



應用深度學習於颱風強度與中心氣壓估測之研究： 模型泛化驗證、在地化調整及自動化作業

20250904

廖宣諭¹、蔡宗育¹、陳柏孚²、林憫惠³、周鑑本³、劉豫臻³、蔡政達¹、趙俊傑¹
資拓宏宇國際股份有限公司¹、國立臺灣大學氣候天氣災害研究中心²
中央氣象署科技發展組³



資拓宏宇永遠與您一起創新前進

always innovative always IISI

背景分析與目的 - 德氏分析法, Dvorak technique

- 早期德氏法 (Davorak technique, DT; Dvorak 1975, 1984)
- 客觀德氏法 (objective Davorak technique, ODT; Velden et al. 1998)
- 進階客觀德氏法 (Advanced objective Dvorak technique) (AODT)(Olander et al. 2002)
- 進階德氏法 (Advanced Dvorak technique)(ADT)(Olander and Velden 2007)進一步融入了下列新技術 > CIMSS執行的第九版(Olander et al. 2019; ADT v9)

背景分析與目的 - 德氏分析法, Dvorak technique

- 德氏法廣為使用，但仍有一些主觀判定的元素，所以不同的作業中心會估算出不同的颱風強度(Maskey et al. 2018)，因而有各種增強德氏法或採用不同方法的研究
- Krizhevsky等(2012)開發出AlexNet
 - ImageNet評比中超過了人類表現
 - 卷積式神經網路(convolutional neural network, CNN)的基本架構、元件與方法大致上確立
 - data driven的深度學習方法，在擷取影像特徵的能力有顯著的突破。

背景分析與目的

- 本研究的發展重點在於發展一個新的深度學習模型架構來降低強烈颱風最大風速估算的誤差，並發展颱風中心氣壓推估模型。
- 本研究以模型堆疊架構，發展出三個模型
 1. 中心定位模型
 2. 分類模型(分出熱帶低壓、輕度、中度、強烈颱風)
 3. 四個強度回歸模型(用來估算熱帶低壓、輕度、中度、強烈颱風的最大風速)

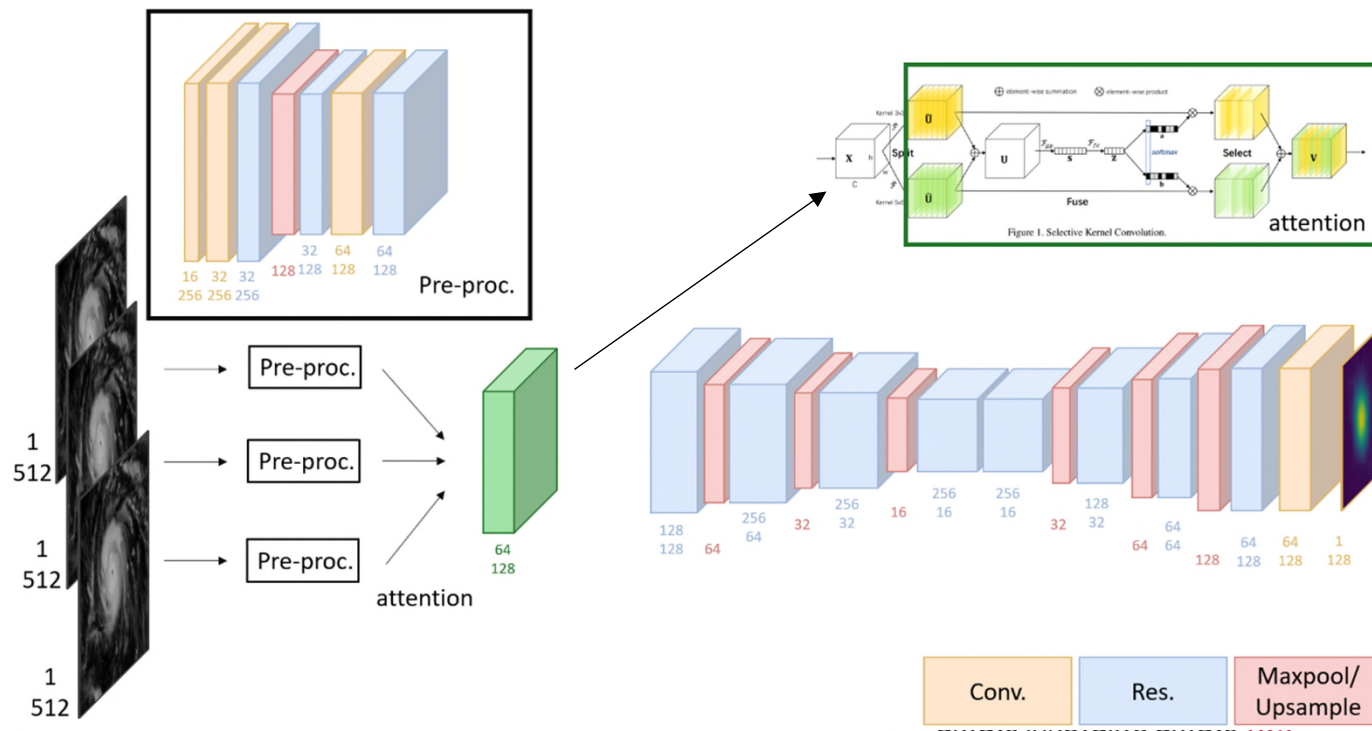
模型 - 中心定位模型

- 參考Tan(2021)建立基於encoder-decoder結構之模型架構(卷積編碼-解碼模型的深度學習架構 - TCLNet)，兩個階段

1. 特徵提取階段：卷積層提取重要特徵。
2. 編碼-解碼階段：將特徵編碼為低維表示，再解碼生成熱圖。也引入注意力機制(Sk-net)，從不同頻道學習不同特徵

- 使用的衛星波段

1. 初期：B07、B08、B13
2. 後期：B07、B08、B09、B10、B13、IRWV



模型 - 中心定位模型

Input size [pixel]	Number of variables	cross	Test set distances [km]
401	3	False	21.596877
		True	21.846040
	6	False	20.326043
		True	21.672526
512	3	False	20.292248
		True	22.112586
	6	False	20.983909
		True	20.375754

模型 - 中心定位模型

Input size [pixel]	Number of variables	cross	Test set distances [km]
401	3	False	21.596877
		True	21.846040
	6	False	20.326043
		True	21.672526
512	3	False	20.292248
		True	22.112586
	6	False	20.983909
		True	20.375754

模型 - 中心定位模型


cross	upsample	norm	activation	1E-3	1E-4	1E-5	
0	0	0	0	17.323663	18.853242	20.983909	
			1	19.273742	19.550406	20.877429	
		1	0	17.208884	18.671042	38.257209	
			1	18.179491	18.830448	29.482693	
	1	0	0	17.480029	19.475022	21.368373	
			1	19.606730	21.069526	21.178238	
		1	0	21.296726	19.506043	35.781628	
			1	20.796346	20.059217	29.887919	
	1	0	0	0	16.689035	18.904831	20.375754
				1	16.839672	18.427605	20.987066
			1	0	16.968311	17.741818	32.012898
				1	19.881405	18.03376	30.553232
1		0	0	19.321591	19.026487	20.898795	
			1	21.701615	21.132049	22.091057	
		1	0	21.102022	18.838789	30.102984	
			1	19.573319	21.386149	30.873853	

模型 - 中心定位模型



cross	upsample	norm	activation	1E-3	1E-4	1E-5	
0	0	0	0	17.323663	18.853242	20.983909	
			1	19.273742	19.550406	20.877429	
		1	0	17.208884	18.671042	38.257209	
			1	18.179491	18.830448	29.482693	
	1	0	0	17.480029	19.475022	21.368373	
			1	19.606730	21.069526	21.178238	
		1	0	21.296726	19.506043	35.781628	
			1	20.796346	20.059217	29.887919	
	1	0	0	0	16.689035	18.904831	20.375754
				1	16.839672	18.427605	20.987066
			1	0	16.968311	17.741818	32.012898
				1	19.881405	18.03376	30.553232
1		0	0	19.321591	19.026487	20.898795	
			1	21.701615	21.132049	22.091057	
		1	0	21.102022	18.838789	30.102984	
			1	19.573319	21.386149	30.873853	

模型 - 中心定位模型

- 強度越強的颱風，其中心定位的準確性越高
- 即使是最強級別的颱風，仍會有預測誤差超過上百公里
- 衛星雲圖中颱風眼不明顯的情況下，誤差提高
- 如果模型預測的颱風中心與原圖片中心的距離超過50公里，則不會使用該預測中心



模型 - 中心定位模型



模型 - 中心定位模型

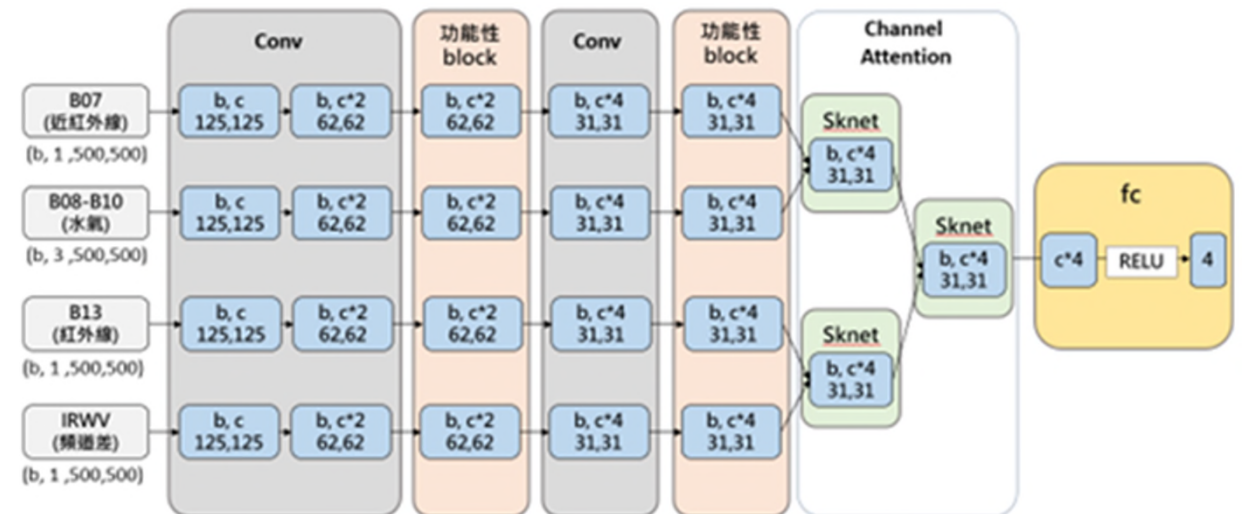
- 目前蒐集使用的西北太平洋颱風最佳路徑資料，不論是源自JTWC或氣象署，時間解析度皆為6小時，為了增加訓練資料量，採用內插的方式將6小時的颱風中心點位資訊線性內插為1小時的點位資訊
- **應用**：在上線使用時，將會以JTWC當下最後一筆的六小時颱風中心經緯度資訊為中心裁切一個1,024 × 1,024公里雲圖，將雲圖給模型判斷正確的颱風中心；再以這個「新的」颱風中心經緯度資訊為中心，切取同樣大小的雲圖，以供給分類模型進行颱風強度等級分類，及回歸模型進行最大風速與中心氣壓估算。

模型 - 分類模型 & 強度回歸模型

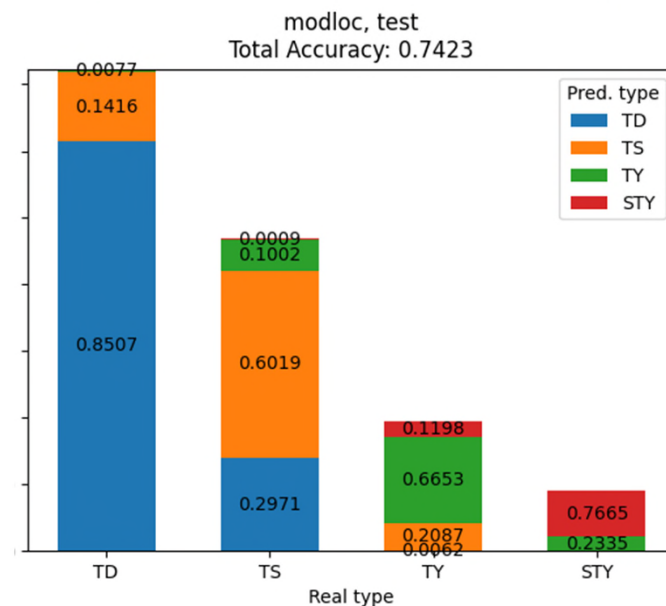
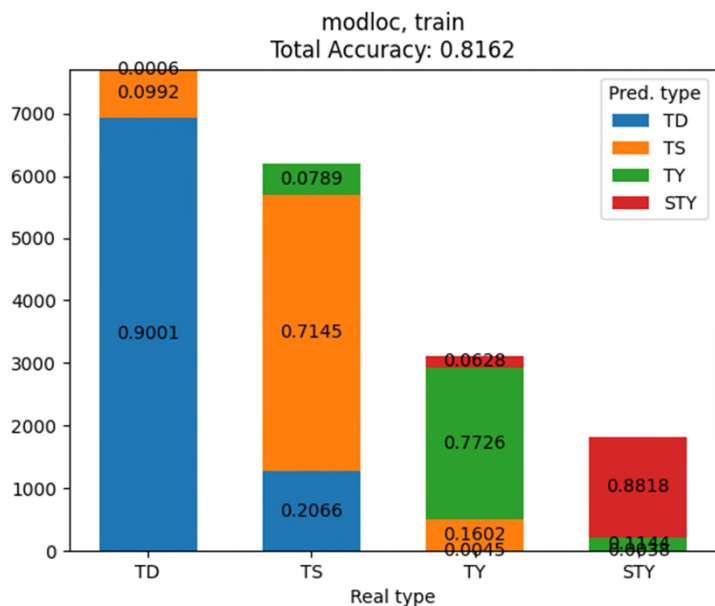
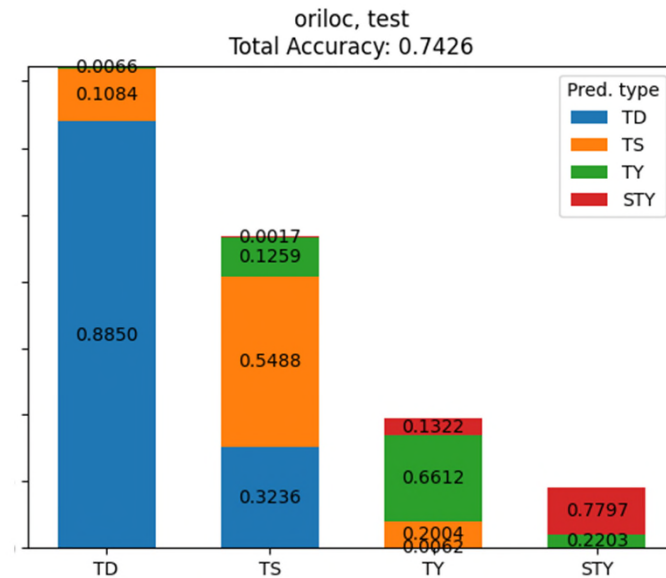
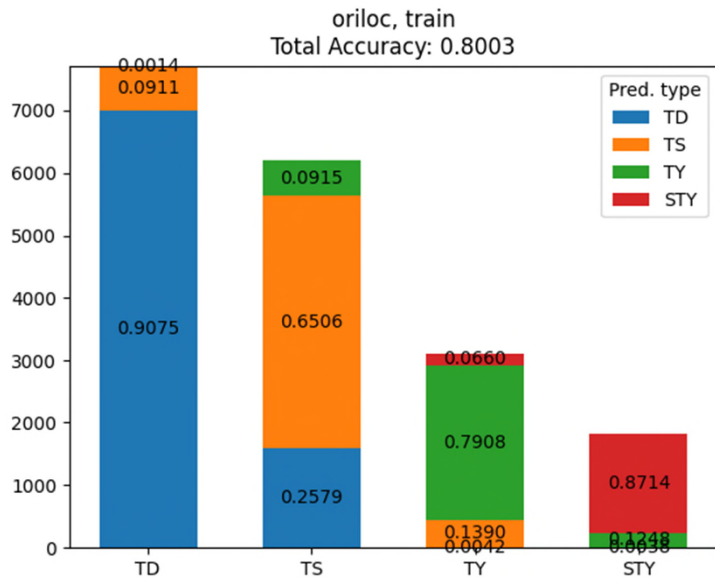
- 目前JTWC之資料為2015~2023年，共9年
- 為提高模型的泛化能力，將資料分成四組做為不同的訓練資料(一種模型架構，四種模型參數)
 1. **Test_old** : 訓練(2015~2019)、驗證(2016)、測試(2023)
 2. **Test_new** : 訓練(2021)、驗證(2022)、測試(2023)
 3. **NM_1** : 訓練(2015~2021)、驗證(2016)、測試(2023) (without 2022)
 4. **NM_2** : 訓練(2015~2021)、驗證(2022)、測試(2023)

模型 - 分類模型

- 使用6個波段B07、B08、B09、B10、B13、IRWV
- 功能性的神經網絡
- 注意力機制(Sk-net)
- 搭配中心定位模型
- 泛化結果




模型 - 分類模型




- 左上及右上未搭配中心定位模型，分別是Train及Test的資料
- 左下及右下為搭配中心定位模型，分別是Train及Test的資料
- 測試資料為2020年
- 中心定位模型應用於實際系統後，對於強度偵測的能力能保持穩定。

模型 - 分類模型

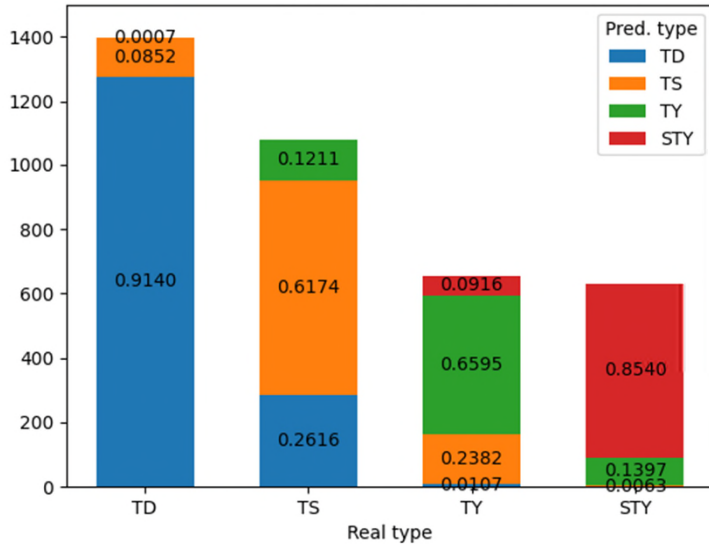
Test_old, test
Total Accuracy: 0.7715



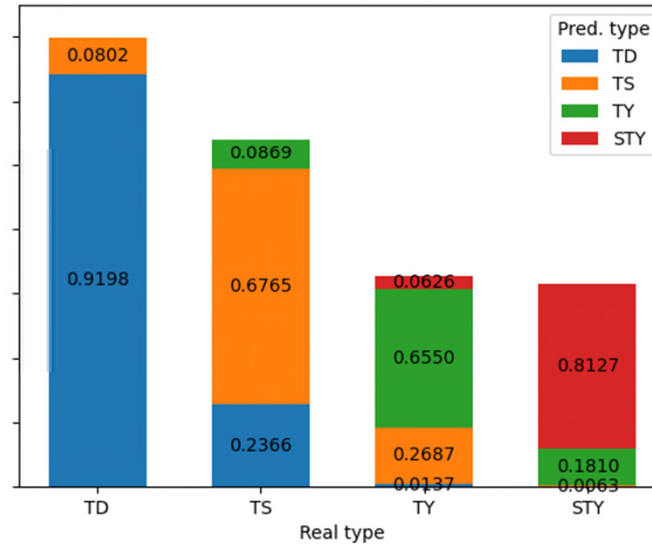
Test_new, test
Total Accuracy: 0.5371



NM_1, test
Total Accuracy: 0.7744



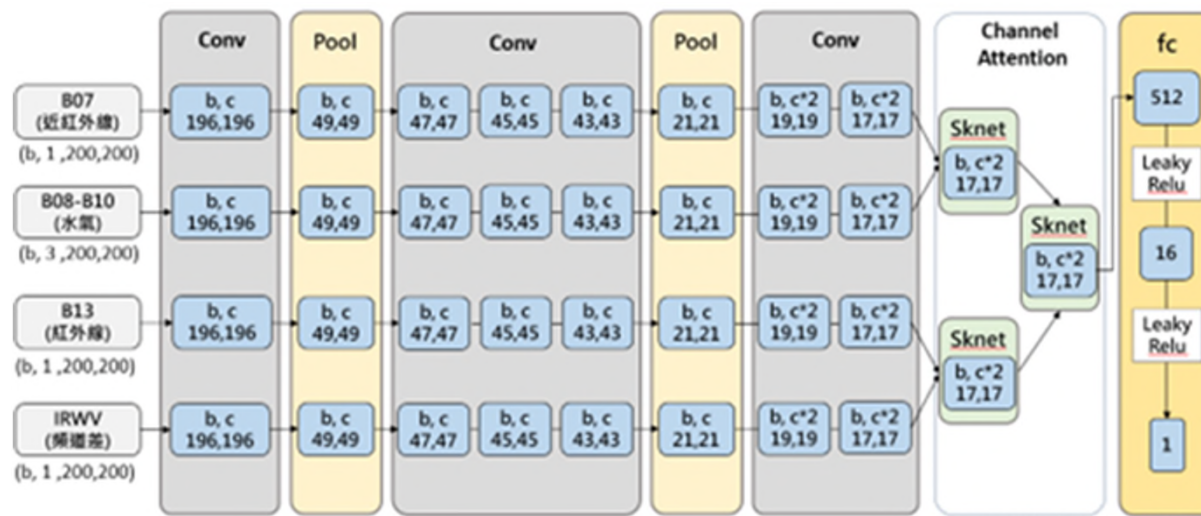
NM_2, test
Total Accuracy: 0.7858



- 搭配中心定位模型
- 分類模型分類結果。左上為 Test_old，右上為 Test_new，左下為 NM_1，右下為 NM_2
- Test_new 不論在整體還是類別的準確率皆差
- 測試資料為2023年




模型 - 強度回歸模型

- 強度回歸模型在訓練都是使用B07、B08、B09、B10、B13、IRWV，另外嘗試加入以下三種特徵變數
- 注意力機制(Sk-net)
- 分別依據右下模型架構訓練出四個強度的強度回歸模型 (STY、TY、TS、TD)
- 泛化結果



模型 - 強度回歸模型

- 強度回歸模型在過去的訓練都是使用B07、B08、B09、B10、B13、IRWV，另外嘗試加入以下三種特徵變數：
 1. 水氣紅外線頻道差(B08-B13)
 2. BD Curve
 3. 乾溼區分類



模型 - 強度回歸模型

- 三種特徵變數的使用：

1. 第一類方法是將新變數替換原先使用的變數

- ◆ 新水氣紅外線頻道差變數替換原有的 IRWV，代號為 r1。
- ◆ BD Curve 類別變數替換 B13 頻道亮溫資料，代號為 r2。
- ◆ 乾濕區分類變數替換原來的三個水氣頻道 (B08、B09、B10)，代號為 r3。

2. 第二類方法是將新變數加入模型。

- ◆ 新水氣紅外線頻道差變數加入水氣紅外線頻道差路徑，代號為 a1。
- ◆ BD Curve 類別變數加入紅外線頻道路徑，代號為 a2。
- ◆ 乾濕區分類變數加入水氣頻道路徑，代號為 a3。

- 氣壓

- STY: a1/ TY: a1/ TS: a1a3/ TD: a2

- 風速:


- STY: a1/ TY: a2/ TS: r1r2r3/ TD: a2a3

-
- a1 = [b07, b08, b09, b10, b13, IRWV, IRWV_new]
 - a2 = [b07, b08, b09, b10, b13, BDCurve, IRWV]
 - a1a3 = [b07, b08, b09, b10, am_dry, b13, IRWV, IRWV_new]
 - a2a3 = [b07, b08, b09, b10, am_dry, b13, BDCurve, IRWV]
 - r1r2r3 = [b07, IRWV_new, BDCurve, am_dry]

模型 - 強度回歸模型 & 分類模型

- 依據強度分類訓練出四個強度回歸的模型。
- 運作方式為
 1. 分類模型先辨識個案之類型，輸出為一組機率(為TD、TS、TY、STY的機率)
 2. 個案再餵入各個強度模型，各強度模型會有相對應的最大風速或中心氣壓預估值
 3. 將各個強度模型的最大風速或中心氣壓輸出值，與分類模型的輸出(各項機率或稱為權重)相乘並加總，成為最後的輸出

模型 - 強度回歸模型



- 左上為Test_old；右上為Test_new；左下為NM_1；右下為NM_2之模型最大風速預測與JTWC最大風速資料做比較。
- 測試資料都是使用2023年之資料。藍點為分類錯誤的資料；紅點為分類正確的資料。
- 除了Test_new之外，其他三者的表現較優異且差異不大。
- [後續模型泛化將不再討論Test_new]

模型 - 強度回歸模型

- 各模型參數在測試資料(2023年)的預測值與真值之間的比較
- 真值使用
 1. SAR (Synthetic Aperture Radar)
 2. CWA - TAFIS
 3. JTWC

模型 - 強度回歸模型

JTWC	MBE	MAE	RMSE
ADT	1.797	8.337	5.508
Test_old	-0.218	8.295	5.880
NM_1	-1.123	8.783	6.00
NM_2	0.859	8.481	5.992
Assemble	-0.160	8.168	5.723

SAR	MBE	MAE	RMSE
ADT	-1.604	8.209	10.656
Test_old	-2.130	7.803	9.597
NM_1	-1.643	7.424	9.045
NM_2	-2.317	7.804	9.647
Assemble	-2.030	7.558	9.239

- ✓ 與TAFIS資料校驗統計結果；僅比較最大風速
- ✓ JTWC vs Test_old：643筆資料
- ✓ JTWC vs NM_1：643筆資料
- ✓ JTWC vs NM_2：643筆資料
- ✓ JTWC vs ADT：518筆資料
- ✓ JTWC vs Assemble：643筆資料
- ✓ 單位：m/s

- ✓ 與SAR資料校驗統計結果；僅比較最大風速
- ✓ TAFID vs Test_old：62筆資料
- ✓ TAFID vs NM_1：62筆資料
- ✓ TAFID vs NM_2：62筆資料
- ✓ TAFID vs ADT：54筆資料
- ✓ TAFID vs Assemble：62筆資料
- ✓ 單位：m/s

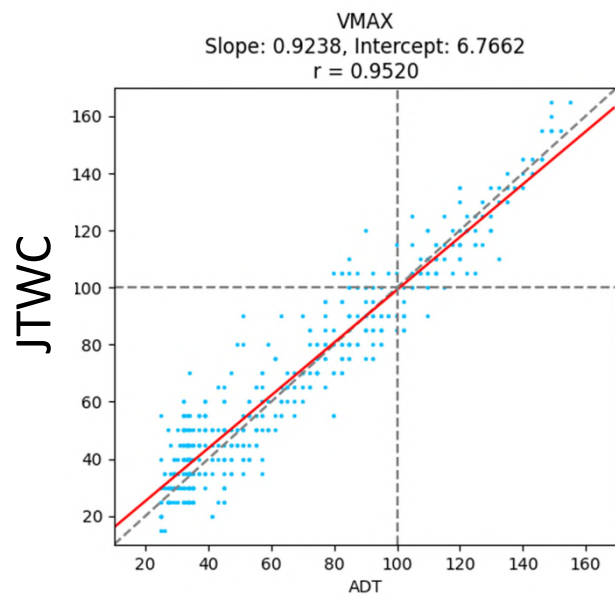

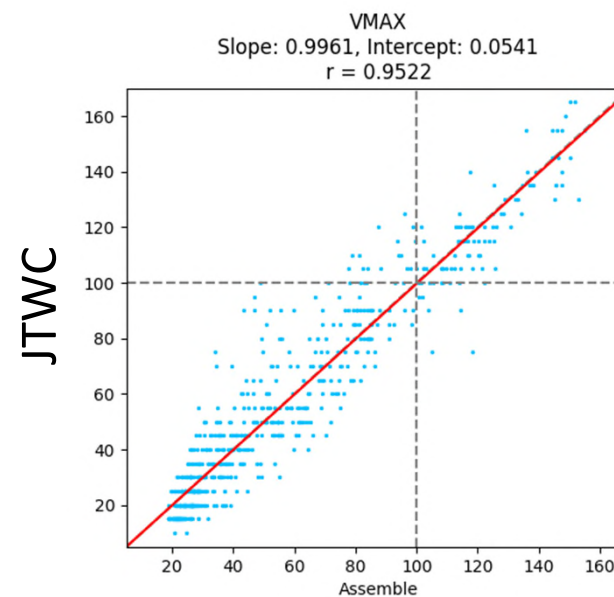

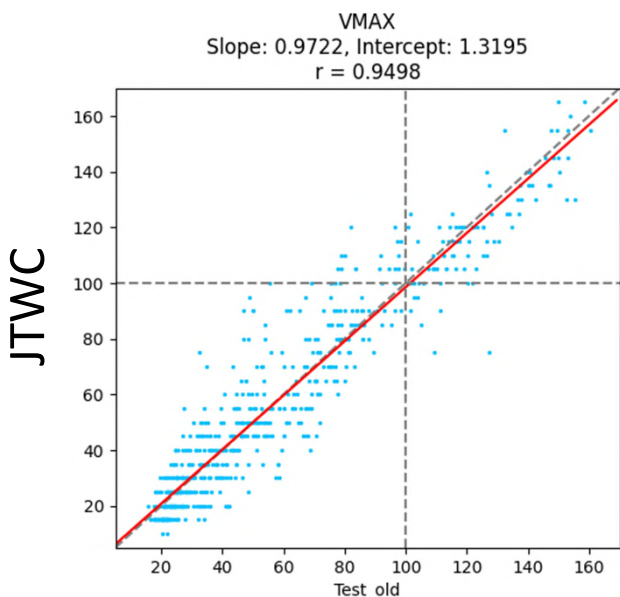
模型 - 強度回歸模型

TAFIS	MBE	MAE	RMSE
ADT	1.469	11.073	7.428
Test_old	1.388	12.361	8.300
NM_1	0.330	11.935	7.990
NM_2	3.068	11.675	7.941
Assemble	1.595	11.610	7.850

- ✓ 與TAFIS資料校驗統計結果；僅比較最大風速
- ✓ TAFID vs Test_old：753 筆資料
- ✓ TAFID vs NM_1：753 筆資料
- ✓ TAFID vs NM_2：753 筆資料
- ✓ TAFID vs ADT：759 筆資料
- ✓ TAFID vs Assemble：753 筆資料
- ✓ 單位：m/s






- 以均方根誤差(RMSE)作為主要的評估方向。
- 與JTWC相比，三個單一模型的RMSE比ADT來的高，儘管如此，Assemble的結果仍讓RMSE有所下降
- 與SAR資料相比，ADT的RMSE反而較三個單一模型及Assemble的結果來的大，而Assemble的RMSE則介在另外三個單一模型之間。
- 與CWA - TAFIS相比，三個單一模型的RMSE也是較高，而Assemble的RMSE相對三個單一模型也是下降的

模型 - 強度回歸模型 - VS JTWC






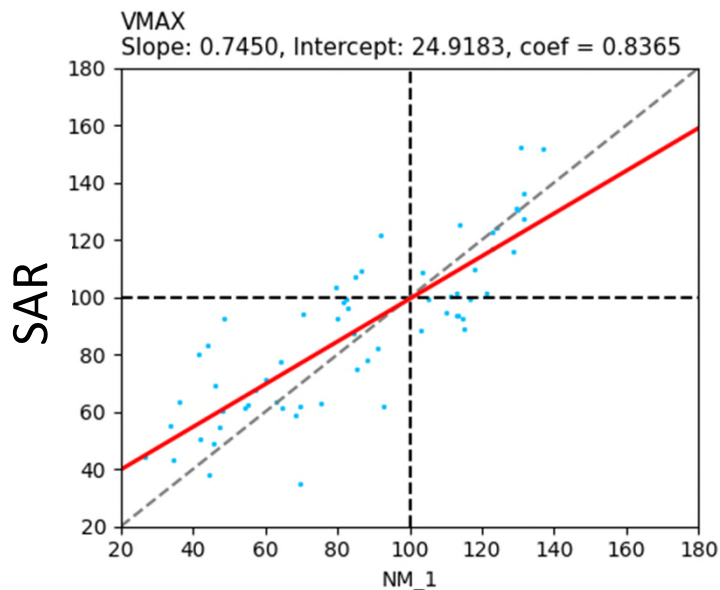

- 三個單一模型以及ADT資料與JTWC資料的回歸線斜率(後簡稱斜率)基本上都相當接近1
- Assemble的斜率則是更優於三個單一模型以及ADT，另外在皮爾森相關係數(corrcoef)，Assemble也是最高的。

模型 - 強度回歸模型 - VS TAFIS



- 三個單一模型及ADT中，NM_2的斜率最接近1、皮爾森相關係數則是ADT最高，儘管如此，Assemble的斜率及皮爾森相關係數表現都非常優異

模型 - 強度回歸模型 - VS SAR




- Assemble的斜率及皮爾森相關係數都與其他四者表現得更好

資料在地化


- 現行中央氣象署作業上所使用的風速為**10分鐘平均風**，與JTWC所使用的習慣(**1分鐘最大持續風速**)有所不同
- 未來模型讀取的及時資料為JTWC，為了自動作業化的流程能夠貼近現行的作業習慣，而提出將資料在地化。
- 國際上針對「**10分鐘平均風**」以及「**1分鐘最大持續風速**」並未有全球統一之標準轉換方法

資料在地化

- 為了讓這兩個風速轉換之間能更彈性及符合現況，因此提出訓練出轉換兩種資料的非線性模型
- 使用JTWC與CWA - TAFIS資料為訓練資料跟標的資料，建立兩組Multilayer Perceptron (MLP，多層感知器)
- 分別為「1min轉10min」及「10min轉1min」之模型，年份為2020~2023年，總共4年。
- 兩者之激勵函數、優化函數及學習率分別為ReLU、Adam及1E-3；隱藏層分別為1層(128)及2層(8, 16)；R2分別為0.9022及0.9144

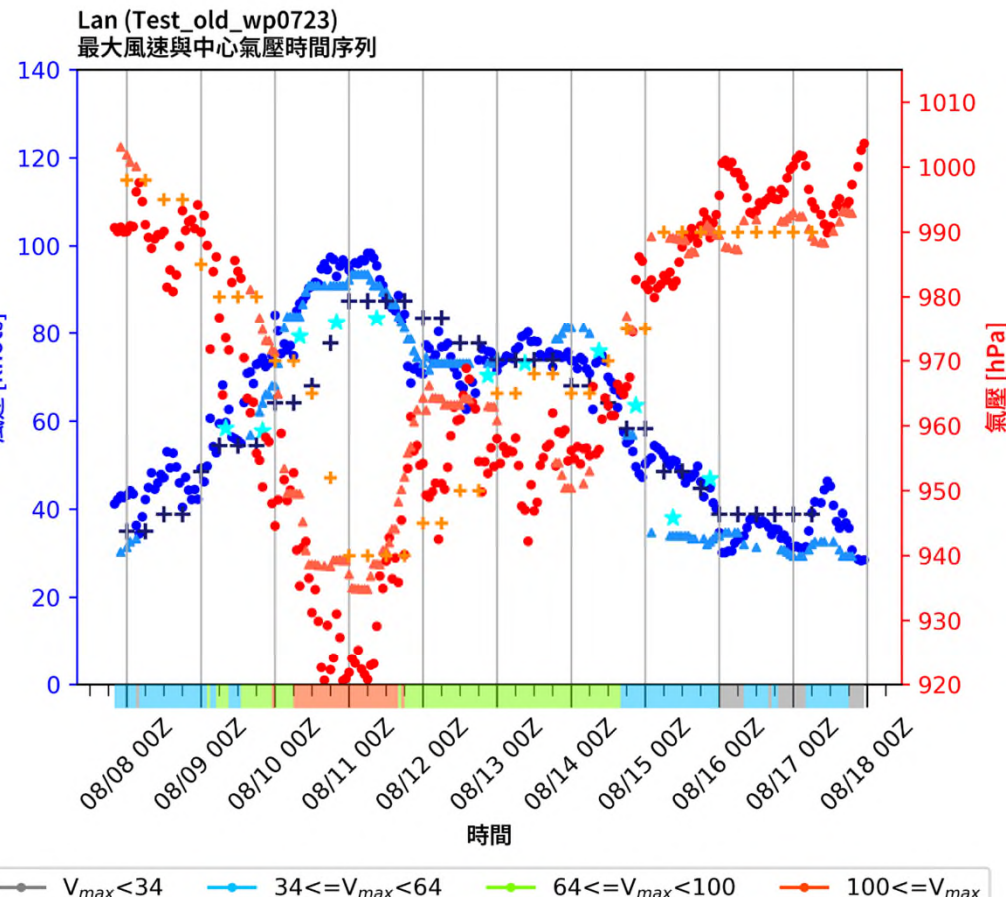


資料在地化



● : Test_old ▲ : ADT ★ : SAR + : TAFIS

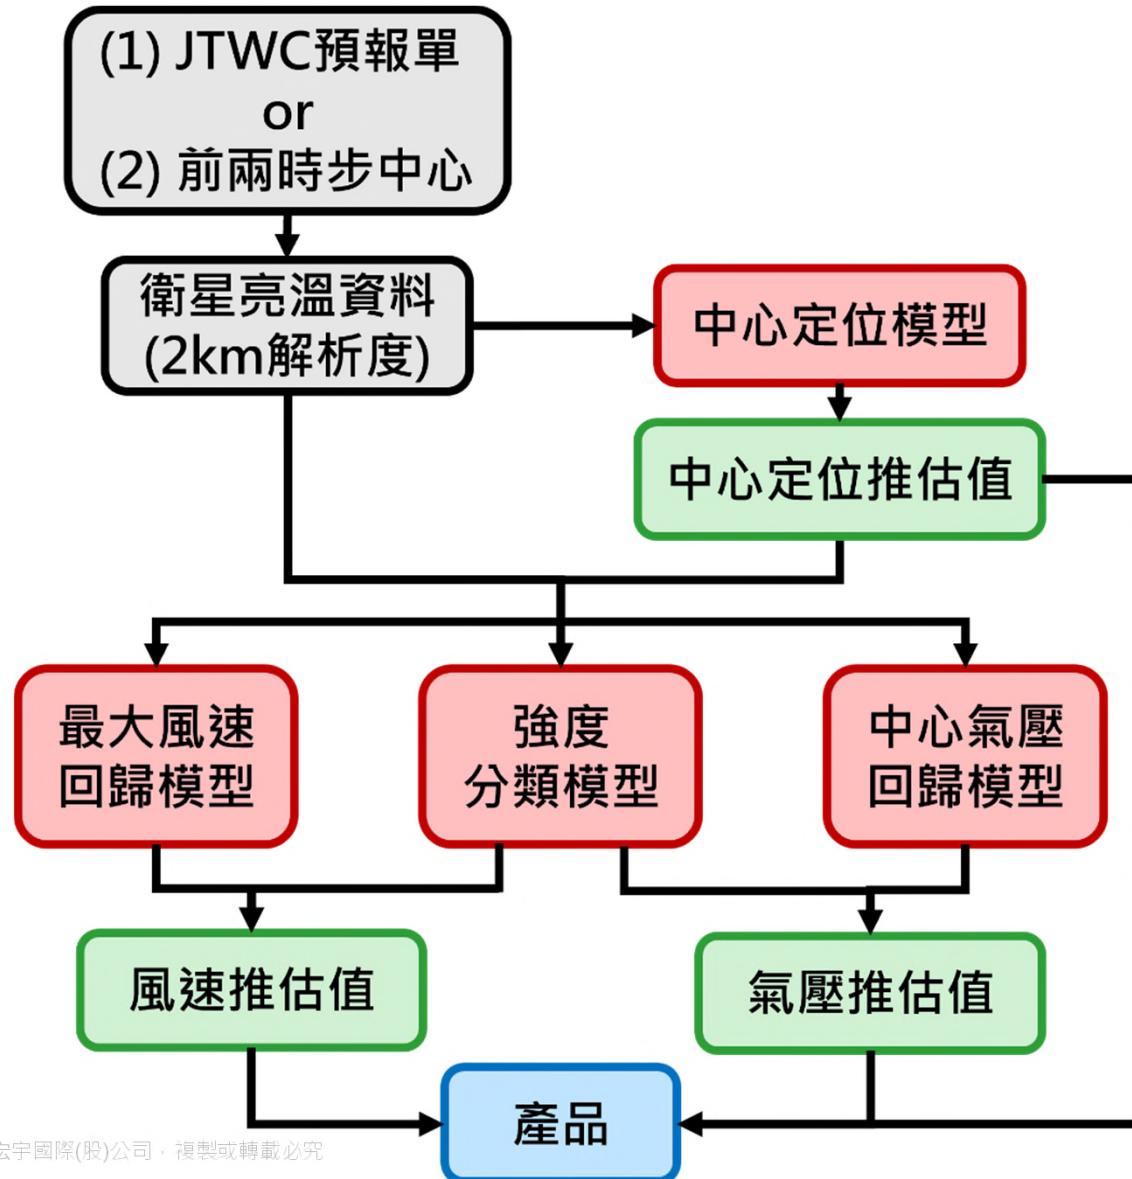
10min轉1min



● : Test_old ▲ : ADT ★ : SAR + : TAFIS

1min轉10min

自動作業化流程



- 每小時執行一次
- 初始中心點除了使用 JTWC 預報內插資料，還新增了透過過去時間步的外插進行預測

自動作業化流程

- 透過分類模型獲得各強度的權重，然後結合風速和氣壓回歸模型計算出風速和氣壓的推估值，最後將這些推估結果製作成產品
- 評估是否使用三個單一模型(Test_old、NM_1、NM_2)所產生的系集平均結果，以及在地化概念的風速轉換流程以符合作業習慣的風速表示。

自動作業化流程

- 目前規劃的產出產品有四類

1. 颱風路徑圖

- 由於中心定位模型在颱風強度較弱的情況下，中心定位會變得相當不穩定，所以颱風路徑圖中心點目前是以JTWC的資料為基準。

2. 最大風速與中心氣壓時間序列圖

- 最大風速與中心氣壓分別會以兩種方式呈現於圖上，第一種是點形式，代表的是模型推估值；第二種是線形式，代表的是模型推估值前後共三個時步的滑動平均值。時序圖下方的色條代表的是推估風速對應的颱風強度區間。

3. 資料列表

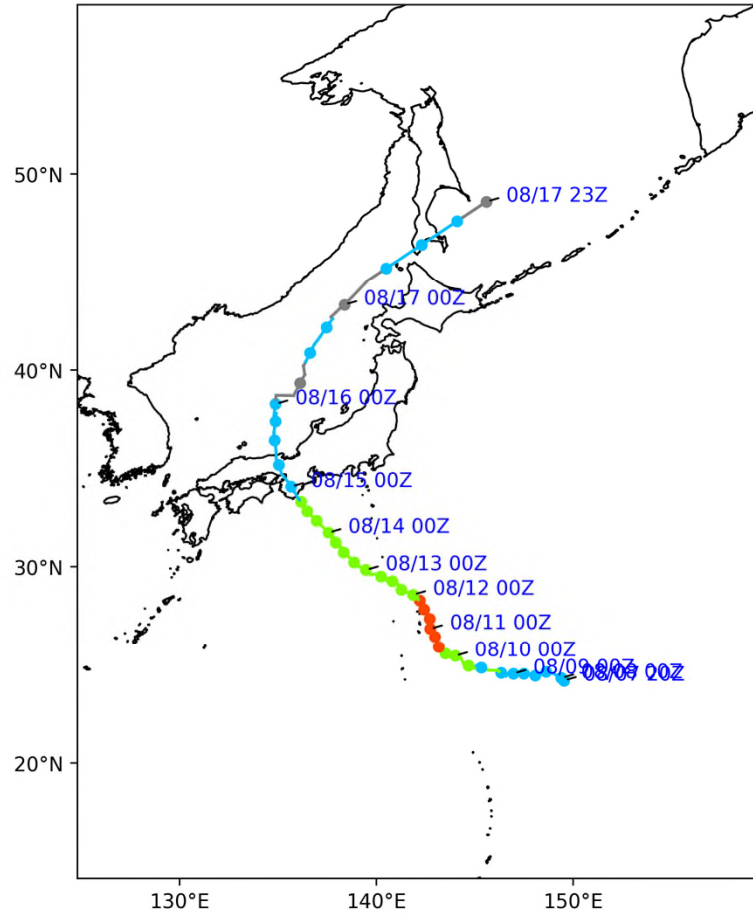
- 將每小時的最大風速、中心氣壓推估值、以及中心位置(包含模型、JTWC、ADT)記錄於此表。

4. 即時動態資料


- 每小時更新，僅記錄該小時的中心位置、最大風速、中心氣壓推估值，以及上述資訊與前一時步的差距。

自動作業化流程

Test_old (Lan)
颱風路徑圖



Lan (Test_old_wp0723)
最大風速與中心氣壓時間序列



結語

1. 目前有三個主要的模型，包含中心定位模型、強度分類模型及強度回歸模型。
2. 目前使用2015~2023年的資料，為了模型的泛化，進行將年份做不同的排列組合成Test_old、Test_new、NM_1、NM_2。
3. 在驗證評估中，以JTWC、CWA - TAFIS及SAR資料作為真值，以2023年為測試資料。除了Test_new之外，其他三者的學習狀況相對都較穩定，並與ADT旗鼓相當。
4. 表現較穩定的模型之系集平均與真值的誤差甚至比ADT表現得更好。

結語

5. 在地化：非線性之轉換模型。
6. 自動化作業方面，建議納入本年度之新模型架構之系集平均作為最終輸出。
7. 未來方向：
 - 納入更多的颱風資料(例如2023年之後)，以模型泛化為核心主軸概念，進行更多的模型測試並得到系集平均，以維持模型輸出的穩定。
 - 在模型架構方面，過去探索了多項變數組合，但未深入剖析各變數對模型學習的具體貢獻。未來也可以進一步研究這些變數的作用，這有助於未來變數選擇的參考。

- 敬請指教 -

資拓宏宇永遠與您一起創新前進
always innovative always **IISI**

