

基於深度學習颱風侵襲期間台灣多測站風力預測

戴燦景¹

李亭玫²

趙涵捷^{1,2}

國立宜蘭大學 資訊工程學系¹

國立東華大學 電機工程學系²

摘要

颱風，是一個生成於熱帶海洋上，其近中心風速達到每小時 34 海浬(約每秒 17 公尺)以上的強烈熱帶性低氣壓。台灣位處熱帶季風氣候與副熱帶季風之間，且位處東亞、緊鄰西北太平洋，夏秋兩季常有颱風侵襲。颱風侵襲期間，挾帶的豐沛雨水，常造成台灣許多地區淹水甚至是山洪暴發及土石流，帶來的強風也容易造成路樹倒塌或吹斷電線桿損壞電力設備進而造成停電甚至造成人員傷亡等災情。現今，縣市政府首長會依據行政院人事行政處所頒佈之《天然災害停止上班及上課作業辦法》當颱風警報期間當預報最大平均風力 7 級以上或最大瞬間陣風達 10 級以上時，作為是否放「災防假」的決策依據。颱風侵襲期間，台灣各地區的風力主要取決於颱風當時的強度、大小，與颱風的位置，或甚至是當時的大氣環境。但是因台灣地形複雜，就算是兩個相近的氣象站，其觀測結果，也可能有很大的差異。目前相關風力預報作業主要依靠數值模式或統計類比法，次預報方法多取決於氣象預報員所累積的預報經驗以及對過去歷史颱風的個案掌握度，透過這些經驗來進行主觀分析與判斷，然而不同的預報員，有不同預報經驗，在預報上的主觀認定也會有所差異。近年來也逐漸發展出一些更客觀的方法來進行颱風影響期間氣象站的風力預測，例如使用多元線性回歸。這類風力預測，颱風與氣象站之間往往存在非線性的關係。線性回歸的過程中也較容易喪失這些非線性的特徵而造成失真。近年來人工智慧在各個領域的應用可說是相當熱門的議題，深度學習具有非常大量的函數與參數，其中包含了輸入層、隱藏層與輸出層，使用非線性函數來模擬人類神經元被激發的過程，對於非線性的特徵有更高的掌握度。目前也廣泛應用於許多領域，像是人臉辨識、醫療影像與網路流量等預測。本研究將使用卷積神經網路，利用中央氣象局 1961~2018 年的颱風個案，中央氣象局局屬氣象站的平均風速，與颱風路徑、強度等資料，作為訓練集，來開發一套模型，藉此來讓模型學習颱風與各氣象站之間的關係，希望透過本研究能提升在颱風警報發布期間風力預測的準確度。

關鍵詞：颱風、風力預測、深度學習、卷積神經網路

一、前言

夏秋之際，熱帶海洋上常有熱帶系統發展，有些則有機會增強為熱帶低壓甚至颱風。中央氣象局根據熱帶性低氣壓近中心最大風速之大小，分別定義為輕度、中度及強烈颱風。台灣因地理位置與氣候型態，夏秋兩季常有颱風侵襲，常帶來許多危害。

政府機關，依據《天然災害停止上班及上課作業辦法》中之第四條第一項：「目前當預報颱風暴風圈在四小時內行經的區域內，最大平均風力達七級以上(≥ 13.9 m/s)，瞬間陣風達十級以上(≥ 24.5 m/s)」，如此一來，風力預報的準確度，對於政府決策可說是

扮演相當重要的因素。根據 [1] 的研究指出，各氣象站的風速，會受到颱風中心位置、地理位置與地形等複雜因素影響。因此，就算是兩個鄰近的氣象站，在颱風侵襲期間，其觀測仍可能有天壤之別的結果。另外 2016 年梅姬颱風侵襲期間，發生了台南市、高雄市因風雨預報之風速明顯被低估，造成許多市民被迫暴露在狂風暴雨的險境中返家，再度顯示了準確風力預報的重要性。而如何克服這些因素來改善地區性風力預報的準確度，是目前相當重要的課題。

這幾年來，深度學習蓬勃發展，從過去的許多研

究中我們發現，深度學習可以從大數據中，找到許多特徵。尤其是非線性方面的特徵，可說是深度學習的強大之處。我們都知道，大自然的許多現象，大多都是非線性的，而如何從這些現象中找到蛛絲馬跡，深度學習可說是絕佳利器。

本研究我們將使用，深度學習的方法來實現颱風影響期間氣象站的風力預測。本研究運用深度學習對於非線性問題的學習能力，讓模型來學習颱風影響期間，空間與大氣環境之間的特性。研究中，會對資料進行前處理，以矩陣的方式來存入空間與颱風相關資料，並建立深度學習模型。

本文的結構如下：第二節的部分，將會介紹本篇研究的研究背景與相關研究；第三章節，將會介紹本研究所使用到的數據等資料；第四節，則是介紹研究所進行之資料前處理與模型建立等工作並依第五節的實驗設定來進行實驗；最後於第六節、第七節的部分進行結果的分析、比較與討論。

二、背景知識與相關研究

天氣，是一個混沌且非線性動態現象。現今預報大多使用數值模式，使用地面觀測、探空與衛星遙測等大氣環境資料來對數值模型進行資料同化，藉此來預測每個網格點在不同時間點的風速與風向。氣象預報員會根據經驗判斷，對模式的預測結果進行校驗，得出最合理的預測。然而預報員的預測結果多依賴過去的預報經驗，不同的預報員在預報上的主觀認知會有所不同。因此後來也發展出使用統計的方法，[1] 利用「多元線性回歸」，將颱風強度、暴風半徑與測站的平均風速資料，來建立台灣個別測站的統計分析模型。其模型建立是將台灣及其鄰近區域(19°N~27°N, 117°E~126°E)以 1°x 1°網格進行切割。每一個網格皆有一組回歸方程，預測颱風侵襲台灣期間氣象站每小時的平均風力變化。

隨著 5G 時代的來臨，透過影像處理、電腦視覺與無線通訊等技術，深度學習也被運用在了智慧城市、IoT，等領域 [2]。近期的研究當中，有人使用注意力機制 (Attention-based) 結合循環神經網路 (Recurrent Neural Network) 用於預測交通流量等時間序列與非線性問題 [3,4]。深度學習具有非常大量的函數與參數，其中包含了輸入層、隱藏層與輸出層。其中層跟層之間是用權重來進行連接，就像人類的腦神經一樣，有訓練就會被激發。而非線性函數，就

是為了模擬人類神經元被激發的過程。訓練過程中，反覆藉由輸出之結果與實際結果來進行驗證。根據其結果使用演算法來更新各神經元之間的權重逐步減少誤差，幫助電腦來學習資料與資料之間的特徵。此方法對於非線性的資料特徵有較高的掌握度。基於深度學習對於非線性特徵的學習能力，結合大數據分析，在大氣科學方面將可有效提升氣象預報的準確度。

近年來，深度學習的技術也開始被運用在了氣象的領域，像是雨量預報，風力發電等預報。[5]以卷積神經網路，來預測多個雨量站的短期降雨量，透過卷積神經網路的特性，來擷取雨量站跟雨量站之間的資料與地理特徵。卷積神經網路與其他機器學習的方法來比較，卷積神經網路無論在方均根誤差、準確度或是在運算效率上，皆占有優勢。[6] Google 團隊也開發了一套 MetNet 使用美國的降雨雷達與氣象衛星，搭配卷積神經網路與長短期記憶模型，來預測美國的逐時降雨機率分布。在風力預測方面，[7]提出了利用頻譜圖理論與粗糙集理論，結合正規化的拉普拉斯矩陣用卷積神經網路來擷取多個氣象站的空間特徵，來預測時間序列的風速資料。[8]使用時空循環卷積神經網路以雷達回波與地面氣象站的資料來訓練模型。藉由鋒面所激發之中尺度對流系統或颱風線，雷達回波與地面的觀測資料，來擷取其回波與地面氣象觀測之間的特徵，來偵測鋒面中中尺度對流系統所可能出現的強陣風。

本研究，將使用卷積神經網路，來預測颱風影響期間台灣局屬氣象站的逐時風速。我們使用過去數十年的氣象資料搭配深度學習，來取得颱風與氣象站之間的空間與數值特徵。氣象站的海拔高度，與當時颱風強度跟颱風中心對氣象站的距離、方位角作為特徵。使用這些特徵來建立一套非線性的氣候模型，提升颱風風雨預測的準確度。

三、資料

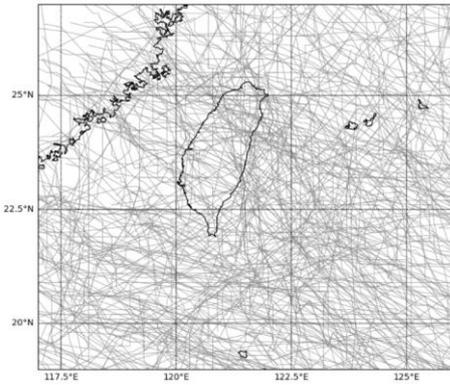
(一) 觀測資料

本研究使用之地面觀測資料，下載自大氣水文資料庫所提供之 1961 年至 2018 年，台灣局屬氣象站逐時資料。其資料包含了全台灣局屬氣象站每小時的各項氣象要素，如溫度、濕度、風速、風向與最大瞬間陣風等資料。

(二) 颱風資料

使用中央氣象局歷年陸上、海上颱風警報路徑，

其資料庫包含 1958 年到 2019 年，台灣海上、陸上颱風警報期間，颱風的中心定位、強度、七級風暴風半徑與十級風暴風半徑大小。本研究使用 1961 年至 2018 年所有侵台颱風，如圖一所示。資料中包含了，中央氣象局海上颱風警報發布到結束期間，每一報的座標、強度、與七級風暴風圈大小。海上警報期間，每一報的時間為當天的凌晨兩點起，間格三小時一報；陸上警報發布期間則會改為每小時發報。研究中使用線性內插法，將海上警報期間三小時的資料，對每一小時的經緯度、近中心最大風速、七級風暴風半徑等資料進行內插，取得每小時的資料。此外，因 1961~1994 年之最大風速資料採用 1 分鐘平均風速，1995 年起至今為 10 分鐘平均風速，為求資料標準一致性，本研究參考 [1,12]，將 1994 年以前的一分鐘平均風皆乘以 0.90 轉換為 10 分鐘平均風速。



圖一、1961~2019 年侵台颱風

四、方法

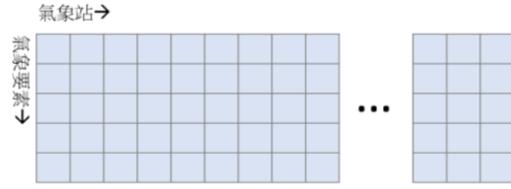
(一) 資料前處理

我們的研究中，我們會將氣象站的經緯度資訊、海拔與測站對颱風之相對位置，作為用來預測氣象站風力的訓練資料，並建立一個模型來實現非線性回歸。為了將各測站資訊與颱風相對位置之空間分布等資料進行整合，在進入深度學習模型訓練前，會先將資料分為輸入資料與輸出資料。 X_i^S 為輸入資料，維度為 $\mathbb{R}^{n \times m}$ ； Y^S 為輸出資料，維度為 \mathbb{R}^n ； S 為氣象站數，假設有 n 個氣象站則 $S \in \{1, 2, 3, \dots, n\}$ 。 i 為氣象站的參數，假設有 m 個參數則 $i \in \{1, 2, 3, \dots, m\}$ 。本研究我們設計一個模型 $h_w(\cdot)$ 利用輸入資料 X ，再以權重 w 的模型來預測各氣象站的風速 Y ，用以公式 1 表示。

$$Y = h_w(X) \quad (1)$$

研究中會將 1961 年~2018 年侵台颱風，氣象局海上(含陸上)颱風警報期間，局屬氣象站的資料，與中央氣象局颱風資料進行結合。利用結合結果產生

一組二維矩陣，作為訓練資料。其矩陣中會包含，每一個氣象站的海拔高度，與該時間點每一個氣象站離颱風中心的距離、方位角與颱風強度，如圖二所示。

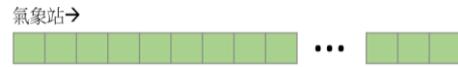


圖二、輸入資料矩陣示意圖

為了計算氣象站與颱風中心之間的距離與方位角，本研究使用公式 2 計算距離。使用公式 3，來計算颱風與氣象站之間的方位角。 d 為兩點之間的距離， r 為地球半徑， θ 為兩點直線方位角， φ_1, φ_2 為兩點之緯度， λ_1, λ_2 為兩點之經度。 d 與 θ 結合颱風的強度與七級風暴風半徑作為輸入之訓練資料。輸出資料使用颱風影響期間，該氣象站每個時間點的整點平均風速，作為深度學習模型輸入資料的相對應預測目標。其預測目標為一維矩陣，如圖三所示。

$$d = 2r \sin^{-1} \left(\sqrt{\sin^2 \left(\frac{\varphi_2 - \varphi_1}{2} \right) + \cos \varphi_1 \cos \varphi_2 \sin^2 \left(\frac{\lambda_2 - \lambda_1}{2} \right)} \right) \quad (2)$$

$$\theta = \tan^{-1} \left(\frac{\varphi_2 - \varphi_1}{\lambda_2 - \lambda_1} \right) \quad (3)$$

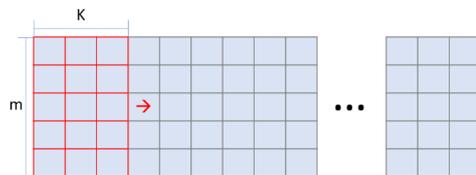


圖三、輸出資料矩陣示意圖

(二) 卷積神經網路

本研究我們使用一維卷積，如圖四所示。此卷積利用公式 4 之卷積核，來擷取矩陣之特徵值。再經由神經網路的非線性過程，透過反向傳播法更新每一個卷積核神經網路到輸出的過程之權重，藉此達成學習的效果。 l 為卷積層之層數， i 為卷積核的座標， K 為卷積核的大小， m 為矩陣單一氣象站參數數量， w_{ab} 為卷積核內座標 (a, b) 的權重大小， B 為偏差值。

$$x_i^l = \sum_{a=0}^{K-1} \sum_{b=0}^m w_{ab} y_{(i+a)b}^{l-1} + B^l \quad (4)$$



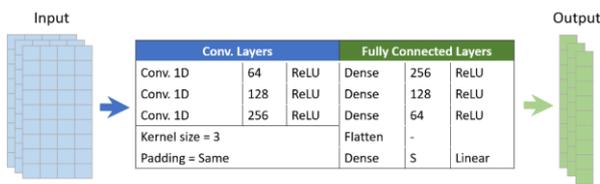
圖四、一維卷積示意圖

(三) 模型設計

為了實現非線性的預測，本研究將建立一個卷積神經網路架構作為模型。而模型的設定，我們將透過實驗來找出較適合之配置，以取得較佳的預測準確度，如圖五所示。搭配 ReLU，如公式 5，作為卷積層與神經元之間的激勵函數。模擬生物學神經元在傳遞資訊的過程中，神經元被激發的現象，此方法目前也是在深度學習領域中，最常被用到的一種激勵函數。此函數主要有以下優點，相較於其他傳統激勵函數，如 sigmoid 與 tanh，ReLU 可有效避免在反向傳播的過程中，有梯度消失的問題。且此函數所需的運算成本較低[9]。

模型中我們將透過使用卷積來擷取大量的資料特徵。再將特徵值透過全聯接層來輸出預測結果。因為結果必須要以數值呈現，所以最後一層我們用線性的方式來輸出回歸結果。

$$f(x) = \max(0, x) \quad (5)$$



圖五、CNN 深度學習模型設計

(四) 損失函數

研究中我們使用平均絕對誤差(Mean Absolute Error)，作為本研究之損失函數，用以比對預測值與真實值之間的差異，如公式 6。 n 為樣本數， $h_w(x_i)$ 為 w 權重底下所輸出的預測值， \hat{y}_i 為真實值。

$$L(w) = \frac{1}{n} \sum_{i=1}^n |h_w(x_i) - \hat{y}_i| \quad (6)$$

(五) 簡單移動平均法

經由實驗測試結果我們發現，在輸出結果極端植的部分有數值跳動的可能性。我們嘗試使用簡單移動平均(Simple Moving Average)對資料來進行平滑化，並測試其是否可對預測結果準確度有所提升。簡單移動平均計算方法如公式 7。

$$\bar{P}_{SM} = \frac{1}{n} \sum_{i=0}^n P_{M-i} \quad (7)$$

五、實驗

(一) 實驗樣本

我們選取 1961 年到 2018 年西北太平洋，所發布海上颱風警報以上之颱風作為本次實驗之樣本。在此期間共有 385 個颱風影響台灣，結合地面氣象站的資料，以每小時為資料間格，總共 69995 筆資料作為訓練使用。另外我們挑選 2015 年蘇迪勒颱風與杜鵑颱風的資料，作為模型測試資料供驗證使用。測試資料總共 600 筆資料。

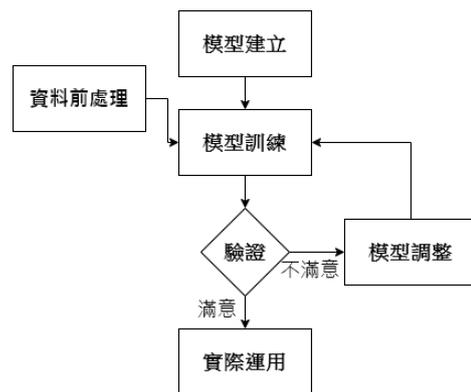
為了得到更完整的訓練資料，本研究選取自 1961 年至 2018 年共同有效資料最多的氣象站為優先考量。為求資料完整，我們選擇了五個氣象站作為本次實驗的樣本來源與預測目標。

(二) 實驗設計

使用 TensorFlow 搭配 Keras 來建立模型與進行運算。TensorFlow，是一個免費且開源的深度學習框架，在現今深度學習領域算是一個相當熱門的一個框架之一。經過數次的實驗調整，本實驗中之參數，我們設定 epoch 為 1000，batch size 設為 500，以 20% 的樣本數來進行交叉驗證。訓練過程中神經網路之權重與模型預測結果息息相關。所以我們通過預測結果與實際結果的差異，使用優化器對權重進行更新。近期研究發現 Adam 優化器可加速模型收斂及更快取得全域最佳解。因此本研究採用 Adam 優化器，對神經網路模型的權重進行更新。

(三) 實驗流程

以下為本研究之實驗流程，首先我們先使用 Keras 來建立模型框架。接著我們利用前處理過之訓練資料，透過 Adam 優化器對模型進行訓練，最後進行驗證。



圖六、實驗流程圖

(四) 驗證

為了驗證實驗結果的有效性，因此我們使用平均絕對誤差(Mean Absolute Error, MAE)、方均根誤差(Root Mean Square Error, RMSE)與皮爾森相關係數

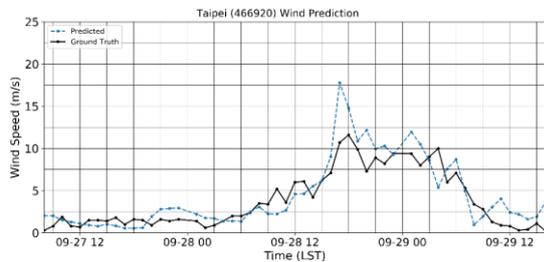
(Pearson Correlation, Corr.)等三種方法來進行驗證。經由公式 8、公式 9 與公式 10 的驗證結果可以發現，本研究對於利用卷積神經網路來預測颱風期間測站風力的有效性。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (8)$$

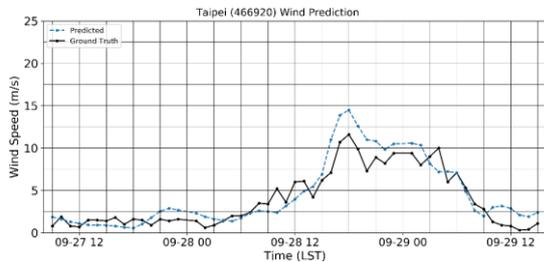
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (9)$$

$$corr(y_i, \hat{y}_i) = \frac{\sum_{i=1}^n (y_i - \mu_{y_i})(\hat{y}_i - \mu_{\hat{y}_i})}{\sqrt{(y_i - \mu_{y_i})^2 (\hat{y}_i - \mu_{\hat{y}_i})^2}} \quad (10)$$

六、結果與討論



圖七、杜鵑颱風台北氣象站預測結果(未經處理)



圖八、杜鵑颱風台北氣象站預測結果(移動平均)

表一、個別颱風總體分析(未處理)

	MAE	RMSE	Corr.
蘇迪勒 (n=325)	2.469	3.212	0.704
杜鵑 (n=275)	1.899	2.677	0.724
總體 (n=600)	2.208	2.979	0.715

表二、個別颱風總體分析(移動平均)

	MAE	RMSE	Corr.
蘇迪勒 (n=325)	2.386	3.070	0.728
杜鵑 (n=275)	1.731	2.428	0.761
總體 (n=600)	2.086	2.795	0.741

表三、單一氣象站颱風個案分析(蘇迪勒颱風)

	未處理			移動平均		
	MAE	RMSE	Corr.	MAE	RMSE	Corr.
台北	2.963	3.658	0.706	2.871	3.550	0.714
台中	2.071	2.591	0.398	2.001	2.442	0.447
花蓮	2.999	4.018	0.630	2.847	3.751	0.679
台東	2.130	2.964	0.706	2.099	2.882	0.724
高雄	2.181	2.564	0.746	2.110	2.488	0.776

表四、單一氣象站颱風個案分析(杜鵑颱風)

	未處理			移動平均		
	MAE	RMSE	Corr.	MAE	RMSE	Corr.
台北	1.460	1.954	0.890	1.274	1.572	0.928
台中	2.057	2.487	0.628	1.965	2.385	0.657
花蓮	3.191	4.437	0.595	2.894	4.058	0.634
台東	1.307	1.673	0.646	1.225	1.514	0.683
高雄	1.478	1.830	0.806	1.296	1.601	0.844

本研究中我們分析了蘇迪勒與杜鵑颱風，總體與颱風個案對預測結果之比較。實驗結果，根據表一與表二，其誤差大致落在 1~2 m/s，大致呈現高度相關，其中杜鵑颱風有較高的準確度與相關性。表三與表四，我們單獨將個別氣象站依不同的颱風來討論，其結果也大致與總體分析差不多，相關係數分析呈現中至高度相關。圖六顯示，模型對於颱風接近與遠離的過程中，氣象站風速增強與減弱的趨勢皆可被成功預測到，也較線性模型來的更加敏感，最大風速發生時間與模型預測結果也大致吻合。由此結果顯示深度學習可有效學習颱風與地面觀測之非線性特徵。

然而預測的結果有時會出現數值跳動的情形，因此研究中我們嘗試使用簡單移動平均法(Simple Moving Average)對資料進行資料平滑化，其結果顯示可對預測結果誤差有所改善。以杜鵑颱風案例台北氣象站為例，經移動平均法處理過後 MAE 降至 1.27、RMSE 也降低至 1.57，相關係數分析甚至來到 0.93 左右，為高度相關，如表四粗體所示。以時間序列圖比較，也可以觀察到，經過移動平均法平滑化過後的預測結果，也更為貼近實際觀測結果。此外根據表一到表四，經平滑化過後之準確度與相關係數，結果顯示皆有效改善。顯示使用移動平均法，平滑化的結果可以使準確度提升。

七、結論

本研究提出使用深度學習來預測颱風影響期間台灣多氣象站的風速預測，且可有效學習到颱風與氣象站之間空間之非線性特徵，對於颱風接近與遠離過程有相當高之掌握度，經移動平均法處理過後，其準確度可有效上升。整體上，其預測結果與實際結果大致呈現中度相關至高度相關，顯示深度學習用於颱風侵襲期間氣象站風力預測等應用，有相當高的潛力。未來可再搭配像是 ECMWF、GFS 等全球系集模式所預報之路徑、颱風強度、大小等資料，來預測台灣區域風速變化。並期許將來可應用在颱風警報期間，氣象預報員風力預測之參考，來提升台灣風雨預報之準確性。希望減少因風雨預報之誤差，造成災情或人員傷亡。

未來目標將會放在能夠預測全台灣氣象站，侵台颱風之風力逐時變化。另外於颱風侵襲期間，主要造成破壞性災害的一般是颱風所產生的瞬間陣風，建立一個平均風與瞬間陣風的轉換模型，也是未來的一個研究方向。

八、誌謝

感謝科技部與中國文化大學「大氣水文資料庫」之颱風與氣象觀測資料，使得本研究得以順利完成。感謝亭攻學姐與仁翔學長的指導與技術支援。感謝賴重祐，提供相關研究資料。感謝科技部 107 年度計劃計畫編號 MOST 107-2221-E-259 -005 -MY3 與 109 年度計劃計畫編號 MOST 109-2511-H-259 -004 -的贊助，在此致上十二萬分謝意。

九、參考文獻

[1] 賴重祐、李清勝，2019：颱風侵襲期間臺灣南北都會區風場特徵分析。

[2] Cheng Dai, Xingang Liu, Jinfeng Lai, Pan Li, Han-Chieh Chao, 2019: “Human Behavior Deep Recognition Architecture for Smart City Applications in the 5G Environment”, IEEE Network, Vol.33, Issue 5. pp. 206-211.

[3] Qi Chen, Wei Wang, Xin Huang, Hai-ning Liang, 2020: “Attention-based Recurrent Neural Network for Traffic Flow Prediction”, Journal of Internet Technology, Vol. 21, No. 3, pp. 831-839.

[4] Nicholas G. Polson, Vadim O. Sokolov, 2017: “Deep Learning for Short-term Traffic Flow Prediction”, Transportation Research Part C: Emerging Technologies, Vol. 79, pp. 1-17.

[5] Minghui Qiu, Peilin Zhao, Ke Zhang, Jun Huang, Xing Shi, Xiaoguang Wang and Wei Chu, 2017: “A Short-Term Rainfall Prediction Model using Multi-Task Convolutional Neural Networks”. 2017 IEEE International Conference on Data Mining.

[6] Casper Kaae Sønderby, Lasse Espeholt, Jonathan Heek, Mostafa Dehghani, Avital Oliver, Tim Salimans, Shreya Agrawal, Jason Hickey and Nal Kalchbrenner, 2020: “MetNet: A Neural Weather Model for Precipitation Forecasting”, arXiv:2003.12140v2 [cs.LG] 30 Mar 2020.

[7] Mahdi Khodayar and Jianhui Wang, 2019: “Spatio-Temporal Graph Deep Neural Network for Short-Term Wind Speed Forecasting”, IEEE Transactions on Sustainable Energy Vol. 10, Issue 2, Apr. 2019.

[8] Yan Li, Haifeng Li, Xutao Li, Xian Li, Pengfei Xie, 2020: “On Deep Learning Models for Detection of Thunderstorm Gale”, Journal of Internet Technology, Vol. 21, No. 4, pp. 909-917.

[9] Andrew L. Maas, Awni Y. Hannun and Andrew Y. Ng, 2013: “Rectifier Nonlinearities Improve Neural Network Acoustic Models” Proc. icml. Vol. 30. No. 1. 2013.

[10] Diederik P. Kingma and Jimmy Lei Ba, 2014: “Adam: A method for stochastic optimization”, arXiv preprint arXiv:1412.6980.

[11] Ritesh Pradhan, Ramazan S. Aygun, Manil Maskey, Rahul Ramachandran, and Daniel J. Cecil, 2018: “Tropical Cyclone Intensity Estimation Using a Deep Convolutional Neural Network”, IEEE Transactions on Image Processing, Vol. 27, No. 2, pp. 692-702.

[12] B. A. Harper, J. D. Kepert and J. D. Ginger, 2010: “Guidelines for Converting Between Various Wind Averaging Periods in Tropical Cyclone Conditions”, World Meteorological Organization.