

Evaluación de los pronósticos de los modelos dinámicos y de IA del ECMWF durante una ola de calor de Argentina

Nota Técnica SMN 2026-215

Lucía M. Castro¹, Alejandro A. Godoy²

¹ Investigadora independiente del proyecto ENANDES+

² Dirección Nacional de Pronósticos y Servicios para la Sociedad, Servicio Meteorológico Nacional

Julio 2026



**Ministerio
de Defensa**
República 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.

Agradecimientos

Los autores de este trabajo agradecen a todas las personas que hicieron posible la colaboración entre el Servicio Meteorológico Nacional y el European Centre for Medium-Range Weather Forecasts (ECMWF), en el proyecto “South American Regional Model Verification Pilot”. El liderazgo y generosidad de los investigadores de ECMWF ha sido una constante fuente de inspiración. En particular, extendemos el agradecimiento a los patrocinadores del proyecto ENANDES+, cuyo objetivo es mejorar la capacidad de adaptación de las comunidades andinas.

Resumen

Se compara el desempeño de Temperatura a 2 Metros (T2M) entre pronósticos con aprendizaje automático y dinámicos, en la escala subestacional (plazo de dos semanas) del ECMWF, durante una ola de calor entre enero y febrero de 2025 en Argentina. Se utiliza el modelo dinámico ensamblado (IFS) para comparar dos modelos de aprendizaje automático, en formato ensamble (AIFS-ENS) y determinístico (AIFS-OPER). Se utiliza de referencia la temperatura media de las estaciones del SMN. Con plazos de dos semanas, todos los modelos pronostican T2M menores a la observada. Aun así, existe acuerdo entre los modelos y las observaciones en la primera semana del evento, en todo el rango de temperaturas observadas. Además, al predecir el inicio de la ola de calor, los pronósticos hechos con aprendizaje automático son comparables al pronóstico dinámico. La subestimación es mayor al pronosticar la segunda semana del evento, especialmente en temperaturas mayores a 30°C. Por lo tanto, los modelos presentaron dificultades en predecir la duración e intensidad del evento. Al analizar la evolución de los pronósticos en las localidades de Rivadavia y Neuquén, se observa mejor desempeño en Neuquén, con señal 7 días antes del inicio del evento, mientras que en Rivadavia la señal se observa 4 días antes. El modelo dinámico IFS tiende a predecir T2M 1 a 2 °C mayores que los modelos AIFS, con menor incertidumbre. Aun así, en plazos cortos los modelos convergen a valores similares. El buen desempeño de los modelos de aprendizaje automático en este evento no aseguran un desempeño similar en otras instancias. Es necesario continuar el análisis en otros eventos y variables.

Abstract

It is compared the performance between dynamic and machine learning subseasonal forecasts of Two Meter Temperature (T2M) from ECMWF, during a heatwave event in Argentina. The dynamical ensemble model (IFS) is chosen to compare with two AI models; AIFS-OPER which is deterministic, and AIFS-ENS that has an ensemble of the same size as IFS. The mean daily temperature observed by National Meteorological Service's stations is used as a benchmark. With a two week lead, every model underestimates the T2M. Still, there is agreement between models and observations in the first event week, in all the observed temperature range. Additionally, when predicting the heatwave onset, dynamical and machine learning forecasts are comparable. During the event's second week the underestimation is larger than in the first week, specially for T2M above 30°C. Therefore, all models presented difficulties to predict the events' duration and intensity. When analyzing forecast evolution in two stations, Rivadavia and Neuquen, is it observed better performance in Neuquen, with a signal 7 days before event's onset, while in Rivadavia the signal is observed 4 days before. IFS tends to predict T2M 1 to 2°C larger than AIFS models, with less uncertainty. However, the values converge in shorter lead times. The good performance of machine learning models during this event does not guarantee an equal performance in similar instances. It is necessary to further this analysis in other events and variables.

Palabras clave: Subestacional, Aprendizaje automático, IA, ECMWF, extremos

Citar como:

Castro, L. M., Godoy A. A., 2026: Evaluación de los pronósticos de los modelos dinámicos y de IA del ECMWF durante una ola de calor de Argentina. Nota Técnica SMN 2026-215.

1. INTRODUCCIÓN

Los pronósticos subestacionales, es decir, con plazos de dos semanas o más, son herramientas útiles para la prevención temprana en casos de eventos extremos ([Domeisen et al 2022](#), [Castro et al, 2025](#), [Wang et al, 2025](#)). El conocimiento con antelación de las olas de calor brinda información a los tomadores de decisiones, permitiendo anticiparse a sus impactos ([Salud y olas de calor, WMO](#)). La ola de calor en enero y febrero de 2025 que tuvo lugar en Argentina es ideal para el estudio subestacional por la persistencia temporal y extensión espacial. Por este motivo, se explora el desempeño de los pronósticos a dos semanas de temperatura de los modelos del ECMWF.

En los últimos años se ha popularizado el pronóstico de variables atmosféricas utilizando técnicas de aprendizaje automático. Los avances tecnológicos y científicos en el área han producido pronósticos de calidad similar a los tradicionales con menor costo computacional ([Lam y otros, 2023](#), [Bonev y otros, 2023](#)). Recientemente, el ECMWF ha desarrollado sus propios pronósticos de aprendizaje automático (AIFS-OPER), basados en Redes Neuronales de Grafos (*GNN, por sus siglas en inglés*) y entrenados con el reanálisis ERA 5 y análisis operativos numéricos ([Lang et al, 2024\(a\)](#)). Los pronósticos determinísticos del modelo demuestran un desempeño similar a los dinámicos para variables en superficie y en altura pero carecen de la habilidad de cuantificar la incertidumbre. Por esta razón, en 2025 el ECMWF incorpora el pronóstico por ensambles ([Lang et al, 2024 \(b\)](#)) obtenido a partir de aprendizaje automático utilizando como función de costo el Continuous Ranked Probability Score (CRPS).

El modelo AIFS-OPER produce pronósticos precisos de 1 a 10 días con buen desempeño en el hemisferio norte, hemisferio sur y en los trópicos, con menor desempeño en niveles altos que en superficie. En particular, la temperatura a dos metros (T2M) tiene menor error y menor incertidumbre que IFS, comparando contra observaciones SYNOP ([Lang et al, 2024a](#)). Similarmente, el AIFS-ENS tiene un desempeño superior al mismo modelo dinámico para temperatura superficial en el hemisferio norte y los trópicos, pero en el hemisferio sur las diferencias de correlaciones y de error cuadrático medio no son significativas desde el plazo de 7 días ([scorecard AIFS-ENS](#)). A su vez, el spread es inferior al obtenido con el modelo dinámico original IFS y a las observaciones SYNOP. Por lo tanto, es de interés explorar el desempeño de los pronósticos alimentados con datos en un evento extremo sin precedentes.

Desde el 29 de enero al 12 de febrero de 2025 se produjo un evento de ola de calor que afectó a todo el territorio argentino, y que fue particularmente intenso en el norte de Argentina ([Informe especial SMN N°3](#)). Durante este caso, 18 localidades registraron récords de temperatura máxima de febrero y en el día 8 de ese mes casi todas de estaciones del país presentaron índices de calor extremo medio y alto (Figura 1). Antes del inicio de la ola de calor, dos índices subestacionales relevantes para la temperatura en Argentina se encontraban activos ([SMN, 2025](#)). La oscilación de Madden-Julian se encontró entre las fases 6 y 7, lo que puede provocar anomalías positivas de temperatura durante el trimestre diciembre, enero y febrero ([Alvarez et al, 2017](#)). Por otra parte, el índice SIS también se encontraba activo el día 28 de enero de 2025. Durante la temporada DEF, el índice en fase positiva está asociado a descensos de temperatura en su etapa inicial y a aumentos en el este de Argentina al finalizar el evento ([Portal Cima, Alvarez 2014](#)). La intensidad y duración del evento SIS regula su impacto en Sudamérica.

Ambos índices, aunque no son suficientes para asegurar aumento de temperatura, actúan como predictores de este tipo de evento, evidenciando dinámicas de baja frecuencia capaces de producir eventos extremos. Por esa razón, los modelos suelen desempeñarse mejor cuando los índices se encuentran activos.




Fig. 1: Mapa de Índice de calor extremo interpolado de observaciones del Servicio Meteorológico Nacional en el día 8 de Febrero de 2025 (izquierda) y evolución de cantidad de localidades argentinas con condición de ola de calor entre el 29 de Enero y el 12 de Febrero 2025. Adaptado del informe especial N°3 por ola de calor de Jose Luis Stella (2025).

En base a lo anterior, se desea responder las siguientes preguntas: ¿Los pronósticos de aprendizaje automático fueron capaces de predecir el inicio del evento? ¿Con cuántos días de antelación se predijo el evento? ¿Los pronósticos de aprendizaje automático pueden pronosticar correctamente la intensidad y duración de eventos extremos?

2. DATOS

Se explora el desempeño de los pronósticos de temperatura a dos metros (T2M) del ECMWF dinámicos (IFS) y modelos con componentes de aprendizaje automático (AIFS). A su vez, el pronóstico AIFS se divide en pronósticos determinísticos (AIFS-OPER) y ensambles (AIFS-ENS). Los modelos AIFS se operativizaron recientemente y se desconoce su desempeño en Argentina. Considerando que el objetivo es el posible uso automático de nuevas herramientas con plazos subestacionales, y así, aumentar el tiempo de previsión frente a eventos extremos, el análisis se enfoca en el desempeño del pronóstico subestacional a dos semanas.

Las características principales de los modelos se encuentran resumidas en la Tabla I. El modelo dinámico con núcleo dinámico IFS utilizado es "Ensemble-Atmospheric Model (ENS)" versión 49r1 teniendo el mismo plazo de pronóstico e igual cantidad de miembros de ensamble que AIFS-ENS ([Configuración IFS, ECMWF](#)). En cambio, la cantidad de niveles verticales es diferente entre modelos dinámicos y aprendizaje automático, con 13 y 137 niveles verticales respectivamente. Respecto a la resolución horizontal, los modelos AIFS-OPER y AIFS-ENS tienen una resolución de 31 Km ([Configuración AIFS, ECMWF](#)), y el modelo dinámico IFS una resolución de 9 Km. Por lo tanto, los modelos estudiados son interpolados a una misma resolución de 0.25°x0.25°. Se obtiene la T2M diaria como el promedio entre los valores a las 00Z, 06Z, 12Z y 18Z.

Los modelos son verificados con observaciones diarias de las estaciones del Servicio Meteorológico Nacional (SMN) obtenidas desde el [portal CRC-SAS](#) en el periodo del evento. Considerando que las variables observadas son temperatura máxima y mínima diaria, se obtiene la temperatura media como el promedio de ambas y se asume que es una buena aproximación de la temperatura media a 2 metros. El evento es estudiado de forma semanal por lo que, por su duración de 15 días, se dividen los datos entre la primera (29/01 a 04/02) y segunda (05/02 a 11/02) semana de la ola de calor, ignorando el día final (12/02).

Tabla 1: Características principales de modelos del ECMWF analizados, indicando si son dinámicos o de aprendizaje automático.

MODELO	ENSAMBLE	INCLUYE I.A.	PLAZO
IFS	50 miembros perturbados + 1 control	No	0 a 360 horas cada 6 horas
AIFS OPER	1 miembro	Si	0 a 360 horas cada 6 horas
AIFS ENS	50 miembros perturbados + 1 control	Si	0 a 360 horas cada 6 horas

3. METODOLOGÍA

Para realizar un análisis de los errores del modelo es necesario trabajar con anomalías ([Coelho, 2018](#)), removiendo la climatología de los modelos (hindcast). A pesar de esto, el trabajo utiliza el valor absoluto pronosticado ya que no se encuentran disponibles las climatologías de los modelos AIFS-OPER y AIFS-ENS. Tampoco son posibles de calcular ya que el historial de los modelos no supera los dos años. De la misma forma, no es posible obtener la métrica “señal a ruido”, que resta la media pronosticada de la media climatológica para cuantificar la señal del evento.

Por otra parte, sí se calcula la climatología observada semanal de cada semana del evento, para conocer su grado de frecuencia. Asimismo, es posible comparar la distribución de los valores pronosticados con la climatología observada. La climatología utilizada se define como el promedio semanal de temperatura de un conjunto de los últimos 20 años, sin incluir el año del evento. De esta forma se utilizan la misma cantidad de años que en la climatología del ECMWF. A su vez, se evita el ruido por la tendencia de la temperatura.

Para analizar la evolución de los pronósticos al acortar el plazo hacia la semana objetivo, dos estaciones son elegidas para representar dos áreas de interés: Neuquen Aero (ID 87715) en el norte de la Patagonia y Rivadavia (ID 87065) en la cuenca del río Pilcomayo en el norte argentino (ver Figura 6). Debido al gran costo computacional de este tipo de cálculo, ya que se obtiene la distribución con todos los miembros de cada modelo, solo se realiza en dos puntos, en vez de áreas más extensas o el país completo.

Usualmente, en escalas subestacionales se analiza el pronóstico del promedio semanal en la semana objetivo ([Pegion, 2019](#)). Por ejemplo, el pronóstico iniciado el día 22 de enero, proyecta la temperatura promedio entre los días 29 de enero hasta el 4 de febrero. Por esta razón, se denomina “pronóstico a dos semanas” al pronóstico inicializado 7 días antes del día inicial del evento objetivo, ya que incluye plazos de hasta 14 días.

4. RESULTADOS

A continuación se detallan los resultados obtenidos para cada modelo del ECMWF en ambas semanas del evento.

La Figura 2 presenta las observaciones diarias de temperatura media de las estaciones del SMN durante la primera y segunda semana del evento, en la primera y segunda fila, respectivamente. Durante la primera semana la masa cálida se desplaza desde el sur hacia el norte de Argentina, concentrando temperaturas mayores a 30°C en el norte del país hacia el final de la semana. Durante la segunda semana, la masa de aire cálido se desplaza nuevamente hacia el sur, entre los días 7 y 10 de febrero para finalmente volver a posicionarse sobre el norte argentino el día 11.

TMED Diaria SMN 109 estaciones





Fig. 2: Temperatura media diaria observada en las estaciones de SMN durante la primera semana (fila superior) y la segunda (fila inferior) del evento de ola de calor.

4.1 Pronósticos con dos semanas de antelación

En primera instancia, se grafican la T2M diaria pronosticada a dos semanas con los modelos IFS, AIFS-OPER y AIFS-ENS para la primera (Figura 3) y segunda (Figura 4) semana del evento. También, se calcula la diferencia entre la temperatura pronosticada y observada, o bias, disponibles en el anexo (Figuras 8 y 9). En caso de pronósticos por ensamble, solo se exhiben las medias del ensamble. Todos los pronósticos de la primera semana del evento (Figura 3) presentan el desplazamiento hacia el norte de la masa cálida, con dos semanas de anticipación. En los tres casos, la temperaturas son menores en el primer día de la semana, 29/01, y aumentan gradualmente. En ese día, el modelo IFS presenta la predicción de T2M más alta de los tres modelos, sobreestimando por 1°C el noreste argentino (Figura 8 del anexo). Los modelos IFS y AIFS-OPER, presentan en los días 01/02 y 02/02 temperaturas mayores a 28 grados que cubren desde 37°S hacia

el norte de Argentina, tal como indican las observaciones (Figura 2, fila superior) pero sin alcanzar los valores observados. En cambio, AIFS-ENS sobreestima la T2M en el noroeste argentino en el día 01/02. A su vez, todos los modelos extienden la región con temperaturas altas hacia el sur, causando sobreestimación sobre el norte y noreste de Patagonia durante esos días. Se observa que el pronóstico determinístico AIFS-OPER alcanza mayores valores de T2M que los pronósticos por ensambles AIFS-ENS y IFS durante la semana. Por esta razón, el AIFS-OPER presenta menor subestimación, es decir, menor error, de T2M que las medias de los ensambles, en el centro y norte argentino. Quitando las diferencias mencionadas los días 29/01 y 01/02, los modelos por ensambles AIFS-ENS y IFS tienen pronósticos similares en la primera semana.

a)



c)


Fig. 3: Pronósticos diarios de temperatura a 2 metros (T2M) inicializados el 22-01-2025 a las 00Z para la primera semana del evento. (a) la media del ensamble del modelo dinámico IFS, (b) el pronóstico del modelo AIFS operativo y (c) la media del ensamble del modelo AIFS.

Al considerar los pronósticos para la segunda semana del evento (Figura 4) se observa que en todos los modelos la subestimación del evento es aún mayor que en la primera parte, en el pronóstico a dos semanas. Nuevamente, todos los modelos predicen el correcto desplazamiento de la masa cálida, hacia el sur en este caso, pero subestimando la magnitud de la T2M. Particularmente, el modelo AIFS-OPER durante 08/02 y 09/02, pronostica un desplazamiento hacia el sur mayor al observado, con T2M mayores a 30°C en Patagonia. Esto provoca una sobreestimación de 2°C a 4°C de temperatura en Buenos Aires, La Pampa y Patagonia el día 09/02 (Figura 9 del anexo). En cambio, aunque el modelo AIFS-ENS predice el retroceso de la masa de aire los días 08/02 y 09/02, la T2M pronosticada es 3°C menor a la observada. Este modelo también extiende


el retroceso de la masa cálida hacia el sur, con sobrestimación en la misma región con menor magnitud a AIFS-OPER el día 09/02. Entre el día 10/02 y 11/02 el aire cálido se desplaza bruscamente hacia el norte y todos los modelos fallan en detectar el cambio de temperatura. Es posible que el movimiento súbito sumado al momento de la semana (plazo 14 de pronóstico) dificulte la correcta predicción. Por esta razón, en el día 11/02 se observa una alta sobrestimación de temperatura desde 33°S hacia al sur en todos los modelos. Dicha sobrestimación es máxima en AIFS-OPER, con más de 4°C y mínima en AIFS-ENS, de entre 1°C a 3°C. Al igual que en la primera parte del evento, las medias de ensamble de los modelos AIFS-ENS y IFS son similares entre sí, posiblemente por el suavizado al promediar.

a)

T2M Diaria IFS Media Ensamble
Semana 2 Inicializacion: 2025-01-2900Z




T2M Diaria AIFS Media Ensamble
Semana 2 Inicializacion: 2025-01-2900Z



b)

T2M Diaria AIFS Operacional
Semana 2 Inicializacion: 2025-01-2900Z



c)

Fig. 4: Idem Figura 3 inicializados el 29-01-2025 a las 00Z para la segunda semana del evento

Los diagramas de dispersión de T2M en la Figura 5 comparan el pronóstico de la media semanal de T2M con un plazo de dos semanas, con las observaciones en cada estación. En el pronóstico del inicio del evento (Figura 5a) se observa buena correspondencia entre los distintos modelos con las observaciones, tendiendo a la subestimación de T2M, al ubicarse los valores por debajo de la diagonal. La diferencia entre la temperatura observada y pronosticada es de 0 a -3 grados, según la región, y no se observan diferencias significativas entre los modelos ya sean dinámicos o de aprendizaje automático. En cambio, el pronóstico de la segunda semana del evento (Figura 5.b) presenta una disminución del desempeño de los modelos, aun manteniendo el mismo plazo, de 14 días, hacia la semana objetivo. En las estaciones del centro del país, el IFS sobreestima la T2M media semanal, a diferencia de los modelos de I.A que subestiman la temperatura,

aunque se mantienen cerca de la diagonal. En cambio, en las estaciones del norte, la subestimación es de igual magnitud en todos los modelos. Como se observa en la sección anterior, los desplazamientos abruptos de la masa de aire provoca que exista sobrestimación y subestimación en Patagonia, en la misma semana. Por tal razón, el promedio semanal se suaviza en las estaciones del sur argentino, y por este motivo que los valores se encuentren cerca de la diagonal no implica necesariamente un buen desempeño.




Fig. 5: Diagramas de dispersión para T2M semanal pronosticada a dos semanas para la primera (a) y la segunda (b) semana del evento. Los colores de los puntos indican el modelo utilizado y la línea de rayas diagonal indica el valor ideal del pronóstico respecto a las observaciones de SMN.

Para analizar dos regiones de interés, fueron elegidas dos estaciones representativas, una en el norte argentino y otra del norte de Patagonia (Figura 6). La Figura 7 presenta la evolución de los pronósticos IFS, AIFS-ENS y AIFS-OPER para el promedio semanal de T2M en la primera semana del evento (29 de enero al 4 de febrero) y la segunda (5 al 11 de febrero) en las estaciones de Neuquén y Rivadavia.




Fig. 6: Mapa de Argentina con la ubicación de las estaciones Rivadavia y Neuquén (izquierda). Evolución de la T2M observada desde el 29 de enero al 11 de febrero de 2025.

Al analizar la evolución del pronóstico para la primera semana del evento, en la estación de Neuquén (Figura 7a) se observa que la mediana del ensamble del IFS pronostica una temperatura mayor a la observada

durante las inicializaciones entre el 23 al 28 de enero, para ajustarse a una temperatura similar a la observada el día anterior al inicio de la semana. Por otra parte, en los modelos de aprendizaje automático la mediana es la misma magnitud que la observada desde el día 23/01 hasta el 29/01, aunque con gran dispersión del ensamble en el caso de AIFS-ENS. A partir del día 26/01 el intervalo intercuartil (IC) del modelo no solapa con el IC climatológico, indicando probabilidades altas de T2M extremas. Al estudiar la distribución de los pronósticos para la segunda semana del evento (Figura 7c) es posible distinguir mayores diferencias entre AIFS-OPER y AIFS-ENS. El pronóstico del primero es mayor a la mediana del segundo en las inicializaciones desde 29/01 hasta 01/02, y luego convergen 4 días antes del evento. Al mismo tiempo, se observa que los pronósticos determinísticos tienen una mediana mayor a la de AIFS-ENS desde la primera inicialización, de una magnitud similar a la T2M media semanal observada. Es importante notar que el IC disminuye al disminuir el plazo de pronóstico con igual velocidad entre el modelo AIFS-ENS y IFS. En ambas semanas objetivo, el AIFS-OPER pronostica T2M similar a la observada con un plazo de 14 días de antelación.

En el caso de la estación Rivadavia, es notable la subestimación de los pronósticos de todos los modelos analizados en la primera semana del evento (Figura 7b), aún en plazos cercanos al evento. En la evolución de los pronósticos para la primera semana se observa que la mediana de AIFS-ENS es mayor a la mediana de IFS, a diferencia de lo que ocurre en los pronósticos en Neuquén. Aun así, los IC no llegan a incluir la T2M observada en sus predicciones, por lo que son subdispersivos. También, se destaca que a partir de la inicialización del 24/01 el IC de IFS es menor rango que el de AIFS-ENS. Cuando la segunda semana es el objetivo de los pronósticos (Figura 7d) la dispersión de AIFS-ENS y IFS es mayor que en la primera semana, pero desde la inicialización del 01/02 los IC de ambos modelos incluyen a la T2M observada, con separación del IC climatológico semanal. Por lo tanto, 5 días antes del inicio de la semana, la señal de altas T2M es clara, a diferencia de la semana 29/01 al 04/02. En la segunda semana del evento la mediana de IFS es levemente superior a la de AIFS-ENS, mientras que el IC de AIFS-ENS es de menor rango que el de IFS. En ambas semanas objetivo, 6 días antes del inicio el AIFS-OPER converge a la mediana de AIFS-ENS.

En resumen, los pronósticos en ambas localidades tienden a subestimar la temperatura observada, a excepción de IFS en Neuquén para el inicio del evento. Como es de esperar, la dispersión del ensamble disminuye al disminuir el plazo de pronóstico, indicando menor incertidumbre. Los pronósticos pueden ser subdispersivos, como sucede Rivadavia en la primera semana objetivo. A su vez, en ambos puntos y semanas objetivo, el IC de IFS es similar o menor que AIFS-ENS. En la mayoría de los casos, IFS predice T2M mayores que AIFS-ENS y AIFS-OPER, excepto en Rivadavia en la semana inicial del evento. El modelo AIFS-OPER exhibe diferencias regionales, al pronosticar correctamente la T2M en Neuquén con plazos largos, pero subestimar la T2M en Rivadavia, en ambas semanas.

En dos casos la temperatura observada fue igual o superior al percentil 99 de la climatología observada: la primera semana en Neuquén y la segunda semana en Rivadavia. En estas instancias el modelo con I.A. AIFS-ENS incluyó la observación en el IC 7 días y 4 días antes de la semana objetivo, respectivamente. Similarmente, el modelo AIFS-OPER se posicionó con T2M cercanas a la mediana de AIFS-ENS en dichos casos. Por lo tanto, se puede concluir que los modelos de aprendizaje automático fueron capaces de pronosticar T2M en eventos poco comunes, tendiendo a la subestimación cuanto mayor es el plazo.




Fig. 7: Boxplots de la evolución de los pronósticos con objetivo en la primera semana del evento, 29/01 a 04/02, (primera fila) y la segunda semana del evento, 05/02 a 11/02, (segunda fila) en las estaciones Neuquén (a y b) y Rivadavia (c y d). Los puntos son la mediana del pronóstico, la caja es el Intervalo Intercuartil (IC) entre los percentiles 25 y 75, y los bigotes son los percentiles 99 y 1. La caja bordó indica la climatología observada en la estación y el punto verde la observación de la semana.

5. CONCLUSIONES

En este trabajo se estudiaron los pronósticos subestacionales de temperatura, dinámicos y de aprendizaje automático en evento de ola de calor entre los días 29 de enero y 11 de febrero de 2025. Se analizaron dos modelos con aprendizaje automático, AIFS-ENS y AIFS-OPER, contra un modelo dinámico IFS, todos provenientes del ECMWF.

La ola de calor elegida se caracteriza por su larga duración y por sus desplazamientos bruscos de la masa de aire cálido. Estas características la convierten de interés para explorar el desempeño de los modelos subestacionales.

En primer lugar, se explora el pronóstico diario de T2M a dos semanas, obteniendo subestimación por parte de todos los modelos en la mayoría de los días. Respecto al movimiento general de la masa de aire cálido, todos los modelos son capaces de predecir el desplazamiento pero con dificultades cuando existe un cambio abrupto y/o en plazos mayores a 10 días. Al pronosticar la segunda semana del evento, todos los modelos por igual presentan mayor subestimación que en la primera semana objetivo. Es decir, que aun con el mismo plazo, los modelos presentaron dificultades en predecir la duración e intensidad del evento.

Al analizar el pronóstico semanal a dos semanas de T2M, en la primera parte del evento se observa acuerdo entre las observaciones y los pronósticos, sin grandes diferencias entre los modelos dinámicos y de aprendizaje automático. Por lo tanto, los modelos con I.A. no presentan diferencias contra los modelos dinámicos en caracterizar el inicio del evento. Por el contrario, en la segunda mitad de la ola de calor, los valores pronosticados se diferencian entre el modelo dinámico y los de aprendizaje automático, especialmente entre 20°C y 30°C. En dicha segunda mitad, en T2M mayores a 30°C, la habilidad de todos los modelos disminuye, aumentando la subestimación.

Finalmente, se observó la evolución de los pronósticos semanales con plazos de dos semanas en dos estaciones: Neuquén y Rivadavia. Al pronosticar la semana inicial del evento, en Neuquén el desempeño fue mejor que en Rivadavia, donde hay subestimación aún en plazos cortos. Aun así, la falla en Rivadavia se observa en el modelo dinámico como en los de aprendizaje automático por igual.

Notablemente, en Neuquén, en ambas semanas objetivo y con plazos de 14 días, las medianas del ensamble son similares a la observación (diferencias menores a 3°C). Por lo tanto, los modelos dinámicos y de I.A. demostraron buen desempeño con plazos de dos semanas. Por otra parte, en Rivadavia los pronósticos subestimaron la semana inicial del evento, mientras que al pronosticar la segunda mitad del evento los modelos demostraron señal 4 días antes.

Aunque IFS tiende a T2M superiores que AIFS-OPER y AIFS-ENS, con menor dispersión, los modelos de aprendizaje automático fueron capaces de detectar una señal del evento extremo de temperatura, en las estaciones estudiadas. Como no se tiene climatología de dichos modelos, no es posible conocer si existe un sesgo de temperatura para ayudar en la predicción.

En conclusión, en este evento en particular, no se observan grandes diferencias entre los pronósticos con aprendizaje automático y los dinámicos. Los novedosos modelos de I.A. pueden ser herramientas valiosas para complementar el monitoreo de olas de calor. Es necesario estudiar más eventos de características similares para generalizar el desempeño esperado durante eventos extremos.

6. REFERENCIAS

- Alvarez, M. S., Vera, C. S., Kiladis, G. N., Liebmann, B., 2013: Intraseasonal variability in South America during the cold season. *Climate Dynamics*, 42(11-12), 3253-3269. <https://doi.org/10.1007/s00382-013-1872-z>
- Alvarez, M. S., Vera, C. S., Kiladis, G. N., Liebmann, B., 2015: Influence of the Madden Julian Oscillation on precipitation and surface air temperature in South America. *Climate Dynamics*, 46(1-2), 245-262. <https://doi.org/10.1007/s00382-015-2581-6>
- Bonev, B., Kurth, T., Hundt, C., Pathak, J., Baust, M., Kashinath, K., Anandkumar, A., 2023: Spherical Fourier Neural Operators: Learning Stable Dynamics on the Sphere (Versión 1). arXiv. <https://doi.org/10.48550/ARXIV.2306.03838>
- Castro, L. M., Godoy, A., Osman M., Spennemann P., 2025: Evaluación de productos de ECMWF para extremos de temperatura durante un evento de ola de calor en Argentina. [Nota Técnica SMN 2025-197](#).
- Coelho, C. A. S., Firpo, M. A. F., de Andrade, F. M., 2018: A verification framework for South American sub-seasonal precipitation predictions. *Meteorologische Zeitschrift*, 27(6), 503-520. <https://doi.org/10.1127/metz/2018/0898>
- Domeisen, D. I. V., White, C. J., Afargan-Gerstman, H., Muñoz, Á. G., Janiga, M. A., Vitart, F., Wulff, C. O., Antoine, S., Ardilouze, C., Batté, L., Bloomfield, H. C., Brayshaw, D. J., Camargo, S. J., Charlton-Pérez, A., Collins, D., Cowan, T., del Mar Chaves, M., Ferranti, L., Gómez, R., ... Tian, D., 2022: Advances in the Subseasonal Prediction of Extreme Events: Relevant Case Studies across the Globe. *Bulletin of the American Meteorological Society*, 103(6), E1473-E1501. <https://doi.org/10.1175/bams-d-20-0221.1>
- ECMWF official site. *AIFS ENS 1 vs ifs scorecard*. Último acceso 26 enero 2026. https://sites.ecmwf.int/aifs/scorecards/aifs_ens_1.html
- Lang, S., Alexe, M., Clare, M. C. A., Roberts, C., Adewoyin, R., Bouallègue, Z. B., Chantry, M., Dramschi, J., Dueben, P. D., Hahner, S., Maciel, P., Prieto-Nemesio, A., O'Brien, C., Pinault, F., Polster, J., Raoult, B., Tietsche, S., & Leutbecher, M., 2024: AIFS-CRPS: Ensemble forecasting using a model trained with a loss function based on the Continuous Ranked Probability Score (Versión 1). arXiv. <https://doi.org/10.48550/ARXIV.2412.15832>
- Lang, S., Alexe, M., Chantry, M., Dramschi, J., Pinault, F., Raoult, B., Clare, M. C. A., Lessig, C., Maier-Gerber, M., Magnusson, L., Bouallègue, Z. B., Nemesio, A. P., Dueben, P. D., Brown, A., Pappenberger, F., & Rabier, F., 2024: AIFS -- ECMWF's data-driven forecasting system (Versión 2). arXiv. <https://doi.org/10.48550/ARXIV.2406.01465>
- Lam, R., Sanchez-Gonzalez, A., Willson, M., Wirsberger, P., Fortunato, M., Alet, F., Ravuri, S., Ewalds, T., Eaton-Rosen, Z., Hu, W., Meroze, A., Hoyer, S., Holland, G., Vinyals, O., Stott, J., Pritzel, A., Mohamed, S., & Battaglia, P., 2023: Learning skillful medium-range global weather forecasting. *Science*, 382(6677), 1416-1421. <https://doi.org/10.1126/science.adi2336>
- Maskell, K., Vuckovic, M., 2025: *Operational Configurations of the Integrated Forecasting System (IFS) - Forecast User - ECMWF Confluence Wiki*. Último acceso 26 enero 2026. <https://confluence.ecmwf.int/pages/viewpage.action?pageId=324860211>

Olivetti, L., & Messori, G., 2024: Do data-driven models beat numerical models in forecasting weather extremes? A comparison of IFS HRES, Pangu-Weather, and GraphCast. *Geoscientific Model Development*, 17(21), 7915-7962. <https://doi.org/10.5194/gmd-17-7915-2024>

Pegion, K., Kirtman, B. P., Becker, E., Collins, D. C., LaJoie, E., Burgman, R., Bell, R., DelSole, T., Min, D., Zhu, Y., Li, W., Sinsky, E., Guan, H., Gottschalck, J., Metzger, E. J., Barton, N. P., Achuthavarier, D., Marshak, J., Koster, R. D., ... Kim, H., 2019: The Subseasonal Experiment (SubX): A Multimodel Subseasonal Prediction Experiment. *Bulletin of the American Meteorological Society*, 100(10), 2043-2060. <https://doi.org/10.1175/bams-d-18-0270.1>

Vuckovic, M., 2025: *Operational Configurations of the Artificial Intelligence Forecasting System (AIFS) - Forecast User - ECMWF Confluence Wiki*. Último acceso 26 enero 2026. <https://confluence.ecmwf.int/pages/viewpage.action?pageId=601298799>

Servicio Meteorológico Nacional, 2025: *Informe Subestacional 28 de Enero 2025. Boletines históricos*. Último acceso 20 de Marzo 2026. <https://www.smn.gob.ar/boletines/boletines-historicos>

Stella, J. L., 2025: Informe Especial N°3 por ola de calor / Altas Temperaturas Temporada 2024-2025, Servicio Meteorológico Nacional. [Informe N°3](#)


Wang, Y., Gao, L., Ren, H.-L., Wang, L., 2025: Subseasonal Extreme Forecast Index for High Temperature Based on the ECMWF S2S Model Data. *Journal of Meteorological Research*, 39(5), 1299-1315. <https://doi.org/10.1007/s13351-025-4199-x>

WMO, 2025: *Heat and health*. World Health Organization. Último acceso 27 Diciembre 2025. <https://www.who.int/news-room/fact-sheets/detail/climate-change-heat-and-health>.


Zhang, Z., Fischer, E., Zscheischler, J., Engelke, S., 2025: Numerical models outperform AI weather forecasts of record-breaking extremes.

ANEXO

a)



b)



c)





Fig. 8: Diferencia de temperatura entre los pronósticos diarios inicializados el 22-01-2025 a las 00Z y las observaciones de SMN para la primera semana del evento. (a) la media del ensemble del modelo dinámico IFS, (b) el pronóstico del modelo AIFS operativo y (c) la media del ensemble del modelo AIFS.


a)

T2M Bias Diario IFS vs CRC-SAS
Semana 2 Inicializacion: 2025-01-2900Z



b)

T2M Bias Diario AIFS Media Ensamble vs CRC-SAS
Semana 2 Inicializacion: 2025-01-2900Z



c)

T2M Bias Diario AIFS Operacional vs CRC-SAS
Semana 2 Inicializacion: 2025-01-2900Z




Fig. 9: Idem Figura 8 inicializados el 29-01-2025 a las 00Z para la segunda semana del evento.

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.