

# CUANTIFICACIÓN DE LA INCERTIDUMBRE EN PRONÓSTICOS NUMÉRICOS USANDO REDES NEURONALES

Maximiliano A. Sacco<sup>1</sup>, Pierre Tandeo<sup>2</sup>, Juan Jose Ruiz<sup>3,4</sup>, and Manuel Pulido<sup>6</sup>

<sup>1</sup>*Servicio Meteorológico Nacional Argentino*

<sup>2</sup>*IMT-Atlantique, Bretagne-France*

<sup>3</sup>*Departamento de Ciencias de la Atmósfera y los océanos - FCEyN - UBA*

<sup>4</sup>*Centro de Investigaciones del Mar y la Atmósfera (UBA-CONICET)*

<sup>5</sup>*UMI-IFAECI (CNRS-UBA-CONICET)*

<sup>6</sup>*Departamento de Física - FACENA-UNNE*

Palabras Clave: pronósticos probabilísticos, aprendizaje automático, estimación de error.

## 1 MOTIVACIÓN

Conocer la incertidumbre de un pronóstico es fundamental para la toma de decisiones en situaciones de riesgo donde una acción preventiva puede evitar daños materiales e incluso salvar vidas. El pronóstico por ensamble es, hasta ahora, el enfoque más exitoso para producir pronósticos probabilísticos de calidad. Esta metodología proporciona para cada pronóstico, una estimación de la incertidumbre asociada a los errores en las condiciones iniciales y en la formulación del modelo, pero tiene el coste de ejecutar el modelo numérico varias veces. Algunos estudios han explorado enfoques de bajo coste para estimar la incertidumbre de los pronósticos basados en técnicas de aprendizaje automático. [Scher and Messori, 2018] diseñó una red neuronal artificial (RNA) que aprendió la cuantificación de la incertidumbre a partir de un ensamble de pronósticos existente. [Camporeale et al., 2019] y [Wang et al., 2018] estimaron la incertidumbre directamente a partir de las observaciones, utilizando un nuevo tipo de funciones de pérdida que incluyen explícitamente la incertidumbre en su formulación. En este trabajo, utilizamos una función de pérdida basada en la verosimilitud para entrenar una RNA como en [Wang et al., 2018], para incorporar tanto una corrección en el componente de error sistemático, como una cuantificación de la incertidumbre del pronóstico corregido.

## 2 METODOLOGÍA

Se consideran dos RNA que proporcionan el primer y el segundo momento de la distribución de probabilidad del pronóstico, que se asume gaussiano. Ambas redes utilizan como entrada, un pronóstico determinístico de 3 plazos de tiempo ( $\{\mathbf{x}_0^d, \mathbf{x}_l^d, \mathbf{x}_L^d\}, 0 \leq l \leq L$ ), proporcionando información sobre la evolución dinámica del sistema a lo largo de una ventana de tiempo  $L$ . Nuestro objetivo es proporcionar la media del pronóstico  $\tilde{\mathbf{x}}_L$  (implícitamente el componente sistemático del error del

pronóstico, ya que se utiliza un pronóstico con el modelo físico como entrada), y estimar la varianza dependiente del estado del error del pronóstico,  $\tilde{\sigma}_L^2$ .

## 2.1 CONJUNTO DE ENTRENAMIENTO

El conjunto de entrenamiento de las RNA consiste en pares de datos (entrada, objetivo) para la entrada y la salida esperada de la red respectivamente.

Para construir este conjunto de datos se utilizaron los pronósticos retrospectivos version 2 de la presión a nivel del mar del National Centers for Environmental Prediction (NCEP) [Guan et al., 2022] disponible desde el 1° de enero de 2000 hasta el 31° de diciembre de 2019. Este conjunto de datos consiste en un ensamble global de 5 miembros (un pronóstico de control y 4 pronósticos perturbados) de 7302 pronósticos en total. Utilizamos 5096 para el entrenamiento, 1104 para la validación y 1102 para la verificación.

El plazo de pronóstico que se desea estimar es de 72hs, el cual se encuentra en la fase lineal del crecimiento del error. Para la entrada de la red usaremos los plazos 0, 36 y 72 horas del pronóstico de control. Como las condiciones iniciales (plazo cero) son análisis que representan el valor más cercano al estado verdadero de la atmósfera, estas son utilizadas como objetivo de entrenamiento.

El dominio seleccionado fue sobre el Atlántico Sur (55° W a 5° W y 60° S a 40° S) con una resolución de 2° dando lugar a una retícula de 10×10 puntos. Esta zona se encuentra dentro del flujo del oeste de latitudes medias y es bastante activa en términos de ondas baroclínicas, por lo que se espera una importante variabilidad en la incertidumbre de los pronósticos en esta zona.

## 2.2 ARQUITECTURA Y ENTRENAMIENTO DE LA RED NEURONAL

Se entrenaron dos RNA, una para la estimación del valor medio (pronóstico corregido) y otra para la estimación de la varianza. Ambas redes de arquitectura totalmente conectadas con dos capas ocultas de 500 neuronas cada una. El tamaño de la entrada y la salida viene determinado por el tamaño de la retícula del dominio y constan de  $3 \times 10 \times 10$  neuronas y  $10 \times 10$  respectivamente para ambas redes.

Ambas redes se entrenaron con el optimizador Adam [Kingma and Ba, 2017] y utilizando mini-batches con un tamaño de lote de 50 elementos. La función de pérdida se evalúa sobre el conjunto de validación cada 20 épocas de entrenamiento. El entrenamiento se detiene cuando la función de pérdida evaluada en el conjunto de validación deja de disminuir o empieza a aumentar (parada temprana).

## 3 RESULTADOS

La figura 1a muestra el análisis del 20 de junio de 2019 correspondiente a un ciclón extratropical intenso. Tanto el ensamble como la RNA sitúan la máxima desviación estándar del error en y al este del ciclón. La distribución espacial de la incertidumbre estimada por la RNA es más suave que la obtenida a partir del ensamble. Para la RNA parece haber una dependencia de la incertidumbre con el valor de la presión en superficie, con mayores incertidumbres asociadas a los sistemas de baja presión. Esto es de esperar, ya que los sistemas de baja presión presentan mayores tasas de profundización y también están asociados a fenómenos de pequeña escala (como la convección húmeda profunda) cuyo efecto no puede representarse con precisión en los modelos numéricos globales de última generación, lo que da lugar a una mayor contribución de los errores del modelo al error total en el pronóstico.




Figure 1: El panel (a) muestra el análisis de la distribución espacial de la presión normalizada a nivel del mar correspondiente al 20 de junio de 2019. Los paneles (b) y (c) muestran el error de pronóstico para el plazo 72hs (sombreado) y la desviación estándar del error estimada (contornos) por el método de ensambles (b) y por la RNA (c)

También se evaluaron otras métricas sobre la estimación de la RNA como el error cuadrático medio, y la probabilidad de cobertura (no mostradas) que confirman una reducción del error comparado con la media del ensamble y una estimación confiable de la varianza.

## 4 CONCLUSIONES

Las RNA son capaces de estimar el componente de error sistemático dependiente del estado asociado al efecto de los errores del modelo. Un aspecto importante relacionado con los experimentos presentados, es el uso de arquitecturas de red simples que no escalan bien con el tamaño de la entrada-salida de la red y de las capas ocultas. Al momento de presentar este resumen, se están realizando experimentos de pronóstico de niebla con otras arquitecturas que permitan un mejor escalamiento del problema, cuyos resultados serán presentados durante el congreso. Otra posibilidad para hacer frente al problema de la dimensionalidad es trabajar en dominios locales como se ha hecho ampliamente en el campo de la asimilación de datos [Carrassi et al., 2018].

## References

- [Camporeale et al., 2019] Camporeale, E., Chu, X., Agapitov, O. V., and Bortnik, J. (2019). On the generation of probabilistic forecasts from deterministic models. *Space Weather*.
- [Carrassi et al., 2018] Carrassi, A., Bocquet, M., Bertino, L., and Evensen, G. (2018). Data assimilation in the geosciences: An overview of methods, issues, and perspectives. *WIREs Climate Change*, 9(5):e535.
- [Guan et al., 2022] Guan, H., Zhu, Y., Sinsky, E., Fu, B., Li, W., Zhou, X., Xue, X., Hou, D., Peng, J., Nageswararao, M. M., Tallapragada, V., Hamill, T. M., Whitaker, J. S., Bates, G., Pegion, P., Frederick, S., Rosencrans, M., and Kumar, A. (2022). Gefsv12 reforecast dataset for supporting subseasonal and hydrometeorological applications. *Monthly Weather Review*, 150(3):647 – 665.
- [Kingma and Ba, 2017] Kingma, D. P. and Ba, J. (2017). Adam: A method for stochastic optimization.
- [Scher and Messori, 2018] Scher, S. and Messori, G. (2018). Predicting weather forecast uncertainty with machine learning. *Quarterly Journal of the Royal Meteorological Society*.
- [Wang et al., 2018] Wang, B., Lu, J., Yan, Z., Luo, H., Li, T., Zheng, Y., and Zhang, G. (2018). Deep uncertainty quantification: A machine learning approach for weather forecasting.