

西北太平洋颱風快速增強之機率預報模式開發

余佳宜 蔡孝忠 張麗秋

淡江大學水資源及環境工程學系

淡江大學水環境資訊研究中心

摘要

颱風強度快速增強(Rapid Intensification；簡稱 RI)為目前颱風預報中最具挑戰性的項目之一。根據美國國家颶風中心(National Hurricane Center)之定義，熱帶氣旋之中心最大風速若在 24 小時內增強達 30 kt 以上，則將該案例之強度變化認定為 RI 等級。本研究採用 Tsai and Elsberry(2014)之颱風強度類比預報模式(Weighted Analog Intensity Prediction；WAIP)，配合 SHIPS 開發資料(Statistical Hurricane Intensity Prediction Scheme Developmental Data)之大氣及海洋環境變數，嘗試開發未來 24 小時 RI 發生機率之統計預報模式。

本研究使用 2000-2012 年之颱風個案資料，採用羅吉斯迴歸(Logistical Regression)，配合 Hosmer-Lemeshow 適合度檢定、ROC(Receiver Operating Characteristic)曲線下方面積(Area Under Curve；AUC)、敏感度、特異度及準確度等校驗指標，討論預測變數(predictor)的最佳組合。初步研究結果顯示，相較於僅採用 SHIPS 資料的預測模型，以 WAIP 模式搭配 SHIPS 大氣海洋環境變數所建立之預測模型，其預報校驗 AUC 值可達 0.83，表示此模式具有良好的判別能力。此外，模式之敏感度、特異度和準確度皆優於其他預測變數組合之預測模型，因此建議使用 WAIP 搭配 SHIPS 大氣海洋資料進行 24 小時 RI 機率預報模式的開發。本研究並進一步應用類神經網路(Artificial Neural Network；ANN)，討論人工智慧理論對於 24 小時 RI 機率預報模式的改進效果。測試結果顯示，以非線性 ANN 方法建立預報模式，其預報測試組之敏感度可較原始模式提升 12.57%。本研究亦將 TCHP 相關因子額外納入 ANN 進行訓練，模式預報測試結果可優於原始模式，其中以原始 Model A 配合 ATCHP 之模式表現最佳，訓練組及測試組之敏感度可較原始模式分別提升 10.3%及 7.4%。

一、研究目的

颱風強度快速增強(Rapid Intensification；簡稱 RI)為目前颱風預報中最具挑戰性的項目之一。根據美國國家颶風中心(National Hurricane Center)之定義，熱帶氣旋之中心最大風速若在 24 小時內增強達 30 kt 以上，則認定該案例之強度變化已達 RI 等級。颱風路徑預報誤差於近年已有明顯的改進趨勢，但強度預報技術仍不理想，部分誤差來源即是對於 RI 個案的掌握不佳，當颱風強度變化達到 RI 等級，可能造成 24 小時強度預報誤差達到 30 kt 或甚至更高。

本研究參考 Kaplan et al. (2010)提出之 RI 發生機率預測方法，除了採用 SHIPS 開發資料(Statistical Hurricane Intensity Prediction Scheme Developmental Data; DeMaria, 2005)之大氣及海洋環境變數之外，嘗試加入 Tsai and Elsberry (2014)之颱風強度類比預報模式(Weighted Analog Intensity Prediction；WAIP)，開發未來 24 小時 RI 發生機率之統計預報模式，以提供颱風預報作業之參考。

二、研究資料與方法

2.1 研究資料

本研究使用美國聯合颱風警報中心(Joint Typhoon Warning Center，簡稱 JTWC)之颱風最佳路徑資料、Tsai and Elsberry (2014)之颱風強度類比預報模式(WAIP)及 DeMaria et al. (2005)之 SHIPS 開發資料進行研究。

颱風強度類比預報模式(WAIP；Tsai and Elsberry, 2014)是採用 JTWC 自 1945 年起之颱風最佳路徑資料做為歷史颱風資料庫，以類比颱風個案的方式搜尋相似之歷史颱風個案，開發颱風強度統計預報指引。此外，為使路徑相似之個案亦具有相似的大尺度背景環境或季節特徵，歷史個案與目前預報個案之日期差異必須小於 30 日，並利用類似個案之颱風中心最大風速資料，配合路徑相似度給予適當權重，以分別計算每 12 小時之颱風強度估計值。

SHIPS 開發資料為颱風強度之相關變數資料，包含氣候平均數據、大氣環境參數(例如：垂直風切)以及海表面溫度等相關參數。本研究使用 2000-2012 年之颱風個案資料，採用隨機選取的方式，將資料樣本區分為 60%的模式訓練組及 40%的預報測試組，以降低年際變化的影響。在剔除不合理資料之後，訓練

組和測試組分別有 1839 筆 (共 292 個颱風個案)和 1259 筆 (共 175 個颱風個案)可做為後續研究使用。SHIPS 開發資料之變數代碼可參考 DeMaria et al. (2005)及 http://rammb.cira.colostate.edu/research/tropical_cyclones/ships/developmental_data.asp。

2.2 研究方法

在模式開發的部分，本研究採用羅吉斯迴歸 (Logistical Regression)，並透過 Hosmer-Lemeshow 適合度檢定 (Hosmer and Lemeshow, 1988)、ROC 曲線 (Receiver Operating Characteristic Curve) 之曲線下方面積 (Area Under Curve; AUC)、敏感度、特異度及準確度等校驗指標，探討預測變數 (predictor) 的最佳組合。此外，本研究更進一步應用類神經網路 (Artificial Neural Network; ANN)，討論人工智慧理論對於 24 小時 RI 機率預報模式的改進效果。

2.2.1. 羅吉斯迴歸 (Logistic Regression)

標準的羅吉斯迴歸模式如下：

$$P(Y = 1|X = x) = \pi(x) \\ = \frac{e^{(\beta_0 + \beta_1 x_1 + \dots + \beta_n x_n)}}{1 + e^{(\beta_0 + \beta_1 x_1 + \dots + \beta_n x_n)}} \\ = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \dots + \beta_n x_n)}}$$

2.2.2 倒傳遞類神經網路 (BPNN)

類神經網路 (Artificial Neural Network; ANN) 將簡單的非線性函數進行組合成複雜的函數，以解決複雜映射的問題。倒傳遞類神經網路 (Back Propagation Neural Network; BPNN)，屬多層前饋式網路，以監督式學習方式，處理輸入輸出間之非線性映射關係，其特性為學習精度高、回想速度快、輸出值可為連續值或類別值，能處理複雜的樣本辨別與高度非線性的函數合成問題。例如：樣本辨別、分類問題、函數模擬以及預測等等。BPNN 架構之輸入層與輸出層是用來表現輸入項與輸出值，兩者神經元數目依問題的形式而定；隱藏層神經元數目則需以試誤法決定，而隱藏層之層數則依問題複雜度而適當採用多層之網路架構 (張和張, 2015)。

2.2.3 模式評估指標

a. ROC 曲線下面積 (AUC)

ROC 曲線下面積 (AUC) 可做為模型優劣的評估指標。AUC 的數值介於 0 到 1 之間，數值越大表示模式越好。AUC 數值之判別參考如下：

- (i) AUC 等於 0.5:
表示模式幾乎沒有判別能力 (no discrimination)。
- (ii) AUC 介於 0.7 至 0.8 之間:
表示模式具有可接受的判別能力 (acceptable

discrimination)。

- (iii) AUC 介於 0.8 至 0.9 之間：

表示模式具有良好的判別能力 (excellent discrimination)。

- (iv) AUC 大於 0.9：

表示模式具有非常好的判別能力。(outstanding discrimination)。

b. 敏感度 (Sensitivity)：

指實際發生 RI，且預報結果為發生 RI 的比例。

c. 特異度 (Specificity)：

指實際未發生 RI，且預報為未發生 RI 的比例。

d. 準確度：

預報結果與實際結果相符合的比例。

三、初步研究結果

本研究以羅吉斯迴歸建立四種模式，各模式簡述如下：

(1) Model A：

使用 WAIP 預測結果，加上 SHIPS 開發資料的大氣及海洋環境因子做為模式預報因子。經羅吉斯迴歸分析後，Model A 之機率預測模式採用 WAIP、DVMAX、PX30、POT、SHRD、LAT、RHCN 及 Z850 等因子。

(2) Model B：

使用 SHIPS 開發資料中的大氣及海洋環境因子。經羅吉斯迴歸分析後，Model B 之機率預測模式採用 DVMAX、PX30、SPD、POT、SHRD、T200、LAT、DOHC、TOHC、DOHA、TOHA 及 REFC 等因子。

(3) Model C：

僅以 WAIP 做為預報因子之機率預測模式。

(4) Model D：

僅使用 SHIPS 開發資料中的大氣因子，經羅吉斯迴歸分析後，Model D 之機率預測模式採用 DVMAX、PX30、SPD、POT、SHRD、LAT、REFC 等因子。

上述 4 個模式的適合度檢定、AUC、敏感度、特異度和準確度分析結果請見表 1、圖 1 及圖 2。由訓練組之 Hosmer-Lemeshow 適合度檢定結果可知，Model A 和 Model B 皆為適合之模式，其中 Model A 之 p-value 值在訓練組及測試組皆大於 0.3，且 AUC 為 0.83，表示模式具有良好的判別能力。而 Model C 及 Model D 之訓練組 p-value 偏低，表示兩模式為不合適的，因此本研究後續不再討論此兩組預測變數組合。若以敏感度、特異度及準確度等指標進行綜合評估，分析結果亦顯示 Model A 為較佳之變數組合，其中以敏感度之差異最為明顯，故本研究建議採用 Model A 之預報因子組合。Model A 的預報因子之中，RHCN

代表 24 小時之後的 TCHP (Tropical Cyclone Heat Potential; TCHP), 或稱海洋熱容量(Ocean Heat Content; OHC), 顯示未來 24 小時颱風中心所在位置之海洋熱容量對於颱風強度發展具有一定的重要性。不過其餘 TCHP 相關變數, 例如 DOHC、DOHA、TOHC 及 TOHA, 皆沒有通過線性模式之變數篩選檢定標準。

為了進一步測試變數之間的非線性相關性, 本研究將 Model A 所使用的 8 個預測因子做為 BPNN 之輸入層進行模式訓練。由表 2 可知, 線性羅吉斯迴歸之訓練組準確度已達 84.45%, 採用非線性架構之 BPNN 後, 訓練組之準確度僅可略為提升 1.19%至 85.64%, 顯示變數之間的線性相關性高, 因此原本採用羅吉斯迴歸已有不錯的掌握程度。不過對於發生頻率相對較為稀少的 RI 事件, 若採用敏感度做為模式主要評估標準, 羅吉斯迴歸和 BPNN 的差異便較為顯著, BPNN 之測試組敏感度仍可較原始模式提升 12.57%。

此外, 為了深入測試 TCHP 的影響, 本研究以 Model A 之預測因子為基礎, 額外將 TCHP 相關的影響因子納入 BPNN 類神經網路進行訓練。變數組合及驗證結果如表 3 及表 4 所示。由表 4 可知, 三種網路架構之 AUC 皆在 0.84 以上, 表示皆具有良好的判別能力。若採用敏感度做為模式主要評估標準, 則以 Model A 配合 ATCHP (未來 24 小時之海洋熱容量累積值) 之 BPNN 模式表現最佳, 其訓練組及測試組之敏感度可較原始 Model A 分別提升 10.3 % 及 7.4%。

四、初步結論

本研究透過線性羅吉斯迴歸方法開發 RI 機率預報模式, 預測變數採用 Tsai and Elsberry(2014)之颱風強度類比預報模式, 配合 SHIPS 開發資料中的大氣及海洋環境因子, 模式之預測準確度可達 84.45%。若以相同預報因子搭配非線性 BPNN 方法建立預報模式, 其測試組之預測敏感度可較原始模式提升 12.57%。本研究進一步將 TCHP 相關因子額外納入 BPNN 類神經網路進行訓練, 模式預報測試結果可優於原始模式, 其中以原始 Model A 配合 ATCHP 之 BPNN 模式表現最佳, 訓練組及測試組之敏感度可較原始模式分別提升 10.3%及 7.4%。

本研究未來將進一步測試其他 TCHP 相關變數之組合(例如過去 24 小時之 TCHP 累積值), 並擴充目前開發之 RI 預測模式, 將預報時間由目前的 24 小時, 延長至 48 及 72 小時, 開發具有較長預報領先時間之 RI 發生機率預測模式, 提供颱風強度預報作業使用。

參考文獻

DeMaria, M., M. Mainelli, L.K. Shay, J.A. Knaff and J. Kaplan, 2005: Further Improvements in the Statistical Hurricane Intensity Prediction Scheme (SHIPS). Wea. Forecasting, 20, 531-543.

Hosmer, D. W., Lemeshow, S., and Klar, J., 1988: Goodness - of - Fit Testing for the Logistic Regression Model when the Estimated Probabilities are Small. Biometrical Journal, 30(8), 911-924.

Kaplan, J., and M. DeMaria, and J. A. Knaff, 2010: A revised tropical cyclone rapid intensification index for the Atlantic and eastern North Pacific basins. Wea. Forecasting, 25, 220-241.

張斐章、張麗秋, 2015: 類神經網路導論原理與應用。滄海書局。

Tsai, H. C., and R. L. Elsberry, 2014: Applications of situation-dependent intensity and intensity spread predictions based on a weighted analog technique. Asia-Pacific Journal of Atmospheric Sciences, 50(4), 507-518.

表 1. 羅吉斯迴歸之測試結果比較

模式 診斷		Model A	Model B	Model C	Model D
H-L 檢定 (p-value)	訓練組	0.335	0.1953	0.0129	0.0006
	測試組	0.373	0.0831		
AUC	訓練組	0.831	0.8134	0.7467	0.798
	測試組	0.818	0.8279	0.7098	0.7884
最佳門檻值		0.4	0.45		
敏感度 (%)	訓練組	33.56	21.92		
	測試組	32	28		
特異度 (%)	訓練組	94.05	96.12		
	測試組	94.37	93.91		
準確度 (%)	訓練組	84.45	84.34		
	測試組	85.7	84.75		

表 2. 羅吉斯迴歸與 BPNN 之測試結果比較

模式 診斷		羅吉斯迴歸 Model A	BPNN Model A
AUC	訓練組	0.83	0.85
	測試組	0.82	0.83
最佳門檻值		0.35	0.4
敏感度 (%)	訓練組	33.56	42.56
	測試組	32.00	44.57
特異度 (%)	訓練組	94.05	93.79
	測試組	94.37	92.90
準確度 (%)	訓練組	84.45	85.64
	測試組	85.70	86.18

表 3. BPNN 模式之輸入變數簡述

模式	敘述
Model A	使用羅吉斯迴歸分析所決定之預報因子：WAIP、DVMAX、PX30、POT、SHRD、LAT、RHCN 及 Z850
Model A + ATCHP	使用 Model A 之預報因子，加上未來 24 小時之海洋熱容量累積值
Model A + ATCHA	使用 Model A 之預報因子，加上未來 24 小時之海洋熱容量與氣候值之差異累積值

表 4. 四種不同預測變數組合之 BPNN 模式結果比較

模式 診斷		Model A	Model A + ATCHP	Model A + ATCHA
		AUC	訓練組 0.85	0.84
	測試組	0.83	0.82	0.82
最佳門檻值		0.35	0.45	0.40
敏感度 (%)	訓練組	42.56	52.82	25.64
	測試組	44.57	52.00	28.57
特異度 (%)	訓練組	93.79	91.08	96.02
	測試組	92.90	89.85	96.86
準確度 (%)	訓練組	85.64	84.99	84.83
	測試組	86.18	84.59	87.37

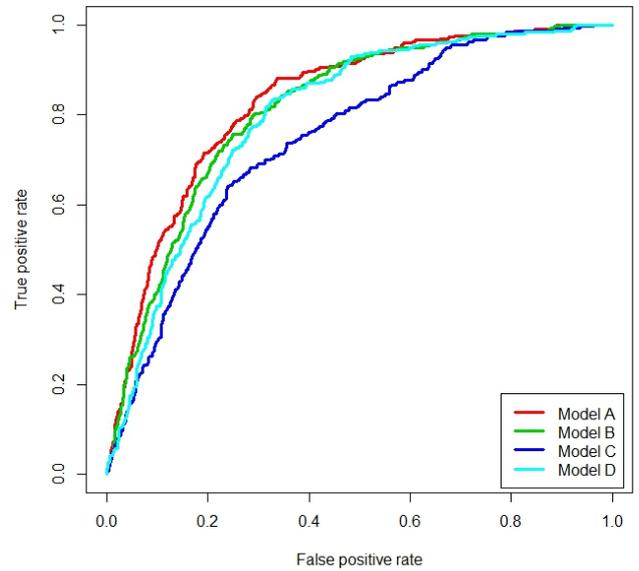


圖 1. 使用羅吉斯迴歸之模式訓練樣本 ROC 曲線圖

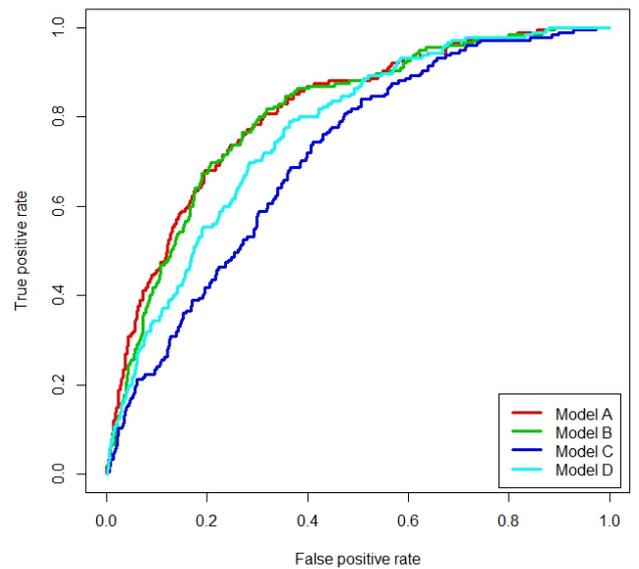


圖 2. 類似圖 1，本圖為測試樣本之 ROC 曲線圖