

# 颱風結構資料之預報模型測試

林宜霖<sup>1</sup> 陳熾竹<sup>1</sup> 江宙君<sup>1</sup>  
台灣颱風洪水研究中心<sup>1</sup>

## 摘要

颱風除了挾帶豪雨，其強風亦可能帶來威脅，因此當預測18小時內颱風七級暴風圈可能碰觸台灣陸地時，中央氣象局即對當地發布陸上颱風警報。統計暴風半徑與其他氣象參數之相關係數逐年變化，可知颱風強度和暴風半徑為正相關但並非一對一之關係。氣象上常有非線性的問題，除了數值天氣預報技術外，機器學習也是近年來可嘗試用在氣象問題之工具之一。

研究將從機器學習的觀點討論颱風強度結構預報，利用常用的機器學習方法與氣象局颱風警報單資料等，研究建置一簡易模型嘗試預報颱風之強度與結構分類，並與氣象模式得分比較。校驗參數選用混淆矩陣(Confusion matrix)中的準確率(Accuracy)與Kappa指數，文中將說明簡易模型設置方法與初步結果。

關鍵字：颱風強度、暴風半徑

## 一、前言

機器學習的主要任務在於從大量資料中建立迴歸、分類模型，好的分類(標籤)方法不僅有助於使用者了解舊資料的特性，也應當能適切地為新資料分類。對應至氣象上則是藉由已知的資料，透過機器學習方法建立模型，並協助使用者預報未來時間的天氣特性。

Zhang et al.(2013)選擇 C4.5 決策樹方法，由 2000 到 2009 年 JMA RSMC Tokyo 之最佳路徑與 NCEP FNL 資料訓練建模，藉該時間之資料判斷太平洋上颱風路徑是否屬於轉向颱風。模式最終建立出 18 種分類路徑，其中 11 種屬轉向路徑，7 種屬非轉向路徑，訓練集的準確率平均為 0.844，且颱風中心位置之經緯度係影響颱風轉向的關鍵之一。最終 Zhang et al. (2013)以 2010 年 14 個颱風個案作為測試集，可得路徑不轉彎的颱風較容易被該模式預報。不過，以路徑轉向的 Malakas(2010)颱風為例，模式在颱風轉向時，幾乎每個時間點都指出颱風路徑會轉向，僅藉由分類並無法明確地指出颱風轉向的時間。

不難想像這個議題可能存在於任何的分類模型中。因此，本研究嘗試將「時間條件」加到分類預報模型中，也就是在定義分類標籤時，將

資料分作「未來 NT 小時颱風強度分級」，及「未來 NT 小時內七級風暴風圈登陸台灣與否」。

本文第二章將說明資料與建模方法，第三章將介紹實驗設計，第四章為初步結果介紹，第五章為結論與未來工作。

## 二、資料說明與方法介紹

研究使用的資料為氣象局 2014~2016 年之颱風海上及陸上警報單資料，自 2014 年起之資料筆數(與個案數)為 119(3)、224(6)和 234(5)。此外，颱風強度分級預報方面加入系集模式結果，藉此討論機器學習模型是否與系集模式有可比較之預報能力。研究中系集模式平均定義有二，第一係指「包含 ECMWF、NCEP、WEPS 和 TAPEX 四個系集模式與警報颱風清單均質化之結果」，模式資料數目(與個案數)為 47080(5)，結果如圖 3 中 Ensemble Mean；第二係指「系集模式與警報颱風清單均質化後，再挑選初始時間在氣象局警報期間內之預報，最終將所有資料平均之結果」，模式資料數目(與個案數)為 15302(4)，結果如圖 3 中 Ensemble Mean\_Warning。研究方法包含「機器學習方法」與「校驗方法」兩部分，以下將分段簡短說明。

### (一) 機器學習方法：

#### 1. 分類與迴歸樹演算法(Classification And Regression Tree, CART)：

CART 最早由 Breiman 等人(1984)提出，屬於二元決策樹的一種，依據每個節點之條件為資料分類。該方法係藉由 Gini impurity 評估分類條件是否能將資料明確分類(Gini impurity 最小時)。實驗預設分類迴歸樹至多能有 10 層。

#### 2. K-Nearest Neighbors(KNN)：

KNN 最早由 Fix and Hodges(1951)提出，該分類法是在空間中取與測試點最鄰近(研究中係指空間中的直線距離)並來自訓練集之 K 個點，由 K 個點之分類結果取多數決為測試點分類。本研究中定義 K=5。

#### 3. RANdom forest GEneRator(Ranger)：

Ranger(Wright et al. 2017)通常被稱為隨機森林(Breiman 2001)之快速實現版本，主要差異在於 Ranger 預先或於分類過程中將變數分組。這個方法能減少隨機森林在學習高維度資料時較長的運算時間，但仍保有隨機森林系集的概念。

### (二) 校驗方法

校驗方法取自常用的混淆矩陣(Confusion Matrix，如表一)。

表一 混淆矩陣(Confusion Matrix)範例。

		實際	
		類別一	類別二
預測	類別一	a	b
	類別二	c	d

$$\text{資料總數 } T = a + b + c + d$$

1. 準確率(Accuracy) =  $(a + d) / T$

2. Kappa 指數( $\kappa$ ) =  $\frac{\text{準確率} - p_e}{1 - p_e}$

$$p_e = \frac{(a + b)}{T} * \frac{(a + c)}{T} * \frac{(c + d)}{T} * \frac{(b + d)}{T}$$

$\kappa < 0.0$  : no agreement

$0.0 < \kappa < 0.2$  : slight

$0.2 < \kappa < 0.4$  : fair

$0.4 < \kappa < 0.6$  : moderate

$0.6 < \kappa < 0.8$  : substantial

$0.8 < \kappa < 1.0$  : almost perfect agreement

## 三、實驗設計

實驗以 2014、2015 年之氣象局警報單資料為訓練集，以 2016 年之警報單資料為測試集，最終計算模式之準確率與 Kappa 指數得分評估模式的預報能力。為了測驗機器學習對不同預報因子之敏感度，研究共設計「A 基礎預報因子」和「B 加入移速路徑等預報因子」兩組實驗，選用之預報因子及實驗說明同表二和表三所示，表二中除了路徑分類(Tracktype)外，所有預報因子都來自於氣象局颱風警報單。A、B 兩組實驗分別有「未來 NT 小時颱風強度分級」和「未來 NT 小時七級風暴風圈是否登陸」兩個預報量(NT = 6, 12, 18, ..., 48)。

## 四、初步結果

### (一) NT 小時內颱風強度分級

圖 1 可得各預報模型經訓練後之準確率與 Kappa 值表現，圖 1(a)以實驗 B，12 小時內颱風強度分級預報為例。由訓練集的結果，可知 Ranger 之準確率和 Kappa 值皆為 1.0，KNN 方法表現則次之，Cart 的準確率雖然平均在 0.7 以上，但平均 Kappa 值約在 0.2 左右，顯示 Cart 訓練模式比起隨機猜測之鑑別力較低。

檢視此時 Ranger 之特徵圖(圖 2(a))，其中颱風中心之經、緯度為前兩名重要之特徵，其次依序為前 6 小時之移速與暴風半徑等...。表示訓練集中經 Ranger 機器學習分類後，實驗 B 中未來 12 小時之颱風強度分級受颱風中心位置影響最大。

接著將測試集資料匯入預報模型中，並與系集模式圖 3(a)、(b)為 NT 小時之颱風強度預報結果。模式的預報能力是隨時間緩緩下降的，但機器學習模型則不然。比較 Ensemble Mean 和 Ensemble Mean\_Warning 之表現，則 48 小時內後者之準確率皆較前者高，推測可能是由於警報期間內颱風的發展已趨於成熟，系集模式成員的 spread 較接近所致。實驗 A 中(圖 3(a))48 小時內各機器學習之預報能力幾乎不如 Ensemble Mean\_Warning 之表現，唯 Ranger 模型對未來 6 小時之預報稍優於 Ensemble Mean\_Warning。與實

驗 B(圖 3(b))之預報結果比較，則可以看到特別是 Cart(NT= 12)、Ranger(NT= 36、42)，增加前 6 小時之颱風移速與颱風路徑分類等預報因子對機器學習改善較多。另一方面，儘管圖 2(a)中說明過去移速對 Ranger(NT= 12)有重要的影響，但圖 3(b)中同時增加過去移速與影響力較小的路徑種類對此時預報結果卻是負面影響。

## (二) NT 小時內七級風暴風圈登陸台灣與否

圖 1 (b)以實驗 B，預報 6 小時內颱風七級風暴風圈登陸台灣與否為例，可以看到各機器學習方法之訓練模型分數都偏高。圖 2 (b)中顯示此時颱風七級風暴風半徑登陸台灣與否，主要受到颱風中心經緯度影響，其次的排名與圖 2 (a)稍有不同，依序為七級風暴風半徑、前 6 小時緯向移速和颱風強度。不難想像這些「排名較靠前的特徵量」對「6 小時內七級風暴風圈是否登陸台灣」預報確實是相關聯的。

圖 3 (c)中各機器學習模型的預報能力並不好，但加上颱風過去移速與路徑分類資訊後(圖 3 (d))，NT= 6 和 30 有顯著改善，特別是 Ranger(NT= 6)亦反映了圖 2 (b)中預報因子的特徵量排名。不過，即便是圖 1 (b)在 NT= 12 時各機器學習模型於訓練集中得分很高，將模型應用於測試集時，則同時間之預報結果卻不盡理想(圖 3 (d)，NT= 12)，這可能表示機器學習模型設計中發生過度訓練(overfitting)的情形。

## 五、 結論與未來工作

本研究使用 2014、2015 年之颱風警報單資料作為訓練集，以不同機器學習方法，建立簡易的預報模型，並以 2016 年警報單資料為測試集，嘗試預報「未來 NT 小時颱風強度分級」和「未來 NT 小時七級風暴風圈是否登陸」兩個預報量。

普遍來說，對於兩個預報量，Ranger 和 KNN 等機器學習方法於訓練集都有很高的訓練結果(圖 1)，且颱風中心位置在此時是特別有影響力之預報因子(圖 2)。但同時間之預報結果的分數比起訓練集的分數皆有顯著下降(圖 3)，顯示目前建立之預報模型仍有過度訓練的可能。加上「颱風前 6 小時移速」及「路徑分類」兩個預報因子後，對於不同時間可能略有

正、負向的影響，例如：對颱風強度分類預報在 36 小時後能縮小機器學習模型與系集模式之差距；對七級風暴風圈登陸預報則在第 6 和 30 小時有顯著改善。但不論如何，目前的預報模型仍舊有很大的進步空間。本實驗若實際使用於預報工作，模型所需之預報因子幾乎全可取自警報單資料，唯有路徑分類需經由使用者另外給定，因此，機器學習模型也必須結合氣象模式預報才有更佳表現。

研究目前選用之機器學習方法與目標，仍將預報量視為一分類問題而不是一個迴歸問題。加上實驗設計，訓練的過程中每個預報時間亦被視為獨立的，也因此機器學習預報之得分並不是隨著時間而下降的。是故為了更嚴謹地建模與評估機器學習模型之預報能力，除了增加訓練集的資料量，建議需要先行評估訓練集中資料的分佈是否平均，此外，亦需要有更客觀的標準為預報模型評分。

## 參考文獻

- Breiman, L., J. H. Friedman, R. A. Olshen, and C. J. Stone, 1984: Classification and Regression Trees, Wadsworth and Brooks, 1 edition, *Chapman and Hall/CRC*, 368 pp.
- Breiman L. : 2001, "Random forests", *Mach Learn.*, **45(1)**, 5-32.
- Fix, E., Hodges, J.L.:1951, "Discriminatory analysis, nonparametric discrimination: Consistency properties.", Technical Report 4, USAF School of Aviation Medicine, Randolph Field, Texas.
- Wright M, Ziegler A., 2017: "Ranger: a fast implementation of random forests for high dimension data in C++ and R." *J. Stat Softw.* **77**:1-17.
- Zhang W., Y. Leung, and J. C. Chan, 2013: "The analysis of tropical cyclone tracks in the western north pacific through data mining. part I: Tropical cyclone recurvature.", *Journal of Applied Meteorology and Climatology*, **52**, no. 6, pp. 1394-1416.

表二 研究預報模型使用之預報因子(Predictor)與定義列表

預報因子	說明	預報因子	說明
<b>MSLP</b>	颱風中心氣壓(hPa)	<b>X7Dir</b>	七級風暴風半徑(km)
<b>VMAX</b>	颱風最大風速(m/s)	<b>X10Dir</b>	十級風暴風半徑(km)
<b>LON</b>	颱風中心經度(deg)	<b>u-6Dir</b>	前 6 小時中心移動速度-經向(deg)
<b>LAT</b>	颱風中心緯度(deg)	<b>v-6Dir</b>	前 6 小時中心移動速度-緯向(deg)
<b>GUST</b>	最大陣風(m/s)	<b>Tracktype</b>	氣象局路徑分類(type 9+1 )
<b>MM</b>	月份		

表三 預報因子敏感度實驗設計

實驗	預報因子(Predictors)	預報量(Predictand)	機器學習方法
<b>A 基礎預報因子</b>	MSLP、VMAX、LON、LAT、GUST、MM、X7Dir 和 X10Dir	(一) 未來 NT 小時颱風強度分級 (輕度颱風/中度颱風/強烈颱風) (二) 未來 NT 小時颱風七級風暴風圈 登陸台灣與否	CART KNN Ranger
<b>B 加入移速路徑等預報因子</b>	同上，增加 u-6Dir、v-6Dir 和 Tracktype	登陸台灣與否 (是/否)	

(a) 未來 NT 小時颱風強度分級

(b) 未來 NT 小時颱風七級風暴風圈登陸台灣與否

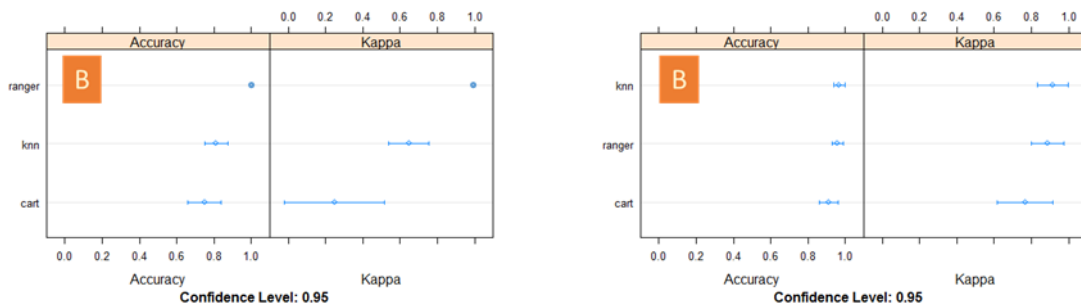


圖 1 各方法於訓練集之準確率和 Kappa 值。圖(a)以未來 NT 小時颱風強度分級預報之實驗 B、NT= 12 為例，圖(b)以未來 NT 小時七級風暴風圈登陸台灣與否預報之實驗 B、NT= 6 為例。

(a) 未來 NT 小時颱風強度分級

(b) 未來 NT 小時颱風七級風暴風半徑登陸台灣與否

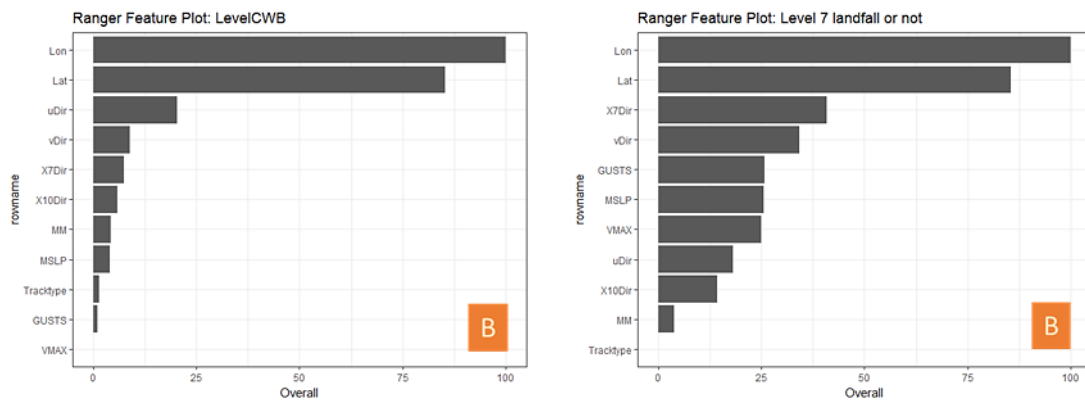




圖 2 Ranger 於訓練集經標準化之特徵圖(Feature Importance Plot)。圖(a)以未來 NT 小時颱風強度分級預報之實驗 B、NT= 12 為例，圖(b)以未來 NT 小時七級風暴風圈登陸台灣與否預報之實驗 B、NT = 6 為例。


(a)未來 NT 小時颱風強度分級




(c)未來 NT 小時颱風七級風暴風圈登陸台灣與否



(b)未來 NT 小時颱風強度分級



(d)未來 NT 小時颱風七級風暴風圈登陸台灣與否



準確率：—○— Cart —○— KNN —○— Ranger —○— Ensemble Mean —○— Ensemble Mean\_Warning  
 Kappa 值：□ kCart □ kKNN □ kRanger □ kEnsemble Mean □ kEnsemble Mean\_Warning

圖 3 圖(a)和(b)為未來 NT 小時颱風強度分級預報，圖(c)和圖(d)為未來 NT 小時七級風暴風圈登陸台灣與否預報，分別包含實驗「A 基礎預報因子」和「B 加入移速路徑等預報因子」。圖中 x 軸表示預報時間，折線圖表示預報之準確率(左側 y 軸)，長條圖表示預報之 Kappa 值(右側 y 軸)。不同顏色表示不同之機器學習方法與系集模式資料，依序為藍色：Cart、綠色：KNN、黃色：Ranger、灰色：系集模式\_全 DTG 和紅色：系集模式\_警報期間 DTG。