

應用自組織特徵映射以雷達回波進行機率式 淹水預警之研究

A study of applying self-organizing map to probabilistic flood early warning based on radar reflectivity

國立臺灣大學

博士	研究助理	博士	博士	博士
潘宗毅	陳羅以	謝宜桓	賴進松	賈新興
Tsung-Yi Pan	Lo-Yi Chen	Yi-Huan Hsieh	Jihn-Sung Lai	Hsin-Hsing Chia

摘 要

世界各地因氣候變遷引致之極端天氣事件發生頻率和強度日益增加。臺灣近年之極端降雨頻仍，導致積淹水災害之發生機率逐年上升。目前水利署以不同延時之累積雨量作為鄉鎮尺度之降雨-淹水警戒值，並以全臺灣之地面雨量站網進行研判。然而，目前警戒系統僅提供定律式之警訊，為提升防災決策支援品質，本研究提出機率式災害預警，期能於發佈警戒之時，亦提供積淹水災害之機率風險。

為發展更完善於警戒標準區域之積淹水災害預警方法，本研究收集在 2014 至 2021 年間，臺北市淹水總次數紀錄最高之區域—松山區中華里之即時雷達回波觀測圖及歷年時雨量資料，爾後採用類神經網路中自組織特徵映射(self-organizing feature maps, SOM)的分群演算法，依序訓練長安國小站及民生國中站之災區相近測站，建立研究區域之三維空間雷達回波數據和雨量實況觀測的關係，並利用聚類演算降訓練資料維度來進行群聚分析，對應出拓撲圖中致災風險與降雨範圍之關係，並採用 K-means 分群(Clustering)有效地辨識在多變量數據中之致災特徵。

研究結果顯示，經由自組織特徵映射分群後，將淹水災害事件進行挑選，結果顯示雷達回波分類與發生災害和極端降雨事件的機率相關性極高；除此之外，SOM 各個神經元亦能呈現出機率降雨範圍。接續 K-means-SOM 分類雷達空間的降雨致災特徵結果也表現顯著，藉由 Nest-SOM 最後訓練可調降降雨警戒閾值至 40 毫米並產生未來 1 至 3 小時之機率淹水警戒。此研究期待能加強鄰里區域之小尺度淹水預警準確度，並提供當地居民相關洪災風險機率分析，來提升及健全面對未來極端降雨之調適能力。

關鍵詞：雷達回波，K-means-SOM，Nest-SOM，降雨—淹水警戒值，機率式預報

Abstract

The frequency and intensity of hazardous weather events have increased year by year under climate change. In recent years, occurrence of extreme rainfall has been frequent in Taiwan as well, resulting in an accumulation in the probability of flooding disasters. For the rainfall-flooding warning, the Water Resources Agency applies rainfall thresholds of ground rain gauges to each township scale. However, the current flood early warning system only provides deterministic warning messages without any information about the uncertainty that can help communities adapt better strategies. Therefore, an unsupervised neural network is applied to develop a probabilistic flood early warning system (PFEWS) for the village-scale in this study.

To develop the PFEWS, this research collected real-time radar reflectivity maps and historical rainfall data in the flood-prone area of Taipei City, Zhonghua village in Songshan District, from 2014 to 2021, and its nearest observation stations are Changan Elementary School Station and Minsheng Junior High School Station. Then the study used a neural network (Self-organizing map, SOM) to establish the relationship between the study area's three-dimensional space radar reflectivity data and the actual rainfall observations. After that, the K-means clustering vectors corresponding to flooding disaster events could be analyzed by extracting the correlation between the radar reflectivity and the probabilistic hazards. Next, to establish the accurate correlation, data would be downsampled to few training materials by Nest-SOM. Additionally, the probabilistic rainfall range could be carried out in each topological map. The research results show that after clustering by the proposed model, the radar reflectivity classification is highly correlated with the probability of flooding disaster events and over 50 mm of hourly rainfall and the information of the rainfall characteristics by three-dimensional radar features. Through the final training of Nest-SOM, the rainfall warning threshold could be adjusted to 40 mm, and the proposed model could provide accurate inundation maps for 1- to 3 -h lead times. The PFEWS based on the proposed SOM model and radar reflectivity could provide a probabilistic flood warning message with the enhanced spatial resolution for communities to adopt preventive measures.

Keywords: radar reflectivity , self-organizing map , K-means , Nest-SOM , rainfall threshold , probabilistic flood early warning system

1、 前言

2019年，8月起降雨引發的淹水區域，在臺北市造成了300多個淹水災點(台北市政府，2019)。2021年6月4日，輕度颱風彩雲共造成306件洪災事件，臺北市多個觀測站實測降雨量超過100毫米，大台北、基隆、北部及中部山區也有40毫米以上時雨量(中央緊急應變中心彩雲颱風災害應對報告，2021)。很多人沒收到撤離或往高處避難的訊息，導致房屋積淹水、車輛受損。而在全臺北市2014年至2021年淹水災害次數最多之松山區中華里，已發生淹水紀錄於20次以上。隨著氣候變遷下降雨強度更高，臺北市需更足夠及完善的能力來應對未來此短期強降雨之降雨型態，建立淹水預警系統在面對極端天氣和豪雨來臨前重要環節。因此，為了減低降雨淹水事件的風險，及需爭取更長的備災時間，透過即時接收的雷達回波圖來分析淹水型態、機率性降雨-淹水和災害預警之相關分析。本研究旨在應用高效的科學機器學習方法來快速解決與傳統模型問題，並必要為短期淹水警戒預報限制取得有效的解決方案。

本研究擬應用非監督式學習之自組織映射網路(Self-Organizing Map, SOM)由降雨雷達所提供之三維回波資料、西南氣流觀測數據(圖1)，綜觀天氣型態中豪大雨檢查表之因子，將研究分為颱風系統、鋒面及午後熱對流系統進行資料探勘。目前已有許多文獻使用機器學習方法來做淹水預測，如Chang et al.(2010), Pan et al.(2011), Kia et al.(2012)。過去研究表現，模型只對提前1小時的提供較可接受的預測數據。根據水利局的定義，二級警戒被定義為淹水熱區鄰里和道路可能在未來3小時內積淹水。因此，開發一個性能良好、可以立即訓練並為防洪、災害預警和緊急疏散決策提供更長準備時間的模型是合理的。

如上所述，CWB衛星中心開發的惡劣天氣監測系統QPESUMS將提供每小時1-3小時的定量降雨觀測和預報，並對當前的強降水事件進行實時預報。然而，該數據將三維雷達反射率空間數據分析轉化為一維定量降水，缺乏三維空間的不確定性因素。對流系統的三維雷達反射率結構也是影響不同降雨模式的關鍵。文獻說明降雨系統降雨的壽命、強度和空間分佈取決於垂直運動速度。垂直移動速度是區分不同類型降雨系統的主要因素(Houze, 1993)。不同的雷達反射率垂直結構和降水過程皆有著相對對流系統的生命階段。由於不同降水模式的垂直熱力學結構不同，液滴粒徑分佈特徵也各不相同。因此，三維雷達反射率結構也是本研究模型的參考。雷達反射率是由雷達發射並被大氣中的降水粒子(雨、雪、冰雹等)反射的信號。根據雷達接收到的降水粒子反射的信號強度，以不同的顏色顯示。反射強度與降水粒子的大小、形狀、狀態、單位體積的粒子數有關。一般來說，反射信號越強，降水強度越強。因此，透過雷達反射率圖來預測天氣系統的降雨強度和分佈。

短延時強降雨是在不同時空尺度之大氣因子複雜交互作用下所引致之極端降雨情形，若用傳統多變量統計分析模式仍不易得到滿意之相關性分析。因此，本研究嘗試結合雷達資料與西南氣流指標，利用短延時強降個案分析的方式，分析西南氣流和回波強度的關係，並期望能得出西南氣流和回波的關係式，嘗試找出西南氣流和降雨的關係。利用自組織映射網路自我學習之特性，研析造成短延時強降雨之氣候因子與降雨量相關性。

2、 研究場域及資料

研究區域位於人口密度最高的臺北市中心，已發展成臺灣政治和經濟中心。選定

臺北市最高頻率淹水區域，即為中華里位於松山區高都市化區域，有小巨蛋、面積 0.1610(平方公里)、總人口 6,729 人、戶數：2,560 戶、人口密度 41,795 人/平方公里，根據水利署紀錄(如表 1)，2014 年至 2021 年，中華里發生 20 起淹水及警戒事件，包括 11 個豪雨和 2 個颱風造成社區積淹水災害。大部分大雨都是滯留鋒稱為梅雨鋒，發生在 5 月和 6 月，兩場大雨是午後雷雨，在極短時間內產生大量降雨。而颱風包括蘇迪勒颱風和杜鵑颱風，在 24 小時內造成了 200 毫米以上的降雨。根據水利署紀錄，積淹水深度超過人行道高度 30 公分，因此許多房屋受影響。圖 1 中發生淹水地點為松山區的南京東路四段，也為高機率淹水災點。

因研究區域位於台北盆地的中央平坦地形(如圖 1)，受到 200 年回水期設計的防洪堤的保護，所以當暴雨超過城市下水道系統的排放能力時，並有 16 個泵站和排水系統的堤壩，可承受每小時降雨 78.8 毫米。模式建置主要以研究區域最近之兩測站為長安國小站(CE station)和民生國中生站(MJ station)，距積淹水熱區中華里不超過 1 公里，並使用中華里正上方雷達回波值做淹水次數選取。根據松山區這兩個站點的歷史積淹水和降雨數據，一小時降雨預警值為 60 毫米。只要觀測到的降雨量達到其中一項觀測值，就會發布二級預警。

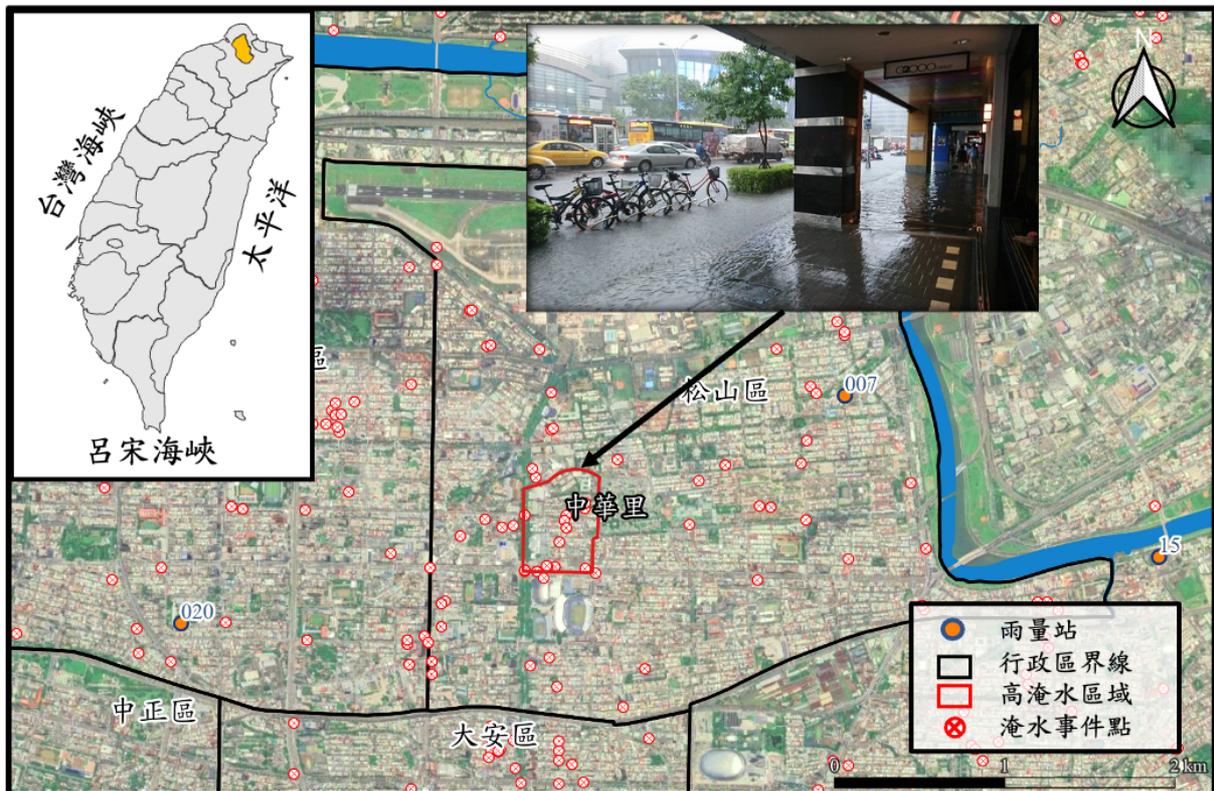


圖 1 研究區域及相關地理資訊：中華里及其最近之兩個雨量站，臺北市水利處長安國小(020)站和民生國中生站(007)。紅叉圖為淹水發生次數紀錄即為高淹水區域。

No.	事件	日期	淹水警戒區域					
			臺北市					
			內湖	中山	松山	文山	大安	北投
E01	0515 豪雨事件	2014/05/15	0	0	1	0	0	-
E02	0519 豪雨事件	2014/05/19	0	1	1	1	1	-
E03	0605 豪雨事件	2014/06/05	0	0	1	0	0	-
E04	104年6月14日豪雨事件	2015/06/14	0	0	1	0	1	-
E05	104年7月23日水災災害	2015/07/23	1	1	0	0	1	-
T01	蘇迪勒颱風	2015/08/07	1	1	1	1	1	1
T02	杜鵑颱風	2015/09/28	0	0	1	1	0	0
E06	105年6月17日豪雨事件	2016/06/17	0	1	1	0	1	0
T03	梅姬颱風	2016/09/25	0	1	0	1	1	1
E07	0602梅雨鋒面	2017/06/02	1	1	1	1	1	1
E08	107年9月8日水災災害	2018/09/08	1	1	1	1	1	1
E09	0520 豪雨事件	2019/05/20	1	1	1	1	0	1
E10	0722 豪雨事件	2019/07/22	0	1	1	1	1	1
E11	0604 豪雨事件	2021/06/04	1	0	1	1	1	0
總計			6	9	12	9	10	6

表 1 2014 至 2021 年臺北市中央區歷史淹水警戒事件

中央氣象局於 2002 年與美國劇烈風暴實驗室、經濟部水利署及行政院農委會水土保持局共同開發劇烈天氣系統(Quantitative Precipitation Estimation and Segregation Using Multiple Sensor, QPESUMS)，為了加強局部劇烈或突變天氣發生之中小尺度天氣系統之即時監測、分析與預報的能力。QPESUMS 產出之雷達整合回波格點資料-解析度為 1.25 公里。原始資料矩陣為 881x921，因本實驗是以小尺度如鄉鎮、鄉里為主要研究單位，網格選取將從原始資料矩陣中選取出以台北市松山區中華里，八年來記錄到 21 次淹水的經緯度取中間值為研究區域，中心點為中心 3X3 共 9 格，再往上 3 層(原始 21 層)切割出較小範圍的三維資料(3X3X3)作為實驗模型的建立，探討模型預測雷達回波的各種影響因素與使用含有高度資訊的三維資料格式參考根據，可參考雷達回波空間示意圖(圖 2)。

此外，研究模式建立結合雷達資料與西南氣流指標，因分析過去每日西南氣流指標和恆春氣象站之風場做相關性測試，相關係數高達 0.8，因此加入恆春氣象站逐時資料。利用短延時強降個案分析的方式，分析西南氣流與雷達回波強度的關係，並期望能得出西南氣流和雷達回波的關係式，嘗試找出西南氣流和降雨的關係。所訓練資料為研究區域上方三維空間雷達回波以及對應時刻之恆春站風速和風向，每筆訓練資料共為 29 個特徵值。

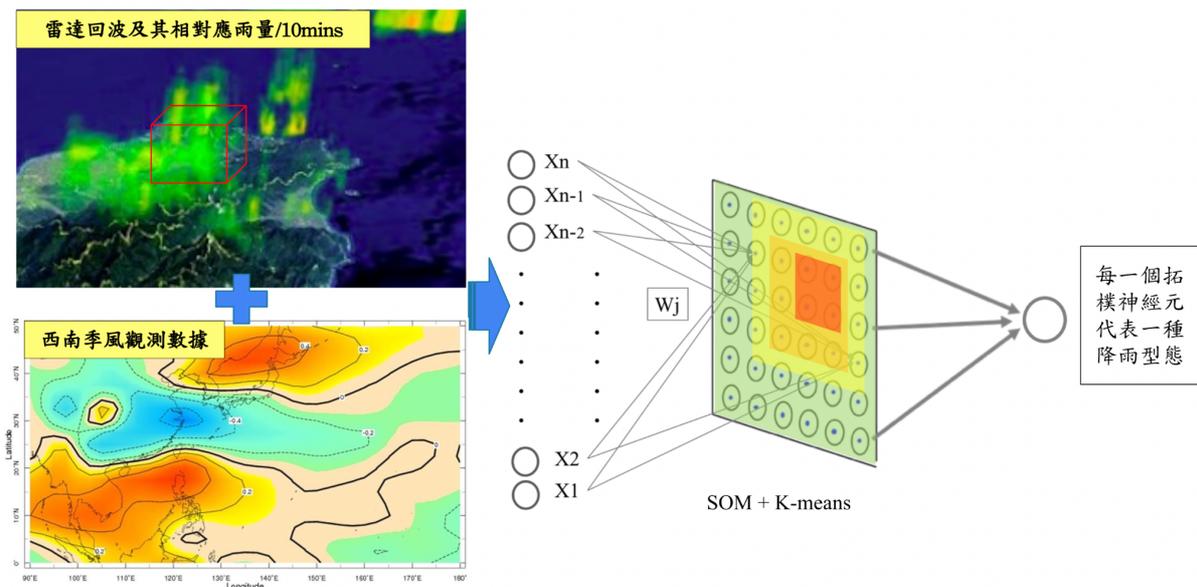


圖 2 每個數據從一個三維空間雷達回波值並加入風速、風向之西南氣流指標，共 29 格輸入為同一筆訓練資料

3、 模式建構與流程

3-1. SOM

自組織映射圖網路在 1980 年由 T. Kohonen 提出(Kohonen, 1982)，它是屬於無監督式學習網路模式的一種。它的基本原理是模仿人類大腦中，具有相似功能的腦細胞會聚集在一起的特性，所發展出來的類神經網路。因此，只要在學習範例中有內在的聚類規則，那麼就適用於自組織映射圖網路。自組織映射圖網路主要由輸入層、輸出層(網路拓撲)及網路連結(加權)三層組成其網路架構(如圖 2 所示)。輸入層即訓練範例的輸入向量，輸出層則是由網路拓撲所組成，而網路連結則是每個輸出層單元與輸入層處理相連結的加權值所成的向量(也是形心座標)。在自組織特徵映射中，輸出層的類神經元是以矩陣方式排列於一維或二維的空間中，並且根據目前的輸入向量彼此競爭以爭取得到調整鏈結值向量的機會，而最後輸出層的類神經元會根據輸入向量的「特徵」以有意義的「拓撲結構(topological structure)展現在輸出空間中。而這種陣列的拓撲關係，簡單地來說，就是神經元之間的鄰居關係。由於所產生的拓撲結構圖可以反應出輸入向量本身的特徵，因此我們將此種網路稱為自我組織特徵映射網路。Self-Organization Map 是由輸入層及輸出層所組成的網路架構。在輸入層中每一個神經元代表著輸入資料之屬性，並且每一個神經元皆互相獨立且擁有互相獨立的權值。對於輸出層而言，常用二維格子網狀之架構，並且輸出層神經元與輸入層神經元有相互連接的網路關係，其方式是以權值向量來表示。

輸入層：用以表現網路的輸入變數，也就是用來訓練網路的資料向量(Data vector)，而輸入資料的數目是依照問題而訂，以 $X_1, X_2, X_3 \dots X_n$ 表示之。

輸出層：用以表現網路的輸出變數，利用拓撲結構以呈現輸入資料的分佈狀況。

權值向量：每個輸出層神經元與輸入層相互鏈結關係所構成的權值向量(Weight Vector) w_j ，當網路訓練完後，其輸出神經元相鄰近者會具有相似的權值向量。 W_j 所代表的向量通常和輸入層的向量維度一樣。

SOM 演算法為一個疊代過程，由輸入向量 X 和輸出向量 Y 組成，每條輸入數據都由等式所示的 m 維輸入向量表示，公式如下，

則其學習之步驟說明如下：

$$X = [X_1, X_2, \dots, X_m]^T$$

步驟 1：初始神經元和權重之間的鏈結權重可隨機生成，並設定學習循環次數 $t=0$ 。

步驟 2：如上所述，鏈結權重調整的模式是一種競爭學習方法。計算在第 t 次學習輸入向量資料與權重值間之 Manhattan 距離 (d_j)，公式如下：

$$d(X) = \sum |P_i(x_1 - y_1) - Q_i(x_m - y_m)|, \quad i = 1, 2, \dots, m.$$

步驟 3：判斷訓練是否達到收斂條件，即疊代次數；否則，重複步驟 2，直到達到設定的疊代次數。因此，每個神經元調整的頻率和時間不一定相同，每個神經元所扮演獲勝神經元或其鄰域神經元的角色，這取決於輸入向量之間的分佈關係，此調整方法也是建立神經元之間拓撲映射關係的主要原因。

根據上述架構可以得知，映射網路的輸出層會依據輸入資料的特性以有意義的拓撲結構展現，所顯示的拓撲結構可以反映出輸入資料的分佈。在網路學習過程中，輸出層的神經元會因輸入資料的分佈情形自我組織成相似的對應分佈，也就是會自動調整輸出層神經元之間的鄰近關係。此鄰近關係是指輸出層神經元間相互連接的情形，因此，在網路學習的過程中鄰近關係會依據輸入資料特性調整其鄰近距離，而使得網路能夠反映輸入資料之特徵。其中，鄰近關係的定義為當網路訓練過程中，某一個神經元被激發時，其鄰近的神經元亦需一同被強化。在網路的學習過程中，鄰近關係將逐步的縮小，係為了使得整個網路訓練能夠達到一個穩定的狀態(收斂的狀態)。通常在網路中採用墨西哥帽函式(Mexican-hat Function)做為神經元刺激強度的標準(Kohonen, T., 1995)。此一標準是用來規範神經元的神經鍵在被訓練時所應加強的強度。愈接近函式中心所得到的刺激強度愈大，而遠離中心所得到的刺激強度則隨之變小。換句話說，在神經元訓練的過程中，鄰近關係最近的神經元所得到的刺激強度也最大，其它神經元所得到的刺激則隨著鄰近關係由遠而減弱。

3-2. 群集分析

本研究採用 k-平均演算法(k-means)針對 SOM 自我學習後所建構之網路特徵值進行群集分析。透過 k-means 對 SOM 中之神經元特徵向量進行分組，將相似的數據歸類為一起，每一筆數據能有一個分組，每一組稱作為群集 (Cluster)。首先使用輸入資料訓練出一個 k-means 聚類表示，然後把任意的輸入資料投射到這一新的特徵空間。k-means 的這一應用能成功地與自然語言處理和電腦視覺中半監督學習的簡單線性分類器結合起來。其主要步驟為(張巧薇等，2019)：

- (1) 設定要分成多少群：K
- (2) 在特徵空間中隨機設定 K 個群心。
- (3) 計算每一個資料點到 K 個群心的距離 (基本上使用 L2 距離，但也是可以換成別的。)
- (4) 將資料點分給距離最近的那個群心。
- (5) 在所有資料點都分配完畢後，每一群再用剛剛分配到的資料點算平均(means)來更新群心。
- (6) 最後不斷重複 3-5 的動作，直到收斂 (每次更新後群心都已經不太會變動) 後結束。

3-3. Nest-SOM

於本文 3.1 節已說明 SOM 演算法以及相關方程式，而在整個研究過程中所使用的 SOM 亦是以此模式為基礎。並依著後續所選定的在分析資料大小做參數上的調整。其中，巢狀自組織映射圖網路(Nest-SOM)也是本研究極為重要的分析步驟。由於所要分析的資料樣本與母體數量差異極大。主要母體中有三分之一的雷達回波值接近於 0 dBZ，而最主要挑出的樣本數即為淹水及警戒事件，其中雷達回波值只佔整體筆數的萬分之一。因此整體型態由 SOM 並加入 Nest-SOM 建置模式。

此分析步驟會先有第一層由雨量測站所建立的回波值之 SOM 模式，分析結果中的分類。選定出平均回波值以及回波值較大的神經元範圍，並藉由 k-means clustering 的分類評估，將相關範圍選定為即將作為 Nest -SOM 的區域，也就是第二層的 SOM 熱區分析如表 2，由四項選定標準分析也將隨著訓練筆數不同有不同的模式參數設定，此 Nest-SOM 將會改為 SOM 10X10，整體研究流程圖如圖 3。

表 2 選定 Nest-SOM 神經元之標準

SOM 36X36 致災熱區之神經元標準選定(Nest-SOM)
1. 1296個神經元中平均時雨量排名前十名
2. 研究區域之分類群較高雷達回波值
3. 訓練結果發生警戒及淹水事件之獲勝神經元
4. K-means 分群1296個神經元之29項特徵結果

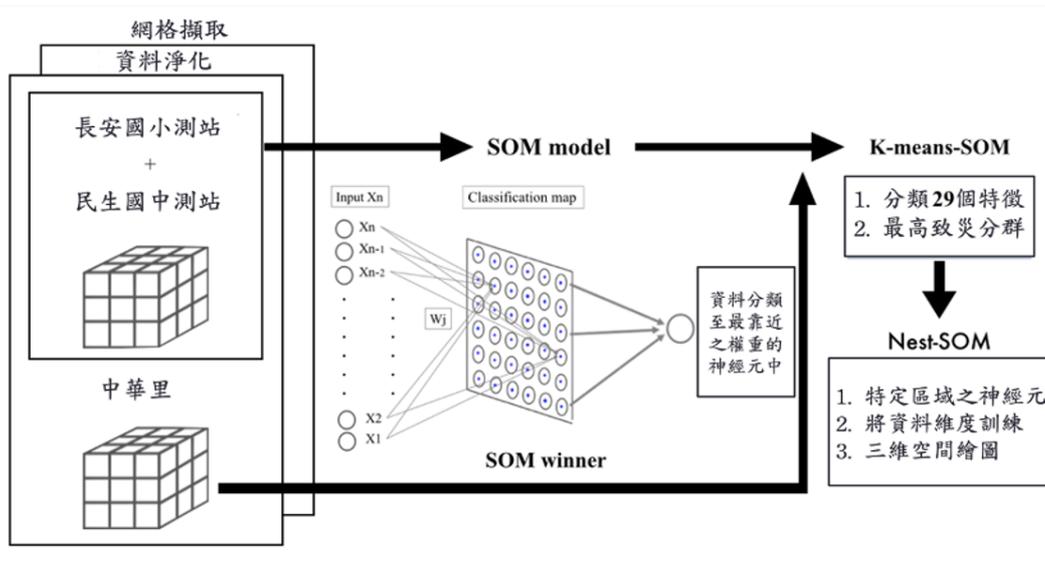


圖 3 研究流程圖

4、 模式結果與討論

在結合雷達資料與西南氣流指標之結果，總神經元個數為 1296(36X36)個，而各個神經元中皆有 27 格雷達回波值和風速、風向共 29 個特徵值。由分析結果得出(圖 4)，加入西南氣流指標建立之模式，使用紅框表達前三高平均時雨量之神經元為：33.60 mm/hr、32.79 mm/hr 及 32.55 mm/hr。此外，另使用 K-means 做特徵分群，K-means 訓練做 10 個分群，從圖 5 左圖為 K-means 結果，將此圖對照圖 5 右圖一平均時雨量由低至高排名(1296 名將為平均時雨量最高)，圖中拓樸圖藍色框起來為較低淹水警戒風險區，紅色框屬於短延時降雨熱區分布，確定 K-means 分群穩定將可建立各神經元之 29 個氣候因子特徵值。

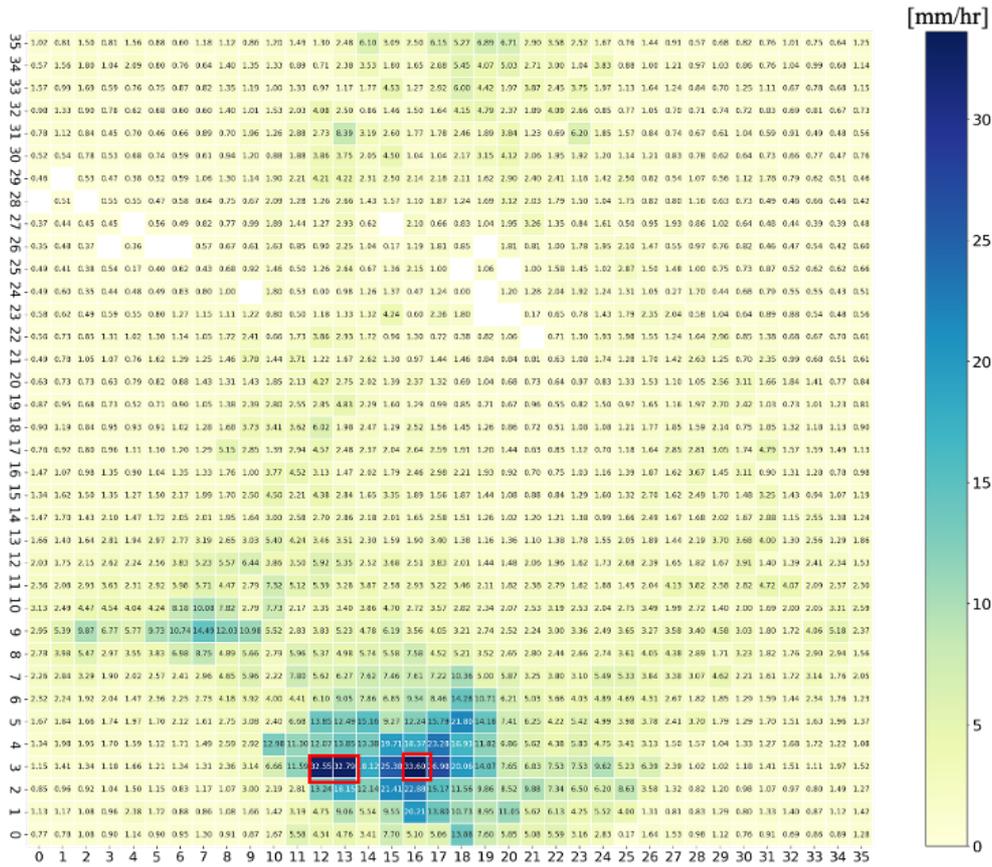


圖 4 加入西南氣流指標之模式建立，拓撲中每個神經元為平均降雨量。藍色越深顯示雨量越高，紅色框為較高雨量之神經元。

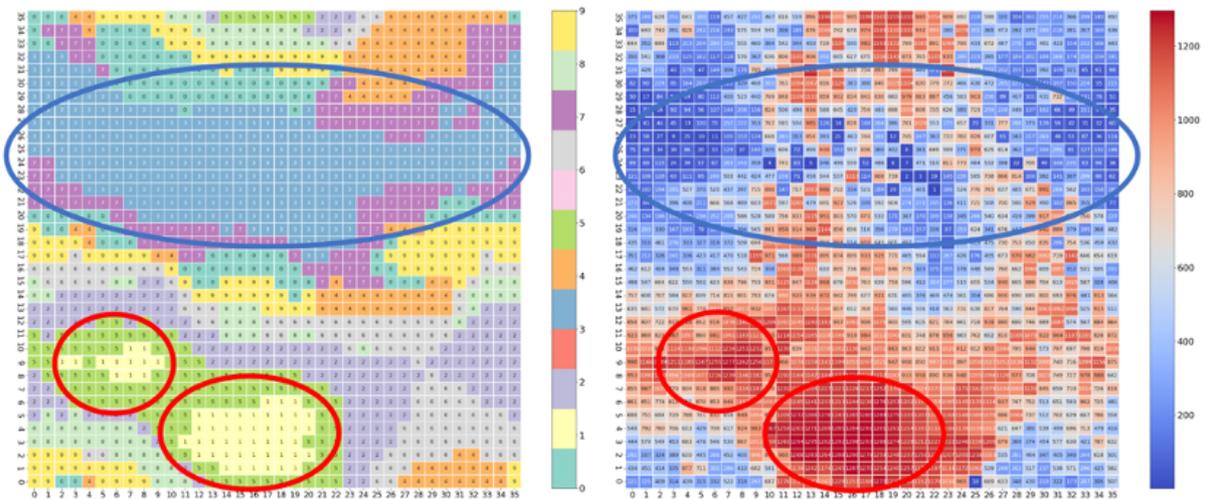


圖 5 左圖：各神經元 K-means 分群結果，右圖：平均時雨量排名之熱區神經元 (藍色框為較低淹水警戒風險區，紅色框屬於短延時降雨熱區分布)

另外在各個神經元挑出風速、風向分析，可顯示出在各分群中仍有不同的風速、風向如圖 6，模式中將因不同氣候因子將訓練出不同的結果，風速、風向特徵明顯影響模式分類，因而將影響雷達回波值分類。以本次加入西南氣流指標初步結果，分類的辨識度是高的，對應平均時雨量高強度的極端值將可以呈現出來。最後再 K-means 分群中，畫出較低淹水警戒風險區(藍色框) Cluster 1 之風花圖及短延時降雨熱區(紅色

框)Cluster 3，從圖 7 中顯示，在低淹水警戒風險以及其他 8 個分群之風花圖，除弱西風以外，皆受東北風面的影響；反之，短延時降雨熱區主要為西南風向，與本研究所預期在各氣流指標中，西南氣流與強降雨關係最高，而其他綜觀環境尤其是東北風較不顯著。

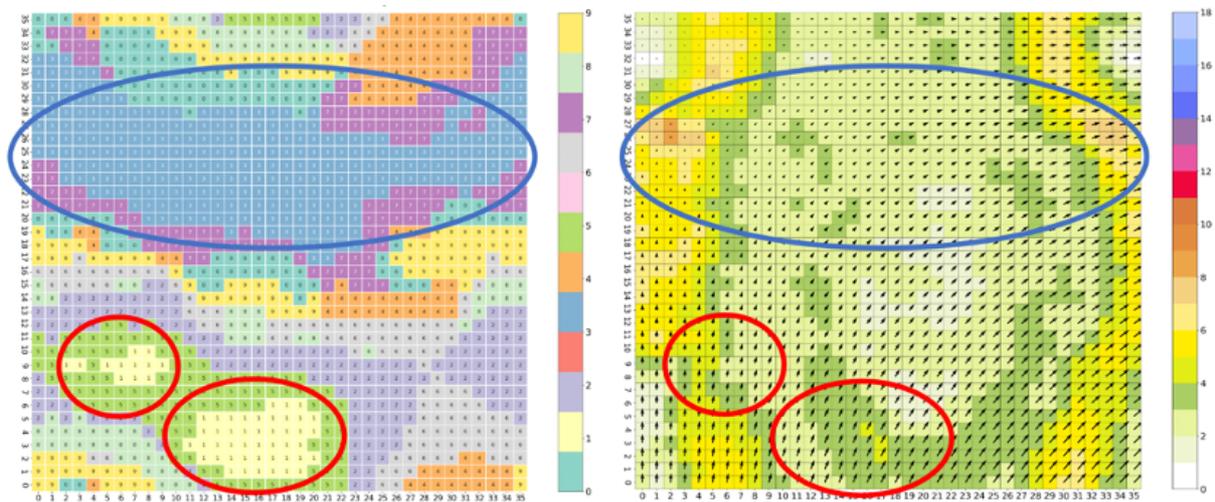


圖 6 左圖：各神經元 K-means 分群結果，右圖：風向及風速之特徵分佈至神經元 (藍色框為較低淹水警戒風險區，紅色框屬於短延時降雨熱區分布)

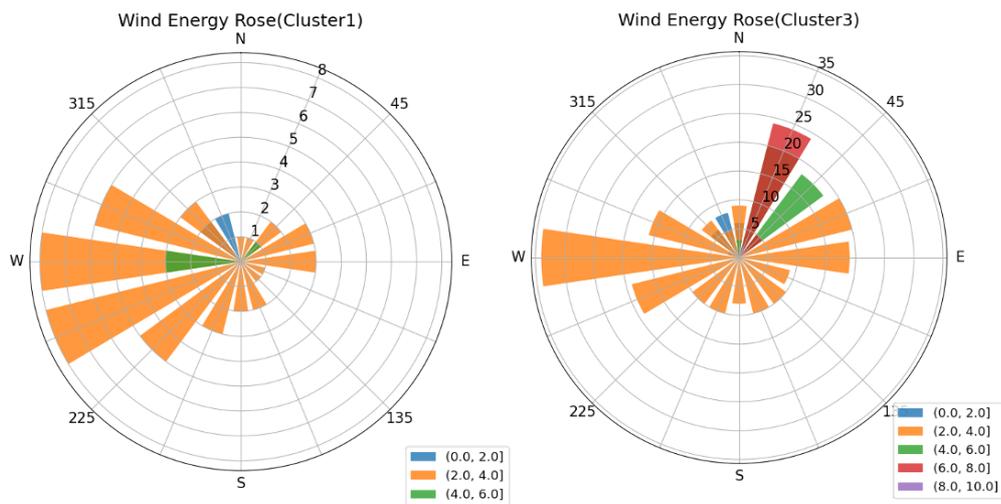


圖 7 左圖：短延時降雨熱區 Cluster 3，右圖：較低淹水警戒風險區 Cluster 1

蒐整完畢之各項氣象因子透過 SOM 之自我學習，可得到如上之拓樸關係圖(圖 4)，接續模式訓練 Nest-SOM 為 10*10 之架構，故具有 100 個神經元。此研究需要特別做 Nest-SOM 主是原因為訓練資料筆數過多，因此會主導 SOM 分類的結果表現，使用 Nest-SOM 分類做更精細及各指標上差異的觀測。為了使整體模式訓練表現更好，降維度至 500 筆左右的資料。找出更精準的回波和雨量關係仍是用長安國小及民生國中站的資料訓練，所得出回波空間資料，並得出中華里淹水及警戒「致災熱區」如圖 8。每一個神經元都代表一類氣象因子群組向量，故可提供短延時強降雨時之各類氣象因子大致類別。此外，在 Nest-SOM 中藉由歷史淹水事件做對應，各個神經元可呈現發生淹水事件之機率圖，在 100 個神經元其中有 15 個機率超過 50%，可說明未來所發生的氣象

因子型態若分類至這 15 個神經元中，有超過一半機率將會淹水，並且當落在神經元 (9,5) 時，有百分之百機率將淹水。其餘為 0% 機率的神經元中平均時雨量 23.60mm/hr，而最高神經元平均時雨量為 57.25mm/hr。

	9	0%	0%	40%	67%	0%	0%	17%	28%	0%	0%
	8	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
	7	0%	0%	0%	40%	20%	0%	0%	0%	0%	0%
	6	62%	40%	0%	0%	0%	0%	0%	0%	0%	40%
x	5	50%	25%	0%	0%	0%	0%	0%	0%	33%	100%
	4	20%	0%	0%	0%	50%	0%	33%	0%	17%	56%
	3	25%	0%	11%	67%	40%	0%	0%	44%	0%	50%
	2	0%	0%	0%	0%	0%	40%	0%	0%	67%	0%
	1	33%	0%	63%	0%	20%	0%	43%	0%	20%	0%
	0	10%	25%	75%	56%	36%	0%	0%	0%	0%	50%
		0	1	2	3	4	5	6	7	8	9
		y									

圖 8 中華里 Nest-SOM 各個神經元之淹水機率圖

本研究採用 SOM 模型對兩測站氣象因子之雷達回波值與實際降雨情況進行訓練，並進行觀測發生淹水機率關係從中做進行特徵分類。此外，採用特定標準來降資料維度至 Nest-SOM 用於訓練和分析更多區域數據，並為研究區域構建概率積淹水預警系統。所提出的模型是在 SOM 的基礎上透過歷史雷達回波、降雨及淹水數據進行分析，挑選出具有特定屬性的數據而建立的，可為淹水預警報提供相關效益訊息，並顯示研究區域警戒和積淹水災害發生前的預警、不同網格之降雨特徵，能提出模型對極端事件的敏感度以提出相關場域之適用性

5、 結論

本論文針對傳統的局限性提出了 SOM 方法，並將其應用於洪水預警預報。研究顯示，使用此雷達回波的模型比現有模型具有更高效率。在本研究中，所提出的模型是 SOM 來訓練兩測站的降雨及淹水關係，並對中華里的淹水降雨氣象因子型態之特徵進行分類。採用 K-Means 聚類方法，建立了 29 個氣象指標特徵和淹水特性。此外，Nest-SOM 用於訓練和分析更多區域數據，構建研究區域的概率洪水預警系統(PFEWS)，而由本研究結果可歸納出以下結論：

- (1) SOM 的模型之間的區別在於三維雷達回波空間數據分析。模型建立在 SOM 的基礎上，藉由歷史數據分析，選定特定數據，為淹水預報提供有用的信息。
- (2) 歷史觀測事件建立之 SOM 以改進提前預測。結果證實，SOM 拓撲圖中的數據提供淹水熱區之神經元，可準確指出歷史淹水事件及高平均時雨量。
- (3) 開發機率式淹水預警系統，所提出的極端事件模型的性能。結果顯示了研究區在預警和淹水災害發生前的預警、不同網格特徵的降雨特徵，以及相對應的氣象因子特徵和降雨頻率。

上述結果顯示，目前使用 SOM 針對了降雨量預估和預報中，的確已有能力提前掌握相

關降雨和災害訊號。但是在雷達回波與不同地形高程、距離關係上掌握程度仍有不確定性；經過評估後選定特定訓練區域以及使用頻率式降雨量預報之方式，能適當的發布警戒和淹水預報，更能提前發布機率性預報以及雷達回波所對應之降雨範圍。此模型可以提供具有增強空間分辨率的機率性淹水預警戒，以便當地居民及使用端對當前的積淹水預警預測採取防災措施。此外，可更完整地評估相關之積淹水和降雨量警戒。

參考文獻

1. 全臺北淹水災情管制表- Emergency Response Center, WRA, <https://fhy.wra.gov.tw/fhy/>，2021年1月28日讀取。
2. 交通部中央氣象局：〈臺灣氣候〉，https://www.cwb.gov.tw/V7/climate/climate_info/taiwan_climate/taiwan_5.html，2018年12月11日讀取。
3. 陳桂霞, & 黃重光. (1999). 自組織映射圖網路簡介.
4. 彩雲颱風災害應變處置報告結報，<https://www.emic.gov.tw/>，2021年7月19日讀取。
5. 國家災害防救科技 (2018)。台灣氣候的過去與未來；臺灣氣候變遷科學報告 2017—物理現象與機制重點摘錄。
6. 臺灣大學氣候天氣災害研究中心團隊。(2017)。106年度臺北市災害防救深耕計畫期末報告書。臺北市政府。
7. 臺灣大學氣候天氣災害研究中心團隊。(2017)。106年度新北市災害防救深耕計畫期末報告書。新北市政府。
8. 黃威雄(2000)，應用類神經網路於颱風期間雷達降雨模擬之研究，國立臺灣大學土木工程學系，碩士論文，共76頁。
9. 黃明宏(2008)，格網型類神經網路颱風降雨量模擬模式，國立成功大學水利工程研究所，碩士論文，共110頁。
10. 童偉安(2015)，以類神經網路及複迴歸分析建構颱風降雨量及地下水位預測模式，國立中興大學水土保持學系，碩士學位論文，共113頁。
11. 蔡孟蓉(2006)，類神經網路結合衛星影像預報颱風降雨量，國立臺灣大學生物環境系統工程學研究所，碩士論文，共87頁。
12. 周乃昉、鄭子璉、林柏承(2000)，應用類神經網路於颱風降雨量的推估，第十一屆水利工程研討會論文集，檢自：<http://www.tlcheng.tk/Paper/rain00/rain00.htm>
13. 羅竣文(2010)，應用類神經網路於颱風降雨量即時預報之研究，國立台灣大學工學院土木工程研究所，碩士論文，共90頁。
14. 劉鑛鏊(2009)，利用機器學習修正QPESUMS雷達估計降雨，國立成功大學水利工程研究所，碩士論文，共102頁。
15. Akbari Asanjan, A., Yang, T., Hsu, K., Sorooshian, S., Lin, J., & Peng, Q. (2018). Short-term precipitation forecast based on the PERSIANN system and LSTM recurrent neural networks. *Journal of Geophysical Research: Atmospheres*, 123, 12,543–12,563.
16. Buahin, C.A.; Sangwan, N.; Fagan, C.; Maidment, D.R.; Horsburgh, J.S.; Nelson, E.J.;

- Merwade, V.; Rae, C. Probabilistic flood inundation forecasting using rating curve libraries. *J. Am. Water Resour. Assoc.* 2017, 53, 300–315.
17. Chang CC, Lin CJ. 2001. LIBSVM: a library for support vector machines. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
 18. Chang FJ, Chung CH. 2012. Estimation of riverbed grain-size distribution using image-processing techniques. *Journal of Hydrology* 440: 102–112.
 19. Chang LC, Shen HY, Wang YF, Huang JY, Lin YT. 2010. Clustering-based hybrid inundation model for forecasting flood inundation depths. *Journal of Hydrology* 385(1–4): 257–268.
 20. Chang, H. K., Lin, Y. J., & Lai, J. S. (2018). Methodology to set trigger levels in an urban drainage flood warning system—an application to Jhonghe, Taiwan. *Hydrological Sciences Journal*, 63(1), 31-49.
 21. Chang, L.-C., Chang, F.-J., Yang, S.-N., Tsai, F.-H., Chang, T.-H., & Herricks, E. E. (2020). Self-organizing maps of typhoon tracks allow for flood forecasts up to two days in advance. *Nature Communications*, 11(1), 1-13.
 22. CHOI-WAN typhoon disaster response report by Central Emergency Operation Center, 2021
 23. F D. Miljković, "Brief review of self-organizing maps," 2017 40th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO), Opatija, 2017, pp. 1061-1066, doi: 10.23919/MIPRO.2017.7973581.
 24. Intergovernmental Panel on Climate Change. *Climate Change 2013: The Physical Science Basis. Working Group I Contribution to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change: IPCC*, 2014.
 25. K. Direk and V. Chandrasekar, "Study of Hurricanes and Typhoons from TRMM Precipitation Radar Observations: Self Organizing Map (SOM) Neural Network," 2006 IEEE International Symposium on Geoscience and Remote Sensing, Denver, CO, 2006, pp. 45-48, doi:1109/IGARSS.2006.16.
 26. Kia MB, Pirasteh S, Pradhan B, Mahmud AR, Sulaiman WNA, Moradi A. 2012. An artificial neural network model for flood simulation using GIS: Johor River Basin, Malaysia. *Environmental Earth Sciences* 67(1): 251–264.
 27. Kohonen T. 2001. *Self-Organizing Maps*. Springer: New York.
 28. Lin GF, Chen GR, Huang PY, Chou YC. 2009a. Support vector machine-based models for hourly reservoir inflow forecasting during typhoon-warning periods. *Journal of Hydrology* 372(1–4): 17–29. DOI: 10.1016/j.jhydrol.2009.03.032.
 29. Lin GF, Chen GR, Huang PY. 2010. Effective typhoon characteristics and their effects on hourly reservoir inflow forecasting. *Advances in Water Resources* 33(8): 887–898. DOI: 10.1016/j.advwatres.2010.04.016.
 30. Lin GF, Chen GR, Wu MC, Chou YC. 2009b. Effective forecasting of hourly typhoon rainfall using support vector machines. *Water Resources Research* 45(8): W08440. DOI: 10.1029/2009WR007911.
 31. Lin GF, Chen LH. 2004. A non-linear rainfall-runoff model using radial basis function network. *Journal of Hydrology* 289(1–4): 1–8.
 32. Rinehart, R. E., & Garvey, E. T. (1978). Three-dimensional storm motion detection by conventional weather radar. In (Vol. 273, pp. 287-289).
 33. Toth, E., Brath, A., & Montanari, A. (2000). Comparison of short-term rainfall prediction models for real-time flood forecasting. *Journal of hydrology*, 239(1-4), 132-147.
 34. Vasiloff, SV, Howard, KW, Rabin, RM, Brooks, HE, Seo, D.-J., Zhang, J., Kitzmiller, DH, Mullusky, MG, Krajewski, WF, & Brandes, EA (2007). Improving QPE and very short term QPF: An initiative for a community-wide integrated approach. *Bulletin of the American Meteorological Society*, 88(12), 1899– 1911.

35. Verworn, A., & Haberlandt, U. (2011). Spatial interpolation of hourly rainfall effect of additional information, variogram inference and storm properties. *Hydrology and Earth System Sciences* 15 (2011), Nr. 2, 15(2), 569- 584.
36. Zhang, J., and et al., 2011: National Mosaic and Multi-Sensor QPE (NMQ) system: Description, results, and future plans. *Bull. Amer. Meteor. Soc.*, 92, 1321–1338, doi:10.1175/2011BAMS-D-11-00047.1.
37. Zhu, Q., Hsu, K.-l., Xu, Y.-P., & Yang, T. (2017). Evaluation of a new satellite-based precipitation data set for climate studies in the Xiang River basin, southern China. *International Journal of Climatology*, 37(13), 4561– 4575.