

USO DE REDES NEURONALES PARA LA IDENTIFICACIÓN DE LAS SITUACIONES SINÓPTICAS DE FONT

USING NEURAL NETWORKS FOR IDENTIFYING FONT SYNOPTIC SITUATIONS

Jaime Castro Arias⁽¹⁾, Francisco Javier Bello Millán^(1,2), Álvaro Subías Díaz-Blanco⁽¹⁾, Juan Andrés García-Valero⁽¹⁾

⁽¹⁾ Agencia Estatal de Meteorología, C/ Leonardo Prieto Castro 8, Madrid, jcastroa@aemet.es

⁽²⁾ Universidad de Málaga, Escuela de Ingenierías Industriales, Málaga

SUMMARY

Synoptic classifications serve as powerful tools for understanding the atmospheric dynamics that influence climatic variability in a specific region. Inocencio Font's classification, comprising 23 synoptic situations, summarizes the dominant circulation patterns over the Iberian Peninsula and the Balearic Islands. Since 2020, the Techniques and Applications for Forecasting Area (ATAP, by its Spanish acronym) at Aemet has subjectively classified each day's synoptic situation according to the most representative Font's situation. Automating this task could facilitate expanding the classification to encompass broader time periods, including medium and long-range forecasting, reanalysis or climate projections. To this end, this study presents the development of an automatic classifier comprising 10 artificial neural networks. These networks utilize mean sea level pressure and geopotential at 500hPa as input variables, emulating ATAP's procedure. The results show the assigned synoptic patterns reflect accurately the expected weather based on Font's classification.

Las clasificaciones sinópticas catalogan dentro de una serie de patrones la situación sinóptica de un determinado lugar. Son herramientas muy útiles para entender la dinámica atmosférica que condiciona la variabilidad climática de un territorio. En consecuencia, pueden ser empleadas para estudios climatológicos, predicción meteorológica, proyecciones climáticas, así como para fines divulgativos y comunicativos.

La clasificación sinóptica de Inocencio Font Tullot es una clasificación de tipo subjetivo desarrollada para la península ibérica y Baleares. En ella se identificaron 23 patrones sinópticos que en general resumen la dinámica atmosférica dominante sobre nuestro entorno. La clasificación se basó en el conocimiento profundo del autor, el cual hizo uso de los análisis diarios de situaciones sucedidas durante la década de los años 70 del siglo pasado [1]. Desde 2020, en el Área de Técnicas y Aplicaciones de Predicción de la Agencia Estatal de Meteorología se asigna subjetivamente la situación sinóptica de cada día a aquella situación de Font en la que estaría representada. Esta asignación se basa principalmente en los mapas sinópticos definidos por las variables presión al nivel del mar y altura geopotencial en 500hPa correspondientes a los análisis del modelo HRES-IFS de las 12 UTC. El resultado de esta clasificación para el periodo 2020-2023 se muestra en la Figura 1.a), en la que se representa el histograma del número de días asignados a cada patrón sinóptico.




Figura 12 – a) Histograma del número de días asignados de forma subjetiva a cada patrón de la clasificación de Font durante el periodo 2020-2023. b) Esquema de la arquitectura de la red neuronal convolucional empleada en este trabajo.

La automatización de esta actividad posibilitaría extender la clasificación de Font a un período de tiempo largo, como podría ser a un período de reanálisis o de proyecciones climáticas. También podría aplicarse a los miembros de un ensemble de medio plazo, como puede ser a los miembros del ENS-IFS, lo cual podría ser de utilidad para evaluar la incertidumbre del marco sinóptico previsto. En el actual contexto de auge de las técnicas de Machine Learning (en adelante, ML), estas constituyen una herramienta adecuada para tal fin propuesto, dada su reconocida habilidad en tareas de reconocimiento de patrones [2].

En Chattopadhyay et al. [3], se describe el desarrollo de un clasificador de situaciones sinópticas basado en CNNs. En este caso se entrenaba a la red para que aprendiera a clasificar entre 4 patrones generales usando para ello los resultados de una clasificación de tipo objetivo. Tomando como referencia este trabajo y, partiendo de los resultados de la clasificación llevada a cabo en el ATAP, se ha procedido a entrenar un buen número de redes neuronales convolucionales haciendo uso de los campos diarios de presión a nivel del mar y de altura geopotencial en 500 hPa procedentes de los reanálisis de ERA5. En la Figura 1.b), se muestra la arquitectura CNN usada en este estudio, la cual está formada por 4 capas convolucionales, 2 capas de *max-pooling* y una red neuronal artificial con una capa oculta intermedia. Para buscar una combinación óptima de hiperparámetros se han entrenado múltiples CNNs, quedándonos con aquellas 10 estructuras que mejores resultados ofrecen en un período distinto al que fueron entrenadas. Así, las salidas de estas 10 CNNs se han usado para la asignación de la situación como si se tratara de un ensemble.

Los resultados del ensemble muestran una precisión de 100% para el set de entrenamiento y un 63% para el set de test, mostrando una clara tendencia al sobreajuste. Si ofrecemos al clasificador 3 posibilidades, la precisión aumenta hasta 82% en el set de test.

Para verificar las salidas del ensemble clasificador se han obtenido los patrones de anomalías de precipitación asociados a cada una de las situaciones asignadas por el clasificador en un período distinto al que se usó para su entrenamiento, observándose en general una coherencia física entre las anomalías de precipitación y los Tipos de Font asignados por nuestro clasificador: A modo de ejemplo, en la Figura 2 se muestran los patrones de anomalías correspondientes a las situaciones de Font, 12 (a) y 13 (b). El tipo 12, conocido como *depresión atlántico-ibérica*, está relacionado con el desarrollo de bajas en el Atlántico, al oeste de la Península asociado al desarrollo de precipitaciones que afectan en mayor medida a la fachada atlántica peninsular. Por contra, el tipo 13 se corresponde con la situación de *depresión del golfo de Cádiz*, asociada a precipitaciones más destacables sobre la mitad sur de la Península y vertiente mediterránea, pudiendo ser muy intensas en el Levante y sudeste, mientras que hacia el noroeste las precipitaciones son escasas.

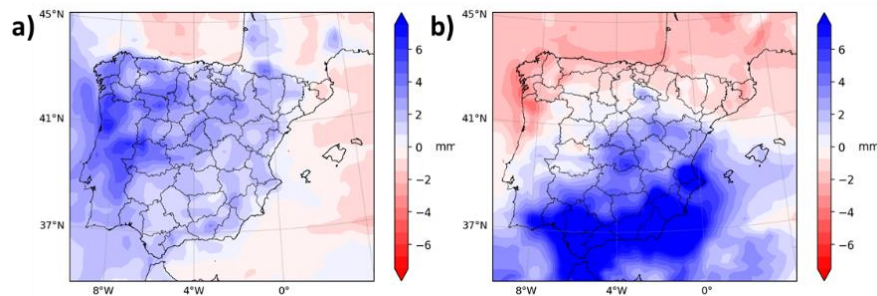


Figura 13 - Anomalías de precipitación obtenidas durante los días en los que el clasificador asignó el marco sinóptico a las situaciones de Font 12 (depresión atlántico-ibérica, a) y 13 (depresión en el golfo de Cádiz, b).

Este trabajo representa una primera incursión en la resolución del problema planteado, abriendo la puerta a futuras exploraciones. El rendimiento del clasificador se beneficiaría significativamente del aumento del tamaño de la muestra de entrenamiento, derivado de distintas pruebas efectuadas. Las aplicaciones potenciales de este clasificador son diversas, desde su uso aplicado a los miembros del ENS-IFS en el medio plazo, hasta su aplicación a un reanálisis o a proyecciones de cambio climático que serviría para analizar cambios pasados y futuros en la dinámica atmosférica sobre nuestro territorio.

REFERENCIAS

- Chase, R. et al. (2022): *A Machine Learning Tutorial for Operational Meteorology. Part I: Traditional Machine Learning*. Wea. Forecasting, 37, 1509–1529, doi: 10.1175/WAF-D-22-0070.1.
- Chattopadhyay, A., Hassanzadeh, P., Pasha, S. (2020): *Predicting clustered weather patterns: A test case for applications of convolutional neural networks to spatio-temporal climate data*. Scientific Reports, 10(1317), doi: 10.1038/s41598-020-57897-9
- Tullot, I. F. (2000): *Climatología de España y Portugal* (Vol. 76). Universidad de Salamanca.