

弱綜觀午後雷暴事件即時預報-機器學習方法

陳鈞澤¹ 洪炯宗¹ 廖宇慶¹
劉千義¹ 鍾佳儒¹ 葉大綱²

¹國立中央大學 ²國立台北大學

摘要

弱綜觀條件的午後雷暴事件上，數值模式對於肇始地區與時間的預報仍有一定的不確定性。本研究以機器學習方法中的隨機森林法，針對對流肇始及後續發展進行一小時及時預報，觀測資料採用了2017、2018、2019年弱綜觀午後雷暴事件(共33天)的向日葵八號衛星、GPS測站可降水量、氣象局地面測站以及QPESUMS雷達回波

根據前述的方法及資料，在下午兩點至下午五點之間，現階段預報平均的ETS分數約在0.1左右，此結果顯示吾人採用的隨機森林法仍有優化的空間。本研究後續亦會針對模型優化及其它的機器學習方法進行測試，期望能改善機器學習方法的預報成果。

關鍵字：午後雷暴、機器學習、隨機森林方法

一、前言

台灣夏季降水主要來源為鋒面、颱風以及午後雷暴，其中在弱綜觀夏季時，降水最大的來源又以午後雷暴系統為主，Chen et al.(2007)指出台北盆地的午後雷暴是由海風環流將潮濕溫暖的空氣帶入台北盆地後，和都市熱島、盆地南側山區地形交互作用，於山坡形成對流，並藉由對流形成的冷池外流與海風的輻合，將整個對流系統與降水自南向北移入台北盆地，從上述過程可以得知，午後雷暴事件為十分複雜、時間尺度短的天氣系統，如果初始場不夠精確時，在數值預報上，要預報正確產生對流的時間、地點仍有一定的難度。

林品芳等人(2017)亦提到許多對於對流天氣系統的預報技術，包括區域性的數值天氣預報模式、模擬預報、拉格朗日外沿法等等，此外他們亦發展了一套模糊邏輯客觀潛勢預報午後對流方法Afternoon Thunderstorm Occurrence Potential forecast using Fuzzy Logic, ATOPFLO)，來預報北台灣午後雷暴發生的機率，而在Shi et al(2015)的文章中，也首次使用了深度學習網路ConvLSTM來針對降水做nowcasting預報，因此本研究主題期望能以機器學習方式，建立一套可用於台灣的午後雷暴nowcasting系統，輸入的特徵資料報含了向日葵八號衛星、GPS測站可降水量、氣象局地面測站以及QPESUMS雷達回波資料，目標為在短時間內預報一小時過後，午後雷暴發生的位置。

二、資料與方法

(一)、研究資料

如圖2-1所示，本研究使用了2017年到2019年共33天弱綜觀午後雷暴事件的觀測資料，觀測資料包含了向日葵八號

衛星資料、QPESUMS資料、CWB地面測站觀測資料、可降水量觀測資料，各資料詳細內容如下：

2019年	2018年	2017年
5/24	5/28	5/3
6/17	5/29	5/8
6/27	5/30	6/9
6/28	6/10	7/8
6/29	6/21	7/14
6/30	6/23	7/18
7/21	6/25	7/24
10/3	6/28	8/3
	7/7	8/7
	7/24	8/16
	7/27	8/24
	8/3	
	8/17	
	8/19	
8天	14天	11天

圖 2-1 本研究選用之弱綜觀午後雷暴案例日期

1.雷達資料

在雷達資料的部分，本研究選用QPESUMS，資料空間分布如圖2-2所示在東西方向資料涵蓋範圍自東經120.5度到122度且間隔0.0125度，總共有121個資料點，在南北方向資料涵蓋範圍自北緯24.55度到北緯25.4875度且間隔0.0125度，總共有76個資料點，雷達網格大小為121*76，在時間解析度上，QPESUMS提供了每10分鐘一筆的最大雷達回波合成資料。而在資料前處理的部分，-999的部分採用-15dBZ，假設為提供晴空的資訊。

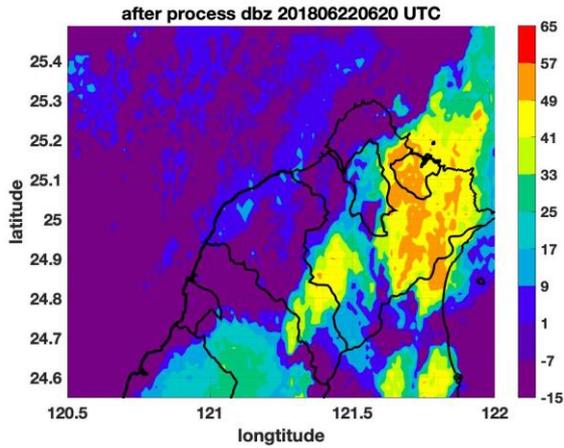


圖 2-2 QPESUMS 雷達回波資料，圖中範圍為本研究雷達資料網格之範圍

2. 衛星資料

在衛星資料的部分，選用了向日葵八號衛星七個不同的波段以及雲頂高(Cloud Top Height, CTH)變數做為後續機器學習模型使用的特徵，包含可見光波段的 $0.4\mu\text{m}$ 、 $0.5\mu\text{m}$ 、 $0.6\mu\text{m}$ ，此三個波段分別接收到藍、綠、紅光的反射率，主要與雲層厚度有有關，雲層越厚則反射率越高，量值範圍為0-1，而在紅外線波段則選用了 $6.2\mu\text{m}$ (K)、 $6.9\mu\text{m}$ (K)、 $7.3\mu\text{m}$ (K) 以及 $11.24\mu\text{m}$ (K)，此四波段單位為亮溫， $6.2\mu\text{m}$ (K)- $7.3\mu\text{m}$ (K)與中高層水氣有關，水氣越多則亮度溫越低， $11.24\mu\text{m}$ (K)則與雲頂高度有關，雲頂高度越高亮溫越低，在資料前處理的部分，本研究將衛星資料對齊到QPESUMS網格，對齊方式採抓取最近衛星資料點。

3. 地面測站資料

本研究亦使用CWB地面觀測站資料做為後續機器學習模型使用的特徵，站點分布如圖2-3，變數包含了東西風(U)、南北風(V)、相對溼度(RH)、壓力(P)、溫度(T)，時間解析度為10分鐘一筆觀測資料，在資料前處理的部分，為了對應後續機器學習演算法所需格式，將地面測站資料對齊到QPESUMS網格，對齊方式採抓取最近衛星資料點。

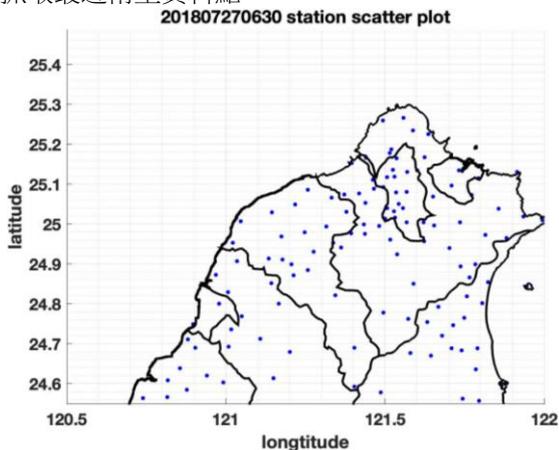


圖 2-3 CWB 地面測站空間分布情況

4. GPS可降水量資料

根據前人的研究，水氣多寡對午後雷暴的初始及發展占了重要地位，因此本研究亦使用反演的大氣可降水量(Precipitable Water Vapor, PWV)做為後續機器學習模型使用的特徵，時間解析度為10分鐘一筆，資料為單點資料，站點分布如圖2-4，為了對應後續機器學習演算法所需格式，將PWV資料對齊到QPESUMS網格，對齊方式採抓取最近衛星資料點。

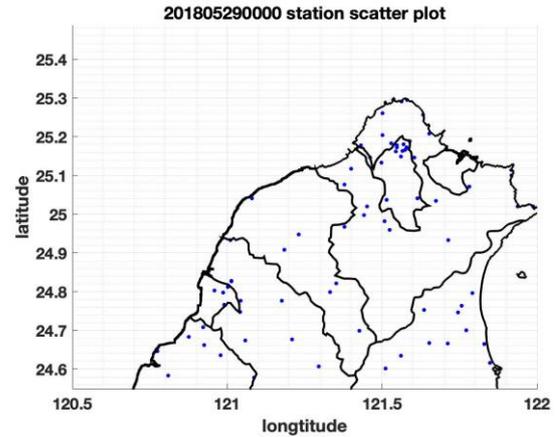


圖 2-4 大氣可降水量測站空間分布情況

(二)、研究方法

1. 隨機森林方法

本研究使用的機器學習演算法為隨機森林(Random Forest, RF)方法，如圖2-5所示，RF先利用Bootstrapping從原始資料提取n個隨機訓練子集，利用每個不同子集生成多棵決策樹(Decision Tree, DT)，其中DT為CART(Classification and Regression Tree)樹，為了訓練出最好的CART樹，必須要獲得最佳分裂點，而CART樹使用了GINI不純度來做為訓練評估指標，GINI不純度將計算每個節點的不純度，每棵DT訓練會傾向在分裂點有較低GINI不純度的狀態，RF最後再綜合多棵DT的結果給予最終結果，在本研究中，RF建模都是使用Python中的軟件包scikit-learn完成的

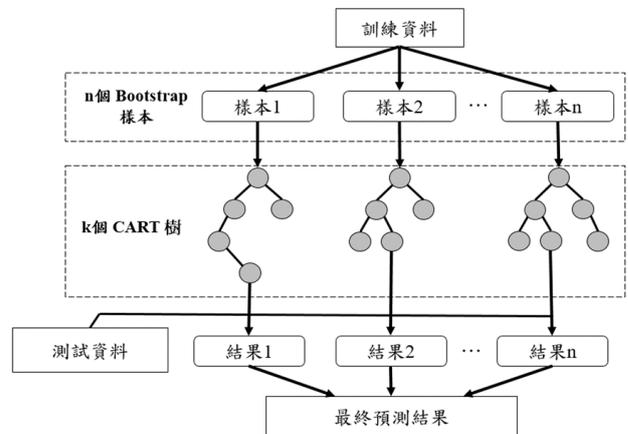


圖 2-5 RF 模型示意圖

2. 訓練資料

根據以上介紹，本研究選取了15個輸入特徵，包含QPESUMS雷達回波(dBZ)資料、向日葵八號衛星8個變數、地面測站5個變數以及GPS可降水量資料，目的為利用這15個特徵，預測一小時後是否會有午後雷暴產生，本研究將午後雷暴產生的定義設為雷達回波大於35dBZ，如果一小時後同樣位置點的雷達回波大於35dBZ則輸出值設為1，小於35dBZ輸出值則設為0。

為了更公正的檢驗模型結果，本研究將2017、2018年觀測資料做為訓練集，2019年做為測試集，訓練集有25天的觀測資料，測試集則有8天的觀測資料。

3. 訓練策略與實驗參數

由於午後雷暴事件多出現在0400UTC以後，本研究預測時間選在0400UTC至0900UTC，每十分鐘預報一筆，訓練策略如圖2-6所示，利用一小時前(例如0300UTC)的15個特徵變數當作輸入資料，對應到一小時後(例如0400UTC)是否產生午後雷暴的結果做訓練，訓練上首先採取單點對單點的方式做訓練。

由於產生午後雷暴的格點數(>35dBZ)和沒有產生午後雷暴的格點數(<35dBZ)資料數量相差過大，為了避免資料不均衡的情況影響到預測結果，本研究資料採樣方式為欠採樣(Undersampling)，在每個時間點會隨機從沒有產生午後雷暴的資料中，選出和產生午後雷暴格點數一樣的格點數量，使的訓練集中的正負樣本達到1:1，為了維持測站資料的代表性，最終訓練資料選擇為圖2-2中台灣本島範圍內的格點。在本研究中，針對RF的參數設定，將測試DT數量($n_estimators$)為1000、2000、3000、4000棵配上最小分裂點數($min_samples_split$)為10、100、1000、10000的結果，測試結果顯示選用1000棵DT、最小分裂點數設為1000、DT選用特徵為3種的結果是最好的，下段將針對訓練結果在2019年測試集的結果進行分析。

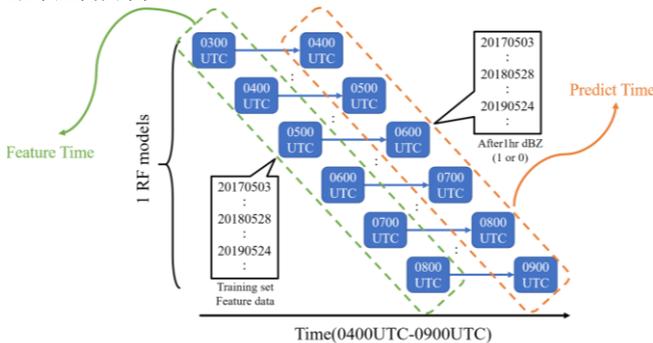


圖 2-6 訓練策略

三、 實驗結果

本段將利用前述RF的模型，針對訓練集以及評估集進行結果分析，評估模型表現參數為Precision、Sensitivity以及ETS，圖3-1混淆矩陣(Confusion Matrix)，顯示了模型預報以及真實情況可能遇到的四種情況，而根據圖3-1代號，可以將評估參數寫成：

$$\text{Precision} = \frac{TP}{TP+FP} \text{-----}(1)$$

$$\text{Sensitivity} = \frac{TP}{TP+FN} \text{-----}(2)$$

$$\text{ETS} = \frac{TP-R}{TP+FP+FN-R}, R = \frac{(TP+FN)*(TP+FP)}{TP+FP+FN+TN} \text{-----}(3)$$

其中Precision代表預測會發生的情況中實際發生的比例，Sensitivity代表實際發生中預測正確的比例，ETS則是減去隨機猜測到的比數，為大氣預報常用評估參數。

	實際 YES	實際 NO
預測 YES	TP	FP
預測 NO	FN	TN

圖 3- 1 Confusion Matrix

(一)、 5-fold grid search

如同前段所述，在2017-2018訓練資料中，為了測試最好的RF參數，本研究隨機將資料分成5份，在訓練RF時取其中4份做訓練，1份做評估，並重複此動作5次，每次選用不同的評估集，讓每一筆資料都有被評估到，以上方法稱為5-fold validation，目的為找到最好的RF參數設定。

圖3- 2為不同RF參數在5-fold validation以sensitivity當做評估參數的結果，橫軸為 $n_estimators$ ，縱軸為 $min_samples_split$ ，結果顯示在不同參數下sensitivity量值約在0.55-0.75，且調整 $n_estimators$ 對結果影響不大，而當 min_sample_splits 增大時，sensitivity也會越來越高，最好可到0.75左右。

圖3- 3為不同RF參數在5-fold validation以precision當做評估參數的結果，結果顯示在不同參數下precision量值約在0.65-0.68，和sensitivity一樣可以觀察到調整 $n_estimators$ 對結果影響不大，然而當 min_sample_splits 增大時，precision則會越來越低，但數值變動範圍較sensitivity來的小。

圖3- 4為不同RF參數在5-fold validation以ETS當做評估參數的結果，結果顯示在不同參數下ETS量值約在0.26-0.34，和sensitivity、precision一樣可以觀察到調整 $n_estimators$ 對結果影響不大，然而當 min_sample_splits 增大時，ETS結果會先升後降，結果顯示 min_sample_splits 在1000時有最好的結果，因此在後續實驗，會將 $n_estimators$ 及 min_sample_splits 都設定為1000，並在真實評估集2019年的資料進行測試。

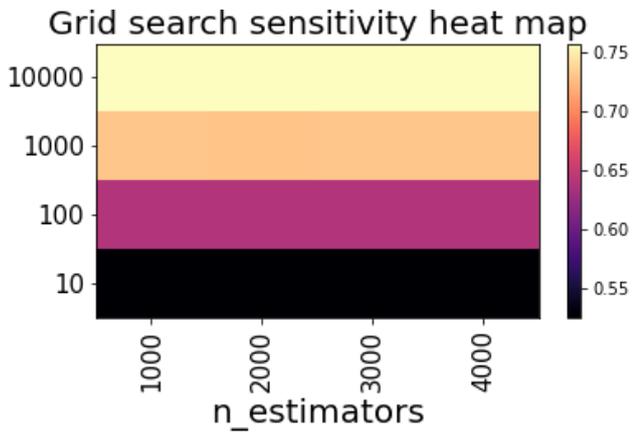


圖3-2 不同RF參數在5-fold validation下sensitivity結果

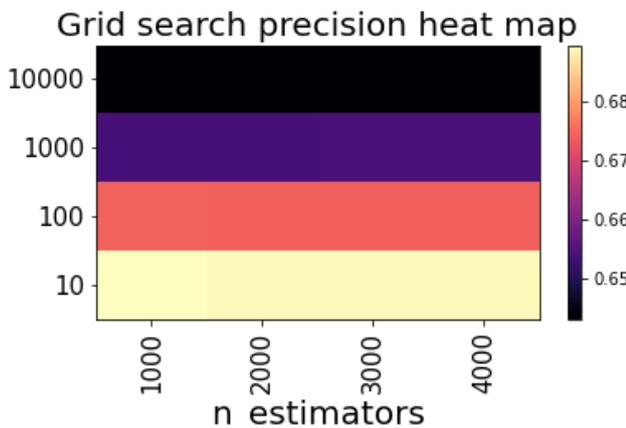


圖3-3 不同RF參數在5-fold validation下precision結果

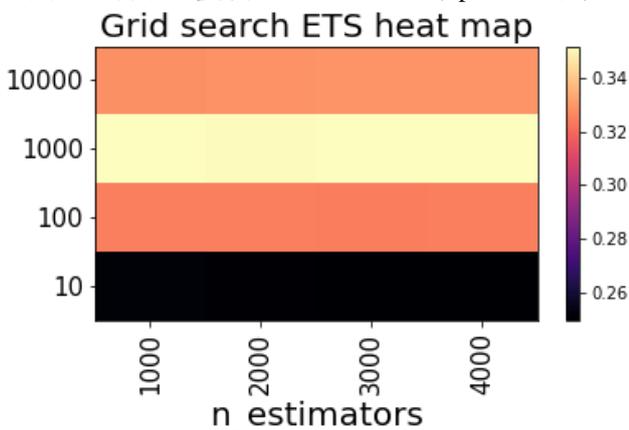


圖3-4 不同RF參數在5-fold validation下ETS結果

(二)、2019真實資料

在訓練資料的5-fold validation中可以看到，ETS的結果約為0.34左右，這是個非常理想的結果，然而在訓練集中，有產生午後雷暴的資料點和沒有產生午後雷暴的資料點數量為1:1，這與真實資料結果不同，因此本段將針對2019年總共八天的資料做評估。

圖3-5橫軸為預報時間，縱軸為不同預報時間的sensitivity結果，不同顏色代表2019年不同天，紫色則是平均結果，結果顯示在0640UTC前，sensitivity表現較不穩定，而在0640UTC後，平均sensitivity約在0.7-0.8中間，推測原因為0640UTC前對流生成數少，資料點極稀少所以評估結果不明

顯，表1為八天在所有時間的平均結果，平均為0.67，最好可到0.851，最差則到0.474。

圖3-6橫軸為預報時間，縱軸為不同預報時間的precision結果，不同顏色代表2019年不同天，紫色則是平均結果，結果顯示時間越晚precision會越高，但最高不會超過0.2，表2為八天在所有時間的平均結果，平均為0.124，最好可到0.234，最差則到0.056，和前段5-fold validation比較起來，precision在真實資料下降許多，顯示在真實資料正負樣本不為1:1的情況下，precision表現不理想。

圖3-7橫軸為預報時間，縱軸為不同預報時間的ETS結果，不同顏色代表2019年不同天，紫色則是平均結果，結果顯示時間越晚ETS會越高，但最高不會超過0.2，表3為八天在所有時間的平均結果，平均為0.0458，最好可到0.107，最差則到0.012，和前段5-fold validation比較起來，ETS在真實資料下降許多，顯示在真實資料正負樣本不為1:1的情況下，ETS表現不理想。

根據2019評估集的評估結果，可以看到sensitivity結果和5-fold validation較接近，然而在precision以及ETS的結果，都與原先5-fold validation相差較大，說明了目前的建模方式在真實資料中仍有很大的改善空間。

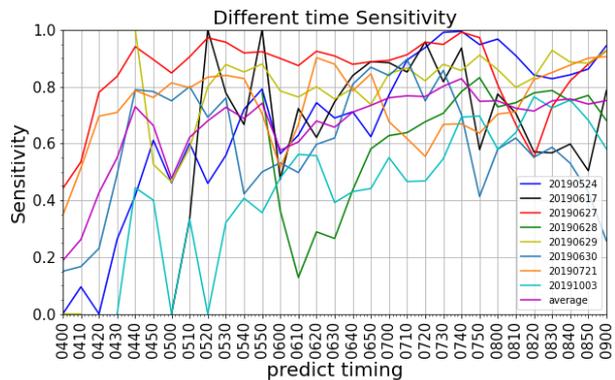


圖3-5 2019年0400UTC-0900UTC sensitivity 評估結果

Date	Mean sensitivity
20190524	0.667
20190617	0.704
20190627	0.851
20190628	0.617
20190629	0.764
20190630	0.596
20190721	0.736
2019091003	0.474

表1 2019年八天 sensitivity 評估結果

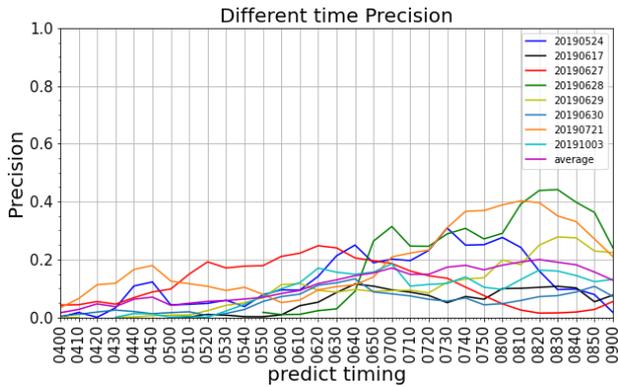


圖 3-6 2019 年 0400UTC-0900UTC precision 評估結果

Date	Mean Precision
20190524	0.128
20190617	0.061
20190627	0.117
20190628	0.234
20190629	0.103
20190630	0.056
20190721	0.191
2019091003	0.098

表 2 2019 年八天 precision 評估結果

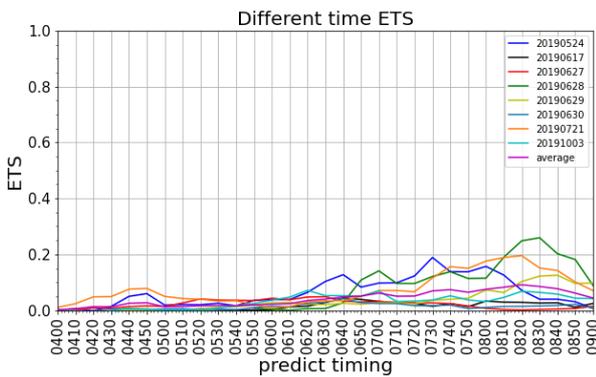


圖 3-7 2019 年 0400UTC-0900UTC ETS 評估結果

Date	Mean ETS
20190524	0.063
20190617	0.018
20190627	0.021
20190628	0.107
20190629	0.035
20190630	0.012
20190721	0.075
2019091003	0.035

表 3 2019 年八天 ETS 評估結果

四、 結論與討論

本研究利用RF模型加上15個來自雷達、衛星、地面測站、GPS可降水量特徵，建立了一套機器學習弱綜觀午後雷暴事件的集時預報系統，根據測試結果顯示：

1. 在目前的測試中，調整min_samples_split參數對於調整n_estimators有較大的改善空間，根據測試最終模型參數設定為min_samples_split=1000, n_estimators=1000，此參數設定在2017、2018訓練資料集中5-fold validation評估結果precision為0.66, sensitivity為0.73、ETS為0.34。
2. RF模型目前在2019年8天評估資料中，評估結果precision為0.124, sensitivity為0.67、ETS為0.0458，和5-fold validation結果相差甚遠，且模型偏向過度預報。

目前推測RF在真實資料表現較差的原因為訓練策略採樣方式採用欠採樣的方式，未來可以測試不同採樣方式，也可以測試更多機器學習、深度學習方法，進一步找到在真實資料能表現更好的模型。

五、 參考文獻

- Chen, T. C., Wang, S. Y., & Yen, M. C. (2007). Enhancement of afternoon thunderstorm activity by urbanization in a valley: Taipei. *Journal of Applied Meteorology and Climatology*, 46(9), 1324-1340
- 林品芳, 張保亮, & 周仲島. (2012). 弱綜觀環境下台灣午後對流特徵及其客觀預報. *大氣科學*, 40(1), 77-107.
- 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).

The Implementation Of Weak Synoptic Afternoon Thunderstorm Nowcasting By Machine Learning Algorithm

Jiun-Tze Chen¹ Jorng-Tzong Horng¹ Yu-Chieng Liou¹
Chian-Yi Liou¹ Chia-Ru Chung¹ Ta-Kang Yeh²

¹National Central University

²National Taipei University

Abstract

For warm season afternoon thunderstorm under weak synoptic-scale forcing in Taiwan, numerical model forecast still has uncertainty on predicting precise afternoon convection initiation (ACI) location and time. This study apply machine learning algorithm to produce 1-h likelihood nowcasts for both ACI and radar nowcast. The machine learning algorithm used here is Random Forest Classifier, and the observation data includes 2017-2019 warm season afternoon thunderstorm events (33 days) Himawari-8 satellite data, precipitable water vapor GPS observations, Central Weather Bureau(CWB) station data and QPESUMS radar reflectivity data.

By the data and algorithm mentioned above, the average ETS score on test dataset is around 0.1 during 0600UTC to 0900UTC. This result indicates that our method still has lots of room to improve, we will do model optimization and test other machine learning algorithm to better the forecast result.

Key words: Afternoon Thunderstorm, Machine Learning, Random Forest Classifier.