

SOBRE EL USO DE DATOS DE RAYOS COMO PROXY PARA LA REFLECTIVIDAD RADAR EN LA REGIÓN CENTRAL DE ARGENTINA

Mailén Gómez Mayol¹, Luciano Vidal¹, Paola Salio², Maximiliano Sacco¹
mmayol@smn.gov.ar

¹ **Servicio Meteorológico Nacional - Argentina**

² **Centro de Investigaciones del Mar y la Atmósfera – UBA - CONICET. Departamento de Ciencias de la Atmósfera y los Océanos – Facultad de Ciencias Exactas y Naturales. UMI-Instituto Franco Argentino sobre Estudios del Clima y sus Impactos CNRS 3351, Buenos Aires, Argentina**

RESUMEN

En este trabajo se presenta una técnica para generar un producto sintético de reflectividad radar máxima de la columna utilizando técnicas de aprendizaje profundo supervisado con datos de descargas eléctricas atmosféricas nube-tierra. La importancia de este tipo de productos radica en su utilidad como alternativa de bajo costo como apoyo a la vigilancia meteorológica de tormentas severas en áreas donde no existe cobertura radar o como un complemento a las imágenes degradadas por atenuación o interferencias.

ABSTRACT

In this work we present a technique to generate a synthetic radar product using supervised deep learning techniques with cloud-to-ground lightning data. The importance of this type of product lies in its usefulness as a low-cost alternative to support meteorological surveillance of severe storms in areas where radar coverage does not exist or as a complement to images degraded by attenuation or interference.

Palabras clave: descargas eléctricas, redes neuronales, radar sintético

1. INTRODUCCIÓN

Las tormentas y sus fenómenos asociados tienen alto impacto en el ámbito social y económico de un país, y los datos aportados por una red de radares meteorológicos es de suma importancia para el pronóstico y seguimiento de las mismas. Numerosas investigaciones en los últimos años han centrado sus esfuerzos en la determinación de una relación sólida entre la actividad eléctrica atmosférica asociada a las nubes de tormentas y los campos de reflectividad generados por los radares meteorológicos (Cheze y Sauvageot, 1997; Tapia y otros, 1998; Soula y Chauzy, 2001; Zhou y otros, 2002).

En este trabajo se presenta un modelo que mediante una red neuronal generativa simula el producto COLMAX (reflectividad máxima de la columna) a partir de datos de descargas eléctricas nube-tierra (CG) obtenidos por una red de detección en superficie.

2. DATOS Y METODOLOGÍA

Los datos de reflectividad provienen del radar meteorológico Selex SI Gematronik Doppler de doble polarización en banda C ubicado en la Estación Experimental Agropecuaria INTA Anguil (La Pampa). Los volúmenes utilizados cuentan con 12 elevaciones (entre 0.5 y 15.1°), una resolución temporal de 10 min y espacial de 0.5 km y 1° en rango y acimut respectivamente. Por su parte, los datos de actividad eléctrica atmosférica provienen de la red Vaisala GLD360 (Said y otros, 2010) cuyos datos se reciben en el Servicio Meteorológico Nacional y provee información de la posición (lat/lon), tiempo y polaridad de las descargas nube-tierra. Los datos de entrenamiento fueron tomados en el período de verano desde noviembre de 2016 a febrero de 2017.

Se entrenó una red GAN condicional (Generative Adversarial Network; Goodfellow, 2014) especialmente diseñada para la transformación de imágenes (Isola y otros, 2016); donde la “imagen entrada” es un campo preliminar de COLMAX obtenido a partir de la aplicación del método de comparación de probabilidades (PMM) en datos de descargas eléctricas y su correspondiente valor de reflectividad COLMAX (Iskenderian, 2008), y la “imagen objetivo” es el campo COLMAX generado a partir de la información de radar. El modelo obtenido puede aplicarse sólo a la información de actividad eléctrica para generar el producto sintético COLMAX de

reflectividad en una dada región a través de la red de aprendizaje y extrapolar a cualquier región con disponibilidad de datos de descargas eléctricas.

3. RESULTADOS

En la figura 1 se muestran los resultados obtenidos para un caso que presenta una línea convectiva al NE del centro del radar y dos celdas aisladas al NNO el día 16/1/2016 a las 19:30 UTC (fig. 1d). El campo COLMAX preliminar (fig. 1b) muestra una buena correspondencia con la región más convectiva, tanto de la línea como de las celdas aisladas ($Z_{COLMAX} > 30$ dBZ). Sin embargo los valores están sobreestimados, con diferencias del orden de 10 dBZ en algunos sectores, y no es capaz de capturar las regiones con reflectividades menores a 30 dBZ (región estratiforme). El campo de COLMAX sintético (fig. 1c) en cambio es capaz de reproducir los máximos de reflectividad en la zona convectiva con diferencias máximas de 5 dBZ y logra capturar muy bien la región estratiforme que rodea a los núcleos convectivos. Algo a destacar es la ausencia del clutter cerca del radar que se observa en la fig. 1d hacia el oeste tanto en el COLMAX preliminar como en el sintético.

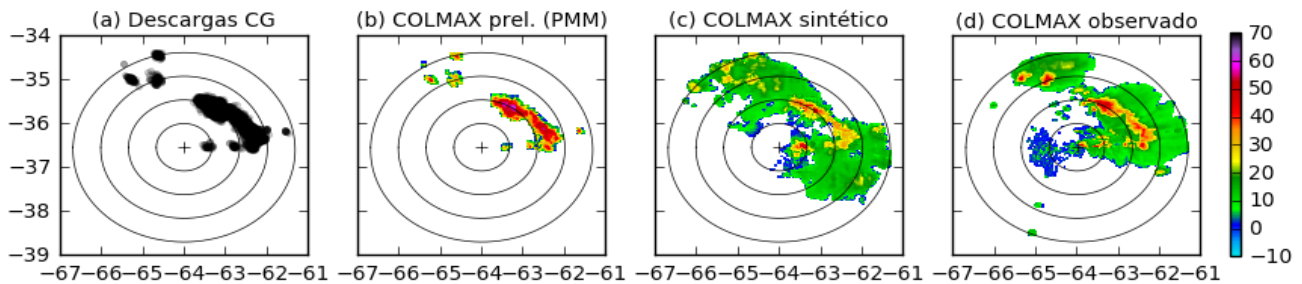


Figura 1. Ejemplo de los resultados obtenidos para el día 16/1/2016 a las 19:30 UTC. La separación entre anillos es de 30 kilómetros.

4. CONCLUSIONES

En este trabajo se propuso utilizar redes neuronales sobre datos de descargas eléctricas y datos de radar para lograr obtener un campo simulado de reflectividad (radar sintético) que no presenta los problemas típicos de datos ruidosos, atenuación, eco de suelo (clutter) y no está limitado por el alcance de los radares. Este producto de radar sintético permite contar con información útil en situaciones de tiempo severo con una frecuencia temporal mayor a la de los radares, en cualquier lugar donde haya información de actividad eléctrica. En trabajos posteriores se evaluará la factibilidad de este modelo para ser extendido a otros radares de la red con la finalidad de lograr un producto de cobertura nacional.

REFERENCIAS

- Chèze J.L. y Sauvageot H., 1997:** Area-average rainfall and lightning activity. *Journal of Geophysical Research: Atmospheres*, 102(D2) (pp.1707-1715).
- Goodfellow I., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A. y Bengio Y., 2014:** Generative adversarial nets. In *Advances in neural information processing systems* (pp. 2672-2680).
- Isola P., Zhu J.Y., Zhou T. y Efros A.A., 2016:** Image-to-image translation with conditional adversarial networks. arXiv preprint arXiv:1611.07004.
- Iskenderian H., 2008:** Cloud-to-ground lightning as a proxy for nowcasts of VIL and echo tops. In *13th Conference on Aviation, Range and Aerospace Meteorology* (pp. 21-24).
- Said R.K., Inan U.S. y Cummins K.L., 2010:** Long-range lightning geolocation using a VLF radio atmospheric waveform bank. *J. Geophys. Res.*, 115, D23108, doi:10.1029/2010JD013863.
- Soula S. y Chauzy S., 2001:** Some aspects of the correlation between lightning and rain activities in thunderstorms. *Atmospheric research*, 56(1) (pp.355-373).
- Tapia A., Smith J.A. y Dixon M., 1998:** Estimation of convective rainfall from lightning observations. *Journal of Applied Meteorology*, 37(11) (pp.1497-1509).
- Zhou Y., Qie X. y Soula S., 2002:** A study of the relationship between cloud-to-ground lightning and precipitation in the convective weather system in China. In *Annales Geophysicae*, Vol. 20, No. 1 (pp. 107-113).