

利用機器學習建立西行侵臺颱風定量降水預報品質客觀 指引之初步研究

陳鑫澔 王重傑*

國立臺灣師範大學 地球科學系

(中華民國 110 年 6 月 11 日收稿；中華民國 111 年 6 月 17 日定稿)

摘要

颱風降雨是臺灣重要的水資源，卻也是主要的致災因素。因此，颱風預報的良莠與改善都十分重要。自發展數值天氣預報以來，不論是單一決定性預報或多成員系集預報，一個難解的問題，是個別預報均有其不確定性，因此該預報情境發生的機率高低，在事前無法得知、或至少無從確定。因此，隨著人工智慧的發展，本研究建構與測試一機器學習模型，在事前提供客觀預報指引，以幫助吾人判別每個颱風預報降水情境的可信度，藉以改善預報。確切而言，本研究使用 2.5-km 雲解析風暴模式，對 10 個西行準侵臺颱風每 6 h 的八天差時系集預報結果，選取共 105 個預報參數，以機器學習模型針對預報颱風在影響期間（中心距離臺灣陸地在 300 km 以內）總累積降雨的相似性技術得分（Similarity Skill Score，簡稱 SSS）進行預估。此得分由本文定義與使用，其值的高低與該雨量預報的可信度（即參考價值）成正比。所有評估的預報，其初始時間的颱風中心均尚未靠近臺灣到 300 km 以內，因此期限多在短期預報以外 (>72 h)。

由此 10 個颱風個案的評估結果顯示，在大多數的情況下，機器學習對逐次預報所預估的 SSS 值，的確可以適當掌握未來真實 SSS 的上升下降趨勢，亦即提早告訴吾人，那些預報的可信度較高、那些可信度較低，而在事前提供有效的客觀預報指引。在本研究裡，當預估 SSS 的 50 百分位數達 0.6 以上時，其實際 SSS 有 71% 也大於 0.6，而颱風行進方向的修正也有 71% 是正確的。特別對在前置時間長、不確定性高的預報初期，提高其參考價值。但是，因機器學習可視為複雜的統計方法，當某個颱風的行為與大部分輸入訓練的資料相左時，其效果也會受到限制，對此，本文提出了幾個可能的改進方向。

關鍵詞：定量降水預報、颱風、雲模式、機器學習、臺灣

*通訊作者：王重傑，E-mail:cwang@ntnu.edu.tw

一、前言

臺灣位於颱風熱區，每年平均約受到3~4個颱風侵襲（王, 1992），而侵臺颱風的強降水是造成災害的主要原因之一。臺灣由於地勢陡峭（在水平距離 50 km 內的地形變化高達 3000 m），對於受到臺灣地形舉升的颱風環流具有相位鎖定現象（Chang et al., 1993, 2013; Su et al., 2012; Wang et al., 2012; Hsu et al., 2013）。因此，個別颱風通過臺灣期間之累積降水，往往與其影響臺灣的時間長短成正比，也就是與其平均移速成反比（Chien and Kuo 2011; Wang et al., 2012; Hsu et al. 2013）。

由於上述地形的角色，臺灣颱風降水的量值與分布特徵，與颱風路徑（即個別時間颱風與臺灣的相對位置）高度相關。因此，Lee et al. (2006, 2013) 得以利用 1989-2006 年歷史颱風路徑與降水觀測資料，發展出一套颱風降水氣候模式，給予參考路徑後即可輸出預報（或預期）之降水分布。由於是氣候統計之結果，此模式較能掌握一般典型颱風的降水，但若遭遇共伴或極度不對稱之非典型颱風，則其降水預報的參考價值便會降低。由此可知，路徑相似的侵臺颱風所造成的降水分布，

往往有一定的相似性，但有時又具有其獨特性。延續上述的相似概念，Hong et al. (2015) 使用針對個別颱風的系集定量降水預報（quantitative precipitation forecast）結果，給予預想之路徑（在該研究中採用觀測之最佳路徑）來協助產生降水預報，則可保留不同颱風的降水特性。

為提高模式解析度來因應強降水對流系統之細部結構與臺灣的複雜地形，Wang et al. (2016) 提出採用單一雲模式差時系集之策略進行颱風定量降水預報。其與傳統多模式系集預報的差異在於集中計算資源以進行高解析度、高解析區域範圍較大、且時間較長的預報，並利用差時預報來提供單一預報所欠缺的系集機率資訊。Wang et al. (2016) 使用的預報長度為 8 天 (192 h)，其針對 2012-2013 年間的六個侵臺颱風進行日累積降水預報的評估，發現分別在 8、4、6、3、6 及 7 天前，就可以對各個颱風產出品質不錯的定量降水預報。因此，此種策略在颱風侵臺約一週前就可以開始產出高解析度的降水分布，對長時間降水可有初期且涵蓋完整事件的預報。然而，其缺點也相當明顯：系集成員乃由差時預報提供，其成員數不若傳統系集來得多，因此分散風險的效果相對較差。

機器學習的各種應用在近年來受到重視而蓬勃發展。Gagne et al. (2014) 使用機器學習的兩個方法：隨機森林 (Random forests) 與 邏輯式迴歸 (Logistic regression) 將 26 個預報成員的結果用來校準機率定量降水預報，顯示不論是哪種方法的結果都比單純系集的結果為佳。Gagne et al. (2017) 在機器學習中放入 12 個不同雲微物理與邊界層參數化的成員預報再輔以雷達資料，以估計風暴中冰雹的生成機率與冰雹的分佈參數。結果顯示，相較於其它方法，機器學習能更有效的預測嚴重冰雹事件。Whan and Schmeits (2018) 分別使用了三種機器學習方法：邏輯式迴歸、零點調整伽瑪分布 (Zero-adjusted gamma distribution) 與分量隨機森林 (quantile random forests)，對劃定的荷蘭地區進行最大時雨量預報，其評估發現在中低強度降水情況下表現不錯。Zhang et al. (2019) 則使用多組機器學習方法來討論中尺度對流系統是否會轉變為熱帶氣旋，結果顯示自適應增強 (AdaBoost) 方法在 6 小時的延時情形下，預測熱帶氣旋生成有 97.2% 的準確度，相較傳統方法的不到 80%，可以說是相當出色。Chandler and Wheater (2002) 使用了廣義線性模型

(generalized linear models) 為框架來解釋時空結構，並用於對愛爾蘭西部地區的日降水序列分析。Tao et al. (2018) 則使用深度學習模型加強衛星產品對於地面降水的估計。此研究中使用了兩段式的模型，第一段區分有降水與無降水，第二段則針對有降水的部分進行逐點降水量估計，研究顯示此方法降低平均偏差與均方差，並提高相關係數。Huang et al. (2018) 使用了深度學習模型，利用貪婪非監督式學習演算法 (greedy unsupervised learning algorithm) 提取降水數據上的特徵預測土石流規模，建立了針對研究區域的土石流預測模型。

不論是系集預報或單一決定性預報，模式對於未來事件的預報，永遠具有誤差與不確定性 (Lorenz, 1963)，其差異僅在於誤差的大小與不確定性的高低而已 (Epstein, 1969; Leith, 1974)。因此，自數值天氣預報開始發展以來 (Bjerknes, 1904; Richardson, 1922; Charney et al., 1950)，如何取得不確定性的資訊已成為一項重要課題 (例如：Toth and Kalnay, 1993; Molteni et al., 1996)。然而，正如俗語所說的「千金難買早知道」，如何在事前就得知某個預報情境是否會發生，仍是一個幾乎無解的問題。就經驗而言，越新越接近的預報，平

均會越準確，但能用來準備與因應防災的時間相對也越短；同時儘管有系集預報，除了機率會隨時間改變以外，機率最高的情境也仍然不保證發生。因此，若能提前得知預報的品質，對於預報應用會有莫大的助益。近年來隨著科技的發展，人工智能中的機器學習，可應用於各種「最佳化」的問題，具有很高的潛力。因此，本研究的焦點，即是應用機器學習方法，針對影響臺灣西行颱風之定量降水預報，發展出能在事前預估其預報品質或可信度的客觀指引。此方法可幫助預報員判斷每次或每個預報的可信度高低，且未來可以推廣應用於所有模式、所有區域之颱風定量降水預報。

本文第二章將分別介紹本研究的資料與分析方法，包括雲解析預報系統、機器學習、輸入之各項預報參數與產出之客觀指引，第三章展示各差時系集預報的結果並稍加討論，第四章討論預報參數與客觀指引的相關程度，以及多種激發函數與不同深度與廣度組合的機器學習結果，第五章則展示各客觀指引的特性與使用方式，並討論未來可能的應用與改善方向。最後，第六章則為結論與未來方向。

二、研究資料與分析方法

(一) 雲解析預報系統

本研究依循 Wang et al. (2015, 2016) 的工作，使用日本名古屋大學研發的「雲解析風暴模式」(Cloud-Resolving Storm Simulator；簡稱 CReSS 模式，Tsuboki and Sakakibara, 2002, 2007)，美國國家環境預測中心 (National Centers for Environmental Prediction; NCEP) 全球預報系統 (Global Forecast System; GFS) 的即時格點分析與預報場做為初始與邊界條件，每 6 小時進行一次預報。CReSS 模式的水平格點間距為 2.5 km，垂直間距平均為 500 m，模擬區域範圍為 $1860 \times 1360 \text{ km}^2$ ，模式頂高度為 20 km，預報長度則為 192 h (8 天)。模式的雲微物理 (含冰相之冷雲過程) 與各物理參數化方案，均與 Wang et al. (2016) 完全相同。

由於模式總網格點數達 $744 \times 544 \times 40$ 點，每個颱風個案完成預報所需之計算資源相當龐大。再者侵臺颱風路徑可分為 10 類 (中央氣象局, 2021)，不同路徑間情況各異，為降低機器學習問題的複雜度，本研究先僅討論侵臺最大宗的西行颱風類型。在颱風強度上，由於在機器學習計算

裡大量考慮路徑相關之預報參數，為降低颱風中心定位的難度，故僅考慮颱風在接近臺灣階段，觀測須曾達中度颱風等級（近中心持續風速 $\geq 118 \text{ km h}^{-1}$ ）以上之個案。在限縮颱風路徑類型與強度條件後，則希望選入個案在路徑上能盡量分散、以多元方式通過臺灣附近，亦即由北部海面掠過、由北、中、南部穿越臺灣、以至於由南部海面掠過者（路徑一至路徑五）均須包含、缺一不可。至於降水來源，則希望主要僅來自於颱風本身的環流。因此，如 2009 年莫拉克 (Morakot, Wang et al., 2012)、2013 年康芮 (Kong-Rey, Wang et al.,

2021) 等伴隨顯著西南氣流的颱風，亦先行排除。

在上述限縮目標個案的條件下，本研究最終選取了 2012-2016 年間的 10 個西行侵臺颱風作為研究對象，分別為 2012 年的蘇拉 (Saola)、2013 年蘇力 (Soulik)、天兔 (Usagi)、及菲特 (Fitow)、2014 年麥德姆 (Matmo)、2015 年昌鴻 (Chan-Hom)、蘇迪勒 (Soudelor)、及杜鵑 (Dujuan)、以及 2016 年的尼伯特 (Nepartak) 與莫蘭蒂 (Meranti) 颱風。這些颱風個案的最佳路徑繪於圖 1，路徑頗為分散。各颱風不同初始時間的路徑預報與降水分布將於第三章

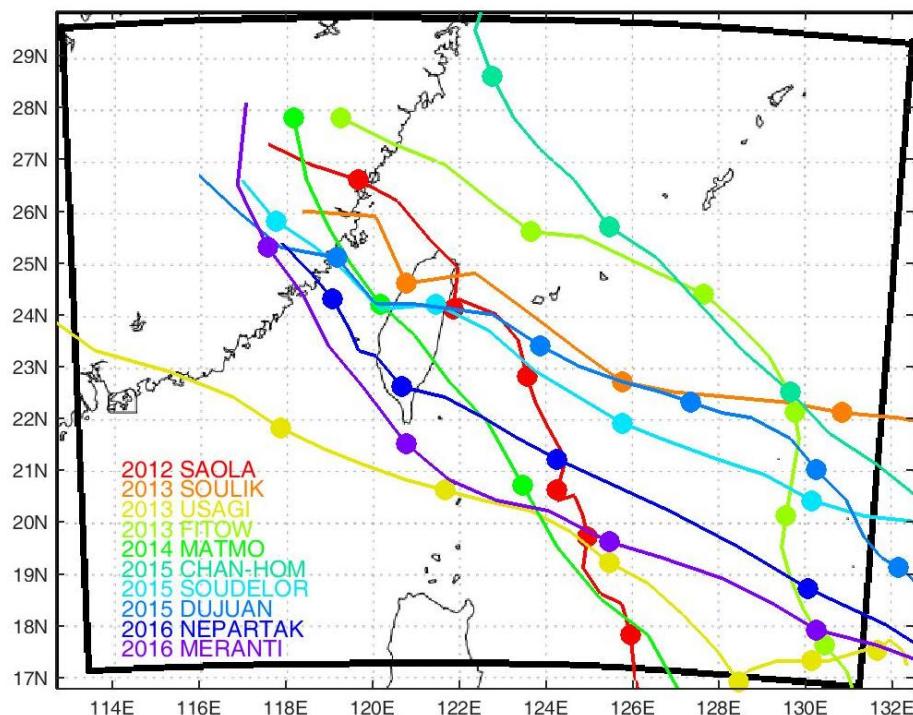


圖 1 本研究選取的 10 個西行準侵臺颱風的最佳路徑（見顏色圖例）。實心圓為各颱風個案逐日 0000 UTC 時的位置。

進行討論，但此處可先提到的是，大部分颱風的路徑預報在初期皆偏北，而後逐漸向南修正。因此，儘管昌鴻颱風造成的降水並不多，但它是備選颱風中唯一一個大部分預報路徑皆為偏南、且之後漸向北修正的颱風，所以仍然將其選入，以便在資料樣本中增加路徑預報特徵的多重面向，幫助機器學習。

(二) 颱風客觀定位與路徑誤差

由於本研究並未包括新生颱風之情況，不需進行颱風辨識而僅需進行中心定位。又因目標是希望未來可應用於即時預報，故採取可自動執行的客觀颱風中心定位方法。由於解析度高，雲模式中的颱風最低氣壓位置有時會發生類似陀螺的晃動情形，而颱風通過臺灣期間，也會受到高聳複雜地形的影響，而產生底層位於地形以下而缺資料、颱風中心模糊不清、或出現副中心的情況。因此，單純辨認最低氣壓值的出現位置，不見得總是合乎理想。由於本研究所欲辨認的颱風中心位置，與最佳路徑相似，是整體氣旋中心附近軸對稱氣壓場的幾何中心，因此設計並採用了以下作法。本研究使用一在空間上呈圓錐塔形狀的係數函數，其圓錐底部的半徑為

200 km，係數值均為 0，塔頂（中心點）的係數值為 1，且向外線性遞減到 0（即半徑 200 km 處），以外則係數亦為 0。應用時，將此圓錐狀之係數函數依序套用在涵蓋颱風幾何中心某範圍內的各個格點上，並計算以該點為中心共 161×161 個格點區域內（即 $400 \times 400 \text{ km}^2$ ），所有相應格點上的係數乘上氣壓與最高氣壓之差值，並加總平均，如式 (1) 所示：

$$\text{Corn Adj.} = \frac{\sum_{i=1}^n [P_{\max} - P_i] \times \frac{200 - D_i}{200}}{n} \quad (1)$$

其中，Corn Adj. 為壓力經圓錐法調整後的結果，P 為氣壓值，D 為與圓錐塔中心點的距離（單位為 km），下標 i 表格點代號，n 為總格點數， P_{\max} 則為預報範圍內的最高氣壓值。因此，前述的圓錐塔係數即為 $(200 - D_i)/200$ 。經此計算後，可使調整後結果具有最大數值之格點，其形狀與圓錐係數函數最為匹配，也就是氣壓場的軸對稱幾何中心位置。在實際應用上，此計算是套用在 896 m 高度處之氣壓資料，若格點在地形以下而缺資料，則不納入計算。

當各時間之颱風定位完成後，可進行颱風路徑誤差計算。圖 2 即為路徑誤差之示意圖，其中 x_0 與 y_0 為目標路徑（常為觀測路徑）前一個時間的經緯度位置、 x_1 與

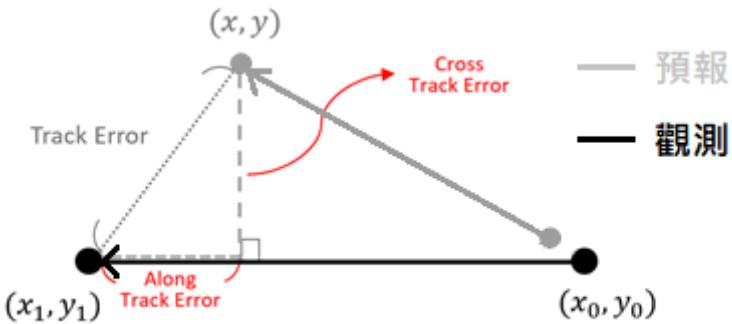


圖 2 颱風路徑誤差計算方式示意圖。其中， x_0 與 y_0 為觀測路徑前一個時間的經緯度位置， x_1 與 y_1 為觀測路徑目標時間之經緯度，而 x 與 y 則為預報路徑在目標時間之經緯度。圖中，路徑誤差 (track error)、移速誤差 (along-track error) 及移向誤差 (cross-track error) 如標示。

y_1 為目標路徑在目標時間之經緯度、而 x 與 y 則為比較路徑 (常為預報路徑) 在目標時間之經緯度位置。如圖 2 所示，颱風的路徑誤差 (track error, TE) 可分為移速誤差 (along-track error, ATE) 與移向誤差 (cross-track error, CTE) 兩個部分，且兩者相互垂直。移速誤差為沿觀測 (或目標) 行進方向上的距離誤差，而移向誤差與其垂直，由颱風移動方向的誤差所造成，其計算方式如下 (圖 2)：

$$CTE = \frac{(y_0 - y_1)(x - x_1) - (x_0 - x_1)(y - y_1)}{\sqrt{(y_0 - y_1)^2 + (x_0 - x_1)^2}} \quad (2)$$

若預報颱風之移向誤差為正表示其較觀測偏左，為負則表示較觀測偏右。在實務上，當總誤差與移向誤差已知，移速誤差的絕對值 (距離) 可計算為：

$$|ATE| = \sqrt{TE^2 - CTE^2} \quad (3)$$

並可藉由 $[(y_0 - y_1)(x - x_1) - (x_0 - x_1)(y - y_1)]$ 判斷式來決定其符號 (正或負)，其結果大於零代表預報颱風的移速 (沿觀測方向) 較觀測為慢，小於零則代表較觀測為快。以圖 2 之例而言，吾人可見其預報路徑較觀測為慢且偏右，故 CTE 為負而 ATE 為正。

(三) 機器學習模型概述

如第一章的前言所述，本研究嘗試應用人工智慧中的機器學習產生預報指引，可以幫助預報與研究人員，在事前判斷各個模式定量降水預報的品質與可信度。機器學習可以想像為一個大型複雜的運算模型，在吾人輸入訓練資料後會產生運算結果，而運算結果與實際結果的差別，將促使模型修正其內部的運算，進而使得每次

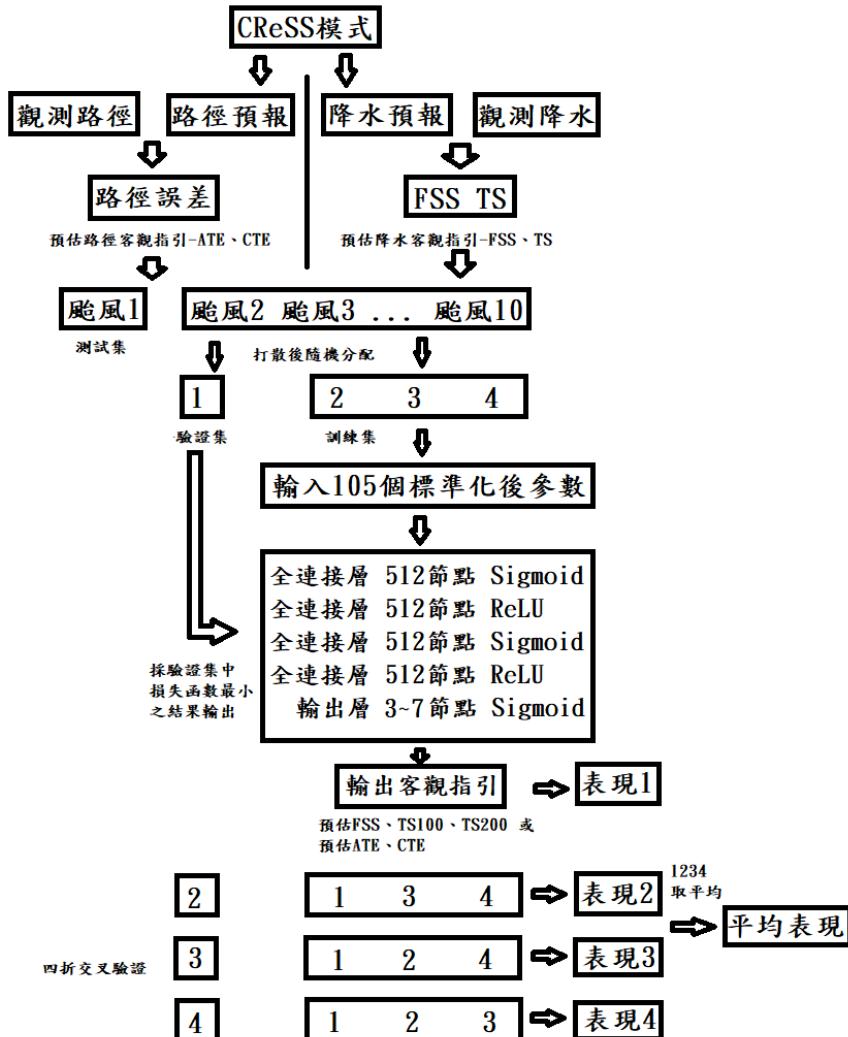


圖 3 本研究由模式預報到產出客觀指引所使用之簡易結構與流程圖。

輸入訓練資料後所產生的結果，與實際越來越趨於接近。

本研究由模式預報到產出客觀指引所使用之簡易結構與流程圖示於圖 3。研究共包括十個颱風個案，針對每個目標颱風，以其他九個颱風資料做為訓練與驗證集，再將結果應用於該颱風，因此訓練驗證的資料與測試者為相互獨立。本研究使用 Python 程式語言中的 Keras (Chollet, 2015)

來幫助架設機器學習環境，類神經網路中採用相同寬度的全連接層，並輔以 Adam 優化器 (Kingma and Ba, 2015)。損失函數使用均方差，應用在降水時即指預估技術得分與實際者的均方差，而應用在路徑時則指預估之路徑誤差 (ATE 或 CTE) 與實際者的均方差。訓練集的樣本將放入訓練重複 50 次 (即 Epoch = 50)，每次訓練則放入 20 組樣本 (即 batch size = 20) 不斷

進行。資料被分為四份，其中三份作為訓練集，而剩下的一份則做為驗證集，此方法可簡稱為四折交叉驗證 (Kohavi, 1995)。本研究在測試期間，也使用過主流的十折與五折交叉驗證，但在驗證時因損失函數變動大導致表現不盡理想，推測應該是由於驗證資料量偏小的緣故。由於驗證集需要足夠的資料量，表現才能較穩定，因此最終選擇四折交叉驗證。

本研究所用的類神經網路僅使用全連接層，但針對全連接層的寬度、深度、及激發函數曾進行過測試與調整。連接層寬度的神經元個數，根據經驗採用 2 的級數，由 128 開始測試至 1024，最後顯示以 512 表現最佳。在激發函數方面，初期測試時發現由單一激發函數所組成的類神經網路表現相對較差，且由線性整流函數 Relu (Nair and Hinton, 2010) 開始的模型結果甚不理想。因此，之後皆使用乙狀函數 Sigmoid (Cybenko, 1989) 開頭，且由 Sigmoid 與 Relu 交錯組合進行，隨後描述時，便簡單以 S 與 R 分別代表這兩種函數。

類神經網路的深度則是由 4 層測試至 7 層，主要結果則採用 5 層。最終，本研究採取了共 105 個預報參數輸入進行機器

學習，並針對降雨與路徑預報品質產出 4 種客觀指引，稍後再加以介紹。由於颱風個案總數偏少且各有其一定程度的獨特性，此點會造成機器學習每次收斂的結果皆有所差異，各自代表某種多組損失函數局部最小化的結果。因此，本研究也套用機率與系集之概念，針對每個颱風皆產出一百組機器學習的結果，將於文後呈現並討論。

(四) 機器學習之預報參數

雖然每次預報皆可產生上百億個參數，但限於機器學習模型的計算能力，僅挑選一些重要的參數輸入。在這之前，首先吾人需要決定本研究在每個颱風預報中所欲評估的臺灣本島之定量降水時段。如 Wang et al. (2015, 2016)，一般研究多評估固定長度時段之累積降水，例如日累積降水 (0000-2400 UTC 或 0000-2400 LST)。但是，此種在特定時間以人工強迫分隔累積時段的方式，無法完整描述跨日的颱風降水事件，不利於機器學習。因此，本研究定義颱風的影響時段為颱風中心距離臺灣海岸線在 300 km 以內者，即由颱風中心首次靠近臺灣陸地至 300 km 內、到遠離臺灣陸地達 300 km 距離的時段，因此，

此時段在觀測與各預報中，均可不同。本研究最終共挑選了 105 個可能影響降水與路徑預報結果的參數，作為輸入機器學習模型之參數，列於表一。由於本研究的結果希望能應用在實際預報，因此選擇在最後所用的預報中，颱風中心在靠近到距離臺灣陸地 300 km 時，仍有至少 24 h 的前置時間，此預報稱為最新預報，之後產生的預報結果均不使用於機器學習。因此，在所有使用的預報中，大致上從預報開始

到颱風登陸至少相隔 48 h。上述靠近與遠離臺灣陸地至 300 km 距離的兩個時間，代號即為 C300_1 與 C300_2，大部分其它參數均由此兩者衍生而出，分別代表颱風影響時段的長短、降水規模、各時間預報之颱風中心位置、先前幾次預報在各時間之路徑差異、以及路徑預報發散之程度...等等。所有參數均為在預報當下可取得者，故可用於即時預報，其各自的進一步說明與選取理由，亦列於表一中。

表一 本研究所選取輸入機器學習的 105 個預報參數，個別代號、及說明與選取理由。

代號	說明與選取理由	個數
C300_1, C300_2	預報開始到颱風中心首次靠近臺灣陸地至 300 km 內的時間 (h)。 預報開始到颱風中心遠離臺灣陸地即將達到 300 km 的時間 (h)。 此兩時間代表臺灣受影響的時段區間，愈接近初始時間即預報長度愈短，因不確定性相對較低，通常越具有參考價值。	2
Duration	颱風影響臺灣的時段長短 (h)，其值等於 C300_2 – C300_1。 颱風影響臺灣的時段越長，累積的雨量傾向於越多，而雨量越多，相同門檻處的 TS 得分亦傾向於越高 (Wang, 2015)。	1
Fr100, Fr200, Fr300	預報降水分別達三個降水閾值 (100、200、及 300 mm) 之範圍佔臺灣本島面積的比例 (無因次)。 預報降水達特定閾值所佔面積比例越高，雨區越大，則該降水門檻處的 TS 值傾向於越高。	3
Max	預報降水事件於臺灣本島的最大累積雨量 (mm)。	1
Lat_C300, Lon_C300	預報颱風中心首次靠近臺灣陸地至 300 km 內的經緯度位置。 颱風相對於臺灣的位置參數之一。	2
Lat-24, Lat-18, ..., Lat+12; Lon-24, Lon-18, ..., Lon+12	預報颱風中心首次靠近臺灣陸地至 300 km 內的時間 (即 C300_1) 之前 24 h 到之後 12 h 間，每 6 h 之中心經緯度位置。 為各時間颱風相對於臺灣的位置參數，颱風位置是相當重要的參數。	12
Along_06_C300, ..., Along_24_C300; Cross_06_C300, ..., Cross_24_C300	本次預報颱風中心首次靠近臺灣陸地至 300 km 內的位置 (目標路徑) 分別與提早 6 h 至 24 h 預報者 (比較路徑) 報至相同時間的 ATE 與 CTE。 若過去路徑隨時間持續往同一方向修正，則預期將繼續往該方向修正。	8

表一 (續)

代號	說明與選取理由	個數
Along_06_-24, …, Along_06_+12, …, Along_24_+12; Cross_06_-24, …, Cross_06_+12, …, Cross_24_+12	本次預報颱風中心在 C300_1 時間之前 24 h 到後 12 h (每 6 h)，分別與提早 6 h 至 24 h 預報者報至各相同時間的 ATE 與 CTE。	48
Along_new_C300, Cross_new_C300	本次預報颱風中心在 C300_1 時間的位置 (目標路徑)，與最新預報 (比較路徑) 報至相同時間的 ATE 與 CTE。此處的最新預報指的是預報開始後在第 24-30 h 就出現符合 C300_1 的預報。經驗上最新預報的結果傾向於最好，故預期路徑將往其修正。	2
Along_new_-24, …, Along_new_+12; Cross_new_-24, …, Cross_new_+12	本次預報颱風中心在 C300_1 時間之前 24 h 到後 12 h (每 6 h)，與最新預報報至相同時間的 ATE 與 CTE。	12
Along_Val_-24, …, Along_Val_C300, …, Along_Val_+12; Cross_Val_-24, …, Cross_Val_C300, …, Cross_Val_+12	較本次提早 6 h 至 24 h 的前 4 次預報中，報至 C300_1 時間之前 24 h、到後 12 h (每 6 h)，也包含 C300_1 當時者，各相同時間之絕對 ATE 與 CTE 的加權平均值，提早 6, 12, 18, 24 h 預報之權重依序為 3, 3, 2, 1。此加權平均值可代表前面幾次預報路徑的發散程度。	14

(五) 降水技術得分與客觀指引

在各颱風影響時段內總累積降水之技術得分，是機器學習所欲改進的項目。其中預兆得分 (threat score, 簡稱 TS) 是一種廣泛使用於評估模式降水預報的「分類統計」技術得分 (例如：Schaefer, 1990; Wilks, 1995; Ebert et al., 2003)，可在全臺雨量觀測站網進行校驗 (Wang, 2014)。在所有校驗點上，觀測與預報降水是否達到特定的降水門檻值，可做列聯表而分類為以下四種可能結果：預報命中 (hit, H)、誤報 (false alarm, FA)、漏報 (miss, M) 和正確預報未達門檻 (correct negative, CN)。將

前三者的統計數字代入公式 (4)，可得 TS 之值為：

$$TS = \frac{H}{M+H+FA} \quad (4)$$

因此 TS 代表在觀測雨區 (H + M) 與預報雨區 (H + FA) 的聯集中，預報命中所占的比例 ($0 \leq TS \leq 1$)，當 TS 越接近 1，表示模式在該雨量門檻值處的預報技術越佳。此處，吾人採用了在 100 與 200 mm 兩個門檻值處的 TS 作為機器學習的依據，其代號分別為 TS100 與 TS200。

由於在不同的颱風個案與預報裡，達到相同降雨門檻值的雨區大小各異，故 TS100 與 TS200 不見得適用於所有情形、

總是良好的指標。因此，本研究參考 Roberts and Lean (2008) 所提出的佔比技術得分 (Fractions Skill Score)，定義了「相似性技術得分」(Similarity Skill Score, 簡稱 SSS) 用以評估預報與觀測降水分布的整體相似性，並隨後應用此指標來評估降雨預報技術。其公式為：

$$SSS = 1 - \frac{\frac{1}{N} \sum_{i=1}^N (f_i - o_i)^2}{\frac{1}{N} (\sum_{i=1}^N f_i^2 + \sum_{i=1}^N o_i^2)} \quad (5)$$

其中，N 為校驗點 (雨量站) 總數， o_i 為第 i 個校驗點之觀測值， f_i 則為其預報值。因此，SSS 值的大小介於 0 到 1 之間，可以反應兩個分布的整體相似性 (0-100%)：當預報雨量與觀測越吻合時，式中右手側第二項的數值就越小，SSS 便越接近 1；反之，當兩者的降雨分布完全相異 (預報有降雨處皆為誤報，而觀測有降雨處皆漏報)，則使 $SSS = 0$ ，兩者沒有任何相似性 (預報技術為零)。實質上，SSS 即為預報的實際均方差 (mean squared error，即右手側第二項的分子) 相對於最大可能均方差 (右手側第二項的分母) 之技術，因此為一種技術得分。

由於 SSS 可代表預報與觀測降雨分布型態的整體相似程度，本研究採用 SSS 作為機器學習的主要依據。針對每個颱風個

案，每次預報完成後，均可利用預報參數計算客觀指引，也就是以機器學習預估該次颱風預報的 TS 值與 SSS 值，以大致代表颱風降水預報的可信程度，若機器學習模型預估出的 SSS 與 TS 值高，代表降水預報結果相對較為可信。模型所產出的客觀指引，包括預報颱風侵襲臺灣期間 (由 C300_1 到 C300_2) 總累積降水的預估 SSS、TS100 及 TS200 得分，以及在 C300_1 之前 24 h 到後 12 h 間，每 6 h 之估計颱風中心路徑的 ATE 與 CTE。

三、差時系集預報結果概述

本章針對所選入的十個颱風個案，分別就其路徑與影響時段內累積降水的預報進行簡短討論，以大致瞭解模式的整體表現與能力。限於篇幅，首先先選擇兩個情況各異的個案，即尼伯特 (圖 4) 與蘇迪勒颱風 (圖 5)。圖 4a 顯示尼伯特颱風 (2016) 在 7/1 1200 UTC 到 7/6 0000 UTC 之間各初始時間的路徑預報，而由觀測所訂的影響期間為 7/7 0500 UTC 至 7/9 1300 UTC (共 56 h)，因此此處所示的所有預報，皆為颱風中心尚未移至距臺 300 km 以內者 (亦即 C300_1 均出現在預報開始之後)，並不包括前置時間 (lead time) 更短、更新 (更

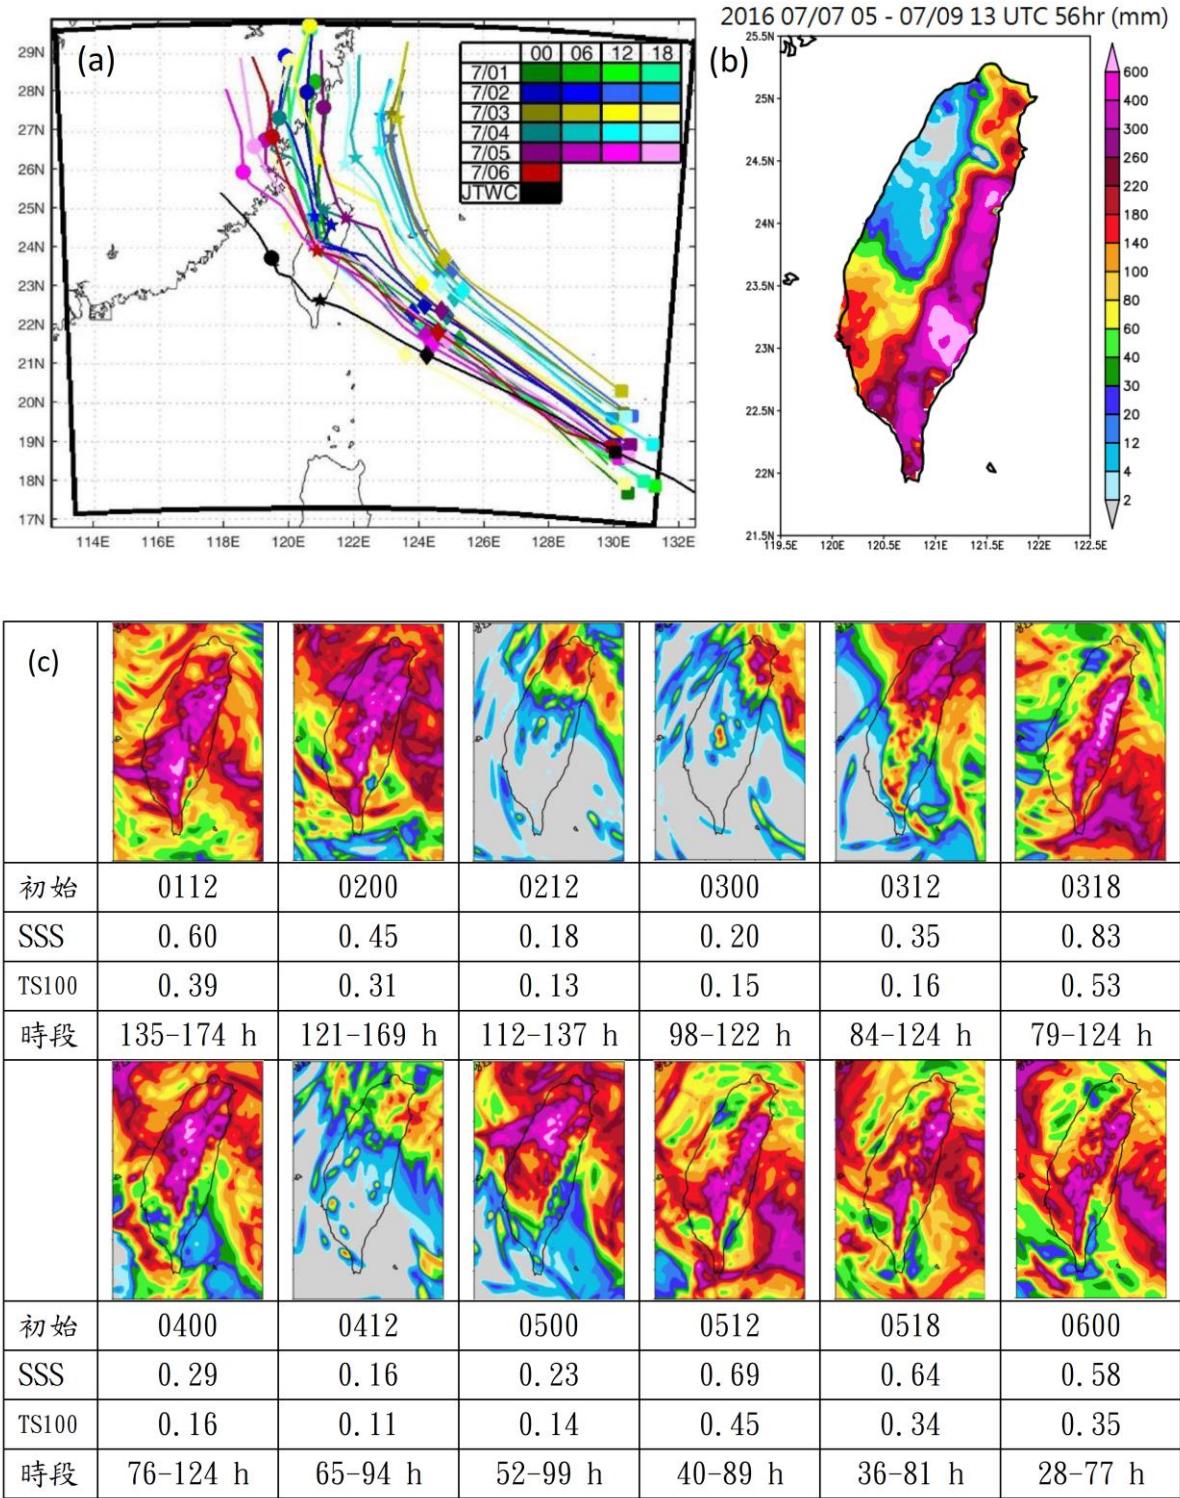


圖 4 針對尼伯特颱風在不同初始時間預報的 (a) 預報路徑，(b) 觀測降水，及 (c) 預報降水分佈 (mm)。預報路徑上各符號為逐日 0000 UTC 之颱風中心位置，X、六角星、正方形、菱形、五角形及與圓形依序分別表示 7/4 到 7/9 者，黑色線為 JTWC 之觀測路徑。本個案由觀測定義之影響期間為 7/7 0500 UTC 至 7/9 1300 UTC，長度共 56 h。預報降水為預報在各自影響期間之降水 (色階同觀測)，其初始時間 (日期與 UTC 小時)、實際 SSS、實際 TS100、及降水累積時段皆示於各圖下方。

晚) 的預報。圖中顯示，此個案的實際路徑主要向西北西，在 7/7 0000 UTC 左右由臺東附近登陸且自臺南一帶出海。而模式的路徑預報，在颱風通過臺灣附近均為偏北，且期間重複出現多次南北向的修正，例如 7/1 0000 與 1800 UTC、7/3 1800 UTC、7/5 0600 UTC 至 7/6 0000 UTC 所做預報，多由花蓮附近登陸而自新竹到台中一帶出海，與觀測路徑較接近。之間的其它預報則大多更為北偏，例如 7/2 1200 UTC、7/3 0000 UTC、及 7/4 0600 UTC 前後者，其颱風中心則穿越日本石垣、西表兩島附近，並未登陸臺灣。

由於尼伯特自臺灣南部穿越，其影響期間的觀測降水主要集中在東半部的臺東、花蓮一帶，最大累積值超過 600 mm (圖 4b)。圖 4c 選擇性地顯示了部分初始時間預報所報出的尼伯特颱風於各自影響期間 (相同定義方式) 的總累積降水分布，可看到若預報與實際路徑的差異越大，則兩者降水的差異也越大。由於並未包括更新更晚的預報，各預報間的路徑誤差頗大且各有不同，預報的降水分佈亦頗多樣，有集中於中央山脈者，也有集中於北部者。依降水 SSS 值所示，圖中最接近的降水情境係由 7/3 1800 UTC 的預報所做出，期限

在 79-124 h，其值可達 0.83。由於降水發生時段大致為預報的第 4-5 天，有此表現其實頗為難得。而本研究的重點，即是應用機器學習在颱風降水發生前就告訴吾人，此次預報的可信度較其它預報者為高，也就是發生機率較高。

圖 5a 為觀測與不同初始時間預報的蘇迪勒颱風 (2015) 路徑，其真實路徑由臺灣中部穿越，登陸花蓮的時間則接近 8/7 2100 UTC。蘇迪勒颱風影響期間的降水 (8/7 1100 UTC 至 8/8 1900 UTC) 主要在臺灣的東北與西南象限，以雪山山脈、中央山脈北段、南段與西南部最多，最大累積雨量超過 600 mm (圖 5b)。在所示預報中 (圖 5c) 最早者為 8/1 0000 UTC，此時預報路徑的方向便已經與觀測者十分接近，其主要路徑誤差為 ATE，颱風移速過快而使事件提早約 12 h 發生。隨後在 8/2-3 預報路徑漸向北偏，到 8/3 0600 UTC 達到最北 (中心未登陸)，然後向南修正，到 8/4 1200 UTC 的預報又再度與觀測接近，且 ATE 亦減小。由此開始，預報路徑已呈收斂狀態，皆與觀測相似 (圖 5c)。由於相對佳的預報路徑表現，模式對蘇迪勒颱風的降水亦多有良好表現：前述幾個 CTE 較小的預報，整體降水的 SSS 值均達 0.84 或以上，最

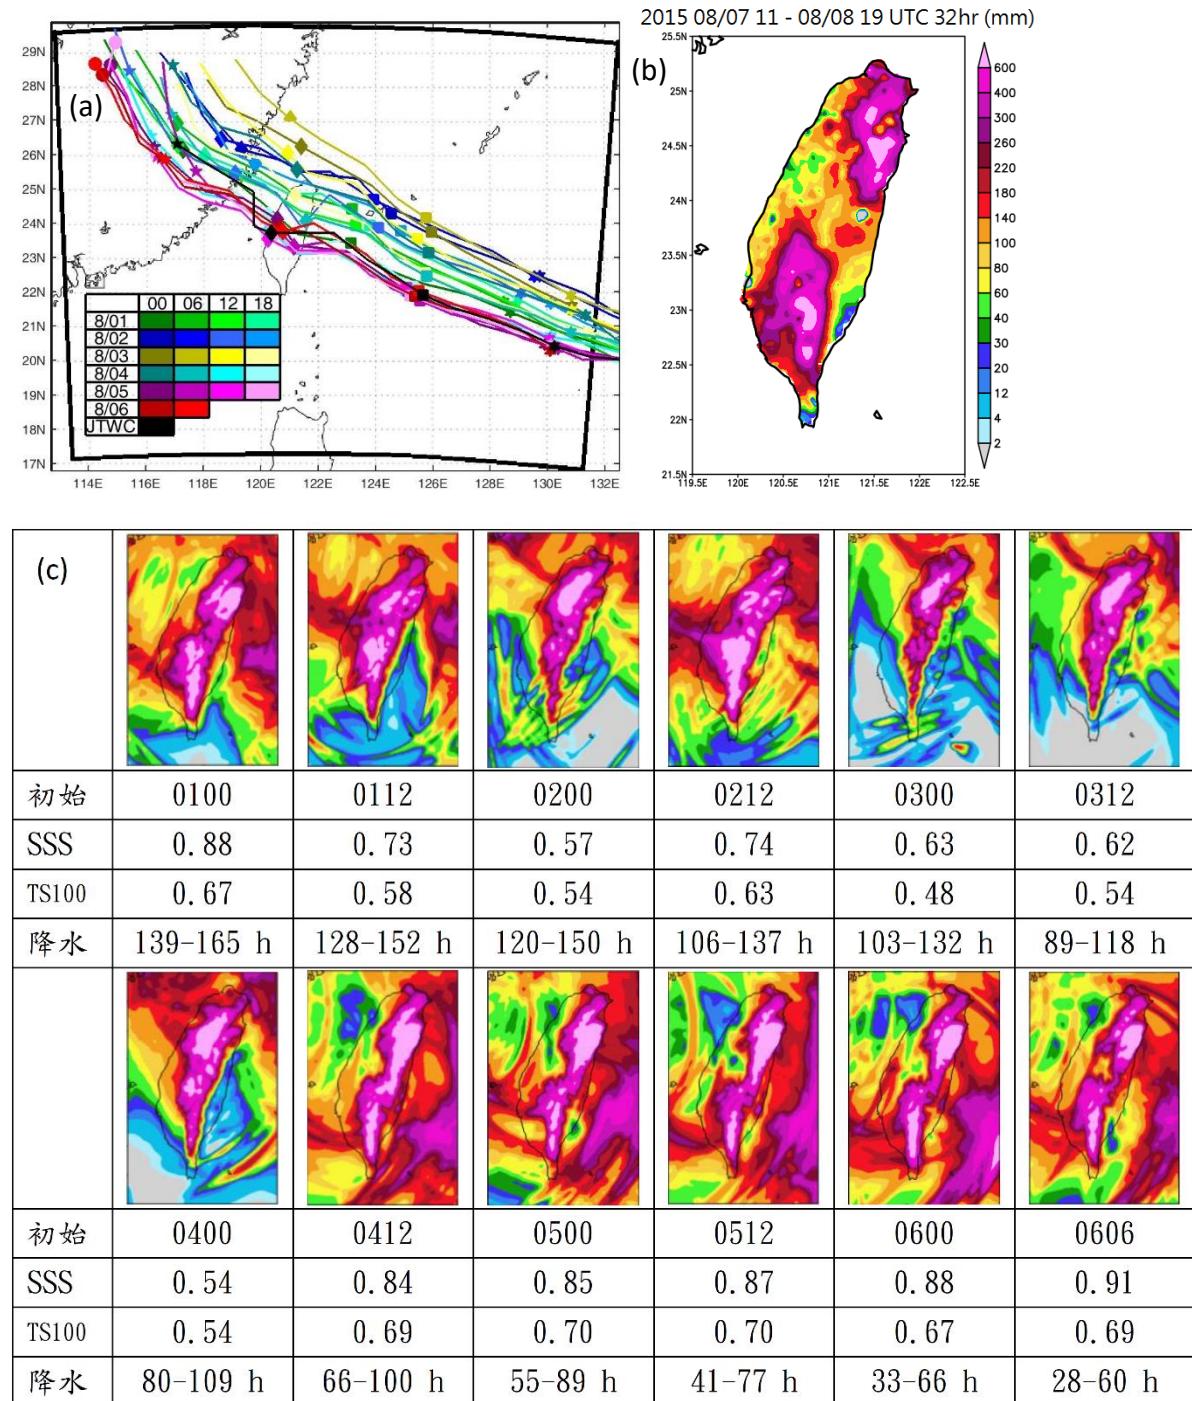


圖 5 同圖 4 但為蘇迪勒颱風之結果。預報路徑上，X、六角星、正方形、菱形、五角形及與圓形依序分別表示 8/5 到 8/10 者。本個案由觀測定義之影響期間為 8/7 1100 UTC 至 8/8 1900 UTC，長度共 32 h。預報降水為預報在各自影響期間之降水（色階同觀測）。

佳的降水情境發生在 8/6 0600 UTC 的預報（期限為 28-60 h），其降水的 SSS 值為 0.91。而當預報路徑偏北時，則中央山脈南部的

降水減少，SSS 下降到不足或接近 0.6。同樣地，若早在事件發生前一週的 8/1 0000UTC，吾人即知道此次預報情境的參

考價值很高，那對於防災準備將會非常有幫助。

由於篇幅有限，對於其餘的八個颱風，此處僅簡短討論。圖 6a 為菲特颱風（2013）的觀測與各初始時間的預報路徑，有別於前面兩個颱風的觀測路徑均較所示的大部分（或所有）預報路徑偏南，此颱風的觀測路徑發生在先前預報路徑中間，亦即預報同時有偏左與偏右者。在 10/1 0600 UTC 的預報中路徑最為偏右（偏北）而穿越奄美大島，隨後路徑漸往南修，但到 10/2 0600 UTC 時則又最為偏左（偏南）。到了 10/3 0000 UTC 以後，預報路徑由原先的發散情況逐漸收斂。由於菲特颱風的中心實際並未登陸，而是掠過臺灣北部外海（路徑一），其降水主要位在雪山山脈（圖 6b），

影響期間則為 10/5 2000 UTC 至 10/6 2300 UTC（共 27 h）。上述預報路徑較觀測更為接近臺灣的預報，由於影響時段（位於陸地 300 km 以內）拉長而造成過度預報降水，故越靠近臺灣者 SSS 值越低，最佳的降水情境預報為 10/3 0000 UTC 者（63-84 h），其降水預報的 SSS 為 0.90。

麥德姆颱風（2014）的觀測與預報路徑示於圖 7a，其由臺灣中部穿越，實際降水則示於圖 7b（累積時段為 7/22 0300 UTC 至 7/23 1500 UTC 的 36 h）。早在 7/16 0000 與 0600 UTC 的預報，便與觀測頗為接近（圖 7a），但如此長的前置時間，使得隨後的幾次預報（7/16 1200 UTC 到 7/17 1200 UTC 者）有路徑過度偏東（偏右）或颱風在登陸前就減弱消失的情況。之後對

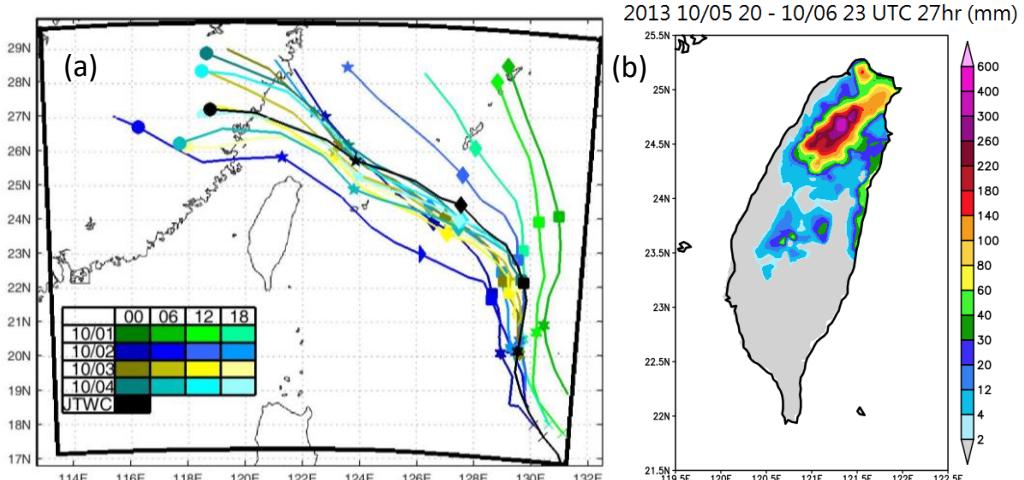


圖 6 同圖 4a,b 但為菲特颱風之結果。預報路徑上，X、六角星、正方形、菱形、五角形及與圓形依序分別表示 10/2 到 10/7 者。本個案由觀測定義之影響期間為 10/5 2000 UTC 至 10/6 2300 UTC，長度共 27 h。

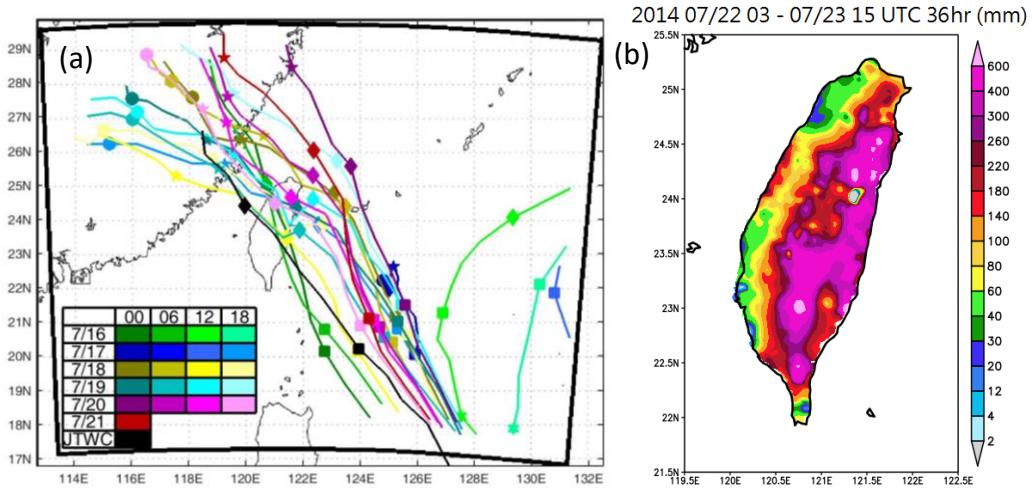


圖 7 同圖 6 但為麥德姆颱風之結果。預報路徑上，X、六角星、正方形、菱形、五角形及與圓形依序分別表示 7/20 到 7/25 者。本個案由觀測定義之影響期間為 7/22 0300 UTC 至 7/23 1500 UTC，共 36 h。

此颱風的掌握有所改善，並在 7/18 1200 UTC 做出最接近觀測的路徑預報。但是，之後的預報路徑又再有北偏之勢，以 7/20 0000 UTC 偏離最多（未登陸），直到所示的最後一次預報（7/21 0000 UTC 者），仍與觀測有相當的偏差距離。麥德姆颱風的降水主在位在山區與東半部（圖 7b），而儘管非常早，所示預報中最接近的降水情境發生在 7/16 0000 UTC 的預報（144-181 h），其 SSS 值達 0.87。

圖 8a 顯示莫蘭蒂颱風（2016）的觀測與不同初始時間預報路徑，其自東南向西北掠過南部近海（路徑五），降水則集中在東半部與南部恆春半島一帶（圖 8b）。在最

初期的預報（9/8 0000 UTC 者）最為偏北，颱風中心穿越沖繩附近，之後漸往南修正，且在 9/10-11 的幾次預報都由中部登陸並穿越，路徑似有收斂的態勢。但是，在 9/11 1800 UTC 的預報裡，路徑再度南修，到 9/12 0000 與 0600 UTC 的預報已與觀測接近。此處後者預報的降水情境與觀測最為接近，發生在 30-78 h，其 SSS 值為 0.80。路徑較偏北的預報，如自花蓮登陸者，則因中心登陸且影響時間亦拉長而多有過度預報（圖未示）。

如前所述，昌鴻颱風（2015）為所選個案中唯一一個預報路徑多較實際偏南的個案（圖 9a），但在最早的 7/4 0000 UTC

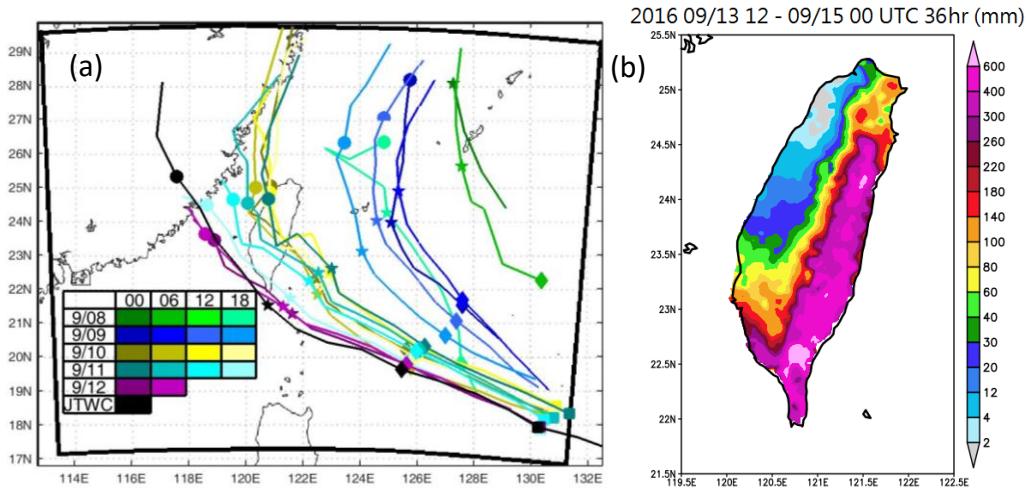


圖 8 同圖 6 但為莫蘭蒂颱風之結果。預報路徑上，X、六角星、正方形、菱形、五角形及與圓形依序分別表示 9/10 到 9/15 者。本個案由觀測定義之影響期間為 9/13 1200 UTC 至 9/15 0000 UTC，共 36 h。

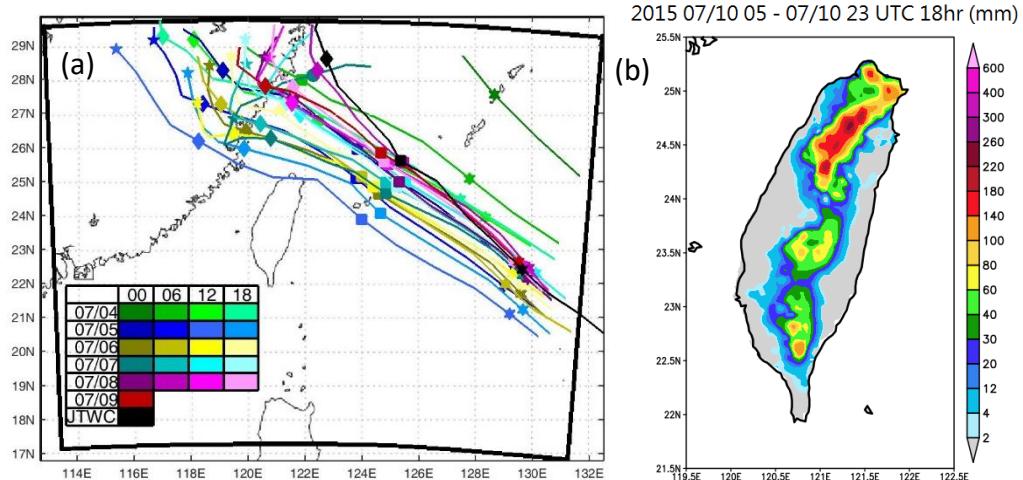


圖 9 同圖 6 但為昌鴻颱風之結果。預報路徑上，X、六角星、正方形、菱形、五角形及與圓形依序分別表示 7/8 到 7/13 者。本個案由觀測定義之影響期間為 7/10 0500 UTC 至 7/10 2300 UTC，共 18 h。

的預報也是過度偏北，中心通過沖繩北方海面。但隨後預報很快變成較觀測偏南，並在 7/5 1200 UTC 的預報路徑達到最南，穿越臺灣北端。而後路徑隨時間向北修正，且在 7/8 0600 UTC 的預報與觀測路徑最為接近，之後在靠近臺灣階段又略微南修。

由於其路徑（路徑一）離臺較遠，實際的影響期間僅 19 h，主要降水區域在雪山山脈（圖 9b）。前述 7/8 0600 UTC 預報降水（48-63 h）的 SSS 值可達 0.74，是圖中所示預報中與觀測最為接近的情境。

圖 10a 為蘇拉颱風（2012）的觀測與

預報路徑，顯示此個案實際在花蓮登陸並向北掠過東北部沿岸，大致位在所有顯示預報路徑裡最偏左的位置。7/26 1200 UTC 預報的路徑穿過沖繩以北，最為偏右，而此颱風在接近階段移速緩慢，前後不同初始時間的預報路徑落差頗大。在 7/27 預報路徑漸向臺灣靠近，且於 7/27 1800 UTC 預報出穿越北臺灣的路徑，與觀測相當接近。之後，預報路徑飄忽不定、再度向右偏而經過石垣島一帶，然後在 7/30 則又漸向左修正而接近臺灣。圖 10b 顯示蘇拉颱風於其影響期間的觀測累積降水，由於颱風移動緩慢且有登陸，累積的降水量十分可觀，以北臺灣與中部山區最多。上述最接近的路徑預報應是 7/27 1800 UTC 所做

者，且前置時間超過 4 天，在 107-161 h 小時，其降水的 SSS 值為 0.84。

圖 11a 為杜鵑颱風 (2015) 的觀測與路徑預報，在最早 9/22 1200 UTC 的預報路徑穿過沖繩一帶，隨後向南修正，在 9/24-25 一度停止修正，但到了 9/26 則再度向南修正、逐漸靠近臺灣並開始登陸。所示路徑中，以 9/26 1200 UTC 者最接近觀測。此個案實際由花蓮與宜蘭交界處登陸，觀測累積降水以東北象限與南部山區最多，且在雪山山脈與中央山脈北端均有達到 600 mm。在所示預報中，前述 9/26 1200 UTC 預報的降水情境亦最佳 (期限為 35-75 h)，SSS 值為 0.72。其餘的各預報路徑均更偏北，因此降水預報誤差亦較大。

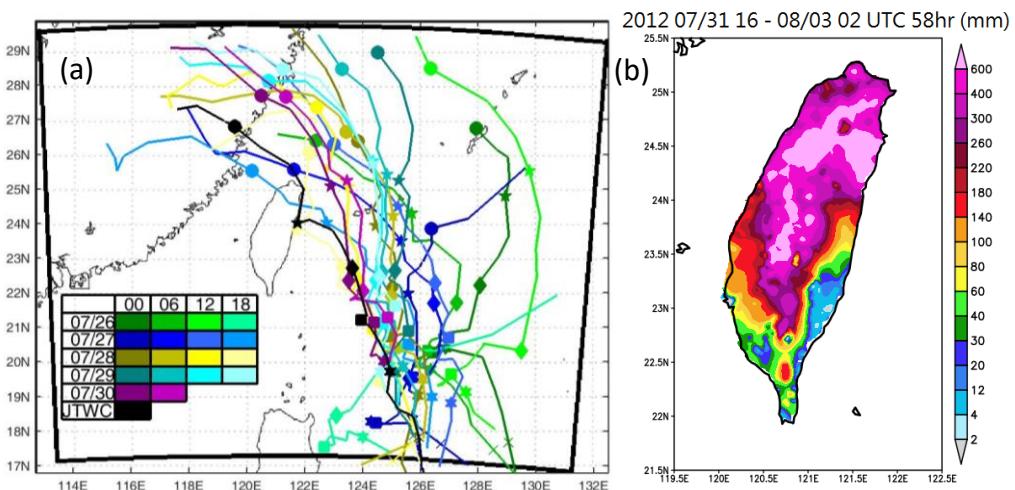


圖 10 同圖 6 但為蘇拉颱風之結果。預報路徑上，X、六角星、正方形、菱形、五角形及與圓形依序分別表示 7/29 到 8/3 者。本個案由觀測定義之影響期間為 7/31 1600 UTC 至 8/3 0200 UTC，共 58 h。

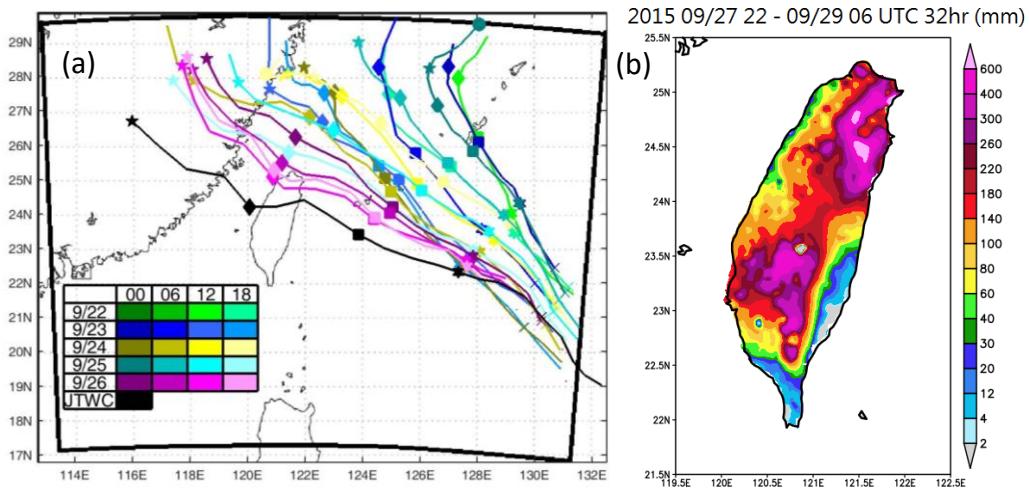


圖 11 同圖 6 但為杜鵑颱風之結果。預報路徑上，X、六角星、正方形、菱形、五角形及與圓形依序分別表示 9/26 到 10/1 者。本個案由觀測定義之影響期間為 9/27 2200 UTC 至 9/29 0600 UTC，共 32 h。

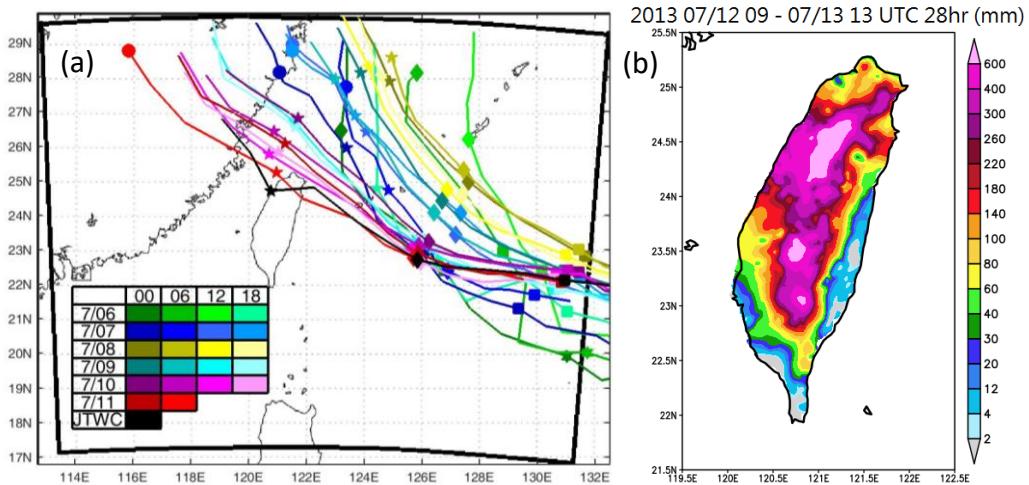


圖 12 同圖 6 但為蘇力颱風之結果。預報路徑上，X、六角星、正方形、菱形、五角形及與圓形依序分別表示 7/9 到 7/14 者。本個案由觀測定義之影響期間為 7/12 0900 UTC 至 7/13 1300 UTC，共 28 h。

圖 12 為蘇力颱風 (2013) 的結果。圖中可見，早在 7/6 0000 UTC 的預報中，颱風中心便通過石垣與西表兩島附近，與觀測頗為接近，但在更靠近臺灣時則向北偏轉，並未像觀測般在北臺灣登陸 (圖 12a)。與此相似，在 7/9 0600 UTC 以前的預報，

颱風在接近北臺灣時均較觀測明顯偏北，直到 7/9 1200 UTC 才開始減小偏轉，而向西北西方掃過台灣北部近海。之後的預報路徑逐漸略往南修正，最後在 7/11 0600 UTC 的預報是唯一報出中心有登陸台灣的預報，其對降水的掌握也最佳。圖 12b

為蘇力颱風於影響期間的觀測降水，主要在山區與中部平地，而 7/11 0600 UTC 預報降水 (27-52 h) 的 SSS 值高達 0.94，此初始時間比觀測影響期間的起始點更早了 27 h。

最後介紹的個案為天兔颱風 (2013, 圖 13)，其實際路徑為自南部近海通過 (路徑五)，故降水集中於東半部。各不同初始時間預報的颱風移動方向大致都頗接近，但越早的預報路徑傾向於越偏北，故 9/14 到部分 9/17 的預報，許多均自臺灣中部到南部穿越，但亦逐漸向南修正，到了 9/17 1800 UTC 者颱風中心開始不登陸臺灣 (與觀測相同)，而 9/18-19 的預報路徑則與觀測較接近。在所有顯示的預報裡，

9/18 1200 UTC 預報降水情境 (47-85 h) 的 SSS 值為 0.91，其路徑預報也與觀測相當接近。較早的各次預報，在路徑往南修正之前，甚至預報颱風中心有登陸臺灣者，便會過度預報累積雨量，但此符合吾人的預期。由圖 4 到圖 13 的個案回顧可以顯示，模式對許多颱風在很早即可做出好的整體降水情境預報 (SSS 達 0.8 以上)，但當路徑誤差 (特別是 CTE) 較大時，降水預報便如預期並不理想。但在事前，吾人往往無從知道，哪一個預報的情境會發生？因此，藉助於機器學習，希望能在事前就各預報的可信度得到適當的預報指引，作為預報的重要參考依據。

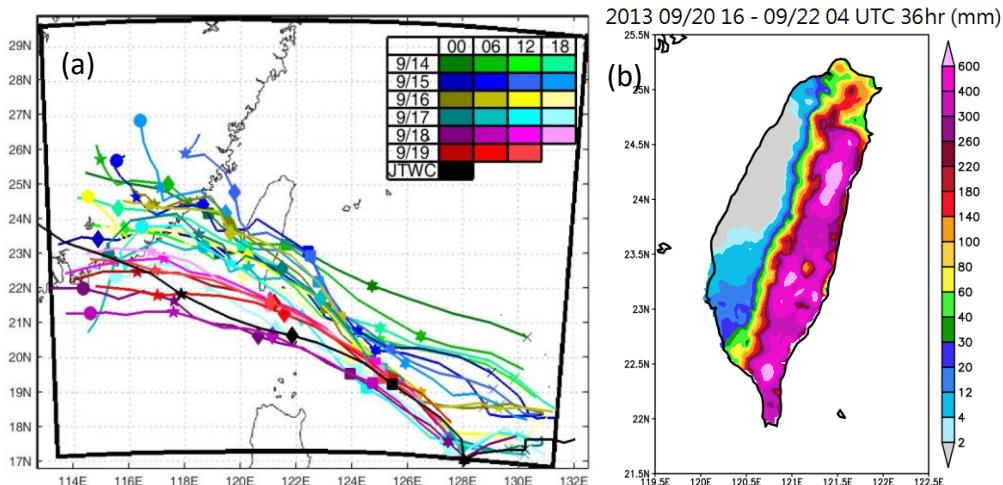


圖 13 同圖 6 但為天兔颱風之結果。預報路徑上，X、六角星、正方形、菱形、五角形及與圓形依序分別表示 9/18 到 9/23 者。本個案由觀測定義之影響期間為 9/20 1600 UTC 至 9/22 0400 UTC，共 36 h。

四、機器學習模型測試與變數相關性

(一) 預報參數與降水客觀指引的相關性

如前所述，本研究共選取了 105 個預報參數 (表一)，在輸入前會分別先將資料做標準化 (即減去平均值後除以標準差) 再輸入機器學習模型。可獲得的客觀指引，包括預報颱風侵襲期間總累積降水的預估 SSS、TS100 及 TS200，以及每 6 h 預估之颱風路徑誤差，包括 ATE 與 CTE。在進行機器學習前，本研究交叉計算了各預報參數與這些指引實際值 (使用觀測所得者) 彼此間的相關係數，其結果列於表二。將結果按照指引類型區分為降水得分 (SSS 與 TS) 與路徑誤差 (ATE 與 CTE) 兩個部分，分別討論如下。

在所有預報參數中，按照其與降品質的相關性，由高到低的前五種類型，依序為：

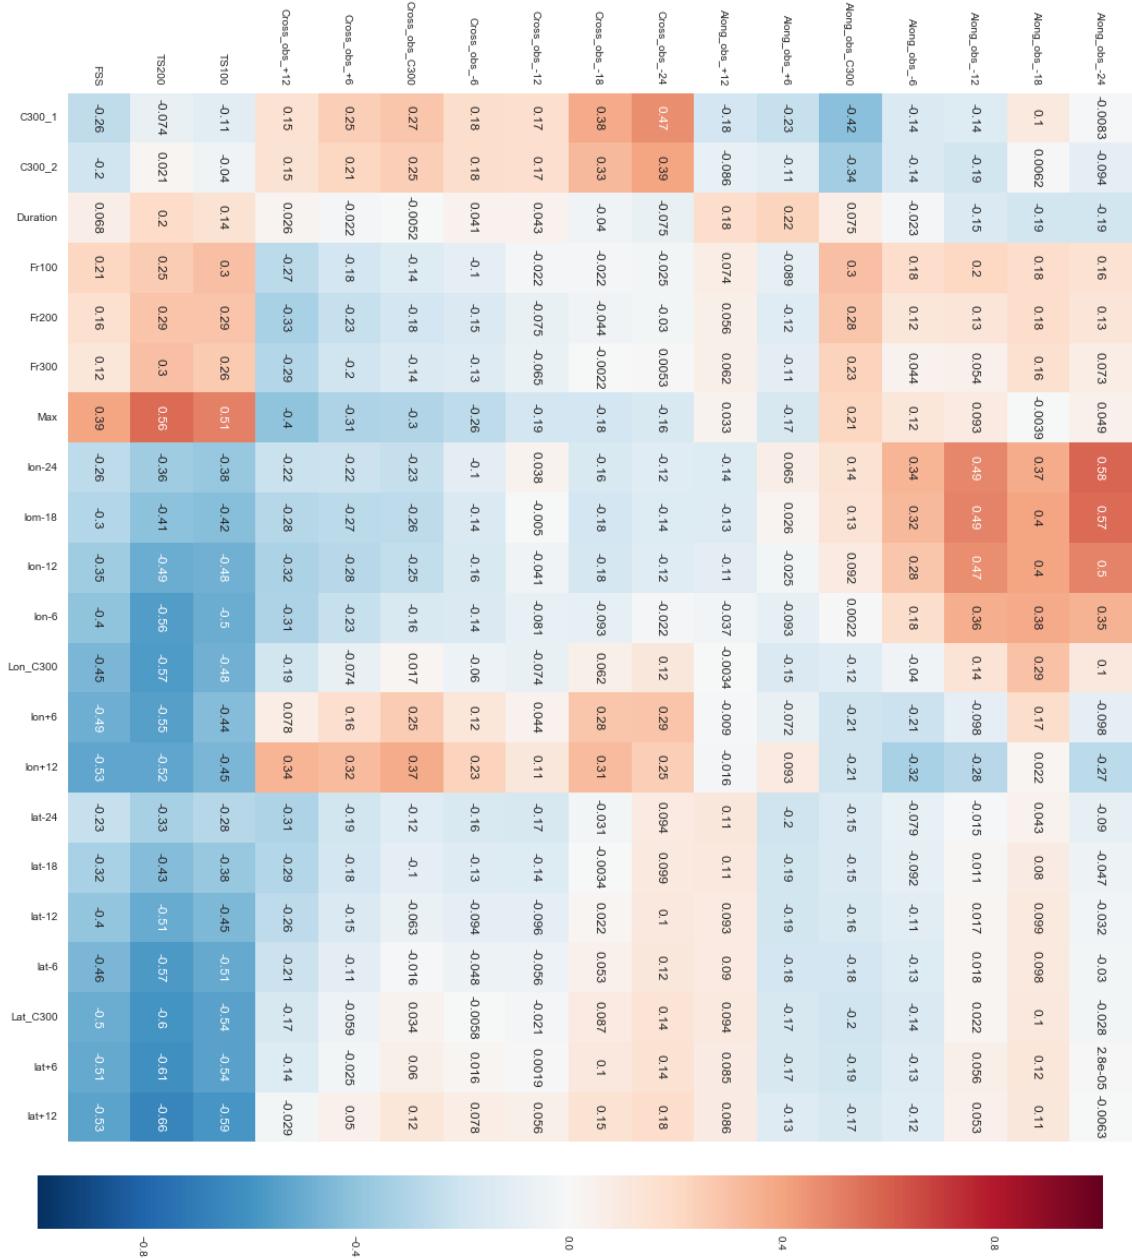
1. 本次預報各時間之颱風中心緯度
(表一第五、六項；Lat-24, ..., Lat+12)，
2. 本次預報之降水最大值 (表一第四項；Max)，

3. 本次預報各時間之颱風中心經度
(表一第五、六項；Lon-24, ..., Lon+12)，
4. 前幾次預報各時間之 CTE (表一第七、八項；Cross_06_-24, ..., Cross_24_+12)，及
5. 本次預報之降水面積覆蓋規模
(表一第三項；Fr100, Fr200, Fr300)。

上述這些預報參數類型，其在本次預報的各時間，也包括 C300_1 者。在所預報參數類型裡，與幾個降水指數相關係數最高者為本次預報各時間之颱風中心緯度，其相關係數介於 -0.66 至 -0.23 之間 [表二 (a) 左下部分]。最大負相關為 Lat+12，其後依序是 Lat+6、Lat_C300, ..., Lat-24，表示颱風路徑預報越往南偏 (緯度越低) 則降水預報越好。而且，此種關係對越後面的時間、亦即越接近累積時段 (或在累積時段內) 的位置則越明顯。此情形是由於在本研究的個案中，大部分颱風的初期預報路徑較為偏北、誤差也較大，造成降水得分偏低，而之後的預報路徑多往南修正，對降水情境的掌握也改善，故偏南路徑較為正確，此項因素所造成的影響。

預報的降水最大值 (Max) 與降水指

表二 (a) 所有颱風個案與預報中，在開始影響臺灣陸地（時間為 C300_1）前 24 h 到後 12 h 間、每 6 h 之觀測路徑誤差 (ATE 與 CTE) 與影響時段預報累積降水之技術得分 (TS100、TS200 及 SSS；各欄)，分別與第 1-21 個預報參數 (各列) 的相關係數 (數值與色階)。此處之預報參數包括表一中第 1-6 項所列者。



數的相關係數為第二高，其值為正，介於 +0.39 至 +0.56 間，[表二 (a) 第七列左側]，顯示模式預報的事件降水極值與其 SSS 及 TS 皆有或大或小的正相關。Wang (2015) 檢視了 CReSS 模式對 2010-2012 的

15 個颱風所做預報，發現在越多雨的情況下，颱風降水預報 (相同門檻處) 的 TS 值也傾向越高。從表中可以看出，Max 與 TS 值的相關性 (≥ 0.49) 也較 SSS (0.39) 為高。

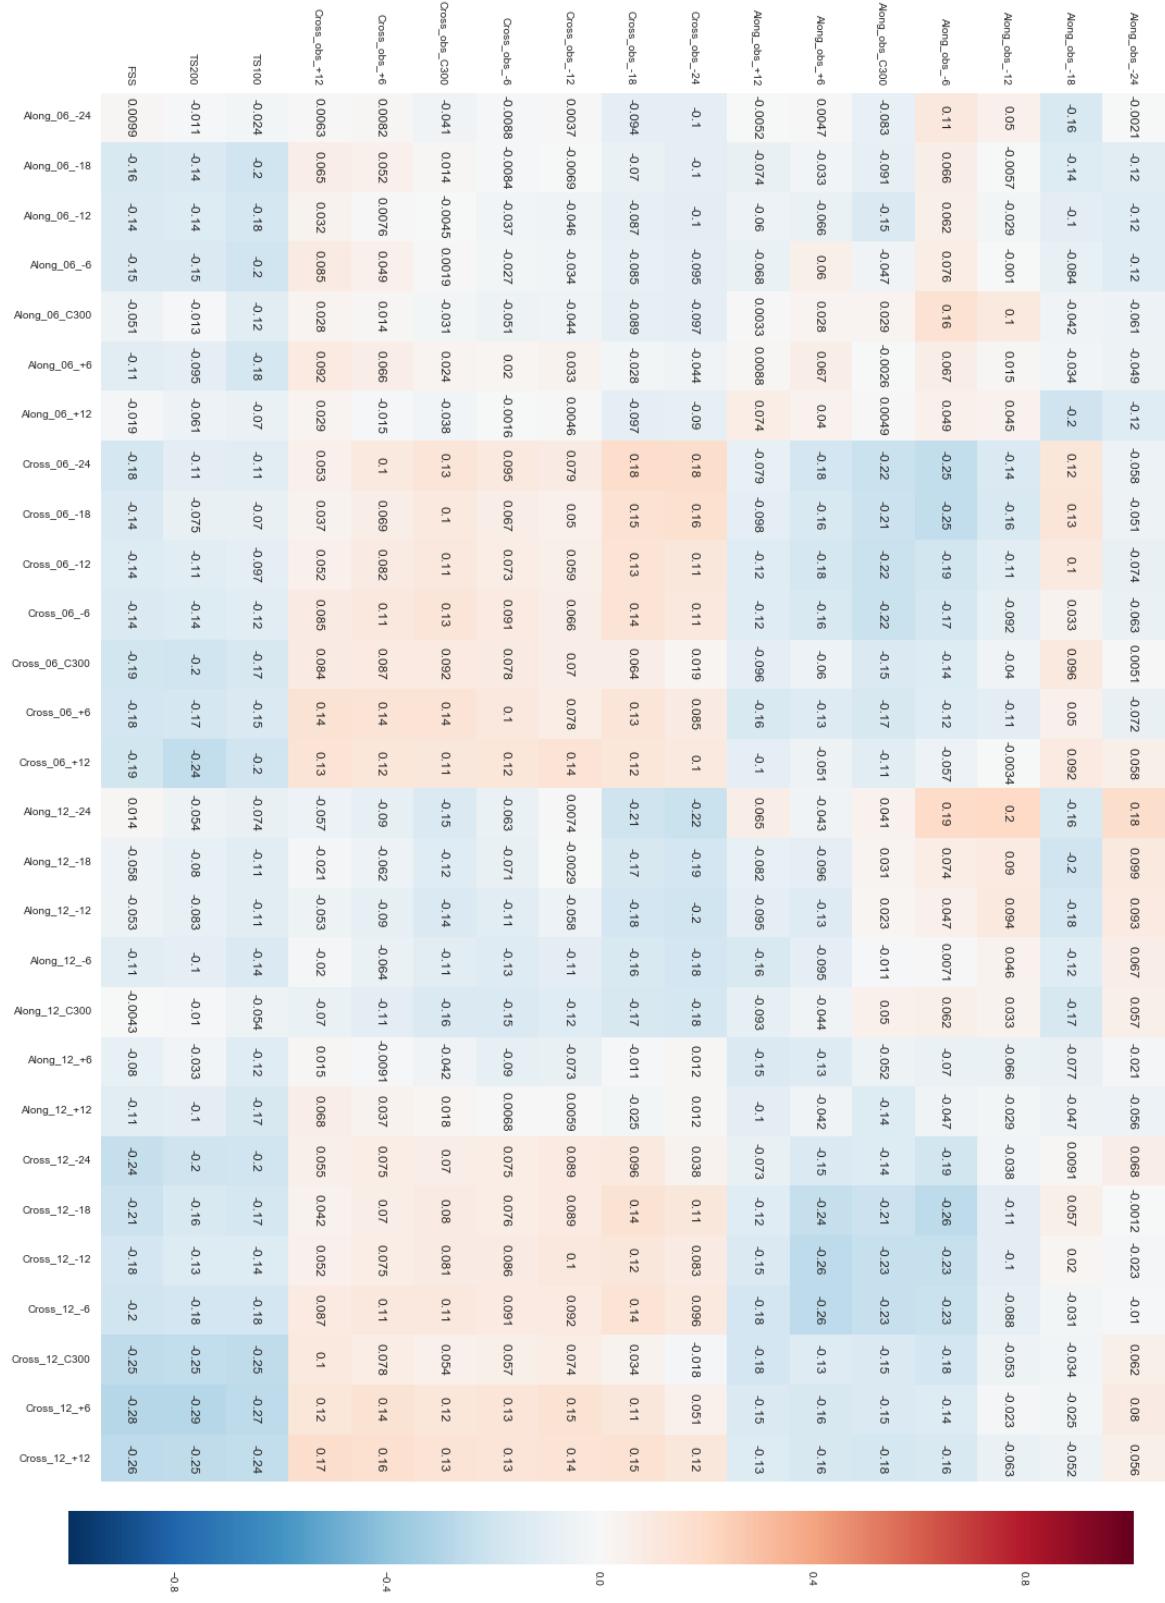
與降水得分相關係數第三高的類型，為預報各時間之颱風中心經度，其相關係數介於 -0.57 至 -0.26 間 [表二 (a) 左側中間]。與緯度相似，相關性有最大負值的是 Lon+12，其次依序是 Lon+6、Lon_C300, ..., 直到 Lon-24，可以解釋為若颱風路徑越往西偏（經度值越小）則降水預報越好。由於個案選取均為西行颱風，且對於預報的侵襲時間做了標準化（相對於 C300_1），因此這個現象意味著模式對於預報走得較快的颱風其降水掌握越好，應該是由於對此類駛流較強的颱風，路徑預報的誤差相對較小之故。另外，一部分原因也可能由於對初始位置與移速相似的颱風個案預報而言，偏北的路徑（預報較差）較容易偏東，而偏南的路徑（預報較佳）則較容易偏西，因而有此現象。

與降水得分相關係數第四高的預報參數類型，為前幾次預報各時間之側向路徑誤差 CTE，此處也包括各預報在 C300_1 者（例如：Cross_06_C300）。各時間方向誤差與降水指數的相關係數，介於 -0.32 至 -0.07 間 [表二 (b),(c) 最左側三欄]。在同一次預報裡，例如 6 h 前者，可看到 Cross_06_+12 、 Cross_06_+06 、 及 Cross_06_C300 的負相關數值皆大於

Cross_06_-24、...、及 Cross_06_-06 者，此現象顯示颱風進入距離臺灣陸地 300 km 線以後的 CTE，較通過之前者的相關性大。而且與 6 h 前的預報相比，其他更早時間所做預報 CTE 的相關性還更大。此現象雖看似與吾人認為越晚（越新）的預報會越準確的預期不一致，但其所反映的其實是路徑誤差在最終預報降水量質中主導性的高低。由於每次颱風預報都有各種誤差與一定的隨機性，而越新的預報路徑越趨於穩定，CTE 的數值落差較小，與其它誤差相較下，CTE 與降水技術得分的相關性就變得較低；反之，較早的預報，路徑預報誤差的落差與影響力皆相對較大，因此相關係數的絕對值較高。

最後一個討論的預報參數類型為預報降水面積在臺灣的覆蓋率，其與降水技術得分的相關係數，介於 +0.12 至 +0.3 之間 [表二 (a) 第三到六列左側]。如前所述，相同門檻值的降水區域越大，亦即越多雨，則颱風降水預報在該門檻處的 TS 值也傾向於越高 (Wang, 2015)。因此，此處的正相關結果，也再度驗證了此現象的存在。如同前述 Max 與降水指數相關性的特性一樣，預報的降水覆蓋率與 TS 值的相關性較與 SSS 者高。

表二 (b) 同表二 (a), 但為各觀測路徑誤差參數與降水技術得分 (各欄) 分別與第 22-49 個預報參數 (各列) 的相關係數。此處之預報參數包括表一中第 7-8 項所列的前一次與前兩次預報 (前 6 與前 12 h) 者。



表二 (c) 同表二 (b)，但為各觀測路徑誤差參數與降水技術得分 (各欄) 分別與第 50-77 個預報參數 (各列) 的相關係數。此處之預報參數包括表一中第 7-8 項所列的前三次與前四次預報 (前 18 與前 24 h) 者。

	Along_obs_-24	Along_obs_-18	Along_obs_-12	Along_obs_-6	Along_obs_C300	Along_obs_+6	Along_obs_+12	Cross_obs_-24	Cross_obs_-18	Cross_obs_-12	Cross_obs_-6	Cross_obs_C300	Cross_obs_+6	Cross_obs_+12	Along_18_-24	Along_18_-18	Along_18_-12	Along_18_-6	Along_18_C300	Along_18_+6	Along_18_+12	Cross_18_-24	Cross_18_-18	Cross_18_-12	Cross_18_-6	Cross_18_C300	Cross_18_+6	Cross_18_+12	Along_24_-24	Along_24_-18	Along_24_-12	Along_24_-6	Along_24_C300	Along_24_+6	Along_24_+12	Cross_24_-24	Cross_24_-18	Cross_24_-12	Cross_24_-6	Cross_24_C300	Cross_24_+6	Cross_24_+12	FSS
Along_obs_-24	0.07	-0.051	-0.071	-0.066	-0.15	-0.17	-0.065	0.029	-0.11	-0.087	-0.16	-0.13	-0.14	-0.12	-0.11	-0.085	-0.13	-0.15	-0.076	-0.16	-0.047	-0.06	0.19	0.13	0.17	0.17	0.079	0.11	0.047	-0.078	-0.16	-0.15	-0.11	-0.14	-0.15	-0.21	-0.14						
Along_obs_-18	-0.051	-0.071	-0.066	-0.15	-0.17	-0.065	0.029	-0.11	-0.087	-0.16	-0.13	-0.14	-0.12	-0.11	-0.085	-0.13	-0.15	-0.076	-0.16	-0.047	-0.06	0.19	0.13	0.17	0.17	0.079	0.11	0.047	-0.078	-0.16	-0.15	-0.11	-0.14	-0.15	-0.21	-0.14							
Along_obs_-12	0.18	0.13	0.097	0.14	0.095	0.073	0.018	0.043	-0.067	-0.1	-0.041	-0.05	-0.047	-0.06	-0.088	-0.19	-0.2	-0.13	-0.15	-0.12	-0.12	0.12	0.01	0.1	0.067	0.067	0.087	0.014	-0.2	-0.27	-0.26	-0.25	-0.26	-0.24	-0.3								
Along_obs_-6	0.2	0.11	0.081	0.1	0.078	-0.023	-0.031	-0.088	-0.19	-0.2	-0.13	-0.15	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12	-0.12									
Along_obs_C300	0.019	-0.0009	-0.034	-0.001	0.09	-0.047	-0.0074	-0.052	-0.15	-0.21	-0.18	-0.15	-0.19	-0.19	-0.013	-0.0085	-0.012	0.0028	0.081	0.13	-0.021	-0.099	-0.18	-0.21	-0.24	-0.23	-0.28	-0.26	-0.28	-0.26	-0.26												
Along_obs_+6	-0.034	-0.1	-0.13	-0.081	-0.037	-0.06	-0.013	-0.034	-0.14	-0.17	-0.14	-0.036	-0.078	-0.09	-0.072	-0.18	-0.09	-0.14	-0.086	0.037	0.025	-0.047	-0.14	-0.15	-0.16	-0.11	-0.14	-0.11	-0.11	-0.11	-0.11	-0.11											
Along_obs_+12	0.069	-0.078	-0.12	-0.13	-0.078	-0.21	-0.15	-0.01	-0.099	-0.13	-0.16	-0.15	-0.14	-0.21	0.045	-0.026	0.0017	-0.13	-0.1	-0.1	-0.14	-0.076	-0.12	-0.18	-0.21	-0.23	-0.19	-0.28	-0.28	-0.28	-0.28	-0.28											
Cross_obs_-24	-0.19	-0.15	-0.13	-0.22	-0.24	-0.06	-0.017	-0.12	-0.044	-0.038	-0.032	-0.073	0.027	0.01	-0.22	-0.29	-0.25	-0.23	-0.23	-0.14	-0.19	-0.028	0.013	0.015	0.062	0.057	0.14	0.14	0.14	0.14	0.14	0.14											
Cross_obs_-18	-0.21	-0.19	-0.18	-0.24	-0.27	-0.086	-0.016	-0.067	-0.012	0.023	-0.011	-0.046	0.046	0.041	-0.21	-0.3	-0.28	-0.29	-0.27	-0.16	-0.24	0.0042	0.016	0.024	0.067	0.063	0.15	0.15	0.15	0.15	0.15	0.15											
Cross_obs_-12	0.0055	-0.022	-0.068	-0.065	-0.1	-0.13	-0.023	0.16	0.12	0.14	0.14	0.11	0.17	0.15	-0.042	-0.11	-0.048	-0.16	-0.14	-0.037	-0.093	0.14	0.12	0.11	0.12	0.1	0.16	0.15	0.15	0.15	0.15	0.15											
Cross_obs_-6	-0.059	-0.097	-0.12	-0.14	-0.19	-0.15	-0.044	0.084	0.057	0.083	0.072	0.058	0.11	0.1	-0.081	-0.19	-0.14	-0.23	-0.23	-0.13	-0.16	0.088	0.074	0.069	0.077	0.069	0.13	0.13	0.13	0.13	0.13	0.13											
Cross_obs_C300	-0.12	-0.15	-0.14	-0.2	-0.26	-0.13	-0.026	-0.031	-0.026	0.013	-0.0025	-0.0073	0.061	0.058	-0.12	-0.25	-0.22	-0.29	-0.27	-0.19	-0.21	0.014	-0.012	0.0074	0.031	0.043	0.12	0.13	0.13	0.13	0.13	0.13											
Cross_obs_+6	-0.085	-0.11	-0.11	-0.13	-0.18	-0.067	0.011	0.021	0.012	0.057	0.042	0.033	0.1	0.11	-0.11	-0.22	-0.18	-0.26	-0.2	-0.14	-0.15	0.05	0.018	0.048	0.054	0.055	0.14	0.17	0.17	0.17	0.17	0.17											
Cross_obs_+12	-0.083	-0.1	-0.11	-0.088	-0.12	-0.013	0.069	0.053	0.032	0.079	0.062	0.072	0.11	0.15	-0.14	-0.21	-0.17	-0.26	-0.17	0.065	-0.1	0.06	0.0035	0.037	0.035	0.065	0.11	0.18	0.18	0.18	0.18	0.18											
TS400	-0.11	-0.12	-0.12	-0.15	-0.072	-0.08	-0.14	-0.28	-0.19	-0.2	-0.23	-0.28	-0.25	-0.26	-0.091	-0.061	-0.14	-0.04	-0.071	-0.067	-0.14	-0.24	-0.12	-0.13	-0.22	-0.28	-0.23	-0.28	-0.28	-0.28	-0.28												
TS200	-0.058	-0.042	-0.043	-0.071	0.041	0.038	-0.045	-0.32	-0.21	-0.21	-0.26	-0.32	-0.29	-0.27	-0.071	-0.028	-0.033	0.023	0.02	0.0062	-0.079	-0.24	-0.091	-0.11	-0.22	-0.28	-0.24	-0.27	-0.27	-0.27	-0.27												
FSS	-0.035	-0.055	-0.061	-0.082	0.021	-0.019	-0.06	-0.26	-0.19	-0.2	-0.21	-0.27	-0.25	-0.26	-0.061	-0.026	-0.033	0.039	0.03	0.0075	-0.031	-0.21	-0.13	-0.15	-0.21	-0.26	-0.26	-0.26	-0.26	-0.26													



0.8
0.4
0.0
-0.4
-0.8

(二) 預報參數與實際路徑誤差的相關性

若考慮預報參數中與各路徑誤差參數(表二中的第四欄到最右欄)的相關性，此處列出前四種類型分別討論，按照相關係數由高到低依序為：

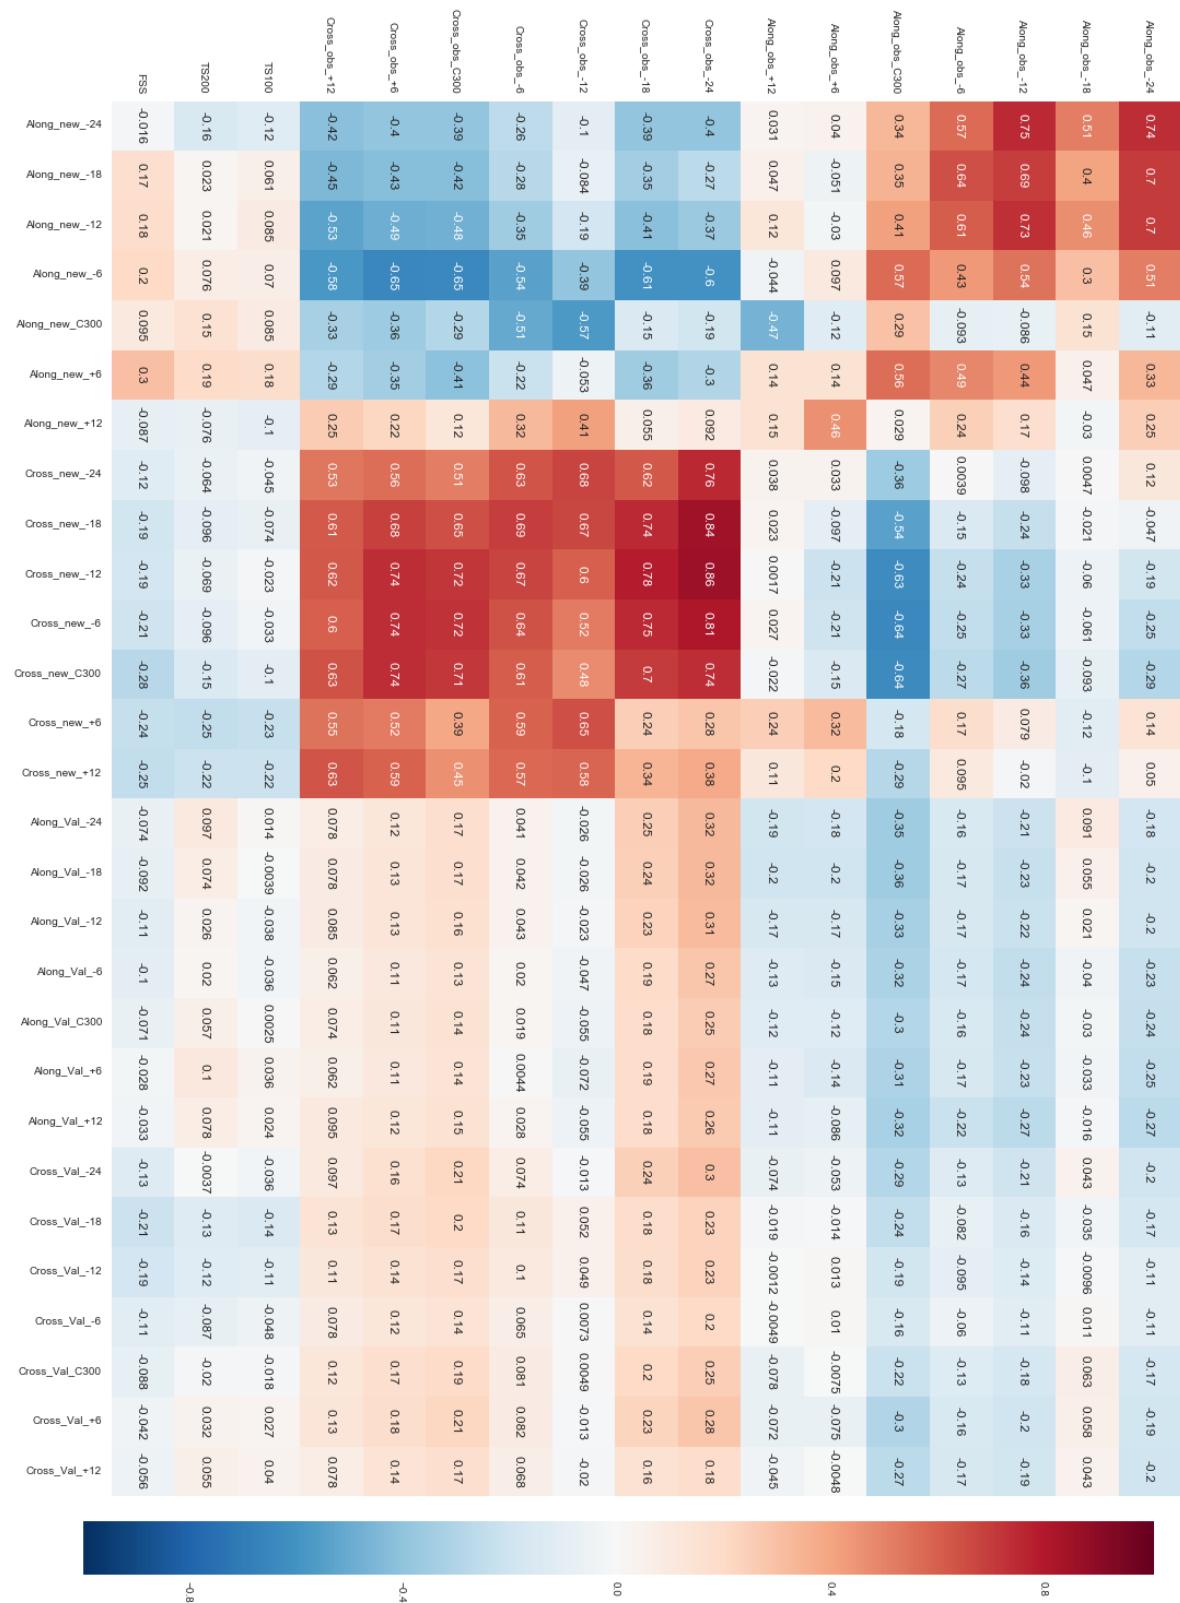
1. 目標和最新預報各時間的 CTE 與目標預報各時間實際的 CTE，
2. 目標和最新預報各時間的 ATE 與目標預報各時間實際的 ATE，
3. 目標和最新預報各時間的 ATE 與目標預報各時間實際的 CTE，以及
4. 目標和最新預報各時間的 CTE 與目標預報各時間實際的 ATE。

由於此處考慮的是與各實際路徑誤差參數的相關性，入選者皆為本次預報的目標路徑和最新預報各時間的路徑誤差參數，應該並不意外。相關性最高的，是目標和最新預報各時間的 CTE 與目標預報各時間實際的 CTE，兩者間的相關係數介於 +0.86 至 +0.24 間 [表二 (d) 左側偏深紅色儲存格]。此兩者的 CTE 如預期呈現高度正相關，因為最新預報與觀測路徑理論上最為接近，故大部分西行颱風的路徑預報，無論是較觀測偏北或是偏南，目標預

報的各時間相較於最新預報，多有著與觀測路徑相似的誤差，兩者有同向性，因此具有高度的正相關。相似地，目標和最新預報各時間的 ATE 與目標預報各時間實際的 ATE 也多呈正相關，其係數介於 +0.75 到 -0.47 之間 [表二 (d) 右側偏深紅色儲存格]，原因也與 CTE 的相關性相似。但是，ATE 又可區分為進入距離臺灣 300 km 假想線之前與之後，在通過之前的各時間呈現高度相關，但通過之後則相關性明顯降低。此現象意味著颱風在靠近臺灣之前，其最新預報與觀測預報移速快慢的關係較為密切，但是在接近臺灣時則關係減弱，此可能是受到地形影響而導致兩者間的相關性下降 (Hsu et al., 2013)。

接下來的兩類參數，是目標和最新預報各時間的 ATE 與目標預報各時間實際的 CTE、以及，目標和最新預報各時間的 CTE 與目標預報各時間實際的 ATE 之間的相關，也就是 ATE 與 CTE 分別與另一種路徑誤差之間的交叉相關。此兩類參數的相關性頗為接近，分別是 -0.65 至 +0.41 之間、以及 -0.64 至 +0.32 之間。如前面所討論的，雖然吾人原本並未預期 CTE 會與 ATE 有明顯的相關，但由於本研究所選個案的路徑預報特性 (圖 4 到圖 13)，較偏

表二 (d) 同表二 (a)，但為各觀測路徑誤差參數與降水技術得分 (各欄) 分別與第 78-105 個預報參數 (各列) 的相關係數。此處之預報參數包括表一中第 9-11 項所列者。



北(偏右)的路徑常也較為偏東(偏慢)，故 CTE 傾向為負而 ATE 傾向為正；而較南(偏左)的路徑則常較為偏西(偏快)，故 CTE 傾向為負而 ATE 傾向為正，再加上最新預報通常與觀測相去不遠，因此導致此兩參數的負相關結果。

(三) 機器學習模型之測試與調整

在第二章中，曾提到本研究針對機器學習類神經網路全連接層的寬度、深度、及激發函數均有進行測試與調整。調整時，針對每個颱風個案，使用其餘九個颱風隨機分配為訓練集與驗證集，並進行 100 次的隨機組合。每個組合下，訓練集的樣本將放入訓練重複 50 次，每次訓練則放入 20 組樣本不斷進行，而結果則取驗證集損失最小的那一組。因此，每個颱風可產出 100 組機器學習的結果，這些預估 SSS 值與實際值的絕對值差異結果示於表三，此處可加以討論。表三中的數據顯示，不同設定所產出 100 組的結果差距不大。經過簡單的統計分析，發現五層激發函數排列為 SRRSS、搭配 512 個神經元數量時的平均表現最佳。整體而言，預估 SSS 與實際模式預報 SSS 的誤差絕對值，有八成介於

0.118 與 0.252 之間(第 10-90 百分位)，中位數為 0.176，平均絕對誤差為 0.204，其標準差則為 0.084。

針對機器學習預估的 TS100 與 TS200 值，也可以有相似的統計分析。同樣以使用五層激發函數，以 SRRSS 方式排列、神經元數量採 512 個的平均表現最佳。八成預估 TS100 的絕對誤差介於 0.150 與 0.221 間，中位數為 0.183，平均值為 0.193，標準差則為 0.074；對 TS200 而言，80% 的數據則介於 0.150 與 0.217 之間，中位數為 0.183，平均值為 0.175，標準差為 0.062(表未示)。

同樣的五層激發函數以 SRRSS 排列、512 個神經元數量時，針對預估的 CTE 與 ATE 表現也是最佳。使用此項預估來修正最新預報之前與修正之後的結果示於表四，每個颱風最新預報的 C300_1 介於預報的第 24-29 h 之間，因此修正的時間是浮動的。由表四可見，CTE 的修正方向有 71% (亦即 5/7) 是正確的，使其絕對值減小，因此對於預報有所助益。但是，ATE 的修正調整方向(加快或減慢) 則只有 37% 正確，大部分並不正確，使得 ATE 絕對值反而增大，因此不太有效。

表三 採用不同寬度、深度、及激發函數組合之模型，所得針對所有颱風個案與所有預報各輸出 100 組後，預估之 SSS 值與實際 SSS 值的差異絕對值，在每 10 個百分位之結果。

深度	激發函數組合	寬度	百分位位置								
			90	80	70	60	50	40	30	20	10
4	SRRS	128	0.276	0.243	0.224	0.207	0.191	0.173	0.160	0.144	0.126
		256	0.259	0.231	0.213	0.197	0.181	0.168	0.154	0.139	0.125
		512	0.264	0.233	0.212	0.194	0.179	0.162	0.148	0.132	0.115
		1024	0.278	0.241	0.215	0.196	0.181	0.166	0.151	0.142	0.124
4	SRSS	128	0.276	0.243	0.220	0.203	0.189	0.176	0.162	0.135	0.119
		256	0.265	0.239	0.214	0.196	0.181	0.169	0.155	0.141	0.125
		512	0.274	0.245	0.221	0.200	0.185	0.170	0.155	0.139	0.121
		5	0.272	0.240	0.214	0.199	0.185	0.171	0.160	0.147	0.126
5	SRRSS	128	0.258	0.231	0.210	0.193	0.176	0.164	0.154	0.140	0.125
		256	0.253	0.224	0.204	0.188	0.176	0.164	0.151	0.136	0.121
		512	0.273	0.238	0.217	0.197	0.183	0.170	0.156	0.143	0.122
		1024	0.260	0.233	0.212	0.195	0.180	0.167	0.152	0.136	0.117
6	SRSRSS	128	0.276	0.244	0.220	0.201	0.188	0.173	0.159	0.144	0.126
		256	0.257	0.230	0.209	0.192	0.178	0.165	0.153	0.141	0.125
		512	0.252	0.225	0.206	0.189	0.176	0.161	0.147	0.135	0.118
		1024	0.260	0.233	0.212	0.195	0.180	0.167	0.152	0.136	0.117
7	SRSRSRS	128	0.279	0.241	0.216	0.197	0.185	0.172	0.159	0.147	0.128
		256	0.252	0.228	0.212	0.194	0.180	0.167	0.154	0.142	0.128
		512	0.258	0.232	0.212	0.194	0.180	0.168	0.157	0.144	0.129
		1024	0.271	0.238	0.215	0.202	0.188	0.177	0.165	0.150	0.133
		256	0.259	0.230	0.211	0.195	0.182	0.169	0.155	0.142	0.124
		512	0.254	0.231	0.213	0.194	0.184	0.171	0.156	0.144	0.122

表四 經機器學習修正前後，不同預報時間長度的平均 CTE、ATE、及 TE 絶對值變化 (km)。

預報期限	0~5 h	6~11 h	12~17 h	18~23 h	24~29 h (C300_1)	30~35 h	36~41 h
修正前							
CTE 絶對值	10.4	18.9	24.9	34.7	44.5	55.0	60.2
ATE 絶對值	16.9	27.9	28.9	31.8	30.3	41.8	58.5
TE 絶對值	19.9	33.7	38.2	47.0	53.8	69.1	84.0
修正後							
CTE 絶對值	11.0	18.6	18.5	25.3	30.9	52.8	70.1
ATE 絶對值	46.8	52.3	35.5	65.2	90.0	86.7	66.7
TE 絶對值	48.1	55.6	40.0	69.9	95.1	101.6	96.7

五、機器學習結果與分析

(一) 機器學習所得之颱風降水預報指引

由機器學習產出的客觀預報指引，包括降水技術得分與路徑誤差兩類，而這些參數也都有由模式預報和實際觀測所計算出來者。為了在討論時加以區分，後者均稱之為模式預報的實際得分 (SSS 或 TS) 或路徑誤差 (CTE 或 ATE)，而機器學習模型所預估者均稱之為預估之得分或誤差。整體而言，預報實際 SSS 的平均值是 0.659，標準差為 0.231；而模型預估 SSS 的平均值是 0.614，標準差則稍小，為 0.170，但兩項參數均仍算頗為接近。圖 14 是實際 SSS 與預估 SSS 以 0.1 為區間的各自分布百分比，可以看到預估 SSS 的分布仍與實際者有些許差距，前者較平滑而後

者則有較多高低起伏的細部變化，實可預期。圖 14 顯示，機器學習預估之 SSS 在 0.2-0.8 的區間呈現高估實際，在其他區間則低估，而在部分區間，兩者的差距可以超過 10%。

表五列出各颱風個案的一百組機器學習模型輸出之預估 SSS 與 TS100 值與實際值 (由模式預報與觀測直接計算者) 絶對誤差的第一四分位 (第 25 百分位)、中位數 (第 50 百分位)、與第三四分位 (第 75 百分位) 值。表中可看出各颱風皆有其一定程度的特殊性，以蘇迪勒、杜鵑、及莫蘭蒂颱風的降水指引較容易以機器學習預估 (SSS 絶對誤差較小，數值介於 0.114 至 0.166)，而以天兔、尼伯特、及菲特颱風的預估則較困難 (SSS 絶對誤差較大，數值介於 0.189 至 0.277)。另外，預估 SSS

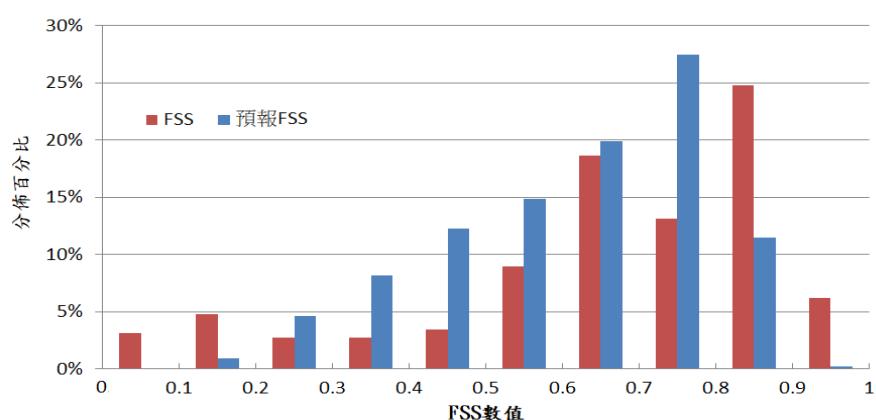


圖 14 模式預報的實際 SSS (紅) 與機器學習模型預估 SSS (藍) 的分佈百分比，可以將 0.6 以上者視為預報可信度較高，而 0.6 以下則視為預報可信度較低。

在對昌鴻颱風的表現上特別不同，絕對誤差數值均特別大 (≥ 0.392)。如前述，這是因為昌鴻颱風是選取個案中唯一一個大部分預報時為偏南且隨後漸向北修正的颱風，所以可想而知，在藉由其他九個颱風的數據學習後，由於都沒有類似的學習經驗，所以做出的預報便會特別不佳。表五中，預估 SSS 上較為困難的颱風預報，其路徑皆通過臺灣北方或南方海面、並未登陸。由於本文定義颱風影響期間為距離臺灣陸地 300 km 以內，故當路徑屬於此類型（路徑一或五）時，其預報路徑稍微偏南或偏北，便會對累積降水的時段長短、以及累積降水量造成很大影響，再加上機器學習為一種複雜統計方法，在預估上將較保守，因此當實際 SSS 偏高時，預估值

往往不夠高；反之，實際 SSS 偏低時，預估 SSS 則不夠低，此種特性也是造成此類型評估時表現較差的部分原因。

接下來，吾人可以進一步討論各颱風個案預報的實際 SSS 與機器學習預估 SSS 的比較，並檢視兩者的相關性。圖 15 顯示尼伯特颱風的結果，各初始時間預報的降水情境則可參見圖 4。各預報中，在其颱風影響期間（即降水累積期間）的實際 SSS 與預估 SSS 的比較，可知尼伯特颱風其實是許多時間降水預報表現較差的一個個案，此點表現在實際 SSS 值偏低的情形，而其原因在第三章已有所討論。但是，此個案在不同初始時間的降水預報品質落差也很大，因此很適合用來展現機器學習的掌握狀況，是否能夠預估好的降水預報較

表五 機器學習針對各颱風個案所產生一百組模型後，實際 SSS 與 TS100 值與模型預估之 SSS 與 TS100 值絕對誤差的第一四分位、中位數、與第三四分位值。

個案	SSS			TS100		
	第一 四分位	中位數	第三 四分位	第一 四分位	中位數	第三 四分位
天兔	0.219	0.244	0.277	0.211	0.230	0.250
蘇力	0.156	0.171	0.188	0.170	0.198	0.215
蘇迪勒	0.114	0.128	0.148	0.135	0.154	0.171
蘇拉	0.172	0.184	0.208	0.242	0.255	0.276
尼伯特	0.194	0.224	0.245	0.211	0.226	0.244
莫蘭蒂	0.127	0.144	0.161	0.169	0.184	0.196
麥德姆	0.139	0.160	0.182	0.108	0.122	0.146
菲特	0.189	0.218	0.252	0.133	0.146	0.160
杜鵑	0.120	0.136	0.166	0.106	0.126	0.154
昌鴻	0.392	0.403	0.420	0.354	0.374	0.393

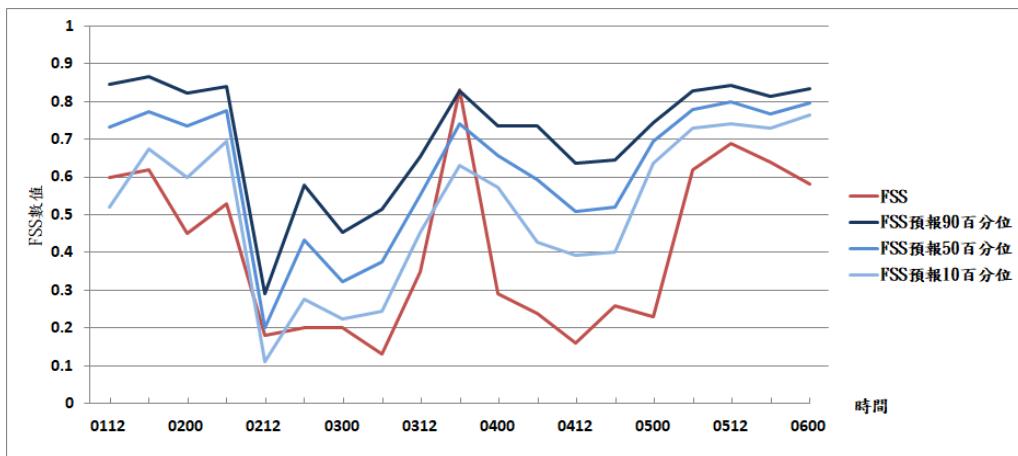


圖 15 針對尼伯特颱風，各不同初始時間預報（橫軸，日與 UTC 時）在其影響期間降水的實際 SSS (紅) 與機器學習預估的第 90、50、及 10 百分位值 (深至淺藍)。

為可信，而不好的則較不可信。圖中可以看到，實際的 SSS 值 (紅色曲線) 在初期的 1 日 1200 UTC 到 2 日 0600 UTC、中間的 3 日 1800 UTC、以及後段的 5 日 0600 到 6 日 0000 UTC 的降水預報都相對較佳 ($SSS > 0.5$)；其它時間則表現不佳 ($SSS < 0.35$)，最好與最差預報的 SSS 差異，接近 0.7。經機器學習後，雖然不同百分位的預估 SSS (藍色系曲線) 有一定的差異範圍、在定量上也未必總是精確掌握，但是可以明顯看出它的確有掌握到實際 SSS 的高低起伏趨勢，在相同百分位的落差約達 0.65。換言之，它可以在事前告訴吾人，實際 SSS 較高的預報比較可信，而實際 SSS 較低的預報則較不可信。在作業情境下，這些實際的 SSS 值要到觀測發生後才能得知，在事前並不知道。

圖 16 則為蘇迪勒颱風在不同初始時間預報的實際與預估 SSS 值之變化，其各預報的降水情境示於圖 5)，且此個案是 SSS 預報表現較好的成員之一，其所有預報的實際 SSS 均在 0.5 以上。圖 16 中，可看到在 4 日 0000 UTC 之前所做預報的實際 SSS 多相對較低，之後則有增高趨勢，但最早的一次預報 (1 日 0000 UTC) 則是所有預報中次佳的。機器學習預估的 SSS 值，也顯示在 0400 UTC 之後的所有預報、以及最早在 1 日 0000 UTC 的降水預報，比較可信 (預估 SSS 中位數 > 0.7)，其間的其它預報則可信度較低 (預估 SSS 中位數多 < 0.6)。然而，當預報品質接近時的一些微小細節，例如在 3 日之間的變化，則機器學習並無法完整掌握。

圖 17 與圖 18 分別顯示其餘的八個颱

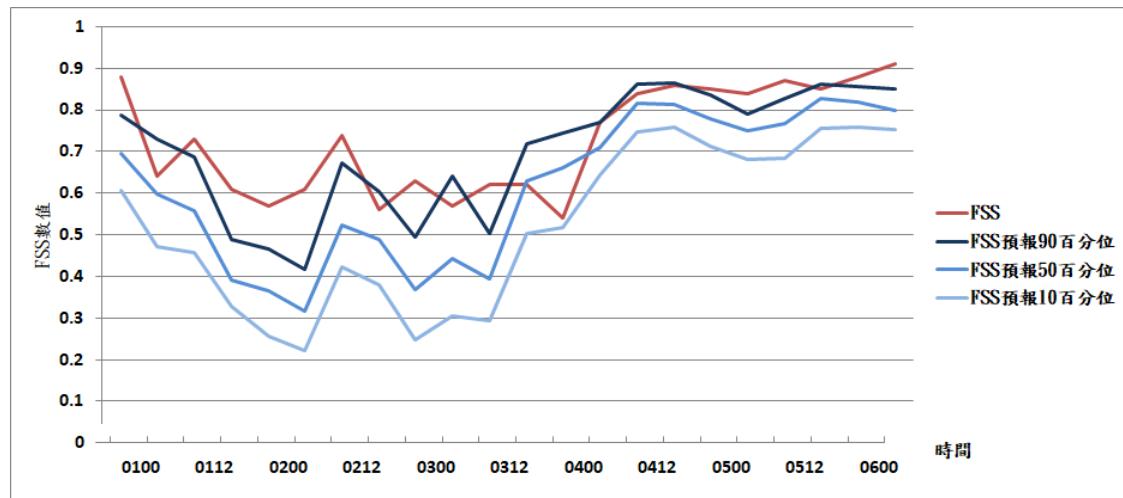


圖 16 同圖 15，但為針對蘇迪勒颱風之實際（紅）與模型預估（藍色系）之 SSS 值。

風個案的結果，包括模型預估 SSS 表現相對較好的四個颱風個案（圖 17）與較差的四個個案（圖 18）。圖 17 中，杜鵑、莫蘭蒂、及蘇力颱風的實際 SSS 隨時間均為增加，而預估 SSS 也大致可以掌握此升降趨勢。其中，杜鵑颱風（圖 17a）於 25 日 0000 與 0600 UTC 的兩個預報中，皆北偏至距離臺灣超過 300 km，因此沒有累積時段與相關的預估 SSS 值。四個個案中，以蘇力颱風（圖 17d）的預報最佳，其實際 SSS 從 9 日 1200 UTC 開始就都達到 0.8，此時間大概是影響時段開始之前三天，預估 SSS 的中位數，自此則均可達到 0.7 左右，指示有較高的信心。對於莫蘭蒂（圖 17b），實際 SSS 曲線相對較平、起伏不大，大概在 0.6-0.75 之間。預估的 SSS 隨時間的變

化則較大，但仍可指示對於 19 日 0600UTC 的預報，以及 20 日 1200 UTC 開始的幾次預報，有較高的信心（預估 SSS 的中位數 > 0.65 ）。圖 18 則顯示剩下的四個颱風，其預估 SSS 對實際值升降趨勢的掌握較不理想，包括蘇拉、菲特、天兔、及昌鴻颱風。其中，菲特與天兔實際的 SSS 變化起伏較小，而蘇拉與昌鴻者則較大。對天兔而言（圖 18c），預估的 SSS 變化範圍大於實際，但蘇拉（圖 18a）則是相反，預估的 SSS 變化範圍小於實際，但兩者的預估 SSS 均仍大致可掌握變化趨勢，當實際降水預報較好時也預估相對較高的 SSS 值。昌鴻（圖 18d）則是所有個案中結果最差的，預估 SSS 與實際 SSS 的變化幾乎相反，其原因也已有討論。另外，菲特颱風也是預估與

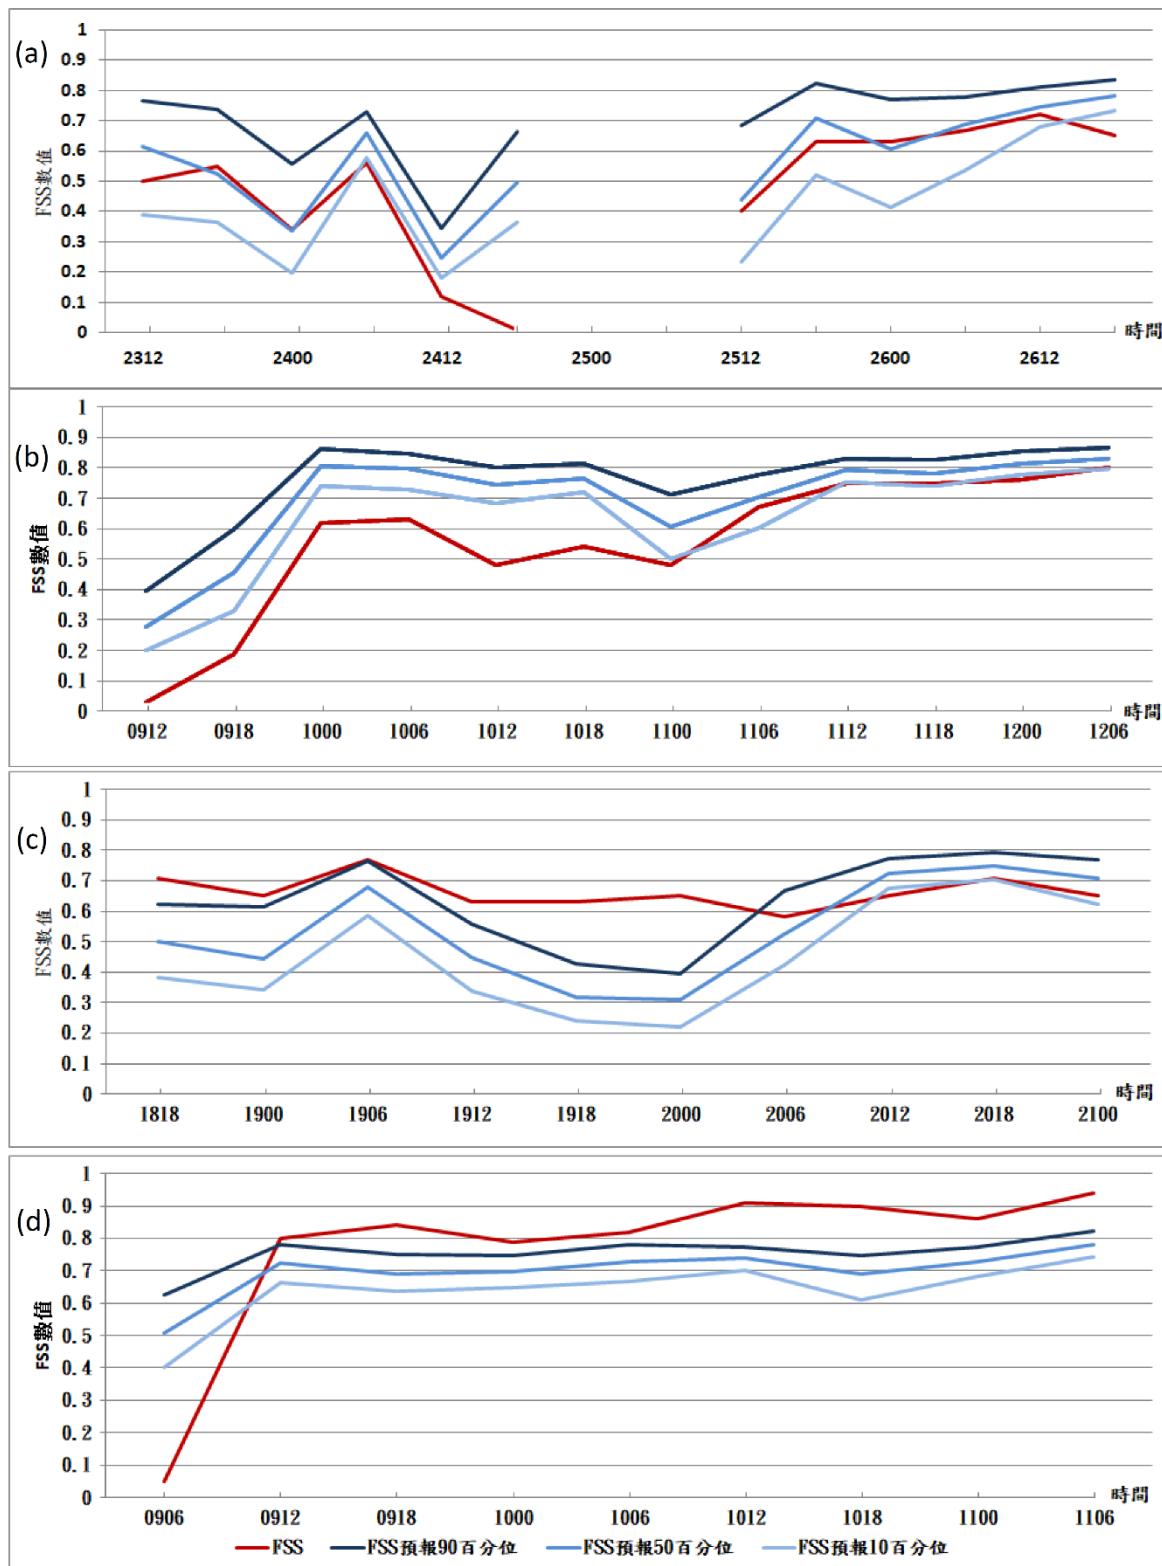


圖 17 同圖 15，但為針對 (a) 杜鵑，(b) 莫蘭蒂，(c) 麥德姆，及 (d) 蘇力颱風之實際 (紅) 與模型預估 (藍色系) 之 SSS 值。

實際 SSS 的變化趨勢相反的個案。可能原因是其實際路徑通過北部海面，而在 3 日 1200 與 1800 UTC、以及 4 日 0600 UTC 的預報路徑都較實際者偏南。由表二 (a) 顯示，預報颱風中心的緯度與 SSS 呈現高度負相關，因此便可能發生此種現象，亦即當預報颱風的行為與大部分輸入訓練的資料相反時，機器學習就無法妥善掌握。若增加更多颱風個案與訓練資料，則此點有可能可以改善。從以上的例子，顯示預估的 SSS 在大部分颱風個案的趨勢上有頗高的參考價值，但是其預估結果往往較實際保守。而且，當實際 SSS 大幅變動時，該颱風平均 SSS 預估結果的表現也會傾向較差。另外，使用預估 SSS 做為客觀指引時，因為 50 百分位的結果在 0.6 上下大致各占一半，可以將 0.6 以上者視為預報可信度較高，以下者則視為預報可信度較低，在使用上可以在颱風中心登陸至少 48 h 前，知道該次模式預報是否可信。在本研究裡，當預估 SSS 的 50 百分位數達 0.6 以上時，其實際 SSS 有 71% 也大於 0.6，當預估 SSS 的 50 百分位數達 0.6 以下時，其實際 SSS 有 46% 也小於 0.6。

針對 TS 的機器學習結果大致與 SSS 者相似，唯一不相同處是菲特颱風在 SSS

預估表現不佳但對 TS 的預估則表現較好。表二 (a) 中，預報最大累積降水在 (Max) 與 TS100 和 SSS 都有頗高的相關性，而菲特颱風是屬於預報降水較少的個案，故在預估 TS100 和 SSS 時會有兩者都應該偏低的趨勢。但實際上，菲特颱風的 SSS 得分很高，僅有 TS 值是偏低的，因此會產生預估 TS 與 SSS 結果不同調的情況。

(二) 機器學習所得之颱風路徑預報指引

路徑修正的客觀預報指引，在僅有 10 個颱風進行訓練時，其機器學習在設計上並不容易。目前模型的訓練目標是針對過去所有路徑預報都進行 CTE 與 ATE 的預估，並期待能夠給予修正。經測試與評估後，CTE 與 ATE 在正負號 (即修正方向) 的正確性分別為 82% 與 74%，但是機器學習給予的修正量 (幅度) 則相對保守，導致雖對過去預報的 CTE (或 ATE) 進行些許修正，但結果仍比未修正之最新預報者為差。因此，本研究轉為僅評估最新預報的修正結果，但是這樣的作法會使得機器學習目標 (修正全部預報路徑) 與評估方式 (僅評估最新預報修正結果) 不一致的情況發生，有待未來進一步改善。整體而言，從上一章的結果討論可以顯示，大部

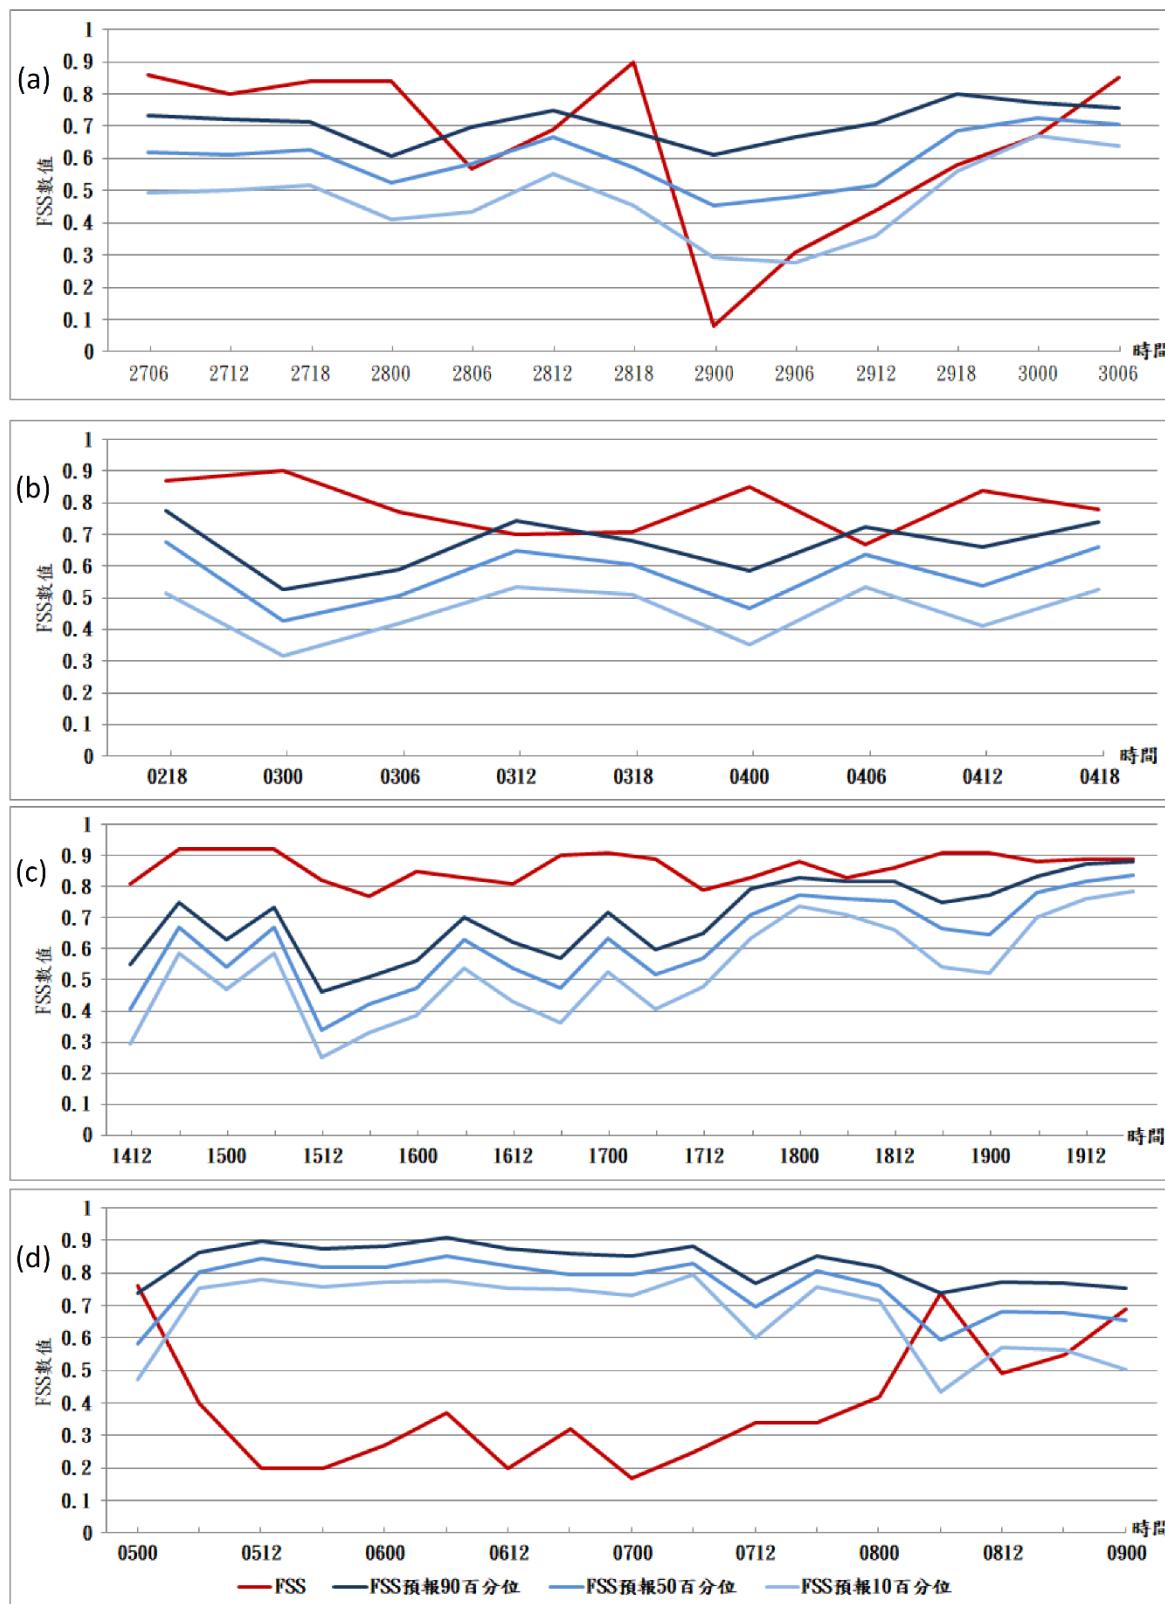


圖 18 同圖 17，但為針對 (a) 蘇拉，(b) 菲特，(c) 天兔，及 (d) 昌鴻颱風之實際（紅）與模型預估（藍色系）之 SSS 值。

分在颱風移動方向 (CTE) 上的修正，仍然具有參考價值。而對颱風移動速度 (ATE) 的修正，由表二(a)右半部可以發現 ATE 與路徑所在經緯度有最高的正相關 (0.58)。但是，將最新預報資料提出統計後，最新預報的 ATE 與經緯度的相關係數僅有 0.23，相對偏低。此處 ML 模型容易放大移速誤差的可能原因在於模型與實際情形有一定程度的落差，因此未能對最新預報的 ATE 做出良好修正。在本研究的範圍內，使用上若針對最新預報 CTE 修正上為正號，可考慮將最新預報往北修正，不過颱風路徑預報指引的結果不若降水預報指引成熟，在使用上應較謹慎，僅斟酌參考即可。

(三) 機器學習敏感度測試

從經驗上來看，相關性高的數據重要性相當高，但是相關性低的數據也並非無用。有時，表面看起來可能覺得無用，但是這些數據可能以某些不易察覺的方式彼此相關，而機器學習即可能能夠找出這些關聯性。不同參數敏感度是相當有趣的問題，研究上將參數分做以下六組：

1. 表一 1-2 項 (C300_1、C300_2 與 Duration)，是預報開始到颱風中心

首次靠近臺灣陸地至 300 km 內的時間、遠離臺灣陸地即將達到 300 km 的時間與影響臺灣的時段長短。

2. 表一 3-4 項(Fr100-300 與 Max)，是颱風預報降水分別達三個降水閾值 (100、200、及 300 mm) 之範圍佔臺灣本島面積的比例與本島最大累積雨量。
3. 表一 5-6 項(Lat-24...Lat+12 與 Lon-24...Lon+12)，是預報颱風中心首次靠近臺灣陸地至 300 km 內的經緯度。
4. 表一 7-8 項 (Along_06_-24...Along_06_+12 與 Cross_06_-24...Cross_06_+12)，是本次預報颱風心在 C300_1 時間之前 24 h 到後 12 h (每 6 h)，與提早 6h 至 24h 者報至各相同時間的 ATE 與 CTE。
5. 表一 9-10 項(Along_new_-24...Along_new_+12 與 Cross_new_-24...Cross_new+12)，是本次預報颱風心在 C300_1 時間之前 24 h 到後 12 h (每 6 h)，與最新預報報至相同時間的 ATE 與 CTE。

6. 表一 11 項 (Along_Val_-24...Along_Val_+12 與 Cross_Val_-24...Cross_Val+12) 是較本次提早 6 h 至 24 h 的前 4 次預報中，報至 C300_1 時間之前 24 h、到後 12 h (每 6 h)，也包含 C300_1 當時者，各相同時間之絕對 ATE 與 CTE 的加權平均值，提早 6, 12, 18, 24 h 預報之權重依序為 3, 3, 2, 1。

進行敏感度測試時，僅針對 SSS，激發函數組合 SRSRS，512 神經節點，每次敏感度測試皆去掉一組參數後輸出 100 次機器學習結果，表六為測試結果。從表六中發現移除部分參數後皆較無移除任何參數的結果差，其中差異最大的是移

除 3 也就是移除颱風路徑經緯度，這方面的結果也符合預期，因為颱風路徑經緯度是所有數據中相關性最高的；而差異最小的應該是移除 6 也就是移除本次預報與之前四次預報 ATE 與 CTE 的權重組合，原因可能是本次預報與前四次預報的 ATE 與 CTE 早已有放入機器學習，原先設計此函數的目的是希望代表著過去四次預報路徑收斂與發散的情況，但是相當遺憾的是並未造成顯著之影響。

移除參數後影響預測結果好壞排名，由影響大排名至影響小應該是 3、2、5、4、1、6，相關係數的排名也大致相同，儘管參數 6(過去四次預報路徑收斂或者發散)影響最小與降水相關性絕對值最高僅

表六 移除部分參數進行敏感度測試，移除 1 為移除表一第 1-2 項，移除 1 為移除表一第 3-4 項，移除 1 為移除表一第 5-6 項，移除 1 為移除表一第 7-8 項，移除 1 為移除表一第 9-10 項，移除 1 為移除表一第 11 項，所得針對所有颱風個案與所有預報各輸出 100 組後，預估之 SSS 值與實際 SSS 值的差異絕對值，在每 10 個百分位之結果。

移除參數	百分位位置								
	90	80	70	60	50	40	30	20	10
無移除	0.252	0.225	0.206	0.189	0.176	0.161	0.147	0.135	0.118
移除 1	0.259	0.231	0.211	0.193	0.178	0.164	0.153	0.142	0.122
移除 2	0.272	0.238	0.217	0.196	0.184	0.170	0.156	0.147	0.124
移除 3	0.275	0.244	0.223	0.206	0.192	0.173	0.160	0.144	0.127
移除 4	0.259	0.234	0.211	0.194	0.181	0.168	0.156	0.144	0.128
移除 5	0.260	0.231	0.214	0.197	0.182	0.167	0.154	0.138	0.124
移除 6	0.252	0.227	0.206	0.188	0.178	0.164	0.152	0.137	0.120

0.21，這樣似有若無的相關下，但仍然發揮著影響力。

六、結論與改進建議

不論是決定性預報或系集預報，每個預報都會有高低不同的參考價值，但往往此價值在事前無法預知，這也是數值天氣預報長期以來的一個難解問題。本研究中吾人藉助深度學習對此問題在事前提供預估指標，代表此預報可信度的高低。本研究使用 2.5-km 雲解析 CReSS 模式，對 10 個西行準侵臺颱風每 6 h 的八天差時系集預報結果，選取共 105 個預報參數，以機器學習模型針對預報颱風在影響期間（中心距離臺灣陸地在 300 km 以內）總累積降雨的相似性技術得分 (SSS) 進行預估，以在事前提供客觀指引，供預報或防災人員參考與使用。SSS 的值在 0-1 之間，越高表示預報降水的分布與實際發生越相似，越低則表示兩者越不相似。因此，預估 SSS 值越高表示機器學習認為此預報越可信，而預估 SSS 值越低則參考價值也越低。除了 SSS 外，模型也針對特定門檻的 TS 值與路徑誤差產生預報指引。再者，所有評估的預報，其初始時間的颱風中心均

尚未靠近臺灣到 300 km 以內，故不包含更新的預報。

十個颱風個案的評估結果顯示，在大多數的情況下，機器學習對逐次預報所預估的 SSS 值，的確可以適當掌握未來真實 SSS 的上升下降趨勢，亦即提早告訴吾人，哪些預報的可信度較高、哪些可信度較低，而在事前提供有效的客觀預報指引。特別在前置時間較長、不確定性也高的預報初期，在幾個颱風個案裡，此方法大多可以提出正確的參考建議。但是，因牽涉龐大計算成本，本初步研究僅納入十個颱風個案進行訓練與評估。由於機器學習可視為複雜的統計方法，當個案數偏少，某個颱風的行為與大部分輸入訓練的資料相左時，例如昌鴻颱風，則機器學習的效果便會較差，亦即無法充分掌握特例的情況。以本研究的訓練經驗而言，若颱風預報的 C300_1 位置介於 21°-25°N 之間，在使用上會較為穩定。在本研究的範圍內，當預估 SSS 的 50 百分位數達 0.6 以上時，其實際 SSS 有 71% 也大於 0.6，當預估 SSS 的 50 百分位數達 0.6 以下時，其實際 SSS 有 46% 也小於 0.6。整體上，機器學習在訓練後足可在事前分辨大部分降水預報的優劣，並且給予颱風移動方向上的修正指引，

以降低路徑誤差。若希望再對機器學習結果進行改進，則本研究建議可以考慮下列的幾個方向：

1. 提供更多的颱風個案成員進行訓練：本研究中，完成每個颱風個案每 6 h 的所有八天的預報結果，大概需要十五天的時間。對於高速運算的大量需求，導致必須在時間與颱風個案數之間有所取捨與抉擇。增加個案成員後，應該可以提高特殊個案的掌握程度，並得以修正一些已選個案特定行為所造成的學習偏差。
2. 選取更多與預報結果相關的參數加入進行訓練：本研究選取的預報參數大多為與颱風運動或降雨規模相關之參數，許多其它參數，例如：預報颱風之大小、中心氣壓值、近中心最大風速、暴風半徑等描述颱風強度與動力的參數，皆尚未包含。未來則可以考慮依序增加此類參數，也許可以更進一步改善結果。

致謝

作者感謝審查者對於本篇論文所提供的寶貴意見，使本文能更加完善。本研究由行政院科技部專題研究計畫 MOST 108-

2111-M-003-005-MY2、MOST 109-2625-M-003-001、及 MOST 110-2111-M-003-004 的經費支持下完成。

參考文獻

王時鼎, 1992 : 侵台颱風路徑、強度、結構及風雨整合研究。國科會防災科技研究報告，NSC 80-0414-P052-02B，285 頁。
中央氣象局，2021：颱風百問。
(<https://www.cwb.gov.tw/V8/C/K/Encyclopedia/typhoon/typhoon.pdf?v=20200330>)

Bjerknes, V., 1904: Das Problem der Wettervorhersage, betrachtet vom Standpunkte der Mechanik und der Physik. Met. Zeit., 21, 1-7. Translation by Y. Mintz: The problem of weather forecasting as a problem in mechanics and physics. Los Angeles, 1954. Reprinted in: The Life Cycles of Extratropical Cyclones. M. A. Shapiro and S. Grönås, Eds., Amer. Meteor. Soc., 1-4, 1999.

Chandler, R.-E., H.-S. Wheater, 2002: Analysis of rainfall variability using generalized linear models: A case study

- from the west of Ireland. *Water Resour. Res.*, 38(10), 1192, doi:10.1029/2001WR000906.
- Chang, C.-P., T.-C. Yeh, and J.-M. Chen, 1993: Effects of terrain on the surface structure of typhoons over Taiwan. *Mon. Wea. Rev.*, 121, 734–752.
- Chang, C.-P., Y.-T. Yang, and H.-C. Kuo, 2013: Large increasing trend of tropical cyclone rainfall in Taiwan and the roles of terrain. *J. Climate*, 26, 4138–4147.
- Charney, J., R. Fjörtoft, and J. von Neumann, 1950: Numerical integration of the barotropic vorticity equation. *Tellus*, 2(4), 237–254. doi:10.1111/j.2153-3490.1950.tb00336.x.
- Chien, F.-C., and H.-C. Kuo, 2011: On the extreme rainfall of Typhoon Morakot (2009). *J. Geophys. Res.*, 116, D05104, doi:10.1029/2010JD015092.
- Chollet, F., 2015: keras, GitHub, <https://github.com/fchollet/keras>.
- Cybenko, G., 1989: Approximation by superpositions of a sigmoidal function. *Math. Control Signals Syst.*, 2(4), 303–314.
- Ebert, E. E., U. Damrath, W. Wergen, and M. E. Baldwin, 2003: The WGNE assessment of short-term quantitative precipitation forecasts (QPFs) from operational numerical weather prediction models. *Bull. Amer. Meteor. Soc.*, 84, 481–492, doi:10.1175/BAMS-84-4-481.
- Epstein, E. S., 1969: Stochastic dynamic prediction. *Tellus*, 21, 739–759, doi:10.1111/j.2153-3490.1969.tb00483.x.
- Gagne, D. J., A. McGovern, and M. Xue, 2014: Machine learning enhancement of storm-scale ensemble probabilistic quantitative precipitation forecasts. *Wea. Forecasting*, 29, 1024–1043.
- Gagne, D., A. McGovern, S. Haupt, R. Sobash, J. Williams, and M. Xue, 2017: Storm-based probabilistic hail forecasting with machine learning applied to convection-allowing ensembles. *Wea. Forecasting*, 32, 1819–1840.
- Hong, J.-S., C.-T. Fong, L.-F. Hsiao, Y.-C. Yu, and C.-Y. Tzeng, 2015: Ensemble typhoon quantitative precipitation forecasts model in Taiwan. *Wea. Forecasting*, 30, 217–237.

- Hsu, L.-H., H.-C. Kuo, and R. G. Fovell, 2013: On the geographic asymmetry of typhoon translation speed across the mountainous island of Taiwan. *J. Atmos. Sci.*, 70, 1006–1022.
- Huang L., Xiang L.-Y., 2018: Method for meteorological early warning of precipitation-induced landslides based on deep neural network. *Neural Process Lett* 48:1243–1260.
<https://doi.org/10.1007/s11063-017-9778-0>
- Kingma, D. P., and J. Ba, 2015: Adam: A method for stochastic optimization. *Proceedings, the Third International Conference on Learning Representations*. San Diego, CA, USA, 13 pp,
<http://arxiv.org/abs/1412.6980>.
- Kohavi, R., 1995: A study of cross-validation and bootstrap for accuracy estimation and model selection. *Proceedings, the 14th International Joint Conference on Artificial Intelligence (IJCAI)*, Vol. 2, San Francisco, CA, USA, 1137 – 1143.
- Lee, C.-S., L.-R. Huang, and H.-S. Shen, 2006: A climatology model for forecasting typhoon rainfall in Taiwan. *Natural Hazards*, 37, 87–105.
- Lee, C.-S., L.-R. Huang, and D. Y.-C. Chen, 2013: The modification of the typhoon rainfall climatology model in Taiwan. *Natural Hazards Earth Syst. Sci.*, 13, 65–74.
- Leith, C., 1974: Theoretical skill of Monte Carlo forecasts. *Mon. Wea. Rev.*, 102, 409–418, doi:10.1175/1520-0493 (1974) 102<0409:TSOMCF>2.0.CO;2.
- Lorenz, E. N., 1963: Deterministic nonperiodic flow. *J. Atmos. Sci.*, 20, 130–141, doi:10.1175/1520-0469 (1963) 020<0130:DNF>2.0.CO;2.
- Molteni, F., R. Buizza, T. N. Palmer, and T. Petroliagis, 1996: The ECMWF Ensemble Prediction System: Methodology and validation. *Quart. J. Roy. Meteor. Soc.*, 122, 73–119, doi:10.1002/qj.49712252905.
- Nair, V., and G. E. Hinton, 2010: Rectified linear units improve restricted boltzmann machines. *Proceedings, the 27th International Conference on Machine*

- Learning (ICML-10), 21-24 Jun 2010, Haifa, Israel, 8 pp.
- Richardson, L. F., 1922: Weather Prediction by Numerical Process. Cambridge University Press, pp. xii + 236.
- Roberts, N. M., and H. W. Lean, 2008: Scale-selective verification of rainfall accumulations from high-resolution forecasts of convective events. *Mon. Wea. Rev.*, 136(1), 78–97.
- Schaefer, J. T., 1990: The critical success index as an indicator of warning skill. *Wea. Forecasting*, 5, 570–575, doi:10.1175/1520-0434 (1990) 005<0570:TCSIAA> 2.0.CO;2.
- Su, S.-H., H.-C. Kuo, L.-H. Hsu, and Y.-T. Yang, 2012: Temporal and spatial characteristics of typhoon extreme rainfall in Taiwan. *J. Meteor. Soc. Japan*, 90, 721–736.
- Tao Y., X. Gao, A. Ihler, S. Sorooshian, K. Hsu, 2017: Precipitation identification with bispectral satellite information using deep learning approaches *J. Hydrometeorol.*, 18 (5) , pp. 1271-1283
- Toth, Z., and E. Kalnay, 1993: Ensemble forecasting at NMC: The generation of perturbations. *Bull. Amer. Meteor. Soc.*, 74, 2317–2330, doi:10.1175/ 1520-0477 (1993) 074<2317:EFANTG>2.0.CO;2.
- Tsuboki, K., and A. Sakakibara, 2002: Large-scale parallel computing of cloud resolving storm simulator. *High Performance Computing*, H. P. Zima et al. Eds., Springer, 243–259.
- Tsuboki, K., and A. Sakakibara, 2007: Numerical Prediction of High-Impact Weather Systems: The Textbook for the Seventeenth IHP Training Course in 2007. Hydropheric Atmospheric Research Center, Nagoya University, and UNESCO, 273 pp.
- Wang, C.-C., 2014: On the calculation and correction of equitable threat score for model quantitative precipitation forecasts for small verification areas: The example of Taiwan. *Wea. Forecasting*, 29, 788–798.
- Wang, C.-C., 2015: The more rain, the better the model performs—The dependency of quantitative precipitation forecast skill on

- rainfall amount for typhoons in Taiwan. *Mon. Wea. Rev.*, 143(5), 1723–1748.
- Wang, C.-C., H.-C. Kuo, Y.-H. Chen, H.-L. Huang, C.-H. Chung, and K. Tsuboki, 2012: Effects of asymmetric latent heating on typhoon movement crossing Taiwan: The case of Morakot (2009) with extreme rainfall. *J. Atmos. Sci.*, 69, 3172–3196.
- Wang, C.-C., S.-Y. Huang, S.-H. Chen, C.-S. Chang, and K. Tsuboki, 2016: Cloud-resolving typhoon rainfall ensemble forecasts for Taiwan with large domain and extended range through time-lagged approach. *Wea. Forecasting*, 31(1), 151–172.
- Wang, C.-C., Y.-H. Chen, M.-C. Li, H.-C. Kuo, and K. Tsuboki, 2021: On the separation of upper and low-level centres of tropical storm Kong-Rey (2013) near Taiwan in association with asymmetric latent heating. *Quart. J. Roy. Meteor. Soc.*, 147, 1135–1149, <https://doi.org/10.1002/qj.3963>.
- Whan, K., and M. Schmeits, 2018: Comparing area probability forecasts of (extreme) local precipitation using parametric and machine learning statistical postprocessing methods. *Mon. Wea. Rev.*, 146(11), 3651–3673.
- Wilks, D. S., 1995: Statistical Methods in the Atmospheric Sciences. Academic Press, 467 pp.
- Zhang, T.; Lin, W.; Lin, Y.; Zhang, M.; Yu, H.; Cao, K.; Xue, W., 2019: Prediction of tropical cyclone genesis from mesoscale convective systems using machine learning. *Wea. Forecasting*, 34, 1035–1049.

Developing Objective Guidance for the Quality of Quantitative Precipitation Forecasts of Westward-Moving Typhoons Affecting Taiwan through Machine Learning

Shin-Hau Chen and Chung-Chieh Wang*

Department of Earth Sciences, National Taiwan Normal University, Taipei, Taiwan

(manuscript received 11 June 2021 ; in final form 17 June 2022)

Abstract

Typhoon rainfall is both an important water resource and potential disaster in Taiwan, so its forecast quality and improvement are important. An issue of all numerical weather predictions, regardless deterministic or ensemble, is that whether its scenario will occur or its exact probability, is not known in advance. Nowadays, this issue may be solved through artificial intelligence. In this study, therefore, we have developed and tested a model through machine learning that provides objective guidance to indicate the credibility of each quantitative precipitation forecasts (QPFs) for typhoons once it is made and thus help improve forecasts. Specifically, time-lagged forecasts (out to 8 days) every 6 h for 10 westward-moving typhoons affecting Taiwan by the 2.5-km Cloud-Resolving Storm Simulator (CReSS) are used. A total of 105 parameters are selected from each forecast and data from nine typhoons are fed into the learning model to, after training, predict the similarity skill score (SSS) of total accumulated rainfall during the period when the storm moves within 300 km from Taiwan in each of the forecasts for the tenth typhoon. As a measure to the overall quality of the QPFs, the predicted SSS thus serves as guidance for forecast credibility. At the initial time of forecasts included, the typhoon center is still at least 300 km away, so many are at ranges beyond the short range (≥ 72 h).

Results from these 10 cases indicate that the machine learning model can capture the tendency of the actual SSS (computed using observed rainfall) for most cases, thereby

informing the forecasters which QPFs are more trustworthy and which other ones are less so before the event. Such guidance is especially valuable at longer lead time, when the forecast uncertainty is relatively high, and thus our results are highly encouraging. Nevertheless, as machine learning can be viewed as a complicated statistical technique, when certain typhoon behaves differently from those that serve as the training data, the outcome would be less useful. Some possible directions for further improvement are also offered and discussed.

Keywords: quantitative precipitation forecast (QPF), typhoon, cloud-resolving model, machine learning, Taiwan. doi:10.53106/025400022022075002001