

USO DE INTELIGENCIA ARTIFICIAL PARA MEJORAR LA PREDICCIÓN DE MODELOS NUMÉRICOS METEOROLÓGICOS

Eduardo Gutiérrez¹ Sebastián Villarroya¹ José M. Cotos¹

¹Grupo COGRADE, Universidad de Santiago de Compostela

RESUMEN

La predicción meteorológica en general es un campo de estudio muy importante, tanto por su complejidad como por su importancia. En concreto, la cantidad de lluvia es especialmente difícil de predecir, y es de vital importancia para una gran cantidad de casos (p. ej. aviación, prevención de catástrofes, gestión de cultivos, y no sólo los terrestres sino también los marinos, etc.). Los métodos tradicionales, llamados “numéricos”, requieren grandes recursos de computación, haciendo que cada cálculo lleve varias horas incluso en súpercomputadores como el Finisterrae III, de CESGA. Para mejorar, no sólo la precisión de predicción de cantidad de lluvia, en los últimos años han aparecido técnicas de inteligencia artificial que permiten mejorar la predicción de esos modelos numéricos. En este artículo mostramos unas técnicas que han dado como resultado una mejora apreciable en esa predicción de caudal.

Para varias estaciones meteorológicas de MeteoGalicia, hemos seleccionado cuadrículas de 3x3 de la salida del modelo numérico, y hemos entrenado redes neuronales probabilísticas usando como referencia verdadera la predicción de lluvia en la correspondiente estación meteorológica.

Comparando las salidas de las redes neuronales con la del modelo, hemos visto que los datos de predicción proporcionados por las redes neuronales son más próximos a las mediciones de las estaciones meteorológicas.

Por tanto, hemos comprobado que, tal como ha sido publicado en otros estudios de uso de inteligencia artificial para mejorar predicciones meteorológicas, es posible usar redes neuronales probabilísticas para mejorar la salida del modelo numérico de MeteoGalicia, obteniendo así una predicción más precisa del caudal de lluvia.

Palabras y frases clave: predicción meteorológica – inteligencia artificial – redes neuronales probabilísticas - MeteoGalicia

1. INTRODUCCIÓN

La predicción meteorológica moderna combina observaciones, asimilación de datos y la integración numérica de las ecuaciones físicas que gobiernan la dinámica atmosférica. A pesar de las mejoras en resolución y representación física de los modelos NWP en las últimas décadas (Bauer et al., 2015), los pronósticos continúan mostrando sesgos sistemáticos y errores de representación, especialmente para la precipitación, ya que esta suele producirse de forma muy localizada y con gran variabilidad en poco tiempo. El postprocesado de las salidas de los modelos es, por tanto, una etapa esencial en el flujo de predicción, ya que permite corregir sesgos, introducir ajustes a escala local y ofrecer productos con mayor utilidad práctica para aplicaciones hidrológicas y operativas (Glahn & Lowry, 1972; Vannitsem et al., 2021).

Las técnicas de aprendizaje automático, y en particular las redes neuronales profundas, han demostrado ser herramientas potentes para el postprocesado. Estas técnicas son capaces de descubrir relaciones complejas entre las variables de entrada y las observaciones sin necesidad de definir de antemano cómo deben ser esas relaciones (Goodfellow et al., 2016). Estudios recientes han mostrado que los métodos basados en redes neuronales pueden superar a técnicas clásicas en la




Figura 1: Área de interés: Cuenta del río Ulla. 12 estaciones meteorológicas. Datos de predicción: 324 (36x9). Periodo: 2012–2022. (a) Mapa de las estaciones; (b) Mapa de las rejillas 3x3 de WRF usadas en cada estación.

corrección de sesgos y en la generación de predicciones probabilísticas para variables meteorológicas, incluyendo trabajos específicos para precipitación y para la estimación de salidas probabilísticas que cuantifican incertidumbre de forma coherente (Rasp & Lerch, 2018; Rojas-Campos et al., 2023).

En este trabajo utilizamos datos regionales y aplicamos técnicas de posprocesado estadístico y de aprendizaje automático para mejorar las predicciones horarias de precipitación proporcionadas por el modelo numérico de MeteoGalicia (el WRF), en zonas correspondientes a 12 estaciones meteorológicas. Son descritos los datos empleados, el preprocesado realizado y las metodologías de modelado aplicadas, incluyendo tanto métodos clásicos como redes neuronales.

A continuación se presentan los resultados comparativos de los distintos modelos en las estaciones seleccionadas y se discute su capacidad para reducir el error respecto a la predicción numérica original. Finalmente, se ofrecen conclusiones y se señalan posibles líneas de mejora y trabajo futuro.

2. DATOS

Los datos empleados proceden del modelo numérico Weather Research and Forecasting (WRF) que MeteoGalicia ejecuta de forma rutinaria para la región de Galicia. MeteoGalicia ejecuta el modelo WRF dos veces al día, obteniendo así distintas variables atmosféricas (temperatura, viento en diferentes niveles, precipitación acumulada, humedad, presión al nivel del mar, etc.), que son utilizadas tanto en aplicaciones operativas (meteorología, oleaje, modelado oceanográfico) como en estudios de investigación y validación. Los ficheros resultantes están accesibles mediante servicios THREDDS y a través de la API MeteoSIX, lo que facilita la descarga automática de ficheros NetCDF/GRIB y el acceso a series temporales o a puntos concretos de la malla.

Para nuestro trabajo hemos usado las salidas de la malla de 4 km (la d03 en la nomenclatura de WRF) como conjunto de predictores para el posprocesado de la precipitación horaria en estaciones. La elección de esta resolución responde a un compromiso entre resolución espacial suficiente para captar la orografía y la variabilidad espacial de la precipitación en Galicia, y los requisitos computacionales y de almacenamiento para manejar series largas. Los ficheros WRF contienen tanto variables de superficie como campos tridimensionales en niveles sigma. Para nuestro objetivo extraemos 36 variables, como por ejemplo precipitación acumulada, velocidad y dirección del viento en superficie, y parámetros termodinámicos relevantes en los primeros niveles atmosféricos. Estos datos son extraídos sólo en rejillas de 3x3 celdas, centradas en 12 estaciones meteorológicas cuyos datos son usados como referencia para saber qué predicción es la más acertada, ya que los datos de las estaciones son los datos medidos.

Además, MeteoGalicia mantiene un archivo histórico accesible que permite construir conjuntos de entrenamiento y validación para modelos de aprendizaje automático. Este archivo ofrece datos

Tabla 1: Selección de características — ejemplo por estación (Muralla).

ESTACIÓN	CARACTERÍSTICAS TOTALES	MÉTODO SELECCIÓN	CARACTERÍSTICAS SELECCIONADAS
Muralla	324	Regresión LASSO	23
		Selección secuencial (scikit-learn)	20
		Selección secuencial (mlxtend)	119
		RFECV (estimador: Random Forest)	291




Figura 2: Comparativa del MSLE obtenido por los distintos modelos de posprocesado aplicados a la estación de Muralla (2012–2022).

en diferentes escalas temporales (horarias y de mayor resolución), lo que facilita la creación de bases de datos consistentes para entrenar y evaluar los modelos presentados en este estudio.

3. METODOLOGÍA

El trabajo parte de un conjunto amplio de predictores extraídos de un modelo numérico regional. En total se consideraron 324 variables obtenidas en una vecindad alrededor de cada estación. Dado el elevado número de entradas y la correlación espacial entre ellas, la metodología se organizó en dos bloques claramente diferenciados: (i) métodos clásicos para selección de variables y referencia de posprocesado, y (ii) redes neuronales para el ajuste final condicionado a las variables seleccionadas.

En el primer bloque se emplearon modelos clásicos (Random Forest, regresión lineal, AdaBoost, Histogram Gradient Boosting y Voting Regression) tanto para medir capacidad predictiva como, sobre todo, para identificar las variables más relevantes por estación. La selección se realizó de forma independiente para cada estación mediante técnicas como LASSO y Random Forest. El objetivo fue reducir las 324 variables iniciales a un subconjunto manejable y específico por estación que preservara la mayor parte de la información predictiva. A modo de ejemplo, para la estación **Muralla** se muestran en la Tabla 1 los resultados de distintos métodos de selección y el número de características retenidas por cada uno.

Las variables seleccionadas por los métodos clásicos se utilizaron después como entrada para los modelos de referencia y para las redes neuronales, de modo que las comparaciones entre enfoques se hicieran partiendo de representaciones predictoras equivalentes. Los modelos clásicos también se entrenaron y evaluaron contra la predicción original del modelo numérico para estimar las ganancias aportadas por el posprocesado estadístico.

En el segundo bloque se diseñaron y entrenaron redes neuronales densas para el postprocesado puntual de precipitación. Se trabajó con dos variantes de red (dos modelos finales) que comparten la idea general de mapear las entradas seleccionadas a la precipitación horaria observada en la estación. Las redes se entrenaron con el optimizador Adam, usando técnicas estándar de regularización (parada temprana basada en validación, normalización de entradas y control de la tasa de aprendizaje). Cada una de las dos redes se entrenó con su propio conjunto de datos (partición entrenamiento/validación/test), y se registraron las curvas de pérdida durante todo el proceso para controlar convergencia y posible sobreajuste.




Figura 3: Curvas de pérdida (entrenamiento y validación) para las dos variantes de redes.

4. RESULTADOS

Modelos clásicos. La Figura 2 muestra una comparativa del *error cuadrático medio logarítmico* (MSLE) obtenido por varios modelos de posprocesado clásico en la estación de Muralla durante el período 2012–2022. En esta figura se observa que todos los modelos estadísticos probados (regresión lineal, Random Forest, AdaBoost, Histogram Gradient Boosting y un ensamble *Voting Regression*) consiguen valores de MSLE inferiores al de la predicción original del modelo numérico sin posprocesado. Es decir, cada método reduce sustancialmente el error respecto a la salida bruta del WRF, lo que indica que el posprocesado estadístico mejora de forma clara la precisión de las predicciones de precipitación. Se aprecian diferencias entre los algoritmos: los enfoques más complejos (como los métodos de *ensemble* y boosting) logran las mayores reducciones de error, mientras que incluso el modelo lineal sencillo supera a la predicción sin ajustar. En conjunto, la Figura 2 evidencia la capacidad de los métodos clásicos para corregir sesgos y disminuir el error de predicción en esta estación de ejemplo, adelantando mejoras similares en las demás estaciones analizadas.

Curvas de entrenamiento. Las Figuras 3a y 3b presentan las curvas de pérdida durante el entrenamiento y validación para las dos variantes de la red neuronal desarrollada (variantes A y B, respectivamente). Ambas redes muestran una convergencia estable de la función de pérdida a lo largo de las épocas: tanto en entrenamiento como en validación, el valor de la pérdida desciende progresivamente hasta estabilizarse, sin indicios de sobreajuste pronunciado. Al comparar las dos gráficas, se aprecia que la variante B alcanza un nivel de pérdida final más bajo que la variante A en ambos conjuntos (entrenamiento y validación), lo que indica que B logra un ajuste más efectivo a los datos. Dicho de otro modo, la red B no sólo converge, sino que termina ofreciendo un error menor en comparación con la red A, sugiriendo una mayor capacidad de esta arquitectura para modelar la relación entre las variables predictoras seleccionadas y la precipitación observada. Este comportamiento superior de la variante B puede deberse a diferencias en su diseño (por ejemplo, una arquitectura más profunda o hiperparámetros optimizados), lo que le permite capturar con mayor fidelidad las pautas presentes en los datos.

Resumen interpretativo. En síntesis, los resultados indican que el posprocesado estadístico aporta beneficios claros frente a la predicción directa del modelo numérico sin ajuste. Los métodos clásicos reducen significativamente el error de las estimaciones de lluvia en las estaciones estudiadas, con mejoras especialmente notables en algunos emplazamientos. Por su parte, las redes neuronales profundas entrenadas también logran mejorar la predicción: ambas variantes convergen correctamente y producen salidas más próximas a las mediciones reales que las del modelo WRF original. En particular, la variante B demuestra un desempeño superior (menor pérdida y, por tanto, mayor precisión), lo que sugiere que las técnicas de aprendizaje profundo pueden captar mejor las relaciones no lineales complejas entre las variables meteorológicas de entrada y la precipitación observada. En conjunto, el uso de inteligencia artificial –desde algoritmos de aprendizaje

automático clásicos hasta redes neuronales profundas— permite refinar la predicción numérica de precipitación, obteniendo pronósticos más acordes con la realidad medida en las estaciones que aquellos proporcionados únicamente por el modelo numérico bruto.

5. CONCLUSIONES

Este estudio mostró que la aplicación de técnicas de inteligencia artificial para el posprocesado de las predicciones numéricas de precipitación con WRF en Galicia proporciona mejoras tangibles en la calidad del pronóstico. Tanto los modelos clásicos de regresión y aprendizaje automático como las redes neuronales profundas lograron reducir el error de las predicciones horarias de lluvia respecto a la salida original de MeteoGalicia. En particular, la mejor de las redes neuronales desarrolladas (variante B) alcanzó la mayor precisión, superando a los métodos tradicionales en la corrección de los valores de precipitación. Estos hallazgos confirman el poder del posprocesado estadístico basado en aprendizaje automático para corregir sesgos y errores de representación en los modelos numéricos, resultando en pronósticos más fiables. De hecho, nuestros resultados concuerdan con trabajos previos en la literatura: por ejemplo, estudios recientes han encontrado que las redes neuronales profundas pueden superar a los métodos convencionales al ajustar pronósticos de precipitación y generar predicciones más acertadas. En particular, Rojas-Campos et al. (2023) aplicaron técnicas de *deep learning* al posprocesado de pronósticos de lluvia y también reportaron reducciones significativas del error frente a los modelos numéricos puros, en línea con lo observado en nuestro caso. Este paralelismo con investigaciones como la de Rojas-Campos et al. refuerza la validez de nuestro enfoque y demuestra que la incorporación de algoritmos de inteligencia artificial es una vía efectiva para mejorar las predicciones meteorológicas de precipitación.

Finalmente, se identifican varias posibles líneas de mejora y extensión futura de este trabajo. Por un lado, sería interesante explorar arquitecturas de redes neuronales más avanzadas, como redes neuronales convolucionales o recurrentes, que aprovechen mejor la estructura espacio-temporal de los datos de entrada (por ejemplo, capturando la información espacial de las rejillas vecinas o la evolución temporal de la lluvia). Este tipo de arquitecturas podrían aumentar aún más la habilidad del modelo para reconocer patrones de precipitación locales. Por otro lado, una ampliación natural sería aplicar el enfoque a predicciones por conjuntos (*ensemble*) para generar pronósticos probabilísticos de precipitación. Incorporar la incertidumbre mediante posprocesado probabilístico permitiría estimar no sólo un valor puntual de lluvia, sino también la probabilidad de distintos escenarios (algo crucial para la gestión de riesgos hidrológicos), siguiendo las recomendaciones de trabajos recientes en posprocesado meteorológico. Asimismo, conviene evaluar el desempeño del modelo con eventos extremos de precipitación y diferentes regiones, garantizando que las mejoras se mantengan bajo diversas condiciones meteorológicas. En resumen, las conclusiones de este estudio evidencian el beneficio de integrar inteligencia artificial en la predicción meteorológica operativa, y abren la puerta a futuras investigaciones orientadas a perfeccionar y extender este posprocesado, ya sea mediante metodologías más sofisticadas o mediante su aplicación a nuevos contextos y variables de interés.

AGRADECIMIENTOS

Este trabajo ha sido realizado con la ayuda de la convocatoria de Grupos de Potencial Crecimiento de la Xunta de Galicia ED431B 2024/44, y del Programa de Ciencias Marinas de Galicia, que forma parte de los Planes Complementarios de Ciencia para Ciencias Marinas del Ministerio de Ciencia, Innovación y Universidades, incluidos en el Plan de Recuperación, Transformación y Resiliencia (PRTR-C17.I1), financiado a través de la Xunta de Galicia con fondos NextGenerationEU y del Fondo Europeo Marítimo de Pesca y de Acuicultura.

REFERENCIAS

- Bauer, P., Thorpe, A., and Brunet, G. (2015) The quiet revolution of numerical weather prediction. *Nature*, 525, 47–55.
- Glahn, H. R. and Lowry, D. A. (1972) The Use of Model Output Statistics (MOS) in Forecasting. *J. Appl. Meteor.*, 11, 1203–1211.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016) *Deep Learning*. MIT Press.

- Rasp, S. and Lerch, S. (2018) Neural networks for postprocessing ensemble weather forecasts. *Mon. Wea. Rev.*, 146, 3885–3900.
- Rojas-Campos, A., Wittenbrink, M., Nieters, P., Schaffernicht, E. J., Keller, J. D., and Pipa, G. (2023) Postprocessing of NWP Precipitation Forecasts Using Deep Learning. *Weather and Forecasting*. doi:10.1175/WAF-D-21-0207.1.
- Vannitsem, S., et al. (2021) Statistical postprocessing for weather forecasts: Review, challenges, and avenues in a big data world. *Bull. Amer. Meteor. Soc.*, 102, E681–E699.