

結合離散小波轉換與深度學習技術 預測短期風速研究

江文山	國立成功大學水工試驗所研究員
賴志峰	國立成功大學水工試驗所技術師
黃國展	國立成功大學水工試驗所技術師
蔡宜秦	國立成功大學水工試驗所助理技術師
衛紀淮	交通部運輸研究所港灣技術研究中心副研究員

摘要

交通部運輸研究所港研中心將蒐集的風力資料經品管分析後，針對強風特性進行研究，並結合離散小波轉換與深度學習技術，以探討定點風力預報之基礎模型。本文藉由對風速資料的特性分析與掌握，進而嘗試建立風速短期預報的技術，並以臺中港測站 6 的過去資料為預測因子，進行臺中港測站 6 的短期風速預測。

經由離散小波轉換所得到之各模態實測風速與所建構模型訓練得到之風速比較，經過訓練後的模型可以合理的反應實測風速的變動，越低頻率的模態，訓練的結果越好，根據不同月份的預測分析結果，顯示預測模型具有穩定特性。

就預測未來某一個時間的風速而言，以高頻率取樣的資料所建置的模型，相較於以低頻率取樣，需要預測更多的步驟，且結果未必更準確。然而高頻率取樣建置的模型，優點是可以預測時間領域更細緻的資料細節。

一、風力預測方法

由於風速的變化高度複雜，為了提高預測的精準度，可能做法包括(一)建構更複雜的人工智慧網路架構；(二)結合更多的環境資訊甚至是數值天氣預報資料；(三)將複雜的風速資料拆解成數

個單純分量，各別預測再整合。本研究採用(三)的方法進行預測。

風速與海浪的時間序列內存在非穩態和非線性的自然隨機性，是沿海和海事工程應用和預測中最重要的挑戰之一。

非穩態特徵導致在序列中呈現非常態性，雙峰性，不對稱循環和非線性。為了處理非穩態性特徵，需要對輸入數據進行適當的前處理，以利後續的分析預測。

傳統上，使用傅立葉變換進行數據內不同時間或是空間尺度的區分，但是它僅以頻率分辨率執行變換，因此，失去數據中隱含的時間訊息。離散小波變換(Discrete Wavelet Transform, 以下簡稱 DWT)是一種處理數據具有多重尺度混合的解析工具，已廣泛用於許多預測應用中。然而，DWT 有一個關鍵的弱點，即抽取效應。在 DWT 的頻率分辨率轉換過程中，只有一半的小波係數會生成，另外一半會以較粗糙的分辨率進行遞歸轉換，可能導致重要信息被忽略。最大重疊離散小波變換(Maximal Overlap Discrete Wavelet Transformation, 以下簡稱 MODWT)應用非抽取小波工具，可以合理地克服重要信息被忽略的問題。小波(包括 DWT 和 MODWT)的另一個問題是，它們需要先選擇一個合適的小波母函數，目前這問題沒有明確依據可供判斷，須藉由冗長的反複試驗過程提供。

另一方面，由 Huang 等人(1998)開發的經驗模式分解(Empirical Mode

Decomposition，以下簡稱 EMD)，其分析程序可避免任何基函數或母小波，提供了依據數據本身特性所推演的自適應性。EMD 是完全數據自適應的，它使用時間局部分解方法提取突出特徵。然後，EMD 將這些重要特徵分離為代表時間序列物理結構的子序列。因此，基於 EMD 的模型亦用相關的應用在預測自然環境參數，包括 EMD 自回歸(AR)模型和 EMD 支持向量回歸(SVR)。但是，固有的“模式混合”缺點削弱了 EMD 的性能。集成經驗模式分解(Empirical Mode Decomposition，以下簡稱 EEMD)，通過將高斯雜訊添加到原始(未分解)時間序列來解決此問題，然後提取嵌入的周期性和趨勢信息。但是，EEMD 分解數據的重建並不是完全沒有雜訊。因此，為了解決雜訊問題，Torres 等學者提出具有自調適雜訊的完整集成經驗模式分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise，簡稱 CEEMDAN)。CEEMDAN 要求在每個分解階段都相繼添加高斯雜訊，因此，增加計算負擔而降低效率，所以其性能要比 EEMD 慢。為了解決以前的基於 EMD 的算法的缺點，後續的研究開發一種更新的，具有自調適雜訊改進的整體經驗模式分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise，簡稱 ICEEMDAN)。綜觀前述的發展歷程可見各種模式的發展亦趨複雜，同時效率隨之降低，但對預測結果的改善卻未顯著提升。

基於實務應用需求，考量常態作業化預測的可能性，本研究利用小波轉換進行模態分解，並配合非線性自回歸類神經網路，對各種模態建置預測模型，最後將各個模態的預測結果整合得到完整的預測風速。

2.1 離散小波轉換(Discrete Wavelet Transform)

1983 年，法國學者 Morlet 提出連續小波轉換理論，並將小波概念引入於地

震波的局部性質信號分析。小波理論的主要精神在於透過一個原型函數所產生的基底函數來對信號做多重解析度的描述與分析。

小波變換主要分成兩個大類：離散小波變換和連續小波變換。兩者的主要區別在於，連續變換在所有可能的縮放和平移上操作，而離散變換採用所有縮放和平移值的特定子集。小波的應用包括訊號不連續點的偵測、頻率鑑別、濾波與壓縮等，且是訊號處理上另一項有用的分析技術，常被用來做為各種訊號處理和工程領域上的應用。

一般數學轉換的基本原理是將訊號根據分析之需求以不同之基底函數表示之，藉由一適當函數的轉移與擴張的方式將信號分解，此一有限且具震盪性的適當函數即為小波。而小波之定義則為在某個時間區段內，波形振幅的平均值為零，其函數值之分佈是有限的，小波轉換是以一連串小波函數之放大縮小、以及平移為其基底函數，並將訊號以這些基底函數之組成表示。小波轉換能得到時間與頻率的關係，其可大略知道在某時間下，會有那些頻率範圍之訊號存在。

2.2 非線性自迴歸模式(Nonlinear Auto Regressive)

自迴歸模型是統計上一種處理時間序列的方法，根據時間序列 $y(t)$ 的過去值進行預測其未來值，這種預測模式稱為非線性自迴歸 (Nonlinear Auto Regressive，以下簡稱 NAR)，自迴歸模型被廣泛運用在經濟學、資訊學、自然現象的預測。其數學函數表示如下：

$$y(t) = f(y(t-1), \dots, y(t-d))$$

其中 $v(t+1)$: 預測在時間 $(t+1)$ 之風速值， $v(t), v(t-1), \dots, v(t-k)$: 是時間 $t, t-1, \dots, t-k$ 之風速觀測值。

2.3 人工智慧網路(Artificial Neural Network)

人工神經網絡(Artificial Neural Network, 以下簡稱 ANN)由稱為神經元的單位組成。計算能力由連接權重、網絡體系結構和訓練算法決定。人工神經網絡可以解決非線性函數逼近、數據分類、群聚分析、模擬預測和負荷預測, 資料補遺等, 近年來快速發展, 並廣泛應用於不同的科學和技術領域, 包括預測不同的環境參數, 例如太陽輻射、風速等以及功率預測。人工神經網絡基本邏輯是從數據中萃取信息以發展輸入和輸出之間的複雜關係。輸入變量乘以連接權重及其乘積, 添加偏差並通過傳遞函數傳遞以預測輸出。該網絡由架構活化函數和訓練算法決定。該架構決定了神經元之間的連接方式。在訓練期間, 將更新連接權重和偏差的值, 以達到最小的均方根誤差。ANN 主要特點是大量的平行處理、非線性輸出及利用多層結構的預測能力, 是一種基於腦與神經系統研究而啟發的資料處理技術。類神經網絡以神經元的運作去模仿生物的學習的行為, 透過數學模型的資訊處理系統, 因此可以視為特殊型式之統計迴歸。類神經網絡的優點是可以接受不同種類的變數作為輸入, 不需要了解系統的數學模型, 只要給予訓練輸入值與訓練目標值, 將可以找到輸出與輸入的相關性, 其缺點是缺乏解釋能力, 在訓練過程中無法得知要多少神經元個數、需要層數, 神經元多寡也將影響類神經網絡的準確性, 所以需要靠嘗試錯誤法(Trial and error)來決定層數和神經元個數。神經元(Neuron)為神經網絡的基本處理單位(Processing Element, PE), 也是組成隱藏層的主要元素, 利用資料不斷的學習及錯誤去修正神經元的權重 (Weight)與偏權值(Bias)以達到正確的輸出。在隱藏層的神經元輸出主要連接至下一層神經元的輸入, 下一層的神經元輸入值為上一

層的神經元輸出值的加總, 其同一層之間神經元不互相連結。

上述為單一神經元的狀況下, 要構成類神經網絡必須將神經元彼此相互連接, 藉由隱藏層中的每一個神經元, 連結其輸出與輸入, 建構起一個類神經網絡的架構, 如圖 1 所示。




圖 1 類神經網絡的架構圖

這裡可以分為輸入層(Input layer)、輸出層(Output layer)、隱藏層(Hidden layer)共三種。「層」的定義是由多個神經元組成, 各層神經元與神經元之間的連結, 可以簡化看成層與層之間的連結, 在同層內神經元互不相接。輸入層在類神經網絡架構中被視為資料輸入接受資料的一方, 用以表示網路的輸入變數, 輸入層並不納入輸入網路層數(Number of layers)的計算。輸出層(Output layer)在類神經網絡模型中視為提供資料輸出的一方, 也是模型的最後一層。隱藏層(Hidden layer)隱藏層介於輸入層與輸出層之間, 主要功能是增加類神經網絡的複雜性, 來模擬複雜的非線性關係, 該層神經元常用非線性轉換函數。目前並沒有明確的標準決定隱藏層神經元個數, 所以一般常用嘗試錯誤法(Trial and error)來決定隱藏層的神經元個數。隱藏層數的層數也和神經元個數一樣, 沒有標準方式去決定。隱藏層的層數決定了事件的複雜度, 越多隱藏層就會越複雜也越難收斂。

結合前述三種方法本研究使用的風速預測模型架構, 如圖 2 所示。




Fig. 2. Flowchart of combined approaches including data pre-processing techniques.

圖 2 風速預測模型架構圖

首先將實測風速數據，利用小波轉換分離出各種不同成份，其次各個成份分別以一組由非線性自迴歸模式與人工智慧網路所合成模型進行訓練與預測，之後將各別成份所預測的結果疊加，得到整體的預測風速。模型長時間預測的執行程序是以一定長度的資料作為模式訓練用，再根據訓練得到的模式進行數個時階預測，隨著時間演進，用以訓練的資料隨之平移，並更新預測。

二、實際案例分析

本項工作目的期藉由對風速資料的特性分析與掌握，進而嘗試建立風速短期預報的技術。初步測試以臺中港 6 號測站的過去資料為預測因子，進行臺中港測站 6 號測站的短期風速預測。圖 3 為臺中港 6 號風速站(北堤燈塔)與 7 號風速站(防風林)2020 年 1 月至 5 月份風速資料的風速風向時序列圖。

明顯可見北堤燈塔站風速較高，判斷是其外於相對接近海域，周遭環境較為開闊；相對地，防風林站位處較內陸且鄰近防風林區，受到陸地、建築物與防風林等影響，因此，出現上述風速的明顯差異。




圖 3 臺中港風速站 6、7 號測站風速風向時序列圖

圖 4 為風速發生機率分布與相關性散佈圖，其中防風林站的機率分布接近 Weibull 分布，機率分布尖峰在風速約 3m/s；而北堤燈塔站則呈現近似雙峰結構，分別在風速約 3m/s 與 12m/s 附近有機率分布尖峰，研判這與測站位置的局部特性有關。




圖 4 風速發生機率分布與相關性散佈圖

兩站的平均風速與陣風的關係如圖 5(上)，兩站平均風速與陣風的散佈圖顯示兩站約略呈線性關係，進一步定義平均風速與陣風的差異值與平均風速的比值為擾動量繪如圖 5(下)，可見擾動量隨風速增大約略逐漸收斂到一個穩定值，此穩定值在 6 號測站相對較大。




圖 5 平均風速與陣風的關係圖、擾動風速對小時平均風速的比值圖

因為離散小波轉換進行模態拆解的過程中與輸入數據量有直接的關係，為能一致性比較，因此以每個月的數據進行小波轉換模態分解後，以 15 天的資料進行模型訓練，並預測當月另外的資料。各模態的最適參數是透過參數空間的計算分析，以最小誤差的條件先初步決定。

然而各模態以最適參數進行預測，再整合各模態的預測得到整體預測結果確未必是較佳的結果，因此最終模型參數的波定尚必須輔以整體誤差作決定，以台中港 6 號測站的 2020 年 1 月份資料為例，圖 6 為小波分析得到之各模態的風速。




圖 6 小波分析得到之各模態的風速

圖 7~圖 9 分別是各模態實測風速與所建構之非線性自迴歸類神經網路模型訓練得到之風速比較，可見經過訓練後的模型可以非常吻合的反應實測風速的變動。

從頻率之角度切入來看，上述結果亦顯示通常越低頻的模態，訓練的結果越好。




圖 7 第一模態模型訓練得到之風速與實測風速比較




圖 8 第二模態模型訓練得到之風速與實測風速比較




圖 9 第三模態模型訓練得到之風速與實測風速比較

進一步以訓練後的模型預測未來的風速並與實測比較，圖 10~圖 17 為預測 1 個時階後 8 個月份各自的風速與實測風速的比較，對應的平均誤差時序列則呈現於圖 18；圖 19~26 則是預測 6 個時階後的風速與實測風速的比較，對應的平均誤差則呈現於圖 27。




圖 10 預測 1 個時階後的風速與實測風速的比較(1 月份)




圖 11 預測 1 個時階後的風速與實測風速的比較(2 月份)




圖 12 預測 1 個時階後的風速與實測風速的比較(3 月份)




圖 13 預測 1 個時階後的風速與實測風速的比較(4 月份)




圖 14 預測 1 個時階後的風速與實測風速的比較(5 月份)




圖 15 預測 1 個時階後的風速與實測風速的比較(6 月份)




圖 16 預測 1 個時階後的風速與實測風速的比較(7 月份)




圖 17 預測 1 個時階後的風速與實測風速的比較(8 月份)




圖 18 預測 1 個時階後的風速誤差 (1 月份)




圖 19 預測 6 個時階後的風速與實測風速的比較(1 月份)




圖 20 預測 6 個時階後的風速與實測風速的比較(2 月份)




圖 21 預測 6 個時階後的風速與實測風速的比較(3 月份)




圖 22 預測 6 個時階後的風速與實測風速的比較(4 月份)




圖 23 預測 6 個時階後的風速與實測風速的比較(5 月份)




圖 24 預測 6 個時階後的風速與實測風速的比較(6 月份)




圖 25 預測 6 個時階後的風速與實測風速的比較(7 月份)




圖 26 預測 6 個時階後的風速與實測風速的比較(8 月份)




圖 27 預測 6 個時階後的風速誤差 (1 月份)

從平均誤差的分布觀察，可見較大的平均誤差發生在風速快速轉折的時間，藉由調整模型參數對於此部份的改善有限。低頻模態包含風速變動的主要趨勢，時間上的變動較為緩和，短時間的預測相對較為準確。另外，週期性較不明顯，較缺乏規則性，所以長時間的預測可能出現未掌握到變動趨勢而產生較大誤差。至於高頻模態主要呈現一定振幅範圍內的正負跳動，其變動速率快，不易精準掌握，是短時間預測誤差的主要來源，但是因數據變動侷限在一定範圍，預測產生的誤差並不會隨時間顯著增大。




圖 28 不同預測時階風速誤差百分比的分佈(10 分鐘間距)




圖 29 不同預測時階風速誤差百分比的分佈(1 小時間距)

圖 28~29 為不同預測時階對應之風速平均誤差累積百分比的分佈，可見累積平均誤差百分比隨著平均誤差增大而減少，同時隨著預測時階增加而增大。設定風速平均誤差 1m/s 為指標，以高頻率(10 分鐘間距)取樣的數據進行不同預測時階風速平均誤差大於 1m/s 的百分比繪如圖 30。




圖 30 不同預測時階風速平均誤差大於 1m/s 的百分比(10 分鐘間距)

顯示誤差在約略前 10 個時階內快速由接近零增大到約 40%，之後維持幾乎固定的數值。

另以低頻率(1 小時間距)取樣的數據進行不同預測時階風速平均誤差大於 1m/s 的百分比繪如圖 31。




圖 31 不同預測時階風速平均誤差大於 1m/s 的百分比(1 小時間距)

每個月的誤差數值雖然略有不同，但是分布型態是幾乎一致，說明預測模型的表現具有穩定特性。

統計各月份的預測風速誤差統計如表 1~2，預測 1 個時階(10 分鐘)後的平均誤差約介於 0.30~0.35 m/s，預測 6 個時階(1 小時)後的平均誤差約介於 0.60~0.90 m/s。

表 1 各月份預測風速誤差統計(10 分鐘間距、預測 6 時階)

月份	預測時階	風速誤差 (m/s) 50%	風速誤差 (m/s) 90%	風速誤差 (m/s) 95%
1	6	0.0199	0.0527	0.0661
2	6	0.0338	0.0742	0.0855
3	6	0.0345	0.0779	0.0898
4	6	0.0221	0.0663	0.0754
5	6	0.0191	0.0387	0.0443
6	6	0.0060	0.0173	0.0220
7	6	0.0056	0.0168	0.0190
8	6	0.0141	0.0368	0.0448

表 2 各月份預測風速誤差統計(10 分鐘間距、預測 12 時階)

月份	預測時階	風速誤差 (m/s) 50%	風速誤差 (m/s) 90%	風速誤差 (m/s) 95%
1	12	0.0195	0.0519	0.0651
2	12	0.0332	0.0730	0.0841
3	12	0.0339	0.0767	0.088
4	12	0.0218	0.0652	0.0743
5	12	0.0188	0.0380	0.0434
6	12	0.0059	0.0170	0.0216
7	12	0.0056	0.0165	0.0187
8	12	0.0139	0.0362	0.0441

表 3 各月份預測風速誤差統計(10 分鐘間距、預測 18 時階)

月份	預測時階	風速誤差 (m/s) 50%	風速誤差 (m/s) 90%	風速誤差 (m/s) 95%
1	18	0.0193	0.0518	0.0651
2	18	0.0332	0.0729	0.0840
3	18	0.0339	0.0767	0.0885
4	18	0.0217	0.0652	0.0743
5	18	0.0188	0.0380	0.0432
6	18	0.0059	0.0170	0.0215
7	18	0.0055	0.0165	0.0186
8	18	0.0139	0.0362	0.0441

表 4 各月份預測風速誤差統計(1 小時間距、預測 1 時階)

月份	預測時階	誤差 (m/s) 50%	誤差 (m/s) 90%	誤差 (m/s) 95%
1	1	0.1616	0.3251	0.3584
2	1	0.2825	0.5841	0.6575
3	1	0.2283	0.4755	0.5669
4	1	0.1426	0.5232	0.5801
5	1	0.1387	0.2933	0.3367
6	1	0.0387	0.0923	0.1144
7	1	0.0336	0.0902	0.1062
8	1	0.0798	0.2093	0.2672

表 5 各月份預測風速誤差統計(1 小時間距、預測 2 時階)

月份	預測時階	風速 誤差 (m/s) 50%	風速 誤差 (m/s) 90%	風速 誤差 (m/s) 95%
1	2	0.1073	0.2162	0.2376
2	2	0.1894	0.3910	0.4394
3	2	0.1515	0.3186	0.3769
4	2	0.1139	0.3478	0.3855
5	2	0.0919	0.1936	0.2169
6	2	0.0260	0.0612	0.0762
7	2	0.0225	0.0606	0.0699
8	2	0.0534	0.1389	0.1795

表 6 各月份預測風速誤差統計(1 小時間距、預測 3 時階)

月份	預測時階	風速 誤差 (m/s) 50%	風速 誤差 (m/s) 90%	風速 誤差 (m/s) 95%
1	3	0.1430	0.2883	0.3168
2	3	0.2526	0.5213	0.5858
3	3	0.2020	0.4247	0.5025
4	3	0.1292	0.4638	0.5140
5	3	0.1205	0.2428	0.2720
6	3	0.0346	0.0816	0.1015
7	3	0.0301	0.0809	0.0933
8	3	0.0712	0.1852	0.2393

嘗試以不同取樣頻率所得的資料，進行預測比較顯示模式中並未包含確切時間的資訊，純粹是就資料的序列預測之後

數個步階會出現的數據，因此就預測未來某一個時間的數據而言，以高頻率取樣的資料所建置的模型，相較於以低頻率取樣的資料所建置的模型，需要預測更多的步階，結果未必較準確。然而高頻率取樣建置的模型，優點是可以預測時間領域更細緻的資料細節。

三、結論與建議

本研究結合離散小波轉換與深度學習的技術，針對臺中港風速測站的資料，發展一個定點短期風速預測的基礎模型。經由離散小波轉換所得之各模態實測風速與所建構模型訓練得到之風速比較，可見經過訓練後的模型可以合理的反應實測風速的變動，而通常越低頻的模態，訓練的結果越好，且預測模型的表現根據不同月份的預測誤差分析結果具有穩定特性。

就預測未來某一個時間的數據而言，以高頻率取樣的資料所建置的模型，相較於以低頻率取樣的資料所建置的模型，需要預測更多的步階，結果未必較準確。然而高頻率取樣建置的模型，優點是可以預測時間領域更細緻的資料細節。

低頻模態與高頻模態都各有其優缺點，不同時階之誤差程度也不一，本研究之成果可應用於實際防災需求，惟須考慮可能之誤差值，並配合適宜之管理方法，以達防災之需求。

參考文獻

1. Huang., Shengzhi., et al., "Monthly streamflow prediction using modified EMD-based support vector machine", Journal of Hydrology 511, 2014, pp. 764-775.
2. Morlet., Jean., "Sampling theory and wave propagation", Issues in acoustic Signal—image processing and recognition, 1983, pp 233-261.

3. Norden E., Huang., et al.,“The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis.”, Proc. R. Soc. Lond. A, 1998, pp 903–995.
4. Zhaohua Wu and Norden E. Huang., “Ensemble Empirical Mode Decomposition: A Noise-Assisted Data Analysis Method”, Advances in Adaptive Data Analysis, Vol. 1, 2009, pp 1–41.
5. Torres ME., Colominas MA., Schlotthauer G., Flandrin P.,“A complete ensemble empirical mode decomposition with adaptive noise”, International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2011, pp 4144–4147.
6. Colominas., Marcelo A., Gastón Schlotthauer and María E. Torres.,“Improved complete ensemble EMD: A suitable tool for biomedical signal processing”, Biomedical Signal Processing and Control, 2014, pp 19-29.