

# 基於卷積長短期記憶網路之臺灣複雜地形雷達回波預測

唐欽<sup>1</sup> 簡郁庭<sup>1</sup> 張保亮<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

中央氣象局使用的數值模式預報在短期預測上受到限制，而雷達回波場外延預報只適用於極短期預報，無法對多變的天氣進行準確的預報。近年來深度學習在雷達回波預測上取得不錯成效。然而，沒有相關文獻探討複雜地形中如何對雷達回波建模並預測。

本研究使用深度學習之卷積長短期記憶網路對 2017、2018 和 2019 年的雷達回波資料建立預測模型。在資料預處理中挑選分布台灣各地共二十地點資料，透過捕捉不同地形下的雷達回波狀態，對全台進行未來一小時雷達回波變化之預測。實驗結果顯示(1)本研究所建立之預測模型在泛化能力測試中驗證透過 6~8 月份的回波資料建立之預測模型可預測全年之短延時強降雨區間之雷達回波。(2)在測試時段的 RMSE 與 CSI 均優於氣象局現有之預報技術。上述結果說明本研究所建立之預測模型能夠有效捕捉不同地形下雷達回波的移動趨勢，具有良好的預報能力。

關鍵字：深度學習、雷達回波預測、卷積長短期記憶網路、短延時強降雨

## 一、前言

氣候變遷造成降雨型態的改變，致災型短延時強降雨發生次數越來越高，根據水利署統計結果，臺灣每年發生大豪雨（日雨量約 350 毫米）的次數在民國 88 年以前平均一年發生 35 次，但近年來次數明顯增加，提升至平均一年發生 77 次大豪雨事件。而豐枯水年交替也更加頻繁，從以往的 19 年一循環，縮短為 7 年一循環，降雨強度上升、大豪雨發生次數增加、豐枯不均與旱澇並存的現象越來越嚴重。突然的強降雨會造成排水系統無法負荷而淹水或引發土石流，對民眾的生活造成嚴重的影響，若能準確的預報短延時強降雨的發生，就能提供相關單位制定緊急應變措施，達到降低災害損失的目的。

雷達回波是發射的電磁波經由大氣中降水粒子反射回來的訊號，根據雷達接收到的訊號強度以不同的顏色進行表示，形成雷達回波圖。訊號的強度與降水粒子的大小、形狀、狀態、數量均有關係。一般而言訊號越強，降水的強度就會越強，因此可以透過雷達回波研判降水強度與分布狀況。

中央氣象局目前所使用的預報方法，包含數值天氣模式預報(Numerical Weather Prediction, NWP)和雷達回波場外延預報(Lagrangian Extrapolation of Radar Fields)，而兩者的降水預報能力對不同預報時間長度各有所優勢 (Golding, 1998)。模式預報透過複雜的數學及物理方程式和參數化設定模擬出大氣運動模式，

能夠對 1~3 天之後的天氣做出較準確的預報，但對於極短時（0 至 3 小時）的預報上受到產生初始場的預報時間與初期動力調整(spin-up time)導致預報結果可信度較低；外延預報法是使用觀測到的雷達回波估算位移向量做雷達回波外推進行降水預報，因為無法完整考慮到降水系統的生成與消散作用 (Radhakrishna et al. 2012)，使預報準確度會隨時間拉長而快速下降，不過外延預報法使用的是實際觀測資料進行外延預報，在極短期的預報結果優於模式預報 (潘等 2018)。

中央氣象局目前使用的外延預報法是與美國劇烈風暴實驗室合作發展的雷達 QPF (Quantitative Precipitation Forecast) 技術，但面對臺灣獨特且複雜的中央山脈地形，梅雨鋒面等天氣系統在遭遇到地形阻礙時，會產生局部滯留的強烈回波，造成捕捉天氣系統運動的困難度提升 (方等 2017)。

近年來深度學習被廣泛應用在不同領域上，Xingjian et al. (2015)針對雷達回波的時空特性提出了卷積長短期記憶網路 (Convolutional LSTM, ConvLSTM) 對臨近降水進行預報，此方法是結合能夠保留空間特徵的卷積神經網路(Convolution Neural Network, CNN)與能夠保留時間特徵的長短期記憶網路(Long Short-Term Memory, LSTM)，使模型能夠學習到空間與時間的特性，使用香港上空的雷達回波資料進行模型建立，在預測取得不錯的成效 (Xingjian, et al. 2015)；但在地形上香港與臺灣完全不同，臺灣有多座高度超過 1000 公尺的高山，而香港最高的大帽山高度也低於 1000 公尺。徐 (2019)在研究中使用

ConvLSTM 成功建立一個能夠預測未來一小時內臺灣雷達回波變化的模型，結果優於持續性預報法（徐 2019）。但此研究僅使用單地點對單地點進行訓練與預測，無法有效捕捉不同地形下雷達回波的特性。

由於臺灣地形多變，若要以單點預測單點的方式進行建模，不同地勢、地形就需要建立不同的模型，而這樣的建模方法會導致建立過多的模型，不利於實際應用。因此，本研究針對臺灣使用 ConvLSTM 建立雷達回波預測模型，採用 2017 至 2019 年的 6 至 8 月份二維的雷達回波數值作為訓練資料，考量到臺灣地形複雜在全臺各地挑選不同地勢、地形共計二十個地點同步訓練，對未來一小時的雷達回波強度進行預報，希望能夠改善臺灣地區臨近降水預報準確度。

## 二、雷達回波預測模型

本研究先對資料進行預處理，再使用 ConvLSTM 建立包含各種地勢、地形之二十個地點雷達回波預測模型，並對不同模型複雜度進行誤差分析。

### (一)資料預處理

臺灣的地形高低起伏變化較大，屬於複雜的地形型態，雷達回波會受到地形遮蔽而產生遺失值，本研究選用的雷達回波資料是經過垂直高度壓縮的二維雷達回波資料，因此外圍的遺失值對整體影響不大，將會以零對遺失值進行填補。

資料時間範圍為 2017 至 2019 年，的 6 至 8 月份，當作訓練模型使用的資料。考量到直接使用原始資料矩陣（881x921，約 80 萬個網格點資料）建立預測模型所需的運算資源過於龐大，本研究將從原始資料矩陣中選取出部分代表地區，作為實驗模型的建立。

雷達回波強度在短時間內的消逝與增長是有限的，以包含一般情況下的 7 級風速(13.9~17.1 m/s)一小時內最多可移動 61.56 公里，推算大約需要的範圍後將模型的輸入矩陣大小訂為 55x55。

本研究考慮到臺灣的複雜地形，建立能夠同時對多地點資料進行訓練之模型，使用座落於雨量觀測站的網格點，包含基隆丘陵、臺北盆地、桃園臺地、南投山地、嘉義平原等，不同地勢、地形共計二十個地點，詳細網格點資訊與位置分別如表 1 和圖 1 所示。

表 1 網格格點資訊表

觀測站	緯度(°N)	經度(°E)	地形
恆春	22.0057	120.7383	臺地
新埤	22.4698	120.5748	平原
潮州	22.5361	120.532	平原

大武	22.3574	120.8957	山地
上德文	22.765	120.6964	山地
花蓮	23.9769	121.6051	平原
褒忠	23.6927	120.2955	平原
嘉義	23.4977	120.4248	平原
玉里	23.3233	121.3316	平原
成功	23.0993	121.3653	山地
臺東	22.754	121.1465	平原
日月潭	23.8831	120.8999	山地
北斗	23.8792	120.5065	平原
雪嶺	24.2825	121.0186	山地
梧棲	24.2578	120.5152	平原
新屋	25.0085	121.0393	臺地
臺北	25.0394	121.5066	盆地
板橋	24.9994	12.4338	盆地
基隆	25.1351	121.7322	丘陵
員山	24.7443	121.7224	平原

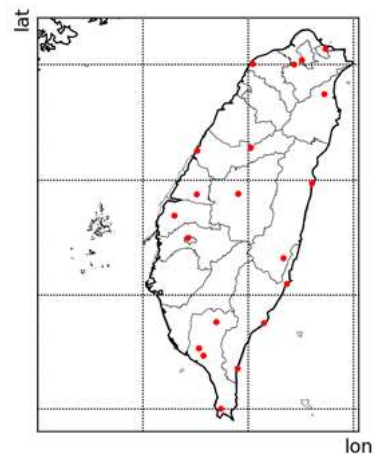


圖 1 網格格點選取地理位置示意圖

### (二)雷達回波預測模型之建立

本研究使用結合空間與時間架構的卷積長短期記憶網路 (Convolutional LSTM, ConvLSTM) 來建立雷達回波預測模型。圖 2 為兩層 ConvLSTM 模型架構圖，以輸入時間顆粒度為每 10 分鐘一筆共六筆時間序

列，隱藏層節點數為 36，卷積核大小為 3x3，輸出時間顆粒度為每 10 分鐘一筆共 6 筆。

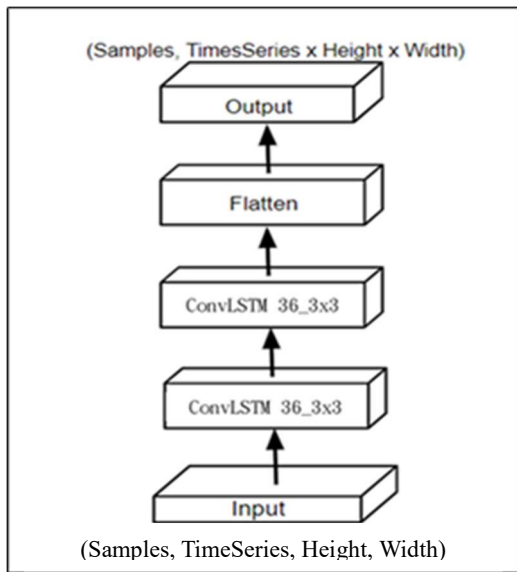


圖 2 ConvLSTM 模型介紹

模型參數關係說明，以圖 3 為例。輸入圖片大小為 6x6x3(RGB)，模型參數中會要求指定 filter (卷積核) 數量，圖中使用 filter 為 2，filter 中可以調整 kernel size、padding、stride..，如圖 kernel size 為 3x3，channel 為 3，而 stride (左至右或上至下移動的步數) 為 1，故所產生 4x4x2 大小的 Feature Maps。從這樣的結構中萃取出特徵可以保留圖片中的空間結構，並利用權重共享的方式減少參數。

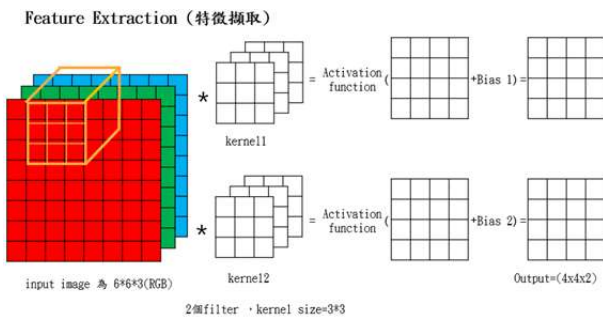


圖 3 模型參數關係說明

本研究僅比較 kernel size，越小的 kernel size 會產生越大的 Feature Maps，複雜度也就越高。而在模型複雜度的選擇上，在固定資料量下，越簡單的模型泛化能力越好，所以在誤差微小的情況下，會選用較簡單的模型。

### (三)ConvLSTM 模型參數

本研究使用的訓練時段為 2017 至 2019 年的 6 至 8 月份，測試時段為 2018 年 3 月 13 日 (日雨量低於 10 毫米，降雨分級為小雨)、2018 年 8 月 24 日 (日雨量高於 80 毫米，降雨分級為大雨)，訓練地點包含不同海拔高度的丘陵、盆地、臺地、山地、平原等，共二十個地點，詳細網格點資訊與位置如表 1。輸入矩陣大小 55x55，輸出矩陣中心大小 1x1，輸入時間序列長度為 6 (時間顆粒度為每 10 分鐘一筆)、輸出時間序列長度為 6 (時間顆粒度為每 10 分鐘一筆)，建立預測模型，詳細參數如表 2 所示。

表 2 ConvLSTM 模型參數

ConvLSTM 模型參數		
時段	訓練時段	2017 至 2019 年 6 月至 8 月份
	測試時段	2017 年 5 月 15 日、9 月 15 日、10 月 15 日、11 月 15 日； 2018 年 3 月 13 日、5 月 15 日、8 月 24 日、9 月 15 日、10 月 15 日、11 月 15 日； 2019 年 5 月 15 日、9 月 15 日、10 月 15 日、11 月 15 日
輸入	矩陣大小	55x55
	時間序列長度	6 (時間顆粒度 10 分鐘一筆)
輸出	矩陣大小	1x1
	時間序列長度	6 (時間顆粒度 10 分鐘一筆)
第一層節點數		36
第二層節點數		36
kernel size		3x3、5x5、7x7
激發函數		tanh
損失函數		RMSE
優化器		adam
地點		20 個測站

### (四)雷達回波模型評估標準

#### 1. 臨界成功指數

氣象預報上，驗證預報是否準確的評估標準較常是以臨界成功指數(Critical Success Index, CSI)為基準，此標準是 Joseph 等人在 1990 年提出 (Schaefer 1990)，在不同的雷達回波強度門檻下以發佈預報和實際觀測結果的混淆矩陣為基礎做計算，如表 3 所示，其中 a 和 d 皆表示命中(Hits)，b 為預報錯誤(False Alarms)，c 為漏報(Misses)，而 CSI 預報準確度判斷如公式(1)：

表 3 混淆矩陣

實際觀測與預報組合		
觀測(O) \ 預報(P)	O ≥ th	O < th
P ≥ th	命中(a)	誤報(b)
P < th	漏報(c)	命中(d)

註：th = 回波強度門檻值

$$CSI = \frac{a}{a+b+c} \quad (1)$$

莊 (2015) 在研究中提到, CSI 指數介於 0~1 之間, CSI 指數得分越高表示在該門檻的預報技術越佳。而 CSI 指數在 0.2 以上表示該預報在此門檻值具有預報技術; 於 0.1 至 0.2 之間表示有一點預報技術; 若低於 0.1 表示預報在此門檻值預報技術不佳; 若為 0 則表示在此門檻值沒有預報技術 (莊 2015)。

## 2. 均方根誤差

本研究使用均方根誤差(Root Mean Square Error, RMSE)作為模型的修正依據, 機器學習領域中多以 RMSE 當作回歸模型的評估標準, RMSE 越趨近於零表示預測結果與實際值的差距越小、模型的預測能力越好, 如下公式(2)：

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

## 三、實驗結果與討論

本研究實驗參數如表 2, 實驗結果在 kernel size 為 3x3 時, 訓練誤差為 3.5551, 測試誤差為 5.2319, 驗證誤差為 4.9151; 在 kernel size 為 5x5 時, 訓練誤差為 3.2398, 測試誤差為 5.2072, 驗證誤差為 4.7998; 在 kernel size 為 7x7 時, 訓練誤差為 3.4928, 測試誤差為 4.9816, 驗證誤差為 4.8521。詳細的實驗結果如表 4 所示。三者誤差無明顯差異, 後續實驗選用較簡單 kernel size 為 7x7 的模型。

表 4 實驗結果

Kernel size	訓練誤差	驗證誤差	測試誤差
3x3	3.5551	4.9151	5.2319
5x5	3.2398	4.7998	5.2072
7x7	3.4928	4.8521	4.9816

## (一) 泛化能力測試

本研究訓練時段為 2017 至 2019 年的 6 至 8 月份, 避免 6 至 8 月份資料相似性過高, 使用測試時段 2017 至 2019 年 5 月、9 月、10 月、11 月逐月的 15 日, 共計 12 天進行模型泛化能力測試。

泛化能力測試之 RMSE 為 5.4010, CSI 結果顯示如圖 4, 在門檻值 40 以下, CSI 都能表現在 0.1 以上, 具有預報技術, 證實 6 至 8 月份資料就足以代表臺灣地區短延時強降雨好發的所有月份 (5 至 11 月)。

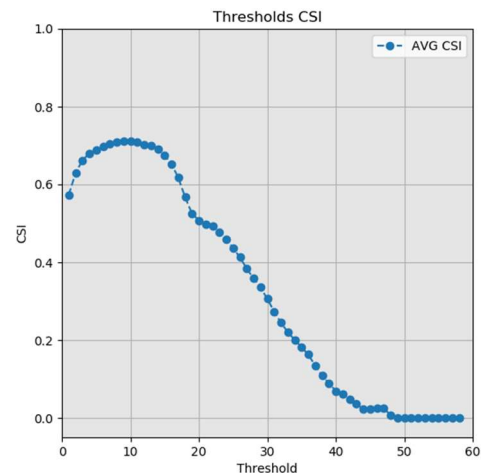


圖 4 模型泛化能力測試平均 CSI, 水平軸為回波值 dBZ。

## (二) 以個案與氣象局現有之預報技術進行比較

使用測試時段 2018 年 3 月 13 日 (日雨量低於 10 毫米, 降雨分級為小雨)、2018 年 8 月 24 日 (日雨量高於 80 毫米, 降雨分級為大雨), 對模型結果與氣象局現有之預報技術進行比較。

個案一, 在 2018 年 3 月 13 日時, 預測模型的 RMSE 為 2.6104; 而氣象局現有預報技術的 RMSE 為 4.6486。CSI 結果如圖 5 所示, 藍線為預測模型之 CSI; 橘線為氣象局現有預報技術之 CSI。在門檻值 20 以下, 預測模型的 CSI 值介於 0.1 至 0.8 之間; 而氣象局現有預報技術的 CSI 值介於 0.1 至 0.4 之間。

2018 年 3 月 13 日沒有發生高於門檻值 20 的雷達回波強度, 因為 CSI 公式不考慮在該門檻值沒有雷達回波時, 準確預測出無雷達回波 (d) 的狀況, 所以 CSI 值的表現為 0 才是正確的預報結果。但本研究預測模型與氣象局所使用的雷達回波場外延預報方法不同, 在深度學習方法中易受模型權重影響導致預測結果為趨近於 0 而不等於 0 的雷達回波值, 所以在該門檻值無雷達回波的情況下會有誤報的情形發生。

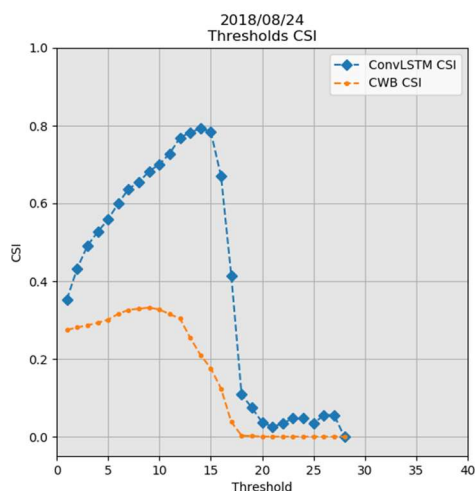


圖 5 測試時段 CSI 結果  
(時段為 2018 年 3 月 13 日，降雨分級為小雨)

個案二，在 2018 年 8 月 24 日時，預測模型的 RMSE 為 6.4446；而氣象局現有預報技術的 RMSE 為 17.0503。CSI 結果如圖 6 所示，藍線為預測模型之 CSI；橘線為氣象局現有預報技術之 CSI。在門檻值 20 以下，預測模型的 CSI 值均能保持在 0.7 以上；而氣象局現有預報技術的 CSI 值僅介於 0.3 至 0.6 之間。在門檻值 20 以上，預測模型的 CSI 值能保持在 0.1 至 0.7 之間；而氣象局現有預報技術的 CSI 值僅介於 0.0 至 0.3 之間。




圖 6 測試時段 CSI 結果  
(時段為 2018 年 8 月 24 日，降雨分級為大雨)

綜上所述，在測試時段下本研究建立之預測模型在大雨與小雨的情況下，RMSE 與 CSI 的表現均優於氣象局現有之預報技術。

### (三) 全台雷達回波可視化

本研究僅使用臺灣各地不同地勢、地形之二十個地點，希望能用此模型對全臺所有網格點做出準確的預報。以測試時段 2018 年 8 月 24 日的 00 點 00 分預測未來一小時，矩陣以日月潭觀測站為中心向外延伸 315x315 進行預測。模型預測 (ConvLSTM) 與氣象局現有預報技術(CWB)結果如圖 7 所示，依序為預測第一筆 (未來 10 分鐘，T+1) 至第六筆 (未來 60 分鐘，T+6)。第二列為 2018 年 8 月 24 日 00 點 10 分至 2018 年 8 月 24 日 01 點 00 分的真實值(GT)。

	T+1	T+2	T+3	T+4	T+5	T+6
GT						
Conv-LSTM						
CWB						

圖 7 全臺雷達回波預測結果

結果顯示，本研究建立之預測模型成功捕捉不同地勢、地形下雷達回波的移動趨勢，能夠對全臺所有網格點作出準確之預報，RMSE 為 8.3438，優於氣象局現有之預報技術 (RMSE 為 14.2137)。但隨著預測時間增加，預測第三筆 (未來 30 分鐘，T+3) 後，相較於氣象局現有預報技術，預測模型的準確度會逐漸下降，無法精準預測雷達回波移動方向。推測是 ConvLSTM 模型架構對於較短時間的預測能夠捕捉空間與時間的特徵變化，但在長時間的預測受到限制。

## 四、結論與建議

為了提升臺灣複雜地形下雷達回波預測準確度，以 ConvLSTM 方法對二十個不同地勢、地形的地點建立雷達回波預測模型，使用 2017 至 2019 年的 6 至 8 月份資料進行模型訓練，建立了以過去一小時雷達回波序列資料，預測未來一小時雷達回波強度之預測模型。

本研究所建立之預測模型能夠有效捕捉不同地形下雷達回波的移動趨勢。在泛化能力測試中驗證透過 6~8 月份資料建立的預測模型足以對全年短延時強降雨月份做出準確的預報，具有良好的預報能力。在測試時段的 RMSE 與所有門檻值下的 CSI 值表現均優於氣象局現有預報技術。證實深度學習方法應用於臺灣

複雜地型之雷達回波強度預測是可行的。

本研究使用 ConvLSTM 僅針對未來一小時雷達回波強度進行預報，但若要達到可實際上線操作的標準，需要能對全臺所有網格點做全年度的預測，並且準確的預報未來 1 至 3 小時。

相較於氣象局現有技術預報，本研究預測模型會隨著預測時間增加，出現難以捕捉雷達回波移動趨勢的情況，推測是 ConvLSTM 模型架構對於較短時間的預測能夠捕捉空間與時間的變化，但在長時間的預測受到限制。對於未來改進方向，可以挑選地形劇烈改變的地點做遷移式學習；而模型優化方面，可以嘗試使用其他深度學習方法進行預測，如 GRU、PredRNN、GAN，並改變輸入時間長度或時間顆粒度，調整模型複雜度使預報時間拉長。希望能夠拉長預報時間，同時提高預測準確度。

## 參考文獻

- 方偉庭、王忠斌、張保亮，2017：雷達定量降水預報外延技術之評估與改進。106 年天氣分析與預報研討會，中央氣象局。
- 徐紹恩，2019：以深度學習進行雷達回波時空序列變化之研究。中興大學資訊管理學系所學位論文，1-41。
- 莊璧瑜，2015：雲解析模式對臺灣梅雨季豪大雨定量降水預報技術之評估研究。
- 潘俊璋、鍾高陞、林欣弘、陳台琦、姚奕安，2018：雷達回波變分追蹤法應用於臺灣複雜地形環境下之可行性評估。大氣科學，46(1), 1-34。
- Golding, B. W.,(1998: Nimrod: A system for generating automated very short range forecasts. *Meteorological Applications: A journal of forecasting, practical applications, training techniques and modelling*, 5(1), 1-16.
- Radhakrishna, B., Zawadzki, I., & Fabry, F., 2012: Predictability of precipitation from continental radar images. Part V: Growth and decay. *Journal of the atmospheric sciences*, 69(11), 3336-3349.
- Schaefer, J. T.,1990: The critical success index as an indicator of warning skill. *Weather and forecasting*, 5(4), 570-575.
- 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* (pp. 802-810).

# **Spatiotemporal Radar Echo Forecasting Based on Convolutional LSTM over Taiwan's complex terrain**

## **Abstract**

The numerical weather prediction(NWP) system used by the Central Weather Bureau(CWB) are limited in short-term forecasts, while the forecasts of radar echo extrapolation are only suitable for extremely short-term forecasts, and cannot accurately forecast the changing weather. In recent years, deep learning has achieved good results in radar echo prediction. However, there is no relevant literature discussing how to model and predict radar echoes in complex terrain.

This research uses convolutional long short-term memory (ConvLSTM) networks to build predictive models for radar echo data in 2017, 2018 and 2019. In the data preprocessing process, the data of 20 locations in all parts of Taiwan are selected, and the radar echo changes in the next hour are predicted for the whole station by capturing the state of radar echoes under different terrains. The experimental results show that (1) It is verified in the generalization ability test that the proposed prediction model established through the echo data from June to August can predict the short-duration heavy rainfall throughout the year. (2) the proposed prediction model is better than the existing prediction technology of the CWB in the test period of RMSE and CSI. The above results indicate that the prediction model established by this research can effectively capture the movement trend of radar echoes under different terrains and has good prediction capabilities.

Keywords: ConvLSTM, deep learning 、 radar echo prediction, short-duration heavy rainfall