

國立臺灣師範大學理學院地球科學系

博士論文

Department of Earth Sciences, College of Science

National Taiwan Normal University

Doctoral Dissertation

臺灣雲解析差時系集颱風定量降水預報應用研究

An Study of Time-Lagged Cloud-Resolving Typhoon

Ensemble Quantitative Precipitation Forecast in Taiwan and

its applications

The logo of National Taiwan Normal University is a circular emblem with a stylized design. In the center, the Chinese characters "師大" (Shi Da) are visible. Below the emblem, the name "陳鑫浩" (Chen Xin-hao) is written in Chinese.

陳鑫浩

Shin-Hau Chen

指導教授：王重傑 博士

Advisor : Chung-Chieh Wang, Ph.D.

中華民國 112 年 7 月

July 2023

## 致謝

本研究感謝我的指導教授王重傑老師的大力支持與指導，他十分有耐心，並且給了我許多的機會與建議，若無遇到王老師，我應該是不可能完成本篇研究。也感謝口試委員們對我論文的建議，讓整篇論文更為完整。也感謝智昇學長、心怡學姊、怡文學姊、碧瑜、茂正、傑仁、沛滕等人提供研究上的小討論與解決各式電腦問題，另外實驗室的各位除了在互相幫忙下，你們應該幫我扛下了很多事情讓我最後一段時間能心無旁騖地寫論文。

或許這就是做學問吧！做研究就感覺像是在水泥中游泳一般，水泥中划水十分吃力，若不進行划水便會停滯，這時死不了但也前進不了，重要的是認清方向，一手一手的前進，若累了記得停下來確認一下方向，不要迷航了，另外很重要的是記得划水。



## 摘要

臺灣的颱風降雨雖為主要的水源之一，但也常因此造成災害。數值天氣預報開發以來，時常面臨著不確定性造成的困難，眾多研究者嘗試使用各式方法獲取防災資訊，本研究面對臺灣颱風防災的需求，嘗試在現有資源限制下，建構針對臺灣颱風降水於防災的建議系統。

具體而言，本研究使用雲解析風暴模式，建構上採用了 2.5km 水平格點間距，每六小時進行八天的預報，在本研究的十個目標颱風內，經過評估後皆能在各颱風風雨影響臺灣前至少 52 小時前，也就是大約兩天以前，找出颱風影響期間總累積降雨量的相似技術得分(Similarity Skill Score，簡稱 SSS) 大於 0.6 的高解析度的降水情境，顯示此方法實際應用上可以在有反應時間的前提下，提供有效的降水情境。

防災事前可以針對最糟糕的降水情境做防範，但為了更有效的找出較有參考價值的預報，本研究針對十個西行侵臺颱風選出 105 個預報參數，使用機器學習嘗試建構能夠預估降水指引(SSS 為其中之一)與路徑指引的模型並進行評估，評估後大多數機器學習預估的 SSS 皆能適度掌握不同初始時間預報中的實際降水 SSS 好壞。機器學習預估的結果約在實際颱風影響臺灣 26 小時前可以產出，當預估的 SSS 中位數達 0.6 以上時，實際的 SSS 也有 71%超過 0.6，顯示可以在中心登陸兩天前預先指出那些預報的可信度低，那些的可信度高。

本研究進行機器學習訓練時進入模型的颱風數量上不多，可當作一初步之研究，文章中亦討論了許多颱風預報相關性分析，並提出了幾個可能的改進方向。總體來說，高解析差時系集預報輔以機器學習可在臺灣西行颱風的防災預警上，提供有效的降水情境，並指出較具可信度的預報。

關鍵字：數值天氣預報、颱風、防災、機器學習

# 目次

|                            |     |
|----------------------------|-----|
| 致謝.....                    | i   |
| 摘要.....                    | ii  |
| 目次.....                    | iii |
| 表目次.....                   | v   |
| 圖目次.....                   | vii |
| 第一章 前言.....                | 1   |
| 第二章 資料來源及研究方法.....         | 6   |
| 2.1 資料來源.....              | 6   |
| 2.2 模式介紹.....              | 7   |
| 2.3 差時系集預報系統與模式設定.....     | 9   |
| 2.4 颱風客觀定位.....            | 10  |
| 2.5 颱風路徑誤差.....            | 11  |
| 2.6 降水技術得分.....            | 12  |
| 第三章 差時系集預報結果.....          | 14  |
| 3.1 尼伯特颱風.....             | 15  |
| 3.2 蘇迪勒颱風.....             | 16  |
| 3.3 杜鵑颱風.....              | 17  |
| 3.4 蘇力颱風.....              | 18  |
| 3.5 麥德姆颱風.....             | 19  |
| 3.6 莫蘭蒂颱風.....             | 20  |
| 3.7 蘇拉颱風.....              | 21  |
| 3.8 昌鴻颱風.....              | 22  |
| 3.9 天兔颱風.....              | 23  |
| 3.10 菲特颱風.....             | 24  |
| 第四章 機器學習模型介紹、變數相關性與測試..... | 25  |
| 4.1 機器學習之預報參數.....         | 26  |
| 4.2 機器學習之客觀指引.....         | 28  |
| 4.3 預報參數與降水客觀指引的相關性.....   | 29  |
| 4.4 預報參數與路徑誤差指引的相關性討論..... | 32  |
| 4.5 機器學習模型介紹、建立、測試與調整..... | 34  |
| 第五章 機器學習初步結果與分析.....       | 37  |
| 5.1 機器學習生成颱風降水預報指引之討論..... | 38  |
| 5.2 機器學習生成颱風路徑預報指引之討論..... | 43  |
| 5.3 機器學習模型敏感度測試.....       | 44  |
| 第六章 綜合討論.....              | 46  |
| 第七章 結論與未來工作.....           | 48  |

|           |    |
|-----------|----|
| 參考文獻..... | 49 |
|-----------|----|



## 表目次

|     |                                                                                                                                                                              |    |
|-----|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 表一  | 本研究中十個颱風有進行預報的所有初始時間，當中有進入機器學習的有 145 個初始時間在表中為黃色底色，各颱風最下方有統計各颱風進入機器學習的數量。.....                                                                                               | 56 |
| 表二  | 本研究所選取輸入機器學習的 105 個預報參數，個別代號、說明與選取理由。.....                                                                                                                                   | 57 |
| 表三  | 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二中第 1-6 項所列者。..... | 59 |
| 表四  | 同表三，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二中第 7-8 項所列的前一次與前兩次預報（前 6 與前 12 h）者。.....                                                                      | 60 |
| 表五  | 同表三，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二中第 7-8 項所列的前三次與前四次預報（前 18 與前 24 h）者。.....                                                                     | 61 |
| 表六  | 同表三，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二中第 9-11 項所列者。.....                                                                                           | 62 |
| 表七  | 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。.....                                                                                  | 63 |
| 表八  | 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 TS 值與實際 TS 值的差異絕對值，在每 10 個百分位之結果。.....                                                                                    | 64 |
| 表九  | 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 ATE 與 CTE 值與實際 ATE 與 CTE 值的差異絕對值，單位為 100km，在每 10 個百分位之結果。.....                                                            | 65 |
| 表十  | 對所有颱風個案與所有預報各輸出 100 組後，預估之 SSS、TS100、TS200 與實際值之平均值、標準差、中位數。.....                                                                                                            | 66 |
| 表十一 | 機器學習針對各颱風個案所產生一百組模型後，實際 SSS 與 TS 值與模型預估之 SSS 與 TS100 值絕對誤差的第一四分位(25%)、中位數(50%)、與第三四分位值(75%)。.....                                                                            | 67 |
| 表十二 | 經機器學習修正前(原始)後(修正)，不同預報時間長度、全部預報與最新一次預報的平均 CTE、ATE、及 TE 絕對值變化 (km)。.....                                                                                                      | 68 |
| 表十三 | 移除部分參數進行敏感度測試，移除 1 為移除表二第 1-2 項，移除 2                                                                                                                                         |    |

為移除表二第 3-4 項，移除 3 為移除表二第 5-6 項，移除 4 為移除表二第 7-8 項，移除 5 為移除表二第 9-10 項，移除 6 為移除表二第 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。..... 69



## 圖目次

- 圖 1 圖中顯示了研究時間內 CReSS 24 小時定量降水預報於不同降雨閾值的平均 TS 值，橫軸為降水閾值，縱軸為 TS 值，分別對 (a) 第 1 天 (0-24 小時)，(b) 第 2 天 (24-48 小時)，和 (c) 第 3 天 (48-72 小時)，自總降水高排至低分別有莫拉克(2009)颱風、降水最多前五名的颱風與 A-D 組颱風。(W15)..... 70
- 圖 2 系集預報系統預測以 3 小時為間隔的颱風中心位置分佈。每個黑點都代表了一該預測颱風中心位置與所帶來的 3 小時累積降水；右上角展示了一個範例。紅線和黑圈分別代表給定的颱風軌跡，以及每個颱風位置為中心半徑為 30 公里的範圍。(Hong et al., 2015)..... 71
- 圖 3 臺灣在颱風防災於數值天氣預報中所需的五個項目：降雨量、颱風路徑、颱風強度、襲擊機率和準備時間，用於描述提供了四種等級(非常好、好、平均和差)。(W16)..... 72
- 圖 4 CReSS 模式雲微物理現象的冷雲過程。(Tsuboki and Sakakibara, 2007)..... 73
- 圖 5 展示了(a)多成員系集預測策略(20 個成員，每 6 小時進行一次，總共預測 3 天)和(b)差時系集預測策略(每 6 小時進行一次，總共預測 8 天)在相同計算資源條件下的比較，模型的定量降水預報的目標日期以黃色區域並搭配橙色邊線來表示。因為不用分散資源的關係，差時系集策略可以在保持相同的預測範圍下，同時達成更高的解析度與更大的精確預測範圍。(W16)..... 74
- 圖 6 颱風路徑誤差示意圖。圖中  $x_0$  與  $y_0$  代表觀測路徑前一時間點的經緯度， $x_1$  與  $y_1$  代表觀測路徑於目標時間之經緯度，而  $x$  與  $y$  則為預報路徑在目標時間之經緯度。路徑誤差 (track error)、移速誤差 (along-track error)、及移向誤差 (cross-track error) 皆如圖所示。..... 75
- 圖 7 不同初始時間預報尼伯特颱風的 (a) 差時系集預報路徑，(b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上各符號為逐日 0000 UTC 之颱風中心位置，X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 7 月 4 日至 7 月 9 日，觀測路徑為 JTWC 並標示為黑色。尼伯特颱風觀測定義的影響期間為 7 月 7 日 0500 UTC 至 7 月 9 日 1300 UTC，長度共 56 小時。預報降水為不同初始時間預報在各自影響期間之降水(色階與觀測相同)，其初始時間、實際 SSS、實際 TS100、及降水累積時段皆示於各圖下方。..... 76
- 圖 8 同圖 7 但為蘇迪勒颱風之 (a) 差時系集預報路徑，(b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上，X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 8 月 5 日到 8 月 10 日。本個案由觀測定義之影響期間為 8 月 7 日 1100 UTC 至 8 月 8 日 1900 UTC，長度共 32

小時。預報降水為預報在各自影響期間之降水(色階與觀測相同)。..... 78

圖 9 同圖 7 但為杜鵑颱風之(a) 差時系集預報路徑, (b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上, X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 9 月 25 日到 9 月 30 日。本個案由觀測定義之影響期間為 9 月 27 日 2200 UTC 至 9 月 29 日 0600 UTC, 共 32 小時。

..... 80

圖 10 同圖 7 但為蘇力颱風之(a) 差時系集預報路徑, (b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上, X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 7 月 9 日到 7 月 14 日。本個案由觀測定義之影響期間為 7 月 12 日 0900 UTC 至 7 月 13 日 1300 UTC, 共 28 小時。

..... 82

圖 11 同圖 7 但為麥德姆颱風之(a) 差時系集預報路徑, (b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上, X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 7 月 20 日到 7 月 25 日。本個案由觀測定義之影響期間為 7 月 22 日 0300 UTC 至 7 月 23 日 1500 UTC, 共 36 小時。..... 84

圖 12 同圖 7 但為莫蘭蒂颱風之(a) 差時系集預報路徑, (b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上, X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 9 月 10 日到 9 月 15 日。本個案由觀測定義之影響期間為 9 月 13 日 1200 UTC 至 9 月 15 日 0000 UTC, 共 36 小時。..... 86

圖 13 同圖 7 但為蘇拉颱風之(a) 差時系集預報路徑, (b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上, X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 7 月 29 日到 8 月 3 日。本個案由觀測定義之影響期間為 7 月 31 日 1600 UTC 至 8 月 3 日 0200 UTC, 共 58 小時。

..... 88

圖 14 同圖 7 但為昌鴻颱風之(a) 差時系集預報路徑, (b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上, X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 7 月 8 日到 7 月 13 日。本個案由觀測定義之影響期間為 7 月 10 日 0500 UTC 至 7 月 10 日 2300 UTC, 共 18 小時。

..... 90

圖 15 同圖 7 但為天兔颱風之(a) 差時系集預報路徑, (b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上, X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 9 月 17 日到 9 月 22 日。本個案由觀測定義之影響期間為 9 月 20 日 1600 UTC 至 9 月 22 日 0400 UTC, 共 36 小時。

..... 92

圖 16 同圖 7 但為菲特颱風之(a) 差時系集預報路徑, (b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上, X 形、六芒星、五邊形、正圓

|                                                                                                                   |     |
|-------------------------------------------------------------------------------------------------------------------|-----|
| 形、正方形與菱形依序分別表示 10 月 2 日到 10 月 7 日。本個案由觀測定義之影響期間為 10 月 5 日 2000 UTC 至 10 月 6 日 2300 UTC，長度共 27 小時。.....            | 94  |
| 圖 17 模式預報實際 SSS (紅) 與機器學習模型預估 SSS (藍) 的分佈百分比。.....                                                                | 96  |
| 圖 18 針對尼伯特颱風(a)與蘇迪勒颱風(b)，於不同初始時間的預報 (橫軸，日期與 UTC 時) 在其颱風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)。.....   | 97  |
| 圖 19 針對杜鵑颱風(a)與蘇力颱風(b)，於不同初始時間的預報 (橫軸，日期與 UTC 時) 在其颱風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)。.....     | 98  |
| 圖 20 針對麥德姆颱風(a)與莫蘭蒂颱風(b)，於不同初始時間的預報 (橫軸，日期與 UTC 時) 在其颱風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)。.....   | 99  |
| 圖 21 針對蘇拉颱風(a)與昌鴻颱風(b)，於不同初始時間的預報 (橫軸，日期與 UTC 時) 在其颱風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)。.....     | 100 |
| 圖 22 針對天兔颱風(a)與菲特颱風(b)，於不同初始時間的預報 (橫軸，日期與 UTC 時) 在其颱風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)。.....     | 101 |
| 圖 23 針對尼伯特颱風(a)與蘇迪勒颱風(b)，於不同初始時間的預報 (橫軸，日期與 UTC 時) 在其颱風影響期間降水的實際 TS100 (紅) 與機器學習預估的第 90、50、及 10 百分位值 (深至淺藍)。..... | 102 |
| 圖 24 針對杜鵑颱風(a)與蘇力颱風(b)，於不同初始時間的預報 (橫軸，日期與 UTC 時) 在其颱風影響期間降水的實際 TS100 (紅) 與機器學習預估的第 90、50、及 10 百分位值 (深至淺藍)。.....   | 103 |
| 圖 25 針對麥德姆颱風(a)與莫蘭蒂颱風(b)，於不同初始時間的預報 (橫軸，日期與 UTC 時) 在其颱風影響期間降水的實際 TS100 (紅) 與機器學習預估的第 90、50、及 10 百分位值 (深至淺藍)。..... | 104 |
| 圖 26 針對蘇拉颱風(a)與昌鴻颱風(b)，於不同初始時間的預報 (橫軸，日期與 UTC 時) 在其颱風影響期間降水的實際 TS100 (紅) 與機器學習預估的第 90、50、及 10 百分位值 (深至淺藍)。.....   | 105 |
| 圖 27 針對菲特颱風(a)與天兔颱風(b)，於不同初始時間的預報 (橫軸，日期與 UTC 時) 在其颱風影響期間降水的實際 TS100 (紅) 與機器學習預估的第 90、50、及 10 百分位值 (深至淺藍)。.....   | 106 |

## 第一章 前言

過去數十年間電腦技術不斷進步，數值天氣預報領域使用越來越高的解析度，產生強降雨的對流雲在大多數區域模式中不再被參數化，導致對流雲必須由模式解析與計算 (Done et al., 2004; Kong et al., 2006)。因此產生了一個需要被定量的問題：「對於深對流雲的基本結構，需要多細的網格解析度？」。臺灣一些豪雨事件的模擬顯示，水平網格間距 ( $\Delta x$ ) 需要縮小到小於 3-4km 才較能真實模擬颱風中雨帶與對流胞結構並正確捕捉其演變和強度 (Gentry and Lackmann, 2010; Yang et al., 2011; Wang et al., 2012, 2013, 2021, 2022; 之後將簡稱為 W22)。

Wang (2015; 之後將簡稱為 W15) 使用雲解析風暴模式 (Cloud-Resolving Storm Simulator; 簡稱 CReSS 模式, Tsuboki and Sakakibara, 2002, 2007)，在 2.5km 的解析度下對 2010-2012 年間 15 個颱風的 24 小時降水預報進行了評估 (見圖 1)。在各颱風降雨量最大最易致災的期間，由 CReSS 模式產生的 0-24 小時降水預報在 50、130、200 和 350mm 降水閾值下評估 TS 得分 (TS; 將在 2.6 小節中詳細介紹)，分別為 0.67、0.58、0.51 和 0.32; 24-48 小時分別為 0.73、0.57、0.42 和 0.17; 而 48-72 小時分別為 0.57、0.37、0.33 和 0.22，對於莫拉克颱風 TS 得分甚至更高，其中第 2 天降水預報的分數在 200、350、500 和 1000mm 的極高門檻降水閾值下分別達到了 0.87、0.69、0.50 和 0.38。研究中展示了降雨量越多，預兆得分 (threat score, 之後簡稱 TS) 越高的特性，打破了過去針對模型對極端降雨的預測能力不佳的誤解。

Wang et al. (2021) 並進一步將研究的範圍擴展至 2010-2015 年間共 29 個颱風，並集中於討論高門檻值的預報，由 CReSS 生成的 0-24 小時降水預報在 200mm, 350mm 與 500mm 降水閾值下的平均 TS 得分為 0.34、0.28 和 0.18，24-48 小時為 0.31、0.25 和 0.16，48-72 小時為 0.20、0.15 和 0.08。並指出 2.5km CReSS 模式預報在臺灣比起 5km 模式能顯著的改進颱風定量降水預報 (quantitative precipitation forecast) 結果。綜合以上，針對臺灣颱風的定量降水預報需要至少 3km 以內水平解析度、且越多雨的颱風，技術得分越高。

臺灣位於西太平洋颱風路徑主要通過區域，平均上每年會受到約 3~4 個颱風侵襲(王, 1992; 中央氣象局, 2021)，另外颱風帶來的豪雨也是災害的首要因素。地勢陡峭的臺灣，地形高低差在水平距離 50 km 內便高達 3000 m，因此當颱風環流經過臺灣時，便受地形舉升產生相位鎖定現象 (Chang et al., 1993, 2013; Su et al., 2012; Wang et al., 2012; Hsu et al., 2013)。因此各個颱風在穿過臺灣期間所累積的降雨量，與對臺灣的影響時間長短成正比，同時與颱風的平均移動速度成反比(Chien and Kuo 2011; Wang et al., 2012; Hsu et al. 2013)。

由於臺灣的地形的特殊性，颱風相對於臺灣的相對位置帶來的降水量和分布特徵與高度相關。Lee et al. (2006, 2013) 基於 1989–2001 年降水觀測資料與歷史颱風路徑，發展颱風降水氣候模式，此模式可以根據輸入的參考路徑，在一分鐘內預估參考路徑帶來的降雨分佈。此預報模式不太佔用計算資源且可以快速地提供降水情境是其價值所在，但是遭遇共伴、遠距降水或極度不對稱的非典型颱風其所提供的降水情境與實際的相似性會降低。

由於有非典型颱風的存在，且個別颱風皆有其獨特性，Hong et al. (2015) 使用針對個別颱風的系集模式颱風定量降水預報(Ensemble Typhoon Quantitative Precipitation Forecast)，輸入參考的颱風路徑（在該研究中採用觀測路徑）來協助合成降水預報。圖 2 以凡娜比颱風(2010)為例子展示，此方法可以保留不同颱風的降水特性，降水預報成果相當優異，缺點是系集預報的颱風路徑散佈有限，當實際路徑超出其颱風預報散佈時便無法提供較好的預估。綜合以上可知，侵臺颱風受地形影響，相近的路徑將有接近的降水分布，但是各颱風又具有獨特性，若能針對每個颱風提供散佈大但是又密集的路徑預報，會有較好的結果。

Wang et al. (2016; 之後簡稱 W16) 自 2012 年以來為了在不犧牲模式解析度、預報範圍與預報時間，使用 2.5km 解析度的 CReSS 模式進行長達八天的預報。針對 2012–2013 年期間對六個侵臺颱風進行差時系集預報評估，發現分別在 3、4、6、6、7 及 8 天前就可以產出品質不錯的定量降水預報結果。圖 3 展示了 2.5km 差時系集系統與

水平解析度 5km 的多模式傳統系集模型相比，對颱風事件的預測其中的五個重要參數：降雨，路徑，強度，命中率和預警時間 2.5km 差時系集都較 5km 多模式系集更好。

延續 W16 的研究，錢(2018)針對 2012-2016 的 15 個颱風進行差時系集預報評估，並將未能在 72 小時前產出較好預報的颱風詳細檢視，發現路徑偏差的主因為副熱帶高壓的不確定性、全球預報的誤差與雲解析預報路徑右偏。而能夠產出較好預報的也可以分做與西南氣流有交互作用的颱風與沒有交互作用的颱風，有交互作用的颱風降水主因為西南氣流，即便颱風路徑偏差大還是能有不錯的準確率。蔡(2021)針對巨爵、茉莉(2015)與山竹颱風(2018) 進行菲律賓地區的差時系集預報評估，顯示差時系集預報應用並不僅限於臺灣颱風降水預報。

無論採用系統預測還是單一決定性預測，模型對未來事件的預測無疑都會面臨誤差與不確定性的問題 (Lorenz, 1963)。這其中的差異點只在於誤差的程度和不確定性的高低 (Epstein, 1969; Leith, 1974)。因此，自從數值天氣預報開始發展 (Bjerknes, 1904; Richardson, 1922; Charney et al., 1950) 以來，如何獲取不確定性信息一直是一項重要的課題 (例如：Toth and Kalnay, 1993; Molteni et al., 1996)。

延續 W16 的研究，Wang et al. (2023; 之後簡稱 W23) 針對蘇拉(2012)、蘇力(2013) 與蘇迪勒(2015)三個颱風也進行了差時系集預報評估，差時系集預報系統分別能在 162 小時、79 小時與 164 小時前產出最糟的情境亦是實際發生的情境以供災防做準備，並分別在登陸前 36 小時、55 小時、80 小時前路徑開始收斂，給予預報更高的可信度。綜合以上，解析度 2.5km 的 CReSS 模式差時系集系統可以有機會在颱風侵臺一周前捕捉到高品質解析度的降水分布，於極初期提供完整涵蓋整個事件的降水情境。

自引入系集預報觀念以來，研發能有效使用和理解模式優劣的產品，便成為了一項重要的課題。自 2003 年開始，中央氣象局在發布颱風預報的同時，也會一同提供颱風路徑潛在預報產品，這些產品提供了 70% 機率的路徑潛勢預報 (顧, 2006)。到了 2007 年，氣象局更進一步提供了颱風路徑侵襲機率產品，該產品採用了二維常態分布函數。颱風路徑侵襲機率可以提供給颱風防救災決策者參考，並採取適當的防救災準備 (顧,

2006; 蔡, 2007)。除此之外, 蔡等 (2011) 探討了蒙地卡羅法在颱風侵襲機率估計中的應用, 顯示蒙地卡羅法可以考慮到各種影響因素。此外, 陳等 (2018) 嘗試使用貝式模型平均法來建立路徑機率預測指引, 得益於貝式模型平均法可以根據各種模式預報的能力給予不同的權重, 這種方法使得 24 小時和 48 小時的路徑預報誤差能分別降低至 65km 和 110km。

近年來機器學習於氣象防災相關領域的應用受到了廣大的重視並快速發展。Gagne et al. (2014) 的研究中, 採用了兩種機器學習方法: 隨機森林 (Random Forests) 和邏輯式迴歸 (Logistic Regression)。將 26 個預報成員的結果導入這兩種方法中, 對機率定量降水預報進行校準。該研究的結果顯示, 無論採用哪種機器學習方法, 其預報結果都優於單一系集預報的結果。Gagne et al. (2017) 將機器學習的應用延伸至冰雹預報。放入了 12 個不同的雲微物理與邊界層參數化的成員預報, 並配合雷達數據, 以估算風暴中冰雹的生成機率以及冰雹的分佈參數。結果顯示, 相對於傳統方法, 機器學習更有效地預測嚴重冰雹事件。Zhang et al. (2019) 利用多種機器學習方法來探討中尺度對流系統是否可能轉變為熱帶氣旋。研究結果突顯出自適應增強 (AdaBoost) 方法在預測熱帶氣旋生成的準確度上達到了 97.2%, 這在延時為 6 小時的情況下顯得特別出色, 相比之下, 傳統的預測方法在這方面的準確度尚不足 80%, 顯示出此方法的優越性。此外, 機器學習分類器亦指出, 低層旋渦和生成潛力指數是颱風生成的最重要預測因子, 這與先前的發現是一致的。莊等 (2022) 亦嘗試以類神經網路建立以中央氣象局前三報的 24 小時系集成員預報與真實降水資料對第四報進行校正, 並討論隱藏層節點數量、層數以及資料權重對颱風校正的影響, 發現非均等權重法使用於淺層類神經網路能對原始預報校正結果較好。但是由於及時作業時無法獲得未來的實際降水資料, 因此此方法無法進行即時的校正。

Bi et al. (2023) 使用 1979 至 2017 共 39 年的全球再分析資料進行訓練, 使機器學習模型 (文章內模型稱之為盤古) 可以預報 1、3、6 與 24 小時後的全球氣象, 計算速度為傳統積分模式的 10000 倍, 並且預測準確度優於歐洲中期天氣預報中心的結果,

針對極端天氣的掌握也相當優良。但是有幾個限制存在，研究中使用的是再分析資料，並無法即時取得，再來並沒有模型中並沒有討論降水，以及為求平滑的預測結果會增加極端天氣的風險，但是仍為目前數值天氣預報帶來衝擊。

Zhang et al. (2023) 使用了來自中國與美國的雷達數據建構了 NowcastNet 一針對極端降雨的即鄰近預報機器學習模型，並邀請了中國氣象局從業人員對不同模型的產出進行評估，結果表示 NowcastNet 在四個成員的比較經評估後，在 71% 的案例排名第一。模型提供了有技巧的即時預報，展現了物理上的合理性和多尺度特徵，而其他模型則難以勝任。

綜合以上前人研究，2.5km 的 CReSS 模式差時系集系統可以於極初期提供完整涵蓋整個事件的降水情境，極度適合作為臺灣颱風防災上的資料來源，但是距離實際應用面上仍需進一步開發。在本文的第二章，將詳細介紹本研究所使用的數據與分析方法，其中包含差時系集預報、資料來源、模式介紹、颱風客觀定位、颱風路徑誤差、降水技術得分等。第三章中將針對所有颱風個案所有定量降水預報結果進行更細部的討論。

當有了數個完整涵蓋整個事件的降水情境，開發能事前得知降水品質的系統勢在必行。作為一項人工智慧技術機器學習已經被廣泛應用於各種最佳化問題上，並展現出巨大的潛力。在本文第四章開始介紹本研究中所使用的機器學習預報參數與客觀指引，討論其中相關性，進而進行模型的測試與調整，第五章將討論所有預報指引之結果，另外還進行敏感度測試，最後在第六章將彙總本研究的結論並闡述未來的研究方向。

## 第二章 資料來源及研究方法

### 2.1 資料來源

研究中使用美國國家環境預測中心(National Centers for Environmental Prediction; NCEP)之全球預報系統(Global Forecast System; GFS)經緯度網格預報資料當作模式的初始及側邊界條件,其空間解析度為 $1^{\circ}\times 1^{\circ}$ ,時間解析度為每六小時一筆,垂直層數共 26 層(地面、1000、975、950、925、900、850、800、750、700、650、600、550、500、450、400、350、300、250、200、150、100、70、50、30 和 10hPa),選用的氣象參數有緯向風場、經向風場、相對溼度、重力位高度、氣溫和氣壓。

降水資料部分,使用中央氣象局觀測之降水資料,於大氣水文研究資料庫下載資料用以進行繪圖計算與比較,時間解析度為一小時。

熱帶氣旋資料使用聯合颱風警報中心(Joint Typhoon Warning Center, JTWC)產製的熱帶氣旋最佳路徑,有颱風中心位置與強度等相關資料,時間解析度為六小時一筆,部分颱風接近或登陸地點之臺灣觀測資料來自中央氣象局颱風警報單。

## 2.2 模式介紹

本研究使用日本名古屋大學(Nagoya University)太空地球環境研究所[Institute for Space-Earth Environmental Research, ISEE, 該研究所過去名為地球水循環研究中心(Hydrosphere Atmosphere Research Center, HyARC)]所研發的 CReSS 模式(Tsuboki and Sakakibara, 2002, 2007)。

本研究所使用的 CReSS 模式(2.3 版)採用非靜力，完全可壓縮之方程式系統。模式之水平座標採用卡氏座標(Cartesian coordinate)，垂直座標則為以高度為基礎之追隨地勢座標(terrain-following curvilinear coordinate;  $\zeta$ )，定義為：

$$\zeta(x, y, z) = \frac{z_t[z - z_s(x, y)]}{z_t - z_s(x, y)} \quad (1)$$

其中， $z_s(x, y)$  為地表高度， $z_t$  為模式頂之高度。

模式中所使用方程式包括：靜力方程式、狀態方程式、運動方程式、氣壓方程式、位溫方程式、水氣與凝結混和比方程式等。

各方程式如下：

(1) 靜力方程式：

$$\frac{\partial \bar{p}}{\partial z} = -\bar{\rho}g \quad (2)$$

其中  $p = \bar{p} + p'$ ， $\rho = \bar{\rho} + \rho'$

(2) 狀態方程式：

$$\rho = \frac{p}{R_d T} \left(1 - \frac{q_v}{\varepsilon + q_v}\right) (1 + q_v + \sum q_x) \quad (3)$$

其中  $g$  為重力加速度， $T$  為溫度， $\varepsilon$  為水氣與乾空氣之分子量比(0.622)， $R_d$  乾空氣之氣體常數( $287.05 \text{ J kg}^{-1} \text{ K}^{-1}$ )， $q_v$  為水氣， $q_x$  為各種水、冰相粒子之混和比。

(3) 運動方程式：

$$\frac{\partial \bar{\rho} u}{\partial t} = -\bar{\rho} \left( u \frac{\partial u}{\partial x} + v \frac{\partial u}{\partial y} + w \frac{\partial u}{\partial z} \right) - \frac{\partial p'}{\partial x} + \bar{\rho} (f_s v - f_c w) + \text{Turbu} \quad (4)$$

$$\frac{\partial \bar{\rho} v}{\partial t} = -\bar{\rho} \left( u \frac{\partial v}{\partial x} + v \frac{\partial v}{\partial y} + w \frac{\partial v}{\partial z} \right) - \frac{\partial p'}{\partial y} - f_s \bar{\rho} u + \text{Turbu} \quad (5)$$

$$\frac{\partial \bar{\rho} w}{\partial t} = -\bar{\rho} \left( u \frac{\partial w}{\partial x} + v \frac{\partial w}{\partial y} + w \frac{\partial w}{\partial z} \right) - \frac{\partial p}{\partial z} - \bar{\rho} \text{Buoy.} w + f_c u + \text{Turbu.} w \quad (6)$$

其中  $f_s$ 、 $f_c$  為科氏參數 ( $f_s = 2\Omega \sin \phi$ 、 $f_c = 2\Omega \cos \phi$ 、 $\phi$  為緯度、 $\Omega$  為地球自轉之角速度， $\Omega = 7.292 \times 10^{-5} \text{ rad s}^{-1}$ )，Turb. 與 Buoy. w 則分別表示亂流混和作用與浮力項。

(4) 氣壓方程式：

$$\frac{\partial p'}{\partial t} = - \left( u \frac{\partial p'}{\partial x} + v \frac{\partial p'}{\partial y} + w \frac{\partial p'}{\partial z} \right) + \bar{\rho} g w - \bar{\rho} c_s^2 \left( \frac{\partial u}{\partial x} + \frac{\partial u}{\partial y} + \frac{\partial u}{\partial z} \right) + \bar{\rho} c_s^2 \left( \frac{1}{\theta} \frac{d\theta}{dt} - \frac{1}{Q} \frac{dQ}{dt} \right) \quad (7)$$

其中  $c_s$  為大氣中的聲速， $q = 1 + 0.61q_v + \sum q_x$

(5) 位溫方程式：

$$\frac{\partial \bar{\rho} \theta'}{\partial t} = -\bar{\rho} \left( u \frac{\partial \theta'}{\partial x} + v \frac{\partial \theta'}{\partial y} + w \frac{\partial \theta'}{\partial z} \right) - \bar{\rho} w \frac{\partial \bar{\theta}}{\partial z} + \text{Turb.} \theta + \bar{\rho} \text{Src.} \theta \quad (8)$$

其中 Src. 表是非絕熱作用之源與匯(加熱與冷卻)

(6) 水氣與滿足混和比方程式：

$$\frac{\partial \bar{\rho} q_v}{\partial t} = -\bar{\rho} \left( u \frac{\partial q_v}{\partial x} + v \frac{\partial q_v}{\partial y} + w \frac{\partial q_v}{\partial z} \right) + \text{Turb.} q_v + \bar{\rho} \text{Src.} q_v \quad (9)$$

$$\frac{\partial \bar{\rho} q_x}{\partial t} = -\bar{\rho} \left( u \frac{\partial q_x}{\partial x} + v \frac{\partial q_x}{\partial y} + w \frac{\partial q_x}{\partial z} \right) + \text{Turb.} q_x + \bar{\rho} \text{Src.} q_x + \bar{\rho} \text{Fall.} q_x \quad (10)$$

其中  $q_x$  代表雲水( $q_c$ )、雨( $q_r$ )、雲冰( $q_i$ )、雪( $q_s$ )及軟雹( $q_g$ )鍾任一種類混和比。Src.、Turb. 及 Fall 分別代表雲物理過程之源與匯、亂流混合作用及降水所造成的時間變率，雲微物理現象的相關轉換過程(冷雲過程)如圖 4 所示。

## 2.3 差時系集預報系統與模式設定

同樣的計算資源，目前常見的方式有將資源集中產出的高解析度大範圍單一決定性預報，以及中低解析度多成員的系集預報，兩者的優點互為對方缺點。高解析度單一決定性預報在降雨量、颱風路徑、強度總體來說皆優於中低解析度多成員的預報結果(W16)，但是無法提供機率資訊造成結果不是大好就是大壞。但是臺灣需要的降雨強度足夠的預報明顯僅能由高解析度預報提供，所以前期便思考如何提供機率預報。

機率資訊可以由差時系集方法獲得，此方法過去有應用在短期定量降水預報(例如，Yuan et al., 2008; Trilaksono et al., 2012; Chang et al., 2012)，但是本研究與過去使用上的差異在於長達八天的差時系集與使用雲解析度的模式，雲解析度的優點在於更能掌握對流的結構，長達八天的預報甫以六小時一次的預報頻率會讓同一時間可用的成員增多。圖 5 展示了使用相同計算資源下，傳統的系集預報預報圖 5(a)與差時系集預報圖 5(b)針對目標日期取得機率預報的方式。

因此自 2012 年以來至今使用日本名古屋大學研發的 CReSS 模式，以美國國家環境預測中心全球預報系統的即時格點分析與預報場做為初始與邊界條件每六小時進行一次預報。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 小時（八天）。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 W15、W16、W22、W23 與錢（2018）完全相同。

## 2.4 颱風客觀定位

本研究並未出現新生颱風的情況，因此僅需進行颱風中心的定位，不需要進行颱風強度辨識。考慮到未來可能的即時預報應用，本研究選擇了可以自動執行的客觀颱風中心定位方法。

進行客觀定位時，直觀上會使用最低氣壓做為颱風中心，但是有幾個可能的問題。第一是颱風在高解析度模式中，最低氣壓位置有時會出現類似陀螺的晃動現象，如果以最低氣壓做為中心，將出現路徑跳動的情形。第二是當颱風通過臺灣地區時，由於複雜的地形，颱風的底層有可能位於地形以下，這將導致缺乏資料或使颱風中心不易辨識，又或者出現副中心的情況，綜合以上原因，直接單純的辨識最低氣壓值的位置並不會是好的方法。

本研究開發出一種方式，嘗試解決以上提到的兩個問題，便是尋找一定範圍內颱風氣壓場的幾何中心。設計了一個在空間上呈現圓錐塔狀的係數函數，圓錐底部的半徑為 200km，圓錐以外的係數值都是 0，塔頂（即中心點）的係數值為 1，並向外線性遞減至 0（即在半徑 200km 處）。圓錐狀的係數函數應用上，會先以某網格點為中心，計算半徑 200km 的區域內所有相應格點上的係數與氣壓與最高氣壓之差值，乘上圓錐狀的係數函數，並對其進行加總平均，如式(1) 所示：

$$\text{Corn Adj.} = \frac{\sum_{i=1}^n [P_{\max} - P_i] \times \frac{200 - D_i}{200}}{n} \quad (11)$$

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，前述的圓錐塔係數即為  $(200 - D_i)/200$ 。每個網格點皆計算完後，再搜尋擁有最大數值的格點，此操作下可以找到形狀最符合圓錐的位置，也就是氣壓場的幾何中心位置。在本研究應用中，這個計算是應用在約 900hPa - 海拔 896 米處的氣壓資料上進行的。如果某個格點位於地形以下且缺乏相應的資料，則不納入計算。

由於本研究的是颱風，因此在客觀定位程式上加了幾個簡易條件：1. 如果一小時前有定位出颱風中心，本時間尋找颱風中心時為前一小時颱風中心周圍 200km。2. 最低壓

附近 200km 內需有任一位置地面風速大於 8m/s，否則不視為颱風。

## 2.5 颱風路徑誤差

颱風預報與實際觀測會有誤差，本研究中討論的主要是西行颱風，垂直於前進方向的誤差將決定颱風侵襲臺灣與否，而平行前進方向的誤差則決定侵襲臺灣的時間快慢與累積時長，本研究認為兩者重要性差異極大，因此在完成颱風各時間點的定位後，參考 DeMaria et al. (2009) 之方法計算颱風路徑的誤差。

圖 6 是關於路徑誤差的示意圖。在圖 6 中  $x_0$  與  $y_0$  代表觀測路徑前一時間點的經緯度， $x_1$  與  $y_1$  代表觀測路徑於目標時間之經緯度，而  $x$  與  $y$  則為預報路徑在目標時間之經緯度，為了計算兩個預報之間的比較，會將被比較的路徑稱為目標路徑，而其他眾多拿來比較的路徑稱為比較路徑。並將颱風的路徑誤差也就是 TE (track error) 分為兩個部分：移速誤差也稱為 ATE (along-track error)；以及移向誤差又稱為 CTE (cross-track error)，這兩者相互垂直，其計算方式如下：

$$CTE = \frac{(y_0 - y_1)(x - x_1) - (x_0 - x_1)(y - y_1)}{\sqrt{(y_0 - y_1)^2 + (x_0 - x_1)^2}} \quad (12)$$

如果預報颱風的 CTE 為正值，表示預報偏向觀測路徑的左側；若 CTE 為負值，則表示預報偏向觀測路徑的右側。在應用上，當已知總誤差和 CTE 時，可以計算 ATE 的絕對值（距離），計算方式為：

$$|ATE| = \sqrt{TE^2 - CTE^2} \quad (13)$$

並可藉由  $[(y_0 - y_1)(x - x_1) - (x_0 - x_1)(y - y_1)]$  判斷式來判斷其正負，當其結果大於零代表預報的颱風移速較觀測為慢，如果小於零則表示較觀測為快。圖 6 中看出預報路徑比實際觀測路徑慢且偏右，故 CTE 為負而 ATE 為正。

## 2.6 降水技術得分

在過去的研究中常看到評估固定時間段內的累積降水量，如日累積降水(0000-2400 UTC 或 0000-2400 LST)。然而這種人為地以特定時間點強制斷開累積時段的方式，並無法準確地描繪那些跨越多日的颱風降水事件。因此在評估各種降水指標時，選擇將颱風影響的時段定義為颱風中心與臺灣海岸線距離在 300km 以內的時間(Lu et al., 2013)。換言之，便是從颱風中心首次接近臺灣海岸線到 300km 範圍（之後文章稱 C300\_1），直到遠離臺灣並再次達到 300km 的距離(之後文章稱 C300\_2)，這段時間被視為颱風的影響期(之後文章稱 C300)。這種定義允許在不同的觀測和預報中，颱風影響的時段可能有所不同。

累積降水量的評估是有許多方式，本研究為了使用一個數值來代表總累積降水之技術得分好壞，使用了可評估預報與觀測整體降水分布相似性的得分指標，靈感來自(Roberts and Lean, 2008)也就是「相似技術得分」(Similarity skill score, 簡稱 SSS, W23)，其公式為：

$$SSS = 1 - \frac{\frac{1}{N} \sum_{i=1}^N (f_i - o_i)^2}{\frac{1}{N} (\sum_{i=1}^N f_i^2 + \sum_{i=1}^N o_i^2)} \quad (14)$$

其中， $N$ 為校驗點（本研究為雨量站）數量， $o_i$ 為第  $i$  個校驗點之觀測值， $f_i$ 則為其預報值。SSS 值的大小介於 1 到 0 之間，數值的大小反應了預報與實際觀測的相似性，當預報結果與觀測完美相同時 SSS 值為 1，當有降水區域皆無降水時則 SSS 值為 0，顯示無預報能力。由於 SSS 可以一個數代表了整體預報好壞，在之後的機器學習環節較好使用。

另外也會使用預兆得分 (threat score, 之後簡稱 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(Schaefer, 1990; Wilks, 2011)，並常用於全臺灣雨量觀測站網進行校驗。(Lee et al., 2013; Wang, 2014; Wang et al., 2021; Hong et al., 2015; 錢, 2018; W15; W16; W22; W23)，基於 Wang (2014) 的研究，常見的公平預兆得分 (Equitable Threat Score, 簡稱 ETS) 會有預報區域測站大多分布於臺灣本島的關係，ETS 降水評估上會導致得分有所偏差。

在所有校驗點上，可以根據觀測和預報的降水是否達到特定的降水門檻值，將其劃

分為以下四種可能的結果：

1. 正確預報(hit, H)：觀測和預報的降水都達到了門檻值。
2. 漏報(miss, M)：觀測的降水達到了門檻值，但預報的降水沒有。
3. 誤報(false alarm, FA)：觀測的降水沒有達到門檻值，但預報的降水達到了。
4. 正確否定(correct negative, CN)：觀測和預報的降水都沒有達到門檻值。

這四種可能結果可以用來建立一個列聯表，以便對觀測和預報的降水進行分類和分析。將前三者的統計數字代入公式 (14)，可得 TS 之值：

$$TS = \frac{H}{M+H+FA} \quad (15)$$

由於 TS 代表了觀測雨區 (H + M) 與預報雨區 (H + FA) 的聯集中交集所占的比例，而 TS 範圍大小介於 1 到 0 之間，TS 越接近 1 時，表示模式在該雨量門檻值處的預報技術越佳，反之亦然。



### 第三章 差時系集預報結果

在進行颱風預報時，單一時間的網格點數高達  $744 \times 544 \times 40$  點，每個颱風個案完成的預報都需要消耗巨大的計算資源。此外根據中央氣象局（2021）侵襲臺灣的颱風路徑可以被分類為 10 類。研究上目標是在路徑分布上具有多樣性，能以各種不同方式接近臺灣的個案。因此挑選了包括從臺灣北部海面通過，由北部、中部、南部穿越臺灣，以及由南部海面（巴士海峽）掠過的五種情況（即路徑一至路徑五）。期待透過這種方法，能擴大颱風數據庫，同時也能增進對於不同颱風路徑的理解，進一步提升預測的準確性。

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，年代由近排到遠分別為有 2016 年的尼伯特（Nepartak）、及莫蘭蒂（Meranti）颱風，2015 年昌鴻（Chan-Hom）、蘇迪勒（Soudelor）、及杜鵑（Dujuan），2014 年麥德姆（Matmo），2013 年蘇力（Soulik）、天兔（Usagi）、及菲特（Fitow）與 2012 年的蘇拉（Saola）。本章針對所選入的颱風個案逐一討論其路徑與降水預報結果，用以了解差時系集預報的表現。

### 3.1 尼伯特颱風

圖 7a 顯示尼伯特颱風 (2016) 於 7/1 1200 UTC 至 7/6 0000 UTC 間的各初始時間的路徑預報，7/7 2150 UTC 於臺東登陸，並於 7/8 0630 臺南市出海。根據觀測訂定颱風的影響期為 7/7 0500 UTC 至 7/9 1300 UTC，總計 56 小時。因此，此處呈現的所有預報都是在颱風中心未距離臺灣 300km 內的時段，並未包含更短前置時間 (lead time) 或更新 (較晚) 的預報。圖 7a 中顯示，該案例的實際路徑主要向西北西，並在 7/7 2150 UTC 左右於臺東附近登陸，隨後 7/8 0630 UTC 從臺南區域出海。然而，模式的路徑預報在颱風經過臺灣時大多呈現北偏，並在此期間多次作出南北向的修正。例如 7/1 0000 至 7/2 0600 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臺中一帶出海，與觀測路徑較接近大部分預估颱風將由花蓮附近登陸，並從新竹到臺中一帶出海，這與觀察到的路徑相近。然而，其他時間的預報則顯示更偏北的路徑，例如在 7/2 1200 UTC、7/3 0000 UTC，以及 7/4 1200 UTC 前後的預報，颱風中心通過日本石垣、西表兩島附近，而並未登陸臺灣。

尼伯特颱風穿越臺灣南部，導致其影響期間的降雨主要集中在東半部的臺東、花蓮地區，最大的累積降雨量為 1266mm (見圖 7b)。圖 7c 顯示了不同起始時間預報的尼伯特颱風在各自影響期間 (定義方式相同) 的總累積降雨分布。可以看到，如果預報路徑和實際路徑的差距越大，則預報和實際降雨量的差異也越明顯。由於這裡沒有包含更新更晚的預報，各預報路徑之間的誤差相當大且多樣化，導致預測的降雨分布亦呈現多種情況，有些集中於中央山脈，有些則集中於北部。從降水 SSS 值來看，圖 7c 中最接近實際降雨情境的預報是由 7 月 3 日 1800 UTC 進行的，其期間為 79 至 124 小時，SSS 值高達 0.83，顯示模式其實有機會於第 4 至 5 天以前模擬得出近乎完整重現實際降水情境。尼伯特颱風 SSS 最早達到 0.6 以上的為 7 月 1 日 1200 UTC 進行的預報，距離實際尼伯特颱風開始影響臺灣有 113 小時。而 SSS 最早達到 0.7 以上的為 7 月 3 日 1800 UTC 進行的預報，距離實際尼伯特颱風開始影響臺灣有 83 小時。

## 3.2 蘇迪勒颱風

圖 8a 展示了蘇迪勒颱風(2015)的實際觀測路徑以及各個不同初始時間的預測路徑。颱風的實際路徑穿越了臺灣中部，並在約 8/7 2040 UTC 時登陸花蓮，並於 8/8 03:00 雲林出海。最早的一次預報始於 8/1 0000 UTC，這次的預報路徑與實際觀測路徑已經非常接近。主要的路徑誤差源自於颱風移動速度過快，導致事件提前約 12 小時發生。在 8/2 到 8/3，預報路徑逐漸向北偏移，到 8/3 0600 UTC 時達到最北（颱風中心未登陸臺灣），然後再向南修正，到 8/4 1200 UTC 的預報與觀測路徑再次接近，且路徑誤差也相應地減小，從此時起，預報路徑已經呈現出收斂狀態，與實際觀測路徑相似。

蘇迪勒颱風影響期間（8/7 1100 UTC 至 8/8 1900 UTC 共 32 小時）的降雨主要集中在臺灣的東北方與西南方，其中雪山山脈、中央山脈北段、南段和西南部的降雨最為嚴重，最大的累積降雨量為 1091mm（見圖 8b）。在預報中（圖 8c）由於路徑預報相對準確，模式對於蘇迪勒颱風的降雨預測也大多表現良好：先前提及的路徑誤差較小的預測，其降水的 SSS 值均達到 0.84 或以上。最佳的降水預報發生在 8/6 0600 UTC 的預報（預測的 28-60 小時），其降水的 SSS 值達到 0.91。然而，當預報路徑偏北時，中央山脈南部的降雨則會減少，SSS 值也會降至 0.6 或更低。

蘇迪勒颱風也揭示了只關注颱風影響期間的評估方法的優勢。相對於颱風登陸的確切時間，防災工作更應專注於整體的降水情境與累積降雨量的極值。例如，對於 8/1 0000 UTC 預報蘇迪勒颱風的降水情境，事後評估的 SSS 達到了 0.81，顯示出模式其實有機會於一周以前模擬得出近乎完整重現實際降水情境。W23 的研究中也提到若只是用傳統的評估方法，事後評估固定時間內的累積降雨量，比如從 8/7 1200 UTC 至 8/8 1200 UTC，那麼由於颱風抵達臺灣的時間實際上提早了大約 12 到 15 個小時，因此在 8/1 0000 UTC 對於 8/7 1200 UTC 至 8/8 1200 UTC 時段的降雨預報 SSS 只有 0.54 分。然而調整累積時段，提前 12 小時以 8/7 0000 UTC 至 8/8 0000 UTC 的累積降雨來評估累積 SSS，SSS 得分則上升至 0.86。蘇迪勒颱風 SSS 最早達到 0.6 與 0.7 以上的為 8 月 1 日 0000 UTC 進行的預報，距離實際蘇迪勒颱風開始影響臺灣有 131 小時。

### 3.3 杜鵑颱風

圖 9a 展示了杜鵑颱風(2015)的觀測與路徑預報，觀測上杜鵑於 9/28 0940 UTC 於宜蘭登陸，穿過臺灣後 9/28 1700 UTC 於彰化出海。最早 9/22 1200 UTC 的預報路徑，預計颱風將穿越沖繩一帶，然而隨後的預報便開始向南修正，9/23 1800 UTC 開始於臺灣北部有路徑收斂的趨向。緊接著 9/24 1200 UTC 的預報又開始往北修正，於 9/25 0000 UTC 預報路徑達到最北，接著路徑再向南修正，9/26 逐漸接近臺灣，並開始預測颱風將在臺灣登陸。

圖 9b 則是杜鵑颱風影響期間的觀測累積降水量，影響時間為 9/27 2200 UTC 至 9/29 0600 UTC 共計 32 小時，最大累積降水 1619mm，降水主要分布於雪山山脈與南部山區。圖 9c 顯示了不同起始時間預報呈現的杜鵑颱風在各自影響期間（定義方式相同）的總累積降雨分布。前述 9/26 1200 UTC 預報的降水情境亦最佳（期限為 35-75 小時），SSS 值為 0.72。杜鵑颱風在 9/25 0000 UTC 與 0600 UTC 的預報路徑皆沒有經過臺灣 300km 的範圍導致沒有影響臺灣累積降水，而其餘的各預報路徑均更偏北，因此降水預報誤差亦較大。杜鵑颱風 SSS 最早達到 0.6 以上的為 9 月 25 日 1800 UTC 進行的預報，距離實際杜鵑颱風開始影響臺灣有 52 小時。而 SSS 最早達到 0.7 以上的為 9 月 26 日 1200 UTC 進行的預報，距離實際杜鵑颱風開始影響臺灣有 32 小時。

### 3.4 蘇力颱風

圖 10a 展示了蘇力颱風 (2013) 的相關結果。蘇力颱風觀測路徑 7/12 1900 UTC 由宜蘭登陸並於 7/13 0000 UTC 新竹出海。圖 10a 中可以看出在 7/6 至 7/8 間的所有預測路徑均存在著不同程度的向北和向東偏移，並沒有任一颱風登陸。然而，從 7/9 開始，連續的預報路徑逐漸向南修正，並且越來越接近最佳路徑，此時也可以看到當時間接近且不確定降低時颱風預報路徑收斂的情形，並在 7/11 0600 UTC 的預報中，唯一報出中心有登陸臺灣的預報，這也是對於降水預測掌握得最好的一次預報。

圖 10b 則是蘇力颱風影響期間的觀測降水量，影響期間為 7/12 0900 UTC 至 7/13 1300 UTC，主要集中在山區和中部平地，最大的累積降水值為 1110 mm。圖 10c 顯示了不同起始時間預報的蘇力颱風在各自影響期間（定義方式相同）的總累積降雨分布。一如預期的 7/6-7/8 的所有預報由於颱風未經過 C300 區域，相對的也不會對臺灣造成太多影響，W23 亦指出蘇力 7/6 至 7/8 預報路徑偏向北方過遠，造成雨量嚴重低估。在 7/11 0600 UTC 的預報中，27 至 52 小時的預報降水量的 SSS 值高達 0.94，這個初始時間比觀測影響期間的起始時間還早了 27 小時。蘇力颱風 SSS 最早達到 0.6 與 0.7 以上的為 7 月 9 日 1200 UTC 進行的預報，距離實際蘇力颱風開始影響臺灣有 69 小時。

### 3.5 麥德姆颱風

圖 11a 展示了麥德姆颱風 (2014) 的觀測路徑與預報路徑，該颱風直接穿越臺灣中部，於 7/23 16:10 臺東登陸，7/23 16:20 彰化附近出海。早在 7/16 0000 與 0600 UTC 的預報中，預報路徑就已經與觀測路徑相當接近。然而，由於前置時間相對長且不確定性高的緣故，接下來的幾次預報 ((7/16 1200 UTC 到 7/17 1200 UTC) 出現了路徑偏東 (偏右) 或颱風減弱消失的情況。在這之後，對此颱風的掌握有所改善，在 7/18 1200 UTC 時產生了最接近觀測的路徑預報。但是隨後的預報路徑又出現北偏的趨勢，最顯著的偏移出現在 7/20 0000 UTC (颱風未登陸)，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。

圖 11b 則描繪了該颱風的實際降水情況，累積時段為 7/22 0300 UTC 至 7/23 1500 UTC 共 36 小時，最大累積降雨為 735mm，麥德姆颱風的主要降水區域集中在山區和東半部。圖 11c 顯示了不同起始時間預報呈現的麥德姆颱風在各自影響期間 (定義方式相同) 的總累積降雨分布，在所有預報中，最接近實際降水情況的則是 7/19 0600 UTC 的預報 (預報範圍為 76 至 122 小時)，其 SSS 值高達 0.77。麥德姆颱風 SSS 最早達到 0.6 與 0.7 以上的為 7 月 18 日 1800 UTC 進行的預報，距離實際麥德姆颱風開始影響臺灣有 81 小時。

### 3.6 莫蘭蒂颱風

圖 12a 展示了莫蘭蒂颱風 (2016) 的觀測路徑與不同初始時間的預報路徑。該颱風自東南向西北擦過臺灣南部。最早期的預報 9/8 0000 UTC 偏向北部，颱風中心預計將穿越沖繩附近。然而，隨後的預報逐漸向南修正，並在 9/10 至 9/11 的幾次預報中，颱風都預測為由中部登陸並穿越臺灣，預報路徑似乎有趨於收斂的跡象。但是，在 9/11 1800 UTC 的預報裡，颱風的預測路徑再次向南調整，到了 9/12 0000 與 0600 UTC 的兩次預報已經與觀測路徑相當接近。

圖 12b 顯示主要的降水區域則集中在東半部及南部的恆春半島地區，累積時間為 9/13 1200 UTC 至 9/15 0000 UTC 共 36 小時，最大累積降水為 1024mm。圖 12c 顯示了不同起始時間預報呈現的莫蘭蒂颱風在各自影響期間（定義方式相同）的總累積降雨分布。9/12 0600 UTC 的降水情境預報與觀測最為吻合，發生在 30-78 小時，其 SSS 值為 0.80。相對於此，偏北的預報路徑，如預測颱風從花蓮登陸的路徑，由於颱風中心預測為登陸，且颱風影響時間較長，因此往往導致降水過度預報。莫蘭蒂颱風 SSS 最早達到 0.6 以上的為 9 月 10 日 0000 UTC 進行的預報，距離實際莫蘭蒂颱風開始影響臺灣有 84 小時。而 SSS 最早達到 0.7 以上的為 9 月 11 日 1200 UTC 進行的預報，距離實際莫蘭蒂颱風開始影響臺灣有 48 小時。

### 3.7 蘇拉颱風

圖 13a 為蘇拉颱風（2012）的觀測與預報路徑，觀測路徑於 8/1 1920 UTC 在花蓮登陸並向北沿著東北部海岸線行進。此颱風不同初始時間下的預報路徑差異相當大，在 7/26 至 7/27 的早期階段預測的大部分路徑都偏右（也就是偏東），7/26 1200 UTC 的預報中，預估的路徑穿過沖繩以北，這是所有預報中最偏右的一條。雖然預測中的大多數軌跡都太靠右（和東邊），然而在 7/27 1800 UTC 預測的路徑顯示颱風將穿越北臺灣，與實際觀測相當接近。在隨後的預報中，路徑顯示出明顯的不確定性，再度向右偏離，指向石垣島一帶，但 7/28 1800 UTC 路徑又偏擺回最左，也是相當接近觀測路徑的一次預報，然後預測的路徑又向右修正，再度遠離臺灣 7/29 0000 UTC 最右，在最後的數次預報中又漸向左修正。

圖 13b 展示了蘇拉颱風影響期間的觀測累積降水量累積時段為 7/31 1600 UTC 至 8/3 0200 UTC，共 58 小時。由於颱風移動速度緩慢且有登陸行為，其累積的降水量相當驚人，尤其在北臺灣和中部山區的降雨量最為突出，最大的累積降水為 1481mm。圖 13c 可以看到，當蘇拉靠近臺灣（更向西）時，預測中有更多的雨水，當它遠離臺灣（更向東）時則雨水較少。從所有的預報中，降水最接近實際觀測路徑的是在 7 月 28 日 1800 UTC 所作的預報，該預報的前置時間接近 3 天，其降水的 SSS 值達到了 0.9。蘇拉颱風 SSS 最早達到 0.6 與 0.7 以上的為 7 月 27 日 0600 UTC 進行的預報，距離實際蘇拉颱風開始影響臺灣有 86 小時。

### 3.8 昌鴻颱風

圖 14a 所示為昌鴻颱風（2015）的觀測路徑與不同初始時間的預報路徑，實際觀測並未登陸。在最初的預報 7/4 0000 UTC 的預報極度偏北，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，預計將穿過臺灣北部。接著預報路徑隨著時間逐漸向北修正，7/8 0600 UTC 的預報修正回最北，且已經與觀測路徑相當接近，但在更接近的時間又稍微向南修正。昌鴻颱風的路徑預報上也呈現著與其他颱風不同的情況，其他颱風整體來說較早的預報路徑發生在較實際北（偏右）的位置，而隨著時間推進逐漸南修（左修），但是昌鴻颱風卻剛好相反，較早的預報路徑發生在較實際南（偏左）的位置，而隨著時間推進逐漸北修（右修）。

昌鴻颱風的路徑相對離臺灣較遠，因此實際影響的時間只有 18 小時，主要的降水區域則位於雪山山脈，如圖 14b 所示，累積的降水時段為 7/10 0500 UTC 至 7/10 2300 UTC，最大累積降水為 242mm。圖 14c 顯示了不同起始時間預報呈現的昌鴻颱風在各自影響期間（定義方式相同）的總累積降雨分布。當路徑越接近臺灣則因為降水累積的越多導致與實際降水情形不同而得分越低，前述的 7/8 0600 UTC 的降水預報（第 116-139 小時）的 SSS 值達到 0.74，是圖 14c 中所有預報中與觀測最為接近的情境也是 SSS 次高的情境。昌鴻颱風 SSS 最早達到 0.6 與 0.7 以上的為 7 月 5 日 0000 UTC 進行的預報，距離實際昌鴻颱風開始影響臺灣有 125 小時。

### 3.9 天兔颱風

圖 15a 為天兔颱風(2013)的觀測路徑與不同初始時間的預報路徑，實際觀測並未登陸，此颱風的實際路徑是從南部近海通過，因此降水主要集中在東半部地區。不同初始時間的預報的颱風移動方向大致上都非常接近，然而較早的預報路徑傾向於偏北。因此，從 9/14 至 9/17 的預報中，許多都預測颱風會從臺灣中部或南部穿越，然而這些預測也逐漸向南修正。到了 9/17 1800 UTC 預報的颱風中心開始不再登陸臺灣，這與實際觀測的結果相同。而 9/18 至 9/19 的預報路徑則與實際觀測的結果更為接近。

圖 15b 為天兔颱風影響期間的觀測累積降水量，影響時間為 9/20 1600 UTC 至 9/22 0400 UTC 共計 36 小時，最大累積降水 787mm，降水主要分布於花蓮臺東一帶。在所有顯示的預報中(圖 15c)，9/18 1200 UTC 的降水預報情境(為預報第 47-85 小時) SSS 值達到了 0.91，該預報路徑與實際觀測的結果也相當接近。在路徑向南修正之前的較早預報中，有些甚至預測颱風中心會登陸臺灣，這些預報都導致了累積雨量的過度預報，然而這符合預期。天兔颱風 SSS 最早達到 0.6 與 0.7 以上的為 9 月 14 日 0600 UTC 進行的預報，距離實際天兔颱風開始影響臺灣有 130 小時。

### 3.10 菲特颱風

圖 16a 為菲特颱風（2013）的觀測與各初始時間的預報路徑，菲特颱風的中心實際並未直接登陸，而是掠過臺灣北部外海，在 10/1 0600 UTC 的預報中路徑最為偏右（偏北）穿越奄美大島，隨後路徑逐漸修正向南，到 10/2 0600 UTC 時則最為偏左（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。

菲特颱風主要的降水區域位於雪山山脈（見圖 16b），影響期間為 10/5 2000 UTC 至 10/6 2300 UTC，總共 27 小時，最大累積降水為 393mm。圖 16c 顯示了不同起始時間預報的菲特颱風在各自影響期間（定義方式相同）的總累積降雨分布，相較於觀測路徑，若預報路徑較接近臺灣，將因影響時段（距離陸地 300 km 以內）的延長，導致預報降水過多。預報路徑越靠近臺灣，其 SSS 值越低。其中，最佳的降水情境預報出現在 10/3 0000 UTC（預報範圍為 63 至 84 小時），其降水預報的 SSS 達到 0.90。菲特颱風 SSS 最早達到 0.6 與 0.7 以上的為 10 月 2 日 1800 UTC 進行的預報，距離實際菲特颱風開始影響臺灣有 74 小時。

## 第四章 機器學習模型介紹、變數相關性與測試

關於颱風有著許多僅能定性或是僅為臆測但是無法定量的經驗，W16 和 W23 的研究皆指出，隨著颱風的接近，預報路徑、各種降水預報產品也會逐漸收斂至某一情境，從前一章的路徑圖和雨量圖中，也可以看到這種趨勢確實存在；蔡等(2011)發現相鄰預報時段路徑誤差具有明顯相關性，最高可達 0.91 最小值亦有 0.72，表示颱風路徑預報此時間點若較觀測偏右則下一時間點也常為偏右；過去的經驗也表明，越接近的預報通常更準確；過去的逐個預報路徑持續向同一方向進行預報調整，可以預見未來的調整可能延續此方向。

機器學習的優勢在於電腦在給予值得學習的資料以及大量訓練後，能在短時間內達到專家的水準。本研究嘗試使用機器學習方法，為影響臺灣西行颱風的定量降水預報建立能提前預估預報品質和信賴度的客觀指引，期待機器學習能於資料中習得經驗，並協助預報員了解每一次預報的信賴度，而且在未來廣泛應用於所有颱風的定量降水預報。

根據中央氣象局(2021)的分類說明，侵臺颱風的路徑可以分為十種，粗分上可劃分為西行和北行兩類，為了降低機器學習問題的複雜性，本研究先專注於討論最常見的侵臺西行颱風。至於降水來源，則希望主要僅來自於颱風本身的環流。因此排除了像是伴隨著顯著西南氣流的颱風，如 2009 年莫拉克 (Morakot, Wang et al., 2012; W22)、2013 年康芮 (Kong-Rey, W16) 等案例，本研究所有用到的 145 個個案與預報初始時間皆列於表一，其中有底色的為納入機器學習的個案，未列入個案的原因為該次預報結果的颱風未侵襲臺灣，自然 SSS 與 TS 值也不會有結果。

本章將講述機器學習會用到的預報參數與客觀指引，接著討論兩者之間的相關性，並進行機器學習之實驗。在對客觀預報指引進行討論時，為了使討論更為精確，因此將模式預報與實際觀測結合產出到的參數稱為模型預測的實際得分 (例如 SSS 或 TS) 或實際路徑誤差 (例如 CTE 或 ATE)，皆會用到實際兩字。而自機器學習模型估算出的項目稱為預估得分或預估誤差，皆會用到預估兩字。

## 4.1 機器學習之預報參數

儘管每次預報生成數十億個參數，但由於計算能力的限制，本研究選取了 105 個可能對降水和路徑預報結果產生影響的關鍵參數，作為機器學習模型的輸入資料，這些參數之代號、說明及選取理由列於表二中。

正如 2.6 節最後部分提到的，人為地以特定時間點斷開累積時間的方式，並無法準確地描繪那些跨越多日的颱風降水事件，因此在評估各種降水指標時，選擇將颱風影響的時段定義為颱風中心與臺灣海岸線距離在 300km 以內的時間，而靠近與遠離臺灣陸地 300km 的兩個時間段分別代號為 C300\_1 和 C300\_2，大部分其他預報參數都是從這兩個時間衍生出來，像是 Duration 便是靠近與遠離兩數字相減，也代表著颱風整體的影響時間，影響的時間越長則總累積的雨量傾向越多。

根據颱風影響的總時間，便可以計算該時間內的累積降水預報。本研究考慮了以下四個降水相關參數：代號分別為 Fr100、Fr200、Fr300 和 Max。Fr100 為預測的降水達到 100mm 的區域佔臺灣本島面積的比例，Fr200 和 Fr300 則分別為 200mm 和 300mm 的比例，Max 則表示預測的臺灣本島最大累積降雨量。在計算 TS100 時會使用到 Fr100，因此預期能在預測 TS100 時提供幫助。

本研究也考慮了多個與颱風路徑預報相關的參數。首先考慮的是預報的颱風中心觸碰 C300\_1 的前 24 小時到後 12 小時的預報經緯度，時間解析度為 6 小時，有經度與緯度的關係，因此有十四筆。以上提到緯度部分代號為 Lat-24、Lat-18……Lat\_C300、Lat+06、Lat+12，而經度部分代號為 Lon-24、Lon-18……Lon\_C300、Lon+06、Lon+12。

本次預報與前 6 小時預報的 CTE 相較於本次預報與前 6 小時預報的 ATE，前者修正的是颱風不同降水情境，而後者修正的是降水提早一小時開始或者延後一小時開始的情況，顯然，CTE 的重要性遠大於 ATE。在研究中考慮到了本預報與前 6 小時、12 小時、18 小時與 24 小時的預報的 CTE 與 ATE，此方面也引入颱風路徑收斂與否的觀念。以本次預報與前 6 小時的預報為例，CTE 的代號為 Cross\_06\_-24、Cross\_06\_-18……Cross\_06\_C300、Cross\_06\_+06、Cross\_06\_+12，本次預報與前 6 小時的預報 ATE 的代號為 Along\_06\_-24、

Along\_06\_-18……Along\_06\_C300、Along\_06\_+06、Along\_06\_+12，而與前 12 小時、18 小時與 24 小時的 CTE 與 ATE 以此類推。

因為這項研究的成果希望能應用於實際預報作業中，所以對於任何颱風個案，最新採用的預報是在颱風中心距臺灣陸地 300km 時(C300\_1)，並且在該時間點之後還有至少 24 小時的前置時間。此預報被稱為最新預報，任何在該時間點之後生成的預報結果都不會被放入機器學習。因此在使用的所有預報中，從預報開始到觀測颱風影響臺灣至少 26 小時，也就是約颱風中心登陸兩天前，確保有足夠的前置時間進行準備。經驗上最新預報的結果傾向最好，因此也將與最新預報計算 CTE 與 ATE，CTE 的代號為 Cross\_new\_-24、Cross\_new\_-18……Cross\_new\_C300、Cross\_new\_+06、Cross\_new\_+12，本次預報與最新預報 ATE 的代號為 Along\_new\_-24、Along\_new\_-18……Along\_new\_C300、Along\_new\_+06、Along\_new\_+12。

本次預報與之前預報的 CTE 與 ATE，對於颱風路徑收斂與否的觀念呈現僅是間接的，因此又設計了一參數其公式如下：

$$\text{Cross\_Val\_24} = \text{Cross\_06\_24x3} + \text{Cross\_12\_24x3} + \text{Cross\_18\_24x2} + \text{Cross\_24\_24}$$

$$\text{Along\_Val\_24} = \text{Along\_06\_24x3} + \text{Along\_12\_24x3} + \text{Along\_18\_24x2} + \text{Along\_24\_24}$$

如果發生收斂，此公式計算出結果會相對小，如果路徑依然發散，此公式計算出結果會相對大。

## 4.2 機器學習之客觀指引

在本研究中降水部分使用到的客觀指引，就是 2.6 節所提到的降水技術得分。這包括了預測颱風侵襲臺灣期間（從 C300\_1 到 C300\_2）的累積降水預估的 SSS、TS100 和 TS200 得分。由於 TS 值相對於 SSS 值有著門檻選擇障礙問題，另外 SSS 值代表了預報與觀測降雨分布的相似度，因此本研究以 SSS 作為機器學習的主要學習、預估與討論項。若能夠提前預估該次颱風預報的 TS 值和 SSS 值，這將大致上可以代表颱風降水預報的可信度。如果機器學習模型預測的 SSS 和 TS 值比較高，那麼就意味著降水預報結果相對更為可信。至於路徑部分的客觀指引，則使用了本次預報與觀測路徑在 C300\_1 前 24 小時到後 12 小時內，時間解析度 6 小時的颱風中心路徑 ATE 與 CTE。



### 4.3 預報參數與降水客觀指引的相關性

如先前所提及，研究中選擇了 105 個預報參數（見表二），客觀指引包括預估的颱風期間總降雨量的 SSS、TS100 與 TS200，以及預估每六小時的 ATE 和 CTE。在將這些參數輸入機器學習模型之前，首先會將資料標準化，即每個數據點都減去平均值並除以標準差。在實際執行機器學習之前，本研究計算了各預報參數與客觀指引之間的相關係數，結果列於表三至表六並分做兩部分：降水客觀指引（SSS 和 TS）和路徑誤差指引（ATE 和 CTE），於 4.3 與 4.4 章分別進行討論。

在所有預報參數中，按照其與降水得分的相關係數絕對值，由高到低的前五種類型，依序為：

1. 當次預報 C300\_1 前後之颱風中心緯度（表二第 5、6 項；Lat-24, ..., Lat+12）。
2. 當次預報影響期間之累積降水最大值（表二第 4 項；Max）。
3. 當次預報 C300\_1 前後之颱風中心經度（表二第 5、6 項；Lon-24, ..., Lon+12）。
4. 當次預報影響期間之累積降水閾值面積覆蓋比例（表二第 3 項；Fr100, Fr200, Fr300）。
5. 與前幾次預報各時間之 CTE（表二第 7、8 項；Cross\_06\_-24, ..., Cross\_24\_+12）。

在所有預報參數類型裡，與降水指數綜合相關係數最高者為本次預報 C300\_1 前後之颱風中心緯度，其相關係數介於-0.66 至-0.23 之間 [表三 左下部分]。最大負相關為 Lat+12，其後依序是 Lat+6、Lat\_C300, ..., Lat-24，這顯示颱風路徑預報偏向南方（即緯度較低）時，降水量的預測效果較好，此外，這種關係在越後面的時間點，也就是越接近或在累積時段內的位置，更為明顯。這種現象的出現猜測是因為在研究案例中，多數颱風在初期的預報路徑偏向北方，且誤差較大，導致降水預測得分偏低，然而，隨後的預報路徑多偏向南方修正，進而對於降水狀況的掌握也相對改善，因此，路徑偏南的預測較為準確，這就是這種現象產生的原因，此現象是颱風挑選造成的誤差，又或是本身預報就存在此現象便需要更大更全面性的研究。

預報的累積降水最大值（Max）與降水指數的相關係數綜合評比第二高，其值介於

+0.39 至 +0.56 間 [表三 第七列左側]，這顯示出模式預測的事件降水極值與其 SSS 及 TS 之間存在一定程度的正相關性。W15 在評估 CReSS 模型對 2010-2012 年間 15 個颱風的預報時，發現當降雨更多的時候，颱風降水預報在相同的門檻處的 TS 值也趨向更高。從表四中可以看出，Max 與 TS 值的相關性 ( $\geq 0.49$ ) 也較 SSS (0.39) 為高。

與降水得分相關性第三高的為本次預報 C300\_1 前後之颱風中心經度，其相關係數介於 -0.57 至 -0.26 間 [表三 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，直接解釋為若颱風路徑越向西偏移（即經度值較小），則降水量的預測效果較佳。由於選擇的個案都是西行的颱風，並且已對預測的颱風侵襲位置進行了標準化至 C300\_1，因此這個觀察現象意味著模型在預測移動速度較快的颱風時，其降水預測更為準確。另種解釋為，臺灣東海岸為東北西南走向，也影響著 C300 東側邊緣走向呈現東北西南，導致了被標準化過後的颱風位置，在 20N-25N 之間會呈現緯度越北則經度越東的現象，降水指數與緯度相關性高、緯度又因為海岸走向的關係與經度相關性高而導致如此結果。

與降水得分相關第四高的預報參數種類為本次預報影響期間之累積降水閾值面積覆蓋比例，介於 +0.12 至 +0.3 之間 [表三 第三到六列左側]。這代表著降水範圍越大，通常也代表著雨量越多，則颱風降水預測在該門檻值處的 TS 值也趨向較高，也與 W15 提到的相同，因此這裡的正相關結果，再次證明了這個現象的存在。不過與累積降水最大值 (Max) 與降水指標相關性的特性相反，預報累積降水閾值面積覆蓋比例與 TS 值的相關性高於與 SSS 的相關性。

第五高的是與前幾次預報各時間之側向路徑誤差 CTE，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 [表四、表五 最左側三欄]。這意味著與之前預報時間相比如果有更多的向南修正，則降水預報傾向於越準確。這比較像是與之前提到的本次預報 C300\_1 前後之颱風中心緯度與降水指數相關所延伸出的二次項，颱風中心緯度越南則降水預報傾向越準，導致本次預報相對先前有向南方修正情形，則降水預報也傾向越準。另外同一次的預報中，例如 6 小時前的預報，可以觀察到 Cross\_06\_+12、

Cross\_06\_+06 和 Cross\_06\_C300 的負相關數值均大於 Cross\_06\_-24、Cross\_06\_-18、Cross\_06\_-12 和 Cross\_06\_+06。這個現象顯示，在颱風通過距離臺灣陸地 300km 線之後的 CTE，比其通過前的相關性要高。而且，與 6 小時前的預報相比，更早時間的預報 CTE 的相關性更高。由於之前提到的本次預報 C300\_1 前後之颱風中心緯度與降水指數相關也有相同現象發生，更可以印證此項相關應為緯度所延伸出的二次項。不過另外值得注意的是 18 小時前預報與其他預報時間相比負相關性更高了一些，這可以看做 18 小時是一個很關鍵的時間，與 18 小時前的預報相比，本次預報南偏的多寡，意味著降水預報準確與否。



#### 4.4 預報參數與路徑誤差指引的相關性討論

本章將討論各實際路徑誤差(位於表三中的第四欄至最右欄)與各預報參數的相關性，以下列出相關係數絕對值最高的四種類型，按照相關係數由高到低依序為：

1. 目標預報與觀測計算出各時間的 CTE (簡稱觀測 CTE) 與目標預報與最新預報計算出各時間的 CTE (簡稱最新 CTE)。
2. 目標預報與觀測計算出各時間的 ATE (簡稱觀測 ATE) 與目標預報與最新預報計算出各時間的 ATE (簡稱最新 ATE)。
3. 目標預報與觀測計算出各時間的 CTE (觀測 CTE) 與目標預報與最新預報計算出各時間的 ATE (最新 ATE)。
4. 目標預報與觀測計算出各時間的 ATE (觀測 ATE) 與目標預報與最新預報計算出各時間的 CTE (最新 CTE)。

由於本章討論的目標是各時間與觀測路徑誤差，因此相關性高的都是目標路徑和最新預報在各時間點的路徑誤差參數，結果並不出人意料。

最高相關性出現在觀測 CTE 與最新 CTE 處，其相關係數範圍在+0.86 至+0.24 之間[見表六左側深紅色格子]。這兩者的 CTE 展現出高度的正相關，因為最新預報與觀測路徑在經驗上應該最接近。這意味著對於大部分西行颱風的路徑預報，目標預報在各時間點相較於最新預報的差異，會有與觀測路徑相近的誤差。

次高的相關性出現在觀測 ATE 與最新 ATE 處，多呈現正相關，其相關係數介於+0.75 至-0.47 之間[見表六右側深紅色格子]，這種現象的原因與觀測 CTE 與最新 CTE 有如此高的相關相同。然而細看下去觀測 ATE 與最新 ATE 又可以區分為通過 C300\_1 之前與之後，通過之前的各時間點與最新 ATE 皆與觀測 ATE 呈現高度相關，但通過之後則相關性明顯降低。猜測有幾個可能，一是颱風與地形之間的交互作用(Hsu et al., 2013)，還有最低氣壓位於地形缺失處增加的定位誤差，以上原因為快慢上增加了更多變數，使得觀測 ATE 與最新 ATE 兩者的相關性下降。

接著第三和第四高相關的兩類參數分別是觀測 CTE 與最新 ATE 的相關係數以及觀測

ATE 與最新 CTE 的相關係數，也就是本小節最高與次高相關係數的交叉相關，這兩類參數的相關性相當接近，範圍分別在-0.65 至+0.41 之間，以及-0.64 至+0.32 之間。此明顯相關的一種解釋為，由於臺灣東海岸為東北西南走向，也影響著 C300 東側邊緣走向呈現東北西南，在 20N-25N 之間會呈現緯度越北則經度越東的現象，因此相對於觀測偏北（偏右）的路徑通常也會相對觀測偏東（偏慢），因此觀測 CTE 越趨向負則觀測 ATE 越趨向正，然而觀測路徑與最新預報路徑又最為接近，造成觀測 CTE 越趨向負則最新 ATE 越趨向正的情況，反之亦然。



## 4.5 機器學習模型介紹、建立、測試與調整

前兩小節介紹並討論了預報參數與客觀指引以及進行了兩者的相關分析。本研究數據上共包括十個颱風個案，個颱風所包含的預報數量可以參考表一，對於每一個目標颱風，本研究十個颱風中使用其餘九個颱風的數據作為訓練和驗證集，然後再將學習到的模型應用於預測目標颱風。因此訓練和驗證用的數據與測試用的數據是相互獨立的。

在這項研究中利用了 Python 語言的 Keras 套件 (Chollet, 2015) 來構建機器學習模型。神經網路中使用了同等寬度的全連接層，並配合使用了 Adam 優化器 (Kingma and Ba, 2015) 進行網路優化。進行評估的損失函數採用均方根誤差 (root-mean-square error, RMSE)，在降水預估時，模型會預估 SSS 或者 TS100 與 TS200 並計算預估值和實際值的均方根誤差；在路徑預估時，則是預估 ATE 與 CTE 和實際 ATE 與 CTE 的均方根誤差。訓練樣本用於 50 次的訓練循環中 (Epoch = 50)，每次訓練中使用 20 組樣本 (batch size = 20)。資料被劃分為四部分，其中三部分作為訓練資料，剩餘的一部分則用作驗證資料，這種方法可稱之為四折交叉驗證 (Kohavi, 1995)。在測試階段也嘗試了傳統常見的十折和五折交叉驗證，但由於損失函數的變動範圍較大，使得驗證結果並不理想，推測可能是驗證資料量過小的原因。鑑於驗證集需要足夠的資料量以確保穩定的表現，最終選擇使用四折交叉驗證。

本研究接著對全連接層的寬度、深度以及激發函數的選擇進行了一系列的探索與測試。在初始的試驗過程中，發現由於颱風案例的數量偏少且各具獨特性，這一現象導致機器學習在每次收斂時得到的結果均存在差異，這可能代表了多組損失函數局部最優的結果。為了解決這個問題，採用了系集預報的概念，對每個颱風案例，利用剩餘的九個案例隨機劃分為訓練集和驗證集，並執行 100 次的隨機組合。訓練集的樣本用於 50 次的訓練迭代中，每次迭代時使用 20 組樣本進行訓練，並最終選取使驗證集損失最小的模型作為最佳模型，測試的客觀指引為 SSS。

全連接層的深度測試時，試驗了從 4 層至 7 層的不同深度，全連接層中不同寬度的神經元數量測試時，這些神經元數量根據經驗選擇，以 2 的級數進行，128 神經元相對

64 以下改善極大，因此測試由 128 開始至 1024 結束。激發函數的選擇上，初步的試驗結果顯示，單一激發函數構成的類神經網路的性能相對較弱，尤其是以線性整流函數 Relu (Nair and Hinton, 2010) 為首的模型，其表現令人失望。因此在後續的研究中，選擇了以乙狀函數 Sigmoid (Cybenko, 1989) 為首，並將 Sigmoid 與 Relu 交錯組合的方式進行，表格中將簡單以 S 與 R 分別代表這兩種函數。測試時為每個颱風產出 100 組機器學習的結果，計算 SSS 時有測試到六層以上的組合，不過深度超過 6 層或神經元超過 2048 個作為深度和寬度會導致計算時間大幅上升，並且對於精確度的提升影響微小甚至降低，因此在 TS 與 ATE 與 CTE 值的測試中便省略了超過六層與超過的測試。表七展示了預估 SSS 值與實際值的絕對值差異，表八則是預估 TS 值與實際值的絕對值差異，表九是預估 ATE 與 CTE 值與實際值的絕對值差異。

表七與表八是降水指引的測試，數據可以看出不同設置下生成的 100 組結果之間的差異並不大，經過簡單的統計後，可以發現當使用五層且激發函數按照 SRRSS 的方式排列，並寬度為 512 個神經元時平均表現最佳。預估的 SSS 與實際模式 SSS 的之間差值的絕對值第 10 與 90 百分位分別為 0.121 與 0.253，表示有 80% 的數值在這兩者之間，平均值為 0.204，中位數為 0.176，標準差為 0.084。接著對機器學習預測的 TS100 和 TS200 值也進行了類似的統計分析，結果也是相同，使用五層激活函數、按照 SRRSS 方式排列且寬度為 512 個神經元時表現最佳。TS100 的預估與實際的差值絕對值第 10 與 90 百分位分別為 0.054 與 0.291，80% 的數值在這兩者之間，平均值為 0.193，中位數為 0.118，標準差為 0.074；對於 TS200 的預估與實際的差值絕對值第 10 與 90 百分位分別為 0.053 與 0.201，80% 的數值在這兩者之間，平均值為 0.175，中位數為 0.126，標準差為 0.062。

表九是路徑指引的測試，數據中可以看出不同設置下生成的 100 組結果之間的差異並不大，在對機器學習預測的 ATE 和 CTE 值也進行了簡單的統計分析。結果顯示當使用五層激活函數按照 SRRSS 方式排列且寬度為 512 個神經元數時平均表現最佳。ATE 的預估與實際的差值絕對值 80% 介於 75.9km 到 160.3km 之間，中位數為 115.1km；對於 CTE 的預估與實際的差值絕對值 80% 的數據範圍在 40.3km 到 79.6km 之間，中位數為 61.7km。

綜合以上，由於颱風案例的數量偏少且各具獨特性，這一現象導致機器學習在每次收斂時得到的結果均存在差異，這可能代表了多組損失函數局部最優的結果。已本研究的資料範圍來說，針對降水指引或者路徑指引，使用五層激活函數按照 SRRSS 方式排列且寬度為 512 個神經元數時平均表現最佳。



## 第五章 機器學習初步結果與分析

在本章節中將深入探討機器學習估計的降雨和路徑預測指引，並最後進行敏感度分析。這項研究利用了 100 組不同的機器學習模型，為侵臺的西行颱風產生了 100 次的預估結果。由於本研究所使用到的個案以機器學習範疇來說十分稀少，上需要未來更進一步的將數據庫擴充，因此在機器學習的結果稱之為初步結果。



## 5.1 機器學習生成颱風降水預報指引之討論

在對所有颱風案例和所有預報進行 100 組輸出後，表十列出了預估的 SSS、TS100、TS200 和實際值的平均值、標準差以及中位數。實際預報與模型預估的比對可以觀察到，預估的降水預報指引在平均值和中位數都比實際結果低大約七至十三個百分點。這表示機器學習模型預估上低估了降雨預報的結果。此外，降水預報指引的預估標準差也低於實際結果，並且在比例上皆低了超過三十個百分點，顯示模型在預估降水指引時應該相對保守，覺得實際 SSS 值差不敢說太差，覺得實際 SSS 值好卻又不敢說太好。圖 17 是實際 SSS 與預估 SSS 以 0.1 為間距的各自分布百分比，可以看出預估 SSS 的分布與實際 SSS 有部分差距，預估 SSS 較平滑而實際 SSS 則有較多高低起伏的變化。圖 17 顯示機器學習預估 SSS 在 0.2-0.8 的區間呈現高估，在其他區間則低估，在部分的區間，兩者差距可以超過 10%。

這時延伸出一個問題，針對每一個預報都有 100 組結果，機器學習模式又出現低估以及保守，那這時候參考中位數是否會較不准，這時候可以針對實際 SSS 與不同百分位的預估 SSS 計算兩者之間的相似技術得分(SSS)，以第 60 百分位的預估 SSS 與實際 SSS 計算出的相似技術得分是 0.8635 是所有百分位中得分最高者，以第 50 百分位的預估 SSS 與實際 SSS 計算出的相似技術得分為 0.8632，實際上以預估 SSS 第 60 百分位的會較準確，但是相差不大，之後使用與討論上皆會以中位數作為討論。

表十一展示了各颱風個案下，一百組機器學習模型輸出之預估 SSS 與 TS 值與實際值（由模式預報與觀測直接計算者）絕對誤差的第 25 百分位、中位數（第 50 百分位）、與第 75 百分位值。從表十一中可以從 SSS 值中觀察到每個颱風都有其特定的特性，對於蘇迪勒、杜鵑和莫蘭蒂颱風的降水指引，機器學習預估上相對較為容易（SSS 的絕對誤差較小，大部分數據範圍在 0.114 至 0.166 之間）。然而，對於天兔、尼伯特和菲特颱風的預估則相對較為困難（SSS 的絕對誤差較大，大部分數據範圍在 0.189 至 0.277 之間）。此外，在預估昌鴻颱風的 SSS 時，表現特別不同，其絕對誤差數值明顯較大（大部分數據大於 0.392）。這是因為在選取的案例中，昌鴻颱風是唯一一個在大部分預報時

間裡偏南，但後來逐漸向北調整的颱風，此現象可以從圖 14 看出，而實際降水與緯度也呈現高度負相關(討論於 4.2 節)，因此由其他九個颱風的數據學習之後，由於缺乏類似的學習經驗，對昌鴻颱風的預估結果特別不理想。

從表十一來看預估 SSS 較困難的颱風預報，其路徑都是經過臺灣的北部或南部海面，並沒有登陸。由於本研究將颱風的影響期定義為颱風距離臺灣陸地 300km 以內的時間。因此，當颱風的路徑屬於這種類型（如路徑一或五）時，其預報路徑稍微偏南或偏北就會對累積降水的時間長短以及累積降水量產生重大影響，導致實際 SSS 值波動極大。另一方面本小節開頭也提到本研究所得出的機器學習模型在預估時較為保守。因此當實際的 SSS 偏高時，預估值往往低於實際值；反之當實際的 SSS 偏低時，預估的 SSS 則可能過高。這種兩種特性結合起來，應該是導致評估這類型颱風預報時表現不佳的部分原因。

接著逐個討論各颱風個案實際 SSS 與機器學習預估 SSS 之間的對比，並觀察兩者的相關性。首先討論尼伯特颱風，圖 18a 呈現了逐個初始時間的機器學習預估 SSS 第 90、50 與 10 百分位值(藍色線)以及實際 SSS (紅色線)，各初始時間的降雨情況則可參見圖 4，透過比對每一次預報的實際 SSS 與預估的 SSS，由於尼伯特颱風在多數初始時間的降雨預報較弱，此情形展現在實際的 SSS 值偏低，其背後原因已於第三章進行討論過。從圖 18a 中可以看到，實際的 SSS 值在初期的 1 日 1200 UTC 到 2 日 0600 UTC、中期的 3 日 1800 UTC，以及後期的 5 日 0600 到 6 日 0000 UTC 的降雨預報表現相對較佳（實際  $SSS > 0.5$ ），而在其它時間表現較差（實際  $SSS < 0.3$ ），這個案例在不同初始時間的降雨預報品質存在顯著差異，因此非常適合用來展示機器學習的預測能力。機器學習的預估 SSS(藍色系線條)在不同百分位存在一定的差距，並且在量化上可能並不總是準確，但明顯可以看出 50% SSS 值在初期的 1 日 1200 UTC 到 2 日 0600 UTC、中期的 3 日 1800 UTC，以及後期的 5 日 0600 到 6 日 0000 UTC 的降雨預報表現相對較佳(50%  $SSS > 0.6$ )，而在其它時間表現較差（50%  $SSS < 0.6$ ）。觀測與實際的比對可以看出實際 SSS 較高的預報表示較為可靠，實際 SSS 較低的預報較為不可靠，機器學習掌握了實際 SSS 的波動

趨勢，可以在颱風登陸 300km 前得知預報品質的好壞與降水預報的可信度，在無機器學習模型協助下，實際的 SSS 值要等颱風通過後才能得知。

圖 18b 展示了蘇迪勒颱風在不同初始時間實際 SSS 與預估 SSS 的變化，其各個預報預測的降雨情況則展示在圖 8c 中。該案例是 SSS 預測表現相對良好的一個例子，所有的預測中的實際 SSS 都在 0.5 以上。從圖 18b 中可以看到，早於 4 日 0000 UTC 的預估 SSS 值大多偏低，之後則呈現上升趨勢，但最早的一次預測（1 日 0000 UTC）卻是所有預測中的次佳。通過機器學習預測的 SSS 值，可以看出在 0400 UTC 之後的所有預測，以及最早在 1 日 0000 UTC 的降雨預測，都比較可靠（預估 SSS 的中位數  $> 0.7$ ），而在此之間的其他預測的可靠性則相對較低（預估 SSS 的中位數大多  $< 0.6$ ）。然而，當預測品質接近時，一些微小的細節變化，像是 SSS 應是 0.9 或者 0.8，如此較小的波動，機器學習並不能完全掌握並預估出來。

圖 19 與圖 20 揭示了四個相對表現較好的颱風案例，可以看到隨著預報時間的接近，杜鵑、蘇力和莫蘭蒂颱風的實際 SSS 值隨之增加，而預估 SSS 值也大致能夠捕捉到這種上升和下降趨勢，另外 SSS 值的分散程度也隨著時間收斂。在這四個案例中，杜鵑颱風（圖 19a）在 25 日 0000 和 0600 UTC 的兩次預報中，因為颱風路徑北偏且沒有任一時間颱風中心距離臺灣低於 300 km，因此沒有累積時間段和相應的預估 SSS 值，比較特別的是 24 日 1800 UTC 的實際 SSS 低但是預估 SSS 高，此情況相當特殊，從與降水相關性高的預報參數一路看下來，該次預報路徑偏北（見圖 9），最大總降水量很小僅 25mm，100mm 於臺灣的降水占比為 0，可能造成預估此降水好的較合理解釋原因便是此預報的前四五次預報集中，給予了機器學習收斂的信號導致如此結果。蘇力颱風（圖 19b）的預估 SSS 表現極佳，實際 SSS 值從 9 日 1200 UTC 開始都達到了 0.8，大約在影響時間段開始前三天，預估的 SSS 中位數就能達到大約 0.7，表明有較高的信心，9 日 0600 UTC 實際 SSS 低但是預估 SSS 高，較可能解釋原因也是此預報的前四五次預報集中，給予了機器學習收斂的信號。麥德姆颱風（圖 20a），實際 SSS 曲線相對平緩，波動不大，大致在 0.6-0.75 之間。預估的 SSS 隨時間的變化則較大，但仍可指出對 19 日 0600 UTC 的預測，以及從

20 日 1200 UTC 開始的幾次預測有較高的信心（預估 SSS 的中位數  $> 0.65$ ），另外 19 日 1200 UTC 至 20 日 0000 UTC 表現較差的原因可能是路徑北偏。莫蘭蒂颱風(圖 20b) 預估 SSS 表現不錯，有強烈掌握到實際 SSS 的高低起伏，實際 SSS 在 10 日 0000 UTC 以後大都超過了 0.6，預估 SSS 中位數平均也給到 0.8 以上。

圖 21 與圖 22 展示了最後的四個颱風，包括蘇拉、菲特、天兔和昌鴻颱風，預估 SSS 對實際值的上升和下降趨勢的掌握相對不理想。在此群組中又可以粗略地分為兩類，一類是蘇拉與昌鴻實際 SSS 變化幅度大，再來是菲特和天兔實際 SSS 變化幅度小蘇拉颱風（圖 21a）預估的 SSS 中位數高低範圍介於 0.31 至 0.90，此變化小於實際的 SSS 高低範圍 0.45 至 0.74，SSS 的預估上相對保守，但是仔細看來兩者的預估 SSS 都大致能捕捉到變化的趨勢，當實際降雨預測較好時，也預估到相對較高的 SSS 值。昌鴻颱風（圖 21b）是所有案例中結果最差的，預估的 SSS 與實際的 SSS 高低差極大，不過這個是在將昌鴻颱風放入機器學習時便可預期的結果。天兔颱風（圖 22a）預估的 SSS 中位數高低介於 0.34 至 0.84，高低差 0.5，此變化則大於實際的 SSS 高低範圍 0.77 至 0.92，高低差 0.25，仔細看可以發現預估 SSS 隨時間緩慢上升，且可以掌握到實際 SSS 的細微高低起伏，但是由於實際 SSS 一直處於高水平狀態，。沒有如預估 SSS 有隨時間上升的趨勢，因此表現較差。菲特颱風(圖 22b)可以發現預估與實際 SSS 的變化趨勢相反，實際 SSS 的高峰便是預估 SSS 的低谷。這可能是因為實際路徑通過北方海面，而在 3 日 1200 和 1800 UTC，以及 4 日 0600 UTC 的預估路徑都比實際路徑偏南，由於預估颱風中心的緯度與 SSS 呈現高度負相關，導致出現這種情況。

綜合以上實際 SSS 與預估 SSS 的結果，預估的 SSS 在大部分颱風案例的趨勢上具有一定程度的參考價值，但其預估結果往往比實際的更保守。對於實際的 SSS 變動小的颱風來說，該颱風平均的 SSS 預估結果也會偏向較好。當實際的 SSS 有大幅度變動時，該颱風平均的 SSS 預估結果也會偏向較差，但是這也展現機器學習能掌握大致方向的優勢，儘管不是定量上的準確，但是能夠給予差的預報較低的預估 SSS，給予好的預報較高的預估 SSS。另外當預測颱風的行為與大部分輸入訓練的數據相反時，機器學習就無法適

切掌握。如果增加更多的颱風案例和訓練數據，這個問題期待可以得到改善。

在實際應用上可以在觀測颱風影響臺灣 26 小時前，也就是約颱風中心登陸兩天前，判斷該次模型預測的可信度，使用預估 SSS 作為客觀指導時，可以酌情參考兩個結果，一個是使用中位數的結果 0.5 作為分界，將 0.5 以上的視為預估可信度較高，0.5 以下的則視為預估可信度較低，在本研究中當預估的 SSS 的中位數達到 0.5 以上時，其實際的 SSS 有 79% 也大於 0.5，當預估的 SSS 的中位數達到 0.5 以下時，其實際的 SSS 有 40% 也小於 0.5，以實際 SSS 與預估 SSS 中位數 0.5 以上和以下來計算 TS 值其值為 0.68。也可以因為中位數的結果在 0.6 上下大致各佔一半，所以將 0.6 以上的視為預估可信度較高，0.6 以下的則視為預估可信度較低。在本研究中，當預估的 SSS 的中位數達到 0.6 以上時，其實際的 SSS 有 72% 也大於 0.6，當預估的 SSS 的中位數達到 0.6 以下時，其實際的 SSS 有 46% 也小於 0.6，以實際 SSS 與預估 SSS 中位數 0.6 以上和以下來計算 TS 值其值為 0.55。

總體上 TS 的機器學習結果與 SSS 的結果呈現出相似性，然而平均而言 TS 的結果較 SSS 低 0.15。圖 23-27 展示了十個颱風實際的 TS100 與機器學習預測的 TS100 之間的比較，每一個結果均存在一定的差異。例如圖 23(a)展現的尼伯特颱風在 4 日 1200 UTC 時，TS100 的降低值顯著地超過了 SSS。同樣，圖 23 (b)呈現的蘇迪勒颱風在 3 日 0600 UTC 的 TS100 變化較為平穩，圖 26 (a)蘇拉颱風於 29 日 0000 UTC 的 TS100 前後變化較 SSS 劇烈，圖 25 (a)麥德姆颱風於 19 日 1800 UTC 的 TS100 前後變化較 SSS 劇烈。另一方面對於菲特颱風，機器學習對其 TS100 的預估與實際值更為接近，而 SSS 的預估則與實際值有較大的差距。

為了進一步解釋這些 TS100 的變化情形，表三中顯示了預測的最大降雨量(Max)與 TS100 和 SSS 的相關性分別為 0.51 和 0.39。這表示兩者均有著相當不錯的相關性。考慮到菲特颱風的最大降雨量預測較少(菲特的平均值僅 300mm，遠低於 850mm 的總平均)，可以預期機器學習在 TS100 和 SSS 的預估中，兩者都會呈現偏低的趨勢。然而實際上菲特颱風的 SSS 得分很高只有 TS 值偏低。對於文中所指出的 TS100 變化劇烈或平緩的情

況，都伴隨著最大降雨量的劇烈變化，這可能與 TS100 的相關性有關，導致了前述的影響。

## 5.2 機器學習生成颱風路徑預報指引之討論

表十二為颱風路徑預報指引之結果，有兩種數據一為機器學習修正前的數據(原始)，另一為機器學習預估出修正量後再將原始值減去修正量的數據(修正)。由於每個颱風最新預報的 C300\_1 介於預報的第 24-29 小時之間，導致時間是浮動的。另外 ATE 與 CTE 有正有負，表十二中的值為取絕對值後再取平均。

本實驗的訓練模型目標是對所有過去的路徑預報進行 CTE 和 ATE 的估計，並期望進行適當的修正。在表十二上半部全部預報的部分，可以看出經修正過後不論 ATE 或者 CTE 結果皆比較好，並且修正方向正確率也高，CTE 和 ATE 的修正方向正確率分別為 82% 和 74%。然而機器學習對修正量的估計相對較為保守，因此即使對 CTE 或 ATE 進行了些許修正，其結果仍然較原始的最新預報差。

因此本研究轉為評估最新預報的修正結果，然而這種做法導致了目標與評估結果不一致的情況：機器學習的目標是修正所有的預報路徑，但評估方式只對最新的預報修正結果進行評估。從 4.2 小節的結果可知，目標和最新預報各時間的 CTE 與目標預報各時間實際的 CTE 相關性極高，機器學習或許大量學習到了將最新預報以外的預報向最新預報修正，因此在全部預報修正表現上不差，但是在針對最新預報進行修正時便失去良好的修正方向建議。

從最新預報的原始以及修正 ATE 與 CTE 兩兩比較，可以發現修正後的 ATE 與 CTE 皆較差，針對最新預報 CTE 和 ATE 的修正方向正確率分別為 71%和 37%，這表示機器學習給予的最新預報 CTE 修正方向應有一些幫助，但是最新預報 ATE 的方向修正比丟銅板還差結論是不太有效。最新預報 ATE 修正方向表現差的可能原因可能如下，根據表四的右半部分，ATE 與路徑的經緯度之間有著最高的正相關性 0.58，但是將最新的預報數據進行統計分析後，發現最新預報的 ATE 與經緯度的相關係數僅為 0.23，出現了差異。除了

標與評估結果不一致的情況，這也可能導致對最新預報的 ATE 的修正不夠理想。在目前的研究範圍內，如果對最新的 CTE 預報的修正為正，可以考慮將最新預報向北調整。然而，颱風路徑預報指引的成熟度不及降水預報指引，因此在實際使用時需要更加謹慎，應僅斟酌參考即可。

### 5.3 機器學習模型敏感度測試

過去兩章以及過去經驗可知，此模型中相關性高的數據重要性高，或許能夠淘汰些許相關性低的數據減少以計算量。本章將所有 105 個預報參數分為六組再進行六次機器學習訓練，評估方式與 4.5 小節相同，皆使用五層激活函數按照 SRRSS 方式排列且寬度為 512 個神經元，預估的客觀指引為 SSS，每次測試皆屏蔽一組數據不用，執行 100 次的訓練隨機組合，每次訓練皆選取使驗證集損失最小的模型作為最佳模型，並列出百分為 10 至 90 的差異絕對值。研究參數分做以下六組：

1. 表二中 1-2 項 (C300\_1、C300\_2 與 Duration): 靠近與遠離臺灣陸地 300km 的兩個時間段分別代號為 C300\_1 和 C300\_2，Duration 是靠近與遠離兩數字相減，也代表著颱風整體的影響時間。
2. 表二中 3-4 項 (Fr100-300 與 Max): Fr100 為預測的降水達到 100mm 的區域佔臺灣本島面積的比例，Fr200 和 Fr300 則分別為 200mm 和 300mm 的比例，Max 則表示預測的臺灣本島最大累積降雨量。
3. 表二中 5-6 項 (Lat-24...Lat+12 與 Lon-24...Lon+12): 預報的颱風中心觸碰 C300\_1 的前 24 小時到後 12 小時的預報經緯度，時間解析度為 6 小時，有經度與緯度的關係，因此有十四筆。以上提到緯度部分代號為 Lat-24、Lat-18...Lat\_C300、Lat+06、Lat+12，而經度部分代號為 Lon-24、Lon-18...Lon\_C300、Lon+06、Lon+12。
4. 表二中 7-8 項 (Along\_06\_-24...Along\_06\_+12 與 Cross\_06\_-24...Cross\_06\_+12): 本次預報與前 6 小時、12 小時、18 小時與 24 小時的預報的 CTE 與 ATE。以本次預報與前 6 小時的預報為例，CTE 的代號為 Cross\_06\_-24、

Cross\_06\_-18……Cross\_06\_C300、Cross\_06\_+06、Cross\_06\_+12，本次預報與前6小時的預報 ATE 的代號為 Along\_06\_-24、Along\_06\_-18……Along\_06\_C300、Along\_06\_+06、Along\_06\_+12，而與前 12 小時、18 小時與 24 小時的 CTE 與 ATE 以此類推。

5. 表二中 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 小時到後 12 小時 (每 6 小時)，與最新預報報至相同時間的 ATE 與 CTE。
6. 表二中第 11 項(Along\_Val\_-24…Along\_Val\_+12 與 Cross\_Val\_-24…Cross\_Val+12)是較本次提早 6 小時至 24 小時的前 4 次預報中，報至 C300\_1 時間之前 24 小時、到後 12 小時 (每 6 小時)，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 小時預報之權重依序為 3, 3, 2, 1。

可以從表十三的測試結果觀察到，當部分參數被移除後，其結果都比未移除任何參數的結果來得差。其中最大的差異來自於移除第三個參數，也就是颱風路徑的經緯度，這項結果是預期之內的，因為颱風路徑的經緯度在所有的數據中具有最高的相關性。而相對的，差異最小的則是移除第六個參數，即本次預報與前四次預報的 ATE 與 CTE 權重組合，這可能是因為 ATE 與 CTE 已經被納入機器學習的計算中，而這個函數的原始設計目的，是希望能反映過去四次預報路徑的收斂與發散狀況，但遺憾的是實際上並未對結果產生顯著影響。

按照移除參數後對預測結果的影響程度，可以將其排名，由影響大到小分別為 3、2、5、4、1、6，與此相對應的相關係數排名也大致相同。雖然參數 6 (過去四次預報路徑的收斂或發散) 的影響最小，且與降水的相關性絕對值最高只有 0.21，但在這種微乎其微的相關性下，仍然具有一定的影響力。

## 第六章 綜合討論

臺灣對颱風防災需求的是高解析度的降水情境，所以數值預報上必須靠雲解析度預報來產生，差時系集預報是經評估後對颱風防災能提供最多資訊的方式，由於涉及大量的計算成本，本研究包括了十個颱風個案評估，使用 2.5-km 雲解析 CReSS 模式，針對十個西行準侵臺颱風的每 6 小時的八天差時系集預報，並專注於颱風影響期間（中心距離臺灣陸地在 300 km 以內）的降水預報，而非傳統的人為地以特定時間點強制斷開累積時段的方式。

本研究在第三章可以看到高解析度的預報能夠在提前於實際颱風觀測路徑開始影響臺灣前，分別在 52、69、74、81、84、106、113、125、130 與 131 小時平均四天前提提供實際 SSS 超過 0.6 的高解析度降水情境，若是更為嚴苛的看待則分別在 32、48、69、74、81、83、106、125、130 與 131 小時平均三天半前提提供實際 SSS 超過 0.7 的高解析度降水情境，相對於傳統多成員系集預報模式在臺灣颱風最糟的情境提供上有幾個好處，一為提前相對多的時間提供最糟情境，二來是颱風降水強度足夠且清晰(SSS 超過 0.7) 且涵蓋整體降水時間，三來是系集路徑分散度足夠，若與 Hong et al. (2015)相同要進行系集模式颱風定量降水預報時，不易有散佈度不足的情況發生。

為了回答每一次預報各自不同的參考價值，本研究於十個西行颱風中選取了 105 個預報參數，並嘗試利用機器學習技術來提供降水指引(SSS、TS)與路徑指引(ATE、CTE)，在第四章的預報參數與客觀指引相關性分析中也可以發現眾多有趣的問題，比如 4.2 節所提到的降水品質與颱風中心緯度呈現高度的負相關，究竟是資料過少所造成偏差，又或者西行侵臺颱風的預報本身就存在此現象，若是後者那造成的原因為何；目標是修正最新颱風預報路徑的機器學習該納入那些參數，相關性以及修正後的優劣，這些都是一個相當大且有趣的題目。

SSS 與 TS 皆可以代表降雨分布情況優劣，數值越高表示預報的結果與實際越接近，機器學習對於 SSS 與 TS 值的預估中可以發現，在大部分情況下能夠有效地掌握真實 SSS 與 TS 的變化趨勢，也就是事前能夠告訴我們，哪些預報的可信度較高，哪些可信度較

低，並提供有效的客觀預報指引。本研究嘗試以機器學習方法衝擊了數值天氣預報面臨的難題，但由於所使用到的個案以機器學習範疇來說十分稀少，上需要未來更進一步的將數據庫擴充，因此在機器學習的結果稱之為初步結果。如果某一個颱風的行為與大多數的訓練資料不同，例如昌鴻颱風，那麼機器學習的效果就會較差，也就是說，無法充分掌握特例的情況。

在實際應用上可以在觀測颱風影響臺灣 26 小時前，也就是約颱風中心登陸兩天前，判斷該次模型預測的可信度，使用預估 SSS 作為客觀指導時，由於中位數的結果在 0.6 上下大致各佔一半，所以將 0.6 以上的視為預估可信度較高，0.6 以下的則視為預估可信度較低。在本研究中，當預估的 SSS 的中位數達到 0.6 以上時，其實際的 SSS 有 72% 也大於 0.6，當預估的 SSS 的中位數達到 0.6 以下時，其實際的 SSS 有 46% 也小於 0.6，以實際 SSS 與預估 SSS 中位數 0.6 以上和以下來計算 TS 值其值為 0.55。

另外也於 5.2 章討論了機器學習對於 CTE 與 ATE 的修正，針對全部預報的修正，不論 ATE 或者 CTE 結果皆比較好，並且修正方向的正確率也高，CTE 和 ATE 的修正方向正確率分別為 82% 和 74%。但是由於然而機器學習對修正量的估計相對較為保守，因此即使對 CTE 或 ATE 進行了些許修正，其結果仍然較原始的更新預報差。因此本研究轉為評估最新預報的修正結果，然而這種做法導致了目標與評估結果不一致的情況，導致在針對最新預報進行修正時便失去良好的修正建議。於研究範圍內，如果對最新的 CTE 預報的修正為正，可以考慮將最新預報向北調整。然而，颱風路徑預報指引的成熟度不及降水預報指引，因此在實際使用時需要更加謹慎，應僅斟酌參考即可。文章並在 5.3 章中測試了不同參數組合敏感度，結論是 105 的參數都放入結果最佳。

## 第七章 結論與未來工作

本研究呈現了雲解析差時系集預報對於臺灣颱風防災的價值，並進行了初步的機器學習研究。在目前研究的基礎上，觀察到颱風預報的 C300\_1 位置位於 22-25N 之間，其使用結果會相對穩定，由於 25N 以北與 22N 以南的預報颱風影響期間，會受預報颱風路徑的偏南偏北造成極大影響。在實際應用上可以在觀測颱風影響臺灣 26 小時前，也就是約颱風中心登陸兩天前，判斷該次模型預測的可信度，使用預估 SSS 作為客觀指導時，由於中位數的結果在 0.6 上下大致各佔一半，所以將 0.6 以上的視為預估可信度較高，0.6 以下的則視為預估可信度較低。

若希望進一步改進機器學習的結果，有以下幾個方向可以考慮：

1. 更多的颱風個案：很明顯的個案數量對機器學習來說顯著不足，以目前的學術計算資源，若要對每個颱風進行完整的差時系集預報，且不算上等候排隊時間約需要十五天的計算時間，實際運作起來遠超乎此範疇。建議在增加個案前對颱風品質進行初步篩檢，增加特殊個案數量的掌握程度，並修正由於選擇的個案特定行為所造成的學習偏差。
2. 更多的預報參數：本研究中選取的預報參數大多皆與運動學與降雨規模的相關參數，但是有相當多如颱風壯度(周等, 2018)、颱風中心最低氣壓、近中心最大風速、暴風半徑等描述颱風強度與動力的參數都未包含在內，還有傳統上常見的副高氣壓位置、駛流強度等，以及研究中常提到路徑收斂之定義，在獲取更多參數後能夠與降水有更好的相關，5.3 小節的結果顯示各種經驗若能被描述出來並放入機器學習中都會對準確性有所增益。

本文之精簡版已發表於大氣科學期刊：

陳鑫濤, 王重傑, 2022：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。大氣科學，78-122。

## 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>)
- 周昆炫、吳聖宇與林書正, 2018: 颱風壯度與大小對台灣風雨之影響。大氣科學, **46-3**, 222-245。
- 陳昱璁、馮智勇、張博雄、許乃寧與賈愛玫, 2018: 應用貝氏模型平均法發展颱風路徑機率預報指引。大氣科學, **46-2**, 172-196。
- 莊美誼、王彥雯、黃煜鈞、李美賢、張惠玲、洪景山與蕭朱杏, 2022: 應用類神經網路進行台灣地區颱風系集降雨機率預報校正。大氣科學, **50**, 188-211。
- 蔡孝忠, 2007: 中央氣象局颱風路徑機率預報新產品—路徑機率預報。中央氣象局通訊月刊, **2007 年 12 月號**。
- 蔡孝忠、呂國臣、許乃寧與賈愛玫, 2011: 蒙地卡羅法在颱風侵襲機率估計的應用。大氣科學, **39-3**, 269-288。
- 蔡建鴻, 2021: 雲解析差時系集在侵襲菲律賓颱風定量降水預報之評估研究。碩士論文, 173 頁。
- 錢稚偉, 2018: 雲解析模式對侵臺颱風八天定量降水預報技術之評估與特性分析。碩士論文, 133 頁。
- 顧欣怡, 2006: 颱風侵襲機率預報系統開發。中央氣象局九十五年度研究報告, **第 CWB95-1A-07 號**。
- Bi K.-F., L.-X. Xie, H.-H. Zhang, X. Chen, X.-T. Gu and Q. Tian, 2023: Accurate medium-range global weather forecasting with 3D neural networks, *Nature*, **619**, 533-538

- 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. Grønås, Eds., *Amer. Meteor. Soc.*, **1–4**, 1999.
- 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.
- Chang, H.-L., H. Yuan, and P.-L. Lin, 2012: Short-range (0–12 h) PQPFs from time-lagged multimodel ensembles using LAPS. *Mon. Wea. Rev.*, **140**, 1496–1516, doi:10.1175/MWR-D-11-00085.1.
- 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.
- DeMaria, M., Knaff, J. A., Knabb, R., Lauer, C., Sampson, C. R., DeMaria, R. T., 2009: A new method for estimating tropical cyclone wind speed probabilities, *Wea. Forecasting*, **24**, 1573-1591.
- Done, J., Davis, C.A., Weisman, M., 2004. The next generation of NWP: explicit forecasts of convection using the Weather Research and Forecasting (WRF) model. *Atmos. Sci. Lett.* **5**, 110–117.

- 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.
- Gentry, M. S., Lackmann, G. M., 2010: Sensitivity of simulated tropical cyclone structure and intensity to horizontal resolution. *Mon. Weather Rev.* **138**, 688–704
- 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.
- 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)*, **2**, San Francisco, CA, USA, 1137–1143.
- Kong, F., K. K. Droegemeier, and N. L. Hickmon, 2006: Multiresolution ensemble forecasts of an observed tornadic thunderstorm system. Part I: Comparison of coarse- and fine-grid experiments. *Mon. Wea. Rev.*, **134**, 807–833, doi:10.1175/MWR3097.1.

- 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.
- Lu, M.-M., C.-T. Lee and B. Wang, 2013: Seasonal prediction of accumulated tropical cyclone kinetic energy around Taiwan and the sources of the predictability. *International Journal of Climatology*. **33**. 2846-2854. 10.1002/joc.3634.
- Molteni, F., R. Buizza, T. N. Palmer, and T. Petrolia, 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.

- 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.
- Trilaksono, N. J., S. Otsuka, and S. Yoden, 2012: A time-lagged ensemble simulation on the modulation of precipitation over West Java in January–February 2007. *Mon. Wea. Rev.*, **140**, 601–616, doi:10.1175/MWR-D-11-00094.1.
- 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. Hydrospheric Atmospheric Research Center, Nagoya University, and UNESCO, 273 pp.
- Wang, C.-C., H.-C. Kuo, Y.-H. Chen, H.-L. Huang, C.-H. Chung, Tsuboki, K., 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., H.-C. Kuo, T.-C. Yeh, C.-H. Chung, Y.-H. Chen, S.-Y. Huang, Y.-W. Wang, C.-H. Liu, 2013. High-resolution quantitative precipitation forecasts and simulations by the cloud-resolving storm simulator (CReSS) for Typhoon Morakot (2009). *J. Hydrol.* **506**, 26–41. <https://doi.org/10.1016/j.jhydrol.2013.02.018>.
- 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**, 1723–1748.

- Wang, C.-C., S.-Y. Huang, S.-H. Chen, C.-S. Chang, 2016: Cloud-resolving typhoon rainfall ensemble forecasts for Taiwan with large domain and extended range through time-lagged approach. *Wea. Forecasting*, **31**, 151–172.
- Wang, C.-C., C.-S. Chang, Y.-W. Wang, C.-C. Huang, S.-C. Wang, Y.-S. Chen, K. Tsuboki, S.-Y. Huang, S.-H. Chen, P.-Y. Chuang, H. Chiu, 2021: Evaluating quantitative precipitation forecasts using the 2.5 km CReSS model for typhoons in Taiwan: an update through the 2015 Season., *Atmosphere*, **12**, 1501. <https://doi.org/10.3390/atmos12111501>.
- Wang, C.-C., S.-H. Chen, K. Tsuboki, S.-Y. Huang, and C.-S. Chang, 2022: Application of Time-Lagged Ensemble Quantitative Precipitation Forecasts for Typhoon Morakot (2009) in Taiwan by a Cloud-Resolving Model. *Atmosphere*, **13**, 585, <https://doi.org/10.3390/atmos13040585>.
- Wang, C.-C., S.-H. Chen, Y.-H. Chen, H.-C. Kuo, J. H. Ruppert, Jr., and K. Tsuboki, 2023: Cloud-resolving time-lagged rainfall ensemble forecasts for typhoons in Taiwan: Examples of Saola (2012), Soulik (2013), and Soudelor (2015). *Weather Clim. Extrem.*, **40**, 100555, DOI: 10.1016/j.wace.2023.100555.
- Wilks, D. S., 2011: Statistical Methods in the Atmospheric Sciences. 3rd Edition, *Academic Press*, Oxford.
- Yang, M.-J., S. A. Braun, and D.-S. Chen, 2011: Water budget of Typhoon Nari (2001). *Mon. Wea. Rev.*, **139**, 3809–3828, doi:10.1175/MWR-D-10-05090.1.
- Yuan, H., J. A. McGinley, P. J. Schultz, C. J. Anderson, and C. Lu, 2008: Short-range precipitation forecasts from time-lagged multimodel ensembles during the HMT-West-2006 campaign. *J. Hydrometeor.*, **9**, 477–491, doi:10.1175/2007JHM879.1.

Zhang Y.-C., M.-S. Long, K.-Y. Chen, L.-X. Xing, R.-H. Jin, M. I. Jordan and J.-M. Wang, 2023: Article Skilful nowcasting of extreme precipitation with NowcastNet, *Nature*, **619**, 526-532

Zhang, T., W. Lin, Y. Lin, M. Zhang, H. Yu, K. Cao, and W. Xue, 2019: Prediction of Tropical Cyclone Genesis from Mesoscale Convective Systems Using Machine Learning. *Wea. Forecasting*, **34**, 1035–1049, <https://doi.org/10.1175/WAF-D-18-0201.1>.



表一 本研究中十個颱風有進行預報的所有初始時間，當中有進入機器學習的有 145 個  
 初始時間在表中為黃色底色，各颱風最下方有統計各颱風進入機器學習的數量。

| 蘇拉               | 蘇力               | 天兔               | 菲特               | 麥德姆              | 昌鴻               | 蘇迪勒              | 杜鵬               | 厄伯特              | 莫蘭蒂              |
|------------------|------------------|------------------|------------------|------------------|------------------|------------------|------------------|------------------|------------------|
| 2012072600_2.5km | 2013070800_2.5km | 2013091300_2.5km | 2013100100_2.5km | 2014071700_2.5km | 2015070300_2.5km | 2015073100_2.5km | 2015092200_2.5km | 2016093000_2.5km | 2016090800_2.5km |
| 2012072606_2.5km | 2013070806_2.5km | 2013091306_2.5km | 2013100106_2.5km | 2014071706_2.5km | 2015070306_2.5km | 2015073106_2.5km | 2015092206_2.5km | 2016093006_2.5km | 2016090806_2.5km |
| 2012072612_2.5km | 2013070812_2.5km | 2013091312_2.5km | 2013100112_2.5km | 2014071712_2.5km | 2015070312_2.5km | 2015073112_2.5km | 2015092212_2.5km | 2016093012_2.5km | 2016090812_2.5km |
| 2012072618_2.5km | 2013070818_2.5km | 2013091318_2.5km | 2013100118_2.5km | 2014071718_2.5km | 2015070318_2.5km | 2015073118_2.5km | 2015092218_2.5km | 2016093018_2.5km | 2016090818_2.5km |
| 2012072700_2.5km | 2013070900_2.5km | 2013091400_2.5km | 2013100200_2.5km | 2014071800_2.5km | 2015070400_2.5km | 2015080100_2.5km | 2015092300_2.5km | 2016070100_2.5km | 2016090900_2.5km |
| 2012072706_2.5km | 2013070906_2.5km | 2013091406_2.5km | 2013100206_2.5km | 2014071806_2.5km | 2015070406_2.5km | 2015080106_2.5km | 2015092306_2.5km | 2016070106_2.5km | 2016090906_2.5km |
| 2012072712_2.5km | 2013070912_2.5km | 2013091412_2.5km | 2013100212_2.5km | 2014071812_2.5km | 2015070412_2.5km | 2015080112_2.5km | 2015092312_2.5km | 2016070112_2.5km | 2016090912_2.5km |
| 2012072718_2.5km | 2013070918_2.5km | 2013091418_2.5km | 2013100218_2.5km | 2014071818_2.5km | 2015070418_2.5km | 2015080118_2.5km | 2015092318_2.5km | 2016070118_2.5km | 2016090918_2.5km |
| 2012072800_2.5km | 2013071000_2.5km | 2013091500_2.5km | 2013100300_2.5km | 2014071900_2.5km | 2015070500_2.5km | 2015080200_2.5km | 2015092400_2.5km | 2016070200_2.5km | 2016091000_2.5km |
| 2012072806_2.5km | 2013071006_2.5km | 2013091506_2.5km | 2013100306_2.5km | 2014071906_2.5km | 2015070506_2.5km | 2015080206_2.5km | 2015092406_2.5km | 2016070206_2.5km | 2016091006_2.5km |
| 2012072812_2.5km | 2013071012_2.5km | 2013091512_2.5km | 2013100312_2.5km | 2014071912_2.5km | 2015070512_2.5km | 2015080212_2.5km | 2015092412_2.5km | 2016070212_2.5km | 2016091012_2.5km |
| 2012072818_2.5km | 2013071018_2.5km | 2013091518_2.5km | 2013100318_2.5km | 2014071918_2.5km | 2015070518_2.5km | 2015080218_2.5km | 2015092418_2.5km | 2016070218_2.5km | 2016091018_2.5km |
| 2012072900_2.5km | 2013071100_2.5km | 2013091600_2.5km | 2013100400_2.5km | 2014072000_2.5km | 2015070600_2.5km | 2015080300_2.5km | 2015092500_2.5km | 2016070300_2.5km | 2016091100_2.5km |
| 2012072906_2.5km | 2013071106_2.5km | 2013091606_2.5km | 2013100406_2.5km | 2014072006_2.5km | 2015070606_2.5km | 2015080306_2.5km | 2015092506_2.5km | 2016070306_2.5km | 2016091106_2.5km |
| 2012072912_2.5km | 2013071112_2.5km | 2013091612_2.5km | 2013100412_2.5km | 2014072012_2.5km | 2015070612_2.5km | 2015080312_2.5km | 2015092512_2.5km | 2016070312_2.5km | 2016091112_2.5km |
| 2012072918_2.5km | 2013071118_2.5km | 2013091618_2.5km | 2013100418_2.5km | 2014072018_2.5km | 2015070618_2.5km | 2015080318_2.5km | 2015092518_2.5km | 2016070318_2.5km | 2016091118_2.5km |
| 2012073000_2.5km | 2013071200_2.5km | 2013091700_2.5km | 2013100500_2.5km | 2014072100_2.5km | 2015070700_2.5km | 2015080400_2.5km | 2015092600_2.5km | 2016070400_2.5km | 2016091200_2.5km |
| 2012073006_2.5km | 2013071206_2.5km | 2013091706_2.5km | 2013100506_2.5km | 2014072106_2.5km | 2015070706_2.5km | 2015080406_2.5km | 2015092606_2.5km | 2016070406_2.5km | 2016091206_2.5km |
| 2012073012_2.5km | 2013071212_2.5km | 2013091712_2.5km | 2013100512_2.5km | 2014072112_2.5km | 2015070712_2.5km | 2015080412_2.5km | 2015092612_2.5km | 2016070412_2.5km | 2016091212_2.5km |
| 2012073018_2.5km | 2013071218_2.5km | 2013091718_2.5km | 2013100518_2.5km | 2014072118_2.5km | 2015070718_2.5km | 2015080418_2.5km | 2015092618_2.5km | 2016070418_2.5km | 2016091218_2.5km |
| 2012073100_2.5km | 2013091800_2.5km | 2013091800_2.5km | 2013100600_2.5km | 2014072200_2.5km | 2015070800_2.5km | 2015080500_2.5km | 2015092700_2.5km | 2016070500_2.5km | 2016091300_2.5km |
| 2012073106_2.5km | 2013091806_2.5km | 2013091806_2.5km | 2013100606_2.5km |                  | 2015070806_2.5km | 2015080506_2.5km | 2015092706_2.5km | 2016070506_2.5km | 2016091306_2.5km |
| 2012073112_2.5km | 2013091812_2.5km | 2013091812_2.5km | 2013100612_2.5km |                  | 2015070812_2.5km | 2015080512_2.5km | 2015092712_2.5km | 2016070512_2.5km | 2016091312_2.5km |
| 2012073118_2.5km | 2013091818_2.5km | 2013091818_2.5km | 2013100618_2.5km |                  | 2015070818_2.5km | 2015080518_2.5km | 2015092718_2.5km | 2016070518_2.5km | 2016091318_2.5km |
|                  | 2013091900_2.5km | 2013091900_2.5km |                  |                  | 2015070900_2.5km | 2015080600_2.5km | 2015092800_2.5km | 2016070600_2.5km |                  |
|                  | 2013091906_2.5km | 2013091906_2.5km |                  |                  | 2015070906_2.5km | 2015080606_2.5km | 2015092806_2.5km | 2016070606_2.5km |                  |
|                  | 2013091912_2.5km | 2013091912_2.5km |                  |                  | 2015070912_2.5km | 2015080612_2.5km | 2015092812_2.5km | 2016070612_2.5km |                  |
|                  | 2013091918_2.5km | 2013091918_2.5km |                  |                  | 2015070918_2.5km | 2015080618_2.5km | 2015092818_2.5km | 2016070618_2.5km |                  |
|                  | 2013092000_2.5km | 2013092000_2.5km |                  |                  | 2015071000_2.5km | 2015080700_2.5km |                  | 2016070700_2.5km |                  |
|                  | 2013092006_2.5km | 2013092006_2.5km |                  |                  | 2015071006_2.5km | 2015080706_2.5km |                  | 2016070706_2.5km |                  |
|                  | 2013092012_2.5km | 2013092012_2.5km |                  |                  | 2015071012_2.5km | 2015080712_2.5km |                  | 2016070712_2.5km |                  |
|                  | 2013092018_2.5km | 2013092018_2.5km |                  |                  | 2015071018_2.5km | 2015080718_2.5km |                  | 2016070718_2.5km |                  |
| 13               | 9                | 22               | 9                | 9                | 10               | 17               | 22               | 12               | 19               |
|                  |                  |                  |                  |                  |                  |                  |                  |                  | 12               |


表二 本研究所選取輸入機器學習的 105 個預報參數，個別代號、說明與選取理由。

| 項次 | 代號                                                                   | 說明與選取理由                                                                                                                              | 個數 |
|----|----------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------|----|
| 1  | C300_1,<br>C300_2                                                    | 預報開始到颱風中心首次距離臺灣陸地 300 km 以內的時間 (小時)。<br>預報開始到颱風中心遠離臺灣陸地即將達到 300 km 的時間 (小時)。<br>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  |
| 2  | Duration                                                             | 颱風影響臺灣的時段長短 (小時)，其值等於 C300_2 - C300_1。<br>颱風影響臺灣的時段越長，累積的雨量傾向於越多。                                                                    | 1  |
| 3  | Fr100,<br>Fr200,<br>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)。<br>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  |
| 4  | Max                                                                  | 預報降水事件於臺灣本島的最大累積雨量 (mm)。                                                                                                             | 1  |
| 5  | Lat_C300,<br>Lon_C300                                                | 預報颱風中心首次靠近臺灣陸地 300 km 以內的經緯度位置。<br>預期是颱風開始影響臺灣相對於臺灣的位置參數之一。                                                                          | 2  |
| 6  | Lat-24,<br>Lat-18, ...,<br>Lat+12; Lon-24,<br>Lon-18, ...,<br>Lon+12 | 預報颱風中心首次靠近臺灣陸地至 300 km 以內的時間 (即 C300_1) 之前 24 小時到之後 12 小時間，每 6 小時之中心經緯度位置。<br>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 |

表二 為本研究所選取輸入機器學習的 105 個預報參數，個別代號、說明與選取理由。

| 項次 | 代號                                                                                                                            | 說明與選取理由                                                                                                                                                                      | 個數 |
|----|-------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 7  | Along_06_C300, ...,<br>Along_24_C300;<br>Cross_06_C300, ...,<br>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 小時至 24 小時預報者（比較路徑）報至相同時間的 ATE 與 CTE。<br>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  |
| 8  | Along_06_-24, ...,<br>Along_06_+12, ...,<br>Along_24_+12;<br>Cross_06_-24, ...,<br>Cross_06_+12, ...,<br>Cross_24_+12         | 本次預報颱風中心在 C300_1 時間之前 24 小時到後 12 小時（每 6 小時），分別與提早 6 小時至 24 小時預報者報至各相同時間的 ATE 與 CTE。                                                                                          | 48 |
| 9  | Along_new_C300,<br>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 小時就出現符合 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  |
| 10 | Along_new_-24, ...,<br>Along_new_+12;<br>Cross_new_-24, ...,<br>Cross_new_+12                                                 | 本次預報颱風中心在 C300_1 時間之前 24 小時到後 12 小時（每 6 小時），與最新預報報至相同時間的 ATE 與 CTE。                                                                                                          | 12 |
| 11 | Along_Val_-24, ...,<br>Along_Val_C300, ...,<br>Along_Val_+12;<br>Cross_Val_-24, ...,<br>Cross_Val_C300, ...,<br>Cross_Val_+12 | 較本次提早 6 小時至 24 小時的前 4 次預報中，報至 C300_1 時間之前 24 小時、到後 12 小時（每 6 小時），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 小時預報之權重依序為 3, 3, 2, 1。<br>此加權平均值可代表前面幾次預報路徑的發散程度。 | 14 |

表三 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二中第 1-6 項所列者。




表四 同表三，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二中第 7-8 項所列的前一次與前兩次預報（前 6 與前 12 h）者。

|                |         |         |         |        |        |         |         |        |        |        |        |        |        |        |        |         |        |        |         |        |        |        |         |        |        |        |        |        |
|----------------|---------|---------|---------|--------|--------|---------|---------|--------|--------|--------|--------|--------|--------|--------|--------|---------|--------|--------|---------|--------|--------|--------|---------|--------|--------|--------|--------|--------|
| Along_obs_24   | -0.0021 | -0.12   | -0.12   | -0.12  | -0.061 | -0.049  | -0.12   | -0.058 | -0.051 | -0.074 | -0.063 | 0.0051 | -0.072 | 0.058  | 0.18   | 0.099   | 0.063  | 0.067  | 0.057   | -0.021 | -0.056 | 0.068  | -0.0012 | -0.023 | -0.01  | 0.062  | 0.08   | 0.056  |
| Along_obs_18   | -0.16   | -0.14   | -0.1    | -0.084 | -0.042 | -0.034  | -0.2    | 0.12   | 0.13   | 0.1    | 0.033  | 0.096  | 0.05   | 0.092  | -0.16  | -0.2    | -0.18  | -0.12  | -0.17   | -0.077 | -0.047 | 0.0091 | 0.057   | 0.02   | -0.031 | -0.034 | -0.025 | -0.052 |
| Along_obs_12   | 0.05    | -0.0057 | -0.029  | -0.001 | 0.1    | 0.015   | 0.045   | -0.14  | -0.16  | -0.11  | -0.092 | -0.04  | -0.11  | 0.09   | 0.084  | 0.046   | 0.033  | -0.066 | -0.029  | -0.038 | -0.11  | -0.1   | -0.088  | -0.053 | -0.023 | -0.063 |        |        |
| Along_obs_6    | 0.11    | 0.066   | 0.062   | 0.076  | 0.16   | 0.067   | 0.049   | -0.25  | -0.25  | -0.19  | -0.17  | -0.14  | -0.12  | -0.057 | 0.19   | 0.074   | 0.047  | 0.0071 | 0.062   | -0.07  | -0.047 | -0.19  | -0.26   | -0.23  | -0.23  | -0.18  | -0.14  | -0.16  |
| Along_obs_C300 | -0.083  | -0.091  | -0.15   | -0.047 | 0.029  | -0.0026 | 0.0049  | -0.22  | -0.21  | -0.22  | -0.22  | -0.15  | -0.17  | -0.11  | 0.041  | 0.031   | 0.023  | -0.011 | 0.05    | -0.052 | -0.14  | -0.14  | -0.21   | -0.23  | -0.23  | -0.15  | -0.15  | -0.18  |
| Along_obs_+6   | 0.0047  | -0.033  | -0.066  | 0.06   | 0.028  | 0.067   | 0.04    | -0.18  | -0.16  | -0.18  | -0.16  | -0.06  | -0.13  | -0.051 | -0.043 | -0.096  | -0.13  | -0.095 | -0.044  | -0.13  | -0.042 | -0.15  | -0.24   | -0.26  | -0.26  | -0.13  | -0.16  | -0.16  |
| Along_obs_+12  | -0.0052 | -0.074  | -0.06   | -0.068 | 0.0033 | 0.0088  | 0.074   | -0.079 | -0.098 | -0.12  | -0.12  | -0.096 | -0.16  | -0.1   | 0.065  | -0.082  | -0.095 | -0.16  | -0.093  | -0.15  | -0.073 | -0.12  | -0.12   | -0.15  | -0.18  | -0.15  | -0.13  | -0.13  |
| Cross_obs_24   | -0.1    | -0.1    | -0.1    | -0.095 | -0.087 | -0.044  | -0.09   | 0.18   | 0.16   | 0.11   | 0.11   | 0.019  | 0.085  | 0.1    | -0.22  | -0.19   | -0.2   | -0.18  | -0.18   | 0.012  | 0.012  | 0.038  | 0.11    | 0.083  | 0.096  | -0.018 | 0.051  | 0.12   |
| Cross_obs_18   | -0.094  | -0.07   | -0.087  | -0.085 | -0.089 | -0.028  | -0.097  | 0.18   | 0.15   | 0.13   | 0.14   | 0.064  | 0.13   | 0.12   | -0.21  | -0.17   | -0.18  | -0.16  | -0.17   | -0.011 | -0.025 | 0.096  | 0.14    | 0.12   | 0.14   | 0.034  | 0.11   | 0.15   |
| Cross_obs_12   | 0.0037  | -0.0069 | -0.046  | -0.034 | -0.044 | 0.033   | 0.0046  | 0.079  | 0.05   | 0.059  | 0.066  | 0.07   | 0.076  | 0.14   | 0.0074 | -0.0029 | -0.056 | -0.11  | -0.12   | -0.073 | 0.0059 | 0.089  | 0.089   | 0.1    | 0.092  | 0.074  | 0.15   | 0.14   |
| Cross_obs_6    | -0.0086 | -0.0084 | -0.037  | -0.027 | -0.051 | 0.02    | -0.0016 | 0.095  | 0.067  | 0.073  | 0.091  | 0.078  | 0.1    | 0.12   | -0.063 | -0.071  | -0.11  | -0.13  | -0.15   | -0.09  | 0.0068 | 0.075  | 0.076   | 0.086  | 0.091  | 0.057  | 0.13   | 0.13   |
| Cross_obs_C300 | -0.041  | 0.014   | -0.0045 | 0.0019 | -0.031 | 0.024   | -0.038  | 0.13   | 0.1    | 0.11   | 0.13   | 0.092  | 0.14   | 0.11   | -0.15  | -0.12   | -0.14  | -0.11  | -0.16   | -0.042 | 0.018  | 0.07   | 0.08    | 0.081  | 0.11   | 0.054  | 0.12   | 0.13   |
| Cross_obs_+6   | 0.0082  | 0.052   | 0.0076  | 0.049  | 0.014  | 0.066   | -0.015  | 0.1    | 0.069  | 0.082  | 0.11   | 0.087  | 0.14   | 0.12   | -0.09  | -0.062  | -0.09  | -0.064 | -0.11   | -0.091 | 0.037  | 0.075  | 0.07    | 0.075  | 0.11   | 0.078  | 0.14   | 0.16   |
| Cross_obs_+12  | 0.0063  | 0.065   | 0.032   | 0.085  | 0.028  | 0.082   | 0.029   | 0.053  | 0.037  | 0.052  | 0.085  | 0.084  | 0.14   | 0.13   | -0.057 | -0.021  | -0.053 | -0.02  | -0.07   | 0.015  | 0.068  | 0.055  | 0.042   | 0.052  | 0.087  | 0.1    | 0.12   | 0.17   |
| TS100          | -0.024  | -0.2    | -0.18   | -0.2   | -0.12  | -0.18   | -0.07   | -0.11  | -0.07  | -0.097 | -0.12  | -0.17  | -0.15  | -0.2   | -0.074 | -0.11   | -0.11  | -0.14  | -0.054  | -0.12  | -0.17  | -0.2   | -0.17   | -0.14  | -0.18  | -0.25  | -0.27  | -0.24  |
| TS200          | -0.011  | -0.14   | -0.14   | -0.15  | -0.013 | -0.085  | -0.061  | -0.11  | -0.075 | -0.11  | -0.14  | -0.2   | -0.17  | -0.24  | -0.054 | -0.08   | -0.083 | -0.1   | -0.01   | -0.033 | -0.1   | -0.2   | -0.16   | -0.13  | -0.18  | -0.25  | -0.29  | -0.25  |
| FSS            | 0.0099  | -0.16   | -0.14   | -0.15  | -0.051 | -0.11   | -0.019  | -0.18  | -0.14  | -0.14  | -0.14  | -0.19  | -0.18  | -0.19  | 0.014  | -0.058  | -0.053 | -0.11  | -0.0043 | -0.08  | -0.11  | -0.24  | -0.21   | -0.18  | -0.2   | -0.28  | -0.26  | -0.26  |

**表五** 同表三，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二中第 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 | TS100  | TS200    | RSS    |
|----------------|--------------|--------------|--------------|-------------|----------------|--------------|---------------|--------------|--------------|--------------|-------------|----------------|--------------|---------------|--------|----------|--------|
| Along_18_24    | 0.047        | 0.019        | -0.011       | 0.15        | 0.12           | 0.0012       | 0.03          | 0.11         | 0.053        | -0.016       | 0.049       | 0.052          | 0.06         | 0.071         | 0.079  | 0.074    | 0.077  |
| Along_18_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         | -0.13  | -0.15    | -0.076 |
| Along_18_12    | 0.18         | 0.13         | 0.097        | 0.14        | 0.095          | -0.0073      | 0.018         | 0.043        | -0.067       | -0.1         | -0.041      | -0.05          | -0.047       | -0.06         | 0.19   | 0.13     | 0.17   |
| Along_18_6     | 0.2          | 0.11         | 0.081        | 0.1         | 0.078          | -0.0023      | -0.031        | -0.088       | -0.19        | -0.2         | -0.13       | -0.15          | -0.12        | -0.12         | 0.01   | 0.1      | 0.067  |
| 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 | -0.00085 | -0.012 |
| 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  |
| Along_obs_+12  | 0.069        | -0.079       | -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 |
| 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  |
| Cross_obs_18   | -0.21        | -0.19        | -0.18        | -0.24       | -0.27          | -0.086       | -0.016        | -0.067       | -0.012       | 0.0023       | -0.011      | -0.046         | 0.046        | 0.041         | -0.21  | -0.3     | -0.28  |
| 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 |
| 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       | 0.088          | 0.11         | 0.1           | -0.081 | -0.19    | -0.14  |
| 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        | 0.081        | 0.068         | -0.12  | -0.25    | -0.22  |
| 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  |
| 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  |
| TS100          | -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  |
| 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 | -0.067   | -0.071 |
| RSS            | -0.035       | -0.059       | -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 |
| Along_24_24    | 0.061        | -0.071       | -0.091       | -0.14       | -0.11          | -0.11        | -0.14         | -0.081       | -0.19        | -0.14        | -0.23       | -0.23          | -0.23        | -0.23         | -0.081 | -0.19    | -0.14  |
| Along_24_18    | -0.026       | -0.028       | -0.033       | -0.033      | 0.023          | 0.02         | 0.0062        | -0.079       | -0.079       | -0.14        | -0.15       | -0.21          | -0.24        | -0.23         | -0.091 | -0.11    | -0.15  |
| Along_24_12    | 0.039        | 0.033        | 0.023        | 0.023       | 0.02           | 0.0062       | -0.079        | -0.079       | -0.14        | -0.15        | -0.21       | -0.24          | -0.23        | -0.23         | -0.091 | -0.11    | -0.15  |
| Along_24_6     | 0.038        | 0.033        | 0.023        | 0.023       | 0.02           | 0.0062       | -0.079        | -0.079       | -0.14        | -0.15        | -0.21       | -0.24          | -0.23        | -0.23         | -0.091 | -0.11    | -0.15  |
| Along_24_C300  | 0.03         | 0.0075       | -0.031       | -0.031      | -0.031         | -0.031       | -0.031        | -0.031       | -0.031       | -0.031       | -0.031      | -0.031         | -0.031       | -0.031        | -0.031 | -0.031   | -0.031 |
| Along_24_+6    | 0.0075       | -0.031       | -0.031       | -0.031      | -0.031         | -0.031       | -0.031        | -0.031       | -0.031       | -0.031       | -0.031      | -0.031         | -0.031       | -0.031        | -0.031 | -0.031   | -0.031 |
| Along_24_+12   | -0.031       | -0.031       | -0.031       | -0.031      | -0.031         | -0.031       | -0.031        | -0.031       | -0.031       | -0.031       | -0.031      | -0.031         | -0.031       | -0.031        | -0.031 | -0.031   | -0.031 |
| Cross_24_24    | -0.21        | -0.24        | -0.24        | -0.24       | -0.24          | -0.24        | -0.24         | -0.24        | -0.24        | -0.24        | -0.24       | -0.24          | -0.24        | -0.24         | -0.24  | -0.24    | -0.24  |
| Cross_24_18    | -0.13        | -0.091       | -0.11        | -0.11       | -0.11          | -0.11        | -0.11         | -0.11        | -0.11        | -0.11        | -0.11       | -0.11          | -0.11        | -0.11         | -0.11  | -0.11    | -0.11  |
| Cross_24_12    | -0.15        | -0.11        | -0.11        | -0.11       | -0.11          | -0.11        | -0.11         | -0.11        | -0.11        | -0.11        | -0.11       | -0.11          | -0.11        | -0.11         | -0.11  | -0.11    | -0.11  |
| Cross_24_6     | -0.21        | -0.22        | -0.22        | -0.22       | -0.22          | -0.22        | -0.22         | -0.22        | -0.22        | -0.22        | -0.22       | -0.22          | -0.22        | -0.22         | -0.22  | -0.22    | -0.22  |
| Cross_24_C300  | -0.26        | -0.26        | -0.26        | -0.26       | -0.26          | -0.26        | -0.26         | -0.26        | -0.26        | -0.26        | -0.26       | -0.26          | -0.26        | -0.26         | -0.26  | -0.26    | -0.26  |
| Cross_24_+6    | -0.26        | -0.24        | -0.23        | -0.23       | -0.23          | -0.23        | -0.23         | -0.23        | -0.23        | -0.23        | -0.23       | -0.23          | -0.23        | -0.23         | -0.23  | -0.23    | -0.23  |
| Cross_24_+12   | -0.29        | -0.27        | -0.28        | -0.28       | -0.28          | -0.28        | -0.28         | -0.28        | -0.28        | -0.28        | -0.28       | -0.28          | -0.28        | -0.28         | -0.28  | -0.28    | -0.28  |

表六 同表三，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二中第 9-11 項所列者。



**表七** 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  | SRRSS   | 128  | 0.272 | 0.240 | 0.214 | 0.199 | 0.185 | 0.171 | 0.160 | 0.147 | 0.126 |
|    |         | 256  | 0.258 | 0.231 | 0.210 | 0.193 | 0.176 | 0.164 | 0.154 | 0.140 | 0.125 |
|    |         | 512  | 0.253 | 0.224 | 0.204 | 0.188 | 0.176 | 0.164 | 0.151 | 0.136 | 0.121 |
|    |         | 1024 | 0.273 | 0.238 | 0.217 | 0.197 | 0.183 | 0.170 | 0.156 | 0.143 | 0.122 |
| 5  | SRSRS   | 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 |
| 6  | SRSRSS  | 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 |
| 7  | SRSRSRS | 128  | 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 |

表八 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 TS 值與實際 TS 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    |
| TS100 |        |      |       |       |       |       |       |       |       |       |       |
| 4     | SRRS   | 128  | 0.311 | 0.262 | 0.214 | 0.172 | 0.143 | 0.119 | 0.101 | 0.077 | 0.055 |
|       |        | 256  | 0.295 | 0.254 | 0.213 | 0.164 | 0.131 | 0.111 | 0.095 | 0.076 | 0.056 |
|       |        | 512  | 0.287 | 0.257 | 0.217 | 0.155 | 0.128 | 0.111 | 0.094 | 0.077 | 0.054 |
| 4     | SRSS   | 128  | 0.309 | 0.252 | 0.202 | 0.164 | 0.135 | 0.112 | 0.093 | 0.074 | 0.052 |
|       |        | 256  | 0.294 | 0.249 | 0.210 | 0.161 | 0.126 | 0.105 | 0.087 | 0.071 | 0.051 |
|       |        | 512  | 0.291 | 0.261 | 0.217 | 0.150 | 0.122 | 0.100 | 0.080 | 0.064 | 0.039 |
| 5     | SRRSS  | 128  | 0.308 | 0.258 | 0.211 | 0.173 | 0.137 | 0.118 | 0.101 | 0.082 | 0.058 |
|       |        | 256  | 0.294 | 0.263 | 0.214 | 0.153 | 0.124 | 0.107 | 0.091 | 0.074 | 0.054 |
|       |        | 512  | 0.291 | 0.254 | 0.212 | 0.149 | 0.118 | 0.102 | 0.090 | 0.074 | 0.054 |
|       |        | 1024 | 0.298 | 0.257 | 0.213 | 0.154 | 0.125 | 0.107 | 0.093 | 0.078 | 0.052 |
| 5     | SRSRS  | 128  | 0.304 | 0.257 | 0.206 | 0.165 | 0.137 | 0.116 | 0.096 | 0.077 | 0.055 |
|       |        | 256  | 0.290 | 0.249 | 0.206 | 0.152 | 0.130 | 0.112 | 0.094 | 0.080 | 0.059 |
|       |        | 512  | 0.286 | 0.252 | 0.211 | 0.152 | 0.124 | 0.105 | 0.091 | 0.074 | 0.050 |
|       |        | 1024 | 0.315 | 0.257 | 0.224 | 0.178 | 0.131 | 0.111 | 0.092 | 0.074 | 0.046 |
| TS200 |        |      |       |       |       |       |       |       |       |       |       |
| 4     | SRRS   | 128  | 0.228 | 0.194 | 0.171 | 0.153 | 0.134 | 0.113 | 0.091 | 0.071 | 0.046 |
|       |        | 256  | 0.212 | 0.185 | 0.166 | 0.146 | 0.129 | 0.112 | 0.096 | 0.076 | 0.047 |
|       |        | 512  | 0.207 | 0.179 | 0.161 | 0.144 | 0.126 | 0.111 | 0.093 | 0.075 | 0.050 |
| 4     | SRSS   | 128  | 0.228 | 0.189 | 0.167 | 0.147 | 0.131 | 0.110 | 0.091 | 0.069 | 0.044 |
|       |        | 256  | 0.211 | 0.184 | 0.165 | 0.144 | 0.127 | 0.110 | 0.088 | 0.066 | 0.043 |
|       |        | 512  | 0.204 | 0.179 | 0.159 | 0.142 | 0.124 | 0.109 | 0.087 | 0.065 | 0.040 |
| 5     | SRRSS  | 128  | 0.230 | 0.197 | 0.171 | 0.149 | 0.132 | 0.113 | 0.094 | 0.071 | 0.048 |
|       |        | 256  | 0.214 | 0.180 | 0.156 | 0.139 | 0.125 | 0.108 | 0.091 | 0.070 | 0.048 |
|       |        | 512  | 0.201 | 0.170 | 0.152 | 0.139 | 0.126 | 0.111 | 0.093 | 0.077 | 0.053 |
|       |        | 1024 | 0.215 | 0.182 | 0.160 | 0.144 | 0.129 | 0.115 | 0.096 | 0.077 | 0.052 |
| 5     | SRSRS  | 128  | 0.234 | 0.193 | 0.169 | 0.149 | 0.129 | 0.110 | 0.089 | 0.068 | 0.049 |
|       |        | 256  | 0.216 | 0.184 | 0.160 | 0.143 | 0.130 | 0.115 | 0.095 | 0.073 | 0.049 |
|       |        | 512  | 0.208 | 0.176 | 0.155 | 0.140 | 0.126 | 0.114 | 0.096 | 0.074 | 0.050 |
|       |        | 1024 | 0.203 | 0.175 | 0.152 | 0.137 | 0.126 | 0.112 | 0.096 | 0.076 | 0.054 |

**表九** 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 ATE 與 CTE 值與實際 ATE 與 CTE 值的差異絕對值，單位為 100km，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    |
| ATE |        |      |       |       |       |       |       |       |       |       |       |
| 4   | SRRS   | 128  | 1.699 | 1.519 | 1.338 | 1.370 | 1.257 | 1.026 | 0.906 | 0.816 | 0.766 |
|     |        | 256  | 1.619 | 1.479 | 1.333 | 1.330 | 1.197 | 0.986 | 0.876 | 0.811 | 0.771 |
|     |        | 512  | 1.579 | 1.494 | 1.353 | 1.285 | 1.182 | 0.986 | 0.871 | 0.816 | 0.761 |
| 4   | SRSS   | 128  | 1.689 | 1.469 | 1.278 | 1.330 | 1.217 | 0.991 | 0.866 | 0.801 | 0.751 |
|     |        | 256  | 1.614 | 1.454 | 1.318 | 1.315 | 1.172 | 0.956 | 0.836 | 0.786 | 0.746 |
|     |        | 512  | 1.599 | 1.514 | 1.353 | 1.260 | 1.152 | 0.931 | 0.801 | 0.751 | 0.686 |
| 5   | SRRSS  | 128  | 1.684 | 1.499 | 1.323 | 1.375 | 1.227 | 1.021 | 0.906 | 0.841 | 0.781 |
|     |        | 256  | 1.614 | 1.524 | 1.338 | 1.275 | 1.162 | 0.966 | 0.856 | 0.801 | 0.761 |
|     |        | 512  | 1.603 | 1.481 | 1.319 | 1.254 | 1.151 | 0.945 | 0.855 | 0.807 | 0.759 |
|     |        | 1024 | 1.634 | 1.494 | 1.333 | 1.280 | 1.167 | 0.966 | 0.866 | 0.821 | 0.751 |
| 5   | SRSRS  | 128  | 1.664 | 1.494 | 1.298 | 1.335 | 1.227 | 1.011 | 0.881 | 0.816 | 0.766 |
|     |        | 256  | 1.594 | 1.454 | 1.298 | 1.270 | 1.192 | 0.991 | 0.871 | 0.831 | 0.786 |
|     |        | 512  | 1.569 | 1.468 | 1.331 | 1.270 | 1.143 | 0.952 | 0.852 | 0.794 | 0.743 |
|     |        | 1024 | 1.719 | 1.494 | 1.388 | 1.400 | 1.197 | 0.986 | 0.861 | 0.801 | 0.721 |
| CTE |        |      |       |       |       |       |       |       |       |       |       |
| 4   | SRRS   | 128  | 0.888 | 0.835 | 0.799 | 0.691 | 0.641 | 0.589 | 0.543 | 0.481 | 0.433 |
|     |        | 256  | 0.820 | 0.787 | 0.755 | 0.651 | 0.601 | 0.569 | 0.519 | 0.461 | 0.429 |
|     |        | 512  | 0.840 | 0.795 | 0.751 | 0.639 | 0.593 | 0.545 | 0.495 | 0.433 | 0.389 |
| 4   | SRSS   | 128  | 0.888 | 0.835 | 0.783 | 0.675 | 0.633 | 0.601 | 0.551 | 0.445 | 0.405 |
|     |        | 256  | 0.844 | 0.819 | 0.759 | 0.647 | 0.601 | 0.573 | 0.523 | 0.469 | 0.429 |
|     |        | 512  | 0.880 | 0.843 | 0.787 | 0.663 | 0.617 | 0.577 | 0.523 | 0.461 | 0.413 |
| 5   | SRRSS  | 128  | 0.872 | 0.823 | 0.759 | 0.659 | 0.617 | 0.581 | 0.543 | 0.493 | 0.433 |
|     |        | 256  | 0.816 | 0.787 | 0.743 | 0.635 | 0.581 | 0.553 | 0.519 | 0.465 | 0.429 |
|     |        | 512  | 0.796 | 0.767 | 0.730 | 0.625 | 0.584 | 0.546 | 0.497 | 0.449 | 0.403 |
|     |        | 1024 | 0.876 | 0.815 | 0.771 | 0.651 | 0.609 | 0.577 | 0.527 | 0.477 | 0.417 |
| 5   | SRSRS  | 128  | 0.888 | 0.839 | 0.783 | 0.667 | 0.629 | 0.589 | 0.539 | 0.481 | 0.433 |
|     |        | 256  | 0.812 | 0.783 | 0.739 | 0.631 | 0.589 | 0.557 | 0.515 | 0.469 | 0.429 |
|     |        | 512  | 0.788 | 0.760 | 0.724 | 0.614 | 0.578 | 0.535 | 0.485 | 0.442 | 0.399 |
|     |        | 1024 | 0.824 | 0.795 | 0.751 | 0.643 | 0.597 | 0.565 | 0.511 | 0.449 | 0.397 |

表十 對所有颱風個案與所有預報各輸出 100 組後，預估之 SSS、TS100、TS200 與實際值之平均值、標準差、中位數。

|            | 平均值   | 中位數   | 標準差   |
|------------|-------|-------|-------|
| 實際預報 SSS   | 0.659 | 0.705 | 0.231 |
| 模型預估 SSS   | 0.614 | 0.652 | 0.170 |
| 實際預報 TS100 | 0.512 | 0.545 | 0.226 |
| 模型預估 TS100 | 0.465 | 0.479 | 0.160 |
| 實際預報 TS200 | 0.345 | 0.320 | 0.235 |
| 模型預估 TS200 | 0.304 | 0.293 | 0.177 |



表十一 機器學習針對各颱風個案所產生一百組模型後，實際 SSS 與 TS 值與模型預估之 SSS 與 TS100 值絕對誤差的第一四分位(25%)、中位數(50%)、與第三四分位值(75%)。

| 個案  | SSS   |       |       | TS100 |       |       | TS200 |       |       |
|-----|-------|-------|-------|-------|-------|-------|-------|-------|-------|
|     | 25%   | 50%   | 75%   | 25%   | 50%   | 75%   | 25%   | 50%   | 75%   |
| 尼伯特 | 0.194 | 0.224 | 0.245 | 0.211 | 0.226 | 0.244 | 0.228 | 0.211 | 0.193 |
| 蘇迪勒 | 0.114 | 0.128 | 0.148 | 0.135 | 0.154 | 0.171 | 0.110 | 0.102 | 0.091 |
| 杜鵑  | 0.120 | 0.136 | 0.166 | 0.106 | 0.126 | 0.154 | 0.185 | 0.146 | 0.112 |
| 蘇力  | 0.156 | 0.171 | 0.188 | 0.170 | 0.198 | 0.215 | 0.243 | 0.230 | 0.207 |
| 麥德姆 | 0.139 | 0.160 | 0.182 | 0.108 | 0.122 | 0.146 | 0.125 | 0.109 | 0.094 |
| 莫蘭蒂 | 0.127 | 0.144 | 0.161 | 0.169 | 0.184 | 0.196 | 0.161 | 0.145 | 0.135 |
| 蘇拉  | 0.172 | 0.184 | 0.208 | 0.242 | 0.255 | 0.276 | 0.284 | 0.268 | 0.250 |
| 昌鴻  | 0.392 | 0.403 | 0.420 | 0.354 | 0.374 | 0.393 | 0.311 | 0.290 | 0.269 |
| 天兔  | 0.219 | 0.244 | 0.277 | 0.211 | 0.230 | 0.250 | 0.319 | 0.296 | 0.277 |
| 菲特  | 0.189 | 0.218 | 0.252 | 0.133 | 0.146 | 0.160 | 0.130 | 0.123 | 0.112 |

表十二 經機器學習修正前(原始)後(修正)，不同預報時間長度、全部預報與最新一次預報的平均 CTE、ATE、及 TE 絕對值變化 (km)。

| 預報期限   | 0-5 h | 6-11 h | 12-17 h | 18-23 h | 24-29 h<br>C300_1 | 30-35 h | 36-41 h |
|--------|-------|--------|---------|---------|-------------------|---------|---------|
| 全部預報   |       |        |         |         |                   |         |         |
| 原始 CTE | 62.0  | 70.1   | 74.0    | 77.3    | 96.8              | 118.5   | 137.7   |
| 修正 CTE | 43.8  | 46.4   | 52.3    | 43.4    | 51.6              | 68.3    | 95.5    |
| 原始 ATE | 94.0  | 96.5   | 99.1    | 105.0   | 119.7             | 141.6   | 170.5   |
| 修正 ATE | 50.2  | 58.7   | 41.3    | 73.1    | 103.0             | 102.8   | 93.8    |
| 最新預報   |       |        |         |         |                   |         |         |
| 原始 CTE | 10.4  | 18.9   | 24.9    | 34.7    | 44.5              | 55.0    | 60.2    |
| 修正 CTE | 11.0  | 18.6   | 18.5    | 25.3    | 30.9              | 52.8    | 70.1    |
| 原始 ATE | 16.9  | 27.9   | 28.9    | 31.8    | 30.3              | 41.8    | 58.5    |
| 修正 ATE | 46.8  | 52.3   | 35.5    | 65.2    | 90.0              | 86.7    | 66.7    |
| 原始 TE  | 19.9  | 33.7   | 38.2    | 47.0    | 53.8              | 69.1    | 84.0    |
| 修正 TE  | 48.1  | 55.6   | 40.0    | 69.9    | 95.1              | 101.6   | 96.7    |

表十三 移除部分參數進行敏感度測試，移除1為移除表二第1-2項，移除2為移除表二第3-4項，移除3為移除表二第5-6項，移除4為移除表二第7-8項，移除5為移除表二第9-10項，移除6為移除表二第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 |






FIG. 13. Averaged TS of CReSS 24-h QPFs from forecasts at 0000 and 1200 UTC for (a) day 1 (0–24 h), (b) day 2 (24–48 h), and (c) day 3 (48–72 h) for groups A–D and the top-5 cases (see legends) as a function of rainfall threshold (mm). Day-1 QPFs are from forecasts starting at the beginning of the 24-h periods of verification, and day-2 and day-3 QPFs are from forecasts starting 24 and 48 h earlier, respectively (i.e., targeting the same periods). The top-5 cases (from group A) are the most-rainy 24-h period from the five most-rainy TCs (one segment from each, Table 2). The group sizes (of available segments) are labeled for selected points. The unweighted (arithmetic) averages (labeled as “Avg”) and the TS values obtained by combining all the forecasts into just one contingency table (labeled as “All”) are also plotted, and the purple dots depict the forecasts for TY Morakot in 2009 (for 0000–2400 UTC 8 Aug, days 1–2 only, see Table 4).

圖 1 圖中顯示了研究時間內 CReSS 24 小時定量降水預報於不同降雨閾值的平均 TS 值，橫軸為降水閾值，縱軸為 TS 值，分別對 (a) 第 1 天 (0–24 小時)，(b) 第 2 天 (24–48 小時)，和 (c) 第 3 天 (48–72 小時)，自總降水高排至低分別有莫拉克 (2009) 颱風、降水最多前五名的颱風與 A–D 組颱風。(W15)




FIG. 2. The predicted typhoon location distribution (black dots) in 3-h intervals from the EPS. Each predicted typhoon location is associated with a 3-h accumulated model QPF; an example is shown in the top-right corner. The red line and black circle are the given typhoon track with 3-h intervals and a radius of 30 km centered at each typhoon position, respectively.

圖 2 系集預報系統預測以 3 小時為間隔的颱風中心位置分佈。每個黑點都代表了一該預測颱風中心位置與所帶來的 3 小時累積降水；右上角展示了一個範例。紅線和黑圈分別代表給定的颱風軌跡，以及每個颱風位置為中心半徑為 30 公里的範圍。(Hong et al., 2015)

TABLE 1. (top) The five major items desired from the forecasts for hazard preparation for typhoons in Taiwan: rainfall, track, intensity, striking probability, and lead time, and their general quality provided by (second column) regional low-resolution ensemble forecasts vs (third column) high-resolution (and cloud resolving) deterministic forecasts utilizing similar resources. Four descriptive levels are used for general quality (very good, good, avg, and poor). The fourth column gives the quality for the five items from 2.5-km cloud-resolving forecasts by CReSS using a time-lagged ensemble. (bottom) The basic model specifications (resolution, domain size, forecast range, and forecast frequency) between a typical 24-member ensemble and time-lagged ensemble, both using about 1500 cores, are compared.

|                      | Low-resolution ensemble forecasts | High-resolution deterministic forecasts | High-resolution forecasts using time-lagged ensemble |
|----------------------|-----------------------------------|-----------------------------------------|------------------------------------------------------|
| Rainfall             | Avg                               | Very good                               | Very good                                            |
| Track                | Avg                               | Good                                    | Very good                                            |
| Intensity            | Avg                               | Good                                    | Good                                                 |
| Striking probability | Avg                               | —                                       | Good/very good                                       |
| Lead time            | Avg                               | Poor                                    | Very good                                            |
| Grid spacing         | 5 km                              | —                                       | 2.5 km                                               |
| Fine-domain size     | 750 km × 900 km                   | —                                       | 1860 km × 1360 km                                    |
| Forecast range       | 3 days (72 h)                     | —                                       | 8 days (192 h)                                       |
| Forecast frequency   | Every 6 h                         | —                                       | Every 6 h                                            |

圖 3 臺灣在颱風防災於數值天氣預報中所需的五個項目：降雨量、颱風路徑、颱風強度、襲擊機率和準備時間，用於描述提供了四種等級（非常好、好、平均和差）。（W16）






圖 4 CReSS 模式雲微物理現象的冷雲過程。(Tsuboki and Sakakibara, 2007)






圖 5 展示了(a)多成員系集預測策略(20 個成員，每 6 小時進行一次，總共預測 3 天)和(b)差時系集預測策略(每 6 小時進行一次，總共預測 8 天)在相同計算資源條件下的比較，模型的定量降水預報的目標日期以黃色區域並搭配橙色邊線來表示。因為不用分散資源的關係，差時系集策略可以在保持相同的預測範圍下，同時達成更高的解析度與更大的精確預測範圍。(W16)




圖 6 颱風路徑誤差示意圖。圖中 $x_0$ 與 $y_0$ 代表觀測路徑前一時間點的經緯度， $x_1$ 與 $y_1$ 代表觀測路徑於目標時間之經緯度，而 $x$ 與 $y$ 則為預報路徑在目標時間之經緯度。路徑誤差 (track error)、移速誤差 (along-track error)、及移向誤差 (cross-track error) 皆如圖所示。






圖 7 不同初始時間預報尼伯特颱風的 (a) 差時系集預報路徑, (b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上各符號為逐日 0000 UTC 之颱風中心位置, X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 7 月 4 日至 7 月 9 日, 觀測路徑為 JTWC 並標示為黑色。尼伯特颱風觀測定義的影響期間為 7 月 7 日 0500 UTC 至 7 月 9 日 1300 UTC, 長度共 56 小時。預報降水為不同初始時間預報在各自影響期間之降水 (色階與觀測相同), 其初始時間、實際 SSS、實際 TS100、及降水累積時段皆示於各圖下方。




圖 7(續) 不同初始時間預報尼伯特颱風的預報降水分布。




圖 8 同圖 7 但為蘇迪勒颱風之 (a) 差時系集預報路徑, (b) 觀測降水與降水最大值 (mm) (c) 預報降水分布。預報路徑上, X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 8 月 5 日到 8 月 10 日。本個案由觀測定義之影響期間為 8 月 7 日 1100 UTC 至 8 月 8 日 1900 UTC, 長度共 32 小時。預報降水為預報在各自影響期間之降水(色階與觀測相同)。




圖 8(續) 不同初始時間預報蘇迪勒颱風的預報降水分布。




圖 9 同圖 7 但為杜鵑颱風之(a) 差時系集預報路徑，(b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上，X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 9 月 25 日到 9 月 30 日。本個案由觀測定義之影響期間為 9 月 27 日 2200 UTC 至 9 月 29 日 0600 UTC，共 32 小時。




圖 9(續) 不同初始時間預報杜鵑颱風的預報降水分布。




圖 10 同圖 7 但為蘇力颱風之(a) 差時系集預報路徑, (b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上, X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 7 月 9 日到 7 月 14 日。本個案由觀測定義之影響期間為 7 月 12 日 0900 UTC 至 7 月 13 日 1300 UTC, 共 28 小時。




圖 10 (續) 不同初始時間預報蘇力颱風的預報降水分布。






圖 11 同圖 7 但為麥德姆颱風之(a) 差時系集預報路徑，(b) 觀測降水與降水最大值 (mm) (c) 預報降水分布。預報路徑上，X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 7 月 20 日到 7 月 25 日。本個案由觀測定義之影響期間為 7 月 22 日 0300 UTC 至 7 月 23 日 1500 UTC，共 36 小時。




圖 11(續) 不同初始時間預報麥德姆颱風的預報降水分布。




圖 12 同圖 7 但為莫蘭蒂颱風之(a) 差時系集預報路徑，(b) 觀測降水與降水最大值 (mm) (c) 預報降水分布。預報路徑上，X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 9 月 10 日到 9 月 15 日。本個案由觀測定義之影響期間為 9 月 13 日 1200 UTC 至 9 月 15 日 0000 UTC，共 36 小時。




圖 12(續) 不同初始時間預報莫蘭蒂颱風的預報降水分布。




圖 13 同圖 7 但為蘇拉颱風之(a) 差時系集預報路徑, (b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上, X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 7 月 29 日到 8 月 3 日。本個案由觀測定義之影響期間為 7 月 31 日 1600 UTC 至 8 月 3 日 0200 UTC, 共 58 小時。




圖 13(續) 不同初始時間預報蘇拉颱風的預報降水分布。




圖 14 同圖 7 但為昌鴻颱風之(a) 差時系集預報路徑, (b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上, X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 7 月 8 日到 7 月 13 日。本個案由觀測定義之影響期間為 7 月 10 日 0500 UTC 至 7 月 10 日 2300 UTC, 共 18 小時。




圖 14(續) 不同初始時間預報昌鴻颱風的預報降水分布。




圖 15 同圖 7 但為天兔颱風之(a) 差時系集預報路徑, (b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上, X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 9 月 17 日到 9 月 22 日。本個案由觀測定義之影響期間為 9 月 20 日 1600 UTC 至 9 月 22 日 0400 UTC, 共 36 小時。




圖 15(續) 不同初始時間預報天兔颱風的預報降水分布。




圖 16 同圖 7 但為菲特颱風之(a) 差時系集預報路徑, (b) 觀測降水與降水最大值(mm) (c) 預報降水分布。預報路徑上, X 形、六芒星、五邊形、正圓形、正方形與菱形依序分別表示 10 月 2 日到 10 月 7 日。本個案由觀測定義之影響期間為 10 月 5 日 2000 UTC 至 10 月 6 日 2300 UTC, 長度共 27 小時。




圖 16(續) 不同初始時間預報菲特颱風的預報降水分布。






圖 17 模式預報實際 SSS（紅）與機器學習模型預估 SSS（藍）的分佈百分比。






圖 18 針對尼伯特颱風(a)與蘇迪勒颱風(b)，於不同初始時間的預報（橫軸，日期與 UTC 時）在其颱風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）。




圖 19 針對杜鵑颱風(a)與蘇力颱風(b)，於不同初始時間的預報（橫軸，日期與 UTC 時）在其颱風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）。




圖 20 針對麥德姆颱風(a)與莫蘭蒂颱風(b)，於不同初始時間的預報（橫軸，日期與 UTC 時）在其颱風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）。




圖 21 針對蘇拉颱風(a)與昌鴻颱風(b)，於不同初始時間的預報（橫軸，日期與 UTC 時）在其颱風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）。




圖 22 針對天兔颱風(a)與菲特颱風(b)，於不同初始時間的預報（橫軸，日期與 UTC 時）在其颱風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）。




圖 23 針對尼伯特颱風(a)與蘇迪勒颱風(b)，於不同初始時間的預報（橫軸，日期與 UTC 時）在其颱風影響期間降水的實際 TS100（紅）與機器學習預估的第 90、50、及 10 百分位值（深至淺藍）。




圖 24 針對杜鵑颱風(a)與蘇力颱風(b)，於不同初始時間的預報（橫軸，日期與 UTC 時）在其颱風影響期間降水的實際 TS100（紅）與機器學習預估的第 90、50、及 10 百分位值（深至淺藍）。




圖 25 針對麥德姆颱風(a)與莫蘭蒂颱風(b)，於不同初始時間的預報（橫軸，日期與 UTC 時）在其颱風影響期間降水的實際 TS100（紅）與機器學習預估的第 90、50、及 10 百分位值（深至淺藍）。




圖 26 針對蘇拉颱風(a)與昌鴻颱風(b)，於不同初始時間的預報（橫軸，日期與 UTC 時）在其颱風影響期間降水的實際 TS100（紅）與機器學習預估的第 90、50、及 10 百分位值（深至淺藍）。




圖 27 針對菲特颱風(a)與天兔颱風(b)，於不同初始時間的預報（橫軸，日期與 UTC 時）在其颱風影響期間降水的實際 TS100（紅）與機器學習預估的第 90、50、及 10 百分位值（深至淺藍）。