

Verificación de los pronósticos semanales de precipitación y temperatura media generados con la técnica de regresión por análogos

Nota Técnica SMN 2025-192

Laura Aldeco^{1,2}, Ramón de Elía¹ y Juan Ruiz^{3,4}

¹ *Servicio Meteorológico Nacional.*

² *Universidad Nacional de La Plata. Facultad de Ciencias Astronómicas y Geofísicas.*

³ *Departamento e Ciencias de la Atmósfera y lo Océanos, FCEyN, UBA.*

⁴ *Centro de Investigaciones del Mar y la Atmósfera, CONICET/FCEyN-UBA.*

Enero 2025



Ministerio de Defensa
Argentina

Información sobre Copyright

Este reporte ha sido producido por empleados del Servicio Meteorológico Nacional con el fin de documentar sus actividades de investigación y desarrollo. El presente trabajo ha tenido cierto nivel de revisión por otros miembros de la institución, pero ninguno de los resultados o juicios expresados aquí presuponen un aval implícito o explícito del Servicio Meteorológico Nacional.

La información aquí presentada puede ser reproducida a condición que la fuente sea adecuadamente citada.

Resumen

El objetivo de este trabajo es documentar el proceso de generación de los pronósticos semanales de precipitación y temperatura media generados mediante la técnica de regresión por análogos y analizar su desempeño entre 2021 y 2023. En febrero de 2019 el Servicio Meteorológico Nacional (SMN) comenzó a generar de forma operativa pronósticos semanales de precipitación y temperatura media para las semanas 1 (días 1 a 7) y 2 (días 8 a 14). Para implementarlos, se utilizaron pronósticos cuyos errores fueron parcialmente corregidos con la técnica de regresión por análogos, dadas las ventajas documentadas que representa usar esta técnica respecto de utilizar las salidas de modelos sin calibrar. Para la generación y calibración de dichos pronósticos se utilizaron datos observados de estaciones de la red del SMN y la base de pronósticos retrospectivos del modelo GEFS, ambos en el período 2000-2019. La verificación en el caso de la precipitación se realizó para los umbrales de 5 mm y 30 mm de precipitación acumulada semanal. Para ello se construyeron tablas de contingencia y se calcularon algunos índices derivados de la misma: el Bias en la frecuencia, la probabilidad de detección y el Equitable Threat Score. Para verificar la temperatura media se calculó la raíz del Error Cuadrático Medio (RMSE) y la correlación entre anomalías pronosticadas y observadas para ambas semanas de pronóstico, en el período 2021-2023. Al mismo tiempo, se comparó el desempeño de los pronósticos generados con la técnica de regresión por análogos con el desempeño de los pronósticos sin calibrar. Los resultados muestran que, tanto para la precipitación acumulada como -de manera más notable- para la temperatura media, la calibración mediante la regresión por análogos reduce el error de los pronósticos, en ambas semanas. De esta manera se obtienen pronósticos de mejor calidad que si se utilizaran las salidas del modelo sin post-procesamiento alguno.

Abstract

This work aims to assess the generation of the weekly forecasts of precipitation and mean temperature built using the analogs technique, and to analyze the performance of these forecasts. The National Meteorological Service (NMS) of Argentina has been generating operational precipitation and mean temperature forecasts for week 1 (days 1 to 7) and week 2 (days 8 to 14) since February 2019. To achieve this, the analog regression technique was used given the documented advantages of using this technique over using the non-calibrated model outputs. The technique was applied to surface stations data from the NMS observation network and to GEFS retrospective forecasts database, both within the 2000-2019 period. Verification was made for 5 mm and 30 mm thresholds of weekly accumulated precipitation, using some scores associated to the contingency table: Bias in Frequency, Probability of Detection and Equitable Threat Score. In the case of weekly mean temperature, the scores used were Correlation of Anomalies and Root Mean Squared Error, in 2021-2023 period. Also, the performance of the forecasts generated using the analog regression technique was compared with the performance of the non-calibrated forecasts. The results show that, for both accumulated precipitation and -to a greater extent- mean temperature, calibration using analog regression reduces the error of the non-calibrated forecasts in both weeks. Consequently, better quality forecasts are obtained compared to using the model outputs without any post-processing.

Palabras clave: pronóstico semanal, calibración, verificación

Citar como: Aldeco, L., S., de Elía R., Ruiz J. J., 2025: Verificación de los pronósticos semanales de precipitación y temperatura media generados con la técnica de regresión por análogos. Nota Técnica SMN 2025-192.

1. INTRODUCCION

Muchas decisiones de gestión que involucran a los sectores de agricultura, energía, defensas civiles, entre otros, necesitan información meteorológica que va desde las próximas semanas a los próximos meses, por lo que los pronósticos meteorológicos dentro de estos plazos de tiempo son de gran valor socioeconómico. Para responder a las demandas de estos usuarios, desde hace algunos años los principales centros globales del clima y algunos servicios meteorológicos comenzaron a elaborar pronósticos semanales. El European Centre for Medium-Range Weather Forecasts (ECMWF), así como el National Centers for Environmental Prediction (NCEP) producen pronósticos en plazos de 4 semanas o más. El desempeño de los modelos numéricos disminuye a medida que aumenta el plazo de pronóstico, y por ello la mejor forma de abordar los pronósticos en estos plazos es mediante el uso de ensambles (Kalnay, 2003). Sin embargo, las salidas en crudo de los modelos numéricos por ensamble también presentan errores debidos a la presencia de imperfecciones en los modelos y a que los métodos de pronósticos por ensambles actuales no son capaces de representar adecuadamente la presencia, evolución e interacción de las diferentes fuentes de incertidumbre dentro del pronóstico. Una forma de abordar esta problemática es mediante métodos de calibración basados en un post-procesamiento estadístico que incorpora dichas fuentes de incertidumbre a posteriori (Hamill y Colucci 1997, Stensrud y Yussouf, 2007, entre otros). Este post-procesamiento estadístico se utiliza de manera cada vez más extendida en los servicios meteorológicos del mundo con el fin de reducir los errores sistemáticos provenientes de los modelos (Vannitsem y otros, 2021). Sobre nuestra región, estudios de estas características fueron realizados por Ruiz y Saulo (2011), Righetti y otros (2022, 2024), entre otros, quienes aplicaron diferentes técnicas de calibración a pronósticos diarios de temperatura y precipitación, logrando así mejorar la calidad de los mismos. Por otro lado, en la escala semanal, Godoy y Cutraro (2022) calibraron temperaturas máxima y mínima en plazos de hasta 2 semanas, obteniendo una notable mejora en el desempeño de los pronósticos.

Para que la calibración sea robusta es necesario disponer de una buena estadística de los errores sistemáticos del sistema de pronóstico utilizado. Para ello, es indispensable contar con un historial de pronósticos lo suficientemente largo, y los pronósticos retrospectivos (Hamill y otros, 2006), cumplen con esta condición. Los pronósticos retrospectivos son pronósticos por ensamble, recalculados en forma retrospectiva, utilizando la misma versión del modelo. La primera versión fue construida utilizando el modelo MRF (Medium Range Forecast) del NCEP (operativo en 1998), se actualizó en 2012, y la última versión corresponde al año 2020. Esta última versión cuenta con pronósticos retrospectivos desde el año 2000 hasta 2019, utilizando el modelo GEFS (Global Ensemble Forecast System), operativo hasta la actualidad. Las bases de pronósticos se utilizan en plazos de hasta 14 días y Aldeco y otros (2015) compararon las versiones de 1998 y 2012, resultando esta última con mejor desempeño, posiblemente debido, en parte, al aumento de la resolución espacial del modelo. Tanto en Aldeco (2011) como en Ruiz y otros (2018) se documentó la ventaja que representa utilizar pronósticos calibrados con la técnica de análogos respecto de utilizar las salidas de pronósticos sin calibrar. Por todo lo expuesto, y aprovechando la disponibilidad de esta base de datos de pronósticos retrospectivos, el Servicio Meteorológico Nacional (SMN) utiliza la técnica de análogos para generar de forma operativa, pronósticos semanales de precipitación acumulada, temperatura media y sus respectivas anomalías.

2. DATOS Y METODOLOGÍA

Para la aplicación de la técnica de análogos se utilizó la mencionada base de datos pronosticados (pronósticos retrospectivos) y una base de datos observados de estaciones meteorológicas del SMN y del INTA (Instituto Nacional de Tecnología Agropecuaria). Los pronósticos retrospectivos utilizados corresponden al GEFS (Global Ensemble Forecast System) versión 12 del Centro Nacional de Predicciones Ambientales (NCEP) de EE. UU y se obtuvieron del siguiente sitio web: <https://noaa-gefs-retrospective.s3.amazonaws.com/index.html>. Los mismos cuentan con un ensamble de 5 miembros (1 corrida control + 4 miembros perturbados), una resolución espacial horizontal de $0.5^\circ \times 0.5^\circ$, 25 niveles verticales y son inicializados una vez al día a las 00Z. Por otro lado, los datos observados utilizados son de precipitación acumulada semanal y temperatura media semanal para 127 estaciones meteorológicas. La semana 1 de pronóstico se cuenta como la suma (en el caso de precipitación) o promedio (en el caso de temperatura media) semanal de los días 1 al 7 de plazo, mientras que para la semana 2 se utilizan los días 8 al 14. La longitud de la base de datos de pronósticos y de observaciones es de 20 años, en el período 2000-2019.

2.1 La técnica de regresión por análogos

Como se mencionó previamente, para utilizar esta técnica se necesitan datos observados y pronósticos retrospectivos. Los pronósticos retrospectivos son pronósticos pasados generados con un mismo modelo numérico. De esta manera se construye una base de datos de pronósticos para un determinado modelo en un período del pasado, para poder comparar con las observaciones en el mismo período de tiempo. De estas comparaciones entre pronóstico y observaciones se pueden identificar los errores sistemáticos de los modelos numéricos y, por lo tanto, se pueden corregir. Este procedimiento se denomina calibración del modelo numérico y es en parte, lo que realiza la técnica de análogos, que puede ser resumida en los siguientes pasos:

- 1) Para cada estación, se compara el pronóstico actual del modelo al plazo correspondiente (a 1 semana o a 2 semanas) con todos los pronósticos pasados del modelo que correspondan al mismo plazo de pronóstico.
- 2) Los análogos son los campos pronosticados pasados que más se asemejen al campo pronosticado, utilizando el RMSE como medida de similitud.
- 3) Una vez obtenidos los pronósticos análogos, se buscan todas las observaciones correspondientes a las fechas de los pronósticos análogos, y en base a dichas observaciones se calcula el promedio del ensamble, con sus respectivas anomalías semanales. Esto resulta en una cantidad de observaciones pasadas igual a la cantidad de pronósticos análogos obtenidos. Este conjunto de observaciones pasadas puede ser considerado como una muestra de los posibles valores observados condicionada por el pronóstico actual. A partir de la muestra de observaciones pasadas, se puede usar su media como valor pronosticado y su varianza como medida de la incertidumbre asociada al pronóstico.

Respecto a la búsqueda de análogos, la misma se realizó sobre los pronósticos retrospectivos correspondientes al trimestre que tiene como mes central al mes que contiene el pronóstico de interés. Por ejemplo, si tomamos el caso del pronóstico para la semana del 01 al 07 de agosto de 2024, la técnica busca pronósticos análogos sólo dentro de los pronósticos retrospectivos de los meses de julio, agosto y septiembre de toda la serie. Por otro lado, la cantidad de análogos que se retienen para formar el ensamble es 75. Esta elección responde a los resultados de Aldeco (2011), donde se evaluó la sensibilidad del método a distintas

cantidades de análogos. Para mayor detalle acerca de la técnica se puede consultar Hamill y otros (2006) y Aldeco (2011).

Para armar las bases de datos, para la aplicación de la regresión por análogos, en el caso de la precipitación se calculó la precipitación acumulada semanal, mientras que para la temperatura se calculó la temperatura media semanal tanto para la base de datos pronosticados, como para los observados, para ambas semanas de pronóstico. Una vez obtenidas las bases de datos semanales pronosticadas y observadas se procedió a la búsqueda de los análogos como en Aldeco (2011). La principal diferencia entre ambas variables respecto de la aplicación de la técnica es cómo se realiza la búsqueda: para la precipitación la búsqueda de análogos se realiza en un entorno de cada una de las estaciones meteorológicas involucradas; es decir que para cada estación la búsqueda de análogos se centra en un dominio de $1^\circ \times 1^\circ$ alrededor del punto de retícula del modelo que representa la mínima distancia con la estación. Por otro lado, en el caso de temperatura media los análogos se buscan en el punto de retícula del modelo más cercano a la estación, como se propone en Hamill & Whitaker (2007). La climatología de cada semana se calcula diariamente para cada estación y para ambas semanas pronosticadas, como un promedio móvil de 7 días en el caso de la temperatura media y como suma semanal móvil de 7 días en el caso de la precipitación acumulada. Luego las anomalías semanales se calculan restando las climatologías a los valores pronosticados.

2.2 Métricas utilizadas

2.2.1 Precipitación

Siguiendo las recomendaciones de Nurmi (2003) para pronósticos categóricos, la verificación se realizó definiendo umbrales para calcular la tabla de contingencia para cada trimestre y para todas las estaciones meteorológicas del territorio nacional donde se generan dichos pronósticos. A partir de dichas tablas se calcularon algunos índices: el Bias en la frecuencia (BIAS), el POD y el ETS. El índice BIAS compara las frecuencias observadas con las pronosticadas, el POD o Probabilidad de Detección, indica la proporción de casos observados que sí fueron pronosticados y el ETS o Equitable Threat Score mide la proporción de aciertos, pero ajustado por la cantidad de aciertos que fueron aleatorios y penalizando también las falsas alarmas. Dichos índices se calcularon tomando como umbrales la precipitación semanal superior a 5 mm por un lado, y la precipitación semanal superior a 30 mm por otro. Para los tres índices, un pronóstico perfecto corresponde a un valor igual a 1.

La Tabla I muestra un ejemplo genérico de una tabla de contingencia de 2x2 como las utilizadas en este trabajo. Dados los pares de pronósticos/observaciones, la tabla de contingencia se construyó comparando dichos pares para un determinado umbral.

Las cuatro combinaciones de pronósticos (sí o no) y observaciones (sí o no) resultan en: Acierto: Evento pronosticado y observado, Sorpresa: Evento no pronosticado y observado, Falsa Alarma: Evento pronosticado y no observado y Acierto negativo: Evento no pronosticado y no observado.

Una tabla de contingencia de un pronóstico perfecto sólo tendría aciertos y aciertos negativos, y ninguna sorpresa ni falsas alarmas.

Tabla 1: Tabla de contingencia teórica de 2x2

Precip. semanal > umbral	Observación si	Observación no	Totales
Pronóstico si	Aciertos	Falsas Alarmas	Pronosticados Si
Pronóstico no	Sorpresas	Aciertos negativos	Pronosticados No
Totales	Observados Si	Observados No	Total

Las tablas de contingencia se calcularon comparando los pronósticos semanales respecto de alguno de los umbrales mencionados, con las observaciones semanales respecto del mismo umbral, para cada estación meteorológica por separado. Luego, se contabilizaron los casos de todas las estaciones consideradas para armar las tablas de contingencia. Esto se realizó primero de forma mensual, es decir para cada mes se tuvieron en cuenta todos los pronósticos diarios para la semana 1 por un lado y para la semana 2 por otro. Luego, para construir las tablas trimestrales se sumaron los casos de los meses involucrados.

Una vez obtenidas las tablas de contingencia para cada trimestre, se calcularon algunos índices a partir de las mismas, según las siguientes ecuaciones:

Bias en la frecuencia (Bias): Rango: 0 a + infinito. Valor óptimo = 1.

$$Bias = \frac{aciertos + falsas\ alarmas}{aciertos + sorpresas}$$

Probabilidad de Detección (POD): Rango: 0 a 1. Valor óptimo =1.

$$POD = \frac{aciertos}{aciertos + sorpresas}$$

Equitable Threat Score (ETS): Rango: -1/3 a 1. Valor óptimo =1.

$$ETS = \frac{aciertos - aciertos_{aleat}}{aciertos + sorpresas + falsas\ alarmas - aciertos_{aleat}}$$

donde,

$$aciertos_{aleat} = \frac{(aciertos + sorpresas) \cdot (aciertos + falsas\ alarmas)}{total}$$

2.2.2 Temperatura media

Para verificar los pronósticos de temperatura media semanal se calculó, por un lado, el coeficiente de correlación de Pearson de anomalías, o CORA por sus siglas en inglés, y por otro la Raíz del Error Cuadrático Medio o RMSE por sus siglas en inglés.

CORA correlaciona las anomalías pronosticadas por la técnica de análogos con las anomalías observadas, brindando una medida de la asociación lineal entre los pronósticos y las observaciones. Una de sus ventajas es que se remueve el ciclo estacional tanto de pronósticos como de observaciones al restar sus respectivas medias climatológicas, y su uso se encuentra bastante extendido en estudios de verificaciones de pronósticos semanales, tanto de precipitación, como de temperatura (Li y Robertson, 2015, Coelho y otros, 2018, Phakula y otros, 2020, entre otros). El cálculo se realizó para cada estación meteorológica, para cada semana y tomando todos los pronósticos semanales de anomalías de temperatura media disponibles dentro del período 2021-2023. Teniendo en cuenta que el primer pronóstico del período es del 1 de febrero de 2021 y el último es el 31 de diciembre de 2023, se tienen 1064 pares de pronóstico/observaciones para cada estación y para cada semana para el cálculo de correlaciones.

Para calcular la correlación de anomalías se utilizó el coeficiente de correlación de Pearson para una muestra de tamaño n :

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

Donde x_i es la anomalía de temperatura media semanal pronosticada e y_i es la anomalía de temperatura media semanal observada. \bar{x} e \bar{y} son los valores medios de la muestra de anomalías de temperatura media, en este caso en el período 2000-2019

El RMSE se calcula como la raíz de la diferencia al cuadrado entre las observaciones y los pronósticos (*pron_i* y *obs_i*).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (pron_i - obs_i)^2}$$

El RMSE tiene como ventaja que mantiene las unidades de la variable que se evalúa. RMSE=0 indica un pronóstico perfecto. Un pronóstico con buen desempeño debería tener RMSE bajos y correlaciones altas.

3. RESULTADOS

3.1 Precipitación

En la Figura 1 se observan los índices bias, POD y ETS, calculados para los trimestres MAM, JJA y SON de 2021, 2022 y 2023, DEF 2021/22 y DEF 2022/23.

Respecto al BIAS, para el umbral de 5 mm en la Figura 1 se observa que fue levemente superior a 1 en la semana 1 para todos los trimestres, mientras que en la semana 2 osciló entre 1.5 y valores superiores a 2.

Un BIAS cercano a 1 indica que la técnica pronosticó precipitación superior a 5 mm una cantidad de veces similar a la cantidad de veces observadas, que es el caso de la semana 1 de pronóstico. En el caso de la semana 2 el resultado indica que la técnica pronosticó precipitación semanal superior a 5 mm más veces de las que se observó, especialmente en los trimestres MAM y JJA 2022 en los cuales obtuvo el mayor valor de BIAS (del orden de 2.1). Para el umbral de 30 mm el BIAS fue menor respecto del umbral de 5 mm, presentando valores entre 0.5 y 1 para la semana 1 y mayor variabilidad en la semana 2. Un BIAS inferior a 1 indica que la técnica pronosticó precipitación superior a 30 mm menos veces de las que se observaron.

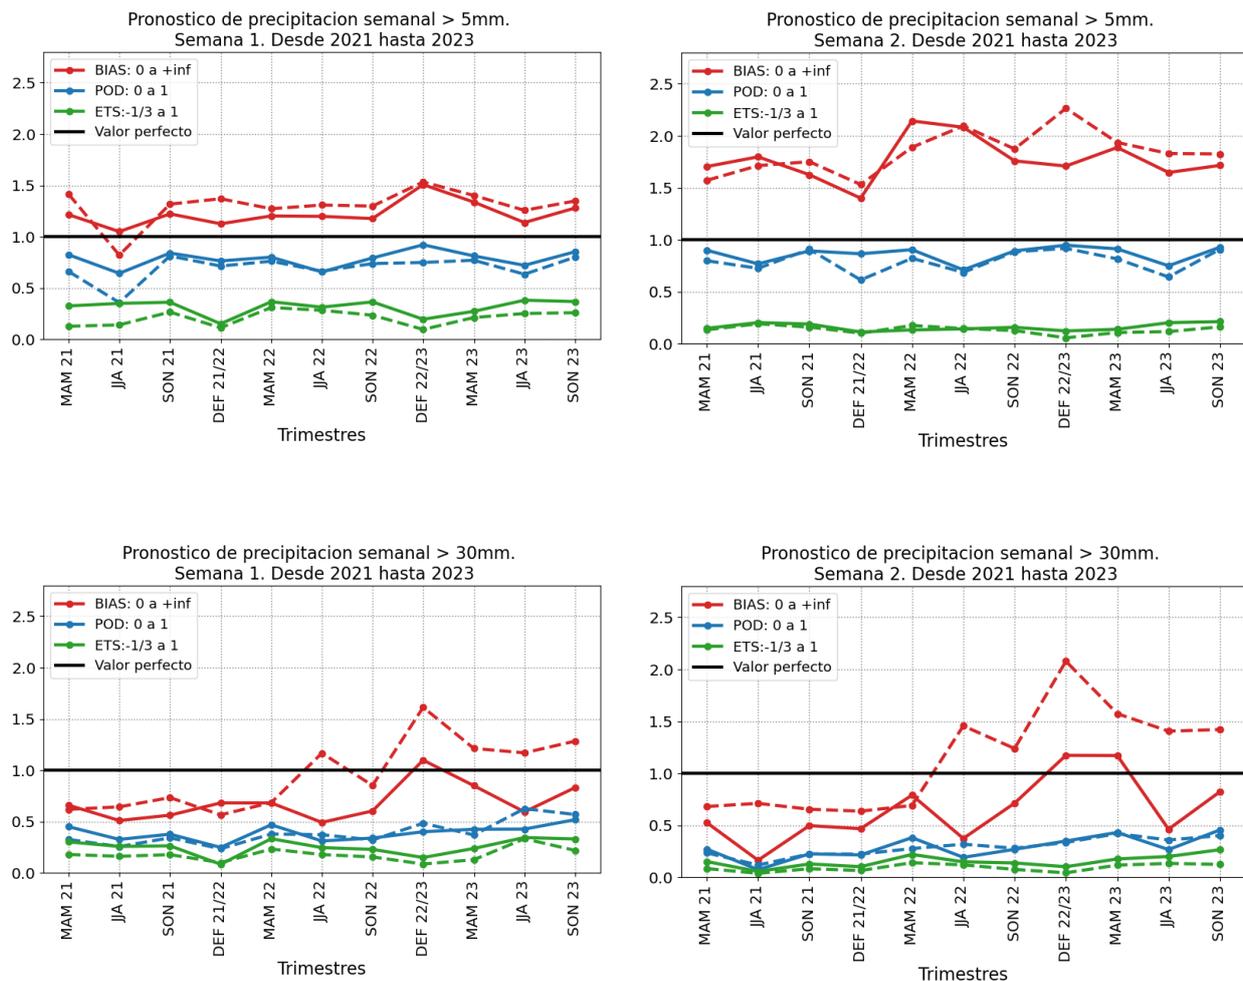


Figura 1: Índices bias, POD y ETS para los pronósticos semanales de precipitación superior a 5 mm (arriba) y para precipitación superior a 30 mm (abajo) para los plazos de pronóstico de 1 semana (izquierda) y 2 semanas (derecha), desde el trimestre marzo-abril-mayo (MAM) 2021 hasta el trimestre septiembre-octubre-noviembre (SON) 2023. Líneas llenas: pronóstico con la técnica de análogos, líneas punteadas: pronóstico GEFS sin calibrar. La línea negra =1 indica el valor óptimo para los tres índices.

Por otro lado, el índice POD en el umbral de 5 mm osciló entre 0.64 y 0.92 para la semana 1 y entre 0.71 y 0.92 en la semana 2. Estos valores indican que la técnica pudo pronosticar la precipitación semanal superior a 5 mm entre un 64 % y un 92 % de las veces en la semana 1, y entre un 71 % y 92 % de las veces en la semana 2. El leve aumento del POD observado en la semana 2 es coherente con el aumento observado del

bias para el mismo plazo, ya que al pronosticar precipitación semanal superior a 5 mm más veces que las observadas, la técnica tiene más chances de detectar el evento, resultando un POD mayor. Para el umbral de 30 mm el índice POD disminuyó respecto al de 5 mm, quedando entre 0.1 y 0.5 para ambas semanas, lo cual también es consistente con el valor del bias inferior a 1 en la mayoría de los trimestres para este umbral.

En el caso del índice ETS, para ambos umbrales y para ambas semanas, este índice fue inferior a 0.5, siendo mayor en la semana 1 que en la semana 2. Si bien no son valores cercanos a 1, lo cual sería óptimo, sus valores superiores a 0 en todos los casos indican que la técnica de regresión por análogos supera a un pronóstico al azar.

Al realizar la comparación con el desempeño de los pronósticos sin calibrar, se puede observar que en algunos de los trimestres hay una mejora del desempeño de los pronósticos respecto del desempeño del pronóstico sin calibración alguna. Esta mejora se traduce en una reducción del índice BIAS y un aumento de los índices POD y ETS, lo cual es más claro en el umbral de 5 mm para ambas semanas. En el umbral de 30 mm el efecto de la calibración tiene mayor impacto en la reducción del BIAS que en los otros índices.

3.2 Temperatura media

En la Figura 2 se presentan los mapas de correlación de anomalías de las semanas 1 y 2 del pronóstico realizado con la regresión por análogos, en el período febrero 2021- diciembre 2023. De acuerdo a los resultados, las correlaciones entre anomalías pronosticadas y anomalías observadas de temperatura media son mayores en la semana 1 de pronóstico respecto de la semana 2, en todas las estaciones utilizadas, lo cual es consistente con lo hallado en trabajos previos. La mayoría de los valores de CORA en la semana 1 oscilan entre 0.65 y 0.9, mientras que en la semana 2 estas correlaciones se encuentran entre 0.3 y 0.69. En ambas semanas de pronóstico se observan las máximas correlaciones en el noreste del país, en Misiones, Corrientes y este de Chaco y de Formosa. Parte de esta región fue estudiada por Álvarez y otros (2014), quienes encontraron que un buen porcentaje de la variabilidad era explicada por oscilaciones en la escala subestacional. Las menores correlaciones se observan en las estaciones del oeste y noreste de la Patagonia con valores inferiores a 0.4 en la mayoría de las estaciones en la semana 2.

En las Figuras 3 y 4 se muestra el RMSE de la temperatura media para las semanas 1 y 2, en el período febrero 2021- diciembre 2023, tanto para el pronóstico sin calibrar como para el pronóstico calibrado con la regresión por análogos. En ambas figuras se puede apreciar la disminución de los RMSE del pronóstico calibrado respecto del no calibrado, en ambas semanas de pronóstico. En la semana 1 (Fig.3), en las estaciones del norte del país se observa la mayor disminución de los errores, ya que en el pronóstico no calibrado los mismos superan los 3°C, y luego de la calibración son inferiores a 1.5°C. En el pronóstico calibrado se observa que los errores son inferiores a 1.5°C en módulo en la mayoría de las estaciones de la semana 1. En este mismo plazo de pronóstico, en las estaciones de la costa Patagónica se observan los menores RMSE (inferiores a 1°C), que coinciden con altas correlaciones de anomalías (entre 0.8 y 0.9) de la Figura 2, indicando un buen desempeño de los pronósticos en esta región en este plazo. Por otro lado, en la semana 2 (Fig.4) los errores son mayores respecto de la semana 1, y la disminución de los RMSE luego de la calibración no es tan marcada, pero aun así se obtiene una mejora en el desempeño de los pronósticos. En este plazo, en el pronóstico calibrado, se observa en la región central del país (Buenos Aires y este de La Pampa) una amplia zona con menores RMSE, que corresponde a correlaciones entre 0.4 y 0.6. Un comportamiento similar se observa en las estaciones del centro y sur de la Patagonia en este mismo plazo.

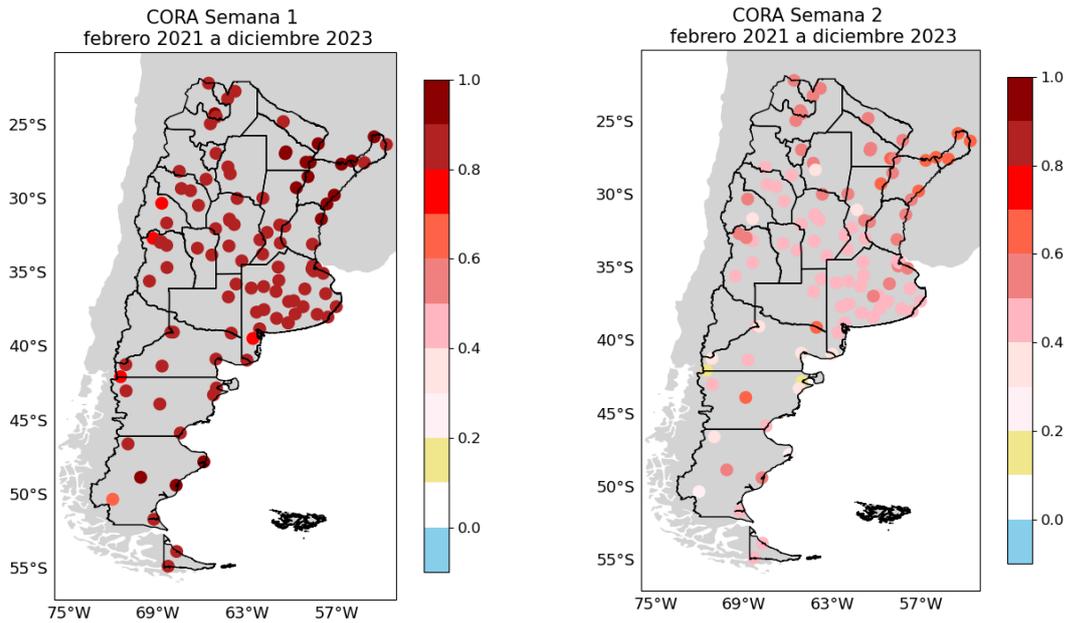


Figura 2: Correlación de anomalías (CORA) para los pronósticos de temperatura media generados con la técnica de regresión por análogos de la semana 1 (izquierda) y de la semana 2 (derecha) desde febrero 2021 hasta diciembre 2023.

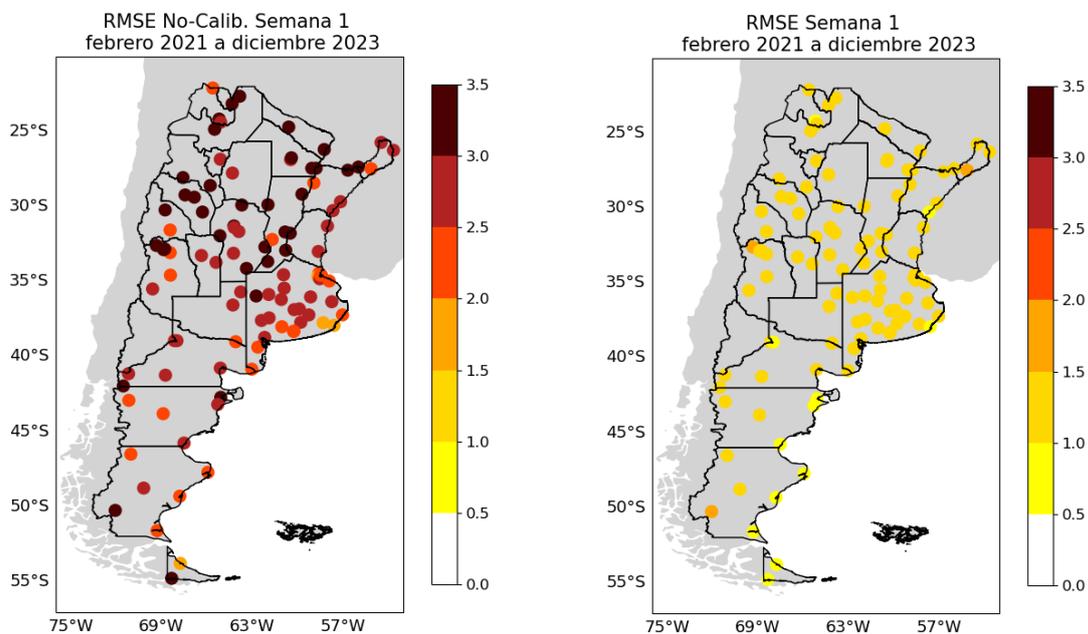


Figura 3: Error Cuadrático Medio (RMSE) para los pronósticos de temperatura media de la semana 1 del pronóstico sin calibrar (izquierda) y del pronóstico de regresión por análogos (derecha) desde febrero 2021 hasta diciembre 2023.

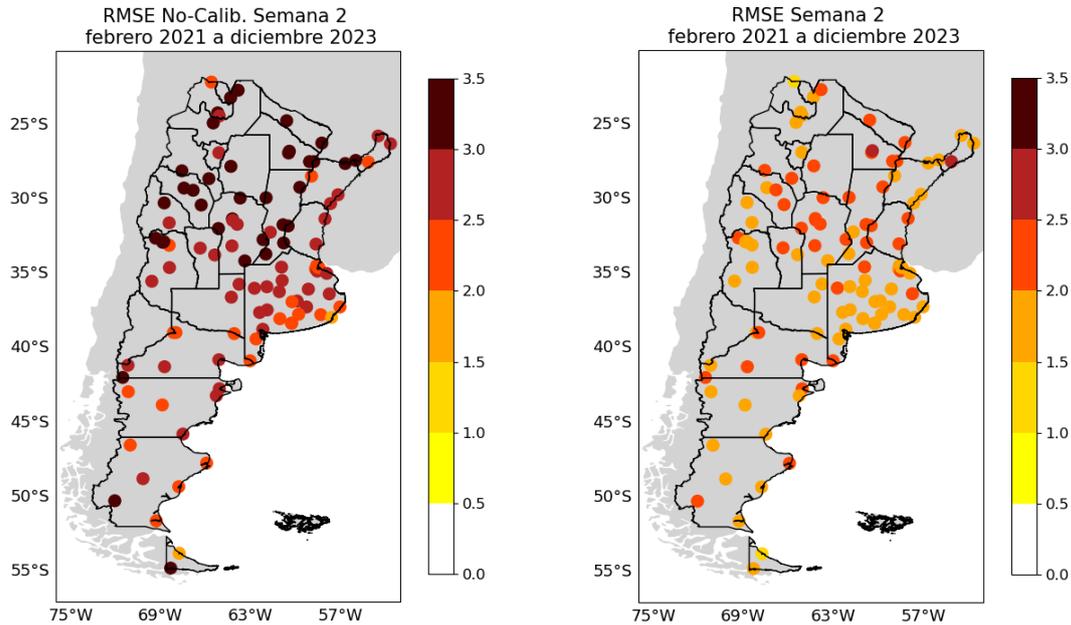


Figura 4: Error Cuadrático Medio (RMSE) para los pronósticos de temperatura media de la semana 2 del pronóstico sin calibrar (izquierda) y del pronóstico de regresión por análogos (derecha) desde febrero 2021 hasta diciembre 2023.

4. CONCLUSIONES

Los resultados muestran que, respecto a la temperatura media, hay alta correlación entre anomalías pronosticadas y observadas, siendo mayores en la semana 1 de pronóstico. En la semana 2 estas correlaciones disminuyen, aunque se mantienen superiores a 0.4 en la mayoría de las estaciones. Para ambas semanas las mayores correlaciones se encuentran en el noreste del país. Por otro lado, los campos de RMSE muestran una clara disminución de los errores luego de la calibración. En ambas semanas de pronóstico, los pronósticos calibrados con la técnica de regresión por análogos logran disminuir los RMSE de los pronósticos sin calibrar, siendo esta corrección más notoria en la semana 1 de plazo.

En el caso de la precipitación, se encuentra que los pronósticos con mejor desempeño corresponden al plazo de 1 semana en el umbral de 5 mm y dicho desempeño disminuye con el aumento del umbral pronosticado. Para el umbral de 5 mm la técnica tuvo una tendencia a pronosticar más eventos que los observados, coincidiendo con lo encontrado por Castro y Godoy (2024) que realizaron una verificación del modelo GFS con datos satelitales en lugar de estaciones. Por otro lado, para el umbral de 30 mm la técnica de regresión por análogos tuvo una tendencia a pronosticar menos eventos que los observados, disminuyendo la probabilidad de detección de estos casos.

De la comparación con los pronósticos sin calibrar resulta evidente que la calibración mediante la regresión por análogos mejora el desempeño de los pronósticos semanales de temperatura media, mientras que la mejora es menos marcada para precipitación acumulada. Por otro lado, de la verificación del período 2021/2023 se confirma que los pronósticos semanales a 1 semana tienen mejor desempeño que a 2 semanas

para ambas variables. Teniendo en cuenta los valores de las métricas estudiadas, la técnica de análogos presentó un desempeño similar al de los pronósticos verificados en otros trabajos en estas escalas (Godoy y Cutraro, 2024, Coelho y otros, 2018, entre otros). Estudios de esta índole brindan un valor agregado a los productos, ya que permite que los usuarios conozcan las fortalezas y debilidades de los pronósticos, permitiéndoles tener herramientas que facilitan la toma de decisiones. Por último, con el fin de mejorar la calidad de los pronósticos, se está trabajando para comparar la técnica de regresión por análogos con otras metodologías de calibración de pronósticos semanales, algunas de las cuales se encuentran en desarrollo en el SMN.

5. REFERENCIAS

Aldeco, L., 2011: Aplicación de la técnica de análogos a la generación de pronósticos probabilísticos de precipitación sobre algunas estaciones de la Argentina. Tesis de Licenciatura del Departamento de Ciencias de la Atmósfera y los Océanos, FCEyN, Universidad de Buenos Aires.

Aldeco L. S., Ruiz J. J., Saulo C. A., 2015: Generación de Pronósticos Probabilísticos Operativos en el Servicio Meteorológico Nacional. Congremet XII. Actas del Congreso Nacional de Meteorología.

Álvarez, M.S., Vera, C.S., Kiladis, G.N., Liebmann, B., 2014: Intraseasonal variability in South America during the cold season *Climate Dynamics*. 42(11-12):3253-3269

Castro, L., y A. Godoy, 2024: Estudio del desempeño del modelo subestacional GFS para pronosticar precipitación a dos semanas. Nota Técnica SMN 2024-168.

Coelho, C. A., Firpo, M. A., & de Andrade, F. M., 2018: A verification framework for South American sub-seasonal precipitation predictions. *Meteorologische Zeitschrift*, 27(6), 503-520.

Godoy A. y Cutraro F., 2022: Calibración de pronósticos semanales de temperatura. Congremet XV. Actas del Congreso Argentino de Meteorología.

Godoy, A. A., F. Cutraro, 2024: Evaluación de pronósticos numéricos calibrados de la temperatura semanal. Nota Técnica SMN 2024-159.

Hamill, T. y Colucci, S. J., 1997: Verification of Eta-RSM Short-Range Ensemble Forecast, *Monthly Weather Review*, 125, 1312-1327.

Hamill, T., Whitaker, J. y Mullen, S., 2006: Reforecasts. An important data set for improving weather predictions. *Bulletin of the American Meteorological Society*, 33-46.

Hamill, T. y Whitaker J. S., 2007: Ensemble Calibration of 500-hPa Geopotential Height and 850-hPa and 2-m Temperatures Using Reforecasts. *Monthly Weather Review*, 135, 3273-3280.

Li, S., y Robertson A. W., 2015: Evaluation of Submonthly Precipitation Forecast Skill from Global Ensemble Prediction Systems. *Mon. Wea. Rev.*, 143, 2871–2889, <https://doi.org/10.1175/MWR-D-14-00277.1>

Kalnay, E., 2003: *Atmospheric Modeling, Data Assimilation and Predictability*. Cambridge University Press, 341 pp.

Nurmi, P., 2003: Recommendations on the verification of local weather forecasts. ECMWF Techn Memo 430:19. <https://doi.org/10.21957/y1z1thg5l>

Phakula, S., Landman, W. A., Engelbrecht, C. J., & Makgoale, T. 2020: Forecast skill of minimum and maximum temperatures on subseasonal-to-Seasonal timescales over South Africa. Earth and Space Science, 7, e2019EA000697. <https://doi.org/10.1029/2019EA000697>

Righetti, S., Cutraro F., García Skabar Y., 2022: Calibración de la precipitación acumulada diaria en el Servicio Meteorológico Nacional. Congremet XV. Actas del Congreso Argentino de Meteorología.

Righetti, S., F. Cutraro, Y. García Skabar y M. Sacco, 2024: Calibración de los pronósticos de precipitación acumulada diaria. Nota Técnica SMN 2024-164.

Ruiz, J. y Saulo, C., 2011: How sensitive are probabilistic precipitation forecasts to the choice of calibration algorithms and the ensemble generation method? Part I: Sensitivity to calibration methods. Meteorological Applications, 19(3), 302– 313. <https://doi.org/10.1002/met.286>

Ruiz, J., Aldeco L., Diehl A., García Skabar Y., Matsudo C., Osman M., Pelorosso L., Saulo C., Vera C., 2018: Capítulo 37: Aplicaciones en Argentina. Física del caos en la predicción meteorológica. <http://dx.doi.org/10.31978/014-18-009-X.37>

Vannitsem, S., and Coauthors, 2021: Statistical Postprocessing for Weather Forecasts: Review, Challenges, and Avenues in a Big Data World. Bull. Amer. Meteor. Soc., 102, E681–E699. <https://doi.org/10.1175/BAMS-D-19-0308.1>

Stensrud, D. y Yussouf, N., 2007: Reliable Probabilistic Quantitative Precipitation Forecast from a Short-Range Ensemble Forecasting System. Weather and Forecasting, 22, 3-17.

Instrucciones para publicar Notas Técnicas

En el SMN existieron y existen una importante cantidad de publicaciones periódicas dedicadas a informar a usuarios distintos aspectos de las actividades del servicio, en general asociados con observaciones o pronósticos meteorológicos.

Existe no obstante abundante material escrito de carácter técnico que no tiene un vehículo de comunicación adecuado ya que no se acomoda a las publicaciones arriba mencionadas ni es apropiado para revistas científicas. Este material, sin embargo, es fundamental para plasmar las actividades y desarrollos de la institución y que esta dé cuenta de su producción técnica. Es importante que las actividades de la institución puedan ser comprendidas con solo acercarse a sus diferentes publicaciones y la longitud de los documentos no debe ser un limitante.

Los interesados en transformar sus trabajos en Notas Técnicas pueden comunicarse con Ramón de Elía (rdelia@smn.gov.ar), Luciano Vidal (lvidal@smn.gov.ar) o Martin Rugna (mrugna@smn.gov.ar) de la Dirección Nacional de Ciencia e Innovación en Productos y Servicios, para obtener la plantilla WORD que sirve de modelo para la escritura de la Nota Técnica. Una vez armado el documento deben enviarlo en formato PDF a los correos antes mencionados. Antes del envío final los autores deben informarse del número de serie que le corresponde a su trabajo e incluirlo en la portada.

La versión digital de la Nota Técnica quedará publicada en el Repositorio Digital del Servicio Meteorológico Nacional. Cualquier consulta o duda al respecto, comunicarse con Melisa Acevedo (macevedo@smn.gov.ar).