

USO DE MODELOS BASADOS EN REDES NEURONALES RECURRENTE PARA EL PRONÓSTICO DE TEMPERATURA MEDIA MENSUAL EN ARGENTINA

Paula Oliveri¹, Marcela González²

poliveri@at.fcen.uba.ar. Autora correspondiente.

¹Departamento de Ciencias de la Atmósfera y los Océanos (FCEN, UBA)

²Centro de Investigaciones del Mar y la Atmósfera (CONICET-UBA)

Palabras clave: pronóstico estacional, LSTMs, redes neuronales convolucionales.

1) INTRODUCCIÓN

Diferentes tipos de redes neuronales como perceptrón multicapa (MLP), redes neuronales recurrentes (RNN), long short-term memory (LSTM), redes neuronales convolucionales (CNN), etc., se han empleado en los últimos años para diseñar modelos de pronóstico de temperatura media en distintas escalas, con resultados muy prometedores (Tran et al., 2021). Dada la importancia de la predicción de la temperatura media, variable que afecta el consumo energético (Gil et al., 2005), durante el presente trabajo fueron desarrollados modelos de pronóstico para esta variable en escala mensual. Dichos modelos estuvieron basados en LSTMs y combinaciones de éstas con otros tipos de RNNs y con CNNs, para cinco estaciones meteorológicas de distintas regiones de Argentina.

2) DATOS Y METODOLOGÍA

Se desarrollaron modelos de pronóstico de temperatura media mensual basados principalmente en redes neuronales recurrentes del tipo *Long short-term memory* (LSTM), para las estaciones meteorológicas: OCBA, Salta Aero, Posadas Aero, Córdoba Obs., y Comodoro Rivadavia Aero, cada una representativa de una región diferente de Argentina. Las LSTM se estudiaron en combinación con *Gated recurrent units* (GRUs), *Bidirectional LSTM* (BLSTM) y *Convolutional Neural Networks* (CNN), generando modelos de diversas arquitecturas.

Los siguientes datos fueron utilizados como inputs para las redes neuronales:

- a) Observaciones de estaciones meteorológicas de la red del Servicio Meteorológico Nacional.
- b) Índices de oscilaciones climáticas de gran escala provenientes de los datasets NOAA Climate Prediction Center, KNMI Climate Explorer y Joint Institute for the Study of the Atmosphere and Ocean (JISAO).
- c) Índices que representan posición e intensidad de los anticiclones del Atlántico y Pacífico (AA y AP) definidos por Garbarini (2016). Los datos de altura geopotencial empleados pertenecen al reanálisis ERA5 (Hersbach et al., 2019)
- d) Otros varios índices definidos especialmente para este trabajo, que representan la variabilidad de los vientos meridionales de capas bajas (Oliveri y González, 2022), por un lado, y la variabilidad de la temperatura de superficie del mar de los océanos Pacífico y Atlántico cercanos a la región, por otro. Los datos utilizados para su cálculo pertenecen al reanálisis ERA5.

Los parámetros de los modelos se obtuvieron utilizando el período de entrenamiento 1980-2010. Para cada estación meteorológica por separado se realizó el ajuste de hiperparámetros en base al período de validación 2011-2016, teniendo en cuenta diferentes combinaciones de: funciones de activación, número de nodos, batch size, número de capas, dropout, entre otros. Las métricas consideradas para evaluar los modelos fueron: el RMSE y el RMSEs (skill score; con respecto a la climatología). La longitud temporal de los inputs se fijó en 2 meses, ya que en general se obtuvieron mejores resultados que con 1 y 3. Para cada estación meteorológica por separado se realizó una selección de predictores utilizando un algoritmo de *Permutation Feature Importance* (Fisher et al., 2019), el cual logró disminuir el tamaño del conjunto inicial de predictores, sin incrementar significativamente el error. Los años 2017 y 2018 fueron destinados a test.

3) RESULTADOS

La mejora de los modelos con respecto a la climatología fue en forma general muy leve, lo que se evidencia a partir de la dificultad de los mismos para representar los valores extremos. Los valores de RMSE para el período de validación (2011-2016) tuvieron valores entre 1.04 y 1.30°C, dependiendo de la estación. Para cada estación se eligieron los mejores modelos en base al valor de RMSEs de validación, para poder evaluar un ensamble además de cada modelo individual. La cota para elegir dichos modelos fue un RMSEs de 0.07, excepto para Córdoba Obs. que se tomó la cota de 0.04 debido a que los modelos tuvieron un desempeño inferior para esta estación, e incluso en ese caso sólo dos modelos la superaron. En la Fig.1 se muestra la serie de temperatura media mensual pronosticada por la media del ensamble, para la estación Comodoro Rivadavia Aero en el período de validación (el resto de las estaciones no se muestran). El ensamble de modelos también fue evaluado para el período de test (2017-2018). Aunque los RMSE para este último resultaron mayores a los del período de validación, también se observó una cierta mejora con respecto al pronóstico por climatología, sobre todo para la estación Posadas Aero. En la Tabla I se muestran los valores obtenidos de RMSE y RMSEs para la media del ensamble de cada estación, para los períodos de validación y test.




Figura 1. Series de temperatura media mensual de la estación Comodoro Rivadavia para el período 2011-2016: observada (negro), climatología (lila) y pronosticada por la media del ensamble (gris).

ESTACIÓN	Validación		Test	
	RMSE (°C)	RMSEss	RMSE (°C)	RMSEss
OCBA (7)	1.11	0.07	1.48	0.09
SALTA AERO (10)	1.12	0.08	1.65	0.08
POSADAS AERO (4)	1.21	0.09	1.45	0.22
CÓRDOBA OBS (2)	1.26	0.04	1.64	0.05
COMODORO RIVADAVIA AERO (14)	1.04	0.09	1.28	0.06

Tabla I. Valores de RMSE y RMSEss para la media del ensamble de cada estación. En la primera columna, entre paréntesis, se indica la cantidad de modelos en cada caso.

4) CONCLUSIONES

Los modelos de pronóstico de temperatura media mensual basados en redes neuronales recurrentes LSTM y distintas arquitecturas que combinan este tipo de redes con otras como GRU, BLSTM y CNN, que fueron estudiados en el presente trabajo, han logrado una mejora muy leve con respecto al pronóstico por climatología, en la mayoría de los casos en menos de 10 puntos porcentuales de RMSE. Esto es consecuente con la dificultad de los mismos para representar los valores extremos. No obstante, como parte de trabajo futuro, se seguirá intentando mejorar los resultados obtenidos, incluyendo el uso de otros hiperparámetros que aún no fueron abordados.

AGRADECIMIENTOS

A los proyectos UBACyT 20020190100090BA y CONICET 11220210100282CO por la financiación.

Al Servicio Meteorológico Nacional, ECMWF, NOAA Climate Prediction Center, KNMI y JISAO por los datos provistos.

REFERENCIAS

Fisher, A., Rudin, C. and Dominici, F., 2019: All Models Are Wrong, but Many Are Useful: Learning a Variable's Importance by Studying an Entire Class of Prediction Models Simultaneously. *Journal of Machine Learning Research: JMLR* 20: 177.

Garbarini, E.M., 2016: Algunos indicadores para la predicción estadística de la precipitación estacional en Argentina. Tesis de Licenciatura. Departamento de Ciencias de la Atmósfera y los Océanos, Facultad de Ciencias Exactas y Naturales, Universidad de Buenos Aires.

Gil, S., Duperron, L. y Ruggero, R., 2005: Evaluación del plan de ahorro de consumo de gas natural en Argentina, *Pretrotécnica (Revista del Instituto Argentino del Petróleo y del Gas)* XLVI, N°3, (pág.48).

Hersbach, H., Bell, B., Berrisford, P., Biavati, G., Horányi, A., Muñoz Sabater, J., Nicolas, J., Peubey, C., Radu, R., Rozum, I., Schepers, D., Simmons, A., Soci, C., Dee, D., y Thépaut, J-N., 2019: ERA5 monthly averaged data on pressure levels from 1979 to present. Copernicus Climate Change Service (C3S) Climate Data Store (CDS). 10.24381/cds.6860a573

Oliveri, P.C., González, M.H., 2022: La relación entre el viento meridional en capas bajas y la variabilidad de la temperatura media en Argentina [Presentación de póster]. XIV Congreso Argentino de Meteorología (Buenos Aires, Argentina). https://cenamet.org.ar/congremet/wp-content/uploads/2023/02/LibroActas_compressed.pdf

Tran, T.T.K.; Bateni, S.M.; Ki, S.J.; Vosoughifar, H., 2021: A Review of Neural Networks for Air Temperature Forecasting. *Water* 2021, 13, 1294. 10.3390/w13091294.