

# ESTIMACIÓN DE PRECIPITACIÓN EN BASE A IMÁGENES SATELITALES EN INFRARROJO UTILIZANDO REDES NEURONALES PROFUNDAS

González Sergio H.<sup>1,2,3</sup>, Ruiz Juan J.<sup>1,2,3</sup>, Negri Pablo<sup>4,5</sup>  
sergio.gonzalez@cima.fcen.uba.ar

<sup>1</sup> Centro de Investigaciones del Mar y la Atmósfera (CIMA / CONICET-UBA)

<sup>2</sup> Instituto Franco-Argentino para el Estudio del Clima y sus Impactos (IRL IFAECI/CNRS-IRD-CONICET-UBA).

<sup>3</sup> Departamento de Ciencias de la Atmósfera y los Océanos (FCEyN, UBA)

<sup>4</sup> Departamento de Computación (FCEyN, UBA)

<sup>5</sup> Instituto de Investigación en Ciencias de la Computación (CONICET-UBA)

**Palabras claves:** estimación de precipitación, sensores remotos, aprendizaje profundo.

## 1) INTRODUCCIÓN

Para complementar las redes pluviométricas se desarrollaron diferentes métodos que aprovechan el potencial de los sensores remotos para obtener estimaciones de la tasa de precipitación (PP) en diferentes escalas de tiempo y espacio (e.g. Joyce et al. 2004; Huffman et al. 2015). Estos métodos se basan en las complejas relaciones que existen entre la radiancia medida por diferentes sensores en infrarrojo (IR) y en microondas, y la PP.

Actualmente, se están incorporando nuevas técnicas que usan el potencial del aprendizaje automático para modelar la relación entre radianzas y precipitación. Estas técnicas permiten extraer información de manera más eficiente de los datos provistos por los sensores remotos, incorporando aspectos relacionados con la forma y tamaño de los sistemas precipitantes, aspectos que son difíciles de considerar en los algoritmos tradicionales. En particular, modelos basados en redes generativas antagónicas como el PrecipGAN (Wang et al. 2021) permitieron obtener estimaciones basadas exclusivamente en imágenes satelitales infrarrojas, con una precisión muy superior a la de los métodos existentes.

Este trabajo propone utilizar datos satelitales en el rango del IR con alta frecuencia temporal (10 minutos) provistos por el Geostationary Operational Environmental Satellite-16 (GOES-16) para desarrollar un método de estimación de precipitación basado en redes neuronales. La red neuronal es entrenada teniendo como función objetivo las estimaciones de precipitación obtenidas a partir del radar a bordo del satélite Global Precipitation Mission (GPM). Adicionalmente, se evalúa su desempeño respecto del algoritmo de estimación cuantitativa de precipitación del satélite GOES-16 (GOES-QPE, Kuligowski et al. 2016).

## 2) DATOS Y METODOLOGÍA

En este trabajo, se entrena una red neuronal que estima la distribución espacial de la PP a partir de la distribución espacial de la temperatura de topos nubosos. Para tal efecto el input de la red consiste en datos de temperatura de brillo (TB) del canal 13 (10,3  $\mu\text{m}$ , C13) del sensor Advanced Baseline Imager a bordo del satélite GOES-16 y la función objetivo

consiste en la PP estimada a partir del Dual-frequency Polarization Radar (DPR) a bordo del satélite GPM (*precipRateESurface, ESpp*). Se definió como región de estudio un entorno de Sudamérica entre 50°S-10°N y 90°O-30°O.

Para el entrenamiento del modelo se seleccionó un conjunto de datos que incluye el periodo comprendido entre el 22 de mayo de 2018 y el 30 de junio de 2021. Para obtener información simultánea de ambos conjuntos de datos, las estimaciones provistas por el ESpp teniendo en cuenta el ancho de escaneo (*Normal Scan, NS*) que es de 245 km, fueron divididas en sectores de 240 km<sup>2</sup> con un solapamiento de 20% respecto de los sectores consecutivos. Esto dio como resultado un total de 232.678 pares de sectores. Luego, se seleccionaron las imágenes del GOES-16 más cercanas en tiempo a cada sector y se interpolaron los datos del C13 a la retícula definida por la estrategia de escaneo NS.

Para facilitar el entrenamiento se impuso una PP máxima estimada por el GPM de 60 mm.h<sup>-1</sup> y se procedió a reducir la resolución espacial a 30 km. Por otra parte, se seleccionaron imágenes en donde la diferencia temporal entre los datos del GOES-16 y los del GPM fuera menor a 5 minutos y en donde se cumplieran los siguientes criterios: que el 15% de las PP estimadas sean mayores a 0.1 mm.h<sup>-1</sup>, y que el 10% de las TB sea inferior a 240 K, y que la correlación de Pearson entre la TB y la PP sea menor a -0.1. Aplicando estos criterios, el subconjunto usado queda conformado por un total de 19.070 imágenes.

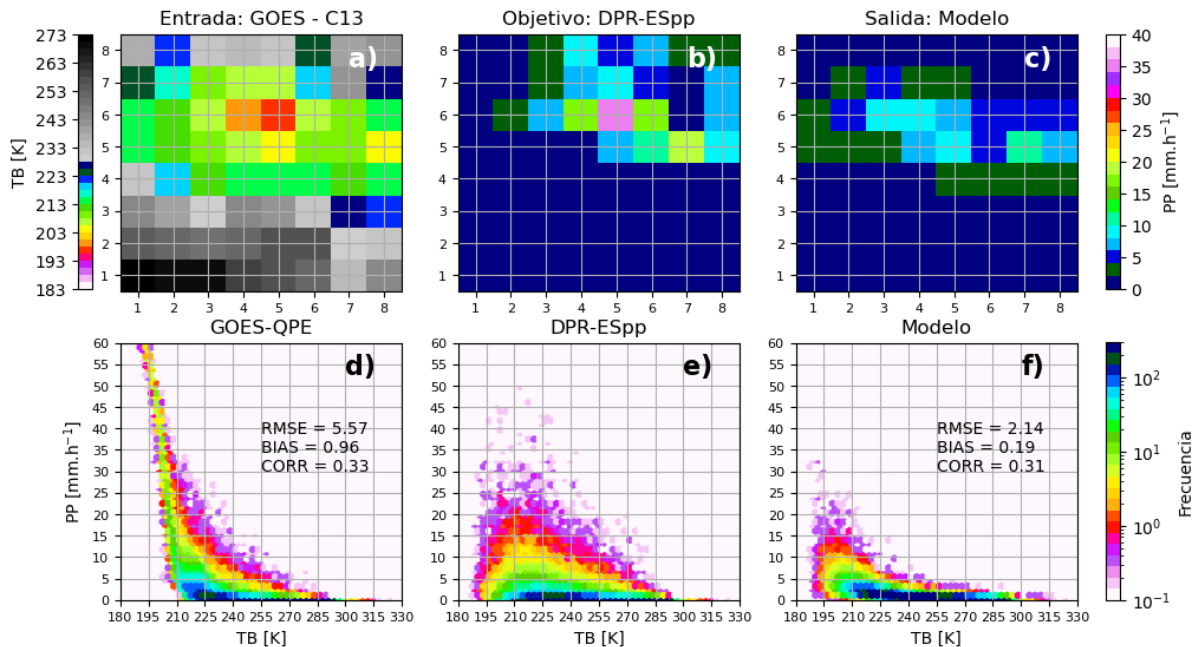
El conjunto de datos obtenido, se divide en 3 partes, una para el entrenamiento (70%), validación (15%) y testeo (15%), que se consideraron en orden cronológico. El conjunto de testeo, se utiliza para cuantificar el desempeño de la red respecto del ESpp y para compararlo con el desempeño obtenido por la estimación de precipitación del GOES-QPE. A tal efecto se utiliza la raíz del error cuadrático medio (RMSE), el sesgo (BIAS) y la correlación de Pearson (CORR) entre las estimaciones de precipitación en base a la TB y las PP instantáneas estimadas a partir del DPR.

Con el objetivo de aumentar la cantidad de muestras de entrenamiento se aplicó una rotación de los pares de imágenes alrededor de su eje horizontal, vertical y la aplicación simultánea de ambas rotaciones.

### 3) RESULTADOS Y CONCLUSIONES

El modelo utilizado es una red neuronal profunda que consta de 5 capas compuestas por 64 neuronas cada una. El batch size es de 50 y la tasa de aprendizaje inicial es de  $1 \cdot 10^{-3}$ . Dado el desbalance en los datos, de pocos eventos de precipitación extrema, se modificó la función de costo, agregando pesos que puedan aumentar la relevancia relativa de los eventos de precipitaciones menos frecuentes en el entrenamiento del modelo (Duan et al. 2021). En la Figura 1, se tiene un ejemplo de su implementación de la imagen de entrada (a), objetivo (b) y salida de la red (c). También se muestra la relación existente entre la TB y las PP estimadas. Se observa que las mayores PP estimadas en el GOES-QPE (d), que sobreestima hacia las TB más bajas. Mientras que nuestro modelo (f) también logra capturar la relación inversa entre las PP del DPR y la TB, pero incurriendo en subestimaciones. No obstante, el RMSE y BIAS de la precipitación estimada por la red neuronal es menor que el de la estimación de precipitación del GOES-QPE. En cuanto a la CORR es ligeramente menor para el GOES-QPE que para la red.

Se ha desarrollado un modelo de red neuronal profunda que estima tasas de precipitación a partir de imágenes satelitales en el rango de infrarrojo. El mismo se ha comparado contra el GOES-QPE, y posee un menor RMSE y BIAS. Dado su potencial para extraer información de la morfología de los sistemas precipitantes, está en desarrollo un modelo basado en redes neuronales convolucionales.



**Figura 1:** (Arriba) Ejemplo de entrada (a), objetivo (b) y salida (c) de la red neuronal centrado en 3.26°N - 49.57°O a las 06:48:03 UTC del día 21/02/2021. (Abajo) Gráfico de dispersión de las PP estimadas [mm.h<sup>-1</sup>] del GOES-QPE (d), DPR (e) y del modelo propuesto (f), en función de la TB [K].

## REFERENCIAS

- Duan, M., Xia, J., Yan, Z., Han, L., Zhang, L., Xia, H. y Yu, S., 2021:** Reconstruction of the Radar Reflectivity of Convective Storms Based on Deep Learning and Himawari-8 Observations. *Remote Sens.*, 13, 3330.
- Huffman G.J., Bolvin D.T. y Nelkin E.J., 2015:** Integrated Multi-satellitE Retrievals for GPM (IMERG) Technical Documentation. NASA/GSFC Code 612, 47.
- Joyce, R. J., Janowiak, J. E., Arkin, P. A. y Xie, P., 2004:** CMORPH: A Method that Produces Global Precipitation Estimates from Passive Microwave and Infrared Data at High Spatial and Temporal Resolution, *Journal of Hydrometeorology*, 5(3), 487-503.
- Kuligowski, R. J., Li, Y., Hao, Y., y Zhang, Y., 2016:** Improvements to the GOES-R Rainfall Rate Algorithm, *Journal of Hydrometeorology*, 17(6), 1693-1704.
- Wang C., Tang G. y Gentine P, 2021:** PrecipGAN: Merging Microwave and Infrared Data for Satellite Precipitation Estimation Using Generative Adversarial Network. *Geophysical Research Letters*. 48. 10.1029/2020GL092032.