

# ESTIMACIÓN DE PRECIPITACIÓN UTILIZANDO SENSORES REMOTOS Y SIMULACIONES NUMÉRICAS MEDIANTE REDES NEURONALES

Ezequiel Geslin<sup>1</sup>, Juan José Ruiz<sup>1,2</sup>, Sergio Hernán González<sup>1,2</sup>, Luciano Vidal<sup>3</sup>, Pablo Negri<sup>4</sup>  
ezezeslin@gmail.com

<sup>1</sup> Departamento de Ciencias de la Atmósfera y los Océanos (FCEyN, UBA)

<sup>2</sup> Centro de Investigaciones del Mar y la Atmósfera (CONICET-UBA)

<sup>3</sup> Servicio Meteorológico Nacional

<sup>4</sup> Instituto de Ciencias de la Computación (CONICET-UBA)

**Palabras clave:** Satélites, Aprendizaje Automático, Pronóstico Numérico.

## 1) INTRODUCCIÓN

La precipitación es una componente esencial del ciclo hidrológico y es sumamente importante para la planificación y gestión de los recursos hídricos, la gestión del riesgo de desastres y la agricultura. Estimar la tasa de precipitación a nivel regional con alta resolución espacial y temporal es un desafío científico y tecnológico. Los sensores infrarrojos a bordo de los satélites geoestacionarios proveen información útil para la estimación de precipitación con una amplia cobertura espacial (ej. Hobouchian et al., 2017). Recientemente, los modelos de machine learning han sido aplicados a la estimación de precipitación en base a sensores remotos (Wang et al., 2023). Una de las ventajas de estos métodos es que permiten combinar de manera flexible diferentes fuentes de información.

Los modelos numéricos globales proveen una fuente de información que resulta complementaria a la información medida por los satélites meteorológicos. A pesar de los avances en estimación de precipitación mediante sensores remotos y modelos de aprendizaje automático, son relativamente pocos los estudios que se han focalizado sobre escalas de tiempo cortas y en la combinación de datos de sensores remotos con información proveniente de modelos numéricos.

En este trabajo se propone desarrollar, entrenar y validar un modelo basado en redes neuronales profundas para estimar la tasa de precipitación en superficie en escalas de tiempo cortas (del orden de los minutos) a partir de datos de temperatura de brillo en el rango del infrarrojo obtenidos a partir de satélites geoestacionarios y pronósticos numéricos globales.

## 2) Datos y Metodología

Para el entrenamiento supervisado del modelo se utilizaron las tasas instantáneas de precipitación estimadas por el radar de doble frecuencia DPR a bordo del satélite GPM (Pfreundschuh et al., 2022). Como variables de entrada se emplearon las temperaturas de brillo (TB) en el rango del infrarrojo, obtenidas a partir del satélite GOES-16 y simulaciones numéricas de agua precipitable provistas por el Global Forecasting System (GFS). El dominio espacial está centrado en Sudamérica y sus océanos adyacentes. La muestra total cuenta con cerca de 10.000 imágenes entre enero de 2020 y junio de 2021, de las cuales el 80% se destinó al entrenamiento y el 20% a la validación. El conjunto de testeo está constituido por los datos obtenidos durante los meses de enero y junio de 2021, con el fin de analizar el desempeño del modelo tanto en condiciones estivales como invernales.

El modelo implementado se basa en una arquitectura de tipo U-Net (Ronneberger et al. 2015). Para incluir los datos de las simulaciones numéricas, estos datos son primero procesados por una red de tipo encoder y posteriormente concatenados a los datos satelitales en el bottleneck de la red U-Net. Del cual, ambos conjuntos de datos son procesados en conjunto a través del decodificador. Para el entrenamiento, se utilizó como función de pérdida el error cuadrático medio (MSE); como optimizador se empleó ADAM, con una tasa de aprendizaje inicial de  $1e^{-3}$  y con lotes de 64 imágenes. Se utilizó una técnica de early stop

para reducir el riesgo de overfitting. Como función de activación se utilizó Leaky ReLU, con una pendiente negativa de 0.01.

Para evaluar el impacto del agua precipitable y posibles formas de combinarla con la temperatura de brillo, se entrenaron 3 versiones diferentes del modelo. Una en donde el input del modelo es solamente la temperatura de brillo, otra en donde se agrega como input la distribución del agua precipitable en una región de 1000 x 1000 km centrada en la imagen del target y otra donde el agua precipitable está disponible solamente en la región donde se estima la precipitación.

### 3) Resultados

Los modelos desarrollados fueron evaluados utilizando el conjunto de testeo y calculando el RMSE, el BIAS y la correlación lineal de Pearson (CORR) entre las predicciones generadas por las redes y las tasas de precipitación observadas por el DPR. Cada configuración fue entrenada con 5 inicializaciones independientes con el objetivo de obtener una mayor robustez en las métricas reportadas. Los resultados obtenidos habiendo promediado las 5 inicializaciones se resumen en la Tabla I.

INPUTS	DOMINIO SIMULACIÓN	RMSE	BIAS	CORR
TEMPERATURA DE BRILLO		1.53	0.11	0.21
TEMPERATURA DE BRILLO Y AGUA PRECIPITABLE	1000 Km x 1000 Km	1.52	0.10	0.24
TEMPERATURA DE BRILLO Y AGUA PRECIPITABLE	Interpolación al dominio del DPR	1.51	0.07	0.23

**Tabla I. Métricas correspondientes a la comparación de la precipitación estimada por diferentes versiones del modelo con respecto a la tasa de precipitación provista por el DPR en el conjunto de testeo**

Si bien el modelo entrenado únicamente con TB tiene resultados satisfactorios, que indican una capacidad adecuada para estimar la tasa de precipitación en superficie, al compararlo con las redes entrenadas con la inclusión del agua precipitable, estas últimas producen un error cuadrático medio y un bias menor y una mayor correlación, sugiriendo que el agregado de las simulaciones mejora el rendimiento del modelo. Respecto a las dos variantes evaluadas para la incorporación del agua precipitable, no se notó una diferencia significativa entre ambas.

En la Figura 1, se presenta una imagen del sensor DPR correspondiente al conjunto de testeo junto con las predicciones generadas por dos de los modelos. En ella, se puede observar cómo la inclusión del agua precipitable le permitió al modelo representar valores más extremos de precipitación con una mayor precisión espacial.




Figura 1. Ejemplo de un caso correspondiente al conjunto de testeo imagen DPR (izquierda), predicción del modelo entrenado con TB (centro) y predicción del modelo entrenado con TB y agua precipitable (PWAT) para el dominio interpolado (derecha)

#### 4) Conclusiones

En este trabajo se implementó una red neuronal convolucional para estimar la precipitación a partir de la temperatura de brillo del canal 13 del GOES-16. Además, se incorporaron simulaciones numéricas de agua precipitable como variable adicional con el objetivo de evaluar su impacto en el rendimiento del modelo. Los resultados obtenidos muestran que, si bien la red entrenada exclusivamente con TB obtuvo resultados satisfactorios, la inclusión del agua precipitable como variable de entrada mejora el desempeño de la red, reduciendo tanto el error cuadrático medio (RMSE) como el bias, y aumentando la correlación con las tasas de precipitación estimadas por el sensor DPR. La mejora se evidencia también en la capacidad del modelo para identificar correctamente las lluvias más intensas, de particular interés por su posible impacto social y económico.

Además, se observó que introducir el agua precipitable en dominios más grandes que el correspondiente a las imágenes del DPR no introdujo un beneficio en el rendimiento de la red, sino que mantuvo resultados similares.

Como líneas futuras de investigación, se propone explorar distintas formas de integrar la variable simulada en la arquitectura del modelo. Asimismo, se analizará el efecto de incorporar nuevas variables provenientes del modelo numérico, tales como tasa de precipitación, energía potencial convectiva disponible (CAPE), energía inhibitoria de la convección (CINE), viento y altura geopotencial en distintos niveles, entre otras.

#### 5) Referencias

**Hobouchian, M. P., García Skabar, Y., Barrera, D., Vila, D., & Salio, P. (2017).**

Estimación de precipitación por satélite aplicando la técnica Hidroestimador en su versión para Sudamérica. Servicio Meteorológico Nacional. <http://hdl.handle.net/11336/178710>

**Pfreundschuh, S., Ingemarsson, I., Eriksson, P., Vila, D. A., and Calheiros, A. J. P.:** An improved near-real-time precipitation retrieval for Brazil, *Atmos. Meas. Tech.*, 15, 6907–6933, <https://doi.org/10.5194/amt-15-6907-2022>, 2022.

**Ronneberger, O., Fischer, P., & Brox, T. (2015).** U-Net: Convolutional Networks for Biomedical Image Segmentation. In *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* (pp. 234–241). [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)

**Wang, F., Tian, D., & Carroll, M. (2023).** Customized deep learning for precipitation bias correction and downscaling. *Geoscientific Model Development*, 16, 535–553.

<https://doi.org/10.5194/gmd-16-535-2023>