

國立勤益科技大學  
工業工程與管理系碩士班

碩士論文

以 ARIMA 模式與 ANN 模式預測短期風機風速

指導教授：楊旭豪 博士

研究生：莊涵如

中華民國一〇二年六月

以 ARIMA 模式與 ANN 模式預測短期風機風速

**Forecasting Short-Term Wind Speed Using ARIMA  
Model and ANN Model**

研究生：莊涵如

指導教授：楊旭豪

國立勤益科技大學

工業工程與管理系碩士班

碩士論文

A Thesis

Submitted to

Institute of Industrial Engineering and Management  
National Chin-Yi University of Technology  
in Partial Fulfillment of the Requirements  
for the Degree of  
Master of Engineering

June 2013

Taiping, Taichung, Taiwan, Republic of China

中華民國一〇二年六月

國立勤益科技大學  
工業工程與管理系碩士班

論文口試委員會審定書

本校 工業工程與管理系 碩士班 莊涵如 君

所提論文 以 ARIMA 模式與 ANN 模式預測短期風機風速

合於碩士資格水準，業經本委員會評審認可。

口試委員：

楊明亭  
李冰博  
曾清枝

指導教授：

楊如子

系(所)主任：

康鶴耀

中華民國 102 年 6 月

# 國立勤益科技大學

## 博碩士論文全文上網授權書

(提供授權人裝訂於紙本論文書名頁之次頁用)

本授權書所授權之論文為授權人在國立勤益科技大學  
工業工程與管理系\_\_\_\_\_組 102 學年度第\_\_\_\_學期取得碩  
士學位之論文。

論文題目：以ARIMA模式與ANN模式預測短期風機風速  
指導教授：楊旭豪

### ■ 同意

本人具有著作權之論文全文資料，非專屬、無償授予本人畢業學校圖書館，不限地域、時間與次數，以微縮、光碟或數位化等各種方式重製與利用，提供讀者基於著作權法合理使用範圍內之線上檢索、閱覽、下載及列印。

論文全文上載網路公開之範圍及時間：

校內區域網路	<input checked="" type="checkbox"/> 立即公開
校外網際網路	<input checked="" type="checkbox"/> 中華民國 107 年 6 月 20 日公開

授權人：莊涵如

簽名：莊涵如

中華民國 102 年 6 月 20 日

# 以 ARIMA 模式與 ANN 模式預測短期風機風速

學生：莊涵如

指導教授：楊旭豪 教授

國立勤益科技大學工業工程與管理系碩士班

## 摘要

近年來全球面臨能源逐漸耗竭，且隨著環保意識的抬頭，許多先進國家開始積極尋求替代能源。然而舉凡太陽能源亦或是水力發電等，都不及風力發電能源的乾淨與低汙染。儘管如此，風的不穩定性仍然是一大挑戰，若能準確預測風速，且善用風力帶來的風能，將是未來最具環保的能源之一。

本研究蒐集台灣某電廠風機 SCADA (Supervisory Control And Data Acquisition) 系統的資料，探討綜合自迴歸移動平均模型 (Autoregressive Integrated Moving Average; ARIMA) 與類神經演算法 (Automated Neural Networks; ANN)，以預測短時間內風機的風速，並根據平均絕對誤差 (mean absolute error; MAE)，與平均相對誤差 (mean relative error; MRE) 比較預測的正確率。

ARIMA 及 ANN 建模的方式，皆採用每十分鐘一筆的 SCADA 數據，並以第二期風速觀測值預測第一期。結果顯示非線性的 ANN 模型的 MAE 及 MAR 皆小於傳統線性的 ARIMA 模型，因此我們可以得知 ANN 在預測風速上，比 ARIMA 好。

**關鍵字：**ARIMA、ANN、風速預測。

# **Short-Term Wind Speed Forecasting Application**

## **ARIMA and ANN**

Student : Han-Ru Chuang

Advisor : Dr. Hsu-Hao Yang

**Department of Industrial Engineering and Management**  
**National Chin-Yi University of Technology**

### **Abstract**

The purpose of this study is to apply autoregressive integrated moving average (ARIMA) and automated neural networks (ANN) models to predict short-term wind speed. We collected the wind speed in a power plant in Taiwan. In addition to the ARIMA, the ANN is also used to model and predict the wind speed that is collected every ten minutes. The prediction accuracy is determined by mean average error (MAE) and mean relative error (MRE) to determine.

We find that both of the MAE and MRE in ANN are smaller than those in the ARIMA. The results show that the ANN model is better than the ARIMA one in forecasting short-term wind speed.

**Key words** : *ARIMA, ANN, Forecasting wind speed*

## 目錄

摘要 .....	I
<b>Abstract</b> .....	II
目錄 .....	III
表目錄 .....	V
圖目錄 .....	VI
第一章、緒論 .....	1
1.1 研究背景與動機： .....	1
1.2 研究目的： .....	2
1.3 研究架構與流程 .....	4
第二章、文獻探討 .....	6
2.1 ARIMA 模型： .....	8
2.2 ANN 模型： .....	9
2.3 混合模型： .....	10
第三章、研究流程、步驟及研究方法 .....	12
3.1 研究流程： .....	12
3.2 研究步驟： .....	13
3.3 研究方法： .....	14
第四章、研究結果分析與比較 .....	15
4.1 綜合自回歸移動平均模型： .....	16
4.2 類神經網路演算法： .....	19
4.3 研究結果顯示： .....	21

4.3.1 ARIMA 研究分析： .....	21
4.3.2 類神經網路演算法： .....	25
4.3.3 ARIMA 與 ANN 的 MAE 及 MRE 比較： .....	27
4.4 ARIMA 及 ANN 研究結果整理： .....	28
第五章、結論與建議 .....	30
參考文獻 .....	31
附錄 .....	37





## 表目錄

表 1.部分 SCADA 資料.....	13
表 2. January ANN 建模部分預測值與觀測值 .....	25
表 3.ANN 及 ARIMA January-June MAE 及 MRE 的比較表.....	27
表 4.ANN、ARIMA July-December 及 January-December MAE 及 MRE 的 比較表 .....	28



## 圖目錄

圖 1. 本文流程架構 .....	5
圖 2. 風力發電機簡圖 .....	6
圖 3. 研究流程圖 .....	12
圖 4. ANN 圖 .....	19
圖 5. MLP 圖 .....	20
圖 6. 風速的類神經網路圖 .....	20
圖 7. January ACF 與 PACF 檢定圖 .....	21
圖 8. January ARIMA(1,0,1) 檢定圖 .....	22
圖 9. January ARIMA(1,0,1) 參數及各統計數值圖 .....	23
圖 10. January ARIMA(1,0,1) 風速預測折線圖 .....	24
圖 11. January ARIMA(1,0,1) 風速預測趨勢折線圖 .....	24
圖 12. January ANN-Ensemble 風速預測折線圖 .....	26
圖 13. January ANN-Ensemble 風速預測趨勢折線圖 .....	26

# 第一章、緒論

在第一章將先介紹本研究計畫的背景動機、目的與本研究架構。

## 1.1研究背景與動機：

近年來全球面臨能源耗竭的世代即將到來，在各國政府倡導節能減碳的趨勢下，環保意識逐漸抬頭，許多先進國家開始積極尋求替代能源。然而舉凡太陽能、生質能源、亦或是水力發電等，都不及風力發電能源來的乾淨甚至低污染。

台灣天然資源匱乏，能源進口比率極高，但沿海的風力資源豐富，適合發展風力發電，尤其澎湖年平均風速高達10m/sec，其風能資源與風場條件在全世界數一數二，也讓風力發電成為我國發展替代能源的重要政策。儘管如此風的不穩定性仍然是一大挑戰，若能準確預測風速，且善用風力帶來的風能，這將是未來最具環保的能源之一。

根據World Wind Energy Association (WWEA, 2012)的統計，截至2012上半年全球風力發電總裝置容量為254,000MW (or 250GW)，其中裝置容量的前五名國家：中國、美國、德國、西班牙與印度共佔全球約74%。預計未來風力發電之設置量仍將大幅成長。風力發電是目前增長最快的可再生能源，而短期預測風速或風能等相關文獻，已成為許多專家學者熱門研究的議題，但風的不穩定性及高度波動性等多項因素影響下，如何準確預測風速變得愈來愈重要，預測的方法有很多，Lei et al.(2009)將預測方法分為以下四種：一、物理模型，二、空間相關性模型，三、傳

統的統計模型，四、人工智慧和新模型。

## 1.2 研究目的：

根據台灣經濟部能源局(2012)的「經濟部 2012 年能源產業技術白皮書」，目前政府提出風能技術發展的推動策略，此報告針對風能評估技術所提出的推動策略包含：(1) 海氣象觀測站之建置技術、(2)開發大氣/海浪/海洋環流耦合數值模型、與(3)建立海況預報系統等，並闡述截至 2011 年 11 月為止，國內陸域風場共設置近 288 架風力機，累計裝置容量約 564MW，離岸風場尚未開始設置。預計陸域優良風場已趨飽和，將在 2020 年之前開發完成，最多可設置約 450 架風力機，約相當於 1,200MW 裝置容量。為進一步強化風能開發利用，將預計在 2015 年完成國內首座離岸風場開發，並於 2020 年完成開發淺海風場 1,000MW，相當於 200 架風力機。之後以每年 200MW 裝置容量的開發速度，推動大規模深海風場開發，以逐步達到裝置容量 3,000MW 的目標，合計離岸共設置 600 架風力機。

但對於風預測部分大都使用氣象資料而非風機資料，該兩者資料並不完全一致，因此本研究預計收集風機的風速應用數量方法與資料挖礦方法，以預測未來的風速。

本研究蒐集台灣某電廠風機 SCADA (Supervisory Control And Data Acquisition) 系統的資料，其優點是可修正即時資料，並探討綜合自回歸移動平均模型 (Autoregressive Integrated Moving Average; ARIMA) 與類神經網路演算法 (Automated Neural Networks; ANN)，以預測短期內風機風速，藉由平均絕對誤差 (mean absolute error; MAE)、平均相對誤差 (mean relative error; MRE) 比較兩者預測的正確率。

本文研究主要目的為以下兩點表示：

1. 本文探討 ARIMA 模型與 ANN 模型，預測短期風機風速。
2. 藉由 MAE 及 MRE 比較兩者預測正確率。



### 1.3 研究架構與流程

本文流程圖如下頁圖 1 所示，而文章架構主要分為五大章節，依序為緒論、文獻探討、研究方法、流程及研究步驟、研究結果分析與比較，並在第五章作一總結，以下為各章節的簡述：

#### 第一章、緒論

說明本研究動機與研究目的。

#### 第二章、文獻探討

分別介紹 ARIMA 模型、ANN 模型與混合模型等相關文獻。

#### 第三章、研究方法、流程及研究步驟

詳述本文研究流程方法及實行研究步驟。

#### 第四章、研究結果分析與比較

依研究說明實驗結果並分析與比較。

#### 第五章、結論

將綜合本文之研究結果，提出結論與後續研究方向與改進。

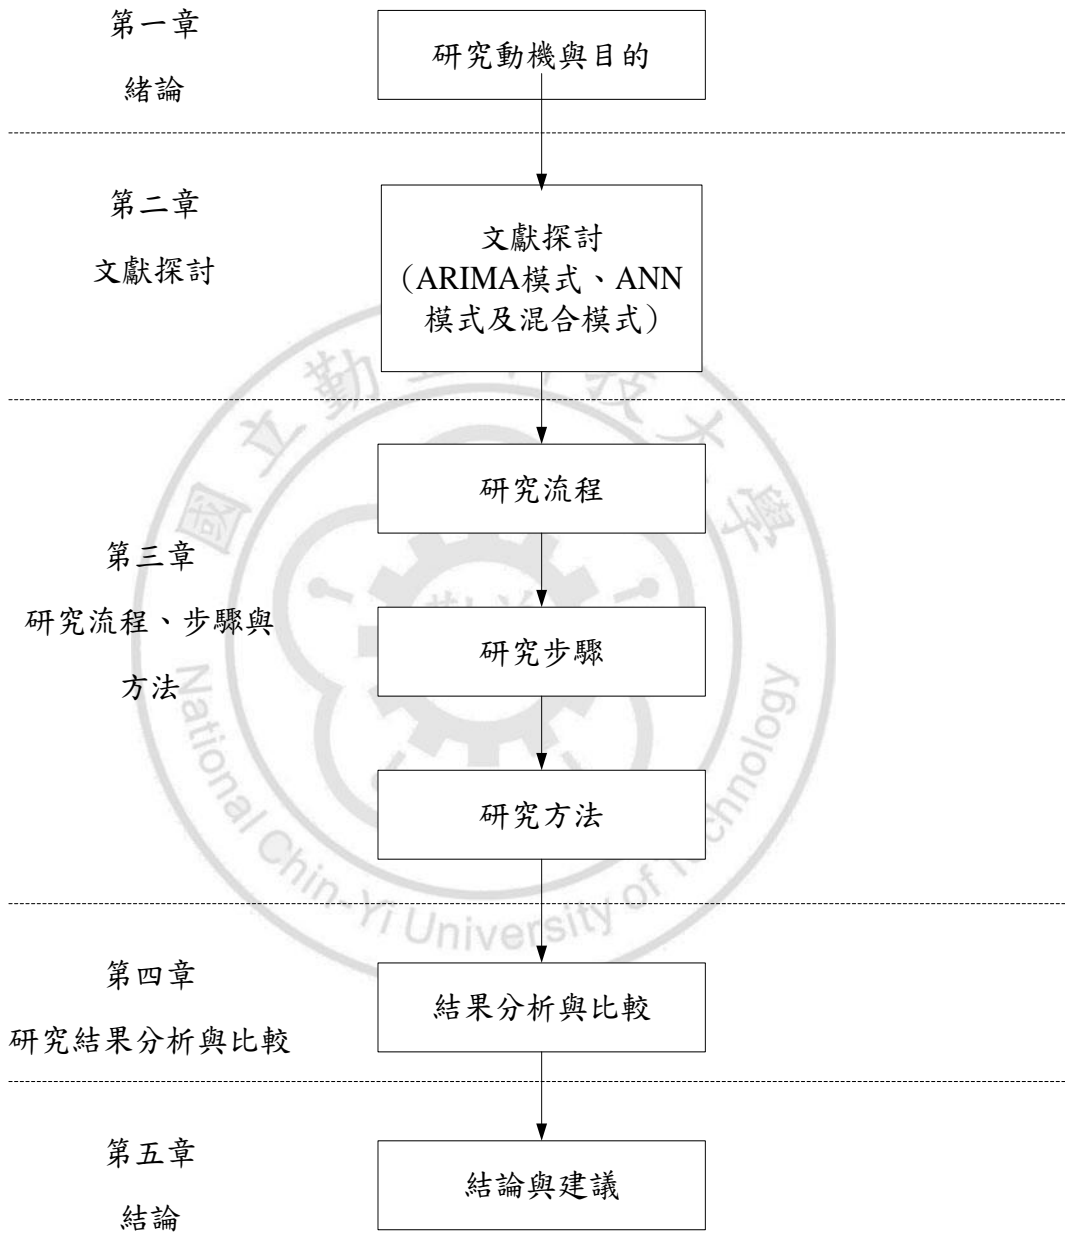


圖 1. 本文流程架構

## 第二章、文獻探討

至今研究再生能源的文獻不少，但風速預測方面卻不多，主因是數據蒐集不易，又大多以氣象觀測數據作為研究數據，而本文則將使用 SCADA 數據作為研究數據，為使讀者較清楚本文所將採用的研究方法，以下先簡介風機與風能相關背景，接續再將分別為 ARIMA 模型、ANN 模型以及混合模型做各相關文獻探討。




圖 2.風力發電機簡圖

風力發電機的特性主要是藉著空氣流動轉動葉片以擷取風的動能，進而轉換成有用的機械能或電能。常見的風力發電機組主要包括風車、機艙(nacell)或稱為引擎艙、和塔架(tower)如圖 2 所示。

風車是由數片扇葉(blade)和旋轉軸組成，當風吹向扇葉時，驅動扇葉繞旋轉軸轉動。葉片轉子受風的風力而轉動，係源於氣動力的作用（包括升力及阻力），



對葉片產生轉動扭矩。當葉片數目愈多，風車所受的阻力愈大，風機的震動和噪音問題愈嚴重，現代風車大多為三片扇葉。扇葉的材料需要質量輕、強度高的材料，新型的風車多用玻璃纖維或碳纖維等複合材料來製造。過去風機的葉片角度通常採用固定旋角(stall)，無法因風向改變而調整葉片角度，其優點是構造較簡單價格低廉，但因無法調整角度，葉片容易磨損，而且風速過大時需配備較大能力之煞車系統，增加維修成本。因此目前所廣為採用的是可變旋角(pitch)，提供風機在運轉中可以調整葉片角度進而調整轉速，獲取最大風能，但也因構造複雜，成本較貴。

機艙在塔架上方，搭載齒輪箱、低速與高速軸、發電機、控制台、偏角馬達(yaw drive)與其它控制設備等。大型風機並於機艙外裝設風速計(amenometer)與風向標(wind vane)，測量風速與風向。因為大型風機的投資、安全與效能等因素，風速與風向的測量必須高度精確，因此一般氣象用的風速計並不適用。因為風速和風向隨時在改變，這會使得風車扇葉的轉速不穩定。因此扇葉在帶動發電機之前，必須加裝一個齒輪變速箱和調節器，將轉速提高到一個固定的轉速後再連接至發電機。新型的風機大多使用電腦控制，除了能自動啟動與關機外，並具有自動迎風轉向、控制葉片旋角(blade pitch)，且可遠距監控不需人員操作，節省人力成本。

偏角馬達或稱迎風轉向馬達，為使風力發電機能正向迎風，以發揮最大風能效率。在接近起動風速時開始迎風，以機艙頂部風向計測得之風向與機艙方向作比較，迎風控制系統即動作馬達重新對準風向；通常以常年最大風速方向（如北方或東北方）作為歸零點，以基準點輸入系統，供比對機艙風向計方向與機艙方向。

而塔架是用以支撐扇葉、機艙與轉向系統，且使風機的迴轉中心有一定的高度

與穩定性，因當離地愈高所能獲得的風速也愈大，故現代的風機不斷往大型化發展，塔架內包含電纜、照明設備及維護爬梯以方便進入維修機艙。

## 2.1 ARIMA模型：

Box and Jenkins (1994)提出 ARIMA 模式，該模型已成熟並廣泛應用於時間序列預測當中。Liu et al. (2013) 探討海上風力渦輪機風速波動影響風力發電輸出功率，使用 ARMA 模型及 ARMA-GARCH-M 模型，並藉由 MAE、RMSE 及 TIC 作為模型檢定，在預測風速上發現兩種模型都有顯著影響，但其中又以 ARMA 模型的擬合度比 ARMA-GARCH-M 模型來得較好。Shi, Qu, & Zeng (2011)根據風速和境外的 2 兆瓦風力發電機組的電力生產數據，比較兩種方法的績效。比較結果為 ARMA(Autoregressive Moving Average)模型的預測值較 ARIMA 模型的預測值，較符合實際測量值，Erdem and Shi (2011)根據 ARMA 模型，提出四種研究方法預測短期風速。Kavasseri and Seetharaman (2009)提出 fractional-ARIMA (f-ARIMA)模型預測未來 1 天與 2 天的風速。Torres et al. (2005)使用 5 種 ARMA 模型，分別在 5 個不同地點預測每小時平均風速，並結論指出本模型預測 9 年資料的錯誤率低於 20%。

Poggi et al. (2003)使用 AR 模型預測未來 3 小時的風速。Milligan et al. (2003) 應用自回歸移動平均 (ARMA) 預測模型來預測風力發電生產，根據不同的預測水平，發現該模型結果比其他傳統預測模型來的較好。而 Durán et al. (2007) and Fugon et al. (2008) 同樣都有發現類似的傳統時間序列模型，在風速預測上有較好的結果顯示。然而考慮到 ARIMA 模型為一個線性方法，另有文獻指出應用 ANN，進行

風速預測。

## 2.2 ANN模型：

Cao et al. (2012)探討類神經網路預測風速，採用同風機塔在 5 個離地面不同高度的數據作為風速預測的研究樣本，並比較分析單變量的 ANN 及多變量的 ARIMA 預測的精準度，該研究主要結論提出，非線性的 ANN 比標準線性的 ARIMA 提供更好的預測結果。

Li and Shi (2010)及 More and Deo (2003)說明 ANN 模型，可以在歷史觀測的數據中，了解隱藏層的模式或關係上，並用它們來預測未來的數值。其中 Li and Shi (2010)更是以三個典型 ANN 演算法，即自適應線性元件(Adaptive Linear Element；ADALINE)、倒傳播函數(Back Propagation；BP)以及徑向基函數(Radial Basis Function；RBF)使用氣象數據風速資料進行提前一小時風速預測，並利用平均絕對誤差 MAE、均方根誤差 RMSE 和平均絕對誤差百分比 MAPE，三個指標性能進行評估，結果表明，三者模型間沒有特別較好的預測模型，而原因與原始風速數據有關。

Cadenas and Rivera (2009)測試預測風速的 4 種 ANN 模型架構，並結論指出最佳的架構只包含 2 層與 3 個神經元。Mabel and Fernandez (2008)根據類神經網路，利用風速的相對濕度，作為每小時訓練輸入變量的一代，並將預測數據與實際數據進行比較，提供了良好的結果。除此之外，Hmzaçe(2008)提出了考慮季節性時間序列預測的類神經網路的結構。該模型在時間序列的季節性強時使用特別方便，但是如果季節性薄弱時，不同的類神經網路結構可能會更適合。Jursa and Rohrig

(2008)則發現進行最佳化算法的應用，適用於風力發電的預測，並有效地找到預測模型的輸入變量和模型參數的 ANN 方法。

而 Louka et al. (2008)在研究中則發現，如果預測的時間為長期的（例如，未來 120 小時），將天氣預報的風速數值列入其中，將有助於提高風電功率預測的準確性。Potter and Negnevitsky (2006) 提出一適應性類神經模糊 (adaptive neuro fuzzy) 系統預測風速。而 Fonte and Quadrado (2005)研究指出，單獨使用 ANN，用來預測每小時平均風速，並將前一小時的風速值作為輸入層參數，比使用氣象數據值來得準確。More and Deo (2003)更是說明 ANN 優於 ARIMA 模型。

### 2.3 混合模型：

許多類型的混合模型都可被用來預測風速及風力發電，組合類型可以分為：

- 一、 結合物理和統計方法
- 二、 短期和中期的組合模型
- 三、 結合替代統計模型

混合模型的優勢是可從中獲益每一個模型，並獲得全局最佳化的預測性能，在一般情況下，系統的使用者可以比較歷史預測數據與實際輸出的數據，且可改善風預測工具的性能。Wu and Hong (2007)指出應當強調，各種預測評估標準的重要性，特別是使用 RMSE 和 MAE 評估的預測模型。

Liu et al. (2013)探討風速預測，使用小波轉換、小波包、ARIMA 及 ANN 提出該三種模型進行預測風速，其數據來自中國青海風電廠，風速數據資料期間為 2011 年 12 月 20 日至 2012 年 1 月 5 日，研究結果表示三種混合模型皆有不錯的顯著結

果，其中又以 Wavelet Packet-ANN 模型為最佳預測模型。Jiang et al. (2012)提出 ARMA 與 generalized autoregressive conditional heteroscedasticity 的混合模型預測風速。而模擬結果驗證該模型於預測風速的有效性、正確性與優越性。Liu et al. (2012) 探討 ARIMA-ANN 及 ARIMA-Kalman 兩種新方法預測風速的比較，運用 ARIMA 模型來決定 ANN 模型的建構，並將兩者結合，結果顯示表明該兩種新方法有其準確度，適合應用在非平穩的風速預測及風力發電系統中，另外 Cadenas and Rivera (2010)使用 ARIMA 結合 ANN 混合模型，預測墨西哥三個地區的風速並比較實際測量數據，結果顯示 ANN 可降低 ARIMA 預測值的誤差項，但預測模型並非為一個正統的 ARIMA 模型。Barbounis et al. (2006) 根據氣象資料，以遞迴 (recurrent) ANN 模型建構預測長期風速與風能的模型。Potter and Negnevitsky (2006) 提出一適應性類神經模糊 (adaptive neuro fuzzy) 系統預測風速。Sfetsos (2002) 根據時間序列分析，提出模型用於預測平均每小時的風速，並且顯示該模型優於傳統的預測模型。Sfetsos (2000) 比較預測風速的數種方法：a persistence model、ARIMA 模型、NN 模型、與 neuro-fuzzy systems，並結論指出，NN 模型的平均改善(average improvement)最好。Ramírez-Rosado and Fernández-Jiménez (2004) 提出的模式先以傅立葉轉換(Fourier transform)風速資料，然後以模糊推論系統(fuzzy inference systems)預測傅立葉轉換的系數，最後再根據預測的傅立葉轉換系數預測風速。

### 第三章、研究流程、步驟及研究方法

本章細分為三節，先介紹 3.1 研究流程接續為 3.2 研究步驟與 3.3 研究方法。

圖 3.為本文研究方法的主要流程。

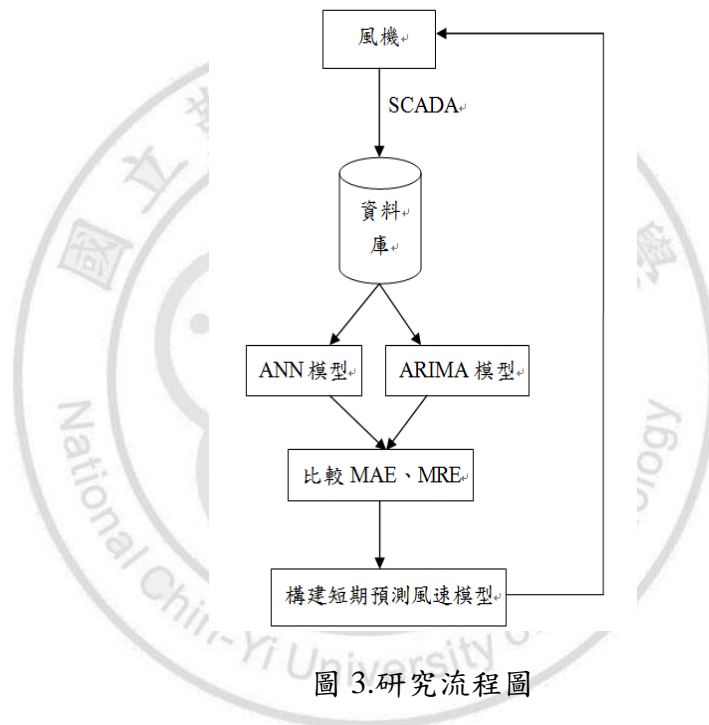


圖 3.研究流程圖

#### 3.1研究流程：

根據圖 3，本研究主要是萃取風機 SCADA 系統的資料，比較 ARIMA 模式與 ANN 所構建的模型，以預測短時間內風機的風速，為比較模型的正確率本研究構想將使用 MAE 與 MRE 來做判定。至於考慮應用類神經網路演算法，將於以下的「4.2 類神經網路演算法」說明。因為風速通常隨時間變化而持續改變，因此本研究特點是由萃取 SCADA 所構建的模型，易於修正即時資料。

### 3.2 研究步驟：

本研究構想之實施步驟預計如下：

1. 收集風機 SCADA 所儲存的資料，如表 1 所示。

表 1. 部分 SCADA 資料

TIME	M_S AVG	KW AVG	KWH
02:10:00	18.20	695.00	116
02:20:00	18.30	705.00	119
02:30:00	18.80	716.00	120

其中，

M\_S AVG 為每秒平均風速(m/s)，

KW AVG 為平均發電量，

KWH 為發電小時數。

2. 區分 SCADA 資料為訓練組與測試組。
3. 根據訓練組與測試組的資料，分別應用二種方式預測風速。
4. 比較預測的正確率。

為比較預測的正確率，本研究構想將使用平均絕對誤差(mean absolute error; MAE)，與平均相對誤差(mean relative error; MRE)，定義如下：

$$\text{MAE} = \frac{\sum_{t \in \text{Data}} |v_t^*(t) - v_t(t)|}{|\text{Data}|}, \text{-----}(1)$$

$$\text{MRE} = \frac{\sum_{t \in \text{Data}} |v_t^*(t) - v_t(t)| \times 100\%}{|\text{Data}|}, \text{-----}(2)$$

其中，

$|\text{Data}|$ ：在訓練組或測試組的資料筆數，

$v_t^*(t)$ ：在時間  $t$  所預測值之風速值，

$v_t(t)$ ：在時間  $t$  所觀測值之風速值。

### 3.3 研究方法：

將使用 Eviews 軟體來構建 ARIMA 模型以及使用 STATISTICA 軟體構建 ANN 模型作為本文預測風速的建模，並分別於「4.1 節 ARIMA 模型」和「4.2 節 ANN 模型」做詳述的研究方法介紹。



## 第四章、研究結果分析與比較

本研究預測風機(wind turbine)的短期風速，但因預測風速模式的複雜度，因此本研究應用類神經網路(neural networks)演算法以及綜合自回歸模型(ARIMA)，以下先介紹產生風能的基本方程式。

風力機利用風可產生的理論風能是：

$$P = 0.5\rho AV^3, \text{-----}(3)$$

其中，

$P$  是風能，

$\rho$  是空氣密度(air density)，

$A$  是風機轉子(rotor)的橫掃面積，

$V$  是風速。

但受限於機械設備能量轉換的效率，實際上可產生的風能為：

$$P = 0.5\rho AC_p(\lambda, \beta)V^3, \text{-----}(4)$$

其中，

$C_p(\lambda, \beta)$  代表轉子能量係數(rotor power coefficient)。

$C_p(\lambda, \beta)$  決定於尖速度比(tip-speed ratio) $\lambda$ ，與葉片旋角角度(blade pitch angle) $\beta$ 。而  $\lambda$

可以由下式決定：

$$\lambda = \frac{\omega_r R}{V}, \text{-----}(5)$$

$R$  是風機轉子的半徑，

$\omega_r$  是轉子的旋轉速度。

空氣密度  $\rho$  在一定高度的風機下，長期而言可視為一常數，而風機轉子的橫掃面積也是常數。因此根據(3)式，影響風能的最重要參數是風速  $V$ 。

預測風速本質上屬於研究時間序列(time series)的問題，因此本文採用傳統時間序列方法 ARIMA 以及 ANN 中的時間序列模式，進行兩者模型間的比較分析，以下將依本研究的研究方法分別做說明：

#### 4.1 綜合自回歸移動平均模型：

時間序列問題一般可表示如下：

$$v(t+1) = f(v(t), v(t-1), \dots, v(t-k)), \text{-----}(6)$$

其中，

$v(t+1)$ ：預測風機在時間  $(t+1)$  之風速值，

$v(t), v(t-1), \dots, v(t-k)$ ：風機在時間  $t, t-1, \dots, t-k$  之風速觀測值。

處理模式(6)可考慮數種方法，其中最常見之一是由 Box and Jenkins 所提出的 Autoregressive Moving Average (ARMA) 模式。一個包含參數  $p$  與  $q$  的 ARMA( $p, q$ ) 模式如下。

$$y_t = \sum_{i=1}^p \phi_i v_{t-i} + \sum_{j=1}^q \theta_j e_{t-j} + \varepsilon_t, \text{-----}(7)$$

其中，

$y_t$  是時間為  $t$  時的風速觀測值，

$\phi_i$  是第  $i$  個自我迴歸 (autoregressive) 的參數，

$\theta_j$  是第  $j$  個移動平均 (moving average) 的參數，

$\varepsilon_t$  是時間為  $t$  時的誤差項。

由於時間序列的資料可能為非穩定 (non-stationary)，因此需要使用差異化 (difference) 或整合 (integrated) 將資料轉為穩定。而經整合後的模式稱為 Autoregressive Integrated Moving Average (ARIMA) 模式。令  $d$  表示非季節因素的整合參數，則 ARMA( $p, q$ ) 模式變成 ARIMA( $p, d, q$ )。其參數值須先經過自相關函數 (autocorrelation function; ACF) 檢定，及偏自相關函數 (partial autocorrelation function; PACF) 檢定，作為判別其參數值的假定是否為正確假定。

ACF 的定義在不同的領域並不一致。在介紹 ACF 前，我們先介紹穩定 (stationary) 的隨機過程表示如下：

$$f(t_1) f(t_2) \dots f(t_n) = f(t_1 + \tau) f(t_2 + \tau) \dots f(t_n + \tau), \text{-----}(8)$$

也就是聯合機率密度函數不受時間影響。假設於時間序列中，風速的樣本觀測值為  $v_1, v_2, \dots, v_n$ 。因此，在穩定的假設下，風速  $v_t$  與  $v_{t-k}$  的共變異 (covariance)，只要是相隔  $k$  期都相同，不受  $t$  的影響。該共變異也稱為相隔  $k$  期的自變異 (autocovariance)，定義如下：

$$r_k = \text{Cov}(v_t, v_{t-k}) = E[(v_t - \mu)(v_{t-k} - \mu)] \text{ , -----}(9)$$

其中，

$\mu$  是觀測值的期望值。

因此，相隔  $k$  期的 ACF 定義如下：

$$\rho_k = \frac{\text{Cov}(v_t, v_{t-k})}{\sigma_{v_t} \sigma_{v_{t-k}}}, \text{-----}(10)$$

其中，

$\text{Cov}(v_t, v_{t-k})$  是觀測值  $v_t$  與  $v_{t-k}$  的共變異，

$\sigma_{v_t}$  是觀測值  $v_t$  的標準差，

$\sigma_{v_{t-k}}$  是觀測值  $v_{t-k}$  的標準差。

$\rho_k$  其值範圍為  $-1 \sim 1$  之間， $1$  為最大相關值， $-1$  則為最大負相關值。

若觀測值  $v_t$  與  $v_{t-k}$  來自穩定隨機過程，則因  $V(v_t) = V(v_{t-k})$ ，則因此(9)式可表示為：

$$\rho_k = \frac{\text{Cov}(v_t, v_{t-k})}{V(v_t)}, \text{-----}(11)$$

更進一步，ACF 相隔  $k$  期的關係為：

$$\rho_k = \frac{r_k}{r_0}, \text{-----}(12)$$

ACF 主要是衡量時間序列的持續性，亦即資料於各期是否有相關性。而與 ACF 常使用的是偏自相關函數(partial autocorrelation function; PACF)，因此於此簡介 PACF。PACF 是衡量目前的觀測值  $v_t$ ，與落後期為  $k$  的觀測值  $v_{t-k}$ ，的相關性，但同時消除兩者間落後期存在的影響。換言之， $p$  次的 PACF 是去除第 1 期到  $p - 1$  期影響之後的相關係數。第一個 PACF 就是第一 ACF。落後期為 5 的 PACF 是測量在  $v_1, v_2, v_3, v_4$  的情況下，加進  $v_5$  的預測能力。PACF 可計算如下：

$$\phi_{kk} = \frac{\text{Cov}(v_t, v_{t-k} | v_{t-1}, v_{t-2}, \dots, v_{t-k+1})}{\sigma_{v_t} \sigma_{v_{t-k}}}, \text{-----}(13)$$

根據(13)式，

$$\phi_{11} = \text{Cov}(v_1, v_0) = \rho_1$$

$$\phi_{kk} = \text{Cov}(v_k - f_{k-1}, v_0 - f_{k-1}), k \geq 2, \text{-----}(14)$$

其中，

$f_{k-1} = f(v_{k-1}, \dots, v_1)$  是最小化  $E(v_k - f_{k-1})^2$ 。

#### 4.2類神經網路演算法：

一個基本ANN模型包含三個素：輸入權值，加總，與輸出函數。輸入權值模擬神經元，輸出函數則產生神經元的最終結果。ANN模型通常還包含一額外輸入項，也就是偏差項(bias)。偏差項的權值通常假設為1。上述的ANN模型如圖4表示。圖3中， $I_1, I_2,$  and  $I_3$ 是輸入項， $w_1, w_2,$  and  $w_3$ 是輸入權值， $B$ 是偏差項， $x$ 是中間輸出， $O$ 是最終結果。

最終結果 $O$ 的方程式為：

$$O = f(w_1I_1 + w_2I_2 + w_3I_3), \text{-----}(15)$$

其中  $f$  可以為  $\pm 1$ ，線性函數，或其他複雜的曲線函數型態。




圖 4. ANN 圖

最常見的 ANN 為多階層感知(multilayer perceptron; MLP)，如圖 5 所示。




圖 5. MLP 圖

MLP 屬於多層前向式網路的監督式學習法，常用以輸入及輸出值間的相對關係，其網路模式的輸出值與目標值間的誤差可以作為模式修正用的參考依據。根據圖 5，應用 MLP 架構於預測風速可表示如圖 6。圖 6 含基本的輸入層(Input layer)，隱藏層(Hidden layer)與輸出層(Output layer)。圖 6 的結構表示，輸入層表示時間  $t-1, t-2, \dots, t-k$  之風速觀測值，經過隱藏層的計算與函數轉換，輸出層表示時間  $t$  之風速值。




圖 6.風速的類神經網路圖

### 4.3研究結果顯示：

本節將細分為 4.3.1ARIMA 研究分析、4.3.2 類神經網路演算法及 4.3.3 ARIMA 與 ANN 的 MAE 及 MRE 比較。

#### 4.3.1 ARIMA 研究分析：

如前 4.2 所介紹，ARIMA 模式包含參數組( $p, d, q$ )。為計算這些參數，使用 Eviews 軟體中的 Autocorrelation Function (ACF)檢定與 Partial Autocorrelation Function(PACF)檢定，作為辨別其參數值的假定。

本研究蒐集台灣某民營電廠，萃取某台風機 SCADA 系統的資料，預測涵蓋期間為 2009 年 1 月 1 日至 1 月 31 日每 10 分鐘一筆共 4464 筆資料，其往後 2 月至 12 月份及整年度數據資料一併附於本文附錄。

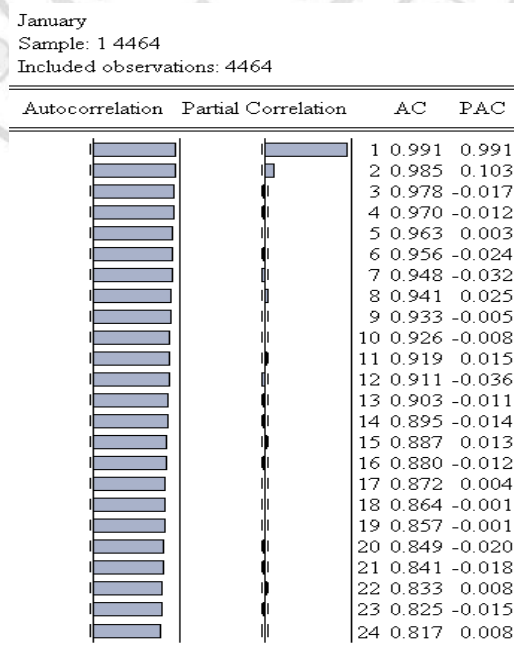


圖 7. January ACF 與 PACF 檢定圖

其中，

AC = Autocorrelation

PAC = Partial Autocorrelation correlation

根據圖 7 顯示，短期風速數據的 ACF 檢定呈現遞減趨勢，因此假定參數  $p=1$ ，且 PACF 在第一根突出後第二根截斷我們可以判定其參數  $q=1$ 。要確定其參數假定是否為有效假定，本研究透過 Eviews 軟體將參數值(1,0,1)帶入，其實際驗證顯示結果如圖 8。

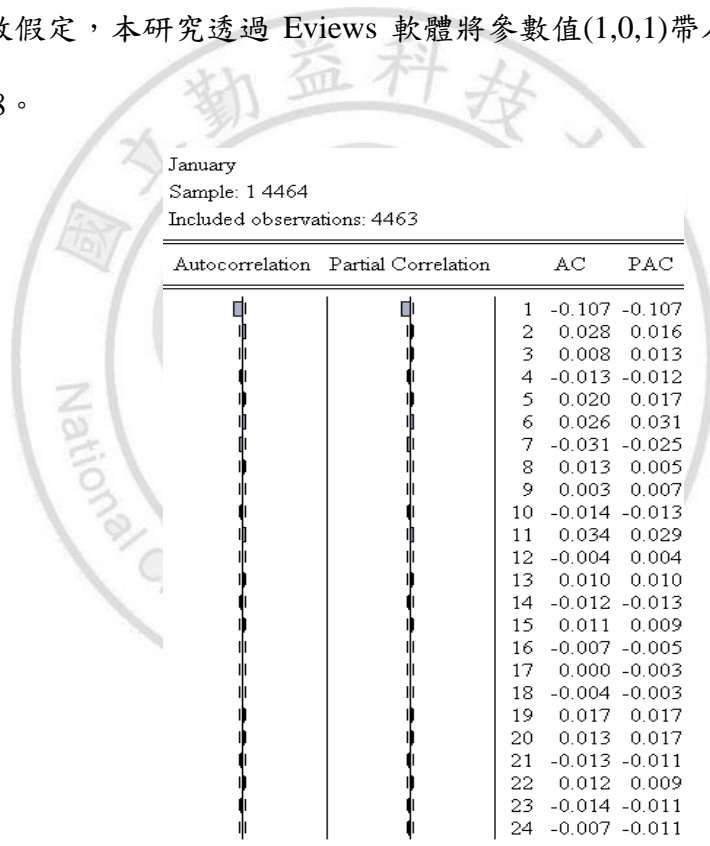


圖 8. January ARIMA(1,0,1)檢定圖

根據圖 8 顯示，我們可以發現在原數據資料呈現遞減的 ACF 及在第一根突出後第二根截斷的 PACF，經由 ARIMA(1,0,1)模式的帶入後，其 ACF 及 PACF 皆表現出收斂狀態，因此可以確定，我們假定的 ARIMA(p, d, q)參數值為 ARIMA(1,0,1)為有效假定。



Dependent Variable: W				
Method: Least Squares				
Date: 06/13/13 Time: 15:43				
Sample (adjusted): 2 4464				
Included observations: 4463 after adjustments				
Convergence achieved after 7 iterations				
MA Backcast: 1				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.998502	0.000752	1327.633	0.0000
MA(1)	-0.101821	0.014918	-6.825187	0.0000
R-squared	0.983887	Mean dependent var	12.18777	
Adjusted R-squared	0.983884	S.D. dependent var	5.971370	
S.E. of regression	0.758065	Akaike info criterion	2.284352	
Sum squared resid	2563.568	Schwarz criterion	2.287222	
Log likelihood	-5095.532	Hannan-Quinn criter.	2.285364	
Durbin-Watson stat	2.005380			
Inverted AR Roots	1.00			
Inverted MA Roots	.10			

圖 9. January ARIMA(1,0,1)參數及各統計數值圖

在此風速樣本數名稱為 W 總樣本數為 4464 筆，因為使用第二期數值預測第一期數值，所以圖 9 該樣本數為 4463 筆。

原公式(7)為  $y_t = \sum_{i=1}^p \phi_i v_{t-i} + \sum_{j=1}^q \theta_j e_{t-j} + \varepsilon_t$ ，依據 Eviews 結果如圖 9 顯示

其中，

AR(1) =  $\phi_1$  第  $i$  個自我迴歸(autoregressive)的參數 = 0.998502

MA(1) =  $\theta_1$  是第  $j$  個移動平均(moving average)的參數 = -0.101821

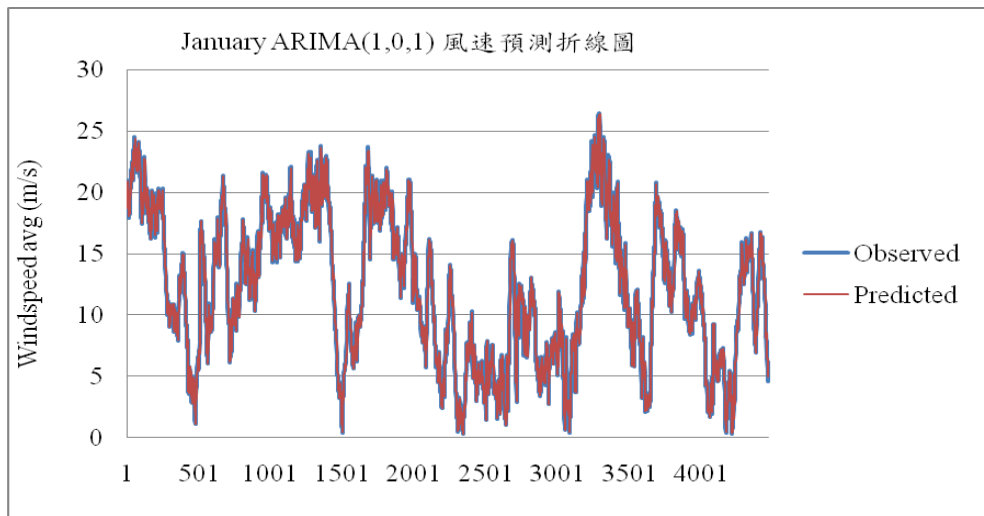


圖 10. January ARIMA(1,0,1) 風速預測折線圖

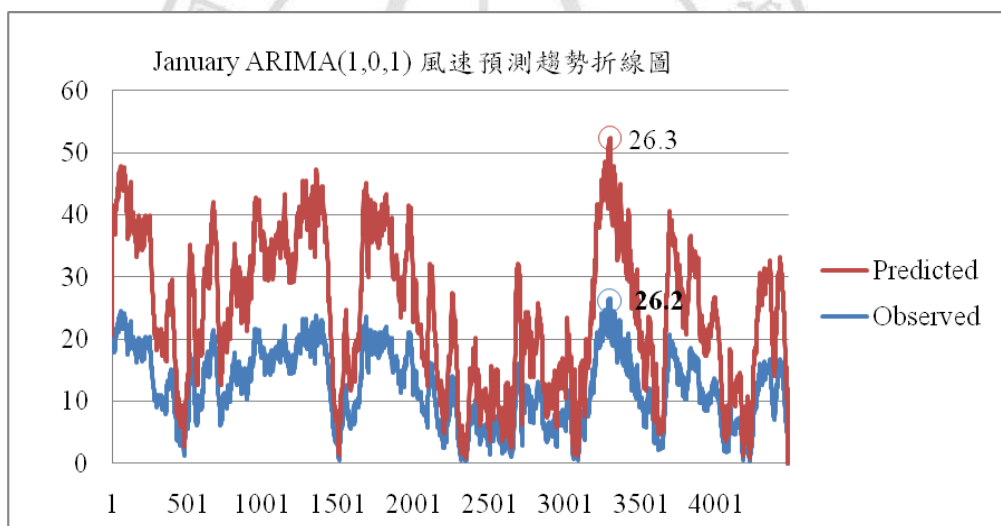


圖 11. January ARIMA(1,0,1) 風速預測趨勢折線圖

圖 10 顯示為 2009 年一月份 ARIMA(1,0,1)模型，在短期平均風速每秒公尺下的觀測值與預測值，而圖 11 顯示其趨勢折線圖共 4464 筆資料，其中在第 3289 筆的平均風速觀測值下為 26.2m/s，平均風速預測值則為 26.3m/s，之間的誤差約為 0.1m/s。

#### 4.3.2 類神經網路演算法：

表 2. January ANN 建模部分預測值與觀測值

時間	風速 觀測值	MLP1-2-1	MLP1-7-1	MLP1-6-1	Ensemble
12:00	19.40				
12:10	19.80	19.35	19.46	19.33	19.38
12:20	18.60	19.73	19.84	19.73	19.77
12:30	19.30	18.59	18.67	18.54	18.60
12:40	20.70	19.26	19.36	19.23	19.23

表 2 為類神經網路演算法中的時間序列方法建模而得的表，以每十分鐘一筆的平均風速 SCADA 資料，再以第二期平均風速觀測值，去預測第一期平均風速值而得到的輸出結果，本研究建構三條 ANN 模型分別為 MLP1-2-1、MLP1-7-1、MLP1-6-1 及平均權重的 Ensemble(ANN-Ensemble)，為了保有數據客觀性，我們將以 ANN 輸出的 Ensemble 作為與 ARIMA(1,0,1)模式比較，其 2009 年一月份數據共 4464 筆資料分別算出 MAE 及 MRE，比較結果與分析。

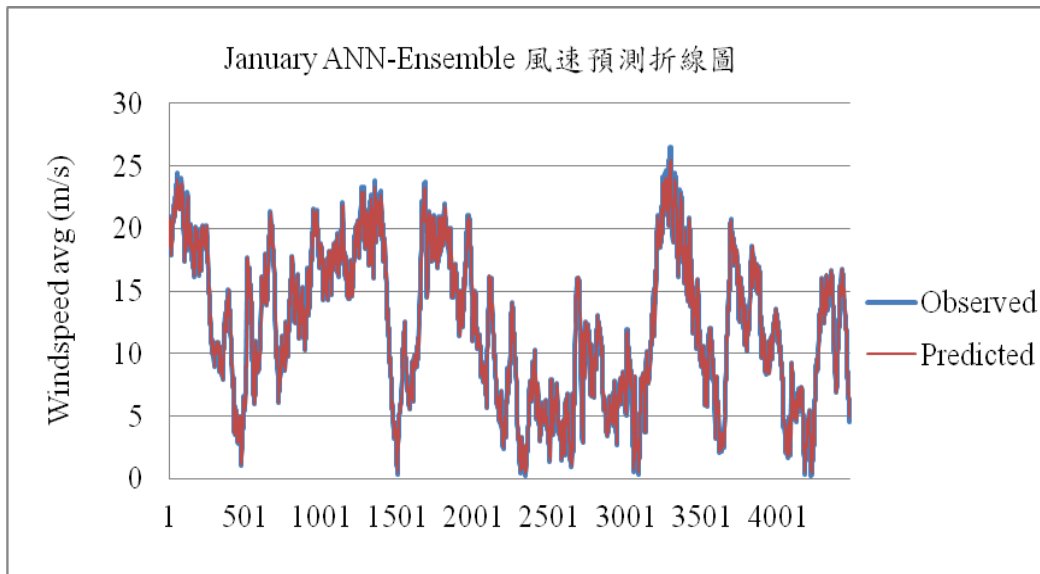


圖 12. January ANN-Ensemble 風速預測折線圖

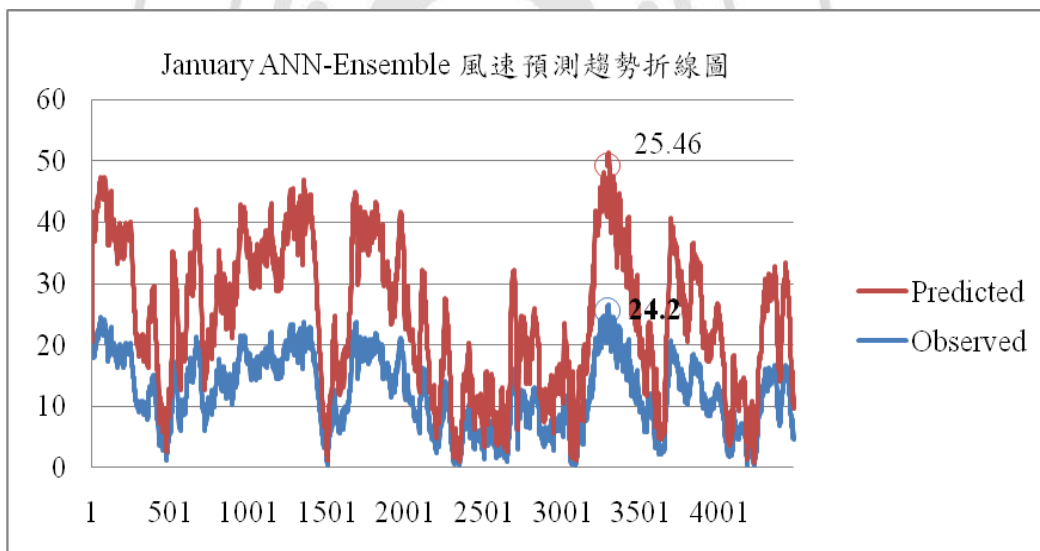


圖 13. January ANN-Ensemble 風速預測趨勢折線圖

圖 12 為 2009 年一月份 ANN-Ensemble 以第二期風速值，預測第一期風速而輸出的結果，表示在每秒公尺下預測的折線圖。圖 13 則是顯示預測值與觀測值的趨勢圖，其中第 3273 筆風速觀測值為 24.2m/s，風速預測值為 25.46m/s，之間的誤差為 1.26m/s。

### 4.3.3 ARIMA 與 ANN 的 MAE 及 MRE 比較：

表 3. ANN 及 ARIMA January-June MAE 及 MRE 的比較表

Month	Model	MAE	MRE
January	ANN-Ensemble	0.0023	0.23
	ARIMA(1,0,1)	0.0164	0.16
February	ANN-Ensemble	0.0093	0.93
	ARIMA(1,0,1)	0.0210	2.10
March	ANN-Ensemble	0.0013	0.13
	ARIMA(1,0,1)	0.0269	2.70
April	ANN-Ensemble	0.0035	0.35
	ARIMA(1,0,1)	0.0253	2.53
May	ANN-Ensemble	0.0007	0.07
	ARIMA(1,0,1)	0.0204	2.04
June	ANN-Ensemble	0.0042	0.42
	ARIMA(1,0,1)	0.0487	4.87

如表 3 所示，可以得知 ARIMA(1,0,1)的 MRE 最小值為一月份 0.23 最大值為六月份 4.87，而 ANN-Ensemble 最小值為五月份 0.07 最大值為二月份 0.93 皆不超過 1，因此從此表我們可以知道 ANN-Ensemble 的預測正確率比 ARIMA(1,0,1)好。

表 4. ANN、ARIMA July-December 及 January-December MAE 及 MRE 的比較表

Month	Model	MAE	MRE
July	ANN-Ensemble	0.0039	0.39
	ARIMA(1,0,1)	0.0295	2.95
August	ANN-Ensemble	0.0015	0.15
	ARIMA(1,0,1)	0.0263	2.63
September	ANN-Ensemble	0.0059	0.59
	ARIMA(1,0,1)	0.0257	2.57
October	ANN-Ensemble	0.0030	0.30
	ARIMA(1,0,1)	0.0200	2.00
November	ANN-Ensemble	0.0110	1.01
	ARIMA(1,0,1)	0.0161	1.61
December	ANN-Ensemble	0.0090	0.90
	ARIMA(1,0,1)	0.0220	2.20
January-December	ANN-Ensemble	0.0019	0.19
	ARIMA(1,0,1)	0.216	2.16

表 4 為 2009 下半年及當年度的兩種模式下風速預測 MAE 和 MRE 的比較表，我們可以得知，ANN-Ensemble MRE 最小值為八月份 0.15 最大值為十一月份 1.01，ARIMA(1,0,1) MRE 最小值為十月份 2.00 最大值為七月份 2.95，其及最小值為最佳，故整體而言 ANN 模型為預測短期風速最好。

#### 4.4 ARIMA及ANN 研究結果整理：

ARIMA 我們假定參數(p, d, q) 建模而成 ARIMA(1,0,1)，進行 ACF 及 PACF 檢定，分別在圖 7 和圖 8 的部分可以看到收斂結果，該結果顯示參數檢定為有效

假設。ARIMA 的一月份風速觀測值與預測值的折線圖和趨勢折線圖共 4464 筆資料，分別顯示於圖 10 及圖 11，在短期平均風速每秒公尺下的觀測值與預測值，其中在第 3289 筆的平均風速觀測值下為 26.2m/s，平均風速預測值則為 26.3m/s，之間的誤差約為 0.1m/s。

ANN 的建模，則是為保有數據資料的客觀性，我們採用 ANN 輸出的平均權重 Ensemble 作為與 ARIMA 比較的模型。圖 12 表示短期平均風速在每秒公尺下預測的折線圖，以第二期風速值預測第一期風速，而輸出的 Ensemble 結果，圖 13 則是顯示預測值與觀測值的趨勢圖，其中第 3273 筆風速觀測值為 24.2m/s，風速預測值為 25.46m/s，之間的誤差約為 1.26m/s。

為了比較 ARIMA 及 ANN 的預測準確程度的高低，表 3 和表 4 分別呈現 ANN 及 ARIMA 兩種模型方法的 MAE 及 MAR。表 3 為 2009 上半年所示，可以得知 ARIMA(1,0,1)的 MRE 最小值為一月份 0.23 最大值為六月份 4.87，而 ANN-Ensemble 最小值為五月份 0.07 最大值為二月份 0.93 皆不超過 1，因此從表 3 中我們可以知道 ANN-Ensemble 的預測正確率比 ARIMA(1,0,1)來的較好。表 4 為 2009 下半年及當年度的兩種模式下風速預測 MAE 和 MRE 的比較表，從中可以得知，ANN-Ensemble MRE 最小值為八月份 0.15 最大值為十一月份 1.01，ARIMA(1,0,1) MRE 最小值為十月份 2.00 最大值為七月份 2.95，其及最小值為最佳。

在表 3 和表 4 中，兩者預測方法皆為 ANN 的表現較好，故整體而言 ANN 模型為短期預測風速中最好。

## 第五章、結論與建議

台灣經濟部能源局(2012)的「經濟部 2012 年能源產業技術白皮書」內有提及政府推動再生能源，計畫在本島近海建置離岸風機約 600 台，也就是在海上豎立風力發電機。當然，再生能源的來源不只有風力發電機，相較於現階段的核能發電、太陽能發電、火力及水力發電等，風力發電是最為乾淨的再生能源。

本研究蒐集台灣某電廠，萃取某風機 SCADA 系統的資料，採用其平均風速預測期間涵蓋為 2009 年 1 月至 12 月每 10 分鐘一筆共計 52274 筆資料，並應用 ARIMA 模型及 ANN 模型，建構每個月份短期預測平均風速及整年度預測模式，比較其兩者的預測正確率。

經本研究比較 2009 年單獨每月與整年度的 MAE 及 MRE 結果顯示，短期預測平均風速 ANN-Ensemble 的數值皆小於 ARIMA(1,0,1)模型，故整體來說 ANN-Ensemble 的預測正確率較高。

為爾後研究作為參考依據，本文有以下 3 點建議：

1. 每個月份的風速都有其獨特性質，是否應針對每個月份的不同而調整 ARIMA 模型以及 ANN 模型的建構。
2. ACF 與 PACF 檢定圖，需要經過專業的判斷，否則參數設定容易出錯。
3. 資料筆數不足或不完整，以致無法完整的模擬。



## 參考文獻

經濟部能源局, (2012).

[http://web3.moeaboe.gov.tw/ECW/populace/content/SubMenu.aspx?menu\\_id=62&sub\\_menu\\_id=148](http://web3.moeaboe.gov.tw/ECW/populace/content/SubMenu.aspx?menu_id=62&sub_menu_id=148).

Box, G. E. P., and Jenkins G. M., (1994). *Time series analysis: forecasting and control*. 3rd ed., New Jersey: Prentice Hall.

Cadenas, E., and Rivera, W., (2010). “Wind speed forecasting in three different regions of Mexico, using hybrid ARIMA-ANN model”, *Renewable energy, Elsevier*; 35: 2732-2738.

Cadenas, E. and Rivera, W., (2009). “Short term wind speed forecasting in La Venta, Oaxaca, México, using artificial neural networks.” *Renewable Energy*, 34(1), 274–278.

Damousis, I.G., Alexiadis, M.C., Theracharis, J.B. and Dokopoulos, P.S., (2004). “A fuzzy model for wind speed prediction and power generation in wind parks using spatial correlation. ” *IEEE Transactions on Energy Conversion*, 19(2), 352–361.

Durán, M.J., D. Cros, and J. Riquelme., (2007). “Short-term wind power forecast based on ARX models.” *Journal of Energy Engineering*, 133(3): 172–80.

Fonte, P. M., and Quadrado, J. C., (2005). “ANN approach to WECS power forecast.” *IEEE Conference on Emerging Technologies and Factory Automation*,1(19-22), 1069-1072.

Fugon, L., J. Juban, and G. Kariniotakis., (2008). “Data mining for wind power forecasting. ” *European wind energy conference & exhibition*, March 31–April 3, in Brussels Expo, Belgium, CD-ROM.

Hamzaç C., (2008).“Improving artificial neural networks’ performance in seasonal time series forecasting.”, *Information Sciences*;178:4550-9.

Heping, L., S. Jing, and Q. Xiuli., (2013). “Empirical investigation on using wind speed volatility to estimate the operation probability and power output of wind turbines” *Energy Conversion and Management* 67 : 8-17.

Hui, L., T. Hong-qi, P. Di-Fu and L. Yan-fei., (2013) “Forecasting models for wind speed using wavelet, wavelet packet, time series and Artificial Neural Networks” *Applied Energy*107 : 191-208.

Hui, L., T. Hong-qi, and L. Yan-fei., (2012) “Comparison of two new ARIMA-ANN and ARIMA-Kalman hybrid methods for wind speed prediction” *Applied Energy* 98 : 415-424.

Jiang, W., Yan, Z., Feng, D.-H. and Hu, Z., (2012). “Wind speed forecasting using autoregressive moving average/generalized autoregressive conditional heteroscedasticity model.” *European Transactions on Electrical Power*, 22(5), 662–673.

Jursa, R., and K. Rohrig., (2008). “Short-term wind power forecasting using evolutionary algorithms for the automated specification of artificial intelligence models.” *International Journal of Forecasting* 24: 694–709.

Kavasseri, R.G. and Seetharaman, K., (May 2009). “Day-ahead wind speed forecasting using f-ARIMA models.” *Renewable Energy*, 34(5), 1388–1393.

Lei M., Shiyang L., Chuanwen J., Hongling L., and Yan Z., (2009).“A review on the forecasting of wind speed and generated power.”, *Renewable and Sustainable Energy Reviews*;13:915-20.

Li, G., and Shi, J., (2010).“On comparing three artificial neural networks for wind speed

forecasting.” *Applied Energy* 87: 2313–20.

Louka, P., G. Galanis, N. Siebert, G. Kariniotakis, P. Katsafados, I. Pytharoulis, G.

Kallos., (2008). “Improvements in wind speed forecasts for wind power prediction purposes using Kalman filtering.” *Journal of Wind Engineering and Industrial Aerodynamics* 96: 2348–62.

Mabel, M. C., and Fernández E., (2008). “Analysis of wind power generation and prediction using ANN: a case study.”, *Renewable Energy*;33(5):986-92.

Milligan, M., M. Schwartz, and Y. Wan., (2003). “Statistical wind power forecasting models: Results for U.S. wind farms.” *NREL Report* ; CP-500-33956.

Morw, A., and Deo, M. C., (2003). “Forecasting wind with neural networks.”, *Marine Structures*, 16(1), 35-49.

Poggi, P., Muselli, M., Notton, G., Cristofi, C. and Louche, A., (2003). “Forecasting and simulating wind speed in Corsica by using an autoregressive model.” *Energy Conversion and Management*, 14(20), 3177–3196.

Potter, C. and Negnevitsky, M., (2006). “Very short-term wind forecasting for tasmanian power generation.” *IEEE Transactions on Power System*, 21(2), 965–972.

- Qing, C., E., Bradley T. and T., Mark A., (2012). "Forecasting wind speed with recurrent neural networks" *European Journal of Operational Research*,221,148-154
- Ramírez-Rosado, I.J. and Fernández-Jiménez, L.A., (2004). "An advanced model for short-term forecasting of mean wind speed and wind electric power." *Control and Intelligent Systems*, 31(1), 21–26.
- Shi, J., Qu, X., and Zeng, S., (2011). "Short-Term Wind Power Generation Forecasting: Direct Versus Indirect Arima-Based Approaches.", *International Journal of Green Energy*, 8(1), 100-112.
- Sfetsos, A., (2002). "A novel approach for the forecasting of mean hourly wind speed time series." *Renewable Energy*, 27(2), 163–174.
- Sfetsos, A., (2000). "A comparison of various forecasting techniques applied to mean hourly wind speed time series." *Renewable Energy*, 21(1), 23–35.
- Torres, J.L., García, A., de Blas, M. and de Francisco, A., (2005). "Forecast of hourly averages wind speed with ARMA models in Navarre." *Solar Energy*, 79(1), 65–77.
- Yuan-Kang Wu and Jing-Shan Hong,(2007). "A literature review of wind forecasting technology in the world," in *Proceeding of IEEE Power Tech Conference*, pp.

504–509, Lausanne, Switzerland, July 1–5.



## 附錄

February  
 Sample: 1 4029  
 Included observations: 4029

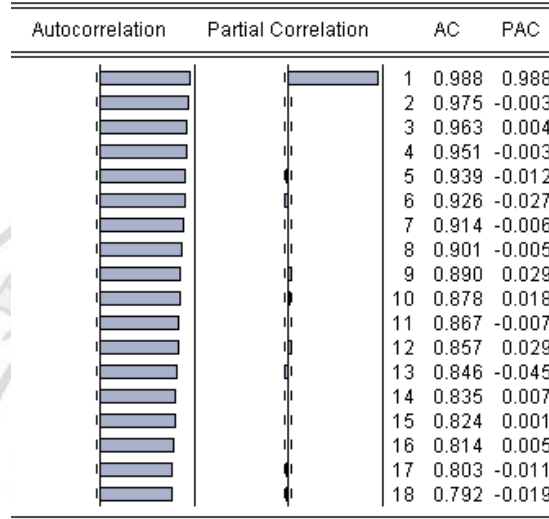


圖 7-1. February ACF 與 PACF 檢定圖

February  
 Sample: 1 4029  
 Included observations: 4028

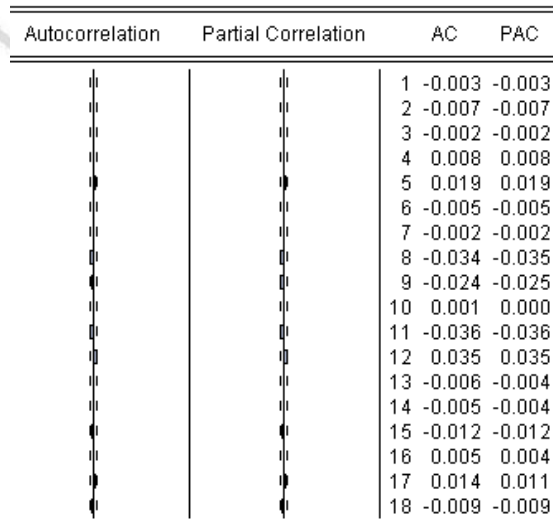


圖 8-1. February ARIMA(1,0,1)檢定圖

March  
 Sample: 1 4464  
 Included observations: 4464




圖 7-2. March ACF 與 PACF 檢定圖

March  
 Sample: 1 4464  
 Included observations: 4463




圖 8-2. March ARIMA(1,0,1)檢定圖



April  
 Sample: 1 4320  
 Included observations: 4320




圖 7-3. April ACF 與 PACF 檢定圖

April  
 Sample: 1 4320  
 Included observations: 4319

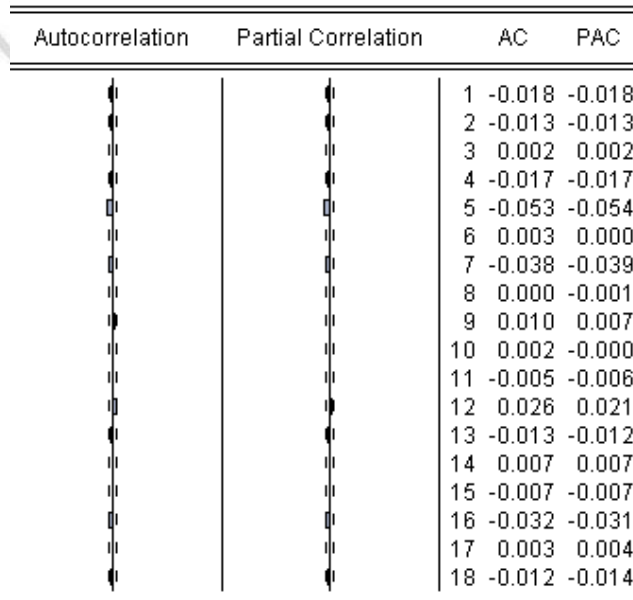


圖 8-3. April ARIMA(1,0,1)檢定圖

May  
 Sample: 1 4464  
 Included observations: 4464




圖 7-4. May ACF 與 PACF 檢定圖

May  
 Sample: 1 4464  
 Included observations: 4463




圖 8-4. May ARIMA(1,0,1)檢定圖

June  
 Sample: 1 4159  
 Included observations: 4159




圖 7-5. June ACF 與 PACF 檢定圖

June  
 Sample: 1 4159  
 Included observations: 4158




圖 8-5. June ARIMA(1,0,1)檢定圖

July  
 Sample: 1 4464  
 Included observations: 4464




圖 7-6. July ACF 與 PACF 檢定圖

July  
 Sample: 1 4464  
 Included observations: 4463




圖 8-6. July ARIMA(1,0,1)檢定圖

August  
 Sample: 1 4464  
 Included observations: 4464

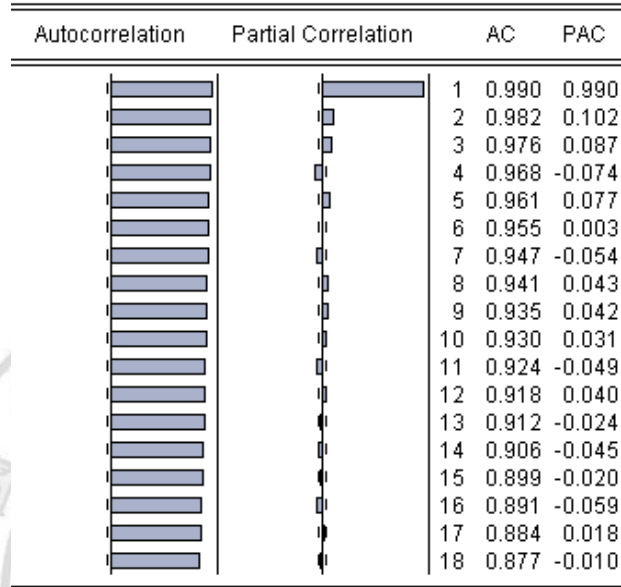


圖 7-7. August ACF 與 PACF 檢定圖

August  
 Sample: 1 4464  
 Included observations: 4463

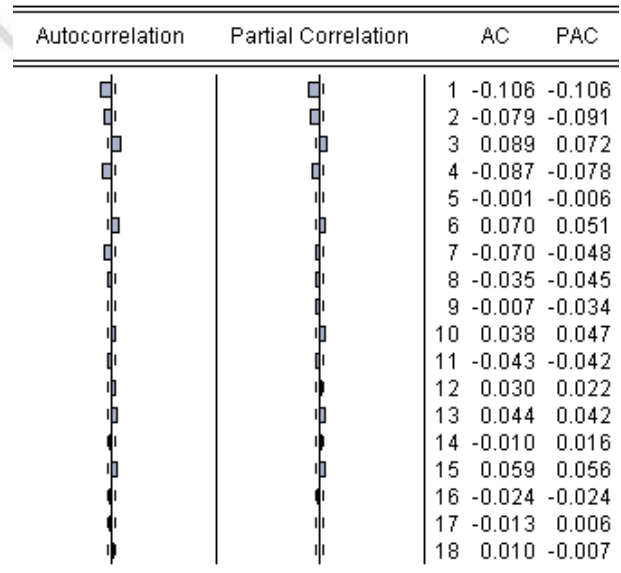


圖 8-7. August ARIMA(1,0,1)檢定圖

September  
 Sample: 1 4260  
 Included observations: 4260




圖 7-8. September ACF 與 PACF 檢定圖

September  
 Sample: 1 4260  
 Included observations: 4259




圖 8-8. September ARIMA(1,0,1)檢定圖

October  
 Sample: 1 4449  
 Included observations: 4449




圖 7-9. October ACF 與 PACF 檢定圖

October  
 Sample: 1 4449  
 Included observations: 4448




圖 8-9. October ARIMA(1,0,1)檢定圖

November  
 Sample: 1 4272  
 Included observations: 4272




圖 7-10. November ACF 與 PACF 檢定圖

November  
 Sample: 1 4272  
 Included observations: 4271




圖 8-10. November ARIMA(1,0,1)檢定圖



December  
 Sample: 1 4464  
 Included observations: 4464




圖 7-11. December ACF 與 PACF 檢定圖

December  
 Sample: 1 4464  
 Included observations: 4463




圖 8-11. December ARIMA(1,0,1)檢定圖

All year  
 Sample: 1 52273  
 Included observations: 52273

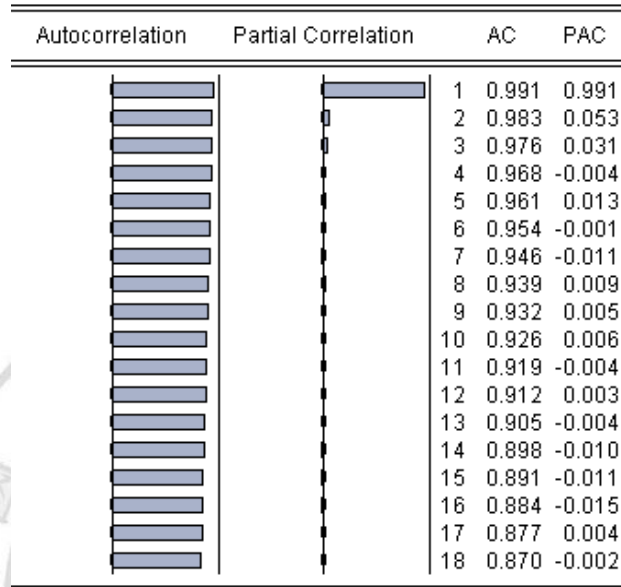


圖 7-12. All year ARIMA(1,0,1) ACF 與 PACF 檢定圖

All year  
 Sample: 1 52273  
 Included observations: 52272

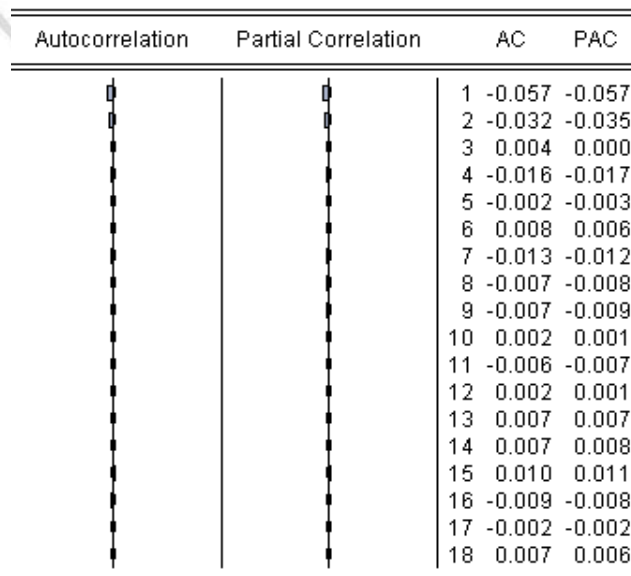


圖 8-12. All year ARIMA(1,0,1)檢定圖




圖 9-1. February ARIMA(1,0,1) 風速預測折線圖




圖 10-1. February ARIMA(1,0,1) 風速預測趨勢折線圖




圖 9-2. March ARIMA(1,0,1) 風速預測折線圖




圖 10-2. March ARIMA(1,0,1) 風速預測趨勢折線圖




圖 9-3. April ARIMA(1,0,1) 風速預測折線圖




圖 10-3. April ARIMA(1,0,1) 風速預測趨勢折線圖




圖 9-4. May ARIMA(1,0,1) 風速預測折線圖




圖 10-4. May ARIMA(1,0,1) 風速預測趨勢折線圖




圖 9-5. June ARIMA(1,0,1) 風速預測折線圖




圖 10-5. June ARIMA(1,0,1) 風速預測趨勢折線圖




圖 9-6. July ARIMA(1,0,1) 風速預測折線圖




圖 10-6. July ARIMA(1,0,1) 風速預測趨勢折線圖






圖 9-7. August ARIMA(1,0,1) 風速預測折線圖




圖 10-7. August ARIMA(1,0,1) 風速預測趨勢折線圖




圖 9-8. September ARIMA(1,0,1) 風速預測折線圖




圖 10-8. September ARIMA(1,0,1) 風速預測趨勢折線圖




圖 9-9. October ARIMA(1,0,1) 風速預測折線圖

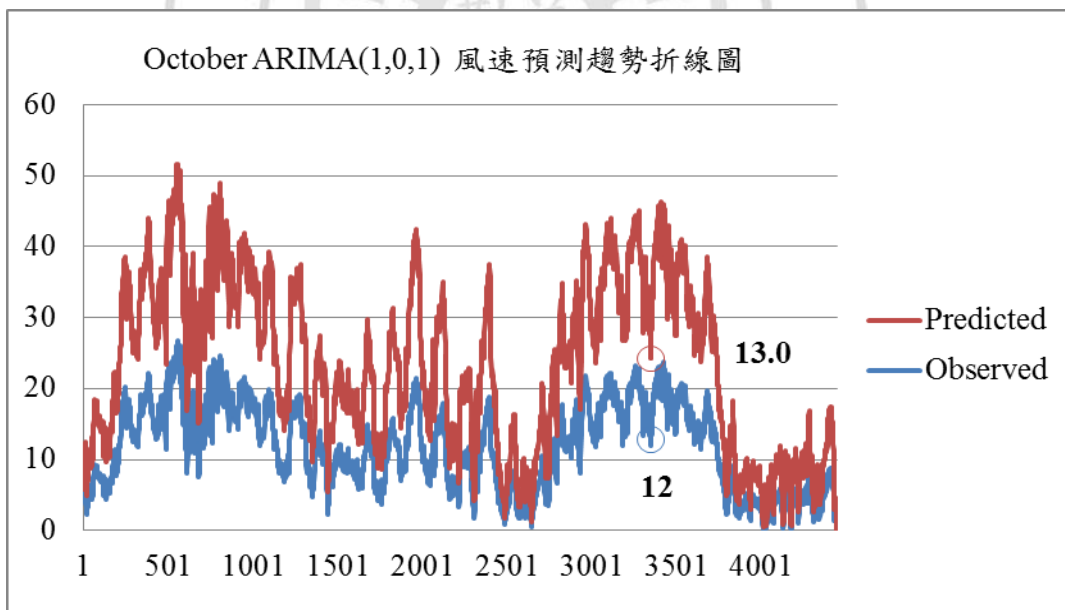


圖 10-9. October ARIMA(1,0,1) 風速預測趨勢折線圖




圖 9-10. November ARIMA(1,0,1) 風速預測折線圖




圖 10-10. November ARIMA(1,0,1) 風速預測趨勢折線圖




圖 9-11. December ARIMA(1,0,1) 風速預測折線圖




圖 10-11. December ARIMA(1,0,1) 風速預測趨勢折線圖




圖 9-12. January-December ARIMA(1,0,1) 風速預測折線圖






圖 11-1. February ANN-Ensemble 風速預測折線圖




圖 12-1. February ANN-Ensemble 風速預測趨勢折線圖




圖 11-2. March ANN-Ensemble 風速預測折線圖




圖 12-2. March ANN-Ensemble 風速預測趨勢折線圖






圖 11-3. April ANN-Ensemble 風速預測折線圖




圖 12-3. April ANN-Ensemble 風速預測趨勢折線圖




圖 11-4. May ANN-Ensemble 風速預測折線圖




圖 12-4. May ANN-Ensemble 風速預測趨勢折線圖

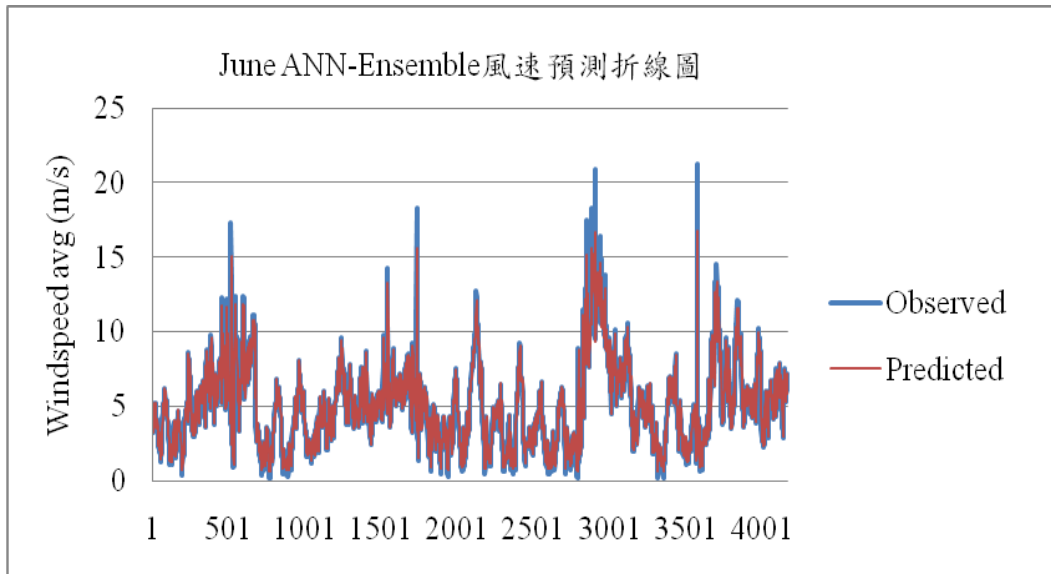


圖 11-5. June ANN-Ensemble 風速預測折線圖




圖 12-5. June ANN-Ensemble 風速預測趨勢折線圖




圖 11-6. July ANN-Ensemble 風速預測折線圖




圖 12-6. July ANN-Ensemble 風速預測趨勢折線圖




圖 11-7. August ANN-Ensemble 風速預測折線圖




圖 12-7. August ANN-Ensemble 風速預測趨勢折線圖




圖 11-8. September ANN-Ensemble 風速預測折線圖




圖 12-8. September ANN-Ensemble 風速預測趨勢折線圖




圖 11-9. October ANN-Ensemble 風速預測折線圖




圖 12-9. October ANN-Ensemble 風速預測趨勢折線圖




圖 11-10. November ANN-Ensemble 風速預測折線圖




圖 12-10. November ANN-Ensemble 風速預測趨勢折線圖






圖 11-11. December ANN-Ensemble 風速預測折線圖




圖 12-11. December ANN-Ensemble 風速預測趨勢折線圖




圖 11-12. January-December ANN-Ensemble 風速預測折線圖

