

# REDES NEURONALES PARA EL POSPROCESAMIENTO DE PRONÓSTICOS CUANTITATIVOS DE PRECIPITACIÓN

Fernando Huaranca<sup>1,4</sup>, Juan Ruiz<sup>1,2,3</sup>

[fernando.huaranca99@gmail.com](mailto:fernando.huaranca99@gmail.com), [jruiz@cima.fcen.uba.ar](mailto:jruiz@cima.fcen.uba.ar)

<sup>1</sup>Dep. de Cs. de la atmósfera y los océanos - FCEyN - UBA

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

<sup>3</sup>Instituto Franco-Argentino para el Estudio del Clima y sus Impactos (IRL IFAECI/CNRS-IRD-CONICET-UBA)

<sup>4</sup>Aires Renewables

**Palabras clave:** precipitación, aprendizaje automático, pronósticos retrospectivos

## 1) INTRODUCCIÓN

Los modelos numéricos de la atmósfera son un componente fundamental de los sistemas de pronóstico numérico modernos implementados en los diferentes servicios meteorológicos del mundo. Estos utilizan el conocimiento de la física del sistema para anticipar su evolución y se han beneficiado a lo largo de los años del incremento de la accesibilidad de datos observacionales y la incorporación de fenómenos de distintas escalas espacio-temporales, lo cual ha generado que su complejidad vaya en aumento. No obstante estos avances, los sistemas de pronósticos están sujetos a errores aleatorios y sistemáticos que se originan en la incertidumbre asociada con las condiciones iniciales y de borde, así como en las simplificaciones introducidas en la representación de procesos de pequeña escala. Para reducir los errores mencionados, se han desarrollado técnicas que buscan caracterizar y corregir el comportamiento de estos errores basándose en el desempeño del modelo en casos anteriores; estas correcciones son denominadas técnicas de posprocesamiento (Vannistem et al. 2021).

Recientemente, las técnicas de postprocesamiento basadas en aprendizaje automático han recibido mucha atención debido a la capacidad de los modelos para aprender relaciones complejas entre conjuntos de datos multivariados en donde la cantidad de predictores y predictandos puede ser muy grande (ej., Rojas Campos et al. 2023). En particular se destacan arquitecturas complejas como las redes convolucionales, diseñadas para extraer eficientemente patrones espaciales y temporales. Por otra parte, la existencia de bases de datos globales sistematizadas, de pronósticos numéricos y observaciones, representa una oportunidad única para el entrenamiento de sistemas complejos de posprocesamiento basados en redes profundas, que puedan utilizar como predictores campos de diferentes variables sobre una región relativamente amplia.

El objetivo de este trabajo es diseñar, implementar y evaluar un modelo de aprendizaje automático basado en redes convolucionales profundas para el postprocesamiento de los pronósticos de precipitación. En particular, el modelo utiliza como predictores la precipitación acumulada en las 24 horas de pronóstico, estimada a partir de un modelo numérico global, y genera un campo de precipitación donde los sesgos del modelo numérico estén parcialmente corregidos. En la evaluación del modelo y en la selección de diferentes aspectos relacionados con el entrenamiento y la arquitectura, se pone particular énfasis en la detección de eventos de precipitación extrema, los cuales ocasionan grandes impactos socio-ambientales.

## 2) DATOS Y METODOLOGÍA

Las bases de datos utilizadas en este trabajo son, por un lado, el conjunto de pronósticos retrospectivos globales (GFS, Hamill et al. 2013), que provee pronósticos por ensambles a 2 semanas de plazo inicializados una vez al día y, por otro lado, las estimaciones

de precipitación basadas en la constelación de satélites de microondas pasivos (GSMaP, Kubota et al. 2020). Dichas estimaciones proveen precipitación acumulada a escala casi global con una resolución temporal de 30 minutos.

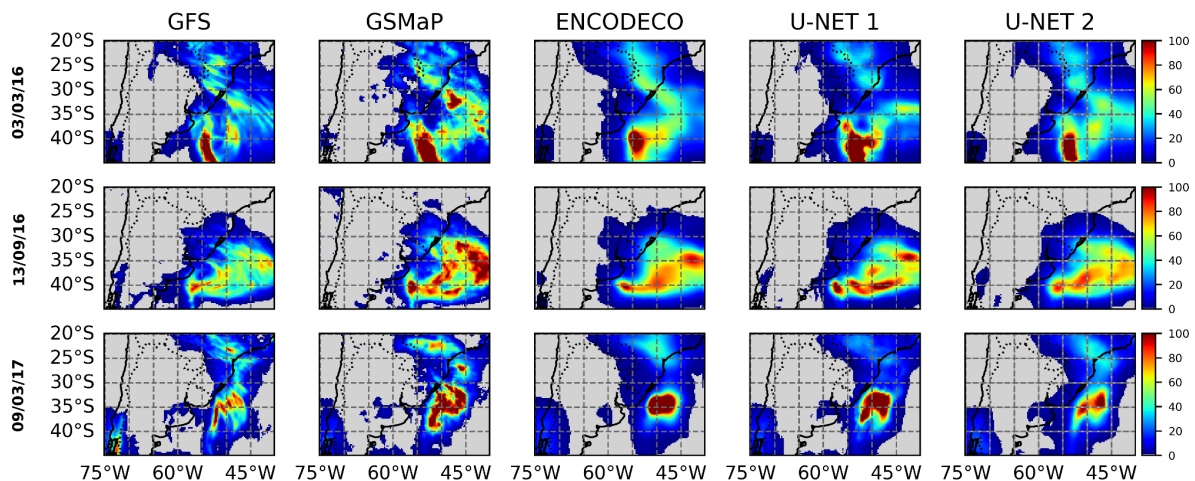
La metodología propuesta consiste en definir un modelo basado en aprendizaje automático entrenado con una estrategia de entrenamiento denominada modelo de control. A partir de esta configuración, se realizarán experimentos en los que se introducirán variaciones controladas en la arquitectura y en la configuración del entrenamiento. Es importante destacar que estas modificaciones se aplicarán de forma individual, de modo que cada experimento evalúe el impacto de un único factor sobre el desempeño del modelo resultante. Llamaremos hiperparámetros a aquellos parámetros cuyo valor afecta el proceso de entrenamiento del modelo (ej., la tasa de aprendizaje o el tamaño del batch). Por otro lado, los parámetros de diseño serán aquellos vinculados a los cambios en la arquitectura del modelo (ej., el tamaño de los kernels convolucionales o el número de canales utilizados en una capa de convolución). En este estudio se plantean dos arquitecturas: una de tipo Encoder-Decoder y U-Nets.

El desempeño de los modelos obtenidos en cada entrenamiento se evalúa utilizando diferentes métricas como el Equitable Threat Score (ETS), Frequency Bias (FB), Probability of Detection (POD) y False Alarms Ratio (FAR). Dado el interés en los eventos de precipitación extremos, se utiliza como criterio de selección el área bajo la curva ETS en rangos altos (superiores a los 100 mm acumulados por día) como medida integrada de rendimiento del modelo.

### **3) RESULTADOS**

La validación de los diferentes modelos muestra que los modelos basados en aprendizaje automático poseen un mejor desempeño en latitudes medias de Sudamérica, respecto a los pronósticos del GFS. En particular, los pronósticos corregidos a través de los modelos de machine learning produjeron mejores ETS para la totalidad de los umbrales de precipitación considerados, y mostraron un mejor desempeño a la hora de anticipar eventos de precipitación extrema (no se muestra). Por otra parte, en latitudes tropicales, los modelos basados en machine learning no pudieron superar el desempeño del modelo numérico en términos de los diferentes índices analizados.

A modo de ejemplo, en la Figura 1 se muestra la precipitación acumulada y pronosticada en tres eventos de precipitación intensa. En esta figura se comparan las predicciones obtenidas directamente del GFS (columna 1) y aquellas corregidas utilizando redes basadas en una arquitectura encoder-decoder (columna 3) y dos redes basadas en arquitecturas U-Net, una entrenada con una cantidad de épocas fija (columna 4) y otra entrenada utilizando un criterio de early stopping (columna 5). La técnica basada en la arquitectura Encoder-Decoder es más suave que las U-Nets, las cuales presentan mayor variabilidad espacial y extremos de precipitación más altos (sobre todo cuando son entrenadas durante una cantidad de épocas mayor a la que indica el criterio de early stopping utilizado). Esta característica es esperable, ya que las redes U-Net permiten representar mejor patrones con varias escalas espaciales. Las redes en general permiten mejorar la intensidad de los extremos de precipitación, aunque no introducen cambios significativos en su ubicación. Con respecto a las métricas de validación, la arquitectura encoder-decoder fue la que obtuvo los mejores resultados (no se muestra).



**Figura 1: Precipitación acumulada en 24 horas de acuerdo con: el pronóstico del modelo GFS a 24 horas de plazo (columna 1), la estimación de precipitación GSMaP (columna 2), la arquitectura encoder-decoder (columna 3), la arquitectura U-Net entrenada con una cantidad fija de épocas (columna 4) y la arquitectura U-Net entrenada con un criterio de early stopping.**

Los resultados obtenidos confirman el potencial de las técnicas de postprocesamiento basadas en redes neuronales. En trabajos futuros se desarrollarán modelos que permitan incorporar una mayor cantidad de predictores, ya sea provenientes de simulaciones numéricas globales o de otros conjuntos de datos.

#### 4) REFERENCIAS

- Hamill, T. M., Bates, G. T., Whitaker, J. S., Murray, D. R., Fiorino, M., Galarneau, T. J., Jr., Zhu, Y., & Lapenta, W. (2013).** NOAA's Second-Generation Global Medium-Range Ensemble Reforecast Dataset. *Bulletin of the American Meteorological Society*, 94(10), 1553-1565. <https://doi.org/10.1175/BAMS-D-12-00014.1>
- Kubota, T. et al. (2020).** Global Satellite Mapping of Precipitation (GSMaP) Products in the GPM Era. In: Levizzani, V., Kidd, C., Kirschbaum, D.B., Kummerow, C.D., Nakamura, K., Turk, F.J. (eds) *Satellite Precipitation Measurement*. Advances in Global Change Research, vol 67. Springer, Cham. [https://doi.org/10.1007/978-3-030-24568-9\\_20](https://doi.org/10.1007/978-3-030-24568-9_20)
- Rojas-Campos, A., Wittenbrink, M., Nieters, P., Schaffernicht, E. J., Keller, J. D., & Pipa, G. (2023).** Postprocessing of NWP Precipitation Forecasts Using Deep Learning. *Weather and Forecasting*, 38(3), 487-497. <https://doi.org/10.1175/WAF-D-21-0207.1>
- Vannitsem, S., and Coauthors, 2021:** Statistical Postprocessing for Weather Forecasts: Review, Challenges, and Avenues in a Big Data World. *Bull. Amer. Meteor. Soc.*, 102, E681–E699, <https://doi.org/10.1175/BAMS-D-19-0308.1>.