

卷積神經網路應用於單都卜勒風場反演

劉正欽¹ 張保亮¹ 洪景山¹ 方偉庭²
¹氣象資訊中心 ²氣象衛星中心
中央氣象局

摘要

由於雷達只能觀測到雷達波束方向上降水粒子的速度分量，使得都卜勒速度的應用受到限制，利用都卜勒速度場的分布特徵所開發之反演方法，可提供天氣系統之環流特徵，但在應用上仍有其侷限性。近年深度學習中的卷積神經網路(Convolutional Neural Network, CNN)技術在圖形辨識已相當成熟，大氣科學界亦有使用深度學習技術建立反演模型之先例，本研究嘗試利用CNN術發展單都卜勒風場反演模型，使用數值天氣模式之預報風場作為訓練與測試資料，以評估風場反演模型之可行性。由初步評估顯示，利用均勻之風場進行訓練與測試，其反演的結果均有不錯的表現，但對於水平風場變動較大之個案，其不確定會隨之提高。未來本研究將逐步增加資料的多樣性及複雜性，以提高風場反演模型之反演準確度，並實際應用於都卜勒雷達之觀測資料中。

關鍵字：都卜勒速度、深度學習、卷積神經網路(CNN)、風場反演

一、前言

風是一項重要的天氣要素，除了透由氣象觀測站之觀測儀器可以得知風的資料外，隨著科技的進步，雷達亦可以提供風的資訊。單一都卜勒雷達能得到的資訊為回波與平行於電磁波束的徑向投影風場，為了獲取並了解垂直及水平(三維)風場資訊，更運用兩座雷達會同時觀測相同區域之特性，將同時觀測相同區域徑向風場進行合成分析，但此方法有許多限制，如：建置雷達耗費甚鉅、兩座雷達觀測不一定會有相同區域、雷達觀測距離之限制等因素。為此，雷達氣象學家運用數學方法針對有限的資料發展多樣單雷達反演技術，如 Lhermittle and Atlas (1961) 應用單都卜勒雷達以一個固定仰角沿各方位角旋轉一圈，並選定一固定之徑向距離，以便推得徑向風速和方位角之關係，進而估算不同高度的水平風向及風速。有針對天氣系統為颱風發展的反演方法，如 Lee et al.(1999)提出的 GBVTD(Ground – Based Velocity Track Display)方法，颱風環流風場有近似軸對稱的特性，在幾何的概念下，可將雷達觀測之徑向速度以傅利葉級數展開，可進而求取颱風的軸對稱、非軸對稱切向風場及軸對稱的徑向風場。利用不同的反演技術對應不同的天氣型態，主要能夠應用於天氣現象的推斷及天氣的預報，由此，可知反演的重要性與其價值。

近年人工智慧(Artificial Intelligence, AI)願景是世界關注的焦點之一，再加上應用演算法的門檻降低、

硬體資源加速提升及開源社群的強力推動，讓各個領域不得忽視人工智慧可能對於當領域的衝擊，開始嘗試使用達成人工智慧願景的技術(例：機器學習)，進行實驗性的工作並規畫如何實際落地。大氣科學界不落人後，近兩年有部分研討會是專門探討人工智慧於大氣科學領域之應用，如美國國家海洋暨大氣總署(National Oceanic and Atmospheric Administration, NOAA)舉辦的 Workshop on Leveraging AI in the Exploitation of Satellite Earth Observations and Numerical Weather Prediction，Boukabara et al. (2019)將重點節錄，明確闡述 AI 應用於大氣科學領域的現況、未來及挑戰，其中提到「反演」也是其中一項應用。而過往已經有應用機器學習中的淺層學習進行風速的反演(Krasnopolsky et al., 1995)及單都卜勒風場反演(Li et al., 2015; Li et al., 2017)。這代表利用機器學習進行風場反演有其可行性，而從淺層機器學習技術至深度學習技術進行風場反演是一項新的嘗試，不僅對於硬體資源的測試有其幫助，並可評估深度學習在風場反演的極限。而深度學習有多種技術，如深度網路(Deep Neural Network, DNN)，本研究先選用深度學習的卷積神經網路(Convolutional Neural Network, CNN)，主要是卷積神經網路於圖形辨識已趨於成熟，有多項在圖形辨識中的發表成就(Ioffe and Szegedy, 2015; He et al., 2016)，而都卜勒風場反演有類似圖形辨識的概念，評估之後，嘗試發展單都卜勒風場反演模型。

二、資料及方法

進行機器學習相關研究，其中一項重點是資料的選用及處理。本研究為嘗試性的研究，為了避免處理雷達觀測資料之複雜程序，並提升 CNN 應用於單都卜勒風場反演之評估效率，因此不使用雷達實際觀測之單都卜勒風場，亦即代表要創建資料。如圖 1 所示，實線方框內的步驟即創建資料樣本的過程，運用(1)數值天氣預報模式可輸出 u 風及 v 風之功能及(2)模擬雷達觀測之單都卜勒雷達風場推估方程式，兩者搭配後，可創建以模擬雷達為觀測角度的單都卜勒風場。運用這樣的方式有其益處，其一是先可不考慮資料有缺測或品質不佳的狀況，其二是資料有其多樣性，有較多樣風向風速(天氣系統)可以做為學習對象，因此，對於資料的選用與處理而言，僅剩下如何分配資料進入模型訓練階段的策略擬定。圖 1 使用的數值天氣模式解析度為 1 公里*1 公里，模擬雷達擺放位置的經度及緯度分別為 121 度及 25 度，座標為卡氏座標，亦為本研究之基本設計。

對於資料有一定掌握後，建立反演模型的概念相對簡單，如圖 1 虛線方框中所示，本研究建立反演模型的方法概念為取單都卜勒風場一視窗區域(視窗維度可調整)，將此視窗區域能夠提供的資料(如：單都卜勒風速、高度、相對雷達位置等，數學上可視為自變數 x)與對應的答案(如： u 及 v ，數學上可視為因變數 y)讓機器學習並建立一個模型(選用一種演算法並透過迭代或格點搜尋調整演算法之參數，數學上可視為映射方程式 $F()$)。

本研究選用建立模型的演算法為 CNN，常用於電腦視覺辨識的深度學習模型。深度學習模型的基本架構即為神經網路，神經網路的架構基本上可以簡單分為輸入層、隱藏層及輸出層，但輸入層所輸入的資料可以先進行不同的處理，隱藏層也可以加入不同的元素，故除了 CNN 之外，還會有其它延伸的神經網路架構。

對於 CNN 而言，最主要的特性在於輸入層之後的連接層為卷積層(convolution layer)及池化層(Pooling layer，池化層不一定需要)，卷積層代表資料進行卷積運算，此卷積運算後的資訊可代表單位資料與單位資料間的空間資訊(但並非相對位置資訊)，而池化層的目的是將卷積後的資訊進行萃取(減

少維度且保留特徵)、同時將參數量下降(提升模型訓練效率)及降低模型過度擬合(over fitting)現象。卷積層及池化層可以有層數的設定，端看模型要如建立。圖 2 為 CNN 網路架構示意圖，建立了兩層卷積層及一層池化層，從示意圖可以觀察一項重點，原始 2 維資料經過卷積或池化層之後產生的特徵圖皆有原始資料的特徵存在，但經過多次的卷積運算及池化後，人眼會無法辨識特徵圖與原始資料的相似性，就交由電腦學習了。由此可以得知 CNN 主要的精神是由原始資料產生多樣特徵圖，透由這些特徵圖找到原始圖形可能的答案。

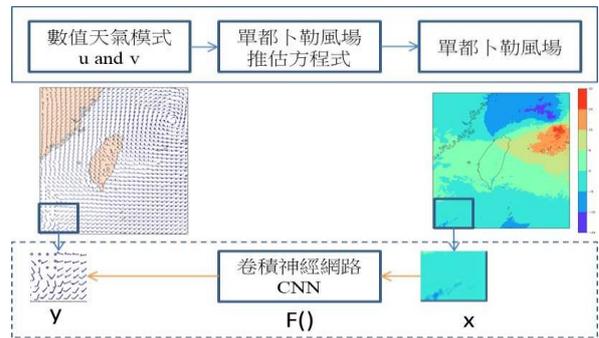


圖 1 創建資料流程及模型建立之概念圖

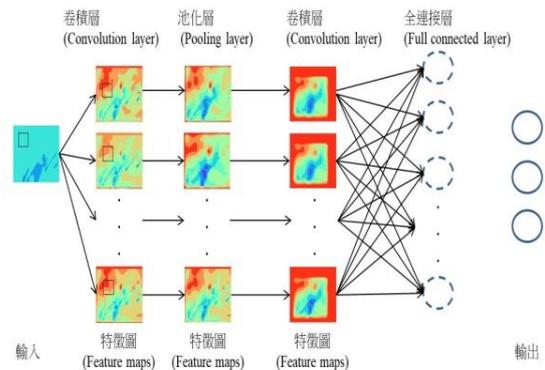


圖 2 CNN 網路架構示意圖

三、實驗設計

進行深度學習建模之前，對於資料的詮釋及如何評估成功可能性的策略相當重要。因此，先由較單純的風場進行測試，此處定義的較單純主要為雷達觀測的風場不受地形遮蔽影響(即沒有缺失值)及風向風速大致穩定。本研究將數值天氣模式的 u 及 v 透過方程式轉換為單都卜勒風場(可參考圖 1 說明)，這代表風場資料是 3 維資料，以垂直方向的維度而

言，總共設定 60 層，每一層的高度間距為 250 公尺 (第一層為 250 公尺)，而實際每一層水平維度為 433*388(如圖 3(a))。

本研究實驗設計如表 1，根據要選擇較單純風場測試的前提下，先選用 4750 公尺高度(即垂直層第 19 層)做為測試高度。資料長度選用 2020 年 5 月 13 日至 5 月 24 日共 12 天，每 1 天共有 12 小時的資料可以使用。5 月 13 日至 5 月 23 日共 11 日資料應用於模型訓練，5 月 24 日應用於模型測試。

對於訓練資料而言，每一項實驗的訓練資料的取得方式皆相同，以實驗 1 為例，5*5 的視窗大小條件下，會類似拼接的方式移動 5 個格點，每個視窗皆不會重疊，如圖 3(b)虛線方框所示，故 1 個都卜勒風場在 5*5 的視窗大小下，會有 86*77 筆訓練資料，綜整 11 天共有 862,752 筆訓練資料，至於實驗 2 及實驗 3 視窗大小 11*11 即移動 11 個格點，每個視窗大小不會重疊，綜整 11 天共有 180,180 筆訓練資料。

對於測試資料而言，實驗 1 及實驗 2 的取得方式與訓練資料相同，而實驗 3 測試資料的取得是採用滑動 1 格的方式，代表視窗會重疊，如圖 3(b)實現方框所示。

實驗 1 及實驗 2 的比較主要目的是針對視窗大小是否會對於模型訓練有顯著的影響，此處的影響是反演結果的好壞，若模型測試結果沒有顯著的差異，可以選擇讓模型訓練時間較短的實驗設計進行後續的研究。

實驗 2 及實驗 3 的比較主要目的是針對拼接結果(視窗不重疊)可能會有視窗大小誤差被鎖定的狀況，代表同一個視窗大小的結果過於相近，因此實驗 3 使用移動 1 格的方式評估是否能夠改善此狀況，而移動 1 格的狀態下，每一個格點會有 121 個反演結果，目前是採先將 121 個反演結果取平均的方式與實驗 2 進行比較。

上述實驗的比較基準皆以均方根誤差(Root Mean Square Error, RMSE)為基準，如式(1)，

$$RMSE = \sqrt{(u_{rfs} - u_{retr})^2 + (v_{rfs} - v_{retr})^2} \quad (1)$$

u_{rfs} 及 v_{rfs} 為數值天氣模式的 u 及 v ， u_{retr} 及 v_{retr} 為 CNN 反演之 u 及 v 。

除了上述反演的結果是使用 RMSE 做為比較基準外，CNN 模型也需要基本設定，基本的設定有輸入層的資料要選用對模型建立有幫助的資料(譬如

該資料明顯與學習的目標有高相關性)及選用的損失函數(Loss Function, loss)，目前輸入層的資料為該格點都卜勒風(V_r)乘以該格點與雷達之距離(r)及相對雷達的格點位置(x,y)，損失函數選用均方誤差(Mean Square Error, MSE)，而另一個參考的量值為平均絕對誤差(Mean Absolutely Error, MAE)，CNN 會持續調整權重讓 MAE 下降，達到使用者設定的條件即會停止訓練。

表1 實驗設計基本設定

實驗	1	2	3
視窗大小	5*5	11*11	11*11
反演方式	面對面		
高度(公尺)	4750		
訓練資料時間長度	11日		
訓練資料筆數	862,752	180,180	180,180
測試資料時間長度	1日		
測試資料筆數	78,432	16,380	159,894
風場產生方式	拼接(滑動5格)	拼接(滑動11格)	滑動1格

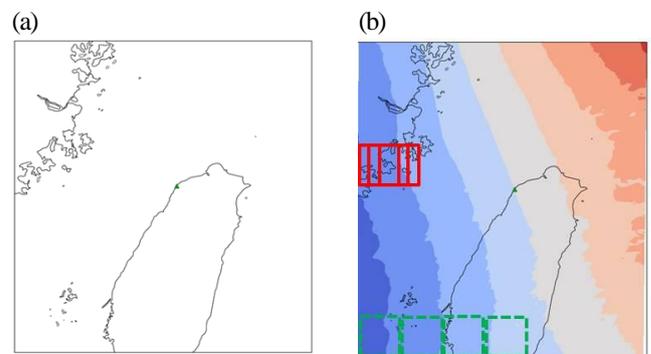


圖3 (a)本研究單都卜勒雷設計位置(三角形圖示)及合理掃描範圍、(b)視窗選取方式，虛線方框為拼接，實線方框為滑動1格。

四、討論與小結

圖 4 為本研究使用之模型架構，實驗 1 使用的模型架構為圖 4(a)，圖 4(b)的模型則是由實驗 2 及實驗 3 使用，兩種模型最大的差別在於實驗 1 沒有池化層。僅設置兩層的主要原因還是維持本研究一開始的理念，評估可行性，若一次將模型的層數加的

過深，會無法掌握結果呈現的原因，故待評估可行性高之後，再將模型層數加深會較為合理。實驗 1 的模型中，兩層卷積層的超參數設定皆相同，總共開了 16 個 2*2 視窗大小的篩選器(filter)，目的是創造特徵圖，啟動函數(Activation Function)使用的是 Leaky relu，目的是讓神經元都有機會傳遞全部訊息。實驗 2 及實驗 3 的模型多使用池化層的原因在於降低參數量，讓學習的效率可以提升。

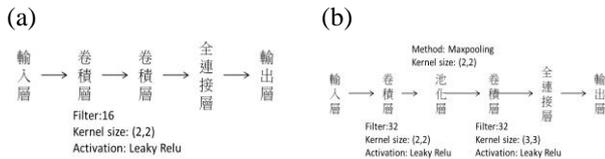


圖4 (a)實驗1使用之模型架構 (b)實驗2及3使用之模型架構

圖 5 的(a)至(c)為實驗 1、實驗 2 及實驗 3 之 RMSE 結果，由於皆實驗 1、實驗 2 是使用拼接方式拼湊成風場，因此誤差猶如拼圖樣態，這代表一開始假設視窗誤差鎖定是成立的。而實驗 1 及實驗 2 的結果相差不多，若以整個範圍而言，實驗 1 的 RMSE 為 2.59，實驗 2 的 RMSE 為 2.46，故經過實驗 1 及實驗 2 的比較後，選用 11*11 做為模型建立的基礎，因為訓練模型能夠更加有效率並且也能得到相近結果。實驗 3 整體範圍的 RMSE 為 2.15，代表採用滑動 1 格的方式有助於模型的表現，加上損失的空間資訊小於 6%，故使用滑動一格並面對面反演風場的策略有其可行性，而圖 6 為實驗 3 在 5 月 24 日 12 個小時各風場的 RMSE，對整體風場而言，大致掌握不錯的區域及掌握不好的區域皆相似，更代表實驗 3 的設計讓模型有一定的穩定性。實驗 3 的訓練曲線請見附錄。

最後，嘗試將實驗 3 的模型進行 7 月 12 日之風場反演，結果如圖 7(a)所示，並沒有維持反演 5 月 24 日風場的水準，其一原因是由於 7 月 12 日台灣與菲律賓之間有低壓通過，反演表現較差區域的封皆含有東風分量(圖 7(b))，而此模型訓練時的資料皆為西南風向，因此有此狀況其實是正常的，另一原因在於水平風場變動較大，整個反演區的風場更加複雜，因此反演的狀況不慎理想。為了證明是由於訓練資料複雜度不夠導致此測試結果不佳，因此將訓練資料的時間拉長，將訓練資料期間改為 5 月 13 日至 7 月 10 日，訓練模型的設定基礎同實驗 3，再

次測試反演 7 月 12 日風場，結果如圖 7(c)，改善非常明顯，這代表有效的資料量增加可以提升模型面對多樣化的風場反演表現。

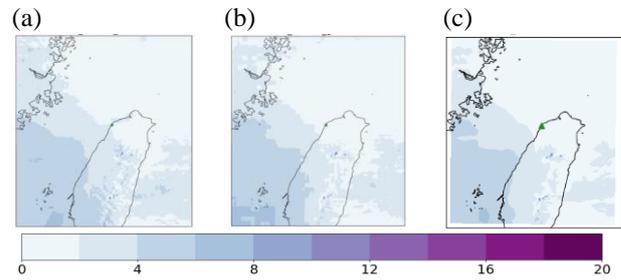


圖5 (a)實驗1、(b)實驗2及(c)實驗3在測試階段之 RMSE

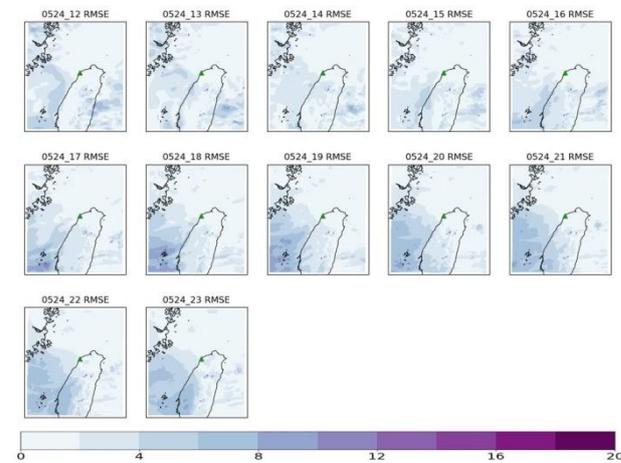


圖6 實驗3在測試階段各小時風場反演之RMSE

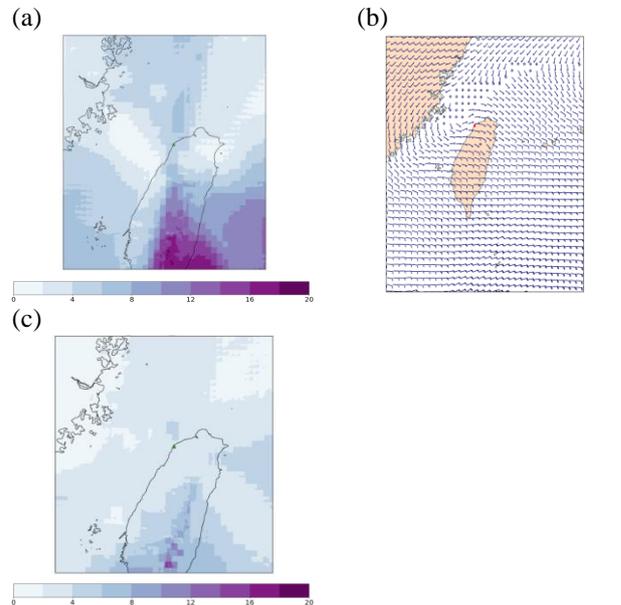


圖7 (a)實驗3模型測試水平風場變動較大反演之 RMSE、(b)環境風場、(c)維持實驗3網路架構並增加訓練資料量後，測試水平風場變動較大反演之 RMSE。

五、未來工作

CNN 針對較均勻之單都卜勒風場反演結果顯示有不錯的效果，整體風場的 RMSE 可以維持在 2 至 3 (m/s)，評估之下有進一步發展的可行性，而從測試水平風場變動較大之結果，可以規劃未來工作條列如下，

1. 拉長訓練資料的時間，主要是能夠面對多樣性的風場。
2. 訓練資料加入不同高度的資料，主要是測試 CNN 在多層時是否可以維持一定的水準表現，未來在應用可以 3 維應用。
3. 優化程式及萃取有效資料，降低模型訓練時間。以實驗 3 的架構為例，訓練資料長度使用 11 天的基礎下，1 個模型所需的訓練時間為半天，在預估未來訓練的資料量一定會更多的前提下，如何優化程式及萃取更有效的資料是絕對要面對的議題。

六、參考文獻

Boukabara, S., V. Krasnopolsky, J. Q. Stewart, E. S. Maddy, N. Shahroudi, and R. N. Hoffman, 2019: “Leveraging Modern Artificial Intelligence for Remote Sensing and NWP: Benefits and Challenges”, *Bull. Amer. Meteor. Soc.*, 100, ES473–ES491, <https://doi.org/10.1175/BAMS-D-18-0324.1>.

He, K., X. Zhang, S. Ren, and J. Sun, 2016: “Deep residual learning for image recognition”, In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).

Ioffe, S., and C. Szegedy, 2015: “Batch normalization: Accelerating deep network training by reducing internal covariate shift”, *arXiv preprint arXiv: 1502.03167*.

Krasnopolsky, V. M., L. C. Breaker, and W. H. Gemmill, 1995: “A neural network as a nonlinear transfer function model for retrieving surface wind speeds from the special sensor microwave imager”, *J. Geophys. Res.*, 100, 11033–11045, <https://doi.org/10.1029/95JC00857>.

Lhermittle, R. M. and D. Atlas, 1961: “Precipitation Motion by Pulse Doppler Radar”, *Preprints 9th Radar*

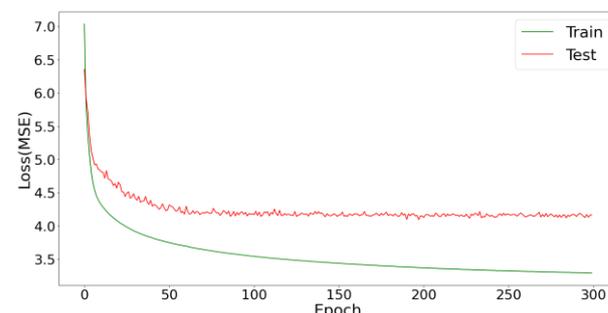
Meteor. Conf. Amer. Meteor. Soci., Kansas City, 218-223.

Li, Nan, Ming Wei, Xiyu Mu, and Chang Zhao, 2015: “A support vector machine-based VVP wind retrieval method”, *Atmospheric Science Letters* 16, no.3, 331-337.

Li, Nan, Ming Wei, Yongjiang Yu, and Wengang Zhang, 2017: “Evaluation of a support vector machine-based single-Doppler wind retrieval algorithm”, *Journal of Atmospheric and Oceanic Technology* 34, no.8, 1749-1761.

Lee, W.-C., B. J.-D. Jou, P.-L. Chang, and S.-M. Deng, 1999: “Tropical cyclone kinematic structure retrieved from single Doppler radar observations. Part I: Interpretation of Doppler velocity patterns and the GBVTD technique”, *Mon. Wea. Rev.*, 127, 2419-2439.

七、附錄



實驗3模型之訓練曲線。

另，本研究除了都卜勒風場是使用程式語言 Fortran 產製外，其它處理過程皆使用程式語言 Python，版本為 3.7，控管套件使用的是 conda-forge 或 pip。相關使用套件表列如下並說明其用途。

套件名稱	版本	目的
numpy	1.18.1	處理數值運算及檔案讀取及儲存
cartopy	0.18.0	繪製含經緯度資訊之圖形
basemap	1.2.1	繪製含經緯度資訊之圖形
matplotlib	3.2.1	繪製基本統計圖形
seaborn	0.10.1	繪製基本統計圖形
tensorflow-gpu	1.9	CNN 網路架構設定
keras	2.2.4	CNN 網路架構設定

wrf-python	1.3.2	處理數值天氣預報 輸出變數
netcdf4	1.5.3	讀取數值天氣預報 輸出變數
xarray	0.15.0	讀取數值天氣預報 輸出變數
numba	0.49.1	加速numpy數值運 算
cupy	7.7.0	利用 GPU 加速 numpy數值運算

本研究使用之GPU型號為Tesla V100，1片GPU記憶體為32GB。

Convolutional Neural Network for Single-Doppler Wind Filed Retrieval

Cheng-Chin Liu¹, Pao-Liang Chang¹, Jing-Shan Hong¹, Wei-Ting Fang²

¹Meteorological Information Center, Central Weather Bureau

²Meteorological Satellite Center, Central Weather Bureau

The applications of Doppler velocity is limited due to the radar can only observe the velocity component of precipitation particles in the direction of the radar beam. The retrieval method developed by using the distribution characteristics of the Doppler velocity field can provide the circulation characteristics of the weather system, but the application still has limitations. In recent years, the Convolutional Neural Network (CNN) technology in deep learning has remarkable performance in image recognition. Moreover, the deep learning has been applied in atmosphere science studies, such as retrieval issues. Thus, this study attempts to use CNN technology to develop a Single-Doppler wind filed retrieval model. In order to efficiently evaluate the feasibility of wind filed retrieval model build by CNN, the data set is derived from numerical weather prediction model. Preliminary evaluation shows that the Single-Doppler wind filed retrieval result has good performance on uniform wind filed, but underperformance with the cases on quite big variations horizontal wind filed. In the future, this research will gradually increase the diversity and complexity of data set to improve the accuracy of the wind field retrieval model, and apply it to the real Doppler radar observations.

Keywords: Doppler velocity, Deep learning, Convolutional Neural Network, Wind Filed Retrieval