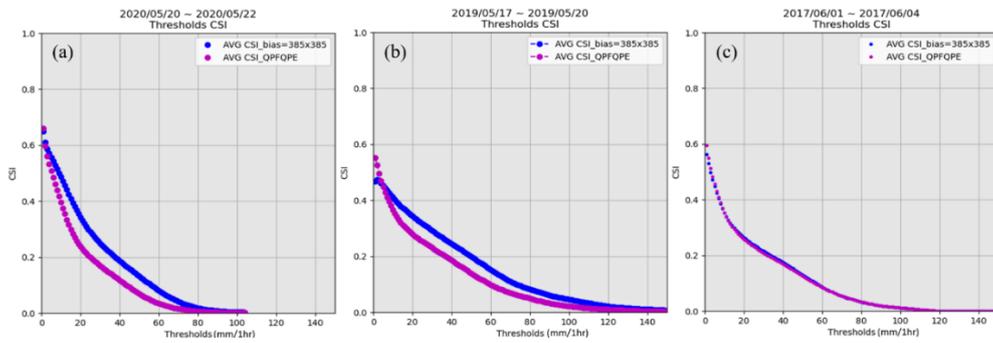


圖 4、個案 CSI 表現。(a)為 2020 年 5 月個案; (b)為 2019 年 5 月個案; (c)為 2017 年 6 月個案。

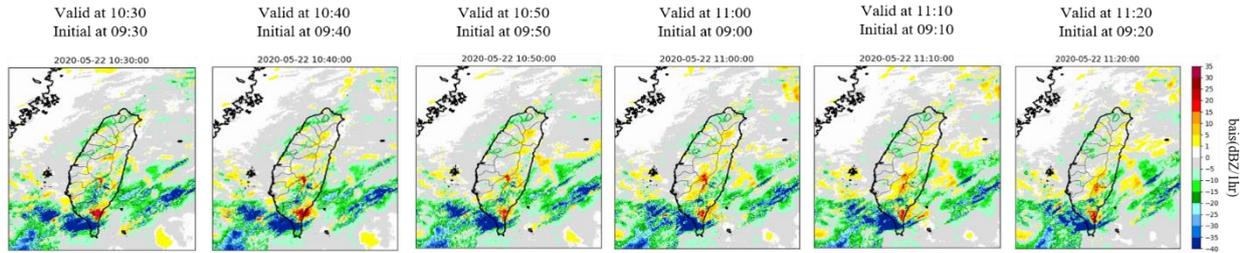


圖 5、2020 年 5 月 21 日 09:30~10:20 之梅雨個案雷達雨量外延預報偏差分布圖，每 10 分鐘產生一筆資料。圖中 Initial 代表預報初始時間，Valid 代表預報時間。

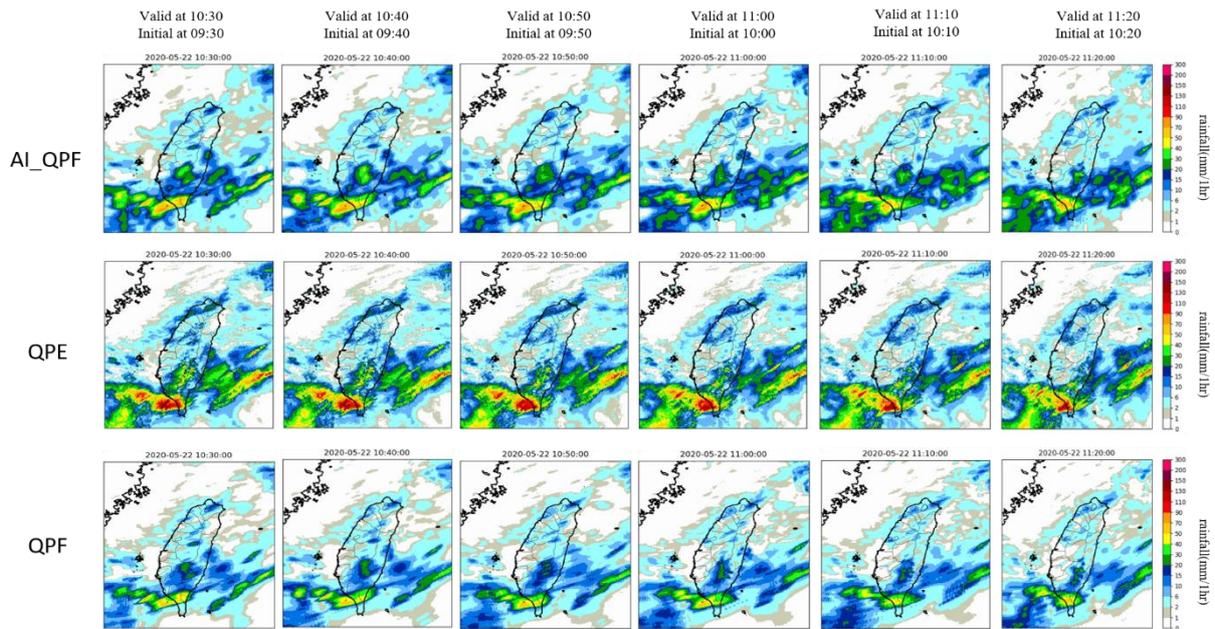


圖 6、2020 年 5 月 22 日 09:30~10:20 之個案，每 10 分鐘產生一筆資料。AI\_QPF 為利用 AI 修正的定量降水預報; QPE 為定量降水估計; QPF 為定量降水預報。圖中 Initial 代表預報初始時間，Valid 代表預報時間。

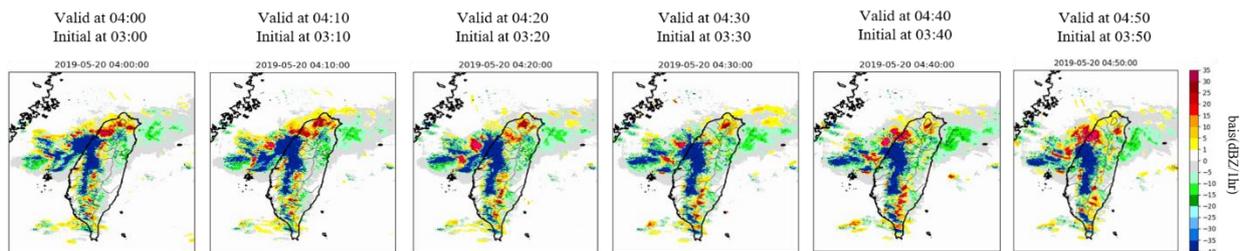


圖 7、同圖 5，但為 2019 年 5 月 20 日 03:00~03:50 之梅雨個案 bias 分布圖。

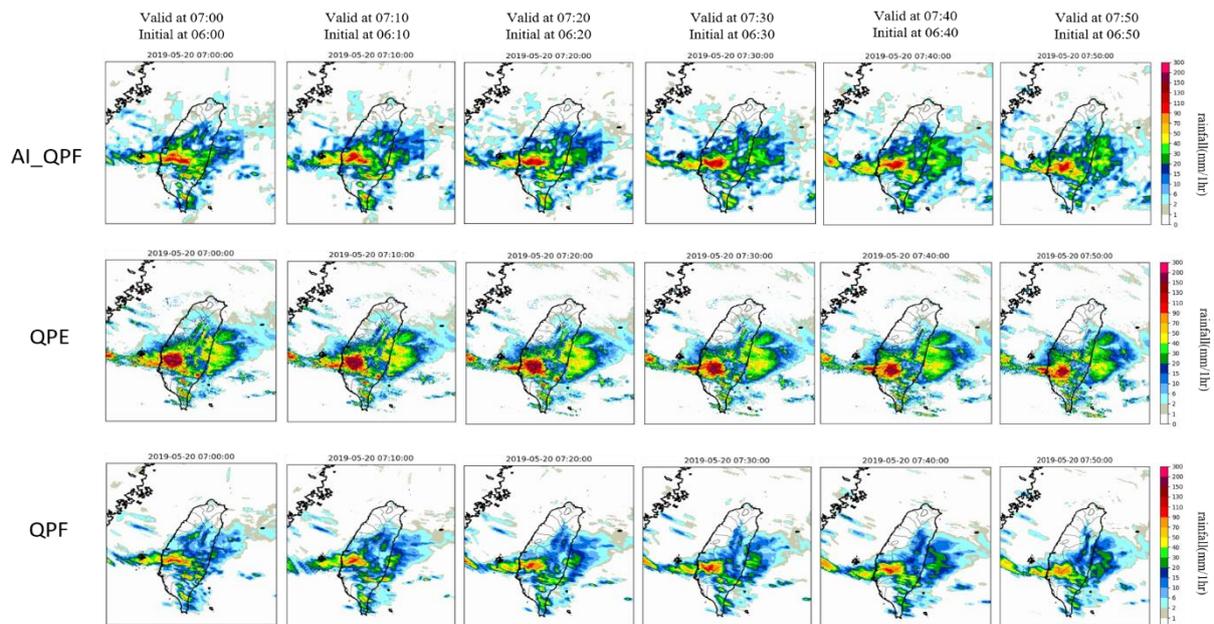


圖 8、同圖 6，但為 2019 年 5 月 20 日 06:00 ~ 06:50 之個案。

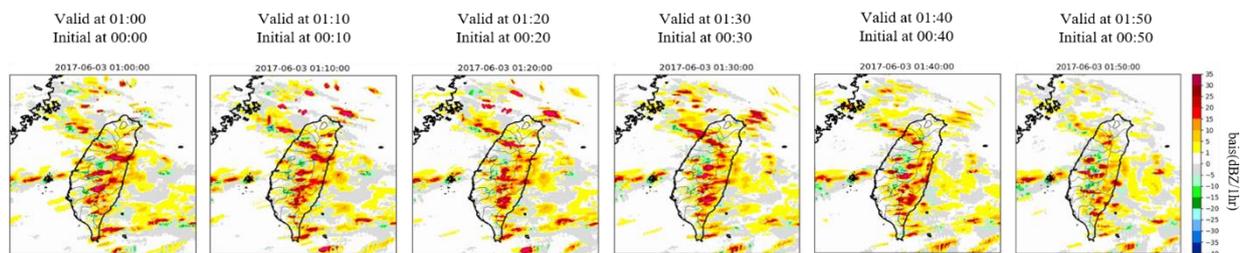


圖 9、同圖 5，但為 2017 年 6 月 1 日 00:00 ~ 00:50 之梅雨個案 bias 分布圖。

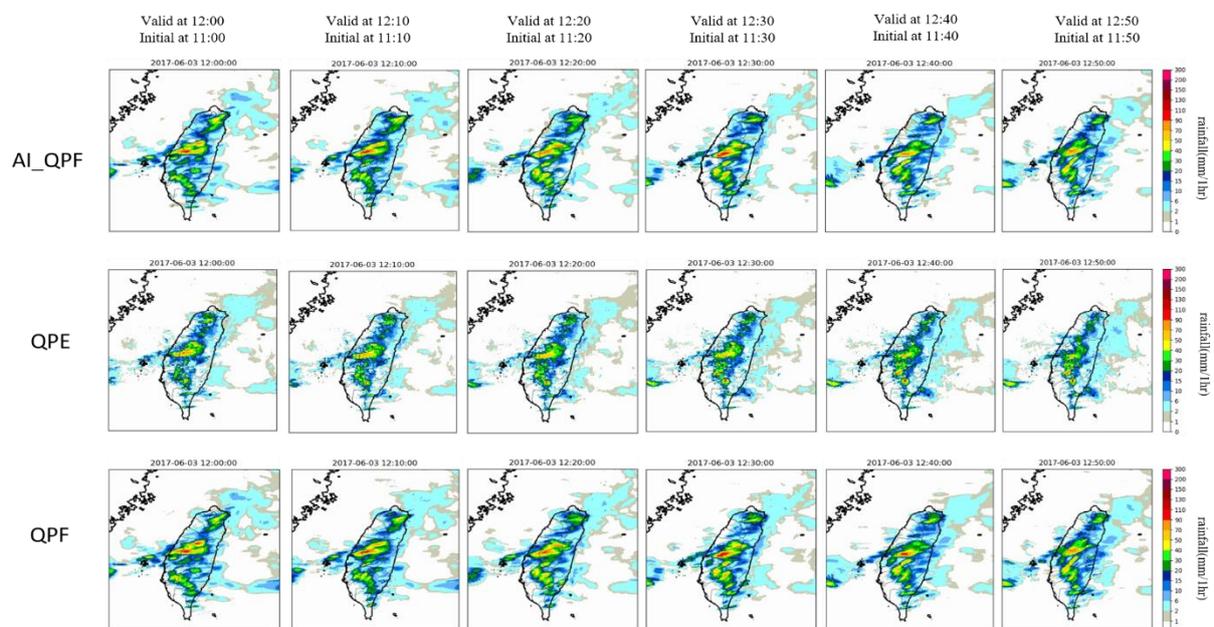


圖 10、同圖 6，但為 2017 年 6 月 3 日 12:00 ~ 12:50 之梅雨個案 bias 分布圖。