

國立中央大學

大氣科學學系

碩士論文

使用深度神經網路預測弱綜觀環境下午後強對
流及肇始-以 WRF 系集資料進行系統建置

Using Deep Neural Networks to predict afternoon
thunderstorm and initiation under weak synoptic forcing
- model development using WRF ensembles

研究生：黃展皇

指導教授：廖宇慶 博士

中華民國 112 年 06 月

國立中央大學圖書館學位論文授權書

填單日期：_2023_/_07_/_25_

2019.9 版

授權人姓名	黃展皇	學號	110621013
系所名稱	大氣科學學系大氣物理碩士班	學位類別	<input checked="" type="checkbox"/> 碩士 <input type="checkbox"/> 博士
論文名稱	使用深度神經網路預測弱綜觀午後強對流肇始 - 以 WRF 系集資料進行系統建置	指導教授	廖宇慶教授

學位論文網路公開授權

授權本人撰寫之學位論文全文電子檔：

- 在「國立中央大學圖書館博碩士論文系統」。
 - () 同意立即網路公開
 - () 同意 於西元_____年_____月_____日網路公開
 - () 不同意網路公開，原因是：_____
- 在國家圖書館「臺灣博碩士論文知識加值系統」
 - () 同意立即網路公開
 - () 同意 於西元_____年_____月_____日網路公開
 - () 不同意網路公開，原因是：_____

依著作權法規定，非專屬、無償授權國立中央大學、台灣聯合大學系統與國家圖書館，不限地域、時間與次數，以文件、錄影帶、錄音帶、光碟、微縮、數位化或其他方式將上列授權標的基於非營利目的進行重製。

學位論文紙本延後公開申請 (紙本學位論文立即公開者此欄免填)

本人撰寫之學位論文紙本因以下原因將延後公開

- 延後原因
 - () 已申請專利並檢附證明，專利申請案號：
 - () 準備以上列論文投稿期刊
 - () 涉國家機密
 - () 依法不得提供，請說明：_____
- 公開日期：西元_____年_____月_____日

※繳交教務處註冊組之紙本論文(送繳國家圖書館)若不立即公開，請加填「國家圖書館學位論文延後公開申請書」

研究生簽名：

黃展皇

指導教授簽名：

廖宇慶

國立中央大學碩士班研究生

論文指導教授推薦書

大氣科學學系大氣物理研究所 學系/研究所 黃

展皇 研究生所提之論文 使用深度神經網路預測弱

綜觀午後強對流肇始 - 以 WRF 系集資料進行系統建

置 係由本人指導撰述，同意提付審查。

指導教授 廖宇慶 (簽章)

112 年 6 月 22 日

國立中央大學碩士班研究生
論文口試委員審定書

大氣科學學系大氣物理碩士班 學系/研究所 黃展皇 研究生
所提之論文 使用深度神經網路預測弱綜觀環境下午後強對流及
肇始-以WRF系集資料進行系統建置

經由委員會審議，認定符合碩士資格標準。

學位考試委員會召集人

委

員

陳柏宇

廖宇慶

鍾高陞

中華民國 112 年 7 月 14 日

摘要

台灣夏季在弱綜觀情況下，午後常有致災性且難以預報的強對流事件發生，因此快速且準確預測對流事件的肇始(Convection Initiation, CI)相當重要。由於小尺度強對流具有非線性特性，而深度神經網路(Deep Neural Networks, DNN)具備擬合非線性函數的能力，因此本研究針對弱綜觀強對流事件進行 WRF (Weather Research and Forecasting)系集模擬，採用 OSSE (Observing System Simulation Experiment)架構取得各式變數，並經過詳細的個案分析、預測目標定義與資料處理後再使用 DNN 進行強對流或 CI 的一小時預報，並且針對 DNN 進行多種如 SHAP (SHapley Additive exPlanations)分析得知各變數的重要性，並依此展開許多面向的探討。

本研究經過許多討論，可提供 DNN 系統參數等建置以及資料選用與處理的指南，且使用了許多不同面向的驗證方法，包括客觀分數、繪圖疊圖分析、性能圖、SHAP 分析、persisFail 實驗、坐標系測試實驗以及敏感度測試實驗，對模型性能、預測傾向以及變數重要性做了一系列討論並得出結果，變數重要性分析上與前人對於 CI 的統計結果接近，另外還考慮了提升 DNN 預報能力的方法例如加入空間相關的變數，以及在不同個案上應用的問題以及提出混合訓練的解決方式，最後預測表現雖無法與模糊邏輯做比較但顯著優於外延法，且僅需要以純測站變數組合即可快速應用於實際資料，若以中央氣象局標準將鄉鎮市行政區視為最小預報單位的情形，使用純測站可取得的資料進行變數組合，ETS (Equitable Threat Score)的預報得分對強對流為 0.338，對 CI 為 0.333，且 ETS 與事件發生頻率僅呈現低度正相關。

Abstract

During Taiwan's weak synoptic summer, there are often unpredictable and disastrous strong convective events occurring in the afternoon, making it important to rapidly and accurately predict the initiation of convection (CI). Due to the non-linear characteristics of small-scale strong convection, and the ability of Deep Neural Networks (DNN) to fit non-linear functions, this study focuses on weak synoptic strong convection events using the Weather Research and Forecasting (WRF) system and adopting an Observing System Simulation Experiment (OSSE) framework to obtain various variables. After detailed case analysis, prediction target definition, and data processing, DNN is used to forecast strong convection or CI for one hour, and various analyses like SHAP (SHapley Additive exPlanations) are conducted on DNN to determine the importance of each variable, leading to exploration in many different angle.

After extensive discussions, this study provides guidelines for the establishment of DNN system parameters, data selection and processing, and uses various validation methods, including objective scores, graph overlay analysis, performance diagram, SHAP analysis, persisFail experiments, coordinate system testing experiments, and sensitivity testing experiments. A series of discussions were conducted on the model performance, prediction tendencies, and variable importance. The analysis of variable importance is consistent with previous statistical results for the CI, and methods to enhance DNN forecasting ability, such as adding spatially-related variables and solving problems with mixed training, were also considered. Although the prediction performance of the DNN cannot be compared with fuzzy logic, the results show a significant improvement over extrapolation methods, and can be quickly applied to

actual data using only pure station variables. When using central weather bureau standards and considering the smallest forecast units as townships, the ETS (Equitable Threat Score) forecast scores for strong convection and the CI are 0.338 and 0.333, respectively, and the ETS and event occurrence frequency only weak positive correlation.

誌謝

兩年的碩士班生活真的很快，從第一次的雷達資料處理到論文口試，中間有相當多可以記得的回憶，跟各位在這裡相遇實屬我的榮幸。

最想先感謝的肯定是指導老師廖宇慶老師，我想願意接受較跨領域的學生來指導就是很突破性的嘗試了，在研究所也給我相當大的研究自由讓我可以發揮創造力，還有許多大氣專業面向與報告技巧的建議，真的相當感謝也辛苦老師了；當然還有雷達氣象實驗室的鍾高陞老師、張偉裕老師、阿練老師與陳老師提供的各式建議，其中尤以鍾老師的細心提醒與張老師的溫柔鼓勵讓我印象深刻！另外還有阿練老師在我大學入學時請的那頓飯，到今天仍然記得這種被重視的感覺並依此努力著，以及資工系張嘉惠老師特別撥空聽外系學生的報告並給出資工面向的建議、資工系蘇木春教授提供的非常清楚的類神經網路教材以解釋 DNN 的運算方式，還有台大陳柏孚老師讓我可以預先報告並找出研究的不足之處加以努力；當然不能忘記實驗室的學長姐的強力支援，尤其是小娜的行政支持(@黃展皇趕快來簽名!)、秉學柏謙的軟硬體資料支援、大柯子睿的聽報告協助修正，以及資工系昱萱學姊的 SHAP 分析建議，不只以上種種，實在相當相當感謝研究之路上的各位。

當然實驗室的同學，感謝最會問問題的沁全陪吃飯打球，下雨天還借我傘☺，華恩一起喝咖啡聊天拚論文，倩瑜、育蕎、思婷也都幫助我很多；還有鈞澤這位研究最相關的夥伴，一起研究互相支援打氣找研替，祝福且相信各位未來一定都好！

最後想感謝我們家族全心對我研究所的祝福跟支持，謝謝融一年多以來的陪伴，謝謝ㄅㄨㄩ寶，謝謝系籃隊友陪我打完最後的學生籃球，謝謝優質的咖啡豆讓我 input coffee output code。最後謝謝自己可以堅持在無人路上並產出已盡力的、可自豪的論文研究成果。

目錄

摘要.....	I
ABSTRACT	II
誌謝.....	IV
目錄.....	V
表目錄.....	VII
圖目錄.....	VII
第一章 緒論.....	1
1-1. 對流肇始(CONVECTION INITIATION, CI).....	1
1-2. 深度神經網路(DEEP NEURAL NETWORKS, DNN).....	2
1-3. 研究動機與目標	2
第二章 資料.....	4
2-1. 實驗架構	4
2-2. 真實與模擬個案	4
2-3. 資料處理	5
2-4. 預測目標定義	7
第三章 方法.....	9
3-1. DNN 原理	9
3-2. DNN 架構設定.....	11
第四章 驗證.....	13
4-1. 預測比較與驗證	13
4-1-1. 預測 pattern 疊圖比較	13
4-1-2. 公平預兆得分(Equitable Threat Score, ETS).....	13
4-1-3. 性能圖(performance diagram)	14
4-1-4. 接收者操作特徵曲線(Receiver operating characteristic curve, ROC)	15
4-1-5. SHAP 分析(SHapley Additive exPlanations analysis)	15
4-2. PERSISFAIL 測試實驗	16
第五章 結果.....	17
5-1. 變數相關測試	17
5-1-1. 變數座標與預測目標選擇.....	17
5-1-2. 變數敏感性測試.....	18

5-1-3 加入時空間資訊效益.....	20
5-1-4. SHAP 分析.....	21
5-2. 實際應用與比較	21
5-2-1. 與其他預測法比較.....	21
5-2-2. 跨個案預測效能.....	23
5-2-3. 鄉鎮市標準 ETS	24
5-2-4. 其他測試.....	25
第六章 結論與討論.....	27
6-1. 討論	27
6-2. 結論	27
6-3. 未來展望	28
參考資料.....	30
附表.....	32
附圖.....	37

表目錄

表格 1, WRF 系集模擬相關參數設定。.....	32
表格 2, 累積降雨(RAINNC)與延伸變數資料處理方式。.....	32
表格 3, DNN 架構測試版本, 由上至下為輸入層至輸出層的神經元數目, N 為輸入變數數量, 最終選取 V8 版本作為 DNN 模型。.....	33
表格 4, 變數座標與預測目標選擇結果, ISOBARIC 及 ISO-ETA 變數組合在各種預測目標下的 ETS, 以及 ISO-ETA 之於 ISOBARIC 的 ETS 比值。.....	33
表格 5, 變數敏感性測試結果, 逐漸減少群數的變數組合對 NP C/CI 的 ETS, 以及該變數組合之於上一個未移除群之變數組合的 ETS 比值。.....	34
表格 6, 變數敏感性測試, 將純測站中的純物理變數與常數變數分別取出做訓練, 其之於純測站的 ETS 比值。.....	34
表格 7, 加入時空間資訊效益測試結果, 逐漸減少群數的變數組合對 NP C/CI 的 ETS, 以及該變數組合之於上一個未移除群之變數組合的 ETS 比值。.....	35
表格 8, 本研究與模糊邏輯預測 CI 相關研究設定比較。.....	35
表格 9, 個案二 WRF 系集模擬相關參數設定。.....	36
表格 10, 全下午預測測試結果, 分別列出取用變數範圍相同但為 1 小時預測的 ADD_TIME 以及全下午預測的 ETS, 以及全下午預測之於 ADD_TIME 的 ETS 比值。.....	36

圖目錄

圖 2-1, 預測流程示意圖。.....	37
圖 2-2, 2020/07/20 (A)0800LST (B)1400LST 地面天氣圖。.....	37
圖 2-3, 2020/07/20 0800LST 板橋探空斜溫圖。.....	38
圖 2-4, 2020/07/20 (A)1200LST-(I)2000LST 逐時氣象局最大雷達合成回波圖。.....	39
圖 2-5, (A)模式模擬之 WPS 網格設定 (B)D03 網格陸地點選取範圍。其中陸地點選取範圍以模式最低 ETA 層之 Z 作為閾值決定。.....	40
圖 2-6, 2020/07/20 第 40 系集(A)1200LST-(E)1600LST 午後逐時最大回波圖。.....	40
圖 2-7, OVERSAMPLING 示意圖, 透過複製較少的類別達到平衡資料集狀態提供良好訓練, 在真實預測時須提高閾值。.....	41
圖 3-1, 單一神經元運算示意圖。.....	42
圖 3-2, 正常訓練 LOSS 誤差函數下降情況。.....	42
圖 4-1, PERSISFAIL 理想測試實驗之 LOSS 誤差函數下降情況。.....	42
圖 5-1, ISOBARIC 及 ISO-ETA 變數組合對於第 40 個系集成員 1500 時對流發展期之 (A)C P2P 預測目標 (B)C NP 預測目標 (C)C P2P ISOBARIC 預測疊圖 (D)C NP ISO-ETA 預測疊圖 (E)C P2P ISOBARIC	

預測疊圖 (F)C NP ISO-ETA 預測疊圖，其中疊圖著色區為採計範圍，紅色為 TP，綠色為 FP，藍色為 FN，灰色為 TN。.....	43
圖 5-2，(A)ISOBARIC 對 C 預測(B)ISOBARIC 對 CI 預測 (C)ISO-ETA 對 C 預測 (D)ISO-ETA 對 CI 預測之性能圖，各點為單一測試系集之單一時間點.....	44
圖 5-3，NO_ADD、ADD_TIME 及 ADD_TIME 對於第 40 個系集成員 1500 時對流發展期之 (A)C NP 預測目標 (B)CI NP 預測目標 (C)C NP NO_ADD 預測疊圖 (D)CI NP NO_ADD 預測疊圖 (E)C NP ADD_TIME 預測疊圖 (F)CI NP ADD_TIME 預測疊圖 (G)C NP ADD_SPACE 預測疊圖 (H)CI NP ADD_SPACE 預測疊圖，其中疊圖著色區為採計範圍，紅色為 TP，綠色為 FP，藍色為 FN，灰色為 TN。.....	45
圖 5-4，比較 NO_ADD、ADD_TIME 及 ADD_TIME 全測試系集全時間之 (A) C NP 平均 ETS 與 1 標準差誤差範圍 (B) CI NP 平均 ETS 與 1 標準差誤差範圍 (C)C NP ETS 勝率 (D)CI NP ETS 勝率 (E)C NP ROC (F)CI NP ROC。.....	46
圖 5-5，比較七種前述實驗對 C 以及 CI 預測之性能圖，各點為各變數組合所有測試系集之所有時間點，其中 CONS+PHY 的純測站組合呈現接近斜率 1 直線的情況.....	47
圖 5-6，(A)ISOBARIC 預測 C 之 SHAP 分析圖(B)ISO-ETA 預測 C 之 SHAP 分析圖.....	48
圖 5-7，(A)C NP 回波+常數+純物理 (B)CI NP 回波+常數+純物理 (C)C NP 常數+純物理 (D)CI NP 常數+純物理 (E)C NP 純物理 (F)CI NP 純物理 之 SHAP 分析。.....	49
圖 5-8，3 種外延法與常數+純物理 DNN (A)C NP 平均 ETS 與 1 標準差誤差範圍(B)CI NP 平均 ETS 與 1 標準差誤差範圍 (C)C NP ETS 勝率 (D)CI NP ETS 勝率。.....	50
圖 5-9，2019/07/21 (A)0800LST(B)1400LST 地面天氣圖。.....	51
圖 5-10，2019/07/21 0800LST 板橋探空斜溫圖。.....	51
圖 5-11，2019/07/21 (A)1200LST-(I)2000LST 逐時氣象局最大雷達合成回波圖。.....	52
圖 5-12，2019/07/21 個案二 (A)模式模擬之 WPS 網格設定 (B)D03 網格陸地點選取範圍。其中陸地點選取範圍以模式最低 ETA 層之 Z 作為閾值決定。.....	53
圖 5-13，2019/07/21 第 40 系集(A)1200LST-(E)1600LST 午後逐時最大回波圖。.....	53
圖 5-14，鄉鎮市標準個案一第 40 系集成員 1500 時對流發展期之 (A)CI 預測目標 (B)CI 預測 (C)為目標預測疊圖，其中紅色為 TP，綠色為 FP，藍色為 FN，白色為 TN。.....	54
圖 5-15，DNN 使用[常數+純物理]變數群個案一各測試系集之.....	54
圖 5-16，(A)系集成員 37 之 C NP 預測目標 (B)系集成員 37 之 C NP 預測 (C)系集成員 45 之 C NP 預測目標 (D)系集成員 45 之 C NP 預測。.....	55
圖 5-17，(A)C NP (B)CI NP 各方法 ETS 對 PRATE 之散布圖與回歸直線。.....	55

第一章 緒論

1-1. 對流肇始(convection initiation, CI)

在現行的天氣預報中，往往較難掌握具有較小時空間尺度特性且具有較高非線性程度的系統，如利用 0~3 小時的短期預報預測午後對流與雷暴便由於模式需要 spin-up 時間而有其難度，而更甚者我們不只需要預測系統，而是系統的肇始情況。然而台灣夏季的弱綜觀情況在午後仍會有短期、致災性且難以預報的強對流事件發生，對於航空、民生等領域均有嚴重影響，因此有必要對此類強對流事件以及其變化與肇始過程進行更深入的了解，並且採用更快速反應的算法進行預測。在此，我們定義本研究的 CI 為小尺度的弱綜觀午後對流肇始。

在前人研究中，Luke et al. (2016)分析系集模擬中的孤立對流肇始與各變數關係，發現雲陰影導致的負溫度異常是風暴肇始的重要特徵，觀測網格在特定 PBL 方案(YSU)應小於五公里，並且在深對流雲形成後就會有邊界層內的，變數與 CI 的高空間相關性(3~7 公里)；Luke et al. (2017)則進一步透過 OSSE 同化了解空間上觀測密度增加對 CI 預測的改善情形，並且發現在積雲形成後地面觀測最為有效；而 Lin et al. (2011)對台灣 2005 年至 2008 年暖季弱綜觀午後對流的時空間特性進行過統計分析，利用北部測站、雷達與探空資料發現該類系統容易發生於平行於山脈的麓山地帶，並且與海風環流有關；緊接著 Lin et al. (2012)透過北部測站與雷達資料將弱綜觀天數區分為有午後對流的天數(TSA)與非 TSA，並以模糊邏輯算法囊括氣候頻率、測站探空等變數以預測是否為 TSA 日，結果可得到 0.385 的 ETS 公平預兆分數；而 Chang et al. (2017)則透過底層算法同為模糊邏輯的 TaiwanAuto-NowCaster (TANC)系統進行一小時的對流肇始預報，經過空間與時間擴寬認定的敏感度測試後最終可得 0.13 的中位 TS 預兆分數，勝過分數為 0.03 的 STMAS-WRF(Space and Time Multiscale Analysis System-Weather

Research and Forecasting)模式，此模式採用多種觀測資料區分波長後採用多次變分法，在非絕熱初始化情況下相較一般 WRF 有更快 spin-up 的優勢。

1-2. 深度神經網路(deep neural networks, DNN)

而在另一方面，已有相當多深度學習模型應用於短期預報的研究，如 SHI et al. (2015)開發 conv-LSTM，同時利用卷積計算捕獲空間資訊以及長短期記憶模型捕獲時間資訊進行短期回波外延；Espenholt et al. (2022)等人開發 Metnet-2，利用雷達與衛星資料進行北美區域的高時空解析度降水概率預測，其性能在 12 小時內高於 High-Resolution Rapid Refresh (HRRR)模式；Ravuri et al. (2021)開發 Deep Generative Model of Radar (DGMR)，以對抗式神經網路為基礎，輸入雷達資料進行短期外延，其預報能力在客觀分數上高於 Pulkkinen et al. (2019)的 pysteps 外延法，在英國氣象局雙盲評測上亦呈現明顯優勢，更顯現其在系統生滅預測上的能力；Zhang et al. (2023)開發 NowcastNet，試圖利用中國與美國的雷達觀測資料在同時考慮物理機制與最低誤差情況下進行多尺度強度的預測，並在客觀分數與雙盲評測上均得到顯著優勢，同樣高於 Pulkkinen et al. (2019)的 pysteps 外延法並高於 DGMR；最後 Bi et al. (2023)開發 Pangu-Weather，使用三維深度網路處理天氣資訊，並以分層時間聚合的方式減少累積誤差，最終可產出比歐洲中期天氣預報中心更好的再分析資料，並且極端預報、系集預報以及初始化颱風的路徑精度均更佳。綜上所述，深度學習在良好的架構與訓練下具備預測精準且快速等優勢。

而由眾多前人透過數學方法證明通用近似定理(Universal Approximation theorem)，已證明深度神經網路(DNN)也就是多層疊加的感知機具備擬合任意非線性函數的能力(Cybenko, G., 1989, Hornik K., 1991, Hinton, et al., 2006)。

1-3. 研究動機與目標

綜上所述，對流肇始已被廣泛認知到是相當重要的議題，也有許多從天氣角度或是以模糊邏輯作為算法的對流肇始預測系統，然而傳統模式模擬需要 spin-

up 時間，而統計與模糊邏輯以線性的方式描述對流及其肇始機制，但目前尚未有針對對流及其肇始機制的深度學習應用，尤其是具有挑戰性的短期小尺度、弱綜觀且更非線性的對流肇始情況，考慮到深度學習在其他面向以及氣象上的應用性，我們有必要引入深度學習處理此類問題。

因此何種方式可以合理進行深度學習的訓練、深度學習對於該議題的預測能力，以及各種變數對於預測的重要性，以上問題皆需要測試了解。若資料與訓練得宜，DNN 的非線性函數擬合能力應可相當好的描述同樣非線性的小尺度弱綜觀 CI 過程，期待 DNN 可以提供更準確的預報。

本論文共分為六個章節，第一章是緒論，介紹何為對流肇始 CI、深度神經網路 DNN 以及研究動機與目的；第二章是資料，介紹實驗架構、WRF 系集模擬個案、資料處理與預測目標的定義方式；第三章介紹 DNN 的擬合原理、DNN 的架構與超參數測試設定；第四章是驗證，介紹各種本研究使用到的驗證方式；第五章是結果，主要分為變數相關測試的 4 小節，以及應用相關測試的 3 小節，針對各種面向進行實驗；第六章是討論、結論與未來展望，最後是參考資料。

第二章 資料

2-1. 實驗架構

本實驗採取觀測系統模擬實驗(Observing System Simulation Experiment, OSSE)做為資料的來源與比對的目標。之所以採用 OSSE 而非實際測站資料是考慮到深度學習訓練需要諸多有效樣本，但現實測站資料並不足以支撐本實驗大量訓練、驗證需要的資料量，且常有資料品質的問題，因此選用 OSSE 作為實驗整體的驗證主體以免除資料層面的問題。另外在 OSSE 中還可以取得現實尚未觀測到的變數，透過後續分析可以了解這些變數之於預測的重要性，可進一步提供未來觀測時的指南。

實際預測的流程上如圖 2-1，使用天氣研究和預報模式 WRF 的系集預報並將所有系集視為獨立個案，將所有陸地點視為測站並可取得該點的眾多變數，該變數由 WRF 模擬直接輸出或經過合理處理後產生。取用部分變數組成變數組合後進行系列的資料處理，將其作為 DNN 的輸入特徵進行 1/0 分類預測，而預測目標則為大於 35dBZ 的強對流或是對流肇始點，最終繪圖分析、計算客觀分數以及進行 SHAP(SHapley Additive exPlanations)分析，即可得到預測可靠度與變數重要性結果並可回頭優化變數組合。

2-2. 真實與模擬個案

本實驗之模擬個案一選用 2020 年 7 月 20 號的弱綜觀午後對流事件，由地面天氣圖 2-2 可以看到綜觀環境下 00Z 地面出海高壓經度位於日本南方，導致台灣位於微弱的高壓迴流東南風場，等壓線相當稀疏為弱綜觀情況；而由板橋探空斜溫圖 2-3 可以看到中低層大氣較為潮濕，CAPE 達 $1198m^2s^2$ ，LCL、CCL 以及 LFC 均在 3km 以下，有利於強對流的產生；而由氣象局逐時最大雷達合成回波

圖 2-4 可以看到午後即開始發生強對流，當地時間 1300 時於新竹山區、台南平地與屏東枋寮麓山地帶產生 35dBZ 以上的對流胞並逐漸發展，而後於 1500 時發展至嘉南平原、北桃竹地區以及花蓮的麓山地帶並趨於成熟，爾後 1700 南部對流消散並於中部山區發展，隨後全台逐漸減弱直至 2000 時消散完畢，屬於由微弱西風帶入水氣，在台灣麓山地帶輻合發展的型態。

而在 WRF 系集模擬參數設定如表格 1，其中選用了 50 個成員的系集模擬，並且取用 d03 包含全台的三公里網格的陸地點作為驗證區域，詳細 d03 框定範圍及陸地點選取範圍如圖 2-5 所示，而時間上則取用當地時間的 1300 至 1700 每半小時的時間解析度作為午後對流的訓練目標。WRF 系集模擬輸出之 mdBZ(最大回波)在所有系集成員中均發生了明顯的午後強對流，列舉第 40 個系集成員午後逐時最大回波圖 2-6，可以看到在本系集中對流發展時間較早，當地時間 1200 即有在中南部山區產生強對流，發展期至 1500 雖然其在中部有略為過報，但在中北部以及南部的對流發展強度與位置均有不錯的對應關係，而後在北部地區的對流在位置上有所偏差，但中南部的對流位置與觀測對應。

最後，以上 50 個系集成員皆被認定為獨立的個案，定義前 35 個成員為訓練集，後 15 個成員為測試集，在前述框定的時空間範圍內進行訓練與預測驗證。

2-3. 資料處理

而在資料處理上，由於是 OSSE 架構因此無須進行 QC，但要將 WRF 產出之變數作為 DNN 之輸入變數仍然需要進行一些處理，包括：

(1) 正規化(Normalization)：

各種變數在所有系集所有時間所有陸地點上的最大最小值尤其在量值上差異很大，然而在前面推導 DNN 運算原理時可以看出，這種量值的差異會導致倒傳遞階段時權重訓練受到較大量值的變數影響，進而使 DNN 無法學習量值較小變數的特徵。因此，對於每種變數需要進行 Min-Max normalization，如以下公式：

$$X_{nor} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (2.1)$$

意即將變數值線性的變換到 0 到 1 之間，以避免上述變數量值影響訓練
 權重問題。最大值線性映射到 1，最小值則線性映射到 0，而最大最小
 值則歷遍所有系集所有時間之陸地點得出。

(2) 過採樣(Oversampling)：

本研究著重於強對流/對流肇始事件，但即使是在顯著發生事件的個案
 中，50 個系集 9 個時間 3750 個陸地點共 1687500 個點中，大於 35dBZ
 的強對流點仍只有 108343 個，約為全部點的 6.4%，若是直接將原始情
 況作為訓練跟測試情況，極有可能會導致 DNN 產生完全預報無事件的
 情況，因為在此情況 loss 函數即可以達到相對的局部低點。

嘗試過許多方法處理此類不平衡資料集問題，包括不做處理去調低預報
 輸出閾值或是 class weight 方法(將不同預報類別設定不同的 loss 計算權
 重)，但結果分別會導致極不穩定的模型或是很奇怪的偏誤預測。而最
 有效的方法為過採樣 Oversampling 如圖 2-7 所示，會複製個數較少的類
 別，此處為強對流或是對流肇始事件，以達到平衡的資料集，提供 DNN
 較好的訓練母體，但在應用在預測時，由於訓練用的是複製過的資料集
 但預測是要在原始不平衡的狀況下，因此須提高最後分類時的閾值，其
 中轉換公式為：

$$A = P_1 / [(\frac{adj Y}{total}) / (\frac{Y}{total})] \quad (2.2)$$

$$B = P_0 / [(\frac{adj N}{total}) / (\frac{N}{total})] \quad (2.3)$$

$$adj P_1 = \frac{A}{(A + B)} \quad (2.4)$$

其中 Y、N 代表原始資料集的有事件與無事件點數，adj Y、adj N 代表
 oversampling 後資料集的有事件與無事件點數，total 為總點數， P_1 與 P_0

為原始給定的類別概率(二元分類問題閾值均為 0.5)， $\text{adj } P_1$ 為調整後有事件之概率，因此最終有事件之閾值應設為 $1 - \text{adj } P_1$ 。

(3) 缺值填值(Nan padding)：

雖然 WRF 輸出變數本身不會有缺值問題，但由於 WRF 為 eta 座標，若需要將輸出變數內插至等壓座標在地形高處可能會有缺值的情況發生。對此無法正確描述該區應有的變數值，因此此處會計算等壓面其他所有有效值點的平均並填入缺值處，相當於此處的變數值無參考價值。

此方法僅限三維等壓座標變數需要進行。

(4) 延伸變數：

本研究取用 WRF 輸出變數中的**三維變數**：高度(z)、氣壓擾動(p)、氣壓(pressure)、各層回波強度(dbz)、東西向風(ua)、南北向風(va)、絕對溫度(tk)、相對溼度(rh)、濕球溫度(td)、位溫(theta)、相當位溫(theta_e)；**二維變數**：經度(XLONG)、緯度(XLAT)、累積降雨(RAINNC)(此處採用前半小時累積降雨)、最大回波(mdbz)、最大對流可用位能(MCAPE)、最大對流抑制能(MCIN)、舉升凝結高度(LCL)、自由對流高度(LFC)；其他**延伸變數**如坡度(slope)、時間(time)、迎風坡度(windward)、輻散度(div)、水氣輻散度(vapor_flux_div)、溫度濕球溫度差(T_sub_Td)、現正是否強對流(persis)，有關累積降雨以及延伸變數的資料處理如表格 2 所示。

2-4. 預測目標定義

在預測目標部分，分別對本研究的強對流、對流肇始做明確的定義，並且透過空間上的擴寬預期達到更好的預測表現與訓練效果。

(1) 強對流(C)點定義：

根據 lin et al. (2017)、Roberts et al. (2003)以及氣象局定義，我們會將模式之最大回波 mdBZ 大於 35dBZ 之格點視為強對流點，該回波強度代

表的降水情況與成熟積雨雲的最終發展有良好的相關性，本研究中以“C”簡化代稱。

(2) 對流肇始(CI)點定義：

對流肇始之簡單定義為一對流系統之生成，也就是對流從無到有的過程，然而實際對地面定點的對流肇始定義還需要考慮系統的移動並扣除之，但在系統移動時仍可能有 cold pool front 強迫所導致的新一波對流肇始等等系統生消問題，因此實務上難以清楚分離該點情況是否為對流肇始。由於本研究為弱綜觀的情況，風速於台灣陸地普遍不強，不易有系統的明顯移動，根據 Mecikalski et al. (2006)的作法，當該點為首次出現大於 35dBZ 的回波強度時，即認定為對流肇始事件；而在本研究中則是在找出強對流(C)點後檢查該點前 2 小時的回波強度，若均低於 35dBZ 則可定義該新生之強對流為 CI 點，本研究中以“CI”簡化代稱。

(3) 點對點(p2p)與九點擴寬(np)定義：

除了 C 與 CI 的分類，lin et al. (2017)同樣指出空間擴寬可降低 false alarm 以及 miss 的頻率，有助於提升預報表現與更好的訓練，因此除了原本像素對像素的事件網格點，本研究稱為“p2p”，也會將事件點鄰近的八個網格點都視為事件點進行空間擴寬，本研究稱為“np”，擴增後為 9 公里的空間尺度，仍符合午後強對流的小尺度範圍。

雖然空間擴寬某種程度上犧牲了空間的解析度，但在空間解析度要求不高的情況下空間擴寬可以更好的囊括事件點及其附近的變數，有助於 DNN 識別相關的變數特徵。

以上預測目標的定義，尤其是 CI 點定義的部分僅適用於弱綜觀低風速低系統移動的情況，並不適用於移動較快的系統如鋒面或是颱風個案。

第三章 方法

3-1. DNN 原理

深度神經網路(Deep Neural Networks, DNN)，又名多層感知機，是一種模擬生物神經連結的模型，其結構必然包含由神經元單元如圖 3-1 組成的輸入層、隱藏層與輸出層且隱藏層層數大於等於一。DNN 具有從大量資料中迭代訓練學習特徵的能力，其訓練過程主要分為前饋(Feedforward)以及倒傳遞(Backpropagation)兩階段：

前饋階段：每個單位神經元 j 接收上層每個神經元 i 的輸出 y_i (若該神經元為接收層則直接接收輸入)並進行多層多神經元的以下計算：

$$v_j = \sum_{i=0}^P (w_{ji} \cdot y_i - \theta_j) \quad (3.1)$$

$$y_j = \phi_j(v_j) \quad (3.2)$$

其中 v_j 為 j 神經元的輸出， ϕ_j 為活化函數(activation function)， P 為給定該層之神經元數目， w_{ji} 為權重， θ_j 為給定閾值，以此類推最終可以得到輸出層之輸出。

倒傳遞階段：得到輸出層之輸出後可算出單神經元誤差函數 e_j 以及瞬間誤差平方函數 E 如下：

$$e_j = d_j - y_j \quad (3.3)$$

$$E = \frac{1}{2} \sum_{j \in C} e_j^2 \quad (3.4)$$

其中 d_j 為期望輸出，也就是訓練目標，而 c 則為所有輸出層神經元子集，我們希望隨著訓練迭代次數增加使 DNN 逐步調整權重 w 而使 E 逐漸降低，而根據誤差最小均方法可將 E 對 w 進行偏微分(代表隨著權重其誤差的斜率)並進行鍊鎖律(chain rule)置換：

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial v_j} \cdot \frac{\partial v_j}{\partial w_{ji}} \quad (3.5)$$

定義左項：

$$\delta_j(n) = -\frac{\partial E(n)}{\partial v_j(n)} \quad (3.6)$$

由(3.1)帶入右項得：

$$\frac{\partial v_j}{\partial w_{ji}} = \frac{\partial}{\partial w_{ji}} \left[\sum_{i=0}^p w_{ji} \cdot y_i \right] = y_i \quad (3.7)$$

因此 w_{ji} 的應修正量 Δw_{ji} 為：

$$\Delta w_{ji} = \eta \delta_j(n) \cdot y_i(n) \quad (3.8)$$

其中 η 為給定學習率，而 w_{ji} 修正公式則為：

$$\text{new } w_{ji} = w_{ji} + \Delta w_{ji} = w_{ji} + \eta \delta_j \cdot y_i \quad (3.9)$$

其中 δ_j 可被推導為：

$$\delta_j = -\frac{\partial E}{\partial v_j} = -\frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial v_j} = -\frac{\partial E}{\partial y_j} \cdot \frac{\partial (\phi(v_j))}{\partial v_j} = -\frac{\partial E}{\partial y_j} \cdot \phi'(v_j) \quad (3.10)$$

若為輸出層神經元，根據(3.3)與(3.4) E 定義可看出 δ_j ：

$$\delta_j = -\frac{\partial}{\partial y_j} \left[\frac{1}{2} \sum_{j \in c} (d_j - y_j)^2 \right] \phi'(v_j) = (d_j - y_j) \phi'(v_j) \quad (3.11)$$

若為隱藏層神經元，則其 E 需要進行遞迴計算：

$$\frac{\partial E}{\partial y_j} = \sum_k \frac{\partial E}{\partial v_k} \frac{\partial v_k}{\partial y_j} = \sum_k \frac{\partial E}{\partial v_k} w_{kj} \quad (3.12)$$

此處 k 為輸出層神經元，因此可代換(3.11)：

$$\frac{\partial E}{\partial v_k} = -\delta_k = (d_k - y_k) \phi'(v_k) \quad (3.13)$$

合併(3.10)、(3.12)與(3.13)可知隱藏層 δ_j ：

$$\delta_j = \phi'(v_j) \sum_k \delta_k \cdot w_{kj} = \phi'(v_j) \sum_k (d_k - y_k) \phi'(v_k) \cdot w_{kj} \quad (3.14)$$

至此完成所有倒傳遞階段之參數計算，其中 ϕ 須為連續可微分之函數如：

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} ; \text{ReLU}(x) = \max(0, x) \quad (3.14)$$

其中 ReLU 在不可微分處常用 Sub-gradient 解決，除此以外尚有相當多的訓練追加項例如慣性項等等以防止訓練時網路的不穩定等等。(蘇木春, 2021)

而之所以採用簡單的 DNN 而非如生成對抗網路 GAN 或卷積長短期記憶網路 consLSTM 等更強的深度學型模型，主要是因為本研究僅為針對單點進行預測，無需使用到需要更多資料或是需要空間插值的模型，並且 DNN 架構簡單易於實作訓練，可隨時更改變數數目的設計也相當彈性。

3-2. DNN 架構設定

在本研究中採用了 python 語言的 tensorflow 開源庫進行開發，版本為 2.4.0。實際的 DNN 訓練中我們需要給定權重的初始值、活化函數的定義、誤差函數的計算方式、學習率以及其訓練策略等等以使 DNN 可以達到最低的誤差函數，以上需要人工給定的參數稱為超參數(hyperparameter)。而以下為表列超參數設定：

- (1) 誤差函數(loss function)：分類問題嘗試過 binary cross entropy(BCE)以及 categorical cross entropy(CCE)，其公式如下：

$$\text{BCE} = - \sum_{i=1}^n \hat{y}_i \log y_i + (1 - \hat{y}_i) \log(1 - \hat{y}_i) \quad \frac{\partial \text{BCE}}{\partial y} = - \sum_{i=1}^n \frac{\hat{y}_i}{y_i} - \frac{1 - \hat{y}_i}{1 - y_i} \quad (2.15)$$

$$\text{CCE} = - \sum_{i=1}^n \sum_{j=1}^m \hat{y}_{ij} \log y_{ij} \quad \frac{\partial \text{CCE}}{\partial y_m} = - \sum_{i=1}^n \frac{\hat{y}_{im}}{y_{im}} \quad (2.16)$$

兩者預測能力無明顯差異但 binary cross entropy 訓練速度略快因此採用。

- (2) 優化器(optimizer)：採用 adam，也就是在純粹的梯度下降法中加入了 Momentum 慣性項，以及 AdaGrad 方法依照梯度對 η 進行調整。
- (3) 驗證(validation)集：在資料打亂順序後設定 validation_split=0.2，即訓練集中的 20% 資料用以驗證訓練過程。

- (4) 資料集迭代次數(epochs)：在本研究中會觀察如圖 3-2 的誤差函數 loss 下降情況。在訓練集 loss 穩步下降的情況觀察驗證集 loss 是否有接近收斂無下降，最終以 100 epochs 作為訓練資料集迭代次數。
- (5) 資料批次大小(batch_size)：考慮到記憶體大小，每次訓練的 batch_size 設定為 1024。
- (6) 防止過擬合(overfitting)機制：除了同(2)觀察 loss 與訓練情況，還採用了 earllystop 機制，當驗證集 loss 在 10 次迭代皆沒有明顯下降時即停止訓練防止 overfitting。
- (7) 活化函數(activation function)：每層隱藏層皆採用 ReLU 函數。另有嘗試無活化函數之訓練(即線性變換)效果非常差。
- (8) 輸出函數：最後一層為 2 個神經元時，採用 softmax 函數進行預測概率的計算並輸出，其中 softmax 函數為：

$$\text{softmax}(\vec{Z}) = \frac{e^{Z_i}}{\sum_{j=1}^K e^{Z_j}} \quad (2.17)$$

其中 \vec{Z} 為一維長度為 K 的陣列，而 i 則為某特定陣列元素。該函數將輸出元素映射到 0 至 1 之間，並且總和為 1。

- (9) DNN 深度與各層神經元數目：設定多種不同深度及廣度的模型如表格 3 所示，其中 N 代表輸入變數數量，而數字由上自下代表各層神經元數目，各層間以 ReLU 函數連接並在輸出層採用 softmax 函數。最終採用表現最佳的表格 3 V8 版本，即逐層神經元數目減半，第一隱藏層為 64 的架構。

第四章 驗證

4-1. 預測比較與驗證

該章節介紹本研究使用的各種驗證方式。

4-1-1. 預測 pattern 疊圖比較

針對每個測試系集成員的每個時間，可以對每個陸地點都進行預測並得到預測圖，除了直接比較該預測圖跟預測目標圖的 pattern，也會進行疊圖並標出其正確預報、誤報、未報以及正確不報的範圍，以了解實際 DNN 預測時的特性。

4-1-2. 公平預兆得分(Equitable Threat Score, ETS)

又名 Gilbert skill Score (GS)，是在 Threat Score (TS)或名 Critical Success Index (CSI)的計算方式下扣除隨機猜測的客觀分類預測分數，可評估預測模型超出隨機猜測的預測能力，其需要計算出預測與實際事件的 TP, FP, FN 以及 TN，其中 TP 為實際發生且預測發生、FP 為實際未發生但預測發生、FN 為實際發生但預測未發生，TN 則為實際未發生且預測也未發生。ETS 的計算方式如下：

$$ETS = \frac{TP - R}{TP + FP + FN - R} \quad (4.1)$$

其中 R 為隨機猜測項，為預測為發聲與實際發生頻率的交集，為：

$$R = \frac{(TP + FP) * (TP + FN)}{(TP + FP + FN + TN)} \quad (4.2)$$

ETS 值落於-1/3 至 1 區間，-1/3 代表預測為反向預測，0 代表預測相當於完全隨機猜測，1 代表預測為完美預測。

即使根據 Wang 文獻的論述,ETS 在高事件發生比例(positive rate, P-rate)時會有低估預測能力的情形,但經過計算本個案的平均 P-rate 約在 0.2 左右,因此暫時不須進行其文獻上的調整;且在本個案中各系集成員皆發生明顯午後對流,預測上不會有混淆矩陣過於集中 correct rejections 的情況,使得 ETS 不會過於敏感,因而是相當良好的客觀預測分數。

最後,在多種預測模型比較預測能力時會分別計算其對於每個測試系集成員每個時間點對預測目標的 ETS,並可以直接比較多種預測模型在每個測試系集成員每個時間點的 ETS 誰為最佳,進而計算出 ETS 勝率,以此作為多種預測模型之間對測試系集比較的預測能力結果。

4-1-3. 性能圖(performance diagram)

此為繪圖式的分析工具,該分析工具考慮隨著橫軸 1-FAR (success ratio) 的上升,縱軸 POD(probability of detection)的上升程度以及 TS 分數的分布情形,其中:

$$POD = \frac{TP}{TP + FN} \quad (4.3)$$

$$FAR = \frac{FP}{TP + FP} \quad (4.4)$$

$$TS = \frac{TP}{TP + FP + FN} \quad (4.5)$$

圖中曲線為 TS 分數等值線,由左下方最低的 0.0 至最高右上方的 1.0;直線則為 POD 相對 1-FAR 的比值線,若模型表現位於斜率 1 直線的左上方則代表模型較傾向高估,模型表現位於右下方則代表模型較傾向低估。該圖可以在表示模型預報能力的同時檢驗模型的傾向。

4-1-4. 接收者操作特徵曲線(Receiver operating characteristic curve, ROC)

此為繪圖式的分析工具，用以探討隨著偽陽性率(FPR)的提升，真陽性率(TPR)的上升程度，其中：

$$\text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (4.6)$$

$$\text{FPR} = \frac{\text{FP}}{\text{FP} + \text{TN}} \quad (4.7)$$

TPR 與 FPR 值均落在 0 至 1，並且在一次預測中繪出的曲線必通過(0,0),(1,1)，且該曲線越接近(0,1)越好，代表隨著 FPR 提升，TPR 可以更快提高，也代表更準確的預測。另外若該曲線低於通過(0,0),(1,1)的直線，可以進行反向預測亦可得到鏡像於直線的預測，但本研究中並無類似案例故不做討論。

4-1-5. SHAP 分析(SHapley Additive exPlanations analysis)

該分析法主要用以解釋在 DNN 的預測中，何種變數造成了多大的影響。其原理主要源於合作賽局理論的 Shapley 值，計算方式如下：

$$\phi_i(v) = \frac{1}{|N|!} \sum_R [v(P_i^R \cup \{i\}) - v(P_i^R)] \quad (4.8)$$

其中 ϕ 為 Shapley 值，N 為總玩家數(在本研究中為輸入變數)， P_i^R 為玩家的有序集合， $v(P_i^R)$ 為有序集合玩家的貢獻值， $v(P_i^R \cup \{i\})$ 為有序集合玩家加上第 i 位玩家的貢獻值。直白的說，我們需要計算所有排列組合下，某位玩家(變數)加入後對整體造成預測的邊際貢獻程度，最終所有玩家(變數)的貢獻值總和為 1。

而由於我們使用的是 DNN，因此實際應用時會採用 DEEP SHAP 方法，使用 DeepLIFT(Shrikumar, et al. 2017)以及 Shapley 值計算 DNN 輸入個變數的貢獻值。

4-2. persisFail 測試實驗

在超參數、架構以及驗證方法均決定後，進行了一個理想化的驗證實驗稱為 persisFail：即在一組輸入變數中，將現正是否強對流(persis)變數置換為一小時後是否強對流(預測目標)，即其中一個變數即為答案，藉此觀察 DNN 在變數足夠好的情況下是否能透過訓練得到準確的預測。訓練過程如圖 4-1，epochs 約在 2 時 loss 即達到接近 0，呈現非常快速的 loss 收斂並且可達 1.0 的準確度，也在後續驗證階段呈現 1.0 的 ETS 分數為完美預測，SHAP 分析也呈現對預測而言主宰性的 persis 變數值。這代表著若提供足夠好的變數，DNN 即可在訓練中學習並給出好的預測，並且驗證階段的 SHAP 分析也能提供給我們相當好的變數重要性分布。

第五章 結果

5-1. 變數相關測試

本章節著重了解訓練中輸入變數以及輸出預測目標的取用策略，以及各種變數對預測的影響力，包含變數座標與預測目標選擇、變數敏感性測試、加入時空間資訊效益以及 SHAP 分析小節。

5-1-1. 變數座標與預測目標選擇

此小節檢視原始的 WRF 輸出變數應該使用何種座標平面作為取用變數的基準，以及空間擴寬的預測目標是否有如文獻所述一樣更好的效果。

在變數部分取用的變數如 2-3.章(4)延伸變數介紹，二維 WRF 及延伸變數可直接經過資料處理作為輸入使用，而三維 WRF 及延伸變數則需要決定要在哪個座標平面上取變數值，若為等壓座標則取五個氣壓層(1000、925、850、700、500hPa)，若為等 eta 座標則取最接近地面的一層相當於地面量測，以此方式分別得到代表等壓與等 eta 平面座標的變數。

在經過測試後，發現難測量的變數如 omega, avo 等對預測能力提升有限，因此決定取用以下變數並以等壓與等 eta 方式取變數：**[z, P, pressure, dbz, ua, va, tk, rh, td, theta, theta_e, XLONG, XLAT, RAINNC, mdbz, MCAPE, MCIN, LCL, LFC, slope, time, windward]**，兩組由不同座標平面得出的變數組合分別稱為 Isobaric 及 Iso-eta。

列出 Isobaric 及 Iso-eta 在各種預測目標下的 ETS，以及 Iso-eta 之於 Isobaric 的 ETS 比值如表格 4，Iso-eta 的變數數量顯著少於 Isobaric，源自於在 3D 變數取用時 Iso-eta 只取一層地面層但 Isobaric 取了五個氣壓層，並且可以明顯看到在強對流 C 預測上 Iso-eta 會減少 6%的 ETS，但在 CI 預測上

兩者幾乎沒有差別，表示在變數較少且無須進行資料處理中的缺值補值的情況下直接採用等 eta 座標資料並不會損失太多的預測能力；而如圖 5-1 所示，在第 40 個系集 1500 時對流發展期的 pattern 上兩變數組合的預測都跟預測目標相近，易有強對流的區域皆有些事件預報，但 p2p 情況容易有預測位置上的偏差，也就導致 false alarm 以及 miss 的頻率上升，使 ETS 下降；但在 np 空間擴寬後此位置偏差的問題減小，顯著增加 hits 的情況並使 false alarm 以及 miss 的頻率下降，ETS 因而顯著上升，而更高的 ETS 有助於後面實驗進行更有說服力的測試。雖然在主要對流位置上有了大致掌握，但還是可以發現在中央山派南端無論是 p2p 還是 np 情況都還是有 false alarm 的情況；最後由圖 5-2 性能圖可以發現，在大多數的分布情況下 DNN 的預測皆傾向過報，有較多的 false alarm 情況。

綜上所述，接下來的實驗皆會使用等 eta 座標平面取變數以及使用 np 預測目標作為討論的依據。

5-1-2. 變數敏感性測試

此小節將變數組合內的變數進行分群並逐步移除，觀察 ETS 的下降進而間接推敲變數的重要性與對預測的敏感程度。

首先我們從 5-1-1 中可知 Iso-eta 取用的變數組合，將這些組合的變數依照特性再次分群，如：

- 探空變數群：[MCAPE, MCIN, LCL, LFC]，代表在實際觀測情況中需要探空才能取得之變數。
- 回波變數群：[dbz, mdbz]，代表雷達觀測回波相關變數。
- 常數變數群：[z, pressure, XLONG, XLAT]，代表對單點的測站來說隨時間幾乎沒有變化的變數，由於眾多虛擬測站有各自的常數變數值，因此此類變數可代表不同的地理位置，相當於地理統計概率。

- 純物理變數群：[P, ua, va, tk, rh, td, theta, theta_e, RAINNC]，代表純物理過程之變數(實際還有包含 slope, time, windward 三個延伸變數，但此三個延伸變數在 SHAP 分析呈現非常低的重要性因而不採計三者貢獻)。

並且逐步移除探空變數群、回波變數群、常數變數群直至剩下純物理變數群，得到三種變數組合(回波+常數+純物理、常數+純物理、純物理)，並以該三者的 ETS 比值判斷各變數之預測敏感性。

敏感性測試結果列出三者的 ETS 以及跟其上方的變數組合比較的比值如表格 5，比值下降越多代表移除的變數群對預報越重要，敏感性越高。首先可以看到移除探空變數群(回波+常數+純物理)後 ETS 相較於 Iso-eta(探空+回波+常數+純物理)並沒有明顯下降，表示探空對預測重要性低；再移除回波變數群後(常數+純物理)相較於(回波+常數+純物理)可以看到 ETS 的下降約在 6%至 5%左右，其中又以對 C 預測影響較大，也就是說提供回波資訊對預測強對流較有用，對 CI 貢獻較小，符合前人研究；拿掉常數變數群(純物理)相較於(常數+純物理)造成 ETS 的下降 C 約為 15%，CI 約為 26%，代表地理統計特徵對預測有其重要性；但即使只剩純物理變數群，相較於 Iso-eta(探空+回波+常數+純物理)仍有約 70%的 ETS，也表示實際用測站可測得的變數(常數+純物理)時 DNN 有能力可以同時考慮地理統計特徵以及和物理相關變數做出更好的預測。

為了進一步驗證 DNN 是否僅透過純粹的地理統計特徵，不考慮任何氣象特徵就有足夠的預報能力，因此另外分別將純測站變數組合中的純物理變數以及常數變數分別進行訓練，並與純測站組合比較如表格 6，可以明顯看到只用常數變數預測的表現是最差的，純物理變數預測表現更好，而若是結合純物理以及常數變數，即可達到更高的預報能力，再次證明 DNN 有能力可以同時考慮地理統計特徵以及和物理相關變數做出更好的預測。

本小節還有測試其他變數衍生方式如對變數進行差分並作為 DNN 輸入等等，由於成效甚微因此略過不提。

5-1-3 加入時空間資訊效益

此小節相較於原先的單點單時間預測一小時後的事件，改為加入時空間資訊並觀察此對於 ETS 的影響。

在此實驗中分為兩種：第一種 `add_time` 是選取單點多時間(更久以前)的相同變數，如想要預測 1300 該點的事件，從只選取該點 1200 改為選取該點 0800 到 1200 的九個時間點之變數，並且隨著預測時間向後，其選取的變數範圍同步向後維持前九個時間點變數進行預測；而第二種 `add_space` 則是選取更多鄰近點的相同變數，如想要預測下午 1300 該點的事件，從只選取該點 1200 改為選取該點及鄰近八個點 1200 之變數，以此兩種方式分別提供時間跟空間上的資訊，並觀察預測能力提高的程度。

加入時空間資訊效益結果列出原單點單時間(`no_add`)、`add_time` 以及 `add_space` 之 ETS 以及其跟 `no_add` 比較的比值如表格 7，可以看到加入時空間資訊皆對 ETS 有所助益，但加入空間資訊明顯效益較大，對 ETS 的提升 C 為 20%，CI 為 18%；在預測 pattern 上如圖 5-3 所示，相較於單點單時間預測，加入時間及空間資訊主要是在對流發展期修掉了 false alarm 的情況，但實際上在後續對流消散期加入時間資訊會有較明顯的全台灣 false alarm，因此實際上也如同表格 7，是由加入空間資訊有更明顯好的 ETS；而由圖 5-4(a)、(b)可知 `no_add`、`add_time` 以及 `add_space` 三個模型的平均 ETS 顯然都是 `add_space` 的 ETS 最高，但 ETS 標準差相對高，該情況在後續應用章節 5-2-1 有所提及並解釋；而由(c)、(d)可知 15 個系集各 9 個時間點共 135 個情況下，三個模型的 ETS 勝率也都是綠色的 `add_space` 取得五成以上的勝率；最後(e)、(f) ROC 曲線上可知 `no_add` 有著最差的表現，而在 0.4 FPR 以下 `add_space` 的 TPR 高於 `add_time`，但在 0.4 FPR 以上則無明顯差別；最後

由圖 5-5 性能圖可知，在所有 5-1-1 到 5-1-3 的實驗中，DNN 大多同樣傾向過報的情況，但在純測站也就是 cons+phy 的情況下實際上相當接近斜率 1 之直線，表示純測站的 DNN 並不會有明顯少報或是過報的情況。

5-1-4. SHAP 分析

此小節透過 SHAP 分析統整前述實驗的結果，並找出重要性高的變數。

針對 5-1-1 以及 5-1-2 產出之 DNN 進行 20 次 SHAP DeepExplainer 分析，其中根據官方文檔 SHAP 值期望值方差計算方式接近 $1/\sqrt{N}$ ，其中 N 為取樣樣本數，此處設定為最高 1000。將完成分析後的結果整理出交集並列出重要變數，由圖 5-6 可知等壓與等 eta 座標平面產生的變數重要性名單非常相近，圖 5-7 則呈現重要性變數包含：雷達回波變數的 mdbz，在 5-1-2 已發現對於強對流預測中較重要；常數變數群如經度 lon、緯度 lat、高度 z 以及氣壓 pressure 也是重要的參數，代表的是隨著地理位置的不同，各地的氣象條件機制和發生頻率會有所不同，這也是 Lin et al. (2011) 提到強對流是否發生的其中一個因素；重要熱力相關變數有 CAPE、LFC、tk，以及水氣相關的變數 QVAPOR、theta_e、rh；重要動力相關變數則有 ua、p，並且觀察等壓座標平面情況還可以發現熱動力參數皆以中低層 850、700hPa 為主。統整重要變數清單：[mdbz, z, lon, lat, pressure, CAPE, LFC, QVAPOR, theta_e, rh, tk, p, u]。

5-2. 實際應用與比較

本章節則主要探討 DNN 預測方法準確性與其他預測方法之比較以及跨個案的能力，以及實際應用的問題與處理方式，包含與其他方法比較、跨個案預測效能、鄉鎮市標準 ETS 以及其他測試小節。

5-2-1. 與其他預測法比較

根據前人研究與文獻，實際一小時預報時間的 CI 預報應該要跟模糊邏輯法比較，較能看出兩種專用於 C/CI 預測方法的預測能力差別，但與前人模糊邏輯法比較如表格 8 所示，受限於資料差異過大(模糊邏輯法多採用現實測站資料，具有氣候頻率等資料；本研究 DNN 則採用 OSSE 系集模擬資料，無氣候頻率資料)，以及預測時間認定不同(資料較相近的模糊邏輯法只針對天為單位須分 TSA 日與非 TSA 日)而難以直接比較。因此在本實驗中選定外延法作為 persistence-base 的方法作為 baseline，目的為觀察 DNN 超出 baseline 的預測性能，DNN 會與三種外延法做比較，分別是 constant、Lucas-Kanade(LK)以及 Variational Echo Tracking(VET)，其中 constant 算法會計算 t 時間回波情況與各種平移後的 t-1 回波情況的相關性，取最高者的全圖相同的移動場，並依照該移動場繼續外延 t+1 時間的回波；Lucas-Kanade(LK)算法則調用 openCV 的光流法，在假定局部臨近運動場恆定的情況下，以最小平方法計算接近的運動場，但較不適用於跨多 pixel 的運動；最後 Variational Echo Tracking(VET)算法則是將 t 時間回波情況與平移後的 t-1 回波情況進行變分計算最小化誤差，最終可得最低誤差之運動場並依此外延。

外延法的部分，主要原理均是使用雷達回波資料的時間序列以不同演算法算出運動場，並依此運動場外延回波至預測時間點，此處會採用一小時的外延結果，並根據預測目標的判斷法判定外延回波是否為 C 或 CI，最終跟預測目標以及 DNN 預測進行比較，而實際算法上則採用 Pulkkinen 於 2019 發布的 python 開源套件 pysteps (Pulkkinen, et al., 2019)。然而在外延法中可能會出現系統移動過快而使系統”穿山”，經過詳細檢查後在本實驗中並未出現移動速度過快的系統，並未有穿山的現象發生。

與其他預測法比較結果如圖 5-8，在平均 ETS 部分可以看到常數+純物理 DNN 與 3 種外延法的一個標準差 error bar，與 5-1-3 小節相同皆相當大，其主因在檢視目標與預測後發現來自於各系集各時間點的事件發生頻率(P-

rate)不一，用同一 DNN 對不同 P-rate 的系集進行預報便會有預報上 ETS 的波動；且高 dBZ 門檻的 C 定義以及更嚴苛的 CI 定義導致了離散的事件點，使得事件發生位置難以精確掌握，進而導致更多的 false alarm 以及 miss，進一步增加 ETS 的離散性。然而顯而易見的是在平均 ETS 以及勝率上 DNN 都顯著較佳，證明至少相較於外延法，在各種情況與預測目標下 DNN 都更能有效進行預測。

5-2-2. 跨個案預測效能

在此小節觀察 DNN 對不同型態的個案的預測能力，以及多個案下的訓練方案以及預測表現。

本實驗模擬了另一個 2019/07/21 的弱綜觀午後對流個案二，其地面天氣圖如圖 5-9，可以看到綜觀環境下台灣東南東方有微弱高壓，台灣仍位於微弱的高壓迴流南風場，等壓線相當稀疏為弱綜觀情況；板橋探空斜溫圖如圖 5-10，中低層大氣較為潮濕，並且 CAPE 達 $1373m^2s^2$ 較個案一略高，LCL、CCL 以及 LFC 均在 1km 以下較個案一為低；其氣象局最大逐時雷達合成回波如圖 5-11，午前即有海上系統移入造成的對流事件，但在 1200 至 1300LST 時即消散，並在下午時於中北部局部山區產生強對流肇始事件，逐步發展延伸至中部山區以及桃竹苗一帶，1800 全台開始逐漸消散但南投產生一小型對流胞，而後於 2000 消散完畢，屬於由微弱南風帶入水氣，並於熱力作用下產生局部對流的型態。個案二 WRF 模擬參數設定如表格 9 所示，主要改變為更換成一公里網格以便更好的掌握小尺度的對流情況，以及改變長短波輻射方案並加了 damping 防止過強的垂直運動，使模式積分穩定，詳細 d03 框定範圍及陸地點選取範圍如圖 5-12 所示，而 WRF 系集模擬輸出之 mdBZ(最大回波)在所有系集成員中同樣發生了明顯的午後強對流，列舉第 40 個系集成員午後逐時最大回波圖如圖 5-13，可以看到在本系集中對流發展時間同樣較早，且在花蓮山區有 false alarm 但對

中北部山區的對流位置與強度變化掌握很好，發展期有些西南部對流線的 false alarm，但總體模擬仍可接受。該個案二的 mdBZ 分布情況與個案一的 mdBZ 分布情況相去甚遠。

使用個案一 35 個訓練系集訓練出的 DNN 模型(使用常數+純物理變數群)，直接對個案二的 5 個測試系集(0、10、20、30、40 號系集成員)進行預測與 ETS 計算，可以得到 $C_{np} 0.083$ 、 $CI_{np} 0.073$ 的 ETS 分數，然而相較於在個案一測試系集的 $C_{np} 0.222$ 、 $CI_{np} 0.175$ 是一個很明顯的預測能力下降的情況，考慮到兩種個案的發生位置與型態皆不盡相同，因此針對個案一進行學習訓練的 DNN 在個案二上預測能力變很差是可以預見的。

對此，我們試圖驗證囊括類似型態的個案，嘗試提供 DNN 不同的個案型態並期待 DNN 可以有更有效的預測。因此我們取個案一 0 到 20 號系集，個案二 1 到 4 號系集，在兩種個案的點數相近的情況下進行訓練，並將此混合訓練的 DNN 對個案二的 5 個測試系集進行訓練，結果得到 $C_{np} 0.114$ 、 $CI_{np} 0.114$ 的 ETS 分數，對比於原先個案一訓練並預測個案二的情況在 C 有 37%的提升、在 CI 有 56%的提升，證明在條件許可的情況下應該盡可能在訓練時囊括盡量多不同型態的個案，使 DNN 有更好的泛化能力。

5-2-3. 鄉鎮市標準 ETS

最後在此小節觀察 DNN 在氣象局空間標準，也就是鄉鎮市尺度的標準下的預測能力。在氣象局防災的考量下，實際預測的空間認定範圍以鄉鎮市為單位，因此我以鄉鎮市的情況計算 ETS，若有事件點落在某鄉鎮市內，則該鄉鎮市即計為有事件。由於事件點無論 p2p 或是 np 的預測目標皆小於大部分鄉鎮市的空間大小，因此鄉鎮市標準可以視為一種比 np 還要大的空間擴寬。預測情況繪圖如圖 5-14，使用個案一 35 個訓練系集訓練出的 DNN 模型(使用常數+純物理變數群)可得 $C 0.338$ 、 $CI 0.333$ 的 ETS 分數。

但由於鄉鎮市面積範圍較大，若將所有鄉鎮市皆一視同仁計算 ETS 可能有些不公平的問題，並且由於計算總單位數較少，在聚焦於更小範圍進行 ETS 計算是可能會有全為correct rejections的情況而無法計算 ETS，需要注意。

5-2-4. 其他測試

在本小節中，另外對一些與一小時 C/CI 預測不直接相關但有趣有參考價值的情況進行測試。

(1) 全下午預測：

本測試中將時間認定由一小時的預測改為更寬鬆的整個下午的預測，意即該點在下午(1300 到 1700)任一時間發生 C/CI 即認定為有事件發生，取用如 5-1-3 小節中的 Add_time 實驗中的 0800 至 1200 變數，預測 1300 至 1700 的 C/CI_{np} 事件。結果如表格 10，可以看到在放寬時間認定後，ETS 顯著的比一小時預測高，C 為 31%而 CI 為 53%的 ETS 提升，表示若可容許的時間範圍由一小時改為整個下午，DNN 可得到更好的預測結果。

(2) 事件發生頻率 P-rate 對 ETS 的相關性：

之所以要做這個檢查，主要是因為各系集成員有特性上的差距需要分開討論，本測試檢查個案一中各系集的 P-rate，以及其對於預報能力 ETS 的關係。列出個案一各測試系集之 ETS 分數如圖 5-15，可以發現報得好的如第 37 個系集，報不好的如第 45 個系集，列出兩者的目標與預測如圖 5-16 可以發現兩個系集明顯主要差異在 P-rate 上，DNN 對於大面積群發的對流預測得到的 ETS 較好，對於零星的小對流預測效果就沒有這麼好。

進一步對 5-1-3 以及 5-2-1 的 DNN 以及外延法進行 ETS 對 P-rate 的散布圖並取回歸直線與相關係數如圖 5-17，其中每個點代表每個系集成員每個時間點，可以發現在 C 預測時所有方法的回歸線斜率相近，而

DNN 系列則因 ETS 較高而有 y 軸上的平移，相關係數皆小於 0.4 為低度正相關；在 CI 預測時 DNN 回歸線斜率則與 C 預測情況類似，但外延法系列則呈現持平，所有方法相關係數仍小於 0.4 為低度正相關。

以上結果告訴我們，雖然 DNN 在各測試系集上的表現不盡相同，但 P-rate 對 ETS 的相關性並不高，DNN 表現不好主要還是來自於零散對流點的位置偏差造成的 false alarm 以及 miss。

第六章 結論與討論

6-1. 討論

本研究對 OSSE 模擬中發生的典型弱綜觀午後對流個案，在經過詳細的個案分析、預測目標定義與資料處理後，使用了 DNN 深度神經網路作為有別於以往對 CI 預測進行的演算法，且除了新算法的引入以外還在 OSSE 情況針對變數的重要性進行一系列的探討，並且可以提供 DNN 系統參數等建置以及資料選用與處理的指南，使用了許多不同面向的驗證方法，包括客觀分數、繪圖疊圖分析、性能圖、SHAP 分析、persisFail 實驗、坐標系測試實驗以及敏感度測試實驗，對模型性能、預測傾向以及變數重要性做了一系列討論並得出結果，變數重要性分析上與前人對於 CI 的統計結果接近，另外還考慮了提升 DNN 預報能力的方法例如加入空間相關的變數，以及在不同個案上應用的問題以及提出混合訓練的解決方式，最後預測表現雖無法與模糊邏輯進行比較但顯著優於外延法，無論是空間或時間的放寬皆可顯著使 DNN 的預測更有參考價值，且僅需要以純測站變數組合即可快速應用於實際資料。

6-2. 結論

- (1) 考慮變數的可量測性與所需變數數量，在預測能力相近的情況應選擇等 eta 座標作為變數平面，而選用 np 預測目標有助於提升預報表現。
- (2) 從變數敏感性實驗可知探空變數對預測不重要，回波有些許影響且對強對流影響較 CI 大，地理統計概率對強對流和 CI 有顯著影響，但即使只用純物理變數仍可有 70% 的預測能力，也代表 DNN 在使用測站可得變數時可同時考慮地理統計概率和物理過程相關變數。
- (3) 加入空間資訊顯著提升 ETS。

- (4) 多次的 SHAP 分析顯示[mdbz, z, lon, lat, pressure, CAPE, LFC, QVAPOR, theta_e, rh, tk, p, u]為預測的重要變數，且水氣熱力變數以及動力變數以中低層為主。
- (5) 相較於 3 種外延法，DNN 在所有情況平均 ETS 以及 ETS 勝率均明顯較高。
- (6) 在訓練時應囊括不同發生型態的個案，以提升 DNN 在各種情況的預測能力。
- (7) 純測站可得的 DNN 鄉鎮市一小時預報，ETS 在 C 有 0.338，CI 有 0.333。
- (8) 時間認定放寬為全下午預測顯著提升 ETS。
- (9) 事件發生頻率 P-rate 對 ETS 的相關性不高。
- (10) DNN 有潛力在實際資料上提供快速準確的一小時強對流或 CI 預報。

6-3. 未來展望

如前討論所述，本研究在許多層面分析 DNN 預測 CI 的可能性與能力，而在短期預報上如同文獻回顧部分，深度學習已經廣泛的應用在氣象上並取得不錯的成績，其快速的預測對災防是相當好的助益。本研究還有相當多的未來展望如下：

- (1) 本研究的 CI 定義僅適用於弱移動場的情況，在應用於其他風速更快的個案時可考慮如 Lin et al. (2017)的方式，以外延法反向的追溯系統的移動並扣除假性 CI，或是直接建立一套更完善的系統性剖析該處是否為 CI 的流程，以取得更純粹的 CI 預測目標。
- (2) 尋找可描述海陸風環流等前人研究中對 CI 發生較為重要的變數，或是將弱綜觀情況下的不同型態如弱西風或是弱東風，以例如 850mean 風或 700theta_e 等新變數區別開，並將以上變數納入預測系統。
- (3) 可測試除了一小時的預測以外，進行更長時間的預測下 DNN 的預測能力如何，嘗試找到 DNN 進行預測的極限。

- (4) 在進行完整的資料蒐集、清洗以及延伸後，將 DNN 應用於實際測站資料上，並檢視其在真實資料上的預測能力表現，並且根據本研究的結果調整或增加變數。
- (5) 使用更強大之深度學習模型如 CNN、ViT 等進行空間上更廣泛的建模，或是 add_time/add_space 的部分可考慮同時加入時間與空間資訊，解決 CI 空間相關因素帶來的影響，並且可配合蒐集更多 WRF 的弱綜觀午後 CI 個案模擬，以更大的資料與模型取得更泛化更好的預測效果。

參考資料

- 蘇木春，類神經網路課程講義 第三章 多層感知機原理，2021，中央大學資訊工程系。
- 陳鈞澤（2021年10月）。弱綜觀午後雷暴事件即時預報-機器學習方法。110年天氣分析與預報研討會，交通部中央氣象局。
- Bi, K., Xie, L., Zhang, H., Chen, X., Gu, X., and Tian, Q, 2023. Accurate medium-range global weather forecasting with 3D neural networks. *Nature* 619, 533–538.
- Chang, H.-L., Brown, B.G., Chu, P.-S., Liou, Y.-C., and Wang, W.-H., 2017. Nowcast guidance of afternoon convection initiation for Taiwan. *Weather and Forecasting*, 32(5): 1801-1817.
- Cybenko, G., 1989, Approximation by superpositions of a sigmoidal function. *Math. Control Signal Systems*, 2: 303–314.
- Espeholt, L., Agrawal, S., Sønderby, C., Kumar, M., Heek, J., Bromberg, C., Gazean, C., Carver, R., Andrychowicz, M., Hickey, J., Bell, A., and Kalchbrenner, N., 2022, Deep learning for twelve hour precipitation forecasts. *Nature*, 13: 5145.
- Hinton, G.E., Osindero, S., and The, Y.-W., 2006, A fast learning algorithm for deep belief nets. *Neural Comput*, 18(7):1527-54.
- Hornik, K., 1991, Approximation capabilities of multilayer feedforward networks. *Neural Netw*, 4(2): 251-257.
- Lin, P.-F., Chang, P.-L., Jou, B.J.-D., Wilson, J.W. and Roberts, R.D., 2011. Warm season afternoon thunderstorm characteristics under weak synoptic-scale forcing over Taiwan Island. *Weather and forecasting*, 26(1): 44-60.
- Lin, P.-F., Chang, P.-L., Jou, B.J.-D., Wilson, J.W. and Roberts, R.D., 2012. Objective Prediction of Warm Season Afternoon Thunderstorms in Northern Taiwan Using a Fuzzy Logic Approach. *Weather and Forecasting*, 27(5): 1178-1197.
- Madaus, L. E., and Hakim G. J., 2016. Observable Surface Anomalies Preceding Simulated Isolated Convective Initiation. *Monthly Weather Review*, 144(6), 2265–2284.
- Madaus, L. E., and Hakim G. J., 2017, Constraining Ensemble Forecasts of Discrete Convective Initiation with Surface Observations. *Monthly Weather Review*, 145(7), 2597–2610.

- Mecikalski, J. R., and Bedka K. M., 2006. Forecasting Convective Initiation by Monitoring the Evolution of Moving Cumulus in Daytime GOES Imagery. *Monthly Weather Review*, 134(1), 49–78.
- Pulkkinen, S., Nerini, D., Pérez Hortal, A.A., Velasco-Forero, C., Seed, A., Germann, U., and Foresti, L., 2019. Pysteps: an open-source Python library for probabilistic precipitation nowcasting (v1.0). *Geoscientific Model Development*, 12(10): 4185-4219.
- Ravuri, S., Lenc, K., Willson, M., Kangin, D., Lam, R., Mirowski, P., Fitzsimons, M., Athanassiadou, M., Kashem, S., Madge, S., Prudden, R., Mandhane, A., Clark, A., Brock, A., Simonyan, K., Hadsell, R., Robinson, N., Clancy, E., Arribas, A., and Mohamed, S., 2021. Skilful precipitation nowcasting using deep generative models of radar. *Nature*, 597: 672–677.
- Roberts, R. D., and Steven, R., 2003. Nowcasting storm initiation and growth using GOES-8 and WSR-88D data. *Weather and Forecasting*, 18(4) , 562–584.
- Scott, M.L., Lee, S.I., 2017, A Unified Approach to Interpreting Model Predictions. *Advances in neural information processing systems*, 30: 4765-4774.
- SHI, X., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W.-K., and WOO, W.-C., 2015. Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Advances in neural information processing systems*, 28: 802-810.
- Wang, 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.
- Shrikumar, A., Greenside, P., and Kundaje, A., 2017. Learning important features through propagating activation differences. In *Proceedings of the 34th International Conference on Machine Learning*, 70, 3145–3153.
- Zhang, Y., Long, M., Chen, K., Xing, L., Jin, R, Jordan, M.I., and Wag, J, 2023. Skilful nowcasting of extreme precipitation with NowcastNet. *Nature* 619, 526–532.

附表

表格 1，WRF 系集模擬相關參數設定。

WRF 版本	3.9.1, 50 ensembles
初始條件	NCEP FNL 1°reanalysis
模擬時間	UTC 2020 07191800 ~ 07200900
網格大小	using d03 domain(211*211*52) Include whole Taiwan
網格解析度	nest 27-9-3(km)
時間解析度	30mins
MP_PHYSICS	Goddard 4-ice scheme
RA_LW_PHYSICS	RRTM scheme
RA_SW_PHYSICS	Dudhia scheme
BL_PBL_PHYSICS	YSU PBL scheme
DAMP_OPT	without damping

表格 2，累積降雨(RAINNC)與延伸變數資料處理方式。

累積降雨(RAINNC)	WRF 原始輸出為模擬開始至當時間點之累積降雨，本研究處理方式為當時間點 RAINNC 減去 30 分鐘前 RAINNC 可得最近 30 分鐘累計降雨
坡度(slope)	對高度(z)東西與南北向各進行一次中插插分得 W-E 坡度與 S-N 坡度，向量相加得到坡度量值
時間(time)	依照時間(午後 1~5 點)線性設為 0~1
迎風坡度(windward)	同坡度操作，並將兩方向坡度乘上 u v 風可得迎風坡量值
輻散度(div)	對 u,v 風在東西與南北向各進行一次中插插分得 W-E 輻散度與 S-N 輻散度，相加得到輻散度量值
水氣輻散度(vapor_flux_div)	同輻散度操作，並將兩方向坡度乘上 qvapor 可得水氣輻散度
溫度濕球溫度差(T_sub_Td)	WRF 輸出中的 tk- td 即可
現正是否強對流(persis)	判斷當時間點 WRF 輸出中的 mdbz 是否大於 35dBZ

表格 3，DNN 架構測試版本，由上至下為輸入層至輸出層的神經元數目，N 為輸入變數數量，最終選取 V8 版本作為 DNN 模型。

V1	V2	V3	V4	V5	V6	V7	V8
N	N	N	N	N	N	N	N
512	256	64	32	8	16	32	64
256	32	16	128	4	8	16	32
128	2	2	256	2	4	8	16
32			512		2	4	8
2			256			2	4
			128				2
			32				
			2				

表格 4，變數座標與預測目標選擇結果，Isobaric 及 Iso-eta 變數組合在各種預測目標下的 ETS，以及 Iso-eta 之於 Isobaric 的 ETS 比值。

variable combinations	target	ETS	ETS normalized by Isobaric
Isobaric (66 vars)	C / p2p	0.135	-
	C / np	0.250	-
	CI / p2p	0.083	-
	CI / np	0.188	-
Iso-eta (22 vars)	C / p2p	0.127	0.943 (ETS-6%)
	C / np	0.235	0.941 (ETS-6%)
	CI / p2p	0.084	1.014 (ETS ~)
	CI / np	0.187	0.994 (ETS ~)

表格 5，變數敏感性測試結果，逐漸減少群數的變數組合對 np C/CI 的 ETS，以及該變數組合之於上一個未移除群之變數組合的 ETS 比值。

variable combinations	target	ETS	ETS normalized by above no removed variable combination
回波+常數+純物理	C / np	0.237	1.009 (compare with+探空)
	CI / np	0.184	0.986 (compare with+探空)
常數+純物理(測站)	C / np	0.222	0.937 (compare with +回波)
	CI / np	0.175	0.951 (compare with +回波)
純物理	C / np	0.189	0.851 (compare with +常數)
	CI / np	0.130	0.743 (compare with +常數)

表格 6，變數敏感性測試，將純測站中的純物理變數與常數變數分別取出做訓練，其之於純測站的 ETS 比值。

variable combinations	target	ETS	ETS normalized by 純測站
純測站(純物理+常數)	C / np	0.222	-
	CI / np	0.175	-
純物理	C / np	0.189	0.851
	CI / np	0.130	0.743
常數	C / np	0.151	0.680
	CI / np	0.092	0.526

表格 7，加入時空間資訊效益測試結果，逐漸減少群數的變數組合對 np C/CI 的 ETS，以及該變數組合之於上一個未移除群之變數組合的 ETS 比值。

Add_type	target	ETS	ETS normalized by No_add
No_add (pure Station)	C / np	0.222	-
	CI / np	0.175	-
Add_time	C / np	0.243	1.094
	CI / np	0.183	1.042
Add_space	C / np	0.267	1.204
	CI / np	0.207	1.177

表格 8，本研究與模糊邏輯預測 CI 相關研究設定比較。

作者	Lin, et al., 2012	Chang, et al., 2017	Huang, et al., 2023
預測模型	fuzzy logic	TANC (fuzzy logic)	DNN
資料型態	Real case	Real case	OSSE WRF 50 ensembles
取用變數	4station, sounding obs.(277)	climate, CWB-WRF analysis, station, radar	常數變數組+純物理變數 組(詳見 5-1-2.)
空間範圍	(North) Taiwan	Station \pm 5km	Station \pm 9km
時間範圍	Whole afternoon	1 hour \pm 18mins	1 hour
客觀分數	ETS \approx 0.385	Median TS = 0.13	ETS=0.175 (township=0.333)

表格 9，個案二 WRF 系集模擬相關參數設定。

WRF 版本	3.9.1, 50 ensembles
初始條件	NCEP FNL 1°reanalysis
模擬時間	2019 07211200 ~ 07230000
網格大小	using d03 domain(901*901*52) Include whole Taiwan
網格解析度	nest 10-2-1(km)
時間解析度	60mins
MP_PHYSICS	Goddard 4-ice scheme
RA_LW_PHYSICS	RRTMG scheme
RA_SW_PHYSICS	RRTMG scheme
BL_PBL_PHYSICS	YSU PBL scheme
DAMP_OPT	with w-Rayleigh damping=0.2

表格 10，全下午預測測試結果，分別列出取用變數範圍相同但為 1 小時預測的 Add_time 以及全下午預測的 ETS，以及全下午預測之於 Add_time 的 ETS 比值。

Add_type	target	ETS (15members*9times)	-
Add_time 1hr predict	C / np	0.243	-
	CI / np	0.183	-
Add_type	target	ETS (15members)	ETS normalized by Add_time 1hr predict
whole afternoon predict	C / np	0.319	1.313
	CI / np	0.279	1.525

附圖

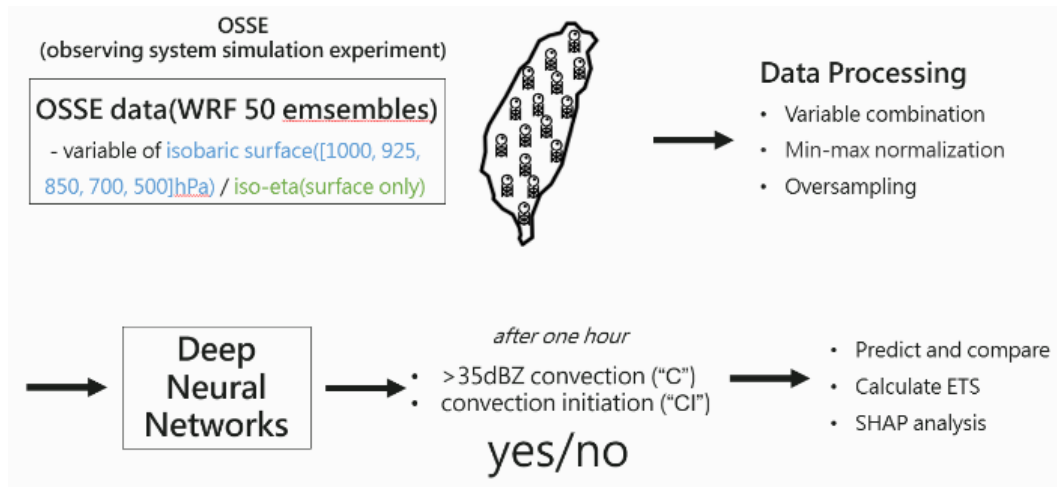


圖 2-1，預測流程示意圖。

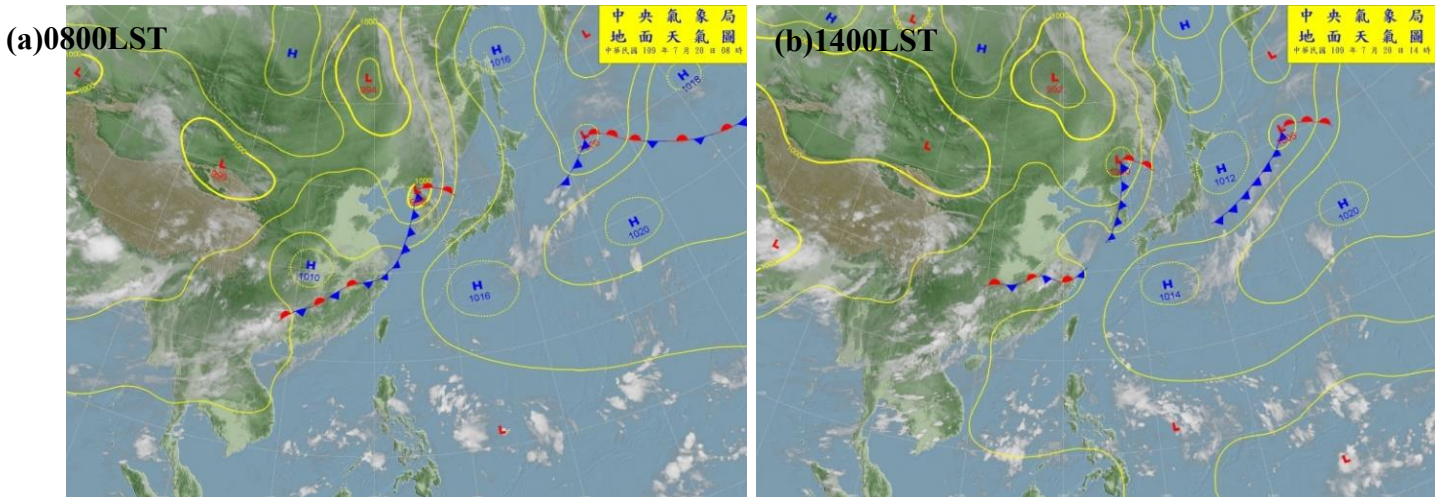


圖 2-2，2020/07/20 (a)0800LST (b)1400LST 地面天氣圖。




圖 2-3，2020/07/20 0800LST 板橋探空斜溫圖。

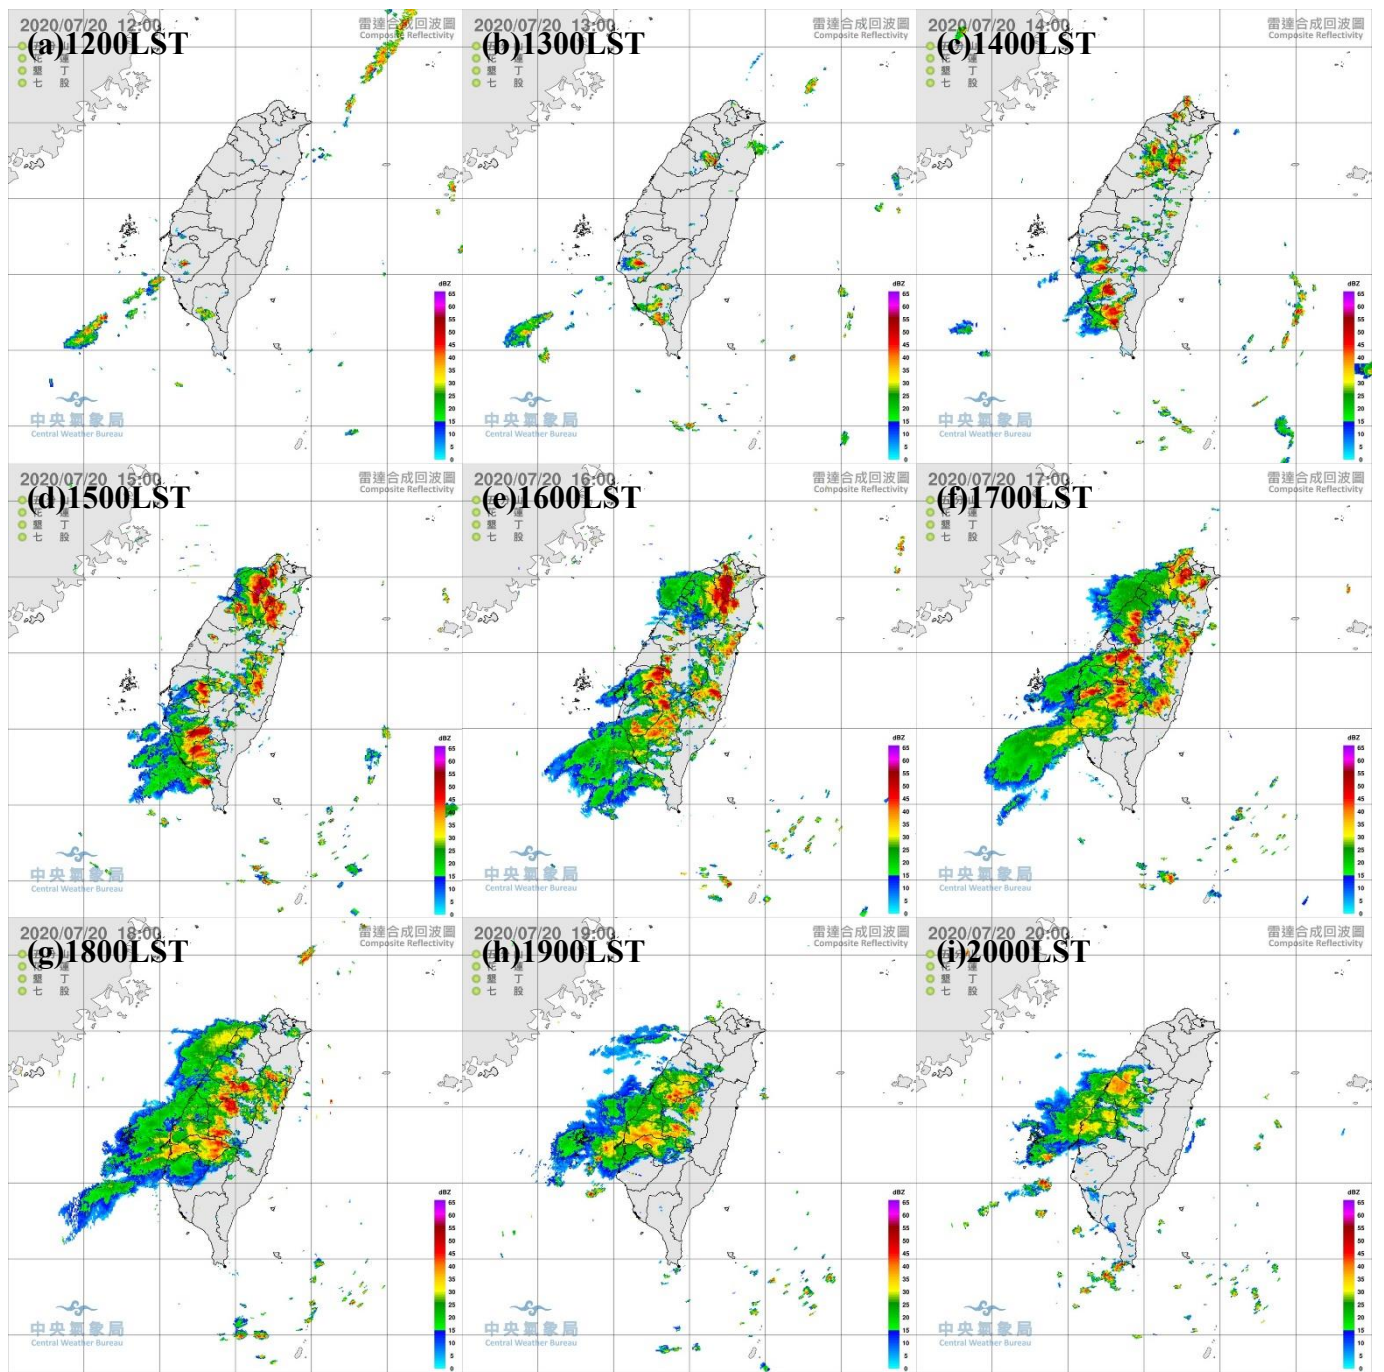


圖 2-4，2020/07/20 (a)1200LST-(i)2000LST 逐時氣象局最大雷達合成回波圖。

(a) WPS 網格設定

(b) d03 網格陸地點選取範圍




圖 2-5，(a)模式模擬之 WPS 網格設定 (b)d03 網格陸地點選取範圍。其中陸地點選取範圍以模式最低 eta 層之 z 作為閾值決定。

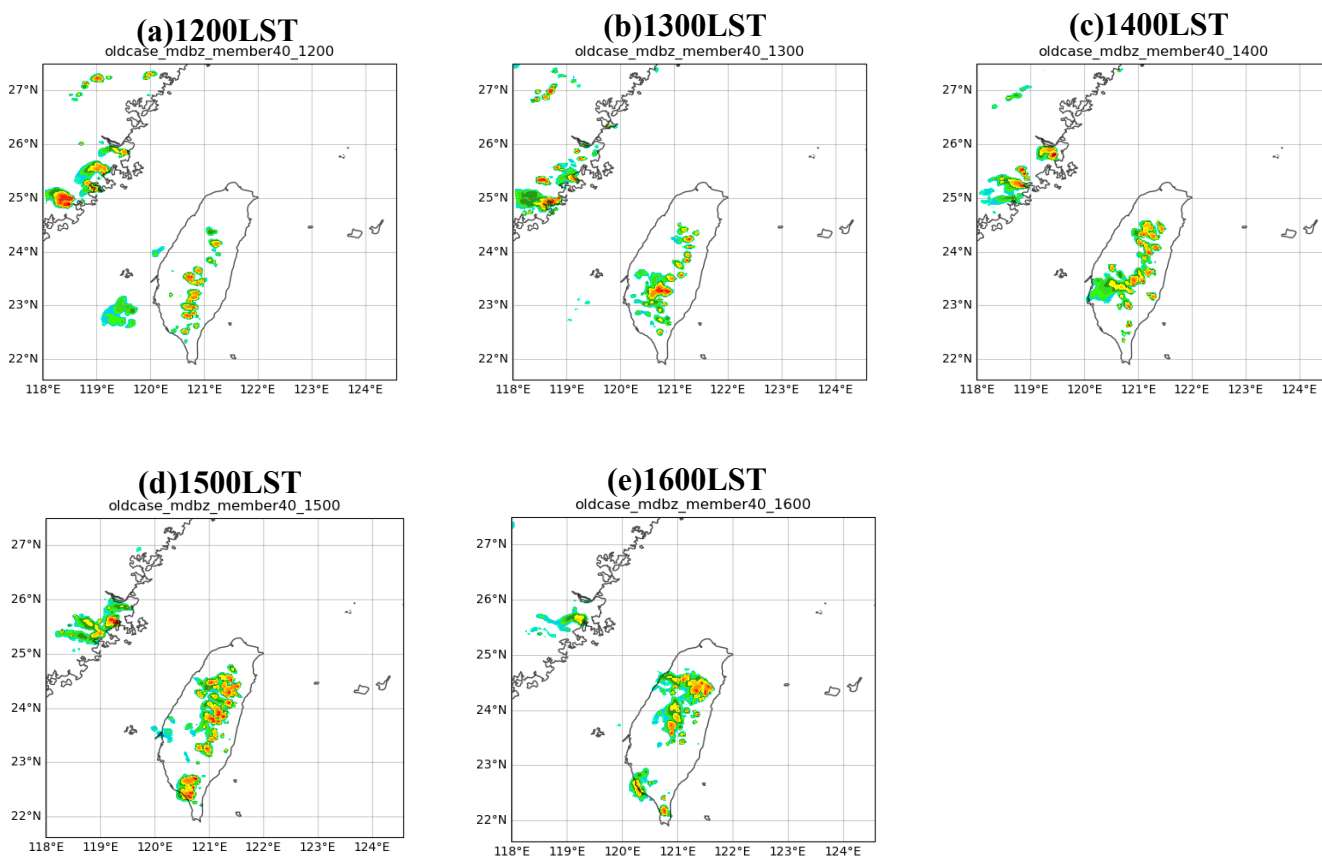


圖 2-6，2020/07/20 第 40 系集(a)1200LST-(e)1600LST 午後逐時最大回波圖。

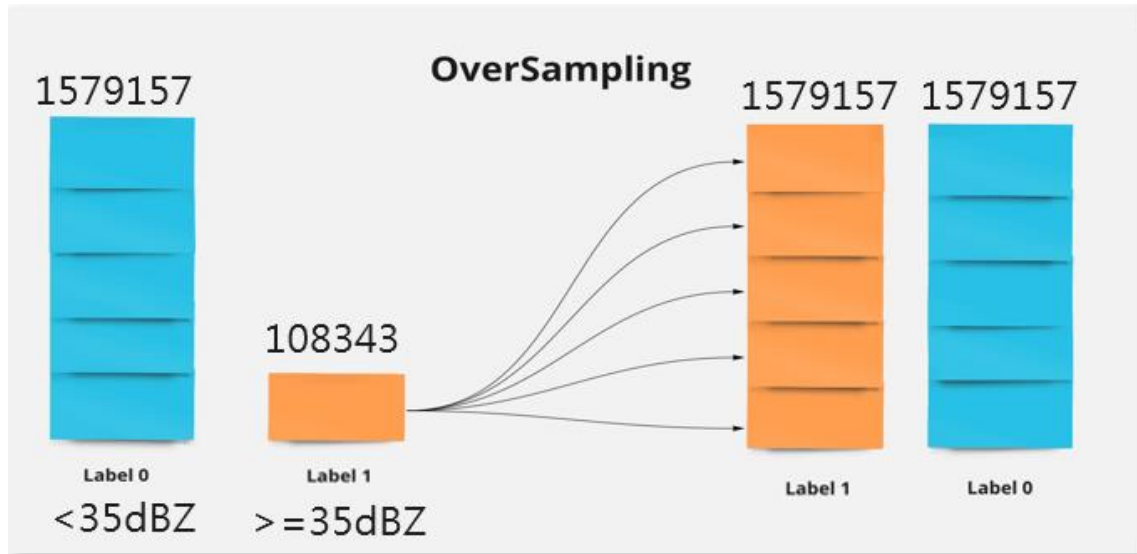


圖 2-7，oversampling 示意圖，透過複製較少的類別達到平衡資料集狀態提供良好訓練，在真實預測時須提高閾值。

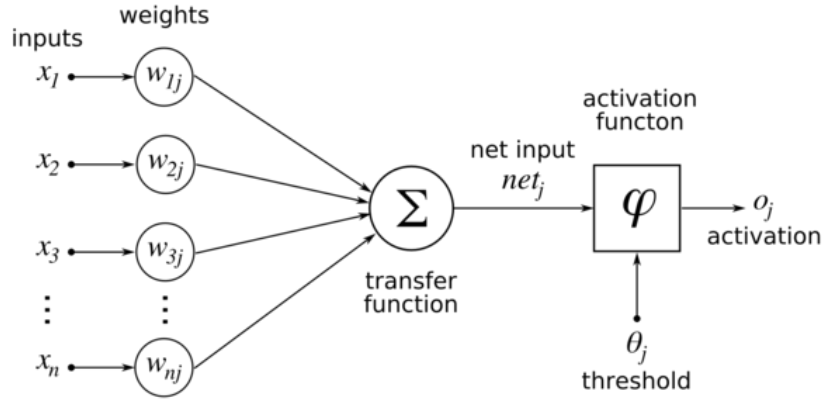


圖 3-1，單一神經元運算示意圖。

(a) 正常訓練之 loss 函數 (b) persisFail 理想測試實驗之 loss 函數

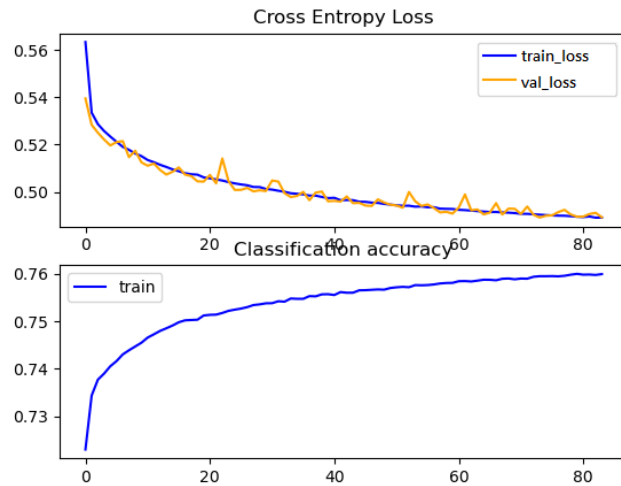


圖 3-2，正常訓練 loss 誤差函數下降情況。




圖 4-1，persisFail 理想測試實驗之 loss 誤差函數下降情況。

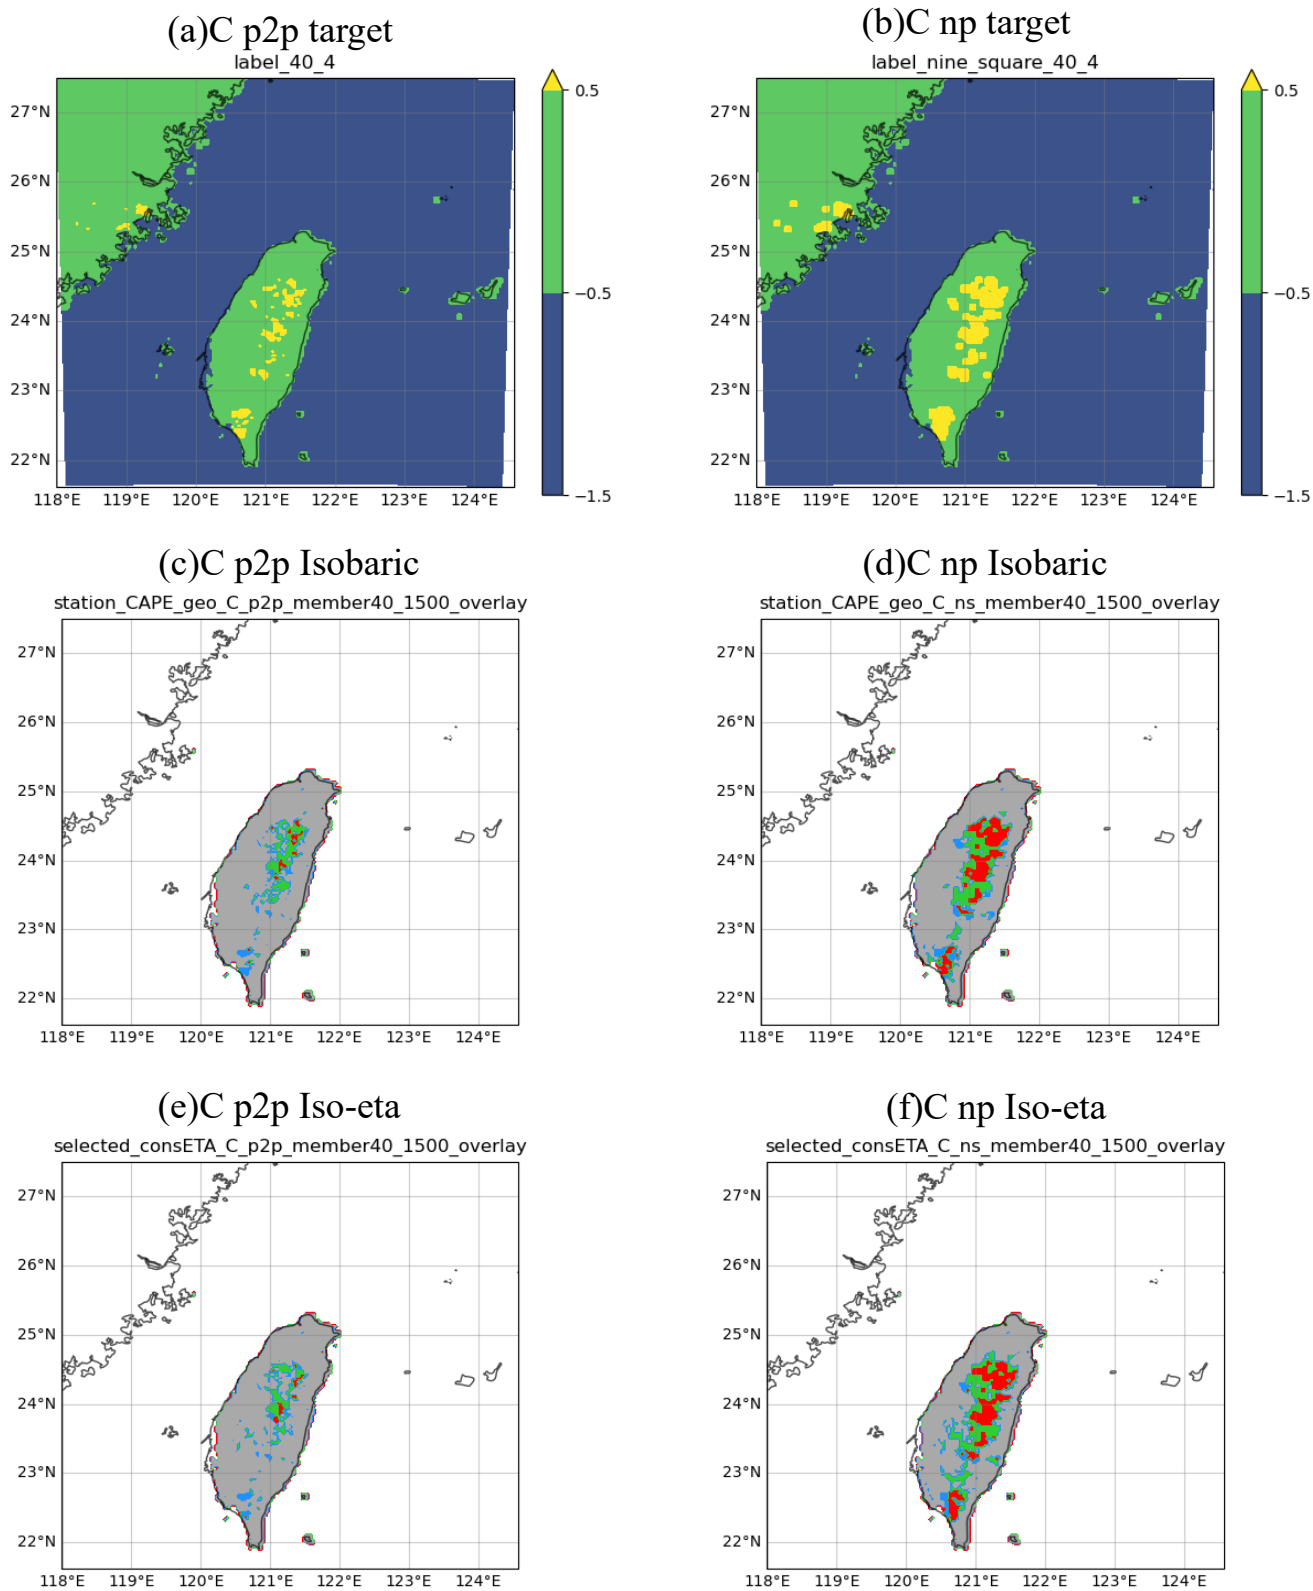


圖 5-1，Isobaric 及 Iso-eta 變數組合對於第 40 個系集成員 1500 時對流發展期之 (a)C p2p 預測目標 (b)C np 預測目標 (c)C p2p Isobaric 預測疊圖 (d)C np Iso-eta 預測疊圖 (e)C p2p Isobaric 預測疊圖 (f)C np Iso-eta 預測疊圖，其中疊圖著色區為採計範圍，紅色為 TP，綠色為 FP，藍色為 FN，灰色為 TN。



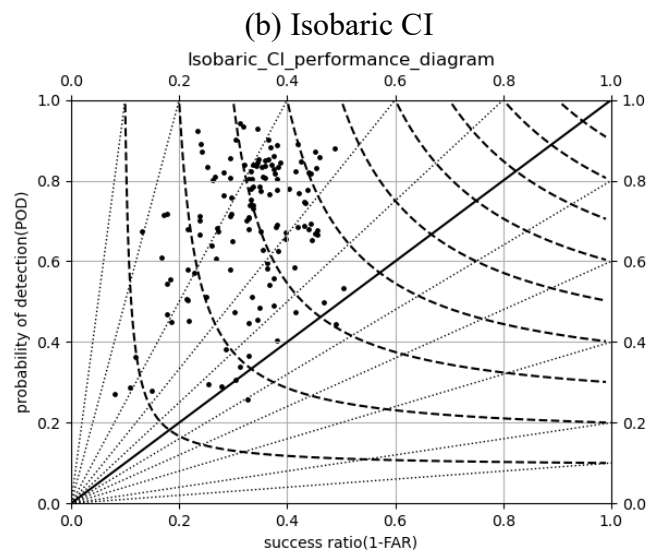
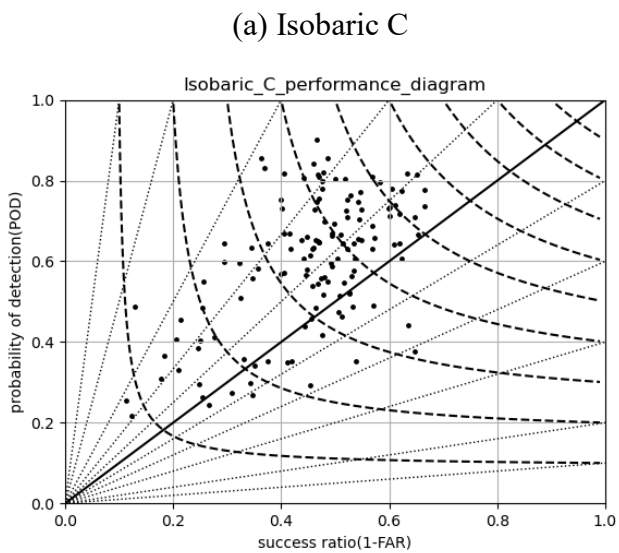


圖 5-2，(a)Isobaric 對 C 預測(b)Isobaric 對 CI 預測 (c)Iso-eta 對 C 預測 (d)Iso-eta 對 CI 預測 之性能圖，各點為單一測試系集之單一時間點

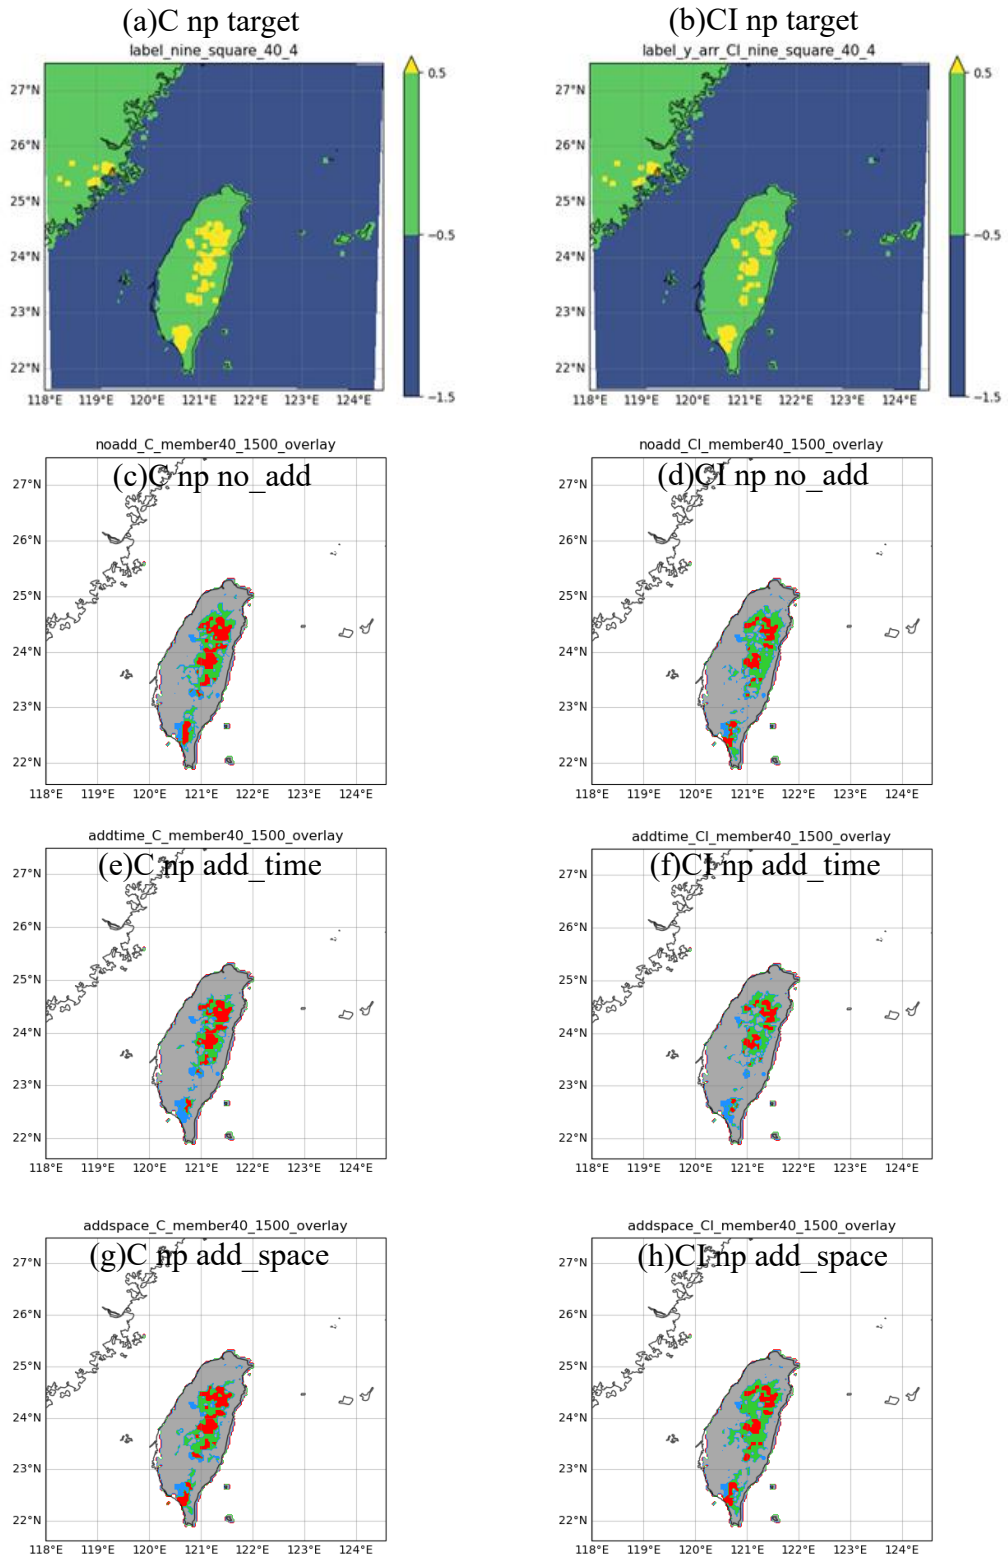


圖 5-3，no_add、add_time 及 add_space 對於第 40 個系集成員 1500 時對流發展期之 (a)C np 預測目標 (b)CI np 預測目標 (c)C np no_add 預測疊圖 (d)CI np no_add 預測疊圖 (e)C np add_time 預測疊圖 (f)CI np add_time 預測疊圖 (g)C np add_space 預測疊圖 (h)CI np add_space 預測疊圖，其中疊圖著色區為採計範圍，紅色為 TP，綠色為 FP，藍色為 FN，灰色為 TN。

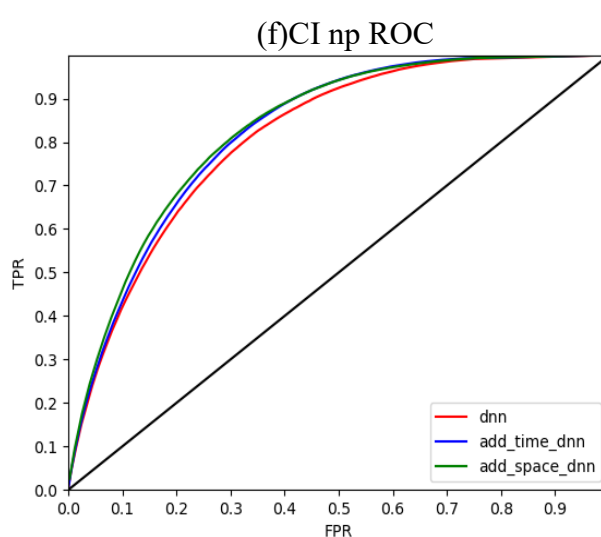

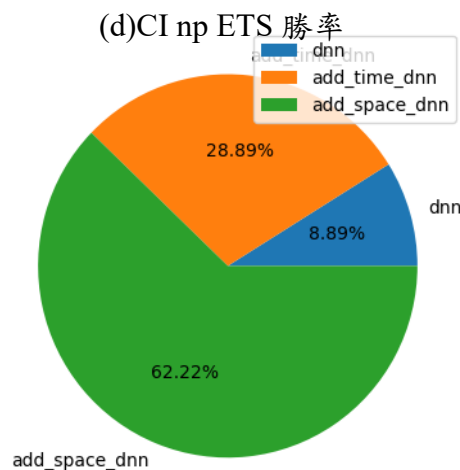


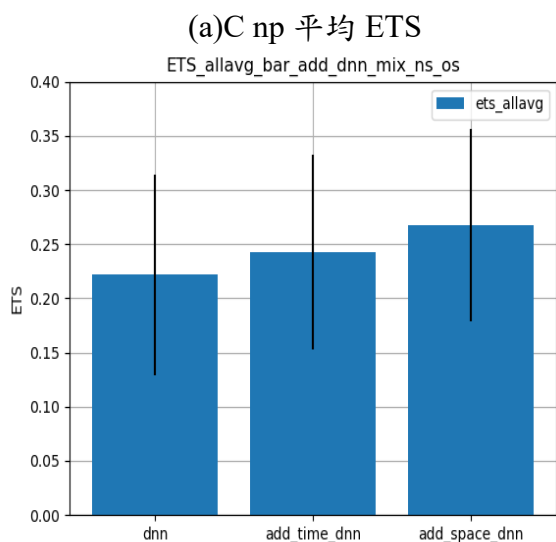


圖 5-4，比較 no_add、add_time 及 add_time 全測試系集全時間之 (a) C np 平均 ETS 與 1 標準差誤差範圍 (b) CI np 平均 ETS 與 1 標準差誤差範圍 (c) C np ETS 勝率 (d) CI np ETS 勝率 (e) C np ROC (f) CI np ROC。

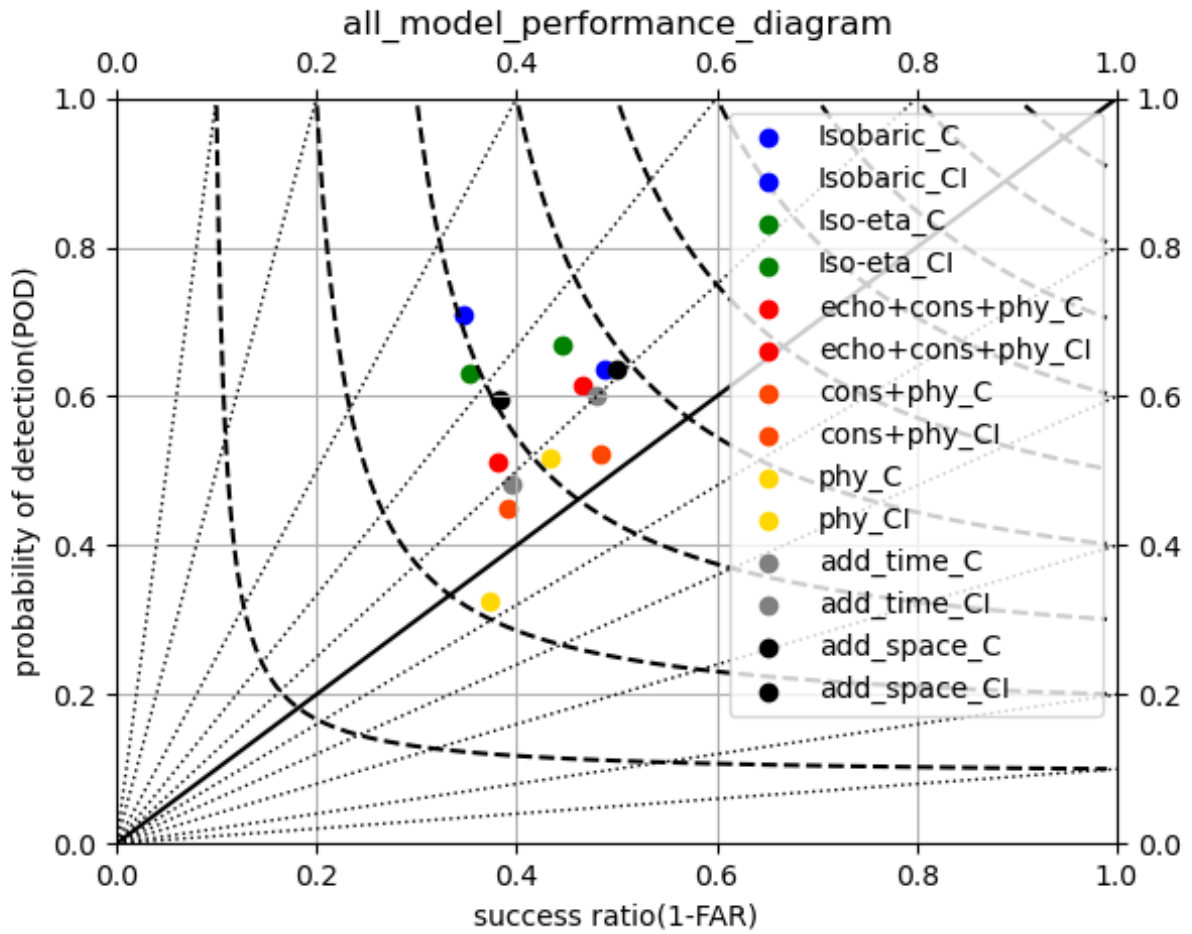



圖 5-5，比較七種前述實驗對 C 以及 CI 預測之性能圖，各點為各變數組合所有測試系集之所有時間點，其中 cons+phy 的純測站組合呈現接近斜率 1 直線的情況

(a) Isobaric SHAP 分析



(b) Iso-eta SHAP 分析




圖 5-6，(a)Isobaric 預測 C 之 SHAP 分析圖(b)Iso-eta 預測 C 之 SHAP 分析圖
所用變數含[探空+回波+常數+純物理]變數群。

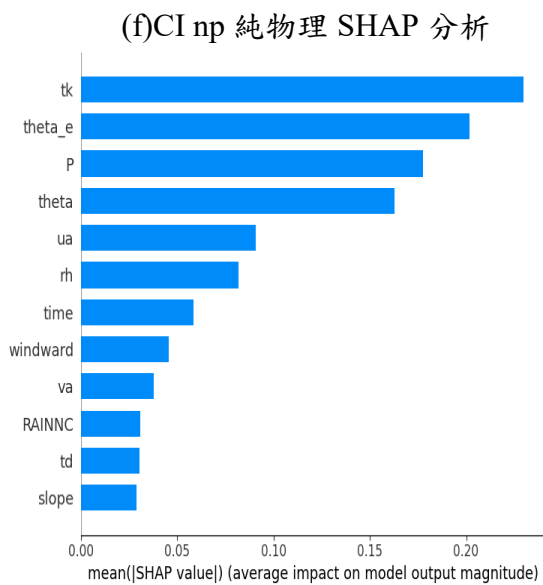
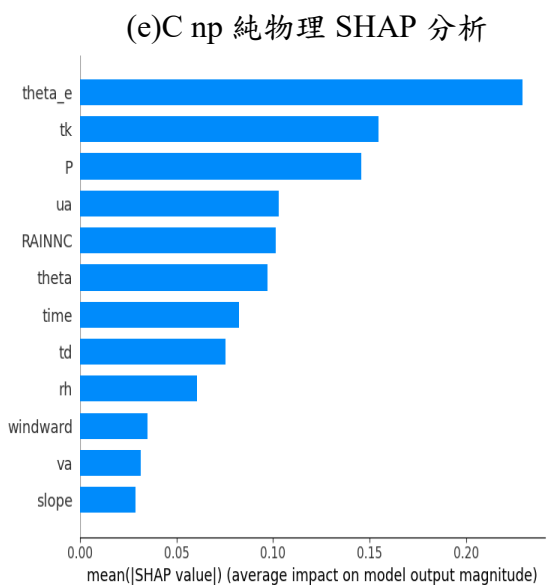
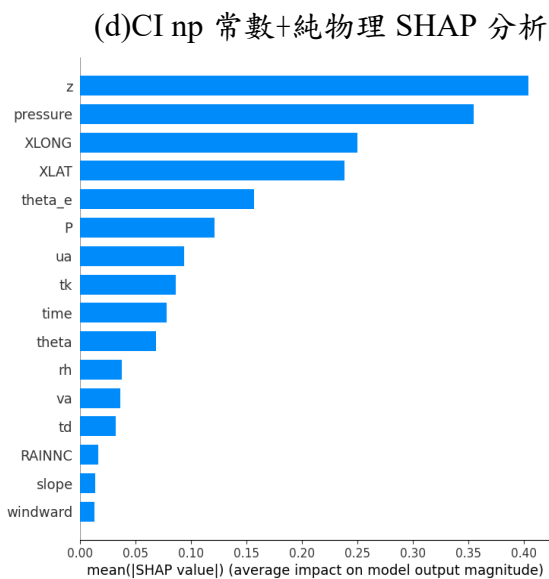







圖 5-7，(a)C np 回波+常數+純物理 (b)CI np 回波+常數+純物理 (c)C np 常數+純物理 (d)CI np 常數+純物理 (e)C np 純物理 (f)CI np 純物理 之 SHAP 分析。


(a)C np 平均 ETS



(b)CI np 平均 ETS



(c)C np ETS 勝率



(d)CI np ETS 勝率




圖 5-8，3 種外延法與常數+純物理 DNN (a)C np 平均 ETS 與 1 標準差誤差範圍 (b)CI np 平均 ETS 與 1 標準差誤差範圍 (c)C np ETS 勝率 (d)CI np ETS 勝率。

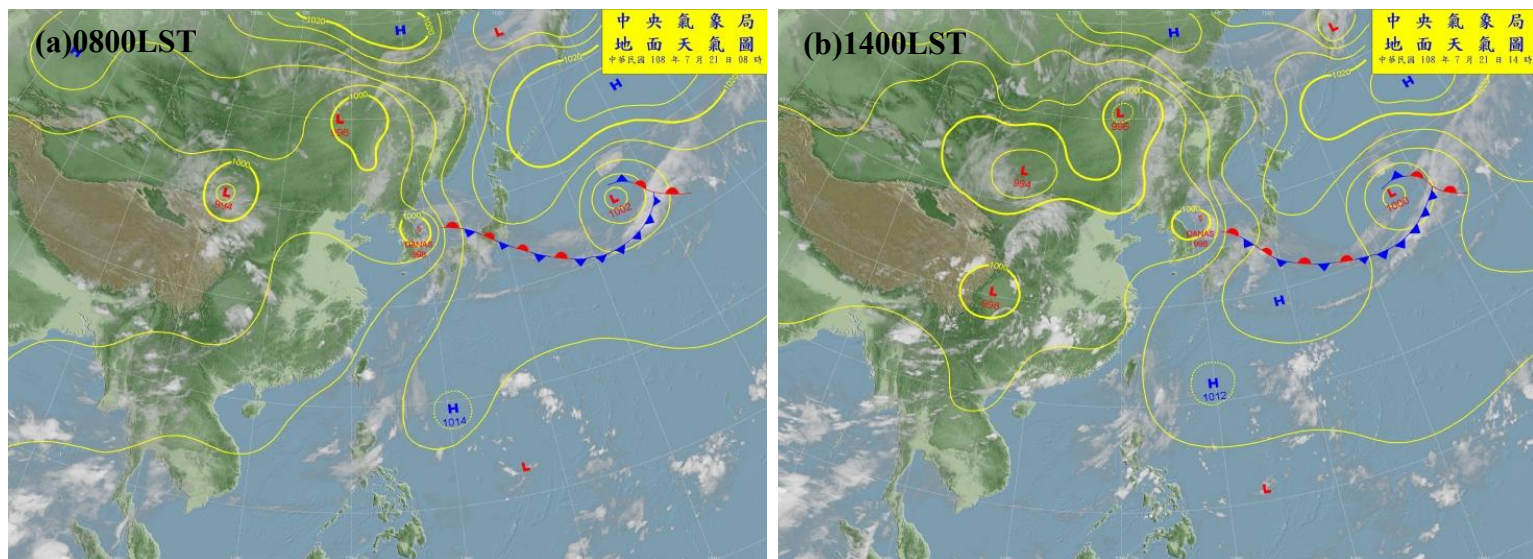


圖 5-9，2019/07/21 (a)0800LST(b)1400LST 地面天氣圖。




圖 5-10，2019/07/21 0800LST 板橋探空斜溫圖。

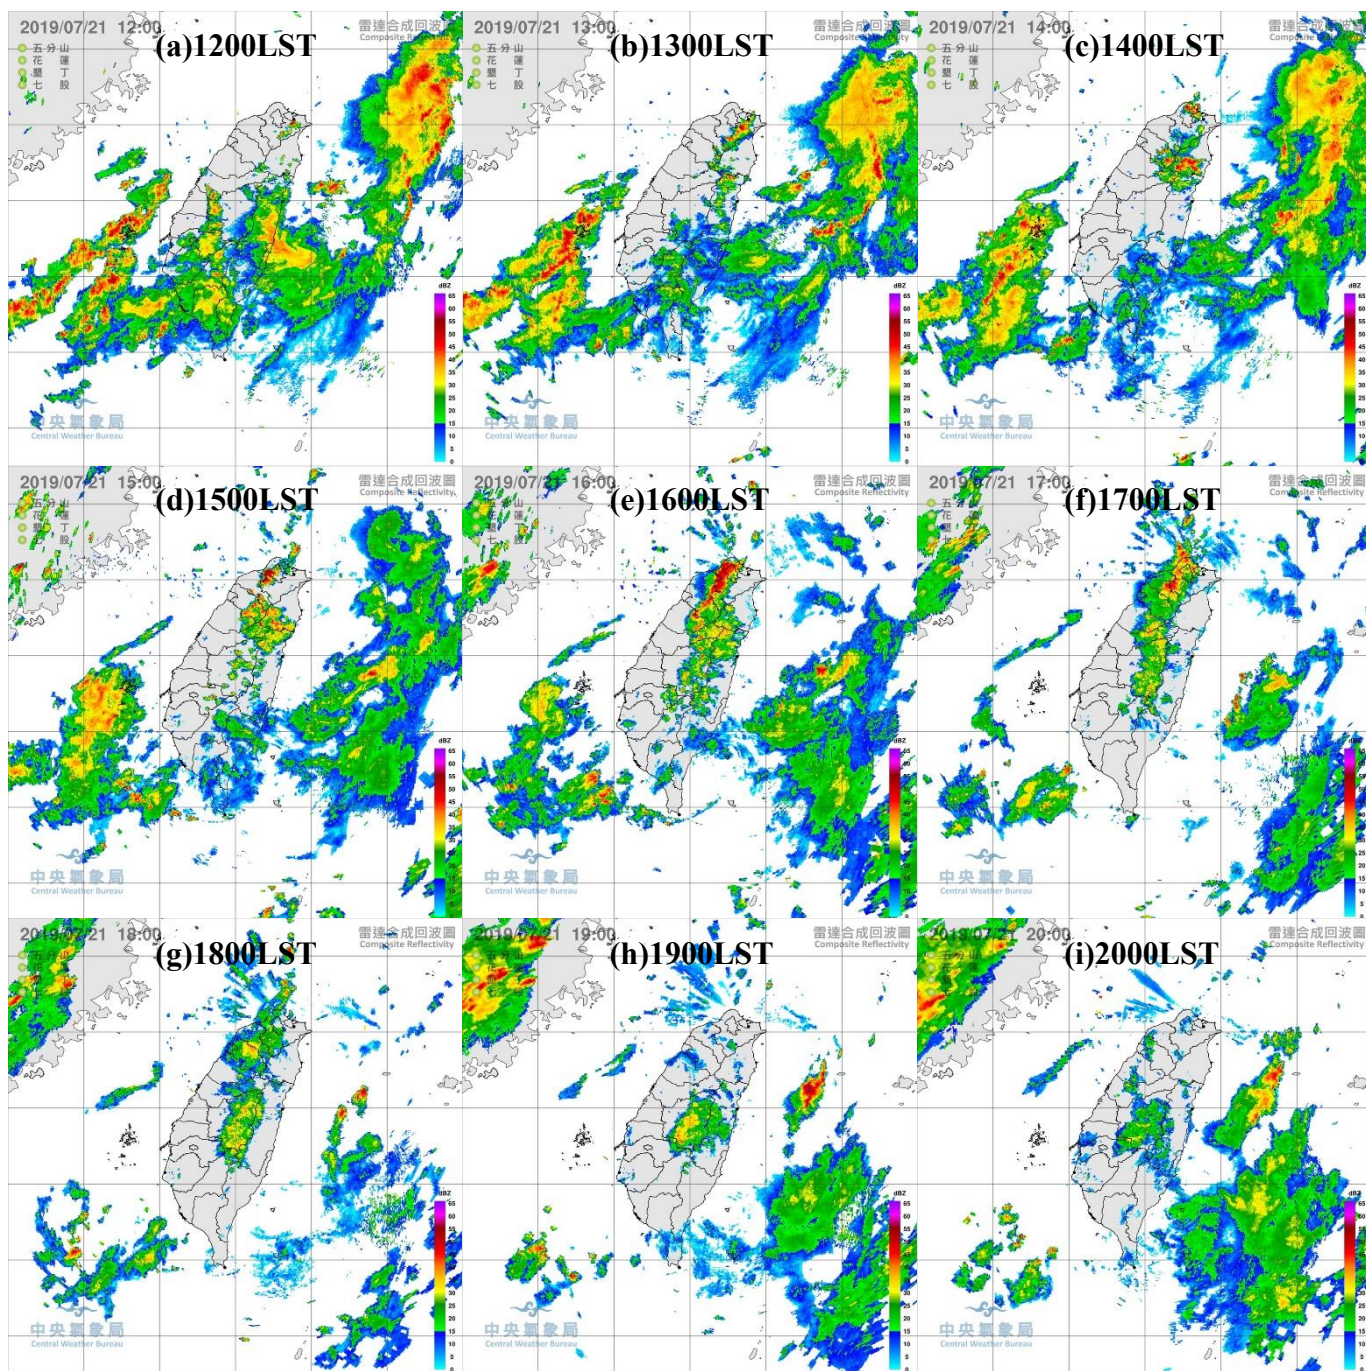



圖 5-11，2019/07/21 (a)1200LST-(i)2000LST 逐時氣象局最大雷達合成回波圖。

(a) WPS 網格設定



(b) d03 網格陸地點選取範圍

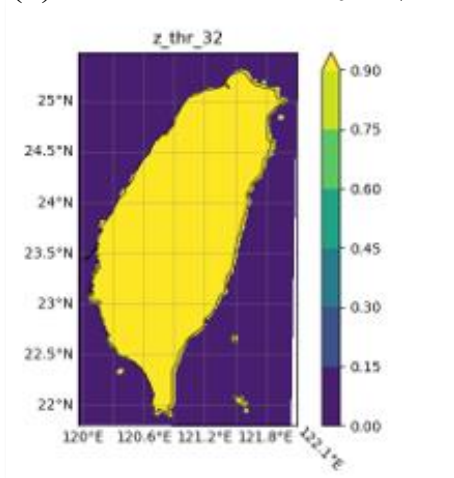


圖 5-12，2019/07/21 個案二 (a)模式模擬之 WPS 網格設定 (b)d03 網格陸地點選取範圍。其中陸地點選取範圍以模式最低 eta 層之 z 作為閾值決定。

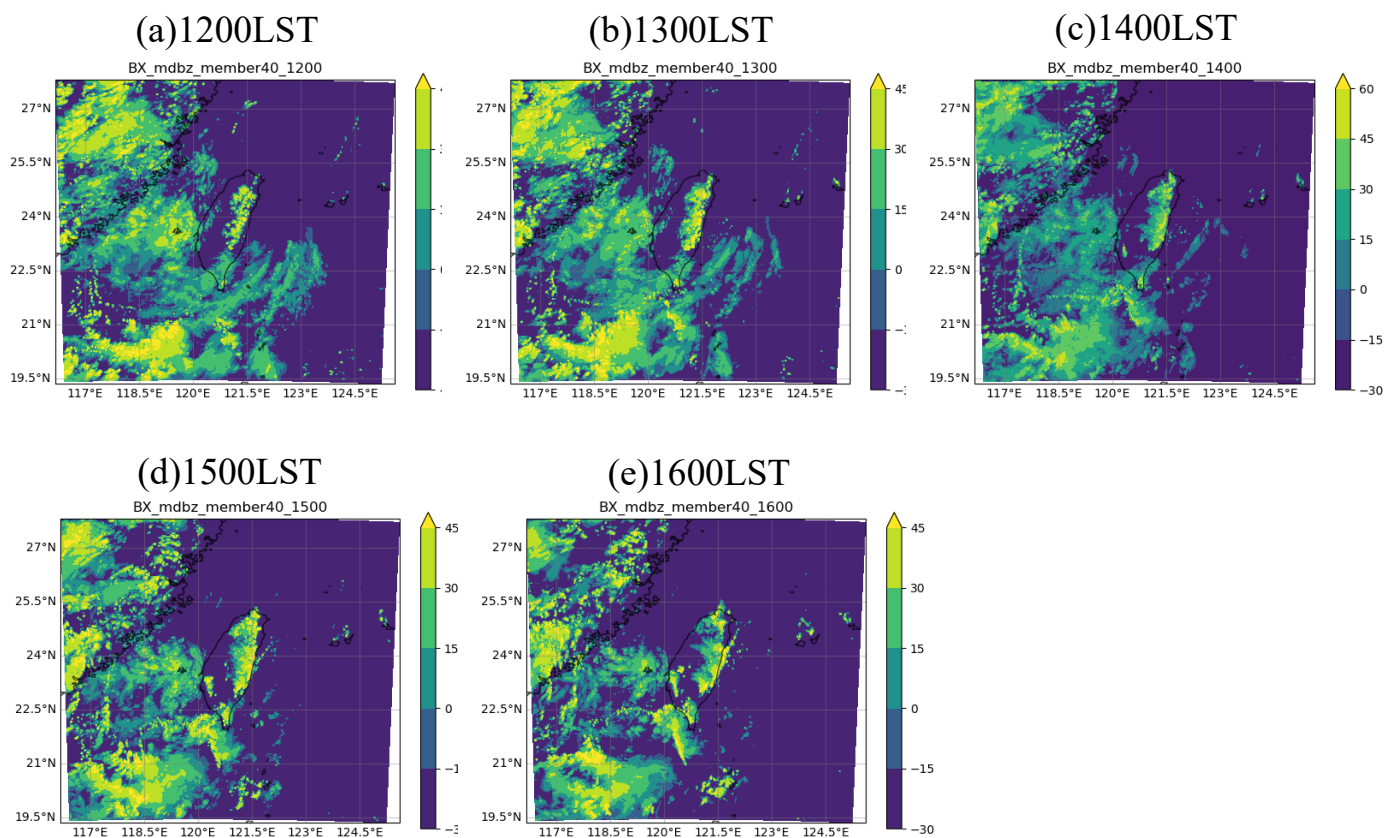


圖 5-13，2019/07/21 第 40 系集(a)1200LST-(e)1600LST 午後逐時最大回波圖。

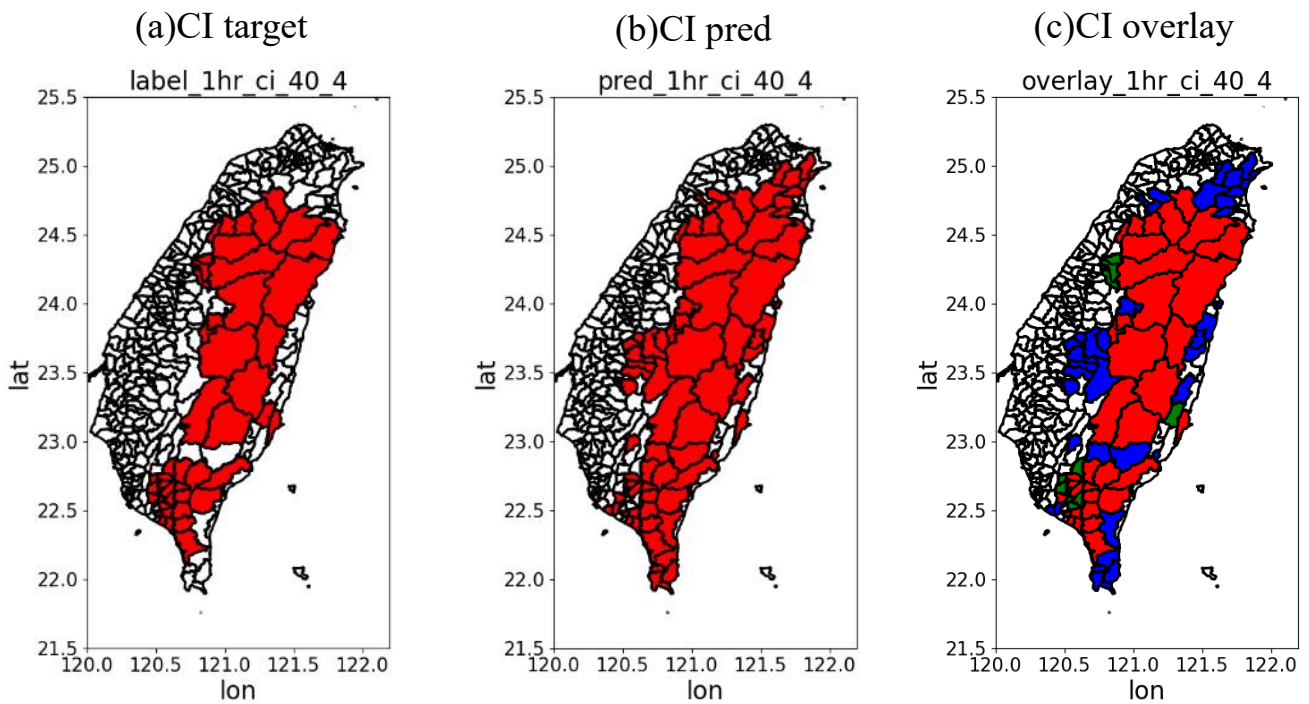


圖 5-14，鄉鎮市標準個案一第 40 系集成員 1500 時對流發展期之 (a)CI 預測目標 (b)CI 預測 (c)為目標預測疊圖，其中紅色為 TP，綠色為 FP，藍色為 FN，白色為 TN。

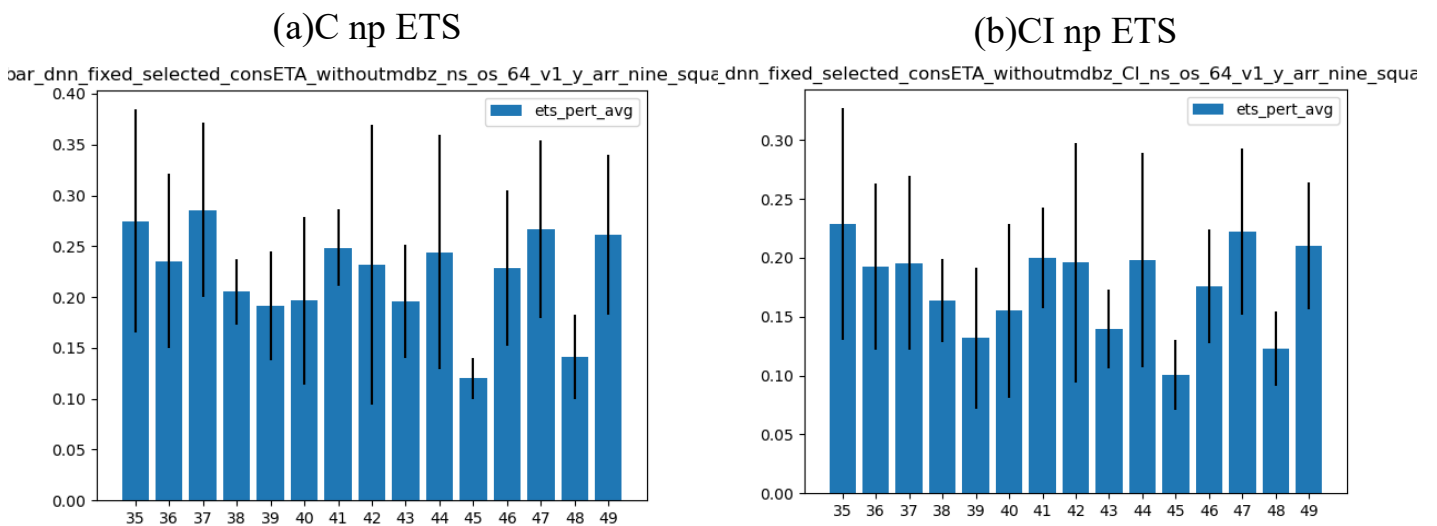


圖 5-15，DNN 使用[常數+純物理]變數群個案一各測試系集之 (a)C np ETS (b)CI np ETS 一小時預測。

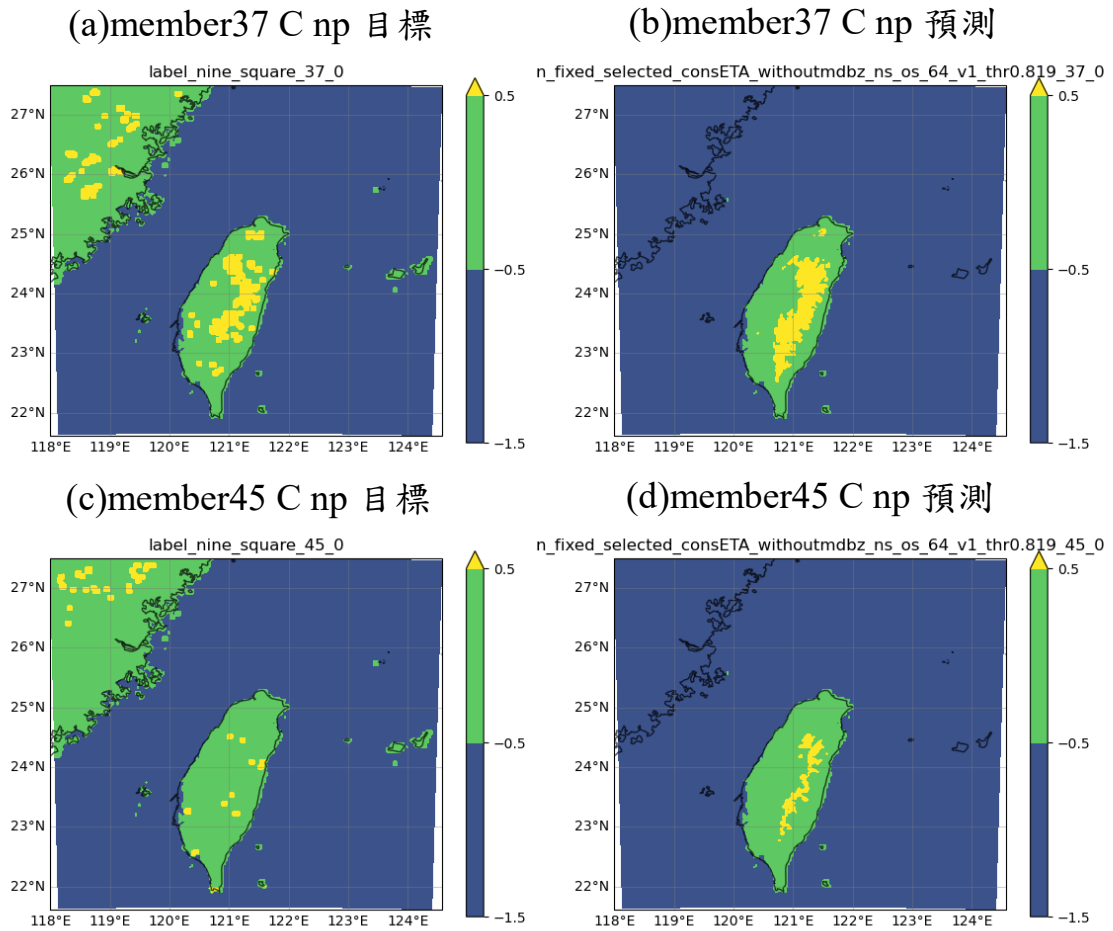


圖 5-16，(a)系集成員 37 之 C np 預測目標 (b)系集成員 37 之 C np 預測 (c)系集成員 45 之 C np 預測目標 (d)系集成員 45 之 C np 預測。

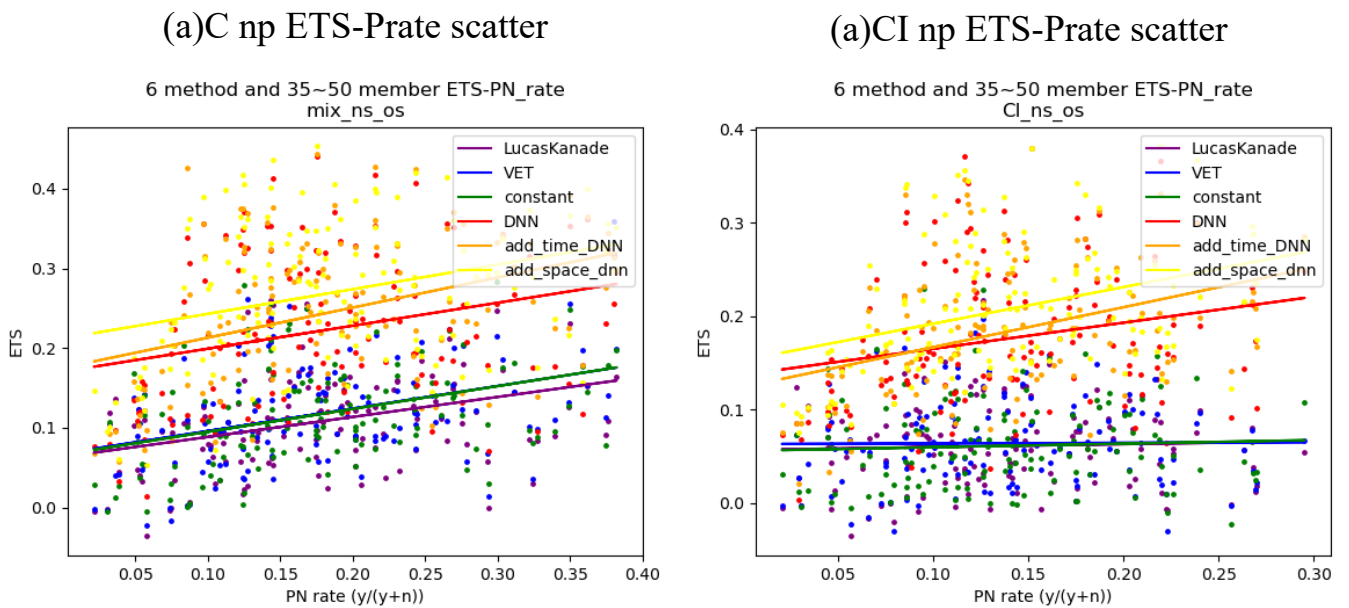


圖 5-17，(a)C np (b)CI np 各方法 ETS 對 Prate 之散布圖與回歸直線。