

深度學習模型的損失函數權重調整對雷達回波強度預測之影響

簡郁庭¹ 張保亮² 林冠成¹
國立中興大學資訊管理學系¹ 中央氣象局²

摘要

中央氣象局使用雷達回波外延法推估降水預報，但是大氣系統為複雜非線性，而外延法預報法採用簡單外推計算雷達回波強度，導致預報能力會隨時間拉長而快速下降。近年來深度學習中的時空序列模型因為能夠同時捕捉時空關係而被廣泛應用在雷達回波預測中，然而，預測結果容易產生低報與不準確情況。本研究使用預測遞歸神經網路(Recurrent Neural Networks for Predictive Learning using Spatiotemporal LSTMs, PredRNN)時空序列模型結合兩種機制，包含加權損失函數與雙重注意力機制，並透過持續學習提升高強度回波預測能力，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)本研究建立之 PredRNN 結合兩種機制在多個個案中均能夠成功捕捉雷達回波移動趨勢，提升高強度雷達回波預測準確度。(2) PredRNN 結合兩種機制與持續學習模型在個案中的 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提升高強度回波預測能力。

關鍵字：雷達回波外延法、時空序列模型、預測遞歸神經網路、持續學習

一、前言

受到全球氣候變遷的影響，各地的溫度、降雨量，以及海平面在過去數十年至百年間呈現漸進卻明顯的變化，近年來全世界各地更頻傳極端氣候所釀成之災害(例如：水災、颱風、乾旱、熱浪等)。

根據 109 年災害防救白皮書(行政院災害防救辦公室, 2018)資料顯示，台灣的極端天氣事件中，颱風與豪雨對於臺灣各地造成重大災情。針對 1958 年至 2017 年臺灣歷年天然災害數量進行分析(內政部消防署 2018, 2018)，颱風的數量最多，而不同的降雨特性，所造成的災害類型也不一樣，長延時強降雨所累積的總雨量容易導致淹水、土石流等，短延時強降雨則可能會在局部地區造成極大的災情。

短時間內發生豪大雨使得防範更加困難，為了加強短延時強降雨防範預警，於 2020 年中央氣象局為針對豪雨中之大豪雨再增列「3 小時累積雨量達 200 毫米以上」之雨量標準，以提高各界對降雨災害的警覺，強化防救災應變處置效能(中央災害防救會報, 2020)。

中央氣象局長期與美國劇烈風暴實驗室合作發展短期預報技術，藉由結合台灣地區之雷達合成回波、定量降水估計的資訊，提供極短時定量降水預報，不僅可以協助政府相關單位提前發佈緊急避難通知，還能夠告知民眾災害發生的具體位置，降低人員傷亡與財物損失(方偉庭等人, 2017)。

極短期定量降水預報技術的方法主要有兩種，

第一種為數值模式預報，模式預報是經過動力和物理過程的方程式，模擬計算可供參考的雨量預報。然而，數值模式在系統模擬初期會有漸進調整的階段(spinup);同時，數值模式的時間和空間解析度較大，無法解析小尺度或短時間的系統變化。上述兩個原因造成數值模式在 3 到 6 小時的降雨預報能力較差，而在 12 小時後的累積降雨預報會較具參考價值(陳新淦等, 2016)。

第二種方法為雷達回波外延法，此技術的輸入資料為整合回波資料，由過去回波之移向及移速推估平移向量計算回波強度，後續再套入 Z-R 關係式以推估未來降水預報。適用移動及強度持續之系統，在 3 小時內的降雨預報一般具有較高的技術表現(陳新淦等, 2016)。

近年來深度學習被廣泛應用在不同領域上，Xingjia 等人針對雷達回波的時空特性提出卷積長短期記憶網路(Convolutional LSTM, ConvLSTM)進行臨近降水預報，模型將輸入資料以卷積進行運算，使資料能夠保持三維形狀，並透過四個閘門更新資訊，讓模型能夠學習序列型態的影像資訊(Xingjian, et al., 2015)。然而，Wang 等人表示，ConvLSTM 模型架構中有時空資料記憶的缺陷，始得無法記憶長期時空關係，造成模糊且不準確的情形(Wang, et al., 2017)。Tang 等人表示，使用 ConvLSTM 模型，以面對點模型預測全台雷達回波，預測結果隨著預報時段拉長，逐漸模糊(Tang et al., 2020)。

Wang 等人基於 ConvLSTM 模型提出修正 PredRNN，作者透過特殊模型堆疊結構傳輸記憶，並

使用 ST-LSTM 對時間序列資料建模，同時提取和空間和時間資訊，提高預測準確度，實驗資料為中國廣州上空的雷達回波灰階圖像，以過去一小時雷達回波預測未來一小時雷達回波，準確度優於 ConvLSTM (Wang, et al., 2017)。

在模型優化方面，Wang 等人提出 PredRNN++優化 PredRNN (Wang et al., 2018)，另外 Wang 等人提出 MIM (Wang, et al., 2019)，上述模型均是修改 ConvLSTM 架構與資料傳輸方式，以複雜的模型提升捕捉雷達回波移動能力。

本研究預測範圍涵蓋完整台灣上空與鄰近海面，使用的數值資料矩陣範圍較大、資料運算成本較高、運算耗時，且因為全台均有下雨的情況較少，導致高強度雷達回波資料量較少，因此本研究不採用。

上述預測雷達回波強度之深度學習模型，普遍都存在兩個重大問題。第一，高強度回波預測易產生低報；第二，高強度雷達回波之預測區域具有消失的趨勢。如果實際用於降水預測，難以對強降雨做出準確預報。

Luo 等人提出高強度回波低報歸納為兩個原因。第一：卷積循環神經網絡 (ConvRNN) 中的各個門都是通過對輸入和隱藏狀態的獨立卷積以及求和融合生成的，但獨立卷積具有局限性，輸入狀態和隱藏狀態不會互相幫助來標識和保留重要信息。第二：遺忘閘門將高強度雷達回波丟棄信息，而此過程是不可逆的，因此，使用 PredRNN 時空序列模型結合雙重注意力機制 IDA-LSTM 模型能提升預測能力與改善雷達回波低報問題 (Luo et al., 2021)。

另外，針對資料不平衡所導致的高強度回波低報問題，除了修改模型外，Shi 等人分析資料集後將大雨資料的損失函數給予較高權重，以利學習高強度回波資料，提升高強度雷達回波預測能力 (Shi et al., 2017)。

本研究將使用 PredRNN 建立預測模型，結合兩種方法提升高強度雷達回波預測能力，第一：增加注意力機制；第二：使用加權損失函數給予高強度雷達回波較大的權重。希望透過上述方法改善現有深度學習模型中雷達回波預測的模糊與不準確問題。

二、雷達回波預測模型

本研究先對資料進行預處理，再分別建立三種模型 PredRNN、PredRNN+加權損失函數+雙重注意力機制(以下簡稱為 PredRNN+兩種機制)、PredRNN+加權損失函數+雙重注意力機制+持續學習(以下簡稱為 PredRNN+兩種機制+持續學習)，本章節將分別以資料預處理、加權損失函數、模型參數、雷達回波模型評估標準進行說明。

(一)資料預處理

資料時間範圍為 2017 至 2018 年，並從中選出

2017 至 2019 年降雨日當作訓練模型使用的資料，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。

為了準確預測台灣上空雷達回波，故選取範圍涵蓋台灣與鄰近海面資料，以日月潭為中心，向上、下延伸 256 個網格點，往東、西延伸 256 個網格點，形成 512x512 個網格點，如圖 1 所示。

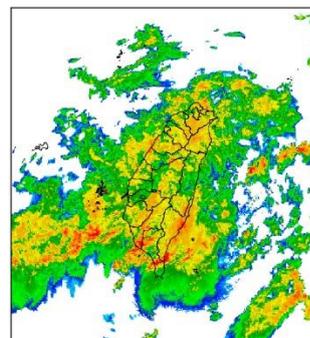


圖 1 輸入資料示意圖

(二)雷達回波預測模型之建立

1.雷達回波模型說明

為了提升雷達回波預測準確度，分別建立三種模型 PredRNN、PredRNN +兩種機制、PredRNN +兩種機制+持續學習，並與氣象局現有技術同時進行比較，各模型說明表 1 所示。

表 1 模型說明

模型	說明
PredRNN	(1) Conv-LSTM 改良之模型 (2) 使用較複雜模型捕捉特徵
PredRNN +兩種機制	(1) 基於 PredRNN (2) 結合加權損失函數，給予高強度回波較高權重 (3) 結合雙重注意力機制，保留細節特徵
PredRNN +兩種機制 +持續學習	(4) 基於 PredRNN+雙重注意力機制，以保留細節特徵。 (5) 持續學習：擴增資料並找到模型適合之凍結層數，例如：凍結前三層 PredRNN + 雙重注意力機制，只訓練最後一層 PredRNN + 雙重注意力機制權重。 (6) 根據擴增資料後的雷達回波資料分析出雷達回波強度分類和對應的權重值

2.加權損失函數

雷達回波預測中，高強度雷達回波過少而低強度雷達回波資料過多，導致雷達回波資料不平衡。針對資料不平衡所導致的高強度回波低報問題，除了修改

模型外，Shi 等人分析資料集，根據雨量大小分類修正損失函數(Shi et al., 2017)。損失函數以均方誤差(Mean Square Error, MSE)為基礎，如公式(1)。

$$MSE = \frac{1}{N} \sum_{i=1}^N w(y_i - \hat{y}_i) \quad (1)$$

將降雨分類並給予不同權重，藉以提升模型對高強度回波的預測能力，加權損失函數權重如表 2 所示。本研究根據其降雨區間使用 Z-R 關係式推估 dBZ，再參考論文中各區間的權重設定。

表 2 加權損失函數權重

降雨量 (mm/h)	佔總資料比例	權重比重 (w(x))
0 ≤ x < 0.5	90.25%	1
0.5 ≤ x < 2	4.38%	1
2 ≤ x < 5	2.46%	2
5 ≤ x < 10	1.35%	5
10 ≤ x < 30	1.14%	10
30 ≤ x	0.42%	30

PredRNN+兩種機制模型訓練時段為 2017~2019 降雨日訓練，本研究參考 Shi 等人設計加權損失函數 (Shi et al., 2017)，將降水換算雷達回波 (dBZ)，因為該論文地點為香港，與台灣天氣型態不同，且本研究為挑選降雨日資料，高強度雷達回波資料較多，因此增加一類 (45 ≤ x)，提升模型對高強度回波的預測能力，詳細資料如表 3 所示。

表 3 雨量與雷達回波區間權重比重

雷達回波值 (dBZ)	2017~2019 年雷達回波強度比例	權重比重 (w(x))
0 ≤ x < 12	68.5%	1
12 ≤ x < 22	10.9%	1
22 ≤ x < 28	7.07%	2
28 ≤ x < 33	5.87%	5
33 ≤ x < 40	5.71%	10
*45 ≤ x	0.5%	*50

*本實驗調整範圍

加權損失函數各區間權重根據持續學習所擴增後的資料進行挑整，本研究將 PredRNN+兩種機制+持續學習訓練時段增加至 2014~2019 年降雨日，整體高強度雷達回波資料較 2017~2019 年資料多，因此另外增加一類(50 ≤ x)，此外，為了解決因權重比重增加導

致的損失函數無法收斂問題，降低(40 ≤ x < 45)權重比例，詳細資料如表 4 所示。

表 4 修正後加權損失函數權重

雷達回波值 (dBZ)	2014~2019 年降雨日	權重比重 (w(x))
0 ≤ x < 12	64.13%	1
12 ≤ x < 22	11.99%	1
22 ≤ x < 28	7.93%	2
28 ≤ x < 33	6.75%	5
33 ≤ x < 40	6.82%	10
40 ≤ x < 45	1.73%	*20
45 ≤ x < 50	0.53%	50
*50 ≤ x	0.08%	*70

*本實驗新增之範圍

(三)模型參數

訓練時段為 2017~2019 年降雨日，而持續學習訓練時段擴增 2014~2016 年降雨日，使資料擴增至 2014~2019 年。個案測試時段挑選非訓練時段 2018 年 8 月 24 日與 2020 年 5 月 27 日。

為了使矩陣涵蓋台灣上空與臨近海面，輸入與輸出矩陣大小設為 512x512，考量資料量與建立模型的運算成本，將輸入、輸出時間序列長度均設為 6，時間解析度為 10 分鐘一筆，過去一小時預測未來一小時，詳細訓練資料參數如表 5 所示。

表 5 模型參數

資料參數				
時段	訓練時段	2017~2019 降雨日訓練		
	持續學習訓練時段	2014~2019 降雨日訓練		
	個案測試時段	2018 年 8 月 24 日 00 點 00 分 2020 年 5 月 27 日 00 點 00 分		
輸入	矩陣大小	512X512	輸入時間序列長度	6 (時間解析度 10 分鐘一筆)
輸出	矩陣大小	512X512	輸出時間序列長度	6 (時間解析度 10)

				分鐘一筆)
--	--	--	--	-------

(四)雷達回波模型評估標準

1. 臨界成功指數

在氣象預報上，驗證預報是否準確常以臨界成功指數 (CSI) 作為評估標準，此標準是在不同的雷達回波強度門檻下以預報和實際觀測結果的混淆矩陣為基礎做計算 (Schaefer, 1990)，如表 6 所示，其中 a 表示預測正確 (Hits)，預測結果與觀測值均高於門檻值；b 表示誤報 (False Alarms)，觀測值低於門檻值，而預報結果高於門檻值，c 表示漏報 (Misses)，觀測值高於門檻值，而預報結果低於門檻值，d 表示預測正確 (Hits)，預測結果與觀測值均低於門檻值。

臨界成功指數 (CSI) 得分介於 0 到 1 之間，得分越接近 1 表示預報能力越好，CSI 預報準確度判斷如下公式 (13)：

表 6 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

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

2. 均方根誤差

本研究使用均方根誤差 (Root Mean Square Error, RMSE) 作為個案測試中的評估標準，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 (12)。

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

三、實驗結果與討論

本節將介紹本研究挑選之降水個案，根據中央氣象局網站所提供之日雨量，雷達回波觀測結果進行說明與討論，個案分別是雷達回波具有旋轉趨勢之個案 2018 年 8 月 24 日 00 點 00 分、梅雨大兩個案 2020 年 5 月 27 日 00 點 00 分，觀察各種模型在不同個案時段之預測結果，分別以 CSI、RMSE、雷達回波圖進行分析。

(一) 個案一：2018 年 8 月 24 日 00 點 00 分

挑選非訓練時段之 2018 年 8 月 24 日 00 點 10 分預測未來一小時，CSI 結果如圖 2 所示。在門檻值 40 以下，PredRNN+兩種機制+持續學習、PredRNN+兩種機制無明顯差異，門檻值 40dBZ 以上，PredRNN+兩種機制+持續學習明顯優於 PredRNN+兩種機制、OP。

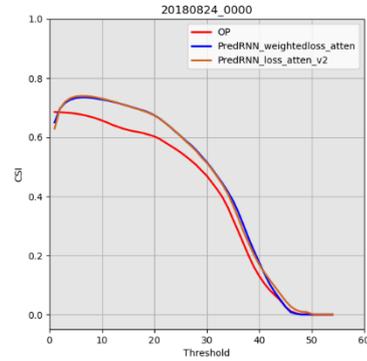


圖 2 測試時段 CSI 結果

此個案相較於外延預報法 (OP)，PredRNN+兩種機制+持續學習在高、低強度回波預測結果均優於外延預報法 (OP)。在門檻值為 45 時，PredRNN+兩種機制+持續學習 CSI 為 0.0701，改善程度為 44.91%，PredRNN+兩種機制 CSI 為 0.0507，改善程度為 4.88%，如表 7 所示。

表 7 各種預報機制 dBZ 改善程度

模型	OP	PredRNN+兩種機制		PredRNN+兩種機制+持續學習	
		CSI	改善程度	CSI	改善程度
門檻值	CSI	CSI	改善程度	CSI	改善程度
20	0.608	0.683	12.33%	0.681	12.09%
30	0.487	0.535	9.89%	0.532	9.12%
40	0.161	0.215	33.84%	0.203	26.06%
45	0.0484	0.0507	4.88%	0.0701	44.91%

各模型預測結果之 RMSE 無明顯差異，但使用加權損失函數有提高的現象，推測為低強度降雨導致的高報問題所造成，如表 8 所示。

表 8 各種預報機制之 RMSE

	OP	PredRNN+兩種機制	PredRNN+兩種機制+持續學習
RMSE	8.966	7.589	7.799

雷達回波圖示結果是以日月潭觀測站為中心向外

延伸 512x512 進行預測。如圖 3 所示，依序為 2018 年 8 月 24 日 00 點 10 分至 2018 年 8 月 24 日 01 點 00 分，每 10 分鐘一筆。雷達回波真實值 (OBS) 顯示回波有順時針旋轉的趨勢，高強度雷達回波發生於台南、高雄、屏東、屏東外海地區。

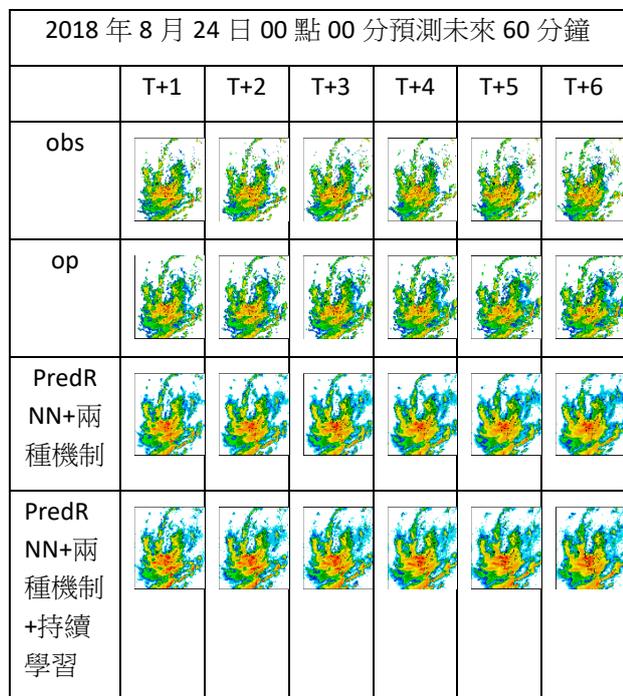


圖 3 測試時段雷達圖示化結果

(二) 個案二：2020 年 5 月 27 日 00 點 00 分

挑選非訓練時段之 2020 年 5 月 27 日 00 點 00 分預測未來一小時，CSI 結果如圖 4 所示。在門檻值 30 以下，PredRNN+兩種機制+持續學習與 PredRNN+兩種機制無明顯差異，在門檻值 30 至 40 間，PredRNN+兩種機制+持續學習明顯優於 PredRNN+兩種機制，但在門檻值 45 以上略低於 OP。

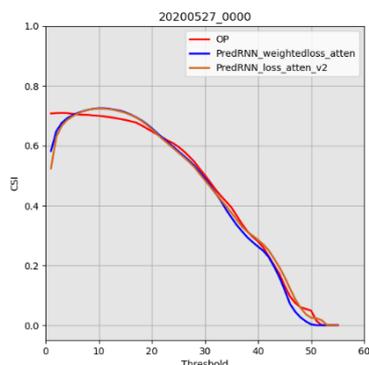


圖 4 測試時段 CSI 結果

此個案相較於外延預報法 (OP)，PredRNN+兩種機制在門檻值 30 以上均低於外延預報法 (OP)；而 PredRNN+兩種機制+持續學習在高強度回波有明顯改善，在門檻值為 40 時，PredRNN+兩種機制+持續學

習 CSI 為 0.299，改善程度為 1.32%；在門檻值為 45 時，PredRNN+兩種機制+持續學習 CSI 為 0.194，改善程度為 13.1%，如表 9 所示。

表 9 各種預報機制 dBZ 改善程度

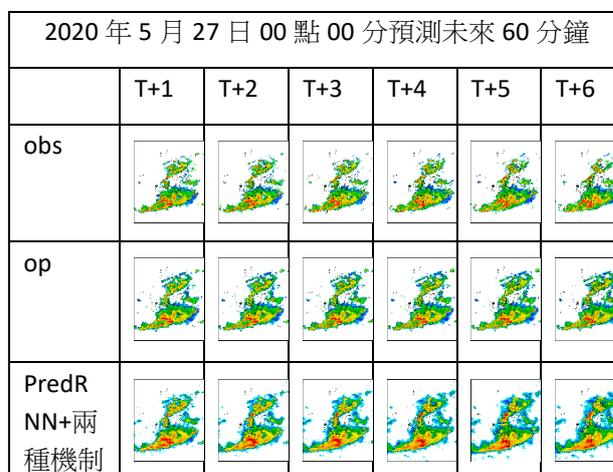
模型	OP	PredRNN +兩種機制		PredRNN +兩種機制 +持續學習	
		CSI	改善程度	CSI	改善程度
門檻值					
20	0.658	0.672	2.21%	0.67	1.86%
30	0.523	0.512	-2%	0.505	-3.18%
40	0.295	0.277	-5.95%	0.299	1.32%
45	0.172	0.161	-6.26%	0.194	13.1%

各模型預測結果之 RMSE 無明顯差異，但使用加權損失函數有提高的現象，推測為低強度降雨導致的高報問題所造成，如表 9 所示。

表 9 各種預報機制之 RMSE

	OP	PredRNN +兩種機制	PredRNN +兩種機制 +持續學習
RMSE	5.758	5.919	6.237

雷達回波圖示結果是以日月潭觀測站為中心向外延伸 512x512 進行預測。如圖 5 所示，依序為 2020 年 5 月 27 日 00 點 10 分至 2020 年 5 月 27 日 01 點 00 分，每 10 分鐘一筆。雷達回波觀測值(OBS)由西南往東北方向移動，整體移動方向一致，只有在 T+5 與 T+6 屏東上空回波強度變化較為明顯。高強度雷達回波發生在屏東、台中地區。



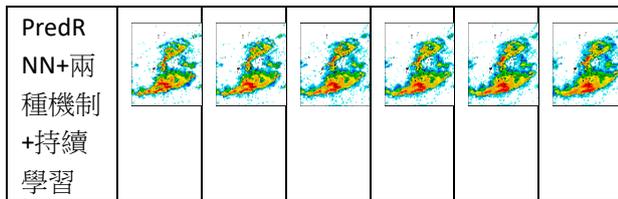


圖 5 測試時段雷達圖示化結果

在兩個個案中，相較於外延預報法（OP），PredRNN 會因為低報，導致無法準確預測，但能捕捉整體回波移動方向，PredRNN+兩種機制在門檻值 30 到 40 區間，CSI 改善程度較大，推測適合用於中強度雷達回波預測，PredRNN+兩種機制+持續學習在門檻值為 30、40 與 PredRNN+兩種機制無明顯差異，在門檻值為 40 到 45 區間，CSI 改善程度較大，有效提升高強度回波預測能力，優於外延預報法。

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。

四、結論與建議

本研究為了解決雷達回波類別不平衡與預測模型低報問題，改良預測遞歸神經網路時空序列模型並結合雙重注意力機制，同時將損失函數修改為加權損失函數，並根據臺灣範圍雷達回波調整分類與權重，建立雷達回波預測型，對未來一小時進行全臺雷達回波強度預測。

為了提升高強度回波預測準確度，針對資料量與加權損失函數權重的相對關係進行模型訓練，並在四個不同天氣變化型態的個案中進行測試，比較觀測結果、外延預報法，驗證模型是否有泛化能力。

實驗結果顯示，本研究所提出之預測模型能夠成功捕捉雷達回波的移動、旋轉能力。相較於外延預報法，本研究所提出之預測模型在門檻值 40 到 45 區間，CSI 改善程度較大，表示能有效提升高強度回波預測能力，且模型在多數個案優於外延預報法，驗證模型具有氣象預報能力。

然而，預測模型與外延預報法均無法準確預測快速生成、消散之雷達回波，進而導致預測可能產生高強度回波低報、低強度回波高報之情形。在未來改善方向中，分別以資料、模型面向進行探討。

資料方面，除了使用持續學習方法增加歷史資料，也可以使用生成對抗網路生成高強度雷達回波資料，提升模型預測能力。另外，可以將雷達回波序列間隔 10 分鐘一筆資料調整為 6 分鐘一筆，捕捉快速變化之回波型態。

模型方面，本研究使用 seq2seq 的雙重注意力機制，雖能得到長時間的資訊，但編碼器只能以單方向訓練，無法平行化訓練，因此未來考慮使用其他注意力機制與生成方法，如：Self-Attention、Transformer，

以更有效率的訓練前後序列關係並建立雷達回波時空模型。另外，針對加權損失函數設定，可以嘗試以動態方法調整加權函數，根據輸入的雷達回波序列決定其各區間加權損失函數權重設定，或是使用集成學習模型同時使用不同模型，自動選擇最適模型。

參考文獻

- 中央災害防救會報。交通部中央氣象局豪雨特報將自本(109)年 3 月 1 日起新增短延時大豪雨降雨量標準。
<https://cdprc.ey.gov.tw/Page/B370E7DF675168E1/01997962-cd43-4d53-b384-bf5023a0a1d3>
- 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。
- 內政部消防署 (2018)。臺灣地區天然災害損失統計表 (47 年至 106 年)。
https://www.nfa.gov.tw/pro/index.php?code=list&flag=detail&ids=233&article_id=9639
- 交通部中央氣象局。雷達回波。
https://www.cwb.gov.tw/V8/C/W/OBS_Radar.html
- 行政院災害防救辦公室 (2018)。民國 109 年災害防救白皮書。
- 陳新淦、黃椿喜、呂國臣、洪景山、張博雄 (2016)。利用雷達回波影像辨識及篩選技術發展極短期系集定量降水預報。大氣科學，44(1)，1-31。
- 臺北氣象站逐日雨量資料 (2021)。交通部中央氣象局。
<https://www.cwb.gov.tw/V8/C/D/DailyPrecipitation.html>
- Luo, C., Li, X., Wen, Y., Ye, Y., & Zhang, X. (2021). A Novel LSTM Model with Interaction Dual Attention for Radar Echo Extrapolation. *Remote Sensing*, 13(2), 164.
- Schaefer, J. T. (1990). The critical success index as an indicator of warning skill. *Weather and forecasting*, 5(4), 570-575.
[https://doi.org/10.1175/1520-0434\(1990\)005<0570:TCSIAA>2.0.CO;2](https://doi.org/10.1175/1520-0434(1990)005<0570:TCSIAA>2.0.CO;2)
- Tang, X., Chien, Y., Lin, K., & Chang, P. (2020, October 13-15). Spatiotemporal Radar Echo Forecasting Based on Convolutional LSTM over Taiwan's complex terrain [Conference presentation]. 2020 Conference on Weather Analysis and Forecasting, Taiwan, Taipei.
- Wang, Y., Gao, Z., Long, M., Wang, J., & Philip, S. Y. (2018, July 10-15). Predrnn++: Towards a resolution of the deep-in-time dilemma in spatiotemporal predictive learning [Conference

presentation]. International Conference on Machine Learning Representations – ICML 2018, Stockholm, SWEDEN.
<https://arxiv.org/pdf/1804.06300.pdf>

Wang, Y., Zhang, J., Zhu, H., Long, M., Wang, J., & Yu, P. S. (2019, June 16-20). Memory in memory: A predictive neural network for learning higher-order non-stationarity from spatiotemporal dynamics [Conference presentation]. Computer Vision and Pattern Recognition – CVPR 2019, Long Beach, CA.
<https://doi.org/10.1109/CVPR.2019.00937>

Xingjian, S. H. I., Chen, Z., Wang, H., Yeung, D. Y., Wong, W. K., & Woo, W. C. (2015, December 7-12). Convolutional LSTM network: A machine learning approach for precipitation nowcasting [Conference presentation]. Advances in Neural Information Processing Systems 28 – NIPS 2015, Montréal, CA.
<https://doi.org/10.1155/2020/6484812>

Prediction and Evaluation of Weather Radar Echo Intensity Based on Deep Learning : An Empirical Study in Taiwan

Abstract

The Central Meteorological Bureau uses the radar echo extrapolation to estimate precipitation forecasts, but the atmospheric system is complex and non-linear, while the extrapolation forecast method uses simple extrapolation to calculate the intensity of the radar echo, resulting in a rapid decline in forecasting capabilities over time. In recent years, the space-time sequence model in deep learning has been widely used in radar echo prediction because it can capture the space-time relationship at the same time. However, the prediction results are prone to underreporting and inaccurate situations. This study uses a predictive recurrent neural network (Recurrent Neural Networks for Predictive Learning using Spatiotemporal LSTMs, PredRNN) spatiotemporal sequence model that combines two mechanisms, including a weighted loss function and a dual attention mechanism, and improves the ability of high-intensity echo prediction through continued learning continuous learning , The model will predict the radar echo changes for the whole station in the next hour. The experimental results show (1) The PredRNN established in this study combined with the two mechanisms can successfully capture the movement trend of radar echo in multiple cases and improve the accuracy of high-intensity radar echo prediction. (2) The RMSE and CSI of PredRNN combining the two mechanisms and the continued learning model in many cases are superior to the existing forecasting technology of the Central Meteorological Bureau. The above results show that the prediction model established by this research can effectively improve the prediction ability of high-intensity echo.