

MODELADO REGIONAL DE UN ÍNDICE DE ESTRÉS TÉRMICO EN EL CENTRO Y NORTE DE ARGENTINA UTILIZANDO REDES NEURONALES CONVOLUCIONALES.

Candela S. Glatstein¹, Rocio Balmaceda-Huarte¹², Maria Laura Bettolli¹²
candeglatstein@gmail.com

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

²Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)

Palabras clave: Estrés térmico, temperatura de bulbo húmedo, redes neuronales convolucionales.

1) INTRODUCCIÓN

La reducción de escala estadística (SD, por sus siglas en inglés) es una herramienta clave para generar información climática de alta resolución, adecuada para los análisis de impacto, especialmente aquellos que se basan en índices climáticos y la superación de ciertos umbrales. En este contexto, las redes neuronales convolucionales (CNNs) se han popularizado como métodos de machine learning prometedores para su uso como técnicas de SD, ya que permiten manejar grandes volúmenes de datos -necesarios para realizar estudios climáticos- y extraer estructuras espaciales relevantes de manera automática para cada sitio. Estas características suponen una ventaja importante frente a técnicas tradicionales de SD, que suelen requerir una selección manual de predictores.

En el sur de Sudamérica (SSA), las CNNs han demostrado ser eficaces para simular temperaturas extremas diarias en condiciones presentes y bajo diferentes escenarios futuros (Balmaceda-Huarte et al., 2024). Sin embargo, la evaluación de diferentes configuraciones de CNN asociadas a su arquitectura, como la elección de la función de activación, son aún un área poco explorada en la región. Más aún, la evaluación de las CNN como técnica de SD para la simulación de índices multivariados de impacto, como los índices de estrés térmico, no se ha llevado a cabo en SSA hasta el momento. Con el fin de abordar estos vacíos, el objetivo de este trabajo es evaluar el desempeño de las CNNs bajo diferentes configuraciones como técnica de SD para simular un índice de estrés térmico durante el verano en el centro y norte de Argentina.

2) METODOLOGÍA

Para la implementación de las CNNs se utilizaron como variables predictando datos observados de temperatura del aire y temperatura de rocío en las horas principales de los meses de verano (Diciembre-Enero-Febrero, DEF) de 43 estaciones ubicadas en el norte y centro de Argentina en el período 1991-2024. Con el fin de abarcar las condiciones más cálidas del año se consideró el trimestre de verano. Como variables predictoras de gran escala se utilizaron los campos diarios del reanálisis ERA5 de temperatura del aire (t_a), altura geopotencial (z), humedad específica (q), viento zonal y meridional (u y v , respectivamente) en 5 niveles de presión (250, 500, 700, 850 y 1000 hPa) y la presión del nivel medio del mar (msl), en el dominio extendido de 40° – 90° W y 14° – 60° S. Estas fueron seleccionadas teniendo en cuenta que son representativas tanto de la circulación como de la termodinámica de la atmósfera y que a su vez, poseen la señal de cambio climático (Balmaceda-Huarte and Bettolli, 2022). Con el objetivo de alinear la resolución de los predictores con la de los GCMs, para futuras aplicaciones, estos fueron reescalados de 0.25° x 0.25° a una retícula espacial de 1° , mediante una interpolación bilineal.

Se emplearon cuatro configuraciones distintas de redes neuronales convolucionales (CNN) que varían según tres aspectos (Baño-Medina et al 2020): la función de activación (ReLU o lineal, indicadas como R y L respectivamente), el tamaño del dominio de los predictores considerado como entrada y el diseño de la última capa (tamaño del filtro). En todos los casos, la SD se abordó bajo el enfoque de Perfect Prognosis. Los modelos se entrenaron para simular la temperatura de bulbo húmedo máxima diaria (TWx) considerada como índice de estrés térmico, la cual es calculada a partir de la temperatura máxima diaria (Tx) y la humedad relativa media diaria (HRm).

El entrenamiento de las redes se realizó utilizando un esquema de validación cruzada (CV, por su nombre en inglés) con datos diarios de DEF en el período 1991–2020. Adicionalmente, las redes fueron evaluadas en forma independiente para los veranos 2021, 2022, 2023 y 2024.

A modo comparativo, se aplicó la misma metodología para simular Tx, con el fin de analizar las diferencias en la capacidad de simulación entre ambas variables. En todos los casos, se analizó el valor agregado de las CNNs, comparando los resultados con los datos de superficie de ERA5. La evaluación de desempeño se basó en métricas como el sesgo (BIAS), el percentil 95 (P95) y dos índices de frecuencia: el número de días en las que se superó el P95 (P95p) y el número de días en que se superaron determinados umbrales fijos (35°C para Tx, Tx35p y 25° para TWx, TWx25p).

3) RESULTADOS Y DISCUSIÓN

En la Figura 1 se presentan boxplots de las métricas evaluadas para las dos variables. Los resultados obtenidos muestran que las CNNs presentan un buen desempeño en la simulación tanto de Tx como de TWx, con errores sistemáticos reducidos y una adecuada representación de los extremos. No obstante, las CNNs simulan TWx con mayor precisión que Tx, mostrando menores valores de BIAS y mejores estimaciones del percentil 95 (P95) en la mayoría de las estaciones.

Al analizar el valor agregado con respecto a ERA5, puede observarse que las CNNs tienen sesgos cercanos a cero para ambas variables, mientras que el reanálisis ERA5 exhibe un sesgo sistemático negativo, especialmente marcado en el caso de TWx. En relación a los extremos, las CNNs representan mejor el valor del P95, con menor dispersión entre estaciones.

Asimismo, al analizar la cantidad de días por verano en que se superan los umbrales fijos (Tx35p y TWx25p) se evidencia que ERA5 tiende a subestimar el número de días en la TWx, mientras que las CNNs se ajustan mejor a las observaciones. Entre las configuraciones

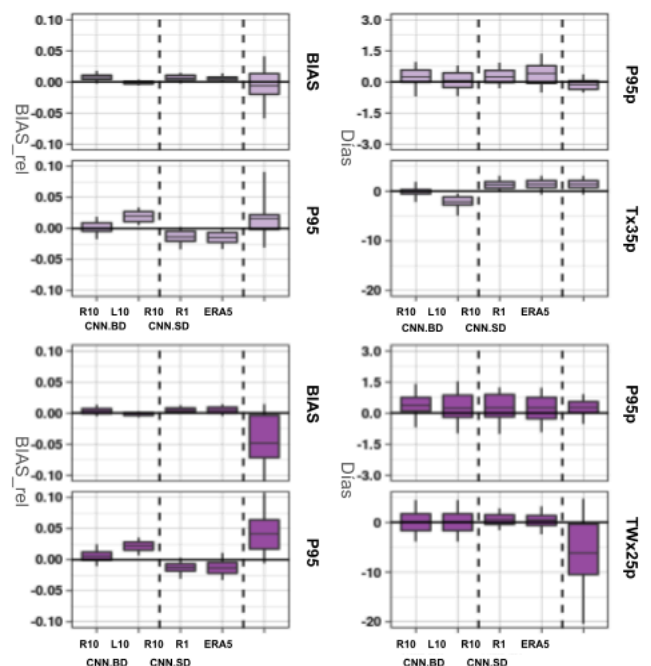


Figura 1: Resultados de la CV para Tx (arriba) y TWx (abajo) para todas las estaciones. Se muestran las 4 configuraciones de CNNs estudiadas y ERA5. En cada caja, la marca central corresponde a la media, y los bordes inferiores y superiores a los percentiles 25 y 75, respectivamente. Los bigotes se extienden al percentil 5 y 95.

evaluadas, los modelos con un dominio espacial móvil más pequeño (CNN.SD) fueron sistemáticamente los más precisos, tanto para Tx como para TWx. Dentro de estos, se observó que la reducción del tamaño del filtro en la última capa (R1) mejora levemente la simulación de Tx. Por otro lado, cuando se utiliza un dominio amplio (CNN.BD), se identifican algunas diferencias entre funciones de




Figura 2: Diagramas de Taylor para Tx (izquierda) y TWx (derecha), para la CV (puntos llenos) y para los veranos estudiados de manera independiente (formas sin relleno). En colores se muestran las distintas CNNs y ERA5 y el punto negro indica la observación como referencia).

dispersas en los diagramas de Taylor de Tx que de TWx).

4) CONCLUSIONES

Los resultados de este estudio evidencian el potencial de las CNNs como herramienta de reducción de escala estadística para simular variables climáticas de impacto en el centro y norte de Argentina. Las CNNs superan a ERA5 en la representación de los valores medios y los extremos, presentando un mejor desempeño en TWx. En este sentido, los resultados sugieren que las CNNs simulan la TWx con mayor robustez, lo que refuerza su aplicabilidad en evaluaciones de impacto por estrés térmico. Las configuraciones con dominio reducido muestran el mejor desempeño y refuerzan la importancia de la información local, por encima de la arquitectura y la función de activación. En este sentido las CNNs, muestran potencial como herramientas para generar información regional de estrés térmico en el norte de Argentina.

REFERENCIAS

- Balmaceda-Huarte R,** Bettolli ML (2022) Assessing statistical downscaling in Argentina: daily maximum and minimum temperatures. *Int J Climatol*. <https://doi.org/10.1002/joc.7733>
- Balmaceda-Huarte, R.,** Baño-Medina, J., Olmo, M. E., & Bettolli, M. L. (2024). On the use of convolutional neural networks for downscaling daily temperatures over southern South America in a climate change scenario. *Climate Dynamics*, 62(1), 383-397.
- Baño-Medina, J.,** Manzanar, R., & Gutiérrez, J. M. (2020). Configuration and intercomparison of deep learning neural models for statistical downscaling. *Geoscientific Model Development*, 13(4), 2109-2124.
- Casanueva, A.,** Kotlarski, S., Herrera, S., Fischer, A. M., Kjellstrom, T., & Schwierz, C. (2019). Climate projections of a multivariate heat stress index: the role of downscaling and bias correction. *Geoscientific Model Development*, 12(8), 3419-3438.

activación. En la evaluación de los veranos independientes (Figura 2), las CNNs mantuvieron un desempeño similar al del periodo de CV para ambas variables. De acuerdo con los resultados de CV, la simulación de TWx en los veranos más recientes, mostró un mayor acuerdo entre modelos comparado con Tx, la cual exhibió mayores discrepancias entre configuraciones (nubes de puntos más