颱風侵臺期間各民航機場風場評估方法演進

徐光前　陳心懋　童茂祥[1]

摘要

臺灣地形複雜，各民航機場風場受地形影響甚巨，當颱風侵臺時，風場預報難度頗大，如何準確地預報颱風侵臺期間的各民航機場風場，一直是臺北航空氣象中心(以下簡稱氣象中心)的重點業務；從早期概略的統計結果與氣象模式的發展(從 MM5 升級至 WRF)，到「侵臺颱風對各民航機場的風場統計」程式的開發應用，也將類神經網路方法應用在風場預報上。然而，無論預報工具如何演變，預報最重要的核心價值仍是在「人」，因此預報工具可以使用、參考，但不能盡信。

一、前言

中央氣象局（以下簡稱氣象局）曾利用多年在颱風侵襲期間的各地測站資料，仔細統計分析颱風和各測站之間的流場分布與颱風位置之關係，建立八種西行且侵襲臺灣的颱風有關其流場類型與程序，並作多方驗證分析，結果證明在侵臺颱風的風力強度預報分析上，有其專業的參考價值。而在實際氣象預報作業應用上，預報員可以從颱風與臺灣的相對位置、颱風模式預報路徑與颱風本身的環流強度中，套用此流場模型以供預報員在作專業判斷上之參考。但是氣象局的概括性的區域統計，並不符合民航氣象作業的需求，亦無法提供給各家航空公司作其營運參考方針。

各民航機場於颱風侵臺期間之風場評估一直是氣象中心颱風作業重點，從早期的經驗模式預報到各民航機場於颱風侵臺期間的風場統計程式的撰寫，甚至目前正在嘗試的類神經網路於風場估計上的應用，均顯示氣象中心不斷地在思考將各機場的風場預報的更準確，以下簡要回顧這些風場預報方法的特質與演替。

[1]臺北航空氣象中心

二、早期的風場評估方式

早期在各民航機場於颱風期間的風場評估上，資深同事的經驗傳承佔了相當重要的一部份，如當颱風直撲臺灣而來的時候，北部機場風場最大時機可能是發生在颱風登陸前後三小時內；當颱風從東部海面北上的時候，松山機場會先為東風，再轉北風，最後轉成西北風，當轉成北風的時候，受北面大屯山系阻擋，風速較弱，風向較不定；當西進的颱風中心通過東經 124 度時，北部機場才開始會起風；當颱風移向西北，且中心從臺灣東北角海岸經過時，桃園機場出現西北風的可能性較低，機場會以東北風為主等等。對於各機場的風向，預報員可以根據颱風中心與各民航機場的相對位置作預報，但對於風速而言，所能參考的資料較少，預報難度比風向更高，再加上颱風中心位置預報誤差較大，風場變化時間點的預報就更難以掌握。

那早期是如何評估各民航機場的風場呢？第一種方法是參考風場統計資料，圖 1 是強烈颱風中心位置與松山機場風速之相關圖，表示強烈颱風中心位置在不同的地方，對松山機場風速變化的影響，當時在使用這一張統計圖時，有幾個顯而易見的缺點：(1)圖上只有風速的資訊，卻沒有風向的參考資料、(2)只有針對松山機場、高雄機場作統計，其它機場沒有類似的參考圖、(3)只分強烈颱風、中度颱風、輕度颱風，在分類上過於簡單、(4)統計資料並沒有持續更新。

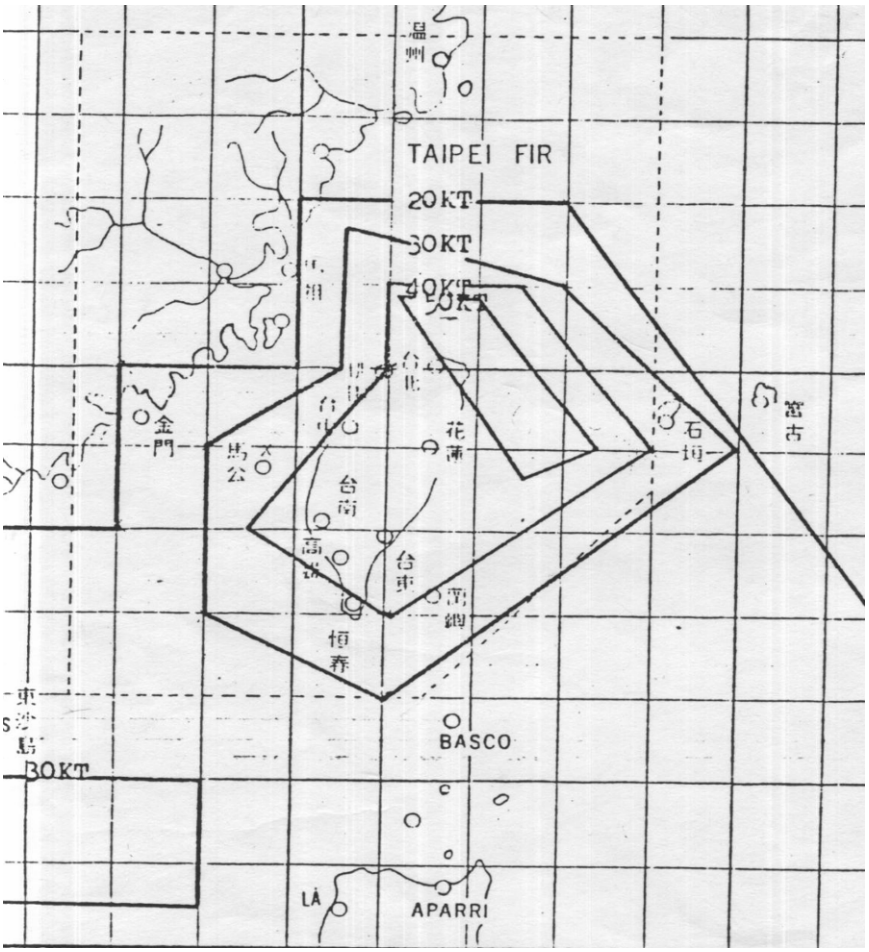

圖 1：強烈颱風中心位置與松山機場風速之相關圖。

第二種方法是參考氣象模式資料，但是日本氣象數值模式時間間距為 12 小時，當時氣象中心的氣象模式(MM5)時間間距是 6 小時，對於風場轉換而言，時間解析度是不夠的。此外，所有的氣象模式都有一個很重要的問題，就是對於像颱風這類的劇烈天氣是沒有辦法完美地模擬，模擬的結果不是颱風強度與實際不符，要不然就是颱風中心位置誤差太大，其參考價值降低。舉例來說，圖 2A 是 2011 年 5 月 10 日 1500Z 的艾利颱風，天氣研究預報模式(WRF)對於艾利颱風位置的模擬結果相當準確，但在颱風強度上卻明顯地過度預報，造成環流風場預報過強；圖 2B 是 2010 年 09 年 01 日的萊羅克颱風，颱風的中心位置應在高雄外海，但模擬出的颱風中心位置卻在東部外海，因此各機場的風場變化模擬幾乎沒有參考價值。

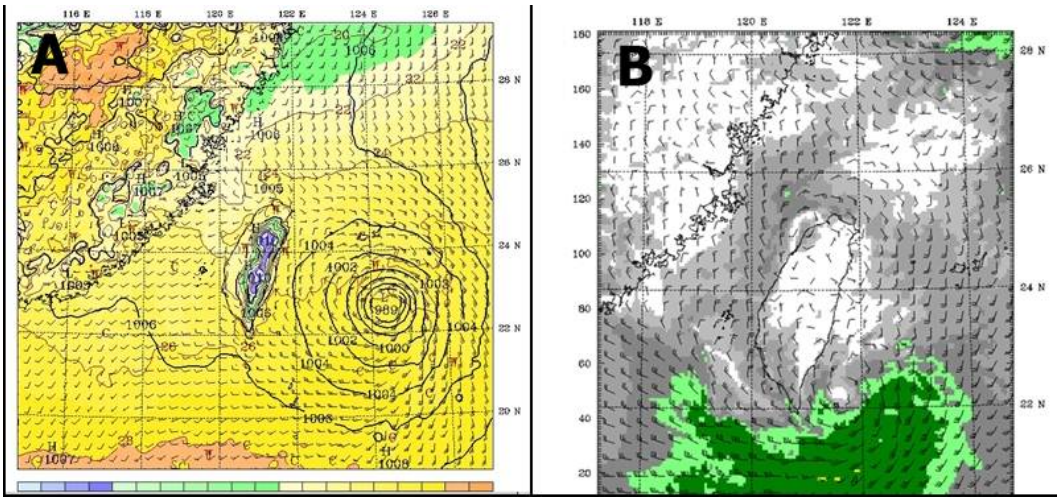

圖 2：(A)2011 年 5 月 10 日 1500Z 艾莉颱風模擬，中心位置正確，但強度過強;(B)2010 年 09 月 01 日萊羅克颱風模擬,颱風位置應在高雄外海，卻模擬至臺東外海。

三、風力統計分析程式

早期的參考工具並不多元，而且有明顯的缺陷，因此資深預報員的經驗傳承就變得相當重要，但在氣象的經驗分享上，若沒有實際的天氣個案輔助是很難表達清楚；再者每位資深預報員自己的預報方法與經驗，並沒有經過系列行的統合整理，因此當資淺預報員在接受經驗分享的時候，就顯得凌亂而紛雜。氣象中心研發團隊自 2008 年就在探索如何建立一套客觀風場評估方法，來協助預報員進行各機場的風場變化預報，而「侵臺颱風對各民航機場的風場統計」程式便是在這一構想推動出來。

圖 3 是資料處理流程圖，1996 年(民國 85 年)之前的颱風資料是每六小時一筆，而在 1997 年(民國 86 年)之後則改為每三小時一筆，但是氣象中心的例行天氣報告(METAR)則是每半個小時觀測及發報一次，因此顯然雙方的觀測資料密度是有明顯地落差，為了要提昇颱風資料的觀測密度以增加符合的有效個案數目，因此，在假設颱風於每六小時(或三小時)的觀測期間內，並沒有迅速變化的前提之下，將颱風資料包含颱風路徑、颱風中心氣壓、颱風風向、風速等線性內插成逐時的觀測資料，並利用前後的颱風位

置計算颱風的移動方向。

當把颱風資料前處理(線性內插成逐時觀測資料)完畢之後，以颱風的經緯度、中心氣壓值、平均風速與移動方向等五項當作過濾因子，在一定可接受的範圍之內，即可以得到符合條件的「逐時」颱風觀測資料。這五項篩選項目都可以由預報員自行決定可接受範圍，如果可接受範圍越嚴謹的話，搜尋的結果雖然較具代表性，但同樣地也可能面臨到有效個案數目偏少的問題；如果範圍越寬鬆的話，也有可能將一些較不具代表性的個數選入而間接影響到之後的統計分析結果；綜合言之，這套程式的「可接受範圍」保留了主觀判定的精神。

經過程式的計算比對，篩選出「逐時」且符合條件的颱風資料之後，其資料與氣象中心航空氣象觀測臺的例行天氣報告兩者之間的唯一共通點就是「時間」。利用「時間」為兩種資料的橋樑，便可以找出相對應的例行天氣報告，並且加以統計分析。為了增加統計分析的母群體數量，當找出相對應的例行天氣報告之後，在其觀測時間前後各 15 分鐘內所發布的特別天氣報告(SPECI)，便一同視為有效個案而納入統計分析之中。

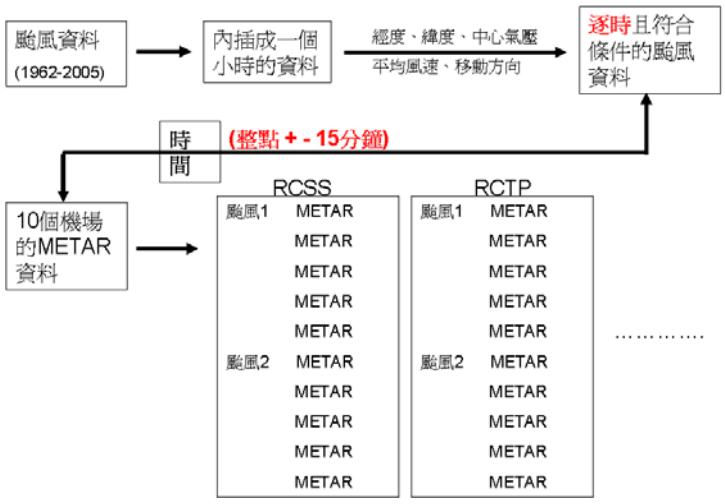

圖 3：「侵臺颱風對各民航機場的風場統計」資料處理流程圖

程式的執行結果如圖 4 所示，圖 4A 是風向示意圖；圖 4B 是各級距平均風速發生的頻率；圖 4C 是各級距風向發生的頻率；圖 4D 是陣風分布示

意圖，從這四張圖可以讓預報員充份地了解到，在所設定的過濾因子下颱風對各民航機場的風場影響。以圖 4 為例，當颱風中心位置在北緯 25.5 度、東經 123.0 度，中心氣壓為 950 百帕，中心最大平均風速為 70 浬，颱風向西北方移動時，桃園機場的風向以北北西風為主，平均風速發生頻率最高於 10-25 浬，但 25-40 浬亦有發生的機會，而陣風比平均風速約增加 10-15 浬左右。

此外，若欲了解 6 小時、12 小時後颱風對各民航機場的影響，預報員需先預判 6 小時、12 小時後的颱風狀況(如颱風中心位置、強度與最大平均風速等等)，再經由「侵臺颱風對各民航機場的風場統計」得到未來各民航機場的風場，預報員就可以評估未來颱風對各民航機場的影響，在風場變化的時間點與趨勢掌握上，預報員有較明確的量化數據可供參考，而經實際颱風作業測試，各航空公司均對各民航機場的風場預報表示滿意。

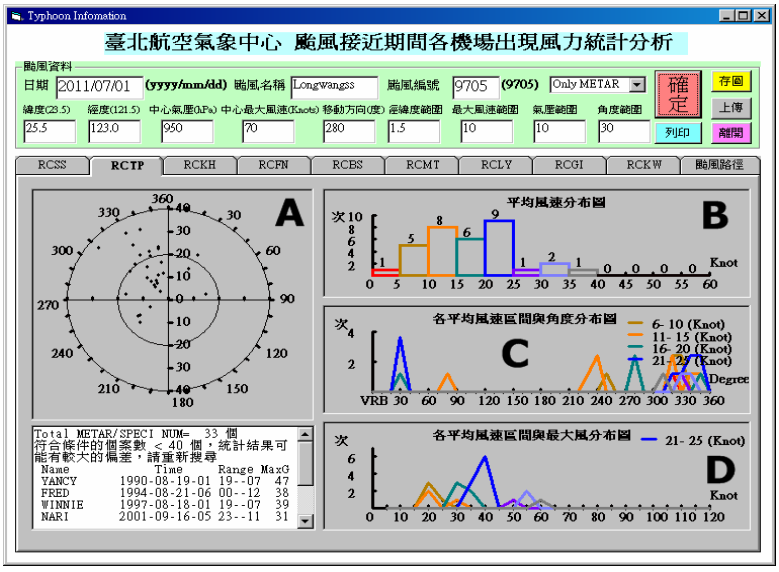

圖 4：「侵臺颱風對各民航機場的風場統計」示意圖

四、類神經網路的應用

上一節所陳述的「侵臺颱風對各民航機場的風場統計」程式，確實能夠解決經驗傳承所造成紛雜的問題，並且從定性分析轉變成為定量分析，讓預報員在預報各民航機場風場變化時有所依憑。但在經過這幾年實際上

線操作之後，氣象中心研發團隊仍覺得有改善空間。

以圖 4B 的平均風速分布圖為例，在過去 43 年的颱風資料，當颱風在上述的過濾條件之下，桃園機場雖然平均風速 10-25 浬有較大的發生頻率，但預報員卻不能斷定此次最大平均風速依然會發生在此級距；然而，平均風速 25-40 浬發生頻率雖小，過去亦仍有發生的案例，因此這一情境下，預報員無法判斷目前的颱風狀況，到底是那一個級距才是符合，而必須透過更多的佐證、參考資料，經過仔細推敲之後，才能作最終的決定。如何提供預報員一個更明確的量化風場數值。是研發團隊新的挑戰。

生物的神經元可在不斷刺激與反應的過程中學習，在 Watanabe et al.(1995)的著名實驗中可以略知一二。Watanabe 將一隻鴿子裝在斯金納箱中，並給鴿子看兩種截然不同畫風的大師畫作(畢卡索與莫內)，當鴿子選擇特定大師畫作時(如畢卡索)而啄了箱子上的開關時，就會給予食物當作獎勵，經過一連中的實驗後，鴿子對已看過的畫作正確率達 90%以上，對未看過的畫作，正確率達 85%以上，顯示鴿子能從過去經驗中得到某種「型態」或「規則」，並從未見識過的畫作中分辨出來，這就是動物神經網路的專長與特色。而氣象上的類神經網路正是要模仿動物神經元在刺激與反應之間的連結而發展出來的，研發團隊認為可以嘗試著用類神經網路來解決上述的問題。

圖 5 是類神經網路的示意圖，分為輸入層、輸出層與隱藏層。輸入層輸入相關的颱風資料，如颱風中心的經緯度、中心氣壓、最大平均風速、最大陣風等等；輸出層輸出各民航機場的風場；而隱藏層將連結輸入層與輸出層，是類神經網路最重要的地方。一般來說隱藏層可以有數層，而每一層有數個神經元，代表著動物神經網絡的特色；輸入層、隱藏層與輸出層之間，有無數連結連接三層。

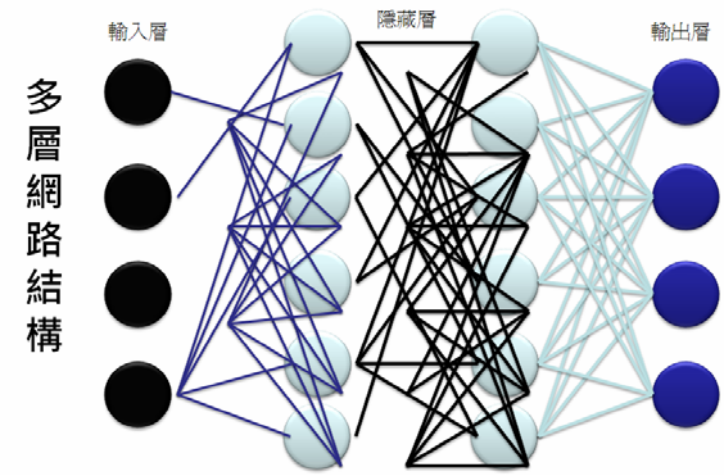

圖 5：類神經網路示意圖

當於輸入層輸入颱風資料後，經過隱藏層的運算，會於輸出層得到各民航機場的風場猜測值，當猜測值與實際值誤差過大時，便會反饋給隱藏層調整各層各神經元的權重，如此反覆進行而降低猜測值與實際值的誤差。這個過程稱為類神經網路的訓練過程，主要的目的是要調整隱藏層各層各神經元的權重，使誤差達到最小，當訓練完成後，各個神經元的權重就被決定。此外，當隱藏層層數越多，各層的神經元數目越多，所需要的訓練時間就越長；對於改進的空間而言，隱藏層與神經元數目都有一定的極限，當超過此極限後，改進的空間與花費的訓練時間不成比例，因此隱藏層與神經元數目並非越多越好。

由於各氣象臺所記錄資料年代長度不同，因此類神經網路的訓練年限亦有長有短；以松山機場為例，氣象中心利用 1962 年至 2008 共 46 年的資料作訓練，得到隱藏層各神經元的權重後，利用 2009 年的資料作校驗(猜測值-實際值)，負值表示猜測值低估，正值表示高估，風速的校驗結果如圖 6 所示。圖 6A 表示各誤差的比例，圖 6B 表示各誤差的個案數，當顏色越亮，表示所佔比例越高，個案數越多，亦越有信心度。圖 6 中較亮的部份多集中於 0 至-10 浬之間，顯示用類神經網路所得到的猜測值有風速低估的現象。比如金門、松山機場誤差較為集中，就可以直接調整，但是桃園、高

雄機場誤差較為分散，便無法直接調整，因此氣象中心必須再克服如何有效調整隱藏層的設定，或是是否有其它方法解決此一問題。

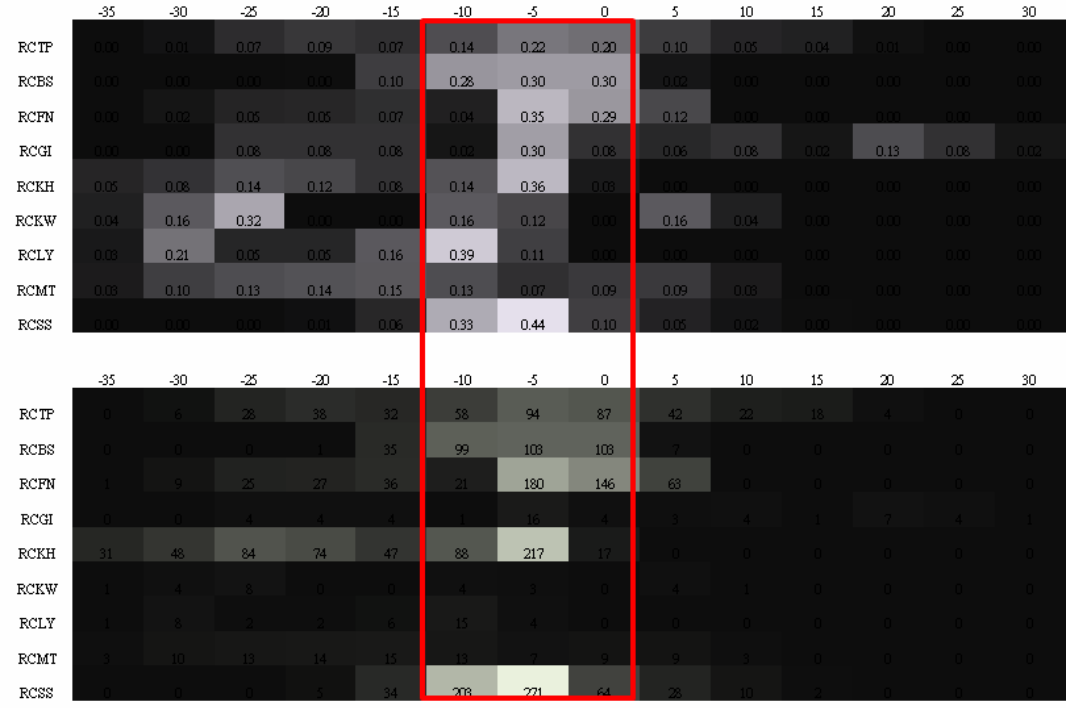

五、結論

颱風作業一直是臺北航空氣象中心重要的工作項目之一，而颱風侵臺期間各民航機場的風場變化又是各航空公司的重點關注項目，如何將風場預報準確，一直是氣象中心所努力的工作，從早期簡略的統計結果與氣象模式(MM5)，至「侵臺颱風對各民航機場的風場統計」程式的設計，最後將類神經網路應用在風場預報上，都顯示氣象中心在思索如何改善各民航機場的風場預報。當然，無論是「侵臺颱風對各民航機場的風場統計」程式或是類神經網路，都只是氣象預報的參考工具而已，而類神經網路只能模仿人的思考，但不能替代人思考，所以預報的工作核心價值仍是在「人」，預報員仍需本持著自己的專業，不能盡信工具。

此外，隨著科技的日新月異，大氣科學的研究亦迎向另一個嶄新的局面，在學校、研究所所學的知識，如何與職場上的作業相輔相成，是一個要認真、嚴肅思考的方向；再者，地球暖化議題不斷地發燒，氣候變遷的

結果是面臨更難以捉摸的颱風，在飛航安全的前題之下，如何兼顧航空公司的營運效率是氣象中心一直在思考的。各民航機場的風場評估方法在最近幾年有很大的變化，同仁不斷地提出新的方法，不斷地在作業上嘗試，期能更精進各民航機場於颱風期間的風力預報，類神經網路的應用只是一個開端，中心期待同仁給予更多的回饋，也期待更多精進的方法能夠被提出且嘗試應用在作業上。

參考資料

童茂祥、徐光前，2008：侵臺颱風對各民航機場的風場統計與分析，交通部民用航空局自行研究計畫。

Bergot, T., Carrer, D., Noilhan, J., and Bougeault, P., 2005: Improved Site-specific Numerical Prediction of Fog and Low Clouds: a Feasibility Study, Weather and Forecasting, 20, 627-646.

Demuth, H., and M. Beale, 2001: Neural Network Toolbox: For Use with MATLAB. 4th ed. The MathWorks, 844 pp.

Fabbian, D., de Dear, R., Lellyett, S., 2006: Application of Artificial Neural Network Forecast to Predict Fog at Canberra International Airport. Wea. Forecasting, 22, 372–381.

Hall, T., H. E. Brooks, and C. A. Doswell III, 1999: Precipitation forecasting using a neural network. Wea. Forecasting, 14, 338–345.

Marzban, and G. J. Stumpf, 1996: A neural network for tornado prediction based on Doppler radar–derived attributes. J. Appl. Meteor., 35, 617–626

Nugroho, A. , Kuroyanagi, S., Iwata, A., 2002: A Solution for Imbalanced Training Sets Problem by CombNET-II and Its Application on Fog Forecasting. IEICE Trans Inf Syst, E85-D.7, 1165-1174.

Pasini, A., V. Pelino, and S. Potestà, 2001: A neural network model for visibility nowcasting from surface observations: Results and sensitivity to physical input variables. J. Geo-phys. Res., 106, 14 951–14 959.

Tasadduq, I., S. Rehman, and K. Bubshait, 2002: Application of neural networks for the prediction of hourly mean surface temperature in Saudi Arabia. Renewable Energy, 25, 545–554.

Tseng, and Chan, 2008: 利用倒傳遞類神經網路模式預測臺灣成霧現象之研究. CWB97-1A-16 研究發展專題.