

# 以深度學習神經網路推估西北太平洋颱風強度

ESTIMATING TYPHOON INTENSITY IN THE NORTHWEST PACIFIC USING DEEP NEURAL NETWORKS

中原大學  
土木工程學系  
副教授

**林旭信\***  
Shiu-Shin Lin

中原大學  
土木工程學系  
碩士生

**溫慶亞**  
Qing-Ya Wen

中原大學  
土木工程學系  
碩士生

**朱楷洋**  
Kai-Yang Zhu

中原大學  
土木工程學系  
碩士生

**何御東**  
Yu-Dong Ho

## 摘要

本研究以深度學習神經網路 (Deep Neural Network, DNN) 架構為基礎預報西北太平洋颱風強度，建立未來五天每十二小時之 DNN 颱風強度預報模式，並以多元線性迴歸 (Multiple Linear Regression, MLR) 建立 MLR 颱風強度預報基準模式，分析比較颱風強度預報之效能改進。以西北太平洋為研究區域，蒐集西元 2000 年 ~ 2012 年總共 13 年西北太平洋颱風之 SHIPS 資料 (SHIPS Developmental Data)，利用原始 SHIPS 資料之大氣海洋環境因子，分別為 DNN 颱風強度預報模式與 MLR 颱風強度預報基準模式之輸入，以 RMSE (Root-Mean-Square Error) 為模式評估指標建立 DNN 與 MLR 模式。

颱風強度預報結果與桑達颱風個案研究結果顯示：(1) DNN 模式相較於 MLR 模式之改進百分比皆有提升，尤其提前時刻超過 84 小時，改進百分比逐漸增加，其最大改進提升幅度甚至近 10%，所有提前時刻皆以 DNN 模式表現較佳，平均改進百分比有 4.53%，(2) MLR 模式低估與高估情況均高於 DNN 模式，(3) 桑達颱風個案研究顯示，提前時刻 12 小時到 48 小時 DNN 模式改進百分比變異性較大，提前時刻 24 小時與 48 小時，DNN 模式改進百分比相對最大。整體而言，DNN 模式對於颱風強度預報優於 MLR 模式。

**關鍵詞：**西北太平洋、颱風強度預報、機器學習、深度學習神經網路、多變量線性迴歸。

\* 通訊作者，中原大學土木工程學系副教授  
32023 桃園市中壢區中北路 200 號，linxx@cycu.edu.tw

## ESTIMATING TYPHOON INTENSITY IN THE NORTHWEST PACIFIC USING DEEP NEURAL NETWORKS

**Shiu-Shin Lin\***

Department of Civil  
Engineering,  
Chung Yuan Christian  
University

**Qing-Ya Wen**

Department of Civil  
Engineering,  
Chung Yuan Christian  
University

**Kai-Yang Zhu**

Department of Civil  
Engineering,  
Chung Yuan Christian  
University

**Yu-Dong Ho**

Department of Civil  
Engineering,  
Chung Yuan Christian  
University

### ABSTRACT

Based on the Deep Learning Neural Network (DNN) architecture, this study estimates the typhoon intensity of the Northwest Pacific Ocean, establishes a DNN typhoon intensity forecast model every 12 hours for the next five days, and uses multiple linear regression (Multiple Linear Regression), MLR) to establish the MLR typhoon intensity forecast benchmark model, to analyze and compare the efficiency improvement of typhoon intensity forecast. Taking the Northwest Pacific as the research area, collect the SHIPS data (SHIPS Developmental Data) of the Northwest Pacific typhoon from 2000 to 2012, and use the atmospheric and marine environmental factors of the original SHIPS data as the DNN typhoon intensity forecast model and the MLR typhoon intensity forecast model respectively. The input of the intensity prediction benchmark model, the DNN and MLR models are established with RMSE (Root-Mean-Square Error) as the model evaluation index.

The results of the typhoon intensity forecast and the case study of typhoon Sanda show that: (1) Compared with the MLR model, the improvement percentage of the DNN model has increased, especially when the lead time is more than 84 hours, the improvement percentage has gradually increased, and the maximum improvement has even increased by nearly 10 %, the DNN model performed better in all advance times, with an average improvement percentage of 4.53%. (2) The underestimation and overestimation of the MLR model were higher than those of the DNN model. (3) The case study of typhoon Sanda showed that the advance time from 12 hours to 48 hours, the DNN mode improvement percentage has a large variability. The advance time is 24 hours and 48 hours, and the DNN mode improvement percentage is relatively the largest. Overall, the DNN model is better than the MLR model for typhoon intensity forecast.

**Keywords:** Pacific northwest, Typhoon intensity forecast, Machine learning, Deep learning neural network, Multiple linear regression.

## 一、緒論

台灣四面環海，位於西北太平洋颱風盛行區，每年都受到颱風的侵襲，加上台灣的地形，山坡地多以及河川又短又湍急，每年颱風來襲，都會給台灣帶來很嚴重的災害。如 2015 年蘇迪勒颱風，由花蓮縣秀林鄉立霧溪口登陸，夾帶大量風雨，甚至在颱風侵台期間，台南機場更出現龍捲風，全台將近 400 萬戶停電，打破 1996 年賀伯颱風造成停電戶數的紀錄，颱風再成多處淹水以及發生土石流、山洪暴發等，估計造成 8 死 437 傷以及 4 人失蹤。

颱風生成的條件非常複雜，簡單分為熱力條件 (Thermal Condition) 與動力條件 (Dynamic Condition)，包括大氣以及海洋等環境因子，因子間呈現非線性關係。目前常見的颱風測報系統，所使用的方法大致分為統計模式 (Statistical Model) 和動力模式 (Dynamic Model) 兩種。常見的統計模式有統計颶風強度預報模型 (Statistical Hurricane Intensity Forecast Model, SHIFOR) (Jarvinen and Neumann, 1979) 以及 SHF5 (即 SHIFOR 預測未來五天的強度預報) Knaff *et al.* (2003) 等。動力模式有 GHMI、GFDI、HWFI 等 DeMaria *et al.* (2014)。統計模式以及動力模式都有各自的優缺點，統計動力方法 (Statistical Dynamics Approach) 則兼具此二者之優點，採用由動力模式輸出之大氣海洋環境因子，利用多元線性回歸 (Multivariate Linear Regression, MLR) 來預測颱風未來強度，如 SHIPS (Statistical Hurricane Intensity Prediction Scheme) (DeMaria *et al.*, 2003, Knaff, 2005)，用於大西洋以及東北太平洋及中北太平洋的颱風強度預測，預測結果表示 SHIP 的預測誤差相較於氣候以及延續性的誤差來的小，另外 STIPS (Statistical Typhoon Intensity Prediction Scheme) 之強度預報模式是用於西北太平洋和印度洋以及南半球的颱風強度預測。

統計動力方法 (SHIPS 和 STIPS) 主要以多元線性迴歸 (Multivariate Linear Regression, MLR) 為工具，預報颱風強度，SHIPS 資料為某一段時間，統計動力法之輸出颱風資料，目前輸出時間為 2000 年到 2012 年。如林 (2016) 以 MLR 為基礎採用了 Tsai and Elsberry (2014) 颱風強度統計預報模式 (Weighted Analog Intensity Prediction, WAIP)，配合 SHIPS 資料將資料分為大氣因子以及大氣因子加上海洋因子兩部分，進行五天颱風強度預報迴歸分析，進行效能比較出結果指出加上海洋因子的預報效果優於 STIPS 模式，但由於大氣海洋環境因子與颱風

的強度變化關係呈現高度的非線性關係，MLR 模式較無法解決因子間非線性之問題。

過去 20 年機器學習 (Machine Learning) 被應用於解決大氣與水文之非線性問題 (Mulia *et al.*, 2013, Samsudin *et al.*, 2010, Li *et al.*, 2019, Li *et al.*, 2020, 甘等, 2017)。有關於統計動力法非線性之相關研究，如 Sharma 等人利用 ANN 方法建立起 Soft-Computing Cyclone Intensity Prediction Scheme (SCIPS)，Sharma *et al.* (2013) 預測西北太平洋颱風強度預報並加入海洋熱容量 (Ocean Heat Content, OHC) 成為其中的預報因子，結果顯示比 MLR 效能表現好很多。宋 (2019) 使用 SHIPS 資料，以機器學習中的模糊推論系統 (Fuzzy Inference System, FIS) 結合類神經網路的調適性網路模糊推論系統 (Adaptive Neuro-Fuzzy Inference System, ANFIS)，透過類神經的自我學習優化參數，比較大氣以及海洋因子對強度預測之影響，將資料分為大氣資料以及大氣資料加上海洋資料，建立未來五天每 12 小時提前時刻之颱風強度預報，研究結果表示加上海洋資料預測出的模式是優於只有大氣資料的模式，研究結果更改善了颱風強度預報的準確度，證實 ANFIS 模式能提供可靠的颱風強度預報。機器學習另一個分支深度學習神經網路 (Deep Neural Network, DNN)，由於電腦計算能力大幅度提升，亦被應用於預測颱風等領域。如 Jiang *et al.* (2018) 利用與流量有關的颱風誘發海表面溫度冷卻 (Sea Surface Temperature Cooling, SSTC) 去預測颱風，並討論淺層學習 (Shallow Learning) 以及深度學習 (Deep Learning) 對預測的效果差異，研究指出深度學習較有效的預測颱風。

有鑑於前述，颱風強度預報之重要性，本研究以颱風強度預報統計動力模式 (SHIPS 開發資料) 為基礎，利用 DNN 深度學習，解決颱風強度影響因子間的非線性關係，提升 SHIPS 颱風強度預報。研究中以 SHIPS 資料所提供之大氣與海洋因子，以 DNN 建立未來 5 天每 12 小時提前時刻之颱風強度預報模式，並參考 Knaff *et al.* (2005) 之 MLR 預報模式方法，建立 MLR 颱風強度預報基準模式，比較 DNN 應用於西北太平洋颱風強度預報之效能提升。

## 二、方法論 (Methodology)

### 2.1 深度學習神經網路

深度學習是機器學習的其中一種方法，DNN 架

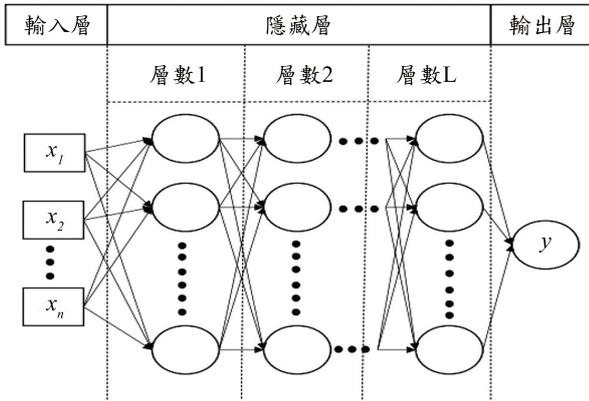


圖 1 深度學習網路架構圖

構如圖 1 所示。包含輸入層、隱藏層以及輸出層，輸入層為將輸入資料放入之後進入隱藏層進行訓練，經過多層隱藏層的訓練之後由輸出層輸出結果，每次將小批量資料放入神經網路進行訓練，找出最佳的模式。訓練流程主要利用反向傳播法優化 DNN 之網路參數，由輸入資料經過不同隱藏層神經元，利用激勵函數 (Activation Function, AF) 推算其輸出值，反覆經過迭代直到誤差值最低。

深度學習網路之所以可以處理非線性的資料是因為有加入激勵函數 (AF)，原來的迴歸方法都是一個  $x$  對應一個  $y$  的狀況，方程式為：

$$y = Wx + b \dots\dots\dots(1)$$

式中， $W$  為權重值， $b$  為偏差值。

深度學習就是在原本的線性函數加上激勵函數 AF 方程式為：

$$y = AF(Wx + b) \dots\dots\dots(2)$$

因此激勵函數扮演了很重要的角色，本研究是選擇兩個激勵函數做選擇，分別為 sigmoid 以及 tanh，sigmoid 函數為：

$$AF = \frac{1}{1 + e^{-x}} \dots\dots\dots(3)$$

tanh 函數為：

$$AF = \frac{2}{1 + e^{-2x}} - 1 \dots\dots\dots(4)$$

DNN 參數優化的方式很多種，最傳統的方法為梯度下降法 (Gradient Descent, GD)，此方法使用全部的輸入資料進行訓練調整參數，速度較慢而且效

果較差，因此有了隨機梯度下降法 (Stochastic Gradient Decent, SGD) 的產生，其使用隨機批量將大批的輸入資料分成較小的批量進行訓練，公式如下：

$$x^{(t+1)} = x^t - \gamma \nabla f(x^{(t)}) \dots\dots\dots(5)$$

$x^t$  為第  $t$  次更新權重， $\nabla f(x^{(t)})$  為函數  $f$  的梯度， $\gamma$  為學習率 (Learning Rate)，為調整權重更新速度的參數，因資料的內容而需要調整不同的學習率，如果沒有設定適合的學習率會導致訓練的效果不理想。

因此 (Duchi *et al.*, 2011) 提出了自適應梯度優化器 (Adaptive Gradient, adagrad)，以 SGD 為基礎衍生可以自動調整學習率的方法，其因應不同的輸入因子調整學習率大小，使學習率跟著每次訓練更新，對頻繁變化的輸入因子以更小的步長更新，反之以更大的步長更新，較適合因子間關係不大的資料，如因子間關係較大導致學習率太過小，影響到訓練的效果。Kingma and Ba (2014) 提出 adam 優化器，由 adagrad 衍生出的方法，為了解決學習率更新至過小的狀況。

每個優化器各有優缺點，會因為輸入資料的結構而有較適合的優化器，因此本研究要依不同的輸入資料選擇不同的優化器 (adagrad, adam) 進行權重更新。

## 2.2 多元線性回歸

多元線性回歸 (MLR) 與簡單線性回歸的理論一致，一樣是在探討自變數 ( $x$ ) 與因變數 ( $y$ ) 之間的關聯性，並建立出回歸模型，利用回歸模型預測變數 ( $y$ )，其差別只在於多元線性回歸是利用兩個以上之自變數 ( $x$ ) 去預測依變數 ( $y$ )，原始模型為：

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \dots\dots\dots(6)$$

(6) 式中， $\beta_0$  為回歸模型的截距， $\beta_1 \dots \beta_k$  為需估計之回歸係數， $\varepsilon$  為誤差值。

## 三、資料簡介

### 3.1 SHIPS 資料

SHIPS 資料內容包括大氣以及海洋因子，預報每場颱風以六小時為單位，時間包括前 12 小時至未

來 120 小時的颱風資料。STIPS 模式 (Knaff *et al.*, 2005) 為 DeMaria and Kaplan 所提出之多元線性颱風強度預報迴歸模式，預測颱風強度變化。STIPS 模式也包含 NHC (National Hurricane Center) 以及 JTWC (Joint Typhoon Warning Center) 颱風作業預報中心所提供的颱風強度及中心位置，另外還包含 NCEP 再分析資料和全球預報模式之颱風附近區域所對應的環境因子。SHIPS 資料則以 STIPS 模式為基礎，包含大氣因子和海洋因子，大氣因子如垂直風切 (SHRD、SHRS) 和相對濕度 (RHLO、RHHI)；海洋因子如海洋熱容量 (RHCN)、海表面溫度 (RSST)。本研究的輸入因子主要來自於 SHIPS 資料於 2013 年新增之西北太平洋颱風共 292 場 (2000 年 ~ 2012 年共 7,113 筆) 的資料，颱風強度及 DELV (颱風強度變化，即未來時刻颱風強度減去目前時刻颱風強度) 分布如圖 2 所示，而採用的因子內容參考宋 (2019) 研究之因子，詳細如表 1 所示，由圖 2 可知，颱風強度以 20 ~ 40 (kt) 比例最高，六小時提前時刻之 DELV，多半集中在 -10 ~ 20 (kt)。

### 3.2 研究資料分組

本研究選用西元 2000 ~ 2012 年總共 13 年之西北太平洋颱風作為研究之資料，所有颱風路徑如圖 3 所示，並將資料分為 10 組提前時刻，分別是 12 小時至 120 小時，以每 12 小時為間隔，將輸入資料分為訓練資料 (Training Data)、驗證資料 (Validation Data)、測試資料 (Testing Data) 三部分，資料長度以年為區別，分別為 2000 ~ 2005 年、2006 ~ 2008 年、2009 ~ 2012 年。

使用之因子是參考宋 (2019)；林 (2016) 所使用建立模式之因子，詳細因子如表 1，總共 29 個因子作為輸入因子，模式的輸出值為颱風強度於初始預報時間之強度變化 (DELV)。參考 Knaff 等人針對西北太平洋颱風強度預報所開發之 STIPS 模式，選擇 DVMAX (12 小時強度變化)、SPD (颱風行徑速度)、VMAX (颱風初始強度)、VMAX<sup>2</sup> (颱風初始強度平方)、MPI (颱風最大可能強度)、MPI<sup>2</sup> (颱風最大可能強度平方)、MPI\*VMAX、SHRD (200 - 850 hPa 之垂

表 1 模式輸入因子列表

使用因子	因子敘述
VMAX	颱風初始強度
VMAX <sup>2</sup>	颱風初始強度平方
DVMAX	颱風前 12 小時強度差異
LON	當前時刻颱風中心經度
LAT	當前時刻颱風中心緯度
SPD	颱風中心移動速度
MPI	颱風最大可能強度
MPI <sup>2</sup>	颱風最大可能強度平方
MPI*VMAX	颱風最大可能強度乘以颱風初始強度
POT	颱風最大可能強度與初始強度差值
SHRD	850 - 200 mb 垂直風切 (距颱風中心 200 - 800 km)
SHRS	800 - 500 mb 垂直風切 (距颱風中心 200 - 800 km)
T200	200 mb 之氣溫平均 (距颱風中心 200 - 800 km)
U200	200 mb 之緯向風速 (距颱風中心 200 - 800 km)
RHLO	850 - 700 mb 之相對濕度 (距颱風中心 200 - 800 km)
RHHI	500 - 300 mb 之相對濕度 (距颱風中心 200 - 800 km)
RSST	海表面溫度
SSTA	颱風中心所在位置之海表面溫度距平
RSSTd12	海表面溫度過去 12 小時差異
RSSTd24	海表面溫度過去 24 小時差異
SSTAd24	颱風中心所在位置之海表面溫度距平過去 24 小時差異
RHCN	海洋熱容量
RHCNd12	海洋熱容量過去 12 小時差異
RHCNd24	海洋熱容量過去 24 小時差異
OHCA	颱風中心位置之海洋熱容量距平
OHCA24	颱風中心位置之海洋熱容量距平過去 24 小時差異

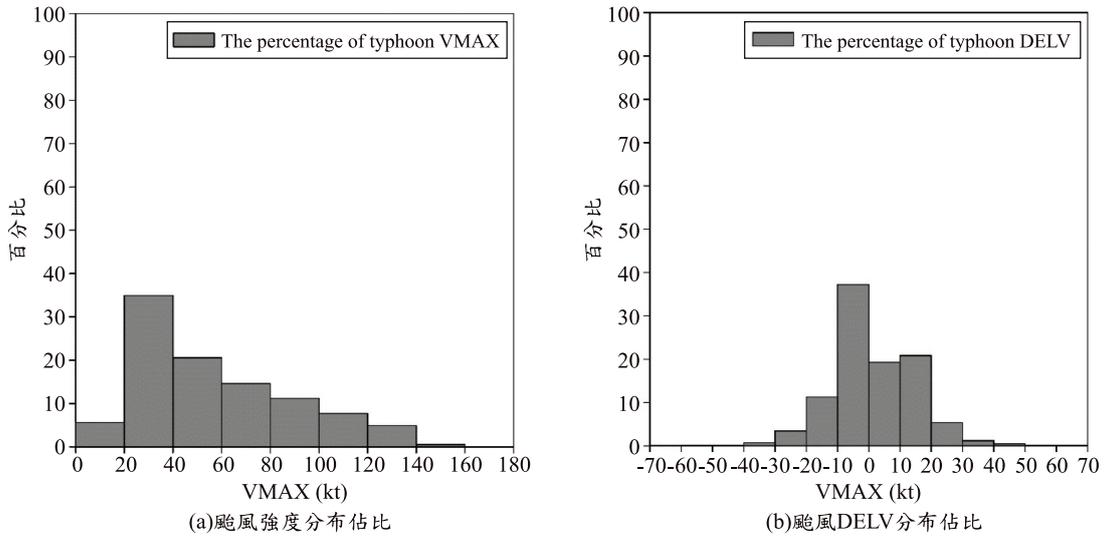


圖 2 颱風強度及 DELV 分布

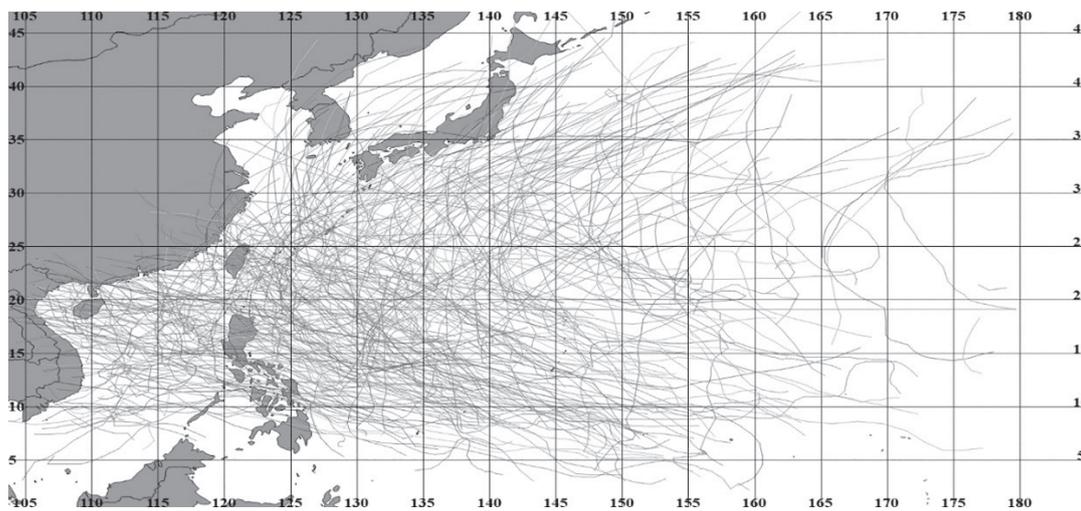


圖 3 西元 2000~2012 年所有颱風路徑圖

直風切)、USHRD (200 - 850 hPa 之緯向垂直風切)、T200 (200 hPa 之氣溫)、RHHI (500 - 300 hPa 之平均相對濕度), 作為 MLR 輸入因子預報颱風強度。本研究以 Knaff 所發展之 STIPS 模式為基準模式, 其中 USHRD 因子無法在 SHIPS 開發資料中取得, 故並未列入。

#### 四、DNN 颱風強度預報模式建立

##### 4.1 模式建立基本流程

本研究使用 DNN 建立颱風強度預報模式, Liu (2017) 表示因優化問題, 因此隱藏層數最好在 1 至 2 層之間, Bai *et al.* (2016, 2017) 之層數選擇範圍為 1 至 3 層, Coppola Jr *et al.* (2005) 建議若輸入層有  $n$

個因子, 則隱藏層節點數為  $2n+1$ , Bai *et al.* (2016) 表示理論上沒有成熟的方法可以決定節點層數之數量。DNN 建立模式的流程為先選擇輸入之變數進行資料標準化, 決定 DNN 架構並優化參數。資料會先進行標準正規化  $z$ , 標準化公式為:

$$z = \frac{x - \mu}{\sigma} \dots\dots\dots(7)$$

(7) 式中,  $\mu$  為資料平均值,  $\sigma$  為資料標準差。模式參數的選擇以及模式效能比較使用均方根誤差 (Root Mean Square Error, RMSE) 作為效能評估的指標如 (8) 式:

$$RMSE = \left[ \frac{\sum_{i=1}^n (Y_i - FY_i)^2}{n} \right]^{1/2} \dots\dots\dots(8)$$

(8)式中,  $Y_i$  為颱風強度觀測值,  $FY_i$  為颱風強度預測值,  $n$  為資料總數。RMSE 值越低, 表示觀測值與預測值之偏差值越小。本研究使用正規化之 RMSE 值, 即  $Y_i$  與  $FY_i$  均為正規化後之數值, 故無單位。

## 4.2 模式參數優化

本研究模式優化的流程如圖 4 所示。優化參數包括優化器、激勵函數、學習率、批量大小、層數、節點。首先進行優化器以及激勵函數的選擇, 其次為學習率的選擇, 再者為批量大小的選擇, 最後是層數節點的選擇, 完成 DNN 參數的優化。優化器的選擇有 adagrad 和 adam 兩種, 激勵函數的選擇有 sigmoid 和 tanh 兩種, 學習率有 0.01、0.001、0.0001 三種選擇, 批量大小有 16、32、64、128、256、512 六種選擇, 層數是由第一層慢慢的往上測試, 節點則取 10 到 100 以 5 為間隔做為測試。

參數優化皆以提前時刻 12 小時資料作為展示, 資料輸入因子數為 29 個, 總筆數為 7113 筆, 資料分為 3 部份依年份切割分別為訓練 (2000~2005 年)、

驗證 (2006~2008 年)、測試 (2009~2012 年) 三部份。

首先決定優化器以及激勵函數, 初始批量大小設定為 16、層數為 1, 節點數為 10 以及 50 確定其誤差函數之下降趨勢, 調整其學習率使其達到收斂, 學習率分別為 0.01、0.001、0.0001, 如收斂圖有過度擬合的現象, 將會使用丟棄法 (Drop Out) 的方式改善, 進行丟棄法後比較各模型之誤差函數並選擇較低值, 選定優化器以及激勵函數後, 進行其他參數選定將會選用此優化器和激勵函數以及學習率並且固定。

表 2 是測試優化器、激勵函數、學習率的結果, 將優化器以及激勵函數分成四個組合:

(adagrad\_sigmoid, adagrad\_tanh, adam\_sigmoid, adam\_tanh), 再分別配合三個學習率總共 12 個組合, 分別進行節點 10 (node10) 以及 50 (node50) 的測試。由表中可知, 整體而言, 優化器為 adam, 激勵函數為 sigmoid, 學習率為 0.001 時, 節點數為 10 與 50 由測試資料推算之 RMSE 均較其他組合小。故提前 12 小時測試的結果是優化器為 adam, 激勵函數為 sigmoid, 學習率為 0.001。

其次選定批量大小 (batch\_size), 以已選定之優化器和激勵函數以及學習率為基礎, 層數設定為 1, 節點數設定為 10 和 50 進行批量大小之測試, 批量大小為 16、32、64、128、256、512, 進行誤差函數的比較, 表 3 為測試的結果, 較好之批量大小為 32,

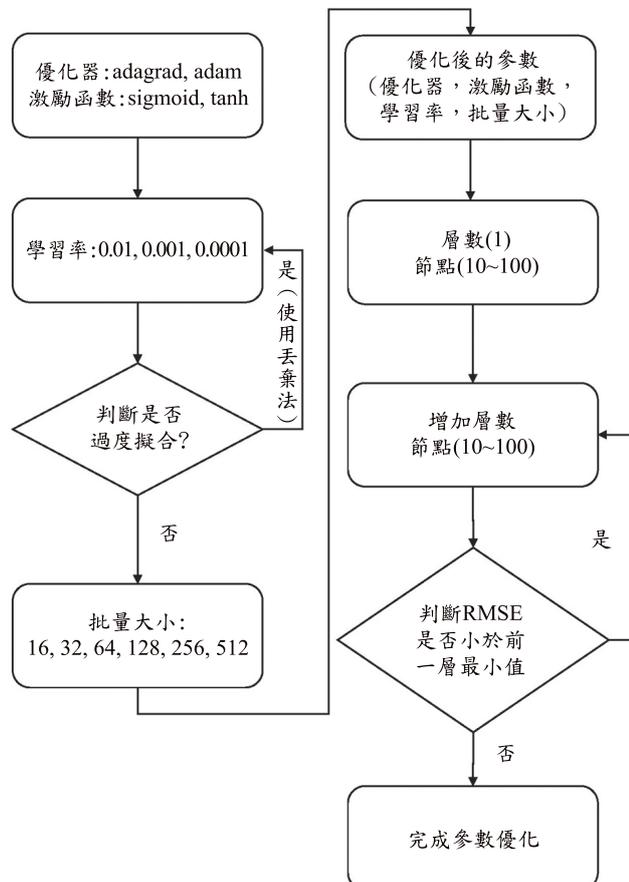


圖 4 參數優化流程圖

表 2 DNN 模式提前 12 小時激勵函數、優化器、學習率參數測試結果

	learning rate	node10_rmse	node50_rmse
adagrad_sigmoid	0.01	8.751	8.299
	0.001	10.066	9.123
	0.0001	11.090	10.732
adagrad_tanh	0.01	8.568	8.293
	0.001	9.345	8.573
	0.0001	10.589	10.238
adam_sigmoid	0.01	8.634	8.324
	0.001	8.310	8.289
	0.0001	8.551	8.262
adam_tanh	0.01	8.768	8.386
	0.001	8.567	8.345
	0.0001	8.576	8.352

表 3 DNN 模式提前 12 小時批量大小參數測試結果

Batch_size	16	32	64	128	256	512
rmse	8.31	<b>8.306</b>	8.52	8.49	8.585	8.641

其 rmse 之值為 8.306，因此選定此模型之批量大小為 32。

批量大小決定後，設定優化器為選定的 adam，激勵函數為選定的 sigmoid，學習率採用選定的 0.001，批量大小為選定的 32，進行層數節點的測試。方法為先從層數 1 節點 10 開始，每 5 節點為一個間隔，測試 10 ~ 100 節點，找出效能評估指標最低的作為第 1 層的節點，繼續往第 2 層測試，第 2 層的節點測試也是一樣由 10 ~ 100 節點以每 5 個節點為一單位進行測試，如效能評估沒有比第 1 層好的話測試就結束，將會以 1 層的層數節點作為最佳參數，如效能評估指標較第 1 層更好，就繼續往第 3 層測試，以此類推。

表 4 為測試各層各個節點的結果，第 1 層經效能評估指標比較結果是節點為 85 是最好的，接下來進行第 2 層發現效能評估有比第一層好且最好的為節點 90，進行第 3 層的測試，結果發現沒有比第 2 層好，因此在提前 12 小時的測試中層數節點的結果是 2 層第 1 層為 85 節點第二層為 90 節點。

表 4 提前時刻 12 小時 DNN 架構層數與節點測試結果

節點	第一層 rmse	第二層 rmse
10	8.397	8.310
15	8.490	8.313
20	8.376	8.224
25	8.260	8.197
30	8.440	8.163
35	8.239	8.161
40	8.209	8.204
45	8.192	8.179
50	8.252	8.168
55	8.223	8.175
60	8.230	8.185
65	8.221	8.147
70	8.267	8.161
75	8.188	8.146
80	8.188	8.152
85	<u>8.187</u>	8.128
90	8.218	<u>8.122</u>
95	8.211	8.124
100	8.229	8.123

### 4.3 MLR 颱風強度預報基準模式建立

為了探討 DNN 深度學習神經網路颱風強度預報效能改進，本研究有另外建立 MLR 模式，因為 MLR 只需要兩組數據，一組為訓練另一組為測試，

而 DNN 深度學習需要三組資料，因此將 DNN 模型之驗證資料捨去，取訓練 (2000 ~ 2005 年) 以及測試 (2009 ~ 2012 年) 資料作為 MLR 模型之輸入資料，輸出資料和 DNN 一樣是強度變化 (DELV)。

本研究在 MLR 模式的輸入因子是採用和 DNN 相同的輸入因子，為了要比較 DNN 方法與 MLR 方法間的差別，採用大氣以及海洋因子總共 29 個因子，詳細因子內容請看表 1。以提前時刻 12 小時至 120 小時每 12 小時為單位之資料做預報，輸出因子為颱風強度變化 (DELV)。

## 五、結果與討論

### 5.1 DNN 深度學習參數優化結果

根據 DNN 深度學習參數的測試流程以及測試的方法，表 5 列出本研究所所有提前時刻 DNN 模式參數，分別為優化器、激勵函數、學習率、批量大小、層數以及節點。表中學習率加上 drop，表示使用丟棄法，優化器的選擇每個提前時刻的模式都是選擇 adam 優化器，激勵函數則為 sigmoid 與 tanh 兩者，學習率的選擇大部分都是使用 0.001，批量大小的選擇每個提前時刻皆不同，層數除提前時刻 12 小時外為兩層隱藏層外，其餘提前時刻皆為一層，節點則從 10 至 90 不定。

表 5 DNN 模式參數決定表

提前時刻	優化器	激勵函數	學習率	Batch size	層數節點
12 hr	adam	sigmoid	0.001	32	85,90
24 hr	adam	tanh	0.001drop	32	80
36 hr	adam	tanh	0.0001	128	70
48 hr	adam	tanh	0.001drop	64	65
60 hr	adam	tanh	0.001	64	10
72 hr	adam	tanh	0.001drop	128	85
84 hr	adam	tanh	0.001drop	512	85
96 hr	adam	sigmoid	0.001drop	32	90
108 hr	adam	sigmoid	0.001drop	64	45
120 hr	adam	sigmoid	0.01drop	32	75

### 5.2 颱風強度預報模式誤差比較

本研究以測試資料集輸入資料輸入以建立之 DNN 模式，與基準模式 (MLR)，比較 DNN 模式改進 MLR 模式之效能。每一提前時刻均建立一 DNN 預報模式與相對應之 MLR 基準模式，探討各提前時

刻 DNN 預報模式之提升效能。將以兩種模式以 RMSE 效能評估指標比較其效能。每個不同的模式都有提前時刻 12 小時 ~ 120 小時總共 10 個提前時刻。圖 5 長條圖為各個提前時刻 DNN 與 MLR 模式 RMSE 效能表現，皆顯示 DNN 模式相較於 MLR 模

式，有較低之 RMSE，整體而言，DNN 模式表現皆優於 MLR 模式。DNN 模式和 MLR 模式之效能改進百分比 (DNN\_PI)，DNN\_PI 以 (9) 式計算，即以 DNN 模式與 MLR 基準模式 RMSE 之差值除以 MLR 基準模式 RMSE 之百分比。

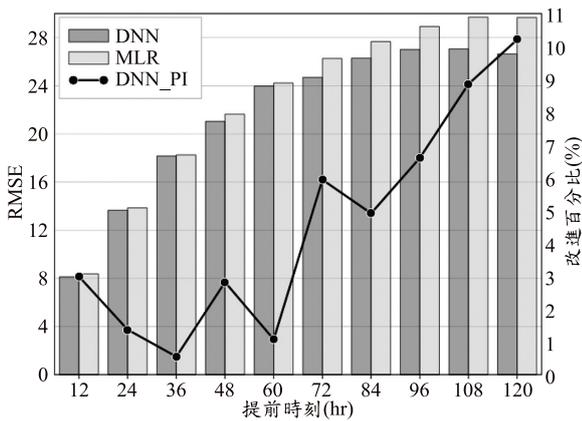


圖 5 測試資料 DNN 與 MLR 模式之 RMSE 與改進百分比

$$DNN\_PI = \left( \frac{DNN\text{模式之}RMSE - MLR\text{模式之}RMSE}{MLR\text{模式之}RMSE} \right) \times 100\% \quad (9)$$

根據圖中 DNN\_PI (折線圖) 顯示，DNN 模式改進百分比皆有提升，提前時刻超過 84 小時，改進百分比逐漸增加，其最大提升幅度甚至近 10%。

## 5.2 颱風強度預報模式效能評估

圖 6 為不同提前時刻，由 12 小時至 120 小時，DNN 模式與 MLR 基準模式測試資料預報之散佈圖。

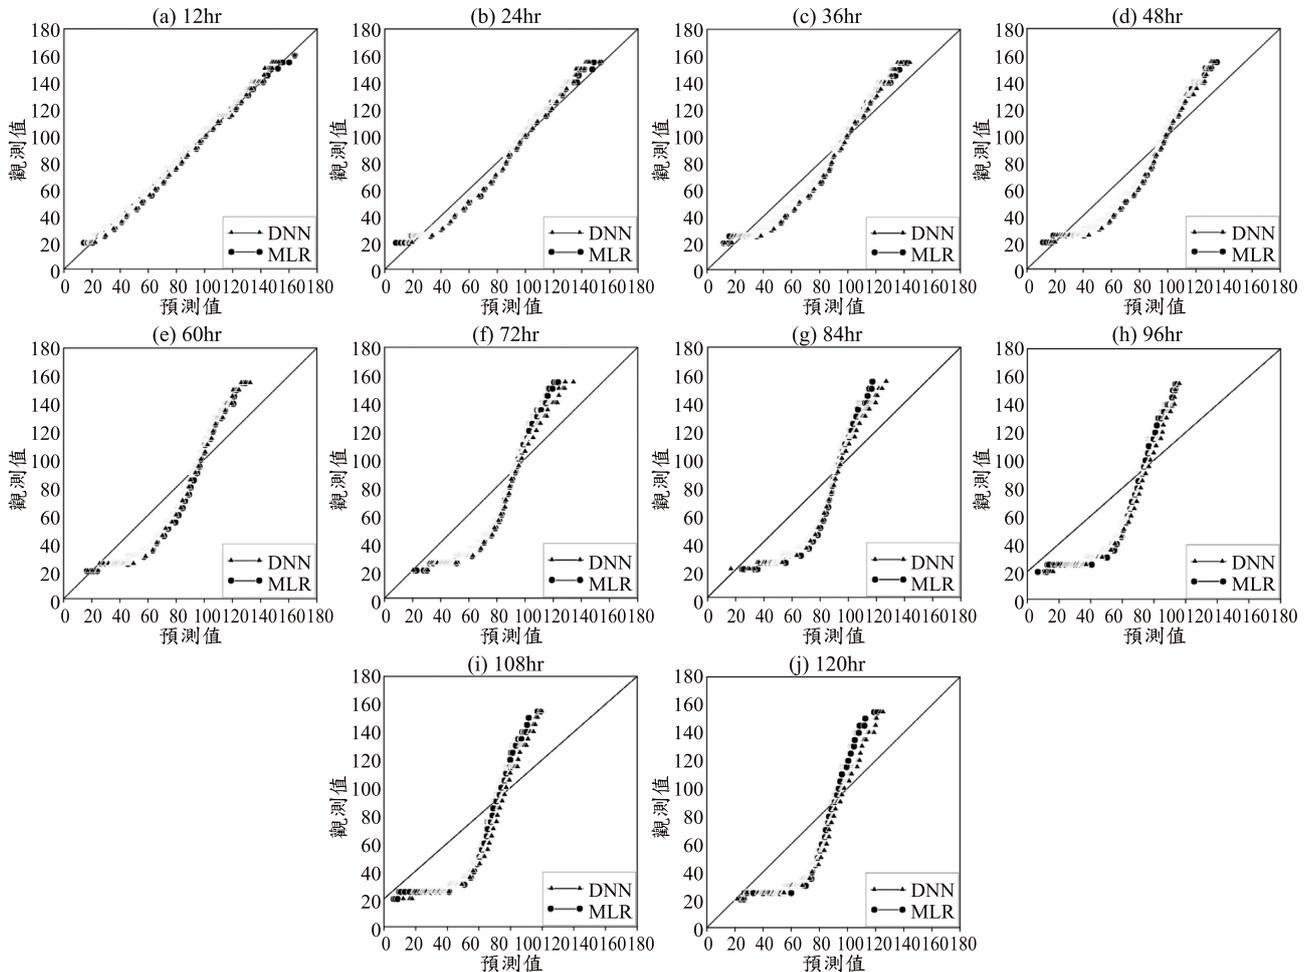


圖 6 DNN 及 MLR 各提前時刻測試資料預報散佈圖

由圖中可知，整體而言 DNN 與 MLR 模式預報趨勢極為一致，除提前時刻 12 小時較不明顯外，均顯示高低估趨勢的一致性，即預報值在 80 至 100 (kts)，為分界，預報強度小於該分界值，顯示低估之趨勢，而預報強度高於該分界值，則顯示高估之趨勢。同時，任何提前時刻而言，MLR 模式低估與高估情況均高於 DNN 模式，顯示 DNN 模式無論高低估預報結果，均優於 MLR 模式。隨著預報提前時刻增加，高估情況越顯著，預報值越高於實測值。預報提前時刻大於 60 小時，預報值介於 40 至 60 kts，低估情況最顯著。

### 5.3 颱風強度預報模式之個案效能分析

本研究選用 2011 年的桑達 (Songda) 颱風為颱風個案，探討 DNN 與 MLR 模式預報颱風強度之效能。桑達颱風編號為 WP042011，其強度及路徑如圖 7 所示。初始預報時間為 2011 年 5 月 21 日 00 時，結束預報時間為 2011 年 5 月 29 日 00 時，其最大強度變化由初始 34 ~ 63 kts，逐漸增強至大於 130 kts，接近台灣時，最大強度逐漸增強至最大，遠離台灣時最大強度逐漸降低至 64 ~ 129 kts。圖 8 為分別利用 DNN

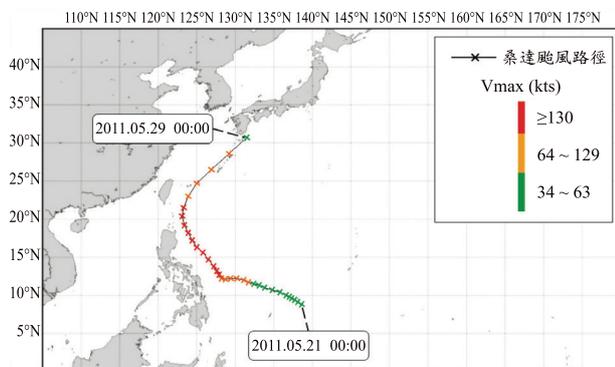


圖 7 桑達颱風強度路徑圖

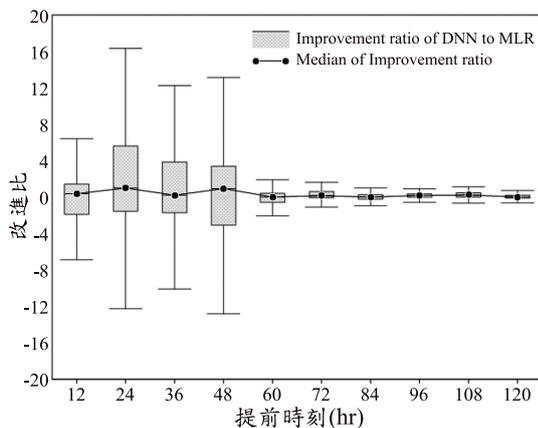


圖 8 桑達颱風之改進比之盒鬚圖

模式與 MLR 基準模式預報不同提前時刻桑達颱風之強度，並計算其改進百分比之盒鬚圖 (boxplot)。由圖可知，桑達颱風提前時刻 12 小時到 48 小時 DNN 模式改進百分比變異性較大，反之提前時刻 60 小時到 120 小時，DNN 模式改進百分比變異性較小。對於桑達颱風強度預報，圖 8 盒鬚圖之中位數可知，當提前時刻為 24 小時與 48 小時，DNN 模式改進百分比相對最大，其他提前時刻 DNN 與 MLR 模式表現，由中位數觀之，改進幅度較不明顯。

## 六、結論

本研究，以 DNN 深度學習神經網路架構為基礎，建立未來五天每十二小時為間隔之 DNN 颱風強度預報模式，使用 SHIPS 資料中大氣以及海洋因子作為模式輸入因子，改進西北太平洋颱風強度預報。以 MLR 多變量線性迴歸建立颱風強度預報基準模式，比較 DNN 與 MLR 模式之效能，選用 2011 年桑達颱風作為個案，比較 DNN 與 MLR 模式個案預報之改進效能。依據結果提出以下結論：

1. DNN 架構與參數使用各個提前時刻以 adam 為優化器，激勵函數則為 sigmoid 與 tanh 兩者，學習率的選擇大部分都是使用 0.001，批量大小每個提前時刻不同，層數除提前時刻 12 小時外為兩層隱藏層外，其餘提前時刻皆為一層，節點則從 10 至 90 不定。
2. DNN 模式相較於 MLR 模式之改進百分比皆有提升，尤其提前時刻超過 84 小時，改進百分比逐漸增加，其最大改進提升幅度甚至近 10%。
3. 整體而言，MLR 模式低估與高估情況均高於 DNN 模式，隨著預報提前時刻增加，高估情況越顯著。預報提前時刻大於 60 小時，預報值介於 40 至 60 kts，低估情況最顯著。
4. 桑達颱風個案研究顯示，提前時刻 12 小時到 48 小時 DNN 模式改進百分比變異性較大，提前時刻 60 小時到 120 小時，DNN 模式改進百分比變異性較小。
5. 桑達颱風個案研究顯示，提前時刻為 24 小時與 48 小時，DNN 模式改進百分比相對最大。

## 誌謝

本研究承蒙科技部計畫補助計畫編號 MOST 109-2625-M-033-001-得以完成，特此致謝。

## 參考文獻

1. DeMaria, M. & Kaplan, J. (1999). An Updated Statistical Hurricane Intensity Prediction Scheme (SHIPS) for the Atlantic and Eastern North Pacific Basins. *Weather and Forecasting*, 14, pp. 326-337.
2. DeMaria, M., Mainelli, M., Shay, L. K., Knaff, J. A. & Kaplan, J. (2005). Further Improvements to the Statistical Hurricane Intensity Prediction Scheme (SHIPS). *Weather and Forecasting*, 20, pp. 531-543.
3. DeMaria, M., Sampson, C. R., Knaff, J. A. & Musgrave, K. D. (2014). Is Tropical Cyclone Intensity Guidance Improving? *Bulletin of the American Meteorological Society*, 95, pp. 387-398.
4. Duchi, J., Hazan, E. & Singer, Y. (2011). Adaptive Subgradient Methods for Online Learning and Stochastic Optimization. *Journal of Machine Learning Research* 12.
5. Jarvinen, B. R. & Neumann, C. J. (1979). Statistical Forecasts of Tropical Cyclone Intensity for the North Atlantic Basin.
6. Jiang, G. Q., Xu, J. & Wei, J. (2018). A Deep Learning Algorithm of Neural Network for the Parameterization of Typhoon-ocean Feedback in Typhoon Forecast Models. *Geophysical Research Letters*, 45, pp. 3706-3716.
7. Kingma, D. P. & Ba, J. (2014). Adam: A Method for Stochastic Optimization. arXiv preprint arXiv:1412.6980.
8. Knaff, J. A., DeMaria, M., Sampson, C. R. & Gross, J. M. (2003). Statistical, 5-day Tropical Cyclone Intensity Forecasts Derived from Climatology and Persistence. *Weather and Forecasting*, 18, pp. 80-92.
9. Knaff, J. A., Sampson, C. R. & DeMaria, M. (2005). An Operational Statistical Typhoon Intensity Prediction Scheme for the Western North Pacific. *Weather and Forecasting*, 20, pp. 688-699.
10. Kuo, B. C., Ho, H. H., Li, C. H., Hung, C. C. & Taur, J. S. (2013). A Kernel-based Feature Selection Method for SVM with RBF Kernel for Hyperspectral Image Classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7, pp. 317-326.
11. Li, C. H., Hsien, P. J. & Lin, L. H. (2018). A Fast and Automatic Kernel-based Classification Scheme: GDA+SVM or KNWFE+ SVM. *J. Inf. Sci. Eng.* 34, pp. 103-121.
12. Li, C. H., Lin, C. T., Kuo, B. C. & Ho, H. H. (2010). An Automatic Method for Selecting the Parameter of the Normalized Kernel Function to Support Vector Machines, in: 2010 International Conference on Technologies and Applications of Artificial Intelligence. *IEEE*, pp. 226-232.
13. Li, C. Y., Lin, S. S., Lin, Y. F. & Kan, P. S. (2019). A Bootstrap Regional Model for Assessing the Long-term Impacts of Climate Change on River Discharge. *International Journal of Hydrology Science and Technology*, 9, pp. 84-108.
14. Mulia, I. E., Tay, H., Roopsekhar, K. & Tkalich, P. (2013). Hybrid ANN-GA Model for Predicting Turbidity and Chlorophyll-a Concentrations. *Journal of Hydro-Environment Research*, 7, pp. 279-299.
15. Samsudin, R., Saad, P. & Shabri, A. (2010). A Hybrid Least Squares Support Vector Machines and GMDH Approach for River flow Forecasting. *Hydrology and Earth System Sciences Discussions*, 7, pp. 3691-3731.
16. Sandhya, N. & Charanjeet, K. R. (2016). A Review on Machine Learning Techniques. *International Journal on Recent and Innovation Trends in Computing and Communication*, 4, pp. 451-458.
17. Sharma, N., Ali, M. M., Knaff, J. A. & Chand, P. (2013). A Soft-computing Cyclone Intensity Prediction Scheme for the Western North Pacific Ocean. *Atmospheric Science Letters*, 14, pp. 187-192.
18. Tsai, H. C. & Elsberry, R. L. (2014). Applications of Situation-dependent Intensity and Intensity Spread Predictions Based on a Weighted Analog Technique. *Asia-Pacific Journal of Atmospheric Sciences*, 50, pp. 507-518.
19. 宋政樺, 2019 年, 「以調適性網路模糊推論系統推估西北太平洋颱風強度預報」, 中原大學土木工程學系碩士班學位論文。
20. 林碩彥, 2016 年, 「利用 SHIPS 資料改進颱風強度統計預報模式之研究」, 淡江大學水資源及環境工程學系碩士班學位論文。
21. 甘秉玄、林旭信、胡衍立、宋政樺, 2017 年, 「結合非線性主成份分析與 GA-FUZZY 之颱風降雨預測模式」, 中原大學土木工程學系碩士班學位論文。
22. Li, C. Y., Lin, S. S., Chuang, C. M. & Hu, Y. L. (2020). Assessing Future Rainfall Uncertainties of Climate Change in Taiwan with a Bootstrapped Neural Network-based Downscaling Model. *Water and Environment*

*Journal*, 34, pp. 77-92.

23. Bai, Y. *et al.* (2016). "Daily Reservoir Inflow Forecasting Using Multiscale Deep Feature Learning with Hybrid Models", *Journal of Hydrology*, 532, pp. 193-206.
24. Bai, Y. *et al.* (2017). "A Multi-pattern Deep Fusion Model for Short-term Bus Passenger Flow Forecasting", *Applied Soft Computing*, 58, pp. 669-680.
25. Coppola Jr, E. A. *et al.* (2005). "A neural Network Model for Predicting Aquifer Water Level Elevations", *Groundwater*, 43(2), pp. 231-241.
26. Liu, F. (2017). "A Flood Forecasting Model Based on

Deep Learning Algorithm via Integrating Stacked Autoencoders with BP Neural Network", in 2017 IEEE Third International Conference on Multimedia Big Data (BigMM). 2017 IEEE Third International Conference on Multimedia Big Data (BigMM), pp. 58-61.

收稿日期：民國 111 年 10 月 14 日

修改日期：民國 111 年 12 月 05 日

接受日期：民國 111 年 12 月 27 日