

ESTIMACIÓN DE PRECIPITACIÓN MULTISENSOR UTILIZANDO REDES NEURONALES CONVOLUCIONALES

Sergio González^{1,2,3,4}, Luciano Vidal⁴, Pablo Negri^{5,6}, Juan Ruiz^{1,2,3}
sergio.gonzalez@cima.fcen.uba.ar

¹ Centro de Investigaciones del Mar y la Atmósfera (CIMA, CONICET-UBA)

² Instituto Franco-Argentino sobre Estudios del Clima y sus Impactos
IRL-IFAECI/IRD-CNRS-UBA-CONICET

³ Departamento de Ciencias de la Atmósfera y los Océanos (FCEyN, UBA)

⁴ Servicio Meteorológico Nacional (SMN)

⁵ Instituto de Ciencias de la Computación (ICC, CONICET-UBA)

⁶ Departamento de Computación (FCEyN, UBA)

Palabras clave: Estimación de precipitación satelital, Aprendizaje profundo, Sensores remotos.

1) INTRODUCCIÓN

Con el objetivo de complementar las escasas observaciones de pluviómetros en superficie, se han desarrollado diversas metodologías para aprovechar el potencial de los sensores remotos. Los datos satelitales en infrarrojo (IR) proporcionan información sobre las características del tope de las nubes, mientras que los destellos de actividad eléctrica ubican las regiones donde la intensidad de la convección es mayor. Los datos de microondas, disponibles en satélites de órbita baja, pueden penetrar y capturar la estructura interna de las nubes, que permite estimaciones de precipitación (ECP) más precisas, pero su frecuencia y cobertura de observación son limitadas debido a su tiempo de revisita y ancho de escaneo.

El objetivo del trabajo es el desarrollo de modelos de estimaciones de precipitación satelitales mediante redes neuronales convolucionales. Se propone utilizar un modelo de aprendizaje profundo que estime la precipitación a partir de la ECP del satélite GOES-16 y evaluar su desempeño incluyendo datos en infrarrojo y actividad eléctrica.

2) DATOS Y METODOLOGÍA

Como input de los modelos se utiliza el algoritmo de ECP del satélite GOES-16 (RRQPE, Kuligowski, R. J., 2020), derivado de datos en infrarrojo; la temperatura de brillo (TB) del canal 13 (10,3 μm) del sensor Advance Baseline Imager (ABI); y del sensor óptico Geostationary Lightning Mapper (GLM, Goodman, et al., 2013) la variable Flash Extent Density (FED). La TB y el RRQPE poseen una resolución espacial y temporal de 2 km (punto nadir) y de 10 minutos respectivamente. Los datos del GLM son provistos en pares de datos latitud/longitud con una resolución temporal de 20 segundos. Por lo tanto, se utilizó la herramienta de GLMTools (CSPP Geo., 2022) para proyectar los datos al reticulado del sensor ABI y en acumulados de un minuto. Posteriormente se utilizó el acumulado de 10 minutos para que todas las variables posean igual temporalidad. El algoritmo de estimación de precipitación en superficie del sensor Dual-frequency Precipitation Radar (DPR, Iguchi et al., 2021) del satélite de órbita baja Global Precipitation Measurement (GPM) constituye el target del modelo. Esta estimación está basada en datos de radar (en microondas activas), pero con un periodo de revisita de 1 o 2 días, con un ancho de sensado de 245 km² y una resolución espacial de 5 km.

El modelo implementado es un modelo de redes neuronales convolucionales con una

arquitectura U-Net. El propósito de la arquitectura U-Net es codificar la información de entrada a un espacio de mínima dimensión, la cual posteriormente es decodificada en conjunto con la información del mismo nivel de codificación. Para el entrenamiento de la red, se utiliza una función de costo de error cuadrático medio y un optimizador ADAM, con una tasa de aprendizaje inicial de 0.001, reduciendo en un orden de magnitud en dos épocas fijas (30 y 75), un tamaño de batch size de 128 y un máximo de 120 épocas de entrenamiento.

Los datos utilizados comprenden el periodo de enero 2020 a junio 2021 inclusive, sobre la región de Sudamérica (90°O - 30°O | 50°S - 10°N). Se excluyen los meses de enero y junio de 2021, los cuales se utilizan como período de testeo. Las muestras de entrenamiento son seleccionadas mediante los siguientes criterios: que la diferencia temporal entre las imágenes sea menor a 5 minutos; que la imagen cuente con al menos 10% de los píxeles con PP mayor a 0.1 mm^{-1} del PP-DPR, y que dichos píxeles posean una correlación espacial con el RRQPE de al menos el 0.2. Mediante este criterio se obtuvieron un total de 6158 muestras de entrenamiento. Para entrenar y definir la cantidad de épocas de entrenamiento óptimas para los modelos, se utilizó el algoritmo de validación cruzada de K-Fold con 5 conjuntos.

RESULTADOS Y CONCLUSIONES

En la Figura 1 se observa un caso de ejemplo para el conjunto de testeo. En la primera fila se observan todos los inputs (RRQPE, TB, FED), seguido por el target correspondiente al DPR. En la fila de abajo se poseen las diferentes salidas del modelo U-Net utilizando el RRQPE como predictor (exp-R), e incluyendo la TB (exp-TR) y el FED (exp-RF) por separado, y en conjunto (exp-TRF).

En el modelo exp-R, el objetivo es ajustar las tasas de precipitación estimadas por el RRQPE (basadas en IR) a las del DPR, derivadas estas últimas de un radar en el rango de microondas activas. Se puede observar que este modelo reproduce una parte de la región precipitante del DPR, particularmente en el área más intensa. No obstante, la predicción es considerablemente más suave en comparación con el DPR.

En el exp-TR, se incluye la temperatura de brillo (TB) además del RRQPE. Al añadir la información de la TB, que provee datos del tope de las nubes y, por ende, permite determinar las regiones de nubes más profundas, es de esperar que este modelo mejore la precisión de la predicción en comparación con el exp-R. De hecho, la salida del exp-TR es muy similar a la del exp-R en las áreas principales de precipitación, pero con un enfoque más marcado en las regiones de nubosidad profunda.

Por su parte, el exp-RF incorpora la densidad de flashes extendida (FED) al RRQPE. El FED puede indicar la presencia de actividad convectiva fuerte, lo cual podría ayudar a identificar áreas de precipitación intensa. Efectivamente, la salida del exp-RF también es consistente con el campo de precipitación del DPR y captura la zona de mayor intensidad.

Finalmente, el exp-TRF representa el modelo más completo, ya que utiliza las tres entradas disponibles: TB, RRQPE y FED. Al combinar toda esta información, se anticipa que este modelo ofrecerá la predicción más precisa y robusta. La salida del exp-TRF es la que mejor se ajusta a la posición e intensidad del área precipitante del DPR. Esto sugiere que, si bien el RRQPE es un predictor que introduce una fuerte señal por sí mismo en las salidas, la incorporación de la TB y el FED puede ofrecer beneficios adicionales en términos de capturar la complejidad y la distribución de la precipitación con mayor fidelidad.

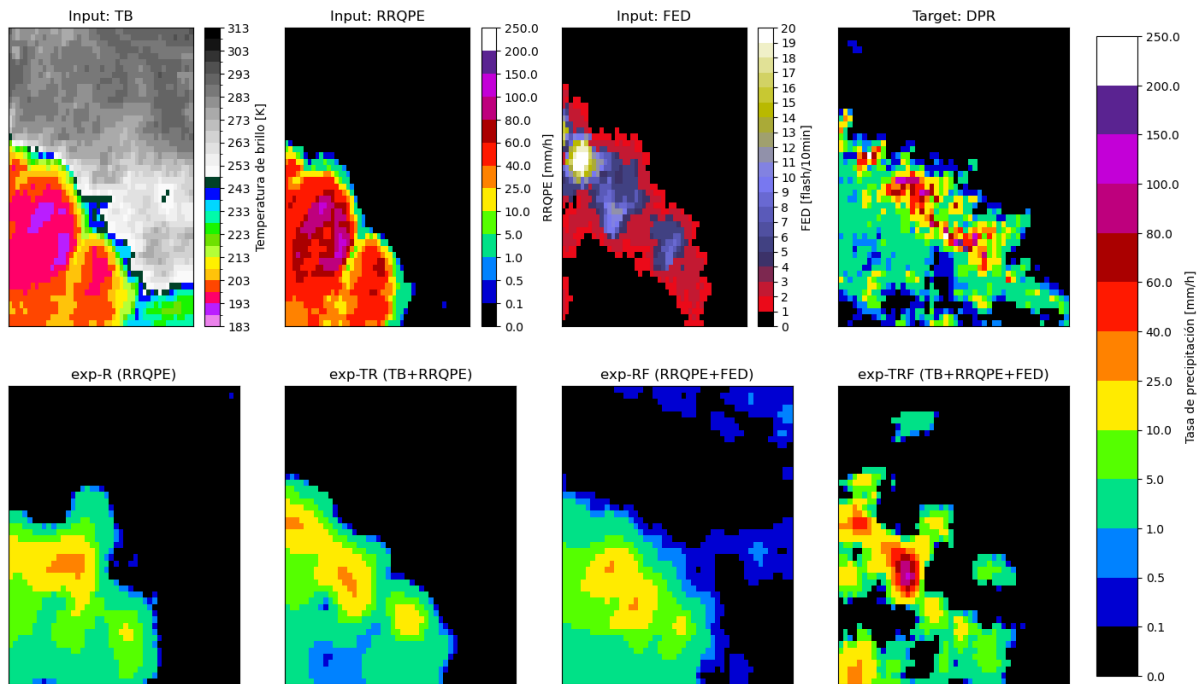


Figura 1: Ejemplo de aplicación del modelo propuesto. Se muestran los datos de entrada (temperatura de brillo - TB, estimación de precipitación del GOES - RRQPE, densidad de extensión de flashes - FED) y el target (estimación de precipitación del DPR). Las salidas de la U-Net se presentan con configuraciones de entrada: RRQPE (exp-R); RRQPE+TB (exp-TR); RRQPE+FED (exp-RF); y todas las variables (exp-TRF).

Como línea de trabajo futuro se explorará la incorporación de más canales del sensor ABI de frecuencias ampliamente utilizadas en la estimación de precipitación que han demostrado un buen desempeño. Otro aspecto a explorar es el uso de funciones de costo pesadas que estén enfocadas en resaltar aquellos valores asociados a los extremos de precipitación, un aspecto que no es representado en funciones clásicas como el MSE.

AGRADECIMIENTOS

Esta investigación ha contado con el apoyo parcial del proyecto [PREVENIR](#).

REFERENCIAS

Kuligowski, R. J., 2020: GOES-R Advanced Baseline Imager (ABI) Algorithm Theoretical Basis Document For Rainfall Rate (QPE) Retrieved June 7, 2024, from https://www.star.nesdis.noaa.gov/goesr/documents/ATBDs/Enterprise/ATBD_Enterprise_Rainfall_Rate_v3_2020-07-10.pdf

Goodman, S. J., Blakeslee, R. J., Koshak, W. J., Mach, D., Bailey, J., Buechler, D., Carey, L., Schultz, C., Bateman, M., McCaul, E., y Stano, G., 2013: The GOES-R Geostationary Lightning Mapper (GLM). Atmospheric Research, 125-126, 34-49. <https://doi.org/10.1016/j.atmosres.2013.01.006>

CSPP Geo., 2022: Gridded GLM Software version 1.0. Cooperative Institute for Meteorological Satellite Studies, University of Wisconsin–Madison. Retrieved from [CSPP Geo, CIMSS](#)

Iguchi, T., Seto, S., Meneghini, R., Yoshida, N., Awa-Ka, J., Le, M., Chandrasekar, V., Brodzik, S., Kubota, T., & Takahashi, N., 2021: GPM/DPR Level-2 Algorithm Theoretical Basis Document. https://gpm.nasa.gov/sites/default/files/2022-06/ATBD_DPR_V07A.pdf