

使用深度學習方法與向日葵8號多頻道資料進行台灣區域衛星降雨推估

蔡政達¹, 趙俊傑¹, 高凱昱¹, 林鈞仁¹, 鄭韶琪¹, 張育承²
資拓宏宇國際股份有限公司¹ 中央氣象局氣象衛星中心²

摘要

地球同步氣象衛星提供了高時空解析度的監測資料，適合用來降雨監測，在沒有氣象雷達觀測的區域尤為重要。限制於地球同步氣象衛星只搭載被動式輻射儀器，及雲頂觀測與地面降雨量為間接的關係，降雨推估產品的結果仍有改進的空間。本工作嘗試使用向日葵8號衛星資料及深度學習方法來改善衛星降雨推估。

資料分析上，除了使用向日葵8號所有的紅外線及水氣頻道外，並增加了具有雲水特徵的頻道差資料。模型訓練時以氣象局雷達推估降雨作為目標資料，訓練資料的長度包括了2016到2018年7、8月及2019年7月的十分鐘兩公里解析度資料。在神經網路的架構上，嘗試了多種深度學習架構-包括卷積長短期記憶網路(Convolutional LSTM)、卷積神經網路(CNN)、自編碼器網路(Autoencoder)、分割網路(U-Net)、生成對抗網路(cGAN, wGAN)。

目前的結果以搭配卷積層及反卷積層作為編碼器及解碼器的自編碼器網路模型，和U-Net模型的結果較佳。與目前作業用的即時衛星推估降雨產品比較，深度學習模型除了在降雨推估上有較佳的表現外，對降雨的日循環特性也有較好的掌握。

關鍵字：深度學習，氣象衛星遙測，降雨推估

1. 前言

從1960年第一顆低軌氣象觀測衛星TIROS-1升空後，人類便善用氣象衛星觀測來監測天氣並嘗試由有限的衛星資料來推估各種環境變數，例如降雨、海溫、水氣量、雲移速移向等。降雨量因為直接影響到日常的生活作息，得到了許多的關注。目前的雨量遙測技術，以可提供三維及高解度時空資料的地面氣象雷達，為最佳的雨量遙測工具，不過受限於地球曲率、地形及建站位置等因素，氣象雷達觀測只能涵蓋部分的陸地及沿岸區域，在廣闊的洋面上，仍需要利用氣象衛星推估資料來監測中緯度氣旋、颱風、東風波等降雨天氣系統。

地球同步氣象衛星具有長時間連續觀測大範圍區域的優勢，但由於衛星在任務設計上的限制，地球同步氣象衛星可搭載的儀器，所提供的觀測頻道有可見光、紅外線及水汽頻道等，只能供應雲頂及地表的亮度溫度及反照率。相較於地球同步氣象衛星，低軌衛星有觀測區域小，一日只能觀測同一區域約兩次的限制，但優點是可攜帶包含微波等多樣的儀器，如SSM/I (Special Sensor Microwave/Imager)、GMI

(GPM Microwave Imager)、DPR (Dual-frequency Precipitation Radar)等被動及主動微波觀測儀器，可提供比較多及更準確的大氣物理參數供推估。

目前使用衛星觀測資料推估降雨的方法大致可分為三類：1)使用低軌衛星的微波輻射儀等或降雨雷達的資料進行推估(Chen et al. 2011, 李 2002, 魏等 2008)，2)使用地球同步衛星的資料進行降雨推估(Huffman et al. 1997, Hsu et al. 1997, 魏等 2011)，這類方法的優點是可以將推估資料追溯到1980年代，便於進行氣候監測，3)混合使用低軌衛星及地球同步衛星的觀測資料(Joyce et al. 2004, Kuligowski 2002, Tan et al. 2019, 呂等 2012)。在使用的演算法上，大致上可分成兩類：1) 統計回歸方法 (Joyce et al. 2004, Huffman et al. 1997, Kuligowski 2002, Tan et al. 2019)，2) 人工智慧方法，如類神經網路(Hsu et al. 1997, Hong et al. 2004, Sadeghi et al. 2019, 劉等 2001, 魏等 2008, 2011)。

作業及研究單位先後開發出了通用的衛星雨量推估產品，供短期及長期天氣及氣候監控使用，目前較為知名的高解析度時間及空間產品為NOAA CMORPH (Joyce et al. 2004)、SCaMPR (Kuligowski 2002)、NASA IMERG V06 (Tan et al. 2019)、

PERSIANN-CCS (Hsu et al. 1997, Hong et al. 2004)等。上述的方法，除了PERSIANN-CCS採用神經網路方法，大部分採用統計回歸方法並使用MORPHing技術做時間及空間的資料填補，以彌補低軌衛星微波資料受到同一區域一日兩次觀測的限制。

鑒於近年來，東亞地區地球同步氣象衛星上的觀測儀器，在觀測頻道、空間及時間解析度上有顯著的升級，深度學習方法在21世紀的第二個十年有了新的發展，本工作嘗試使用向日葵8號的觀測資料，氣象局雷達定量降水估計(QPESUMS)與深度學習方法建立台灣區域即時衛星降雨推估模型，並與目前作業用的即時衛星降雨推估產品進行評估比較。

2. 資料

2.1 向日葵8號多頻道觀測資料

近年來，東亞地區地球同步氣象衛星上的觀測儀器，在空間及時間解析度上有顯著的升級，可見光紅外線及水汽頻道的總數量，由MTSAT-1/2的5個頻道擴展成向日葵8號的16個頻道，提供了部分中低大氣層的資訊，紅外線頻道的解析度由GMS-5的5公里提升到MTSAT-1/2的4公里及向日葵8號的2公里。本工作使用向日葵8號每10分鐘提供一次的紅外線及水汽頻道觀測資料。

2.2 QPESUMS

QPESUMS為氣象局的雷達定量降水估計(QPE)產品，每10分鐘提供約1公里解析度的1小時累積降雨估計。本工作使用此產品做為訓練目標資料。

2.3 CWB-SCaMPR, CMORPH RT, IMERG V06

CWB-SCaMPR提供10分鐘2公里解析度的衛星降雨推估，產品延遲時間15分鐘。CMORPH RT(real time)為NOAA CMORPH系列的即時產品，提供30分鐘8公里解析度的衛星降雨推估，產品延遲時間2小時。NASA IMERG V06提供30分鐘10公里解析度的衛星降雨推估，產品延遲時間4小時。這些資料將用來與模型推估降雨資料進行比較。

2.4 資料長度與範圍

訓練資料的長度包括了2016到2018年7、8月及2019年7月的10分鐘2公里解析度資料，區域範圍為119°E-122.98°E, 21°N-25.98°N,大致上位於良好氣象雷達觀測品質的區域。2019年8月的資料則用來測試模型。

3. 方法

3.1 頻道差及CLAVR-x

理論上只要有一定數量的神經元及神經層便可以用神經網路解決任何的問題。實務上，特徵工程並不會因為深度學習方法的出現而降低重要性，良善的特徵工程可以有效的提升模型的性能並降低對硬體資源的需求及降低模型的複雜度。

本工作根據Mecikalski et al. (2010)和So及Shin (2018)的研究，利用向日葵8號各頻道的特性，使用紅外線及水汽頻道資料，並使用以下的頻道差: 6.2 - 11.2 μm 、8.6 - 11.2 μm 、11.2 - 12.4 μm 、(8.6 - 11.2 μm) - (11.2 - 12.4 μm)，以得到更多雲物理特徵作為輸入資料。另外，也使用CLAVR-x (Heidinger et al. 2014, 章等2014)產製雲遮(cloud mask)、雲種類(cloud type)、雲頂氣壓(cloud top pressure)及雲頂溫度(cloud top temperature)資料。

3.2 深度學習神經網路架構

機器學習包含了非神經網路的方法及深度學習方法。非神經網路的方法包括了如SVM、Random Forest、XGboost等，超過三個神經層的神經網路方法，目前稱為深度學習。本工作在先導試驗時，曾嘗試使用非神經網路方法來進行降雨區域及降雨量推估，但發現模型的通用性不佳，且衛星資料龐大，雖然可採用增量學習(Incremental learning)技巧來進行類似神經網路中的遷移學習(transfer learning)，但缺點是可用的方法有限，所以後續的測試皆使用深度學習方法來進行資料建模。

推估模型建置過程中測試過數種神經網路架構，大致的說明如下:

- 1) 全連接深層神經網路(fully connected DNN) - 測試結果有通用性不佳的問題，原因在於雲頂的特徵，需要使用周圍的格點一起做判斷，而非單一格點。卷積神經網路(CNN)在擷取圖像的特徵時，會採用周圍的資料，正符合這樣的需求，之後的測試便皆使用有卷積過程的神經網路架構。
- 2) DenseNet和Convolutional LSTM - 訓練結果會出現部分區域有明顯的數值異常情形，可能起因於模型的複雜性不夠，無法學習較細微的特徵。
- 3) 卷積自編碼網路(convolutional autoencoder) - 依照PERSIANN-CNN (Sadeghi et al. 2019)的架構以向日葵8號的紅外線(10.4 μm)及水汽(6.9 μm)兩個頻道試做後，注意到該模型的性能不錯，接著進一步進行改良，提升模型的性能，本文將改良後的版本稱為PERSIANN-CNN-改(Tsay et al. 2020)。
- 4) U-Net - 本工作參考PERSIANN-CNN的精神進行改良，根據各頻道不同的特性，分別使用不同的卷積層來大範圍的抽取頻道特徵，再經由Skip connection將特徵傳遞到後面的網路中以提升了模型的性能，改良後的版本稱為U-Net-改。

由2019年8月4日08UTC(16LST)的雷達降雨估計可以觀察到，當時在台灣北部的雪山山脈及中央山脈西邊山麓有午後對流生成(圖4a)，模型的衛星降雨推估(圖4b-c)明顯在降雨量及分布上，比現有的衛星降雨產品(圖4d-f)有較佳的表現。

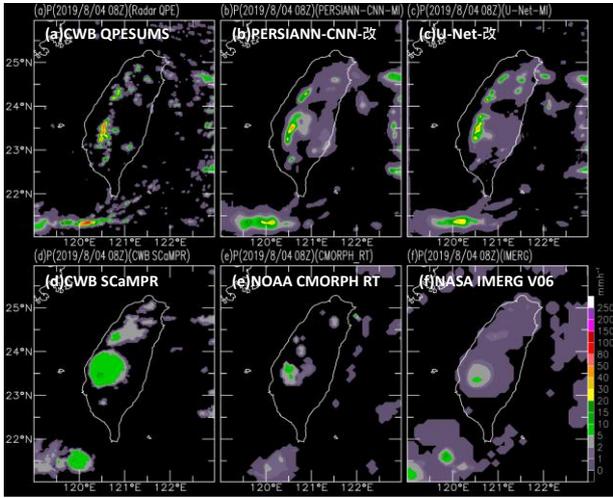


圖4 2019年8月4日16 LST 1小時累積雨量: (a) CWB QPESUMS, (b) PERSIANN-CNN-改, (c) U-Net-改, (d) CWB ScaMPR, (e) NOAA CMORPH RT, (f) NASA IMERG V06。(a)為雷達定量降雨推估, (b)及(c)為深度學習模型的衛星降雨推估, (d)-(f)為目前作業及研究用的即時衛星降雨推估產品。

圖5a為2019年8月13日16UTC(8月14日00LST)的雷達降雨估計，當日午夜在台灣西南外海有帶狀的降雨，CWB ScaMPR(圖5d)有捕捉到大略的型態，CMORPH RT(圖5e)及IMERG V06(圖5f)並沒有呈現出帶狀降雨，模型的衛星降雨推估(圖4b-c)有較細膩的兩帶呈現。2019年8月所有的時雨量水平分布比較圖，可以在這個[連結](#)下載供參考。

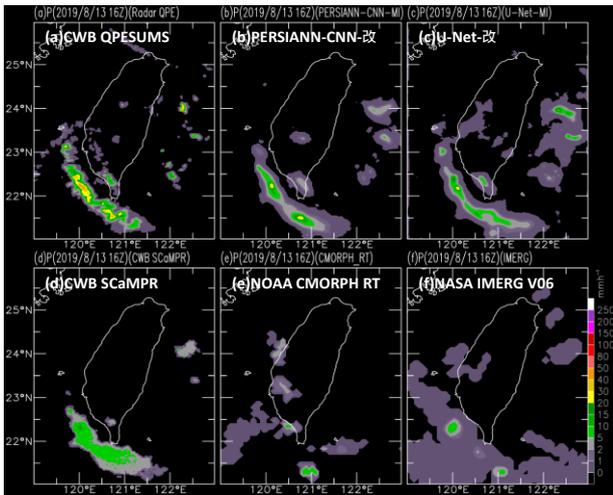


圖5 同圖4，日期為2019年8月14日00 LST。

4.2 日雨量

將24小時的時雨量累積後為日雨量。圖6為各資料與QPESUMS比較後的統計分析的結果，圖6a及d為 R^2 及對應的箱形圖(boxplot)， R^2 越接近1愈佳，圖6b及e為RMSE及對應的箱形圖，RMSE越小愈佳，圖6c及f為TS(降雨量 $\geq 1\text{mm/day}$)及對應的箱形圖，TS越接近1愈佳。在這三種統計分系中，雖然每日的統計數值有變化，整理來說，PERSIANN-CNN-改(圖6a-c中的實心紅色三角形，d-f中的左邊第一個)及U-Net-改(圖6a-c中的紅色空心圓，d-f中的左邊第二個)，明顯的改進了PERSIANN-CNN圖6(a-c中的紅色空心方塊，d-f中的左邊第三個)的效能，與其它的降雨資料集相比，同樣的有較小的四分位距及較好的表現。相較於時雨量，日雨量的統計分析結果較佳，推估是因為24小時的累加使得每個小時的誤差互相抵消。

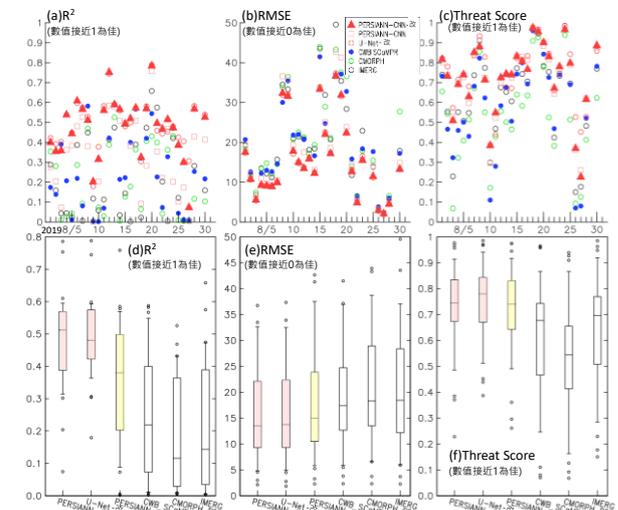


圖6 各衛星日雨推估資料與CWB QPESUMS降雨估計比較: (a) R^2 , (b) RMSE, (c) Threat Score 散佈圖, x軸為日期(2019年8月1日至31日). (d)-(e)為相對應的箱形圖 (box plot). (a)-(c)的x軸為時間(2019/8/1~8/31). (d)-(f)的x軸為資料名稱, 依序為PERSIANN-CNN-改, U-Net-改, PERSIANN-CNN, CWB ScaMPR, NOAA CMORPH RT, IMERG V06.

由2019年8月11日的雷達降雨估計可以觀察到，當日在台灣北部的雪山山脈及中央山脈南部有大規模的降雨現象(圖7a)，模型的衛星降雨推估(圖7b-c)明顯在降雨量及分布上，比現有的衛星降雨產品(圖7d-f)有較佳的表現。2019年8月所有的日雨量水平分布比較圖，可以在這[連結](#)下載供參考。

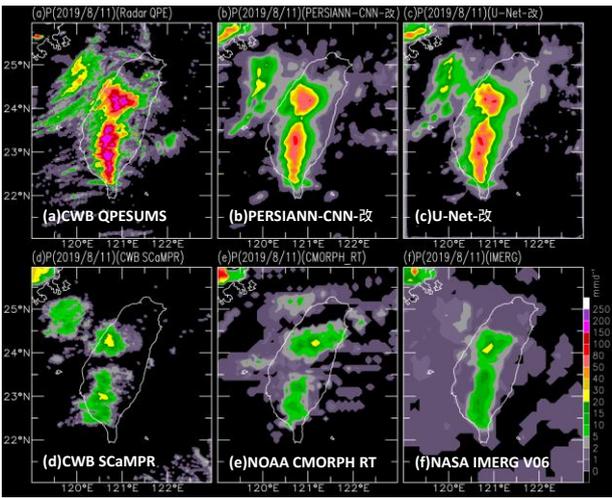


圖7 2019年8月11日累積雨量: (a) CWB QPESUMS, (b) PERSIANN-CNN-改, (c) U-Net-改, (d) CWB SCaMPR, (e) NOAA CMORPH RT, (f) NASA IMERG V06。

4.3 降雨的日循環特性

日循環(diurnal cycle)為臺灣夏季降雨日夜變化的重要成分，為了瞭解深度學習模型在這方面的特性，將2019年8月份的每小時降雨計算成月小時平均，接著將24小時月平均透過快速傅立葉轉換(FFT; Brenner and Rader 1976)得到各降雨資料的日循環相位(phase)及振幅(amplitude)，並進行比較。

圖8中，箭頭方向代表相位的時間，箭頭長度代表振幅大小，為了量測向量的相似性，使用餘弦相似性(cosine similarity)方法計算了與CWB QPESUMS結果(圖8a)的相似性。經過比較，PERSIANN-CNN-改(圖8b)與U-Net-改(圖8c)有比較其他資料接近CWB QPESUMS的表現，有以下的特徵：

- 從雲林口湖鄉到高雄茂林村的這條紅虛線，兩邊的相位時間有明顯的差異，PERSIANN-CNN-改 與U-Net-改 有呈現出差異，與CWB QPESUMS比較接近。
- 台中到嘉義沿岸及東部外海上的時間分布，PERSIANN-CNN-改 與 U-Net-改 也跟CWB QPESUMS比較相似。
- 雲林、嘉義山區，相位的時間為上午10點左右，但沒有一個衛星估算降雨資料跟CWB QPESUMS相同，這一塊地方發生這種現象的原因，是因為8月15日上午，這一個區域有較大的降水現象，但是模型跟衛星降雨產品在雨量上皆沒有好的推估。

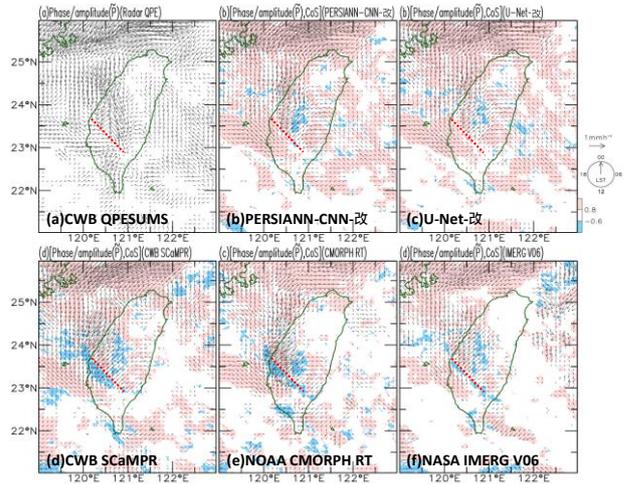


圖8 2019年8月降雨日循環(diurnal cycle)的相位(phase)及振幅(amplitude), (b)-(f)的塗色為該資料與CWB QPESUMS的餘弦相似性(cosine similarity; CoS), 藍色為負相似, 粉色為正相似: (a)CWB QPESUMS, (b) PERSIANN-CNN-改, (c) U-Net-改, (d) CWB SCaMPR, (d) NOAA CMORPH RT, (f) NASA IMERG V06。紅虛線為在CWB QPESUMS資料中，臺灣中南部有明顯相位幅合的地方。

5. 結論

衛星雲頂觀測資訊與降雨量為間接的關係，數十年來，作業及研究單位不斷的嘗試使用各種方法來求得最佳的衛星降雨推估，以提供更佳的天氣及氣候監控，尤其是在氣象雷達觀測網無法涵蓋的大洋及人煙稀少區域。

鑒於近年來機器學習方法在各領域的應用上有著蓬勃的發展，本工作嘗試探索深度學習方法是否能改善現行作業用的衛星降雨推估產品，進行了一系列的測試與初步的評估。

本工作使用向日葵8號多頻道紅外線、水汽觀測、頻道差、地形及CLAVR-x推算的雲物理相關等資料，以QPESUMS做為目標資料，進行台灣地區的衛星降雨推估模型訓練。目前的結果可以發現深度學習方法的確比過去的神經網路方法更有能力來處理衛星降雨推估問題，對於小尺度的降雨現象也有較佳的掌握，整體的性能有比現行作業及研究用產品佳。

目前的深度學習模型仍有可以精進的地方及方向：

- 考量模型訓練時間及模型的性能，目前的深度模型架構以卷積自編碼網路(convolutional autoencoder)較優，自編碼網路的演變架構：VAE (variational autoencoder)、VQ-VAE (vector-quantized variational autoencoder)是否仍進一步改進模型的表現仍待測

試；GAN等目前測試起來比較不理想的方法，也將持續視技術的演進進行發展與測試。

- 目前的訓練資料為7~8月，其它的月份及季節的表現如何，仍需要測試。
- 此工作的目標為開發通用的降雨模型，由模型預測的結果顯示，模型對於颱風與颱風地形降雨的掌握，仍有改進的空間。需評估是否將針對特殊的天氣系統訓練特殊的模型或進行多模型的混和模型等，將是一個視測試結果而討論的開放議題。
- 初期的工作為建立台灣地區的衛星降雨推估模型，未來將以此為基礎，建立東亞地區的衛星降雨推估模型。

致謝

感謝中央氣象局衛星中心王建國技正提供SCaMPR降雨反演資料。

參考文獻

Brenner, N. and C. A. Rader, 1976: New principle for fast fourier transformation. *IEEE Acoustics, Speech & Signal Processing*, **24** (3), 264–266.

Chen, L., K.-C. Yeh, H.-P. Wei, and G.-R. Liu: 2011, An improved genetic programming to SSM/I estimation typhoon precipitation over ocean. *Hydro. Process*, **25**, 2573-2583.

Hayatbini, N., and co-authors, 2019: Conditional Generative Adversarial Networks (cGANs) for near real-time precipitation estimation from multispectral GOES-16 Satellite Imageries-PERSIANN-cGAN. *Remote Sensing*, **11**, 2193.

He, K., X. Zhang, S. Ren, and J. Sun, 2015: Deep residual learning for image recognition. arXiv: 1512.03385v1.

Hong, Y., K.-L. Hsu, S. Sorooshian, and X. Gao, 2004: Precipitation estimation from remotely sensed imagery using an artificial neural network cloud classification system. *J. Appl. Meteor.*, **42**, 1834-1853.

Hsu, K.-L., X. Gao, S. Sorooshian, and H. V. Gupta, 1997: Precipitation estimation from remotely sense information using artificial neural network. *J. Appl. Meteor.*, **36**, 1176-1190.

Huffman, G. J. and co-authors, 1997: The Global Precipitation Climatology Project (GPCP) combined data set. *Bull. Amer. Meteor. Soc.*, **78**, 5-20.

Joyce, R. J., J. E. Janowiak, P. A. Arkin, and P. Xie, 2004: CMORPH: A method that produces global precipitation estimates from passive microwave and infrared data at high spatial and temporal resolution. *J. Hydrometeors.*, **5**, 487-503.

Kuligowski, R. J., 2002: A self-calibrating real-time GOES rainfall algorithm for short-term rainfall estimates. *J. Hydrometeors.*, **3**, 112-130.

Ronneberger, O., P. Fischer, and T. Brox, 2015: U-Net: Convolutional networks for biomedical image segmentation. arXiv:1505.04597.

Sadeghi, M., A. A. Asanjan, M. Faridzad, P. Nguyen, K.-L. Hsu, S. Sorooshian, D. Braithwaite, 2019: PERSIANN-CNN Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks - Convolutional Neural Networks. *J. Hydrometeorology*, **20**, 2273-2289.

So, D. and D. B. Shin, 2018: Classification of precipitating clouds using satellite infrared observations and its implications for rainfall estimation. *Q. J. R. Meteorol. Soc.*, **144**, 133–144.

Tan, J., G. J. Huffman, D. T. Bolvin, E. J. Neklin, 2019: IMERG V06: Changes to the Morphing Algorithm. *J. Atmos. Oceanic Technol.*, **36**, 2471-2482.

Tsay, J.-D., K. Kao, C.-C. Chao, Y.-C. Chang, and S.-Y. Wang, 2020: Satellite rainfall retrieval by enhanced PERSIANN-CNN with Himawari 8 multiple-spectra channels. *Remote Sensing*. (pending review).

李慶忠, 2002: TRMM 微波資料海面降雨反演及應用, 國防大學中正理工學院國防科學研究所博士論文.

呂高森, 陳萬金, 汪建良, 劉振榮, 胡仁基, 2012: 結合衛星微波及紅外線資料估算即時定量降水, 101年天氣分析與預報研討會, 台灣台北.

章鶴群, A. K. Heidinger, 趙俊傑, 張拱祿, 2015: 地球同步衛星之可見光及紅外線頻道衍生產品. 104年天氣分析與預報研討會, 台灣台北.

劉清煌, 劉廣英, 劉敏香, 2001: 類神經網路估計颱風降水之研究. 兩岸颱風研討會, 台灣台北, 179-1852.

魏曉萍, 葉克家, 劉振榮, 趙俊傑, 2008: 結合SSM/I 衛星資料與類神經網路推估海上颱風降雨量之研究. *大氣科學*, **36**, 147-162.

_____, 趙俊傑, 葉克家, 劉振榮, 2011: 使用紅外線頻道與水氣頻道差改善同步衛星降雨估算. 建國百年天氣分析與預報研討會, 台灣台北.

Precipitation estimation over the Taiwan area from Himawari 8 multiband observation using the deep learning method

Jenq-Dar Tsay¹, Chun-Chieh Chao¹, Kevin Kao¹,
Chun-Jen Lin¹, Shao-Ci Jheng¹, Yu-Cheng Chang²

¹International Integration System, Inc., New Taipei
City, Taiwan

²Meteorological Satellite Center, Central Weather
Bureau, Taipei City, Taiwan

Abstract

The geostationary weather satellite provides high spatial and temporal observation data, which are vital for rainfall monitoring in areas where weather radar observations are unavailable. The current operational satellite rainfall estimation products are not comparable with weather radar-derived quantitative precipitation estimation due to the limitation of the instruments onboard the satellite and indirect relationship between cloud and precipitation. This task conducted experiments of using deep learning methods and Himawari 8 multiband observation to improve satellite-derived quantitative precipitation estimation.

All of Himawari 8's infrared, water vapor channels, and several specially designed differences between channels, which represents cloud characteristics, were used to train models. Central Weather Bureau QPESUMS was chosen as target data. Data of July and August of 2016, 2017, 2018 and July 2019 were used for training purposes. Data of August 2019 were used for testing. Several neural network architectures were selected for the trails, include Convolutional LSTM, CNN, U-Net, Autoencoders, cGAN, and wGAN.

The result shows Convolutional Autoencoders and U-Net have better performance than the other architectures. These deep learning models do improve from operational real-time satellite rainfall estimation products and have a good portrait of rainfall diurnal cycle.

Key word: deep learning, meteorological satellite remote sensing, satellite rainfall estimation