

臺灣地區鋒面系統客觀辨識方法之比較

張巧薇¹ 江建霆² 劉高原¹ 蘇世顥^{1*}

1 中國文化大學大氣科學系 2 中國文化大學地學所

(中華民國 107 年 10 月 26 日 收稿；中華民國 108 年 3 月 27 日定稿)

摘要

本研究利用三種不同的客觀分析診斷工具，測試對於辨識臺灣地區鋒面事件的能力。基於鋒面熱力參數(TFP)之空間變異所發展之診斷工具，在診斷分析時，可同時提供鋒面位置與強度等資訊，有助於推估受鋒面影響之降雨之空間分布與降雨強度變化。另外，以自組織映射圖(SOM)群聚分析技術發展之診斷工具，為非監督式學習架構，可大幅降低人為主觀判斷所導致之誤差。診斷的同時，將各類型相似環境特徵的事件加以標示，對於推估氣候變遷下，伴隨鋒面系統之劇烈天氣事件發生頻率變異提供極佳的資訊。考量到計算資源限制與降低主觀誤差等要素，我們發展基於機器學習技術之診斷工具。針對鋒面系統判定之測試結果顯示，無論是以線性或非線性模組作為核心之演算模型，均能掌握鋒面頻率變化之長期變異。傳統客觀分析方法診斷影響臺灣之鋒面系統能力較差，各季節之命中率約 0.1-0.25，但誤報率較低。SOM 診斷工具在命中率表現些微優於機器學習方法，但同時伴隨著誤報率偏高的缺點。相較於傳統客觀分析方法，這兩種新的客觀診斷工具之系統判定成效皆較佳。整體而言，以 SOM 技術為基礎之診斷工具能診斷出大部分鋒面事件，但有過度判定的傾向。而基於機器學習方法之診斷工具，在命中率上與 SOM 相距不遠，但卻可大幅降低誤報率，對於長期鋒面系統頻率變化有較好的掌握能力。

關鍵詞：鋒面系統、客觀診斷、群聚分析、機器學習

* 通訊作者：蘇世顥, ssh3@g.pccu.edu.tw

一、前言

臺灣位於副熱帶東亞季風氣候區，氣候上多屬於高溫且多雨條件，年平均降雨量約 2500 mm (Su et al., 2012)。但因為臺灣的地勢陡峭，導致水資源保留不易，同時也容易產生災害性的大雨事件，故雨量變化趨勢一直是天氣分析預報與氣候推估上的重要研究議題。過去關於臺灣降雨的時間與空間分布特性的研究分析顯示，臺灣的降雨時空分布呈現高度的不均勻 (e.g. Su et al., 2012; Wu et al., 2017)。在空間分布上，受到地形的影響，導致山區的降雨比平地多。時間分布特性上，南臺灣有分明的乾、濕季變化，降水主要集中在梅雨季與夏季，冬季至隔年春季則為相對乾季。這樣的季節差異特性受到區域性之天氣系統的影響，如北臺灣的冬季降雨相較於夏季雖然較少，但受東北季風與鋒面系統影響，12 月至隔年 2 月間的區域平均降雨量依舊可達 600 mm。進一步區分影響臺灣降雨時空分布的天氣型態，主要包含冬季之東北季風、乾季的綜觀鋒面（以冷鋒系統為主）、梅雨季的滯留鋒面、夏季的颱風與西南氣流，還有在缺乏主要天氣系統影響下的弱綜觀午後熱對流。這些天氣型態中，最主要的兩種綜觀天氣系統分別為颱風與鋒面，且其伴隨之降雨特性也不相同，對於水資源調度、災害防救與氣候調適策略都會產生影響。

利用中央氣象局（central weather bureau, CWB）24 個局屬測站的時雨量資

料，並使用臺灣大氣事件資料庫 (Taiwan Atmospheric event Database, TAD) 所提供的天氣事件資料，針對天氣事件之降雨進行分析。我們定義降雨強度達 0.1 mm/hr 以上為降雨事件，並使用 10 mm/hr (Su et al., 2012) 以上為強降雨事件，分析不同天氣事件之降雨變化。圖 1 為 2001 年到 2016 年間，颱風 (TY)、鋒面 (FT) 與其他天氣型態之降雨量變異。以兩大主要綜觀天氣系統而言，伴隨鋒面發生的降雨事件佔全年降雨事件的 20-25%，其整體佔比多於伴隨颱風發生的降雨事件 (圖 1(a))。而標準化之年累積降雨量分析 (圖 1(b)) 顯示，我們可以看到伴隨颱風與鋒面系統的累積降雨可達全年降雨之 40-50%。但我們已注意到，即便是兩者之累積雨量多於其他天氣事件，兩者都具有明顯的年際變異。如果聚焦在易導致災害的強降雨事件，資料顯示伴隨鋒面的強降雨事件佔比較颱風更多 (圖 1(c))。整體來看，颱風雖然事件發生頻率較低，但伴隨之降雨平均降雨強度較強，而鋒面系統所伴隨的降雨延時較長，發生的事件頻率比颱風更高。換句話說，我們需要更精準之掌握鋒面系統之特性與變化，可以降低對於水資源調度與天氣災害的衝擊。

過去我們缺乏針對鋒面系統長期變化的研究，原因在於缺少快速且相對準確的診斷技術去進行相關鋒面系統判定。這樣的分析方法在 1960 年代以前，一律是由受過專業訓練的天氣分析員，透過主觀的方法利用

觀測資料手動進行主觀分析(e.g. Lamb, 1950)，這也是目前全球主要天氣中心作業的主流方法(e.g. Pook et al., 2012)。受限於天氣分析員的專業背景訓練差異，在鋒面系統判定過程中會產生主觀誤差，同時在資料判讀過程中需耗費大量的人力與時間，也無法透過系統性偏差分析加以修正。受惠於數值模式的進展，在 1960 年代之後逐漸發展出客觀鋒面系統診斷方法，早年主要利用網格化資料之熱力與動力參數的空間梯度變化作為指標(e.g., Renard et al., 1965, Clark et al., 1966; Steinacker, 1992)。Hewson (1998) 曾整理過去相關鋒面系統客觀診斷方法的研究，指出單純使用熱力或動力變數診斷鋒面系統會導致判斷上的偏差，需要加入能代表鋒面系統特徵之門閥值加以判定。但使用人為定義之門閥值修正判定標準的同時，也在客觀分析方法中引入主觀判定的誤差。Kirchhofer (1973)則嘗試由統計的概念出發，利用累計平方差建立起天氣系統相似性的判斷標準，並依此發展天氣型態診斷方法。類似的概念下，另一些研究則利用在統計領域已相對發展成熟之經驗正交函數(Empirical Orthogonal Functions, EOFs)作為工具，透過分析天氣系統的主要空間型態(principal spatial patterns)進行天氣系統的診斷(Richman, 1981; Huth, 1996a, b)。

伴隨電腦科技與統計方法演進，更多基於進階統計模型所發展的天氣分類技術陸續問世。Key and Crane (1986)提出利用群聚

分析方法，去區分各類型不同的天氣型態。他們的研究顯示相較於傳統的線性診斷工具，這類型基於非線性計算概念的統計工具可以處理更多複雜的非線性問題。K-means (Kanungo et al., 2002)與 Kohonen (1982)所提出的自組織映射圖(self-organizing maps, SOMs)，這兩種基於類神經網路(Artificial Neural Networks, ANNs)為架構分析方法，便曾被嘗試用來作為天氣診斷的工具。例如，Nguyen et al. (2017)便運用 SOM 技術，以 2011-2016 年日本九州的梅雨季節的強降水事件訓練統計模型，在針對梅雨季強降水事件所進行之預報實驗中，展現出優於傳統數值模式的預報能力。但群聚分析方法中初始猜測與預先選擇輸入之天氣參數等需求，都因為必須預先滿足已知的物理條件限制，導致在診斷系統中引入部分之主觀偏差。近年來受惠於資料科學的快速發展，提供了我們另一種發展天氣系統診斷方法的途徑。如果能透過大量已發生之歷史個案與氣候資料的訓練，可由氣象資料本身發展出辨認天氣特徵的診斷工具，這便是機器學習的基本概念。

本研究基於能準確區分影響臺灣之天氣系統為目標，發展能辨識臺灣地區鋒面事件的客觀診斷工具。本文將分別介紹三種不同的客觀鋒面系統診斷工具的特性與使用上的限制，包含了傳統鋒面熱力參數(Thermal Front Parameter, TFP)客觀診斷工具、自組織映射圖(SOM)診斷工具與機器學

習診斷工具。第二部分介紹研究中所使用的各種資料，與作為判定基準的主觀鋒面系統資料，並針對 2011-2016 年的鋒面事件進行

診斷實驗，探討三種鋒面系統診斷的技術能力。最後將討論各種分析技術與方法的特性，並說明未來可應用之方向。

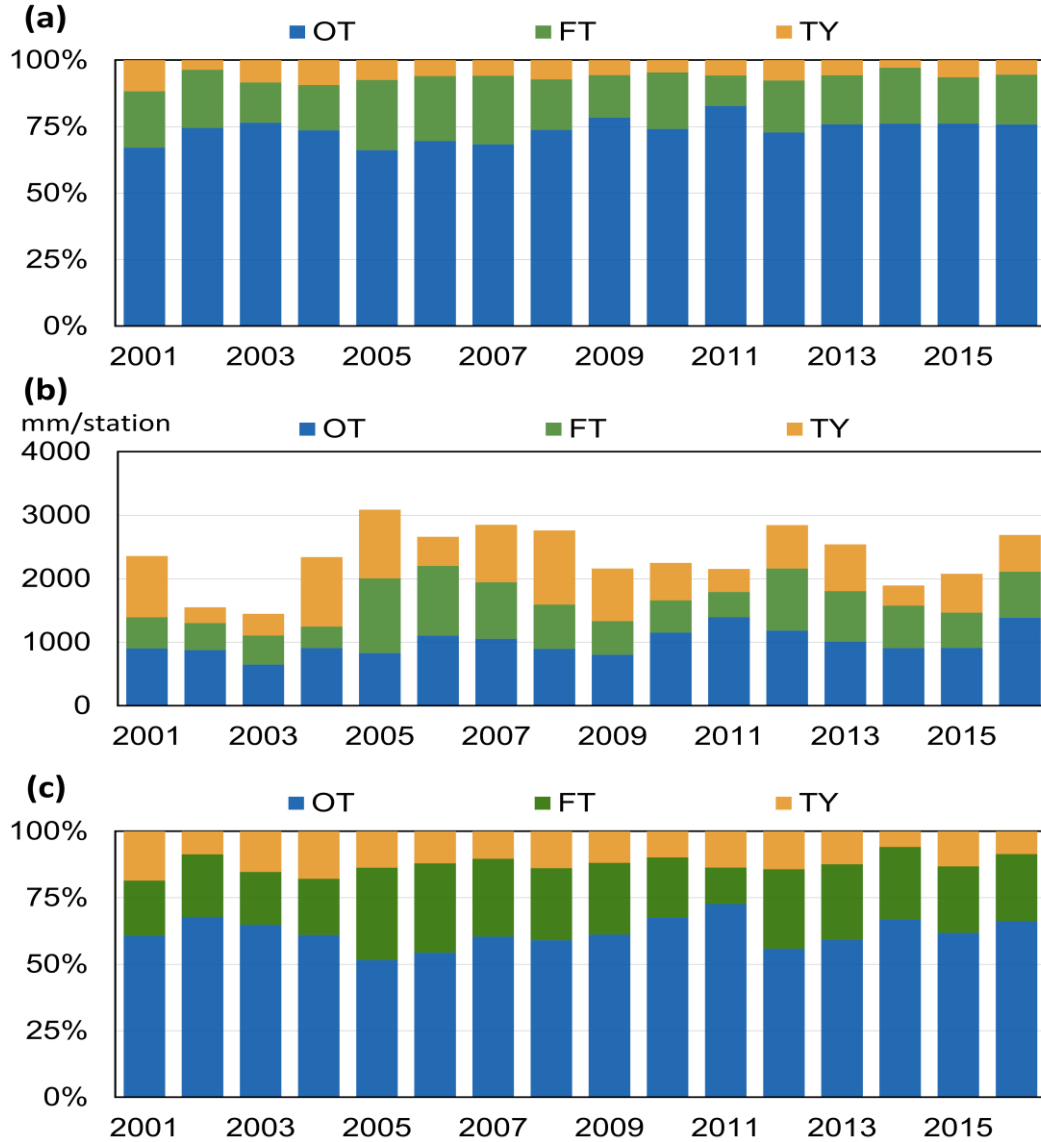


圖 1 2001-2016 年 (a)臺灣降雨事件相關天氣事件百分比圖。(b)臺灣標準化降雨量(mm/station)與相關天氣事件統計圖。(c)臺灣強降雨相關之天氣事件百分比圖。本研究使用 CWB 24 個局屬測站資料，定義時雨量達到 0.1 mm 為發生降雨事件，達到 10 mm 則定義為發生強降雨事件，並根據 TAD 資料對應降雨事件發生當日的天氣事件。鋒面(FT)與颱風(TY)為造成降雨的最主要天氣系統，兩者之外的天氣事件歸類為其他(OT)。假設鋒面與颱風同日發生，則優先採計鋒面事件。

二、實驗資料與臺灣鋒面系統主觀分析

(一)長期氣象資料

本研究依循 Su et al. (2018)的工作，同樣透過臺灣大氣事件資料庫(TAD)取得 1980-2016 年間影響臺灣鋒面事件的日期，並以此主觀判定資料作為客觀判定的比較基準。TAD 中的鋒面事件，是基於 CWB 每日 00Z 所發布的東亞地面天氣圖，作為判定鋒面事件是否發生的依據。考量到鋒面特性為一過渡帶，缺乏絕對精準的定位依據，因此在劃定鋒面影響臺灣地區時，我們設定北緯 21° 至 26°、東經 119° 至 123° 的範圍做為判定標準，其中包含部分臺灣外海。若主觀分析之鋒面通過範圍內的任一區域（圖 2(a)），或主觀分析之鋒面的尾端在臺灣範圍內（圖 2(b)），還有主觀分析之鋒面觸碰到所劃定之範圍邊界時（圖 2(c)），皆紀錄為鋒面事件。這樣的主觀分析鋒面資料，與 Pook et al. (2012)所使用之人為分析鋒面資料分析方法相似。

本研究同時利用美國國家氣象局國家環境預測中心 (Nation Centers for Environmental Prediction, NCEP)，所產製的高解析再分析資料 NCEP-CFSR(Climat Forecast System Reanalysis)(Saha et al., 2010)。此資料集可提供水平解析度為 0.5×0.5 度，由 1979 - 2016 年間逐日的氣象環境資訊，並將其作為傳統鋒面熱力參數 (TFP)客觀診斷工具、自組織映射圖(SOM)

診斷工具與機器學習診斷工具等三種診斷鋒面的方法的輸入。針對不同之分析方法，我們分別選用 925 hPa、850 hPa、700 hPa、500 hPa 等層場之重力位高度場 (geopotential height, 簡稱 HGT)、海平面氣壓場 (mean sea level pressure, 簡稱 MSLP)、相對濕度 (relative humidity, 簡稱 RH)、溫度場 (temperature, 簡稱 T)、U 風場 (horizontal wind of U component, 簡稱 U)、V 風場 (horizontal wind of V component, 簡稱 V) 及降水率 (precipitation rate, 簡稱 PR) 等變數 (表 1)。使用此資料集的優點在於，再分析資料已經透過大量觀測資料去調整數值模式模擬的結果，過去也被廣泛使用在各項氣象研究中用來代表實際的觀測值。我們相信再分析資料能有效表現當時大氣環境條件，一定程度上可降低診斷鋒面系統大氣環境特徵時因數值模擬所產生的誤差。

(二)臺灣地區鋒面系統之氣候分析

在使用這些資料前，我們先利用 TAD 所定義出的鋒面系統影響時間，分析 1981 年至 2016 年臺灣之鋒面頻率，結果如圖 3 所示。長期資料顯示，臺灣平均一年約有 73 天受鋒面系統的影響，且在近 36 年間呈現下降的趨勢。若以鋒面系統主要影響的季節來看，冬季（前一年之十二月至二月）、春季（三月至四月）與梅雨季（五月至六月）的鋒面日數，分別為 17.8 天、20.7 天與

22.5 天。而鋒面影響日數佔該季節總日數之百分比，分別約 20 %、34 % 與 37 %。由資料中我們注意到梅雨季之鋒面系統影響頻率最高，但若以影響的鋒面系統個數來看卻是最少，這代表每一道鋒面系統的影響時間最長。另一方面，各季節鋒面影響日數的標準差分別為冬季 7.4 天、春季 5.4 天與梅雨季 4 天。這顯示了冬季鋒面的年際變異較大，而梅雨季鋒面頻率之年際變異則最小。近 36 年間的長期變化而言，冬季和春季分別以每十年減少 2.2 天與 2.5 天，兩者都呈現顯著遞減的趨勢。換句話說，影響臺灣乾季降雨的主要綜觀天氣系統頻率呈現遞減的趨勢，而這與大氣環境場的長週期變異有關。Hung et al. (2004)指出北臺灣春雨除了聖嬰週期的訊號外，亦與太平洋年代際震盪(Pacific Decadal Oscillation)所導致的大尺度大氣環境場變異有關。梅雨季的鋒面系統頻率相較於乾季，並沒有明顯的變化趨勢，但梅雨鋒的影響時間在近 15 年卻以每年減少 2.5 小時的趨勢減少。

我們將受鋒面系統影響的時間進行合成分析，圖 4 可以代表鋒面影響時東亞的大氣環境特徵。以低層大氣而言，冬季鋒面的南北溫度梯度最大，春季其次；梅雨鋒面的水平溫度很小，與典型的中緯度鋒面系統特性差異較大。而低層大氣之水氣場一直呈現北乾南濕的配置，春季之鋒面系統相較於

冬季鋒面有較多的水氣。梅雨季則伴隨著東亞夏季季風，有一水氣較多的濕舌，由南海經過華南地區延伸至臺灣附近。低層大氣之輻合場則顯示，冬季與春季鋒面系統之輻合帶主要位於臺灣海峽至北部外海區域。除了鋒面系統導致的輻合作用外，北臺灣局部地區會伴隨較強的輻散場，輻合帶呈現典型的西南-東北走向。而梅雨季鋒面影響時，臺灣大部份地區位在強輻合區，且鋒面帶的走向較接近東-西走向。整體來說，鋒面系統在不同季節的熱力與動力特徵皆不相同，而臺灣附近之鋒面系統與中緯度鋒面系統的熱力特徵也有差異，故傳統用來判定中緯度鋒面系統的客觀分析方法在診斷臺灣鋒面系統時需要一定程度的調整。

三、鋒面判定之客觀方法

我們分別利用三種不同的客觀分析診斷方法，測試判定 2011-2016 年間影響臺灣地區之鋒面個案。第一種方法為基於鋒面熱力參數(TFP)的空間變異所發展之診斷工具，屬於傳統客觀分析方法之一。第二種則是基於類神經網路架構的自組織映射圖(SOM)分析方法，配合大量長期氣象資料加以判定鋒面事件。第三種方法則是利用機器學習技術，透過學習辨識已知的鋒面事件大氣環境特徵，發展出可診斷鋒面事件的統計模型。

表 1 客觀診斷工具所輸入之 NCEP-CFSR 變數。(x 標記該工具所使用之變數)

Levels	200 hPa			500 hPa	700 hPa / 850 hPa / 925 hPa				925 hPa	Surface level	
Variables	Zonal wind (U)	Meridional wind (V)	Temperature (T)	Geopotential height (H)	Zonal wind (U)	Meridional wind (V)	Temperature (T)	Relative Humidity (RH)	Equivalent potential temperature (θ_e)	Mean sea level pressure (MSLP)	Precipitation rate (Pr)
Methods											
Traditional objective analysis									×		×
SOM clustering method					850 hPa only	850 hPa only	850 hPa only	850 hPa only			
Machine learning method	×	×	×	×	×	×	×	×		×	
Unit	$m s^{-1}$	$m s^{-1}$	K	gpm	$m s^{-1}$	$m s^{-1}$	K	%	K	Pa	$K \cdot kg \cdot kg^{-3} \cdot s^{-1}$

(一) 熱力鋒面參數(TFP)之鋒面診斷工具

本研究利用低層大氣 TFP 作為鋒面系統是否影響臺灣之判定標準。過程中，我們依據臺灣地區的大氣環境特性並考慮地形等因素，針對熱力參數之選定、地形效應之修正、鋒面降水權重調整與判定門閥值的修改等問題，透過一系列之分析實驗，最佳化基於熱力鋒面參數所發展之鋒面系統診斷工具。在 Hope et al. (2014)的研究中，建議使用濕球位溫梯度作為 TFP 進行鋒線系統的診斷，此一參數過去廣泛地被應用在中緯度鋒面系統客觀工具中，因為它同時可以顯示溫度與水氣空間梯度之特徵。Su et al. (2012)的研究中分析 1960-2010 年間臺灣地區大氣環境平均相對濕度的變化，顯示

即便受到全球暖化之影響導致相對濕度呈現下降之趨勢，但是整體而言都高於 75%。在這種環境相對濕度偏高的條件下，透過蒸發過程產生的降溫會受到限制，導致濕球溫度與環境溫度差異較小，使得濕球溫度梯度變化較不顯著。本研究保留 Hope et al.(2014)利用溫度與水氣空間梯度變化判斷鋒面系統的概念，改用相當位溫梯度($\nabla\theta_e$)當作判定依據。相當位溫能同時量化環境中溫度變化與水氣之潛熱效應，在臺灣地區之空間分布特徵較濕球位溫梯度顯著，對環境溫度與水氣在空間上的分布特徵也更具代表性。

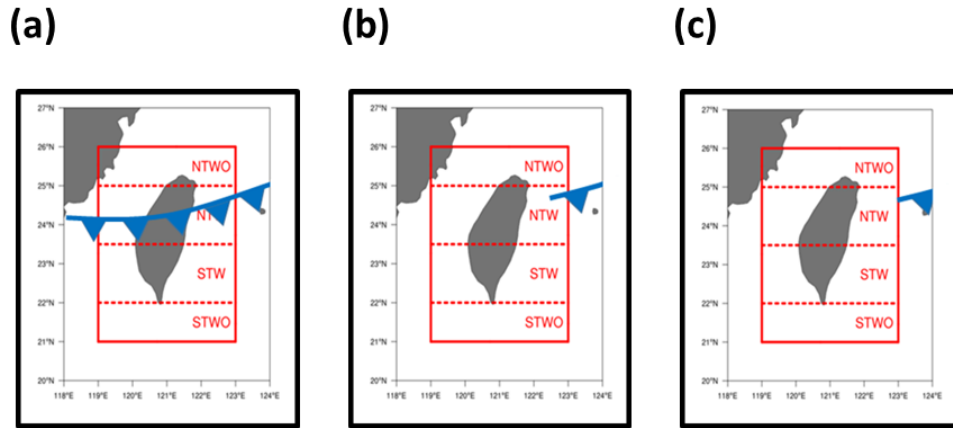


圖 2 判定影響臺灣之鋒面系統示意圖。我們將以下天氣條件判定為影響臺灣之鋒面系統，(a) 鋒面系統完全進入影響範圍。(b)鋒面系統僅影響臺灣附近海域。(c)鋒面系統位於判定邊界。紅色邊框為判定影響臺灣之邊界；藍色為鋒面系統。

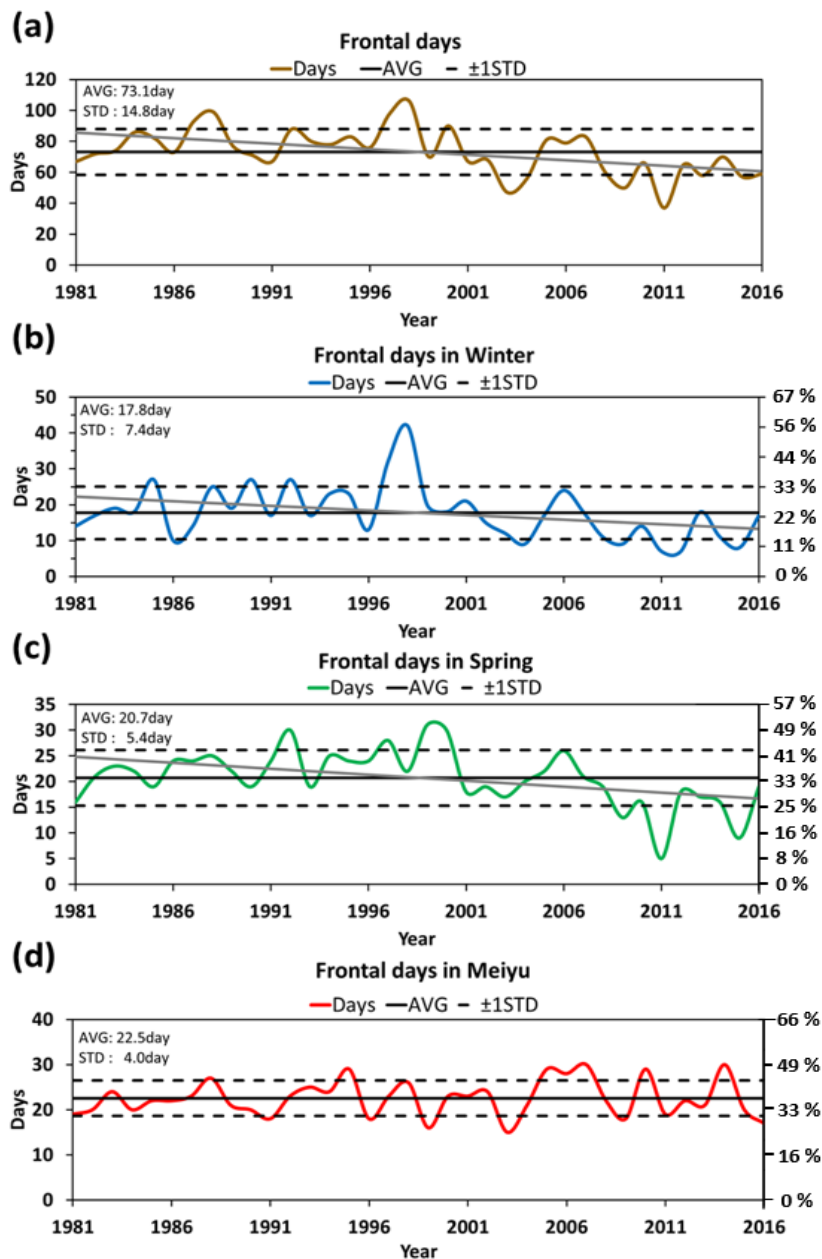


圖 3 1981-2016 鋒面天數。左側縱軸為鋒面日數，右側縱軸為佔季節總日數之百分比，黑色實線為平均值，黑色虛線為正負一個標準差，灰色實線表示通過 95% 統計檢定的趨勢。(a)全年，(b)冬季，(c)春季，(d)梅雨季。

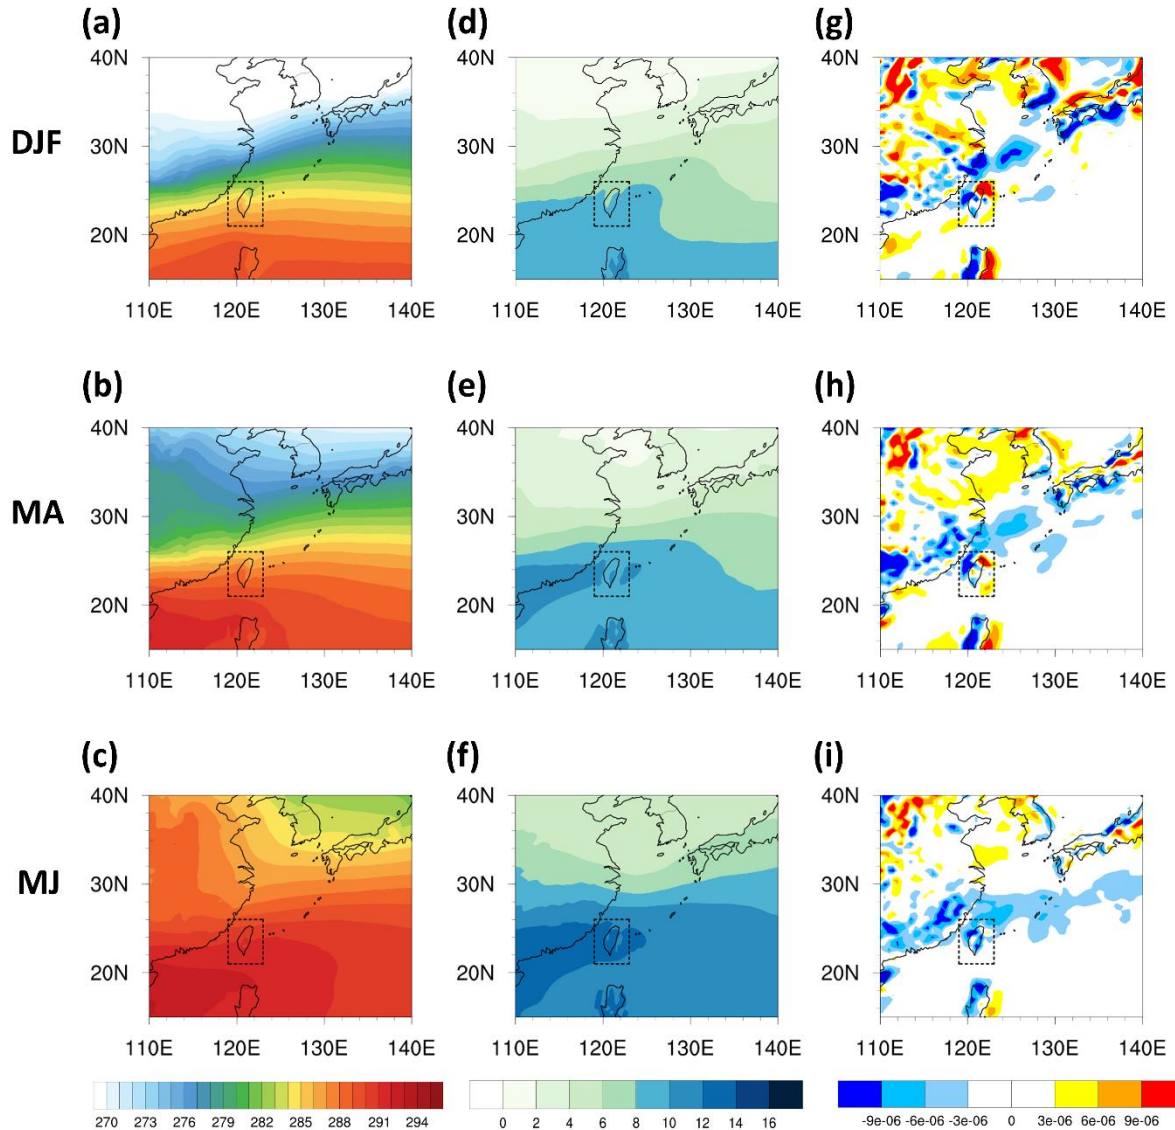


圖 4 1981-2016 年鋒面日合成平均。(a)-(c)分別是冬季、春季、梅雨季的 850 hPa 溫度場 (單位: K)，(d)-(f)為冬季、春季、梅雨季的 850 hPa 水氣 (比濕) 場 (單位: g kg^{-1})，(g)-(i)則是各季的 850 hPa 輻散場 (單位: s^{-1})。

另一方面，受限於傳統的鋒線客觀診斷工具，使用單一高度 TFP 水平空間梯度作為鋒面診斷之依據。當冬季鋒面系統影響緯度較低的臺灣區域時，大陸冷氣團受到動力與熱力條件之限制，會導致冷空氣厚度變薄。因此，為增加對於此類型鋒面系統之診

斷能力，我們在使用 TFP 為基礎之客觀診斷工具時，將使用 925 hPa 之相當位溫 (單位: K) 作為輸入之資料。在過去的研究中 (e.g., Odon et al. 2018) 顯示，在使用數值模式之近地表資料時，受到模式地形的影響熱力與動力參數皆會產生系統性之偏差。為避

免這些系統性誤差所導致的誤判，在診斷過程中我們加上地形高度的限制，僅使用高度在 750 公尺以下的資料點。在診斷流程中，我們參考 Hope et al. (2014) 之作法，設定 500 公里作為鋒面系統之長度下限。同時為了降低地形上之 TFP 資料的影響，我們在診斷流程中也加入搜尋鄰近 200 公里（臺灣東西寬度）與 400 公里（臺灣南北距離）的補償機制。

透過以上的分析流程測試，我們發現對於判斷臺灣附近之鋒面系統時，僅使用 TFP 作為判斷依據時，命中率與誤報率相當，也代表對於鋒面系統之診斷能力較低，尤其以梅雨鋒面系統最低（劉，2017）。考量到大部分影響臺灣的鋒面系統都伴隨降水現象，所以我們利用降雨率 (PR) 做為 TFP 的權重，透過將相當位溫梯度乘上 PR，使用 $\nabla\theta_e \times PR$ 作為新的判定之依據。我們同時分析 $\overline{\nabla\theta_e \times PR}$ 的氣候特徵與鋒面事件特徵值，使用累積機率函數 (cumulative distribution function, CDF) 分析合適之鋒面系統判定門閥值。本研究以誤報

事件累積最快的區間作為條件，將 $\overline{\nabla\theta_e \times PR}$ 大於 $200(10 \cdot K \cdot kg / km^3 \cdot s)$ 設定為鋒面系統之判定門閥標準。圖 5.1 為我們利用 TFP 進行鋒面系統診斷分析之流程圖，其中包含了使用門閥值篩選之步驟，各步驟之說明如下：

1. 輸入計算 TFP 之氣象參數，搜尋空間上所有 TFP 經向最大值之位置（以下簡稱最大值點）。
2. 資料範圍內，由最小經度之最大值點，向東尋找 200 公里內相鄰點並標記。
3. 資料範圍內，由最低緯度之最大值點，向北搜尋 400 公里內相鄰點並標記。
4. 計算所有標記之最大值點的平均 TFP，並利用門閥值篩選滿足條件之連線。
5. 累計滿足條件之相鄰最大值點連線長度，將總長度超過 500 公里之系統視為鋒面。
6. 利用所標定之鋒面位置，判定系統是否影響臺灣地區（與主觀分析使用相同判定標準）。

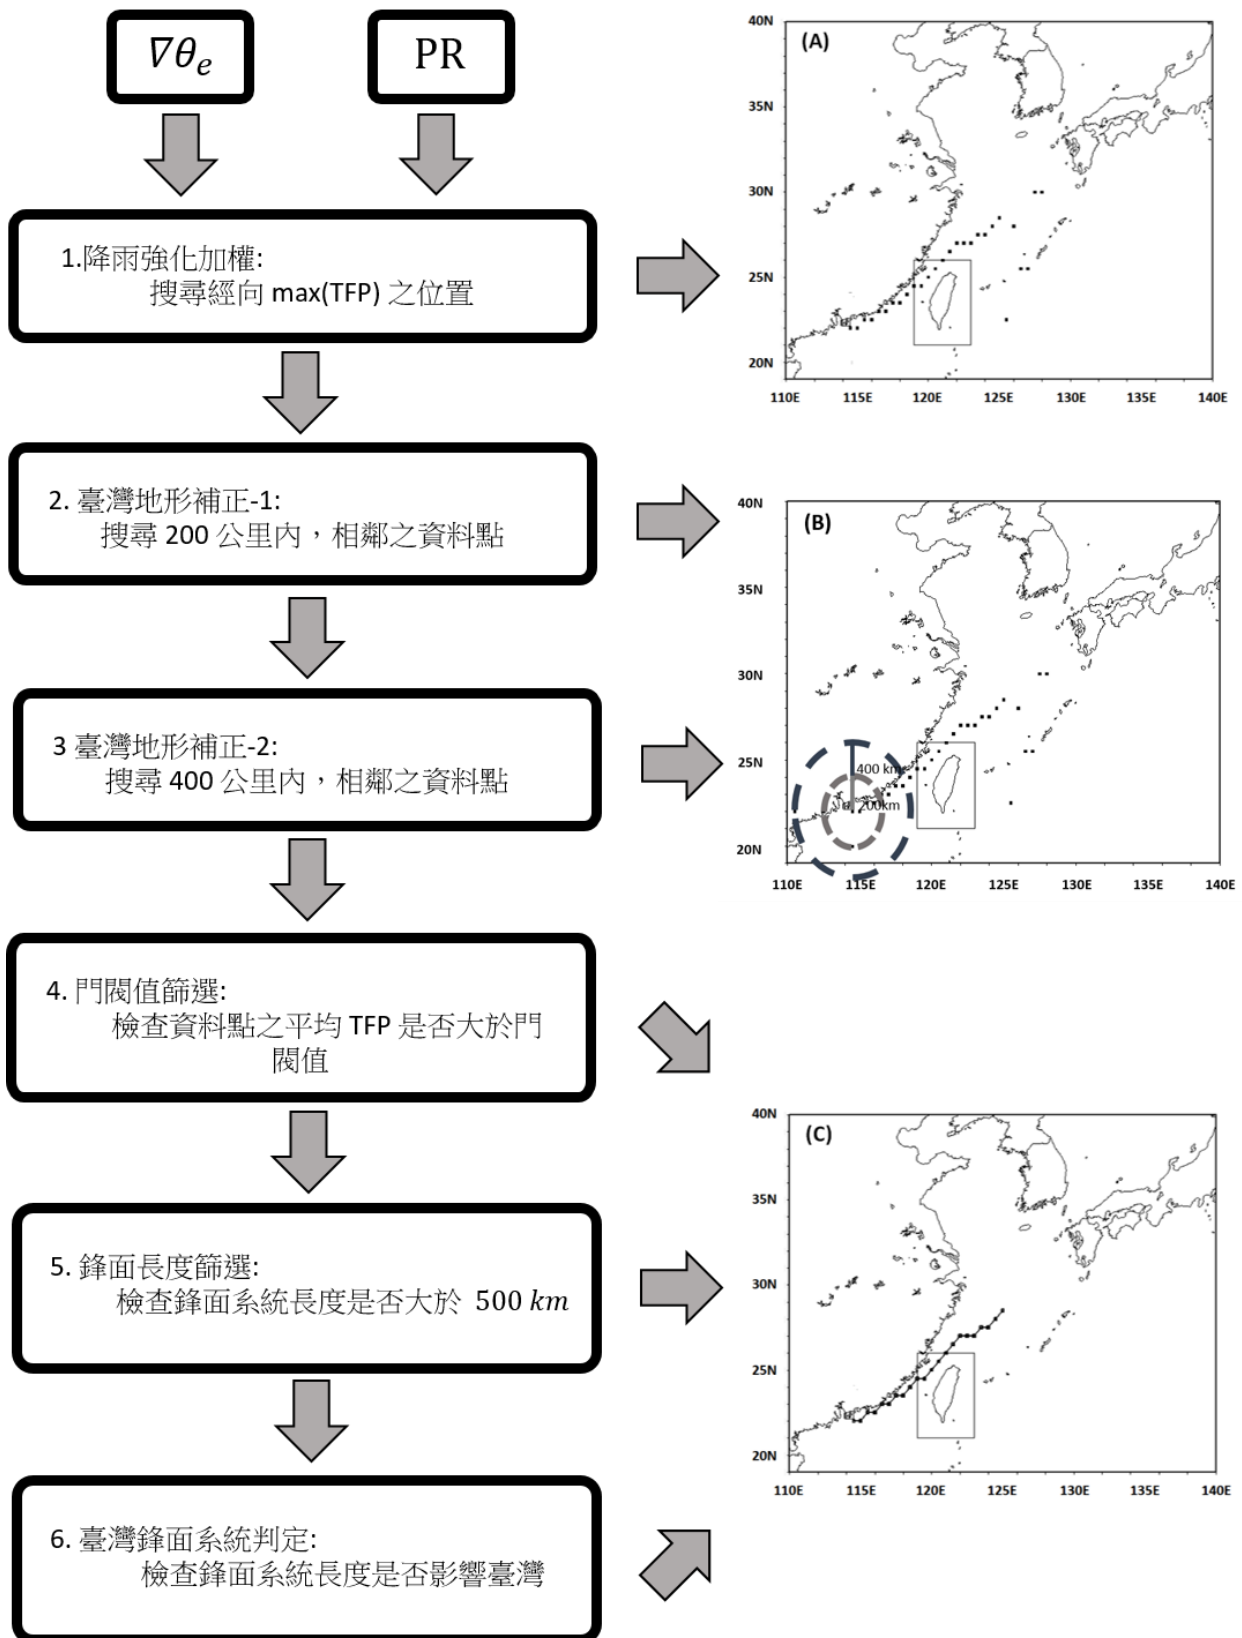


圖 5 客觀分析方法判定鋒面流程圖，(a)分別計算 $\nabla\theta_e$ 、 $\nabla\theta_e \times PR$ 以及加入門閥值 TFP 判定之鋒面位置，(b)利用降雨率(PR)加權 TFP 所判定之鋒面位置，(c)透過門閥值篩選後之鋒面位置。

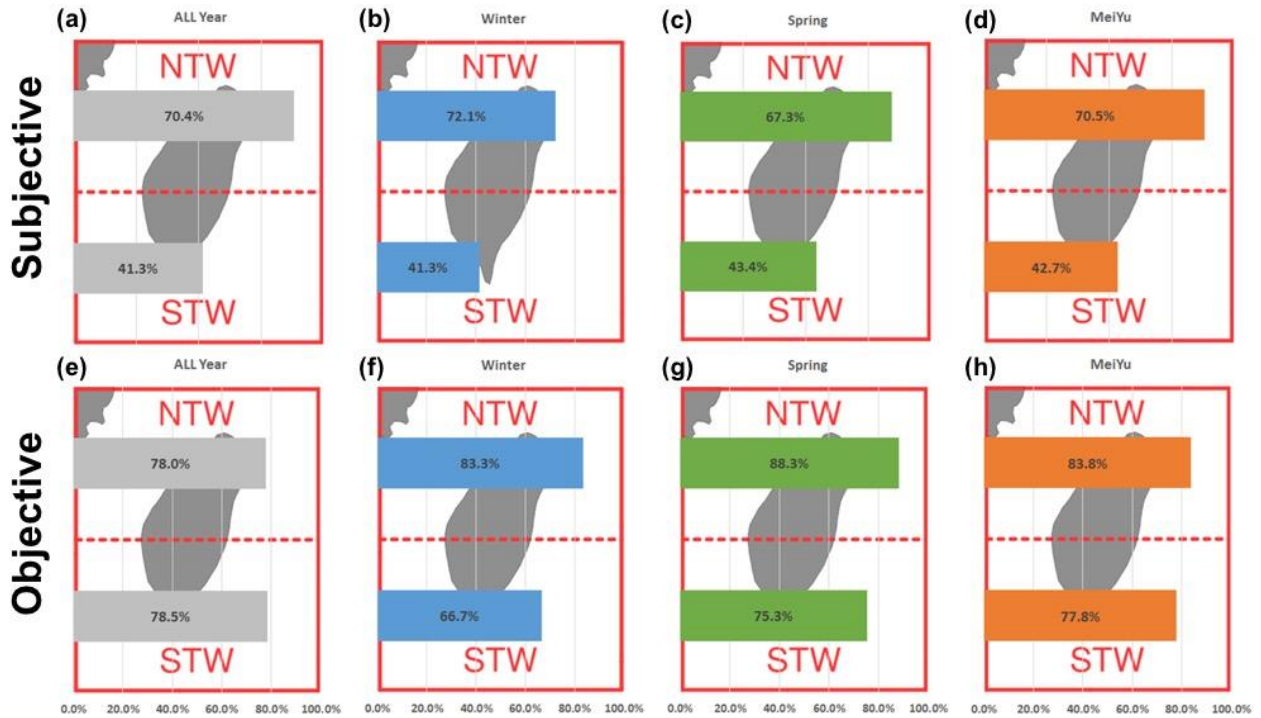


圖 6 影響臺灣之鋒面系統空間分布特性。(a)-(d)為主觀判定之鋒面系統空間頻率，(e)-(h)則為傳統客觀分析方法診斷知結果。由左至右，分別代表全年、冬季、春季與梅雨季之鋒面頻率空間分布。

整體來說使用 TFP 發展之客觀診斷工具存在一些限制，首先類似鋒面系統的線狀對流會在診斷過程中因為降雨強化而產生誤判。且為了減少診斷工具的誤報率而引進之門閥值，也會在客觀分析方法中引入主觀偏差。但這樣的工具卻有其他的優勢，使用這種診斷工具的優點在於在判定鋒面系統的同時，可提供鋒面影響時間、鋒面空間位置與強度等資訊，而這些鋒面特徵值對於分析降雨頻率空間變異的研究上會有很大的助益。圖 6 是我們使用 TFP 發展之客觀診斷工具，分析 2011-2016 年影響臺灣地區鋒面系統之空間分布特性。圖中之(a)-(d)為主觀分析之鋒面影響頻率，(e)-(h)則是客觀分析結果。我們可以發現，相較於主觀

分析之鋒面影響頻率，使用傳統客觀分析方法大致可以掌握鋒面事件北多南少的分布特徵。但受到線狀對流系統的影響，在南臺灣會發生鋒面系統頻率高估之現象。

(二) 自組織映射圖診斷工具

在過去的研究中，我們注意到影響臺灣地區的鋒面系統特性，與傳統中緯度氣象學所描述的鋒面特性有所差異(e.g., Ninomiya et al., 2007)。如果能利用長期大量的大氣環境特徵，針對天氣事件進行分類，應該能找出符合臺灣地區鋒面型態的天氣特徵。因此，我們嘗試利用 SOM 的群聚分析方法，作為發展診斷鋒面系統工具的基礎。SOM 是透過非監督式學習(unsupervised learning)的方法，是利用類神經網路架構針對資料特

性進行群聚分析，透過移動節點的方式，依據資料間之差異將事件分為不同群集 (Kohonen, 1982; Sá et al., 2012)。非監督式學習的特點在於，不需事先給予事件之標示，讓透過演算法由資料中自主判斷大氣環境之特徵是否相似。這大幅降低分析中的非客觀因素，過程中可避免大部分之人為主觀誤差。使用 SOM 鋒面診斷工具時，我們必須在完成群聚分析後，針對不同群集給予天氣型態之標記。這部分須對應輸入之氣象資料特徵，與實際天氣事件之環境特徵進行比對，並配合實際事件發生頻率給予標記。

使用群聚分析方法作為診斷技術，首先必須確定輸入之資料必須足以代表大氣環境狀態特徵之資訊，才能透過大量迭代運算依據特徵之相似性完成群聚分析。但以本實驗所使用之再分析資料而言，單一時間之資料維度可以高達 1.9×10^9 ，若加計資料時間長度則將超過 8.5×10^{13} ，這樣的資料量超過現有計算資源可有效處理之資訊量。在考量計算資源之限制下，在本實驗中僅選定部分之氣象參數作為輸入值。我們參考 Ninomiya et al.(2007)分析之東亞梅雨鋒面時所使用的氣象參數，並使用每日 00Z 之東亞地區（經度 118°E 至 124°E ，緯度 20°N 至 27°N ）的氣象參數場作輸入資料之區域。我們進一步透過主成分分析 (principal components analysis, PCA) 方法降低資料的維度，並採用累積可解釋變異量達九成以上的主要模態作為輸入值。透過使用

PCA 作為輸入資料，我們可以大幅降低群聚分析時所需之計算量，也確保所輸入之氣象特徵資訊具有代表性。

使用 SOM 作為群聚分析方法的優點，在於經過群聚分析後之節點與節點間的距離，亦代表大氣環境特徵之相似程度。兩個節點距離越近代表兩者之大氣環境特徵越相似，反之則差異越大。圖 7 是我們利用 1981-2016 年梅雨季之大氣環境特徵進行群聚分析後的類神經網絡節點分布。以 850 hPa 相當位溫分析為例，C3 至 C7 的節點距離較遠，代表兩者特性差異較大，而兩者也分別呈現為北方系統主導(C7)與南方的系統主導(C3)的特徵。透過這樣的分析，我們除了可獲得鋒面影響的時間頻率等資訊外，也同時得到鋒面之間的特性差異與其氣候特徵，這是使用此方法的優點。圖 8 為透過 SOM 作為客觀鋒面診斷工具，分析梅雨季的天氣特徵之範例，我們可以將 5-6 月的天氣型態區分為九種類型。藉由臺灣地區梅雨鋒面的典型特徵分析可以發現，當梅雨鋒面影響臺灣地區時，在 850hPa 相當位溫場上具有暖舌指向臺灣；同時在動力場上，臺灣地區存在顯著的輻合帶（分析未呈現於本文）。利用上述兩項之梅雨鋒面典型特徵作為依據，可將其中的 C1-C5 等歸類屬於梅雨季之鋒面系統影響的天氣狀態。

進一步分析這些可歸屬於鋒面影響的天氣型態特徵，我們注意到不同群集之間仍存在熱力場之水平梯度、空間配置或動力場

之輻合帶之強弱與位置的差異。換句話說，即便是同屬於梅雨季的鋒面系統，其大氣環境還是具有不同的特徵，導致降雨強度也不盡相同。相較於傳統使用 TFP 之鋒面客觀

診斷工具，使用群聚分析技術做為診斷工具雖然無法提供準確之鋒面空間位置與強度資訊，卻可提供更多元之鋒面系統型態、發生頻率與降雨強度差異等資訊。




圖 7 自組織映射圖 (SOM) 群聚分析之節點分布示意圖。圖中藍色圓點為迭代計算後之節點，代表不同群集之天氣特徵，紅色實線代表距離。節點距離越遠，代表天氣特徵差距越大，以 850 hPa 相當位溫空間分布為例。

(三) 機器學習診斷工具

在前一小節中我們介紹之群聚分析方法，屬於一種非監督式的類神經網路架構，雖可將不同之大氣環境條件加以分類，但與傳統氣象學的標準天氣事件分類還是有一定程度之差異。其實在現行之天氣分析作業過程上，由於影響臺灣的鋒面系統特性與傳統中緯度鋒面系統的結構特徵有所差異，也發展出一些參考的指標與檢核機制。這代表主觀鋒面診斷的過程中，天氣分析員是基於過去對當地之相關天氣系統的認知，進行大

氣環境的分析與診斷。如果我們希望所使用之鋒面系統客觀診斷工具，能與現行主觀診斷方法保持一致性，且能反映臺灣地區鋒面系統的特性，那唯有透過大量天氣系統個案去訓練統計模式，並用來診斷鋒面系統，Su et al. (2018) 便是基於相同的概念發展天氣分類工具。本研究延續相關的概念，基於長期主觀分析資料配合長期再分析模式資料，建立以監督式學習 (supervised learning) 架構為基礎的機器學習模型，並使用其作為鋒面診斷之工具。

圖 9 為本研究中建置機器學習模型之流程圖，其架構依據使用之目的，分為模式訓練與診斷應用兩個主要的階段。機器學習模型是屬於監督式學習架構，換句話說，我們透過大量已發生之天氣事件資訊，讓模型透過對於輸入資料之分析與比對，自我學習所使用之判定條件，並建立相對應之統計模型。本研究使用與 Su et al. (2018) 相同的天氣事件資料庫(TAD)，使用 2001-2010 年間所紀錄之鋒面系統作為標記，並將相對應之 NCEP-CFSR 再分析資料作為相對應的大氣環境特徵輸入資料。我們將上述資料結合鋒面系統之標記，組成標準樣本(golden standard)，並作為訓練使用之資料集。我們透過大量已發生的鋒面事件，讓模式從標準樣本中學習區分事件是否發生的資料特徵，亦即建立起天氣系統之分類演算模型。本研究基於過去之經驗，使用近年來被資料科學界廣泛應用之支援向量機(supported vector machine, SVM)模組作為主要架構(Chang et al., 2001)，並使用多項式核心(polynomial kernel)作為模型建置之演算法。利用 SVM 模組進行鋒面事件判定之的概念，是透過數學模型將訓練資料投影到高維度的特徵空間，透過數值方法在此一高維度空間中找出一個可區分鋒面事件是否發生的超平面(hyper-plane)。這樣的高維度空間投影概念之 SVM，相較於本研究中所測試之另一種亦被長期應用的廣義線性模型(generalized linear model, GLM)，SVM 在處理具有非線

性特性之資料時更具有優勢，而非線性特性也是大氣資料的重要特性之一。

使用機器學習架構的鋒面系統診斷工具的特點之一，是可由大量資料中學習如何判定鋒面系統之依據。換句話說，如何確保所輸入之資料能代表當時大氣環境特徵，會是在訓練模型過程中極為重要的環節。本研究使用 2001 到 2010 年間，CFSR 每六小時一筆之再分析資料作為訓練機器學習模型的輸入資料。我們依據過去傳統天氣診斷分析之經驗，選取 200 hPa 溫度場與風場，700 hPa、850 hPa 與 925 hPa 風場、溫度場與相對濕度，500 hPa 重力位高度場與海平面氣壓場(表 1)等變數作為輸入資料。即便僅選取部分氣象資訊作為輸入資料，但由於再分析資料具備三度空間的高時空解析度之特性，導致需處理之資料量過於龐大。由於計算資源有限，且考量到診斷分析效率的問題，我們透過 PCA 將所選定之大氣資料進行降維度處理。在本研究中，我們使用每個變數前 20 個主要模態(mode)作為大氣環境特徵資訊，與 TAD 主觀分析場所輸出的鋒面事件標籤，合併產製成模型訓練所需之整齊資料(tidy data)。我們分別基於 SVM 和 GLM 作為演算法，各自訓練鋒面系統診斷工具。在完成模型訓練後，我們固定所有變數之統計關聯，並應用此模型判定與輸入訓練資料不同之 2011 到 2016 年再分析資料，進行獨立鋒面事件診斷分析驗證。

使用機器學習之鋒面診斷工具之優點在於可突破傳統 TFP 分析方法的限制，透過輸入較多的氣象變數，可充分反映臺灣地區鋒面系統之大氣環境特徵。此外，使用這種診斷工具的另一優勢，在於可容許輸入資料存在系統性之偏差。由於大氣數值模式受限於計算能力的限制，導致依據數值模式之解析度不同，須對物理過程進行簡化或參數化。這也導致在模式中的物理過程存在著各種假設，而隨著模式所使用參數化模組的不同，也導致模式可能存在一定程度的系統性偏差。在機器學習模型的訓練過程中，我們透過過去已發生之天氣事件進行診斷模型的訓練，過程中會自主性的發展出包含修正部分系統性誤差之統計模型。這樣的優勢可以讓我們使用機器學習之鋒面診斷工具時，大幅減少因為模式系統性偏差導致的誤判，並提高正確辨識的機率。這樣的方式不僅對作業化之天氣分析過程有所幫助，若配合氣候模式的後報(hindcast)資料，可優化對於氣候變遷情境下，鋒面系統變化趨勢的推估能力(圖 10)。

四、鋒面客觀診斷工具之定量校驗與分析

在本研究中，分別使用三種不同客觀鋒面診斷工具，針對 2011-2016 年間影響臺灣地區之鋒面個案進行判定測試。我們選擇此段時間作為鋒面判定實驗的原因，除了可利用 TAD 所提供的主觀鋒面事件判定結果做為依據外，也避免使用在機器學習鋒面

診斷工具訓練過程中所使用過之資料，這樣可以更為正確的比較三種不同客觀鋒面診斷工具的能力。我們將三種工具之診斷結果，參考 Fawcett(2006) 以混淆矩陣(confusion matrix)方式量化評估各項工具之診斷能力。混淆矩陣被廣泛使用在各種針對事件判定能力的評量系統中，在資料科學領域有時也被稱之為錯誤矩陣(error matrix)。它是依據單一事件之診斷結果與實際事件間的差異，區分為命中(True Positive or Hits, TP)、誤報(False Positive or False alarm, FP)、漏報(False Negative or Miss, FN)與正確否定(True Negative, TN)四種結果。過去我們在天氣預報分析中，經常使用之前估(prefiguration)與後符(postagreement)等校驗方法，也是基於相同的概念進行。傳統天氣分析作業上，我們慣於直接使用命中率與誤報率，做為判定診斷或預報工具好壞的指標。由於兩者分別是獨立指標，在評估上無法綜合顯示診斷工具對於正確與誤判之差異對系統判定之影響。舉例來說，對於高衝擊性天氣診斷上，我們希望能盡量提高對於天氣事件之辨識能力，所以評估辨識工具的能力上以命中率為優先，誤報相對不是最重要的指標。但是對於氣候變遷研究上，天氣系統的發生頻率是一項重要的變化訊號，那誤報過程所導致的過度判定的現象就需要避免。本研究考量到這些工具可應用的各種面向，分別利用兩種不同方式呈現診斷工具的綜合能力，第一種是透過計算同時考量命

中與誤報事件之 F1 score 作為評分之標準。另一種方式，則參考 Su et al. (2018)的方法，透過接收操作特性圖 (Receiver Operating Characteristic, ROC) 分析 (Fawcett, 2006)，在下一章中呈現各種客觀鋒面診斷工具之相對能力。

依據混淆矩陣之量化的資料，分別計算各種工具之準確率 (accuracy) 命中率 (hit rate)、誤報率 (false alarm ratio) 與 F1 score 等指標，各種指標定義如下，並將結果呈現於表 2：

$$\text{準確率} = (\text{TP} + \text{TN}) / (\text{TP} + \text{FP} + \text{FN} + \text{TN})$$

$$\text{命中率} = \text{TP} / (\text{TP} + \text{FN})$$

$$\text{誤報率} = \text{FP} / (\text{FP} + \text{TN})$$

$$\text{F1 score} = 2 \times \text{TP} / (2 \times \text{TP} + \text{FP} + \text{FN})$$

(一) 熱力鋒面參數 (TFP) 診斷工具之鋒面判定實驗

如果單純使用與 Hope et al. (2014) 類似之相當位溫梯度作為 TFP 時，各季節之平均命中率約為 0.09-0.16，分別是冬季 0.16、春季 0.16、梅雨季 0.09；平均誤報率約為 0.05-0.18，分別是冬季 0.18、春季 0.16、梅雨季 0.05。這樣的結果顯示傳統客觀分析方法對於春季與冬季之判定效果較佳，對梅雨季則幾乎沒有診斷能力。這是因為相當位溫雖然同時反應了溫度與水氣的變化，但由於臺灣附近之水氣量一直維持相對高值，故相當位溫梯度與溫度梯度在空間差異較小所導致。這也說明在溫度梯度差異

大，且時間變異高的冬季與春季時使用相當位溫梯度作為 TFP 的表現較梅雨季佳。

因此我們利用降水率強化相當位溫梯度作為 TFP，結果顯示鋒面系統之平均命中率提高。伴隨鋒面降雨較顯著之春季與梅雨季鋒面系統，其診斷命中率上升至 0.21 與 0.29，而降雨相對較弱之冬季鋒面系統，命中率則略微下降至 0.15。且強化降雨權重之 TFP，使得冬季與春季的誤報率下降至 0.14 與 0.10，但梅雨季之誤報率則因上升至 0.12。在此之後，我們引入與 Hewson (1998) 相似之 TFP 門閥值作為篩選機制，透過將微弱的線狀對流系統濾除的過程，達到降低誤報率的目標。使用門閥值篩選後，冬季將損失 31.5% 的命中事件，但能改善 79.5% 的誤報；春季則損失 25.8% 的命中事件，改善 68.2% 的誤報；梅雨季損失 8.6% 的命中事件，改善 28.6% 的誤報。

整體而言，使用降雨強化之 TFP 作為依據，並配合門閥值篩選機制，三個季節的平均命中率為冬季 0.12、春季 0.16 與梅雨季 0.21。但對於平均誤報率則有較大的改善，分別為冬季 0.03、春季 0.03 與梅雨季 0.02。若以 F1 score 評估診斷工具之得分，冬季、春季與梅雨季，分別為 0.19、0.27 與 0.34。實驗結果整理於表 2。

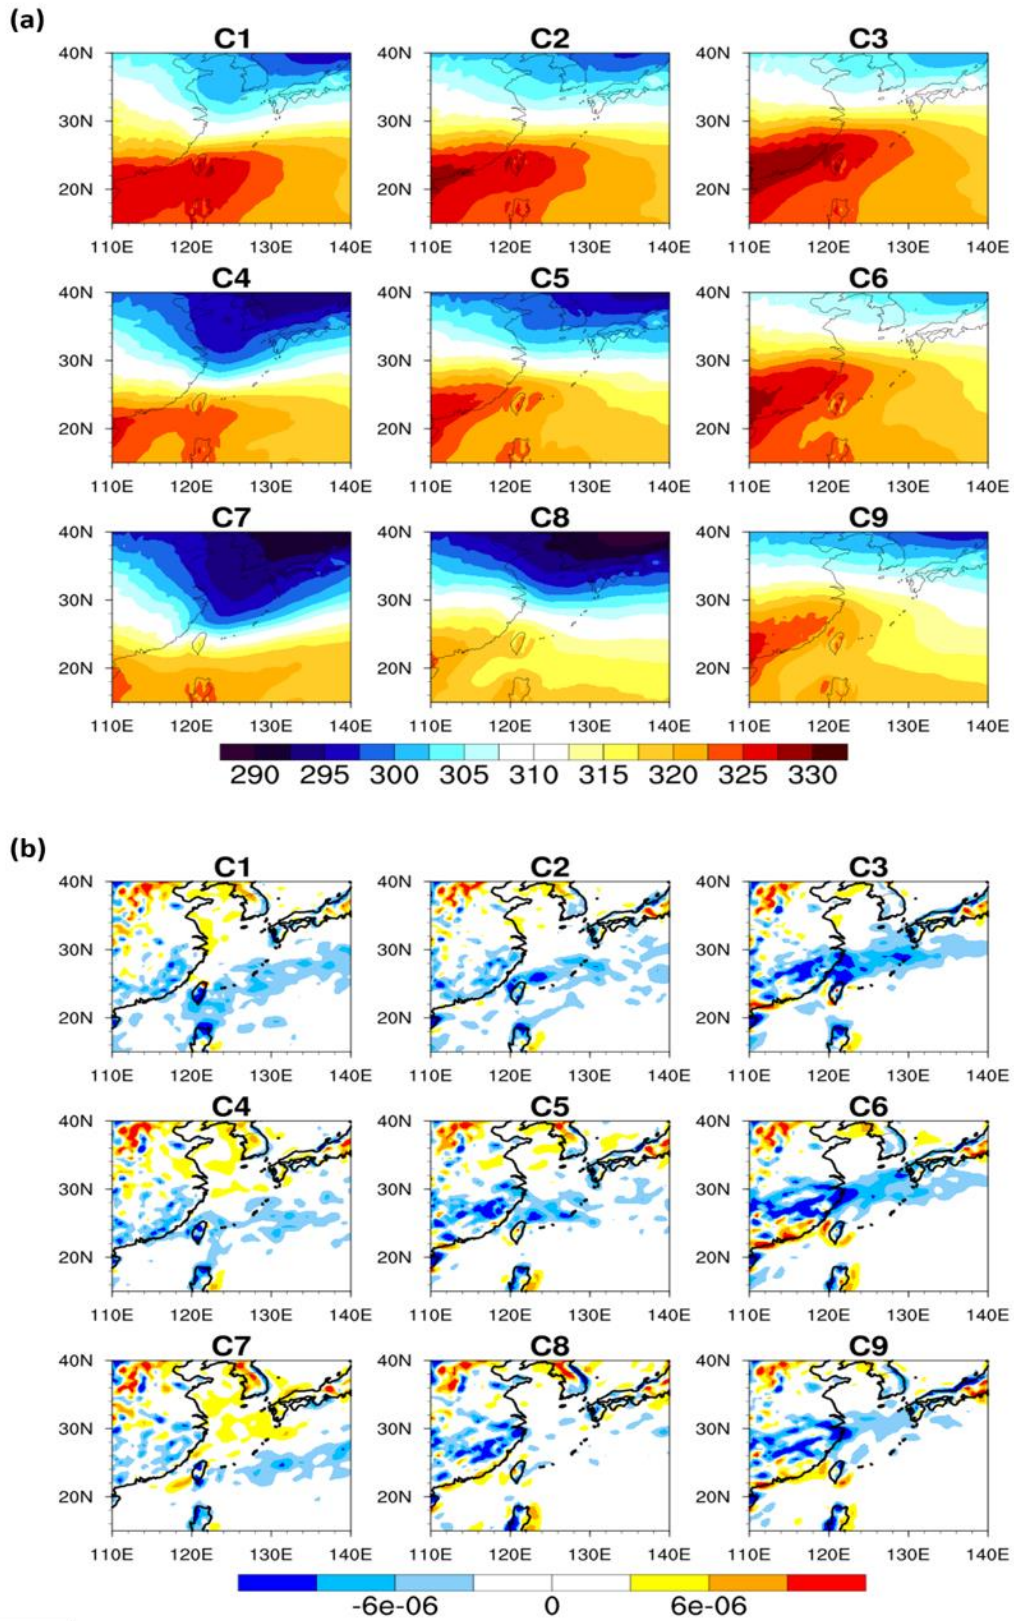


圖 8 自組織映射圖(SOM)群聚分析工具診斷梅雨季鋒面系統之結果。(a)850 hPa 相當位溫(單位: K), (b)850 hPa 輻散場(單位: s^{-1}), 負值為輻合。C1-C5 為梅雨季發生鋒面時主要環境配置。

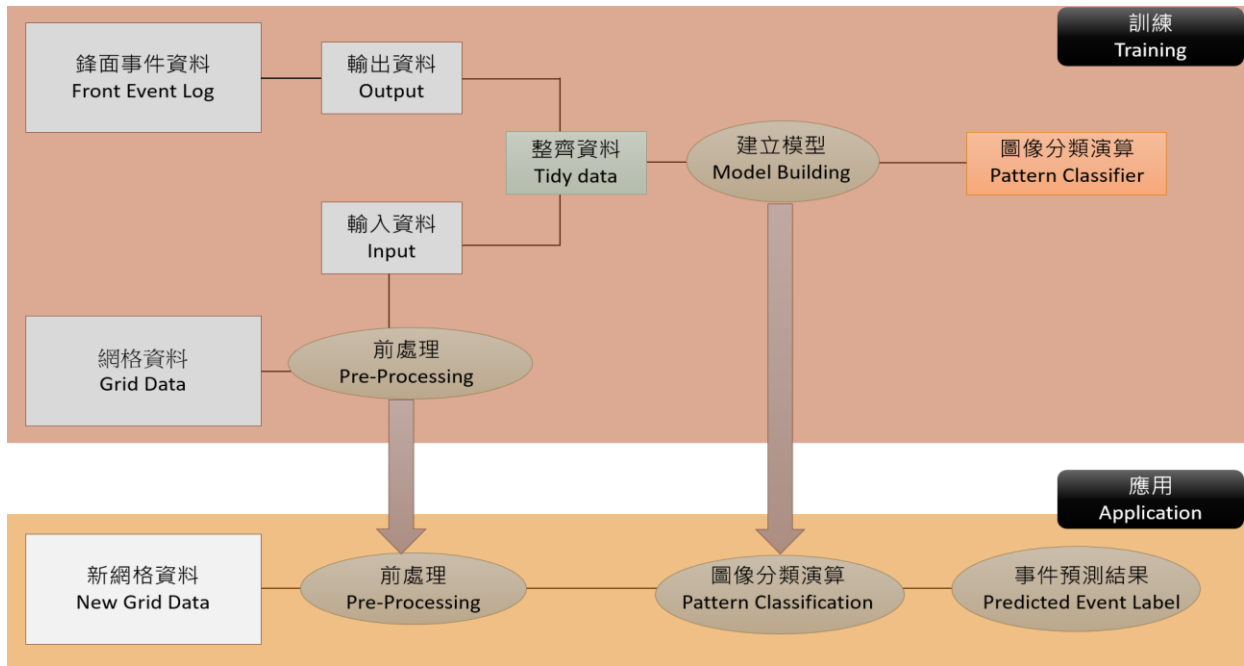


圖 9 機器學習技術之診斷系統操作流程圖。




圖 10 2011-2016 年臺灣鋒面事件數與機器學習診斷工具之分析結果。黑色折線為主觀鋒面系統發生頻率年際變化觀測值(OBS.)，藍色與紅色柱狀圖分別為利用線性(GLM)與非線性(SVM)核心所預測之鋒面影響頻率。鋒面天數定義為每六小時一筆的天氣圖與模式診斷當中任一筆發生鋒面事件即視為鋒面發生日，三者所診斷出之全年鋒面天數平均值分別是：79、88.5 與 87.3 天，標準差分別是 16.3、18.4 與 14.3 天。

表 2 傳統客觀分析、SOM 群聚分析與機器學習技術診斷工具之量化評估得分。

Season	Evaluation score	TFP objective analysis	SOM clustering method	Machine learning method	
				GLM	SVM
All year	Hit rate	0.16	0.85	0.67	0.69
	False alarm rate	0.03	0.42	0.21	0.24
	F1 score	0.27	0.52	0.62	0.64
DJF	Hit rate	0.12	0.85	0.61	0.65
	False alarm rate	0.03	0.20	0.15	0.17
	F1 score	0.19	0.52	0.54	0.56
MA	Hit rate	0.16	0.92	0.71	0.70
	False alarm rate	0.03	0.59	0.26	0.26
	F1 score	0.27	0.45	0.62	0.64
MJ	Hit rate	0.21	0.79	0.69	0.71
	False alarm rate	0.02	0.46	0.22	0.28
	F1 score	0.34	0.60	0.71	0.72

(二) 自組織映射圖(SOM)診斷工具之鋒面判定實驗

透過 SOM 作為客觀診斷工具進行鋒面事件判定, 所得到各季平均之命中率約為 0.79-0.92, 相較於前述以 TFP 作為診斷依據之工具表現更好。若區分季節來看, 冬季、春季與梅雨季之命中率, 分別為 0.85、0.92 與 0.79。但平均誤報率相比於 TFP 診斷工具較差, 約為 0.20-0.59, 各季節分別為 0.20、0.59 與 0.46。這樣的結果表示利用 SOM 做為診斷之工具, 在不同季節中都具有相當高的能力能判定出臺灣地區之鋒面系統, 但由於群聚分析之判定條件較為寬鬆, 導致誤報率的上升。在各季節中, 以春季鋒面系統的判定誤差最為明顯, 主要是因為由華南移出的雲帶, 具有與鋒面系統相似特性之環境特徵, 在非監督式判定方法中難以被診斷模式所區分。若以 F1 score 作為

指標, 則梅雨季為 0.60, 這樣的表現比冬季 (0.52) 與春季 (0.45) 更佳。

在本研究使用 SOM 作為鋒面系統診斷工具的所有的訓練與實驗過程中, 受限於計算資源與考量到工具之通用性, 我們所輸入代表大氣環境條件之變數皆相同。但由先前的分析中, 我們注意到, 鋒面系統的環境特徵有顯著的季節性差異。換句話說, 使用相同的大氣環境特徵場, 在不同季節中能提供的有效大氣環境特徵訊息量皆不相同, 易導致不同季節間鋒面診斷表現上產生差異。因此透過提高輸入之大氣環境特徵資訊量, 是進一步提升冬、春季的鋒面診斷表現的方法之一。但由於計算效率的限制, 還是必須透過針對不同季節鋒面系統之大氣環境特徵更深入的瞭解, 找出不同季節中具代表性大氣環境場之變數作為輸入資訊。這樣的做

法可有效率的提升 SOM 分析的表現，但因此產生引入主觀誤差之風險。

(三) 機器學習診斷工具之鋒面判定實驗

我們利用 2001-2010 年之鋒面與再分析資料，作為訓練機器學習模型訓練之用。訓練過程中，利用演算法隨機將訓練用資料分割成十等份，利用 90 % 之資訊訓練模型，10 % 之資料則用來進行測試驗證。訓練流程中會重複此一交叉驗證之流程，直到完成機器學習診斷模型之建構。在模型建構過程的交叉驗證中，GLM 與 SVM 模組之全年鋒面事件準確率分別是 0.89 與 0.94，命中率分別是 0.59 與 0.8，誤報率分別是 0.05 與 0.04。整體來說，機器學習診斷模型之 GLM 與 SVM 模組的 F1 score 分別是 0.65 與 0.81，表示模式對於鋒面系統特徵的掌握能力佳，且 SVM 模組具有非線性之特性，其診斷表現比 GLM 更佳。

在鋒面診斷實驗中，我們將 2011-2016 年之全年再分析資料作為輸入資料，透過與模型訓練過程中相同之 PCA 模態投影，並將其輸入至我們已訓練完成之模型，模式技術量化評估得分結果整理於表 2。圖 10 是我們利用機器學習診斷工具之兩種不同核心模組進行的鋒面判定實驗結果，GLM 所診斷出來的鋒面天數僅 2012 年為高估，與實際鋒面頻率年際變化間之相關係數為 0.8，較之 SVM 更接近實際發生鋒面天數。而 SVM 於 2011 年到 2013 年的鋒面天數診斷結果與實際值相近，從 2014 年開始

產生較大分歧，但與實際鋒面頻率年際變化間之相關係數依然有 0.74。綜合以上分析，我們注意到 GLM 與 SVM 對鋒面系統的辨識結果雖然表現較前兩種方法更好，但所診斷出之鋒面與實際鋒面間還是有一定程度之差異。這樣的差異多來自於大氣環境條件的季節差異有關，為探討導致診斷誤差之原因，我們將兩種不同核心模組所判斷出來各季節的鋒面事件合成平均進行比較。

我們將診斷偏差(bias)定義為命中事件合成平均減去漏報事件合成平均的差值，結果顯示於圖 11 與圖 12。冬季時，GLM 命中事件相較於漏報事件，有一道溫度正距平從日本延伸到臺灣，緯向溫度梯度較強，且臺灣到中國南部沿海以及日本琉球一帶水氣較多。春季時，溫度與水氣偏差結構與冬季類似，呈現類似溫帶氣旋系統的結構。梅雨季時，GLM 命中事件當中，臺灣北方冷空氣較強，臺灣附近水氣亦較豐沛。SVM 所診斷的偏差結構與 GLM 類似，代表當鋒面結構近似於典型中緯度斜壓系統時，較容易被機器學習模型判定為鋒面事件。換句話說，機器學習所診斷的鋒面事件依循著我們主觀判斷之標準，以類似中緯度斜壓鋒面系統為主要判斷之依據。同時也顯示出，機器學習診斷工具就如同 SOM 等非監督式診斷工具一樣，對於鋒面系統之判定標準具有相當之彈性，但其判定之基準相較於主觀分析過程依舊保有一致性。

五、討論與結論

本研究利用三種不同的客觀分析診斷工具，針對影響臺灣地區重要水資源與災害天氣的鋒面系統進行診斷分析。傳統使用 TFP 空間變異作為分析依據之傳統客觀診斷工具，受限於影響臺灣之鋒面系統特性與中緯度斜壓鋒面系統特徵的差異，而無法有效掌握鋒面系統發生之頻率。但其優點在於診斷分析之同時，可提供鋒面帶之空間位置與鋒面強度等資訊，這些資訊有助於判定臺灣降雨之空間分布變化與降雨強度變異。在使用 TFP 作為鋒面診斷工具時，需注意判定結果會受到季節特性之影響。在臺灣地區 TFP 客觀鋒面診斷工具對於氣候乾季之鋒面系統判定表現較佳，但在梅雨季鋒面之診斷上，則需透過降雨率加權方式強化 TFP 之空間變異。這也代表在使用此類型診斷工具進行鋒面系統診斷或長期氣候分析時，所選用之 TFP 與篩選鋒面系統之門閥值需要隨季節/氣候特徵進行調整。

另一方面，為解決鋒面系統的區域性特徵差異問題，我們使用基於非監督式類神經網路結構之 SOM 群聚分析技術為基礎發展之診斷工具。使用自組織映射圖(SOM)診斷工具時，在診斷過程中不需要給予任何事件標示，單純透過輸入大量氣象資訊透過數值方法，讓模式自主依據大氣環境之特徵加以分類。使用這樣的鋒面診斷工具，優勢在於可大幅降低人為主觀判斷所導致之誤差，同時可將相似環境特徵的事件加以標示。如圖 8 所示，我們利用自組織映射圖(SOM)

診斷工具將梅雨季之大氣環境條件區分為九種型態，發現在低層大氣的環境上，存在指向臺灣之暖舌的環境特徵時，臺灣地區大部份時候都受到鋒面系統之影響。同時在這些被判定為鋒面系統的事件中，彼此仍存在著熱力條件之空間梯度或輻合帶強弱等差異。換句話說，使用 SOM 作為診斷工具，不僅能判定出鋒面事件，也能同時將鋒面系統之不同特性加以區分。以臺灣地區之梅雨鋒面為例，圖 8 中 C1 與 C2 群集雖同屬鋒面天氣型態，但其水平溫度梯度與低層輻合強度，相較於其他群集環境狀態更易導致發生強降雨事件，且鋒面系統影響台灣的時間也相對較久。這種梅雨鋒面系統的環境差異資訊，不僅對於伴隨梅雨鋒面系統之強降雨事件的分析預報上有所幫助，對於針對不同氣候變遷情境的氣候推估上，以及對於梅雨季鋒面降雨與劇烈天氣事件的發生頻率變異，可以提供極佳的推估資訊。在使用此一工具時，一個重要的前提是作為群聚分析參考之輸入資料，需要大量足夠代表當時大氣環境狀態之資訊，且需透過大量迭代運算，最終導致所需要的計算資源十分龐大。這代表需要搭配合適的降維度工具，才能在保留大氣環境特徵的前提下，進行相關的診斷分析。

我們利用機器學習技術發展鋒面系統之診斷工具，透過針對鋒面系統判定之測試結果顯示，無論是以線性(GLM)或非線性(SVM)模組作為核心之演算模型，均能有效

的掌握鋒面頻率變化之長期變異(圖 10)。而透過誤差診斷之大氣環境差異分析(圖 11, 12), 我們發現使用機器學習診斷工具時, 無論是利用 GLM 與 SVM 模組作為核心, 其所診斷之鋒面系統依舊保留著類似中緯度斜壓系統的結構的特徵, 也導致對於斜壓性較低的系統地判定能力較低。

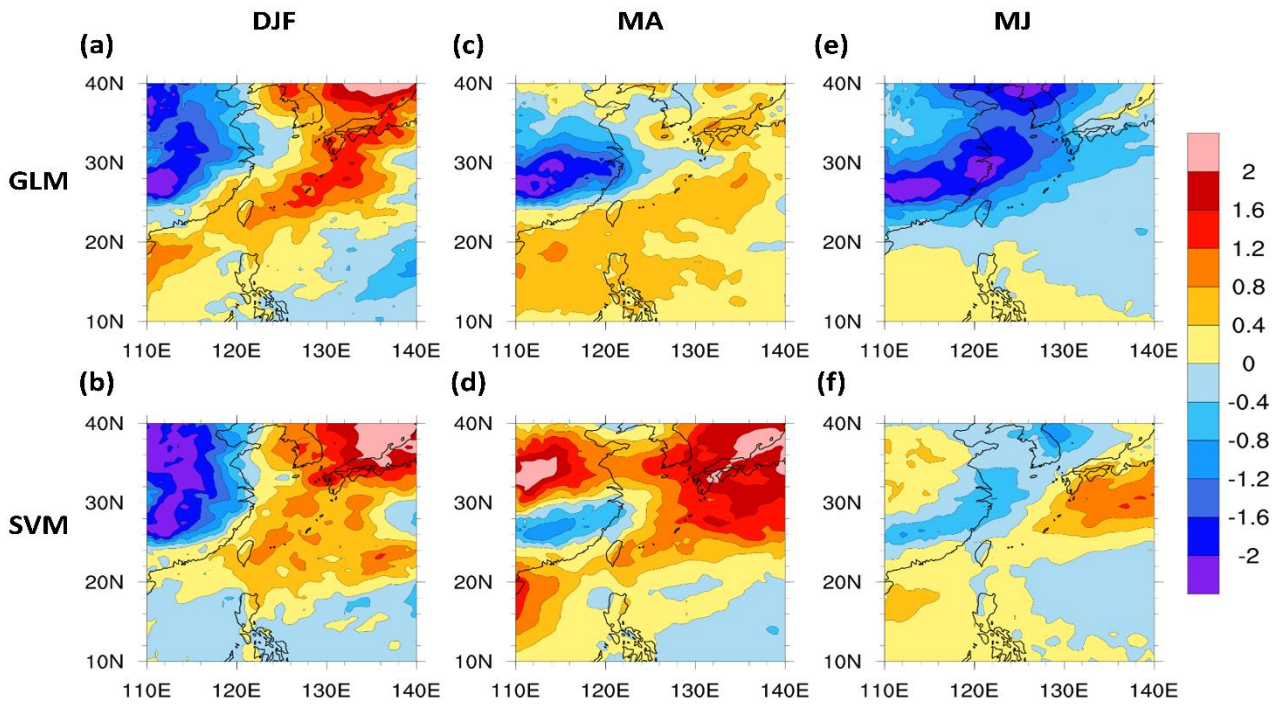


圖 11 鋒面事件診斷溫度偏差(bias)。由左而右之圖集，分別為冬季(DJF)、春季(MA)與梅雨季(MJ)的鋒面事件診斷偏差溫度空間分布。(a)、(c)、(e) 與 (b)、(d)、(e) 分別是 GLM 與 SVM 所診斷的溫度場偏差 (單位: K)

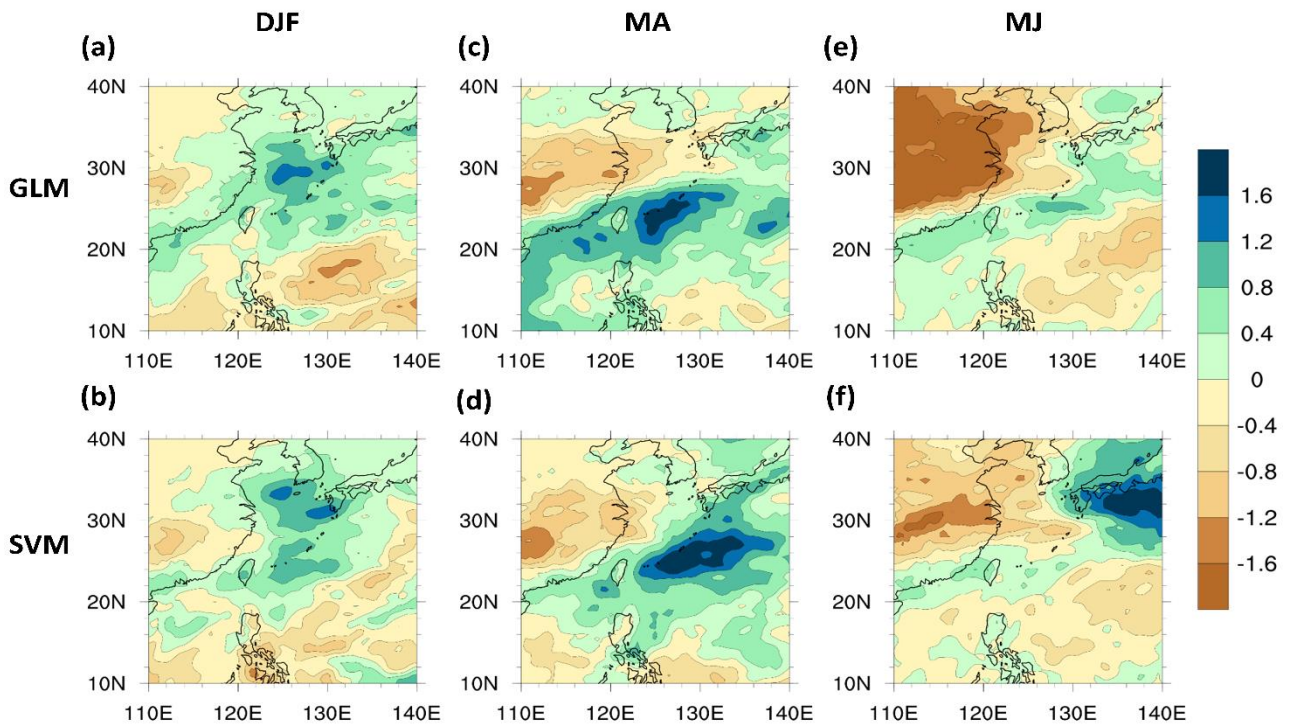


圖 12 鋒面事件診斷水氣偏差(bias)。由左而右之圖集，分別為冬季(DJF)、春季(MA)與梅雨季(MJ)的鋒面事件診斷偏差水氣(比濕)空間分布。(a)、(c)、(e) 與 (b)、(d)、(e) 分別是 GLM 與 SVM 所診斷的水氣場偏差 (單位: g kg^{-1})

我們利用 ROC 分析呈現這三種不同診斷工具之綜合表現（圖 13），並分別比較各種診斷工具在 2011 年到 2016 年間各季節之鋒面診斷能力。整體來說，在 ROC 圖中離左上角越近的点，表示命中率越高，誤報率越低，也就是鋒面系統的診斷能力越好。反之，離右下角越近，表示命中率越低，誤報率越高，也代表診斷能力越差，而低於對角線的部分則代表此一工具沒有診斷能力。整體來看，使用傳統熱力鋒面參數(TFP)診斷工具的診斷能力相對較差。雖透過 TFP 門閥值篩選與降雨強化等方式可降低誤報率，但各季節的鋒面系統命中率僅介於

0.1-0.25 之間。而自組織映射圖(SOM)診斷工具的命中率高，然而誤報率亦較高。對春季與梅雨季鋒面系統的診斷能力相去不遠，平均命中率分別是 0.92 與 0.79、誤報率分別是 0.59 與 0.46。冬季鋒面的診斷表現上，平均命中率 0.85、誤報率 0.20。機器學習診斷工具的部分，無論是使用 GLM 或 SVM 兩種核心，對於冬季鋒面的命中率均略低於其他兩個季節，命中率分別為 0.61、0.65，誤報率則是 0.15、0.17。對於春季鋒面和梅雨鋒面的命中率則提高至 0.7 左右，誤報率皆為 0.26。

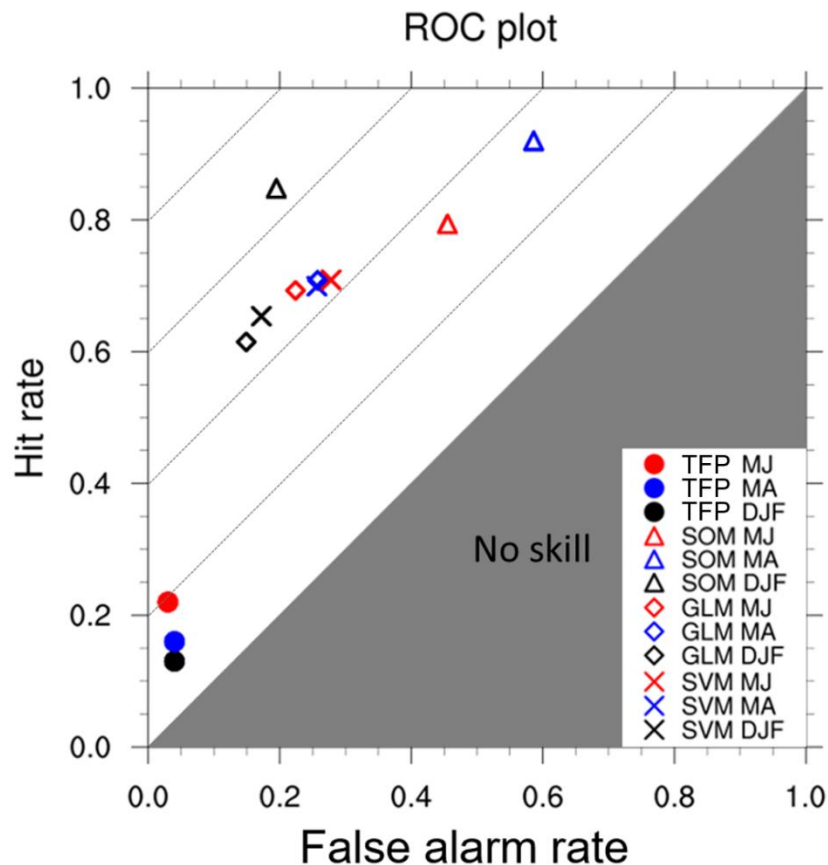


圖 13 接收操作特性(Relative Operating Characteristic, ROC)分析圖。實心圓點代表傳統熱力鋒面參數(TFP)診斷工具之技術得分，三角形代表 SOM，菱形代表機器學習之 GLM 模組，X 代表機器學習之 SVM。顏色代表不同季節，黑色為冬季，藍色為春季，紅色為梅雨季。斜對角虛線代表不同的診斷能力。

使用 F1 Score 作為鋒面系統診斷能力的量化值(表 2)，可以看到自組織映射圖(SOM)診斷工具遠較使用傳統熱力鋒面參數(TFP)診斷工具為佳，而使用機器學習診斷工具的診斷能力最佳。整體而言，基於群聚分析技術為基礎之診斷工具能診斷出大部分鋒面事件，但相較於主觀判定之結果過度判定的現象較顯著，導致誤報率較高。這在天氣預報分析作業上可藉由更多觀測資訊加以修正，但在研究氣候變遷下鋒面系統變化時，會導致過度推估的問題。若使用機器學習診斷工具時，在命中率上與使用自組織映射圖(SOM)診斷工具相距不遠。但可大幅降低鋒面診斷的誤報率，對於鋒面系統頻率變化有較好的掌握能力。且使用機器學習診斷工具的優點在於，透過增加大氣環境資料與更大量且多元之天氣事件分析，可進一步針對不同降雨型態之鋒面系統發展診斷工具，可提供更高效率且相對準確之鋒面系統診斷資訊。

致謝

本研究感謝科技部計畫之研究經費支持(計畫編號：MOST 106-2111-M-034-005-，MOST 107-2119-M-034-001-，MOST 107-2111-M-034-003-)，使研究得以持續進行。我們十分感謝 Data Qualia Lab. 游廷碩先生提供機器學習模型技術支援，感謝大氣資料庫提供相關天氣資料。特別感謝大氣科學期刊編輯與審查委員在審查過程中給予許

多寶貴的建議，使得文章的完整度與可讀性更佳。

參考文獻

- 劉高源，2017：2001-2016 年影響臺灣鋒面系統之時空變化(碩士論文)。臺北市，中國文化大學。
- Chang, C. C., and Lin, C. J., 2001, LIBSVM: a library for support vector machines. <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- Clarke, L.C., and Renard, R. J., 1966, The U.S. Navy numerical frontal analysis scheme: further development and a limited evaluation. *J. Appl. Meteorol.*, **5**, 764-777.
- Fawcett, T., 2006, An introduction to ROC analysis. *Pattern Recognition Lett.*, **27**, 861-874.
- Hewson, T. D., 1998, Objective Fronts. *Meteorol. Appl.*, **5**, 37-65.
- Hope, P., Keay, K., Pook, M., Catto, J., Simmonds, I., Mills, G., McIntosh, P., and Berry, G., 2014, A comparison of automated methods of front recognition for climate studies: a case study in southwest Western Australia. *Mon. Weather Rev.*, **142**, 343-363.
- Hung, C.-W., Hsu, H.-H., and Lu, M.-M., 2004. Decadal oscillation of spring rain in northern Taiwan. *Geophys. Res. Lett.*, **13**, L22206.
- Huth, R., 1996a, An intercomparison of computer-assisted circulation

- classification methods. *Int. J. of Climatol.*, **16**, 893-922.
- Huth, R., 1996b, Properties of the circulation classification scheme based on the rotated principal component analysis. *Meteorol. Atmos. Phys.*, **59**, 217-233.
- Japan Meteorological Agency, 1988, On the improvement of the significant weather chart. *Weather Serv. Bull.*, **55**, 1-16.
- Kanungo, T., Mount, D. M., Netanyahu, N. S., Piatko, C. D., Silverman, R., and Wu., A. Y., 2002, An Efficient k-Means Clustering Algorithm: Analysis and Implementation. *IEEE Trans. Pattern. Anal. Mach. Intell.*, **24(7)**, 881-892.
- Key, J., and Crane, R.G., 1986, A comparison of synoptic classification schemes based on 'objective' procedures. *Int. J. Climatol.*, **6**, 375-388.
- Kirchhofer, W., 1974, Classification of European 500 mb patterns. *Arbeitsbericht der Schweizerischen Meteorologischen Zentralanstalt*, **43**.
- Kirk, T. H., 1965, A parameter for the objective location of frontal zones. *Meteorol. Mag.*, **94**, 351-353.
- Kohonen, T., 1982, Self-organized formation of topologically correct feature maps. *Biol. Cybern.*, **43**, 59-69.
- Lamb, H. H., 1950, Types and spells of weather around the year in the British Isles: annual trends, seasonal structure of the year, singularities. *Q. J. R. Meteorol. Soc.*, **76**, 393-429.
- Nguyen-Le, D., Yamada, T. J., and Tran-Anh, D., 2017, Classification and forecast of heavy rainfall in northern Kyushu during Baiu season using weather pattern recognition. *Atmos. Sci. Lett.*, **18**, 324-329.
- Ninomiya, K., and Shibagaki, Y., 2007: Multi-scale features of the Meiyu-Baiu front and associated precipitation systems. *J. Meteor. Soc. Japan*, **85B**, 103-122.
- Oden, P., West, G., and Stull, R., 2018, Evaluation of Reanalyses over British Columbia. Part I: Daily and Extreme 2-m Temperature. *J. Appl. Meteorol. Clim.*, **57**, 2091-2112.
- Pook, M., Risbey, J.S., and McIntosh, P.C., 2012, The synoptic climatology of cool-season rainfall in the central wheatbelt of Western Australia. *Mon. Weather Rev.*, **140**, 28-43.
- Renard, R. J., and Clarke, L.C., 1965, Experiments in numerical objective frontal analysis. *Mon. Weather Rev.*, **9**, 547-556.
- Richman, M. B., 1981, Obliquely rotated principal components: An improved meteorological map typing technique? *J. Appl. Meteorol.*, **20**, 1145-1159.
- Saha, S., et al., 2010: The NCEP Climate Forecast System Reanalysis. *Bull. Amer. Meteor. Soc.*, **91(8)**, 1015-1057.
- Steinacker, R. A., 1992, Dynamic aspects of frontal analysis. *Meteorol. Atmos. Phys.*, **48**, 93-103.

- Su, S.-H., Kuo, H.-C., Hsu, L.-H., and Yang, Y.-T., 2012, Temporal and spatial characteristics of typhoon extreme rainfall in Taiwan. *J. Meteor. Soc. Japan*, **90**, 721-736.
- Su, S. H., Chu, J. L., Yo, T. S., & Lin, L. Y. (2018). Identification of synoptic weather types over Taiwan area with multiple classifiers. *Atmospheric Science Letters*, e861.
- Sá, J., Rocha, B., Almeida, A., and Souza, J. R., 2012, Recurrent self-organized map for severe weather patterns recognition. *Recurrent Neural Networks and Soft Computing*, Intech Open, 151-175.
- Wu, M., W., C.-C., Yen, T.-H., and Luo, Y., 2017, Synoptic analysis of extreme hourly precipitation in Taiwan during 2003–12. *Mon. Wea. Rev.*, **145**, 5123–5140.

The comparison of objective diagnose methods for Taiwan frontal system classification

**Chiao-Wei Chang Chien-Ting Chiang Kao-Yuan Liu
Shih-Hao Su***

Chinese Culture University, Taipei, Taiwan

(manuscript received 26 October 2018 ; in final form 27 March 2019)

Abstract

In this study, we used three different objective classifiers to evaluate the performance of frontal system diagnosing in Taiwan. First, the traditional objective diagnostic method which is based on the spatial variability of frontal thermal parameters (TFP). This method can provide frontal position and intensity while diagnosing process, which can use to estimate the spatial distribution of precipitation amount and rain intensity variation. The second method be evaluated is the self-organizing map (SOM)-based classifier. It is an unsupervised learning method, which can reduce the subjective error. It can also provide the clustering results of different weather types with similar atmospheric characteristics. Finally, considering the limitations of computing resources, we developed a third method, new diagnostic tool which is based on machine learning techniques. The results of the frontal system diagnosing show that the long-term variation of the front frequency can be well represented by both linear and nonlinear kernels. The traditional objective diagnostic method has a poor ability to identify the frontal system in Taiwan. The diagnosing hit rate was only 10-20% of all events and with very low false alarm rate. In the other hand, comparing with the machine learning mode, the SOM diagnostic method has higher hit rate (70%-80%); however, the false alarm rate is also higher (20%-60%). Overall, SOM classified more frontal events than actual, with overdiagnosis issue. The diagnostic tool based on the machine learning method can greatly reduce the false alarm rate and has a better diagnostic ability for frontal frequency variations.

Keywords: frontal system, objective classifier, clustering analysis, machine learning method. doi: 10.3966/025400022019034701001

* Corresponding author : Dr. Shih-Hao Su, ssh3@g.pccu.edu.tw