

GENERACIÓN DE PRONÓSTICOS PROBABILÍSTICOS DE PRECIPITACIÓN USANDO REDES NEURONALES

Maximiliano A. Sacco¹, Juan J. Ruiz^{2,3,4}, Manuel A. Pulido^{4,5}, Paola V. Salio^{2,3,4}

msacco@smn.gob.ar

¹ Servicio Meteorológico Nacional (SMN)

² Dep. de Cs. de la atmósfera y los océanos - FCEyN - UBA

³ Centro de Investigaciones del Mar y la Atmósfera (UBA-CONICET)

⁴ Instituto Franco-Argentino para el Estudio del Clima y sus Impactos (IRL
IFAECI/CNRS-IRD-CONICET-UBA)

⁵ Departamento de Física - FACENA-UNNE

Palabras clave: redes neuronales, incertidumbre, pronósticos probabilísticos, precipitación.

1) INTRODUCCIÓN

El pronóstico cuantitativo probabilístico de la precipitación sigue siendo un desafío crítico en meteorología debido a la naturaleza no gaussiana de las distribuciones de precipitación. Aunque técnicas como el promediado bayesiano de modelos (Bayesian Model Averaging, BMA) se han aplicado con éxito a los pronósticos por ensamble para variables meteorológicas como la temperatura [Raftery et al. 2005], su extensión a la precipitación requiere un tratamiento especial, como muestra [Sloughter et al. 2007]. Su enfoque combina la regresión logística para la probabilidad de precipitación con distribuciones gamma produciendo distribuciones de precipitación calibradas.

Este trabajo propone un enfoque innovador donde redes neuronales artificiales (RNA) son entrenadas con una función de costo basada en la verosimilitud negativa de la distribución gamma para generar pronósticos probabilísticos de precipitación a partir de campos simulados de reflectividad de radar.

2) METODOLOGÍA

La motivación surge de la necesidad de capturar la naturaleza altamente no lineal de la precipitación y proporcionar una estimación de la incertidumbre asumiendo una distribución gamma y estimando sus parámetros α (shape) y β (rate).

2.1) Datos y conjunto de entrenamiento

Se utilizan datos de reflectividad simulada con el ensamble de modelo WRF 4.0 operativo del Servicio Meteorológico Nacional. El conjunto de datos está formado por casos históricos de pronósticos horarios a 24hs inicializados 4 veces al día entre enero del 2020 y octubre del 2024 que tuvieran más de 10 píxeles con reflectividad mayor a 30 dbz en el dominio [longitud=-55 ~ -68 y latitud=-25 ~ -37].

De esta selección se obtuvieron 25424 campos de reflectividad por miembro representados por imágenes de 332 x 346 puntos y se reservó el 70% para el conjunto de entrenamiento, 20% para validación y 10% para el conjunto de verificación.

2.2) Arquitectura del modelo

Se implementa una red tal que en su entrada reciba un campo de reflectividad X_{radar} y su salida tenga 3 canales asociados a cada pixel de entrada: el primero (p) para la clasificación binaria del pixel en lluvia/no lluvia, y dos canales para estimar los parámetros α y β de la distribución gamma asociada a la probabilidad de precipitación. Así, una predicción de la red está dada por:

$$p, \alpha, \beta = f_{RNA}(X_{radar}).$$

En los experimentos preliminares, la arquitectura de red utilizada fue una red de 3 capas convolucionales de 32, 64 y 64 canales respectivamente, pero se están realizando experimentos para encontrar la arquitectura más adecuada para el problema.

2.3) Función de costo

En [Sacco et al 2022] se utilizó una función de costo basada en la distribución normal para estimar los parámetros de la distribución del error de pronóstico. Siguiendo la misma línea de trabajo, utilizamos la verosimilitud negativa de la distribución gamma para estimar los parámetros α y β con el agregado adicional del término correspondiente a la probabilidad de lluvia (p):

$$\mathcal{L}(Y|p, \alpha, \beta) = BCE(p, Y) + I_{Y \neq 0} [(1 - \alpha) \log Y + Y\beta - \alpha \log \beta + \log \Gamma(\alpha)]$$

donde **BCE** es la función de costo *Binary Cross Entropy*, Γ es la función gamma y $I_{Y \neq 0}$ la función indicador que vale 1 si $Y \neq 0$ y 0 si $Y = 0$.

3) ENFOQUE EXPERIMENTAL

Con el objetivo de evaluar la capacidad de las redes neuronales para aprovechar información espacial en la estimación probabilística de precipitación, diseñamos dos experimentos complementarios. En primer lugar, entrenamos una red neuronal convolucional (*espacial*) que procesa campos bidimensionales de reflectividad para estimar directamente los parámetros α y β de la distribución gamma que modela la probabilidad de precipitación. Como contrapunto, desarrollamos una segunda arquitectura que opera únicamente sobre valores escalares de reflectividad (*escalar*), manteniendo la misma salida paramétrica. Esta comparación nos permite discernir hasta qué punto el contexto espacial aporta información significativa para la caracterización probabilística de la precipitación.

Para contextualizar el desempeño de ambos modelos, establecemos dos líneas base de referencia: 1) la estimación de incerteza obtenida mediante un ensamble de modelos numéricos, y 2) la probabilidad condicional climatológica derivada de relaciones históricas entre reflectividad y tasa de precipitación (dBZ-R). Esta estructura experimental no sólo valida la utilidad de los enfoques basados en redes neuronales, sino que particularmente cuantifica el valor añadido de incorporar información espacial frente a aproximaciones tradicionales basadas en observaciones puntuales.

4) RESULTADOS PRELIMINARES

La fig. 1 muestra los resultados de los primeros experimentos donde se puede ver en la figura central superior, el histograma en gris correspondiente a los valores históricos de precipitación asociados, en este caso, al valor de reflectividad 33.27 correspondiente a la posición indicada por la cruz roja en el gráfico de reflectividad ubicado arriba a la izquierda. La curva azul corresponde a la distribución de probabilidad de precipitación correspondiente a los parámetros inferidos por la red *escalar* que vincula un único valor escalar de reflectividad con la precipitación. Es notable cómo esta distribución distribuye las probabilidades prácticamente igual al histograma climatológico. Este resultado es el esperable ya que el histograma y la red *escalar* vinculan los mismos datos de entrada con los de salida. La curva roja corresponde a la red *espacial* y a diferencia de la curva azul, asigna más masa a los valores altos de precipitación generando una cola de distribución más pesada. Esta diferencia en el comportamiento de ambas redes podría atribuirse al análisis de la vecindad del punto sugiriendo que grandes áreas de precipitación tienen más probabilidad de precipitar valores mayores.

Los gráficos de la parte inferior de la fig. 1 muestran, de izquierda a derecha, los campos de

probabilidad de superar un umbral de $2 \text{ (mm/h)} \frac{1}{3}$ de precipitación de la red *espacial* (derecha), la red *escalar* (centro) y la probabilidad producida por un ensemble de modelos numéricos de 20 miembros *ens* (derecha). En estos puede verse que la distribución espacial de probabilidad tanto en la red *espacial* como en el ensemble tienen bordes difusos indicando una incertidumbre espacial asociada, mientras que la red *escalar* presenta bordes bien marcados de áreas de precipitación y no precipitación lo que en principio no parece muy realista. Otra clara diferencia entre la red *espacial* y *escalar* es que la primera asocia valores más altos de probabilidad, similares a los pronosticados por el ensemble. Esto está en correlación con la cola más pesada de la distribución estimada en el gráfico superior central.

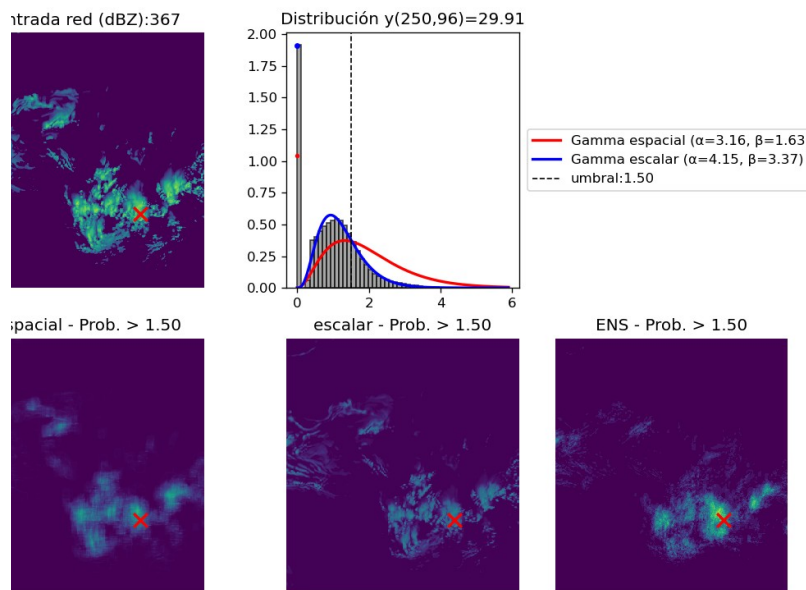


Figura 1: El gráfico superior izquierdo muestra el campo de reflectividad usado como entrada para la red. El gráfico superior central muestra en gris el histograma correspondiente a los valores de precipitación asociados a un valor de reflectividad (33.27dBZ) indicado por la cruz roja. Las líneas roja y azul representan respectivamente la distribución de probabilidad generado con los parámetros estimados por la red *espacial* y *escalar*. Los gráficos inferiores muestran los campos de probabilidad de superar un umbral reconstruidos a partir de la red *espacial* (izquierda), la red *escalar* (central) y un ensemble de modelos numéricos (derecha)

4) CONCLUSIONES

Los resultados sugieren que las redes son capaces de aprender los parámetros de la distribución de probabilidad de la precipitación comparado con los resultados obtenidos de un análisis climatológico y un ensemble de modelos numéricos. Por otro lado, la red *espacial* es capaz de integrar información del contexto y corregir la distribución asociada al punto geográfico en función de lo que ocurre en la vecindad del mismo. Estos resultados son muy alentadores pero necesitan ser corroborados con métricas estadísticas que permitan analizar el comportamiento general de estos pronósticos en distintas situaciones, como por ejemplo los diagramas de confiabilidad y CRPS entre otros.

AGRADECIMIENTOS:

Al Servicio Meteorológico Nacional, por proporcionar los datos y financiar la participación al congreso. Al proyecto de colaboración Suizo-Argentina **SPiRiT** por el financiamiento de la investigación que dio lugar a este trabajo.

REFERENCIAS

A. E. Raftery, T. Gneiting, F. Balabdaoui, and M. Polakowski. Using bayesian model averaging to calibrate forecast ensembles., 2005.

Maximiliano A. Sacco, Juan J. Ruiz, Manuel Pulido, and Pierre Tandeo. Evaluation of machine learning techniques for forecast uncertainty quantification. Quarterly Journal of the Royal Meteorological Society, 148(749):3470–3490, 2022.

J. Mc Lean Slaughter, Adrian E. Raftery, Tilmann Gneiting, and Chris Fraley. Probabilistic quantitative precipitation forecasting using bayesian model averaging. Monthly Weather Review, 135(9):3209 – 3220, 2007.