

REGIONALIZACIÓN DE LA PRECIPITACIÓN EXTREMA EN ARGENTINA BASADA EN LA TEMPERATURA MÁXIMA MEDIANTE UN INNOVADOR ENFOQUE DE ANÁLISIS DE EXTREMOS

Melanie Meis¹, Ramiro Saurral², Mariela Sued³, Patricia Menendez⁴
mmeis@dcao.uba.ar

¹Dto. de Ciencias de la Atmósfera y los Océanos. Facultad de Cs. Exactas y Naturales. Universidad de Buenos Aires (DCAO-FCEN). CONICET – Universidad de Buenos Aires. Centro de Investigaciones del Mar y la Atmósfera (CIMA). Buenos Aires, Argentina. CNRS – IRD – CONICET – UBA. Instituto Franco-Argentino para el Estudio del Clima y sus Impactos (IRL 3351 IFAECI). Buenos Aires, Argentina.

²Barcelona Supercomputing Center (BSC), Barcelona, Spain.

³Universidad de San Andrés, Instituto de Cálculo, Facultad de Ciencias Exactas y Naturales, Universidad de Buenos Aires – CONICET, Buenos Aires, Argentina.

⁴School of Mathematics and Statistics, The University of Melbourne, Melbourne, Australia.

Palabras clave: Eventos extremos, sistema de alerta, covariabilidad climática.

1) INTRODUCCIÓN

Los eventos de precipitación extrema han aumentado globalmente y en Argentina en las últimas décadas (Hannart, 2015; Rivera, 2021), desafiando modelos predictivos y políticas de gestión. Mientras que los estudios tradicionales analizan variables atmosféricas de forma aislada, el enfoque actual busca integrar múltiples procesos para comprender mejor las anomalías de precipitación. En este marco, se propone una metodología que combina modelos de series temporales y regresión por cuantiles, utilizando la temperatura máxima diaria como predictora. Este enfoque permite identificar patrones físicos, comprender la covariabilidad entre variables y mejorar la regionalización de eventos extremos (Meis et al., 2024).

2) DATOS Y METODOLOGÍA

Consideramos datos diarios de precipitación y temperatura máxima de 32 estaciones meteorológicas in-situ de Argentina para el periodo Enero-1980 a Diciembre-2019. Los datos fueron obtenidos a través del Servicio Meteorológico Nacional (SMN), (Tabla I).

Estudiamos el proceso conjunto de temperatura (X) y precipitación (Y), modelando los eventos extremos de esta relación condicional. Nuestro objetivo es entender la relación entre estos dos procesos climáticos y determinar la ocurrencia de eventos extremos de precipitación en función de la temperatura máxima diaria.

Dado un nivel τ entre 0 y 1 vamos a estimar el percentil τ de precipitación condicional al valor de temperatura $Q_{Y|X}(\tau) = F_{Y|X}^{-1}(\tau)$ que puede ser representada como la solución a la siguiente Ec.1:

$$Q_{Y|X}(\tau) := \arg \min_{a \in \mathbb{R}} \mathbb{E}_{Y|X}(\rho_{\tau}(Y - a))$$

Donde $\rho_{\tau}(u)$ es una función de costo.

De esta manera vamos a proponer dos pasos para la estimación de la precipitación extrema:

- 1) Vamos a modelar el proceso de temperatura máxima diaria (\hat{X}_i) y utilizar estos valores modelados en la Ec.1. De esta manera podremos describir y cuantificar la estructura temporal del proceso de temperatura de varios días en un único valor. Esto involucra evaluar la no estacionariedad de la serie y luego aplicar un modelo de regresión armónica dinámica con componentes autoregresivas y estacionales Ec.2:

$$X_t = c + \sum_{i=1}^p \varphi_i X_{t-i} + S_t + \epsilon_t$$

Donde $c \in \mathbb{R}$ es una constante, $\varphi_i \in \mathbb{R}, i = 1, \dots, p$ son los coeficientes de la componente autoregresiva con el orden de número necesarios de los valores temporales precedentes para predecir la medición al tiempo t , S_t representa la componente estacional y ϵ_t es la secuencia de ruido blanco. La parte autoregresiva del modelo captura la dependencia temporal de las temperatura a través de los diferentes lags, utilizando el parámetro p , logramos modelar la persistencia de las condiciones atmosféricas en el tiempo.

Estación	Longitud	Latitud	Acronimo
Aeroparque	-58.25	-34.34	AER
Bahia Blanca	-62.10	-38.44	BBL
Bariloche	-71.10	-41.09	BAR
Catamarca	-65.46	-28.36	CAT
Cordoba	-64.12	-31.18	CBA
Corrientes	-58.46	-27.27	COR
Esquel	-71.10	-42.56	ESQ
Formosa	-58.14	-26.12	FOR
Iguazu	-54.28	-25.44	IGU
Jachal	-68.50	-30.14	JAC
Jujuy	-65.05	-24.23	JUJ
Laboulaye	-63.20	-34.08	LAB
La Plata	-57.54	-34.58	LPL
La Quiaca	-65.40	-22.06	LQU
Malargue	-69.40	-35.30	MAL
Mar del Plata	-57.58	-37.93	MDQ
Mendoza	-68.47	-32.50	MEN
Parana	-60.48	-31.78	PAR
Posadas	-55.58	-27.22	POS
Resistencia	-59.42	-27.27	RES
Rio Cuarto	-64.10	-33.07	RCU
Rio Gallegos	-69.17	-51.37	RGA
Salta	-65.29	-24.51	SAL
San Juan	-68.25	-31.34	SJU
Santa Rosa	-64.16	-36.34	SRO
Santiago del Estero	-64.18	-27.46	SDE
Sauce Viejo	-60.49	-31.42	SVI
Tandil	-59.20	-37.14	TAN
Trelew	-65.16	-43.12	TRE
Tucuman	-65.10	-26.85	TUC
Ushuaia	-68.31	-54.80	USH
Viedma	-63.00	-40.51	VIE

Tabla I: nombre, longitud, latitud y acrónimos de las estaciones meteorológicas utilizadas.

2) Estimamos los cuantiles extremos (con valores no nulos de precipitación) de la distribución condicional de precipitación basados en la temperatura máxima. En este sentido asumimos una regresión de cuantiles por polinomios y estimamos el cuantil mediante la Ec. 3:

$$(\hat{\beta}_0, \dots, \hat{\beta}_k) = \arg \min_{\beta} \frac{1}{N} \sum_{i=1}^N (\rho_{\tau}(\log(Y_i) - (\beta_0 + \beta_1 \hat{X}_i + \dots + \beta_k \hat{X}_i^k)))$$

Donde N representa el número totales de observaciones en cada estación in-situ, i corresponde con el valor i -ésimo de observación de precipitación, \hat{X}_i son las temperaturas simuladas y $\hat{\beta}_0, \dots, \hat{\beta}_k, k \in \mathbb{R}$ los coeficientes de la regresión de cuantiles estimados. Aplicamos logaritmo al valor de precipitación para modelar una relación exponencial. Luego, \hat{X}_i e Y fueron separados en verano (DIC-ENE-FEB) e invierno (JUN-JUL-AGO). Para la elección de los hiperparametros del modelo empleamos validación cruzada con el 80% inicial de los datos, mientras que el 20% restante fue utilizado para evaluar el comportamiento del modelo seleccionado. Para validar nuestro modelo utilizamos una medida de error estándar, la función de costo de la regresión de cuantiles. De esta forma, evaluamos la diferencia en magnitudes entre el modelo propuesto y el modelo que solo utiliza datos de precipitación para estimar los cuantiles (modelo nulo).

Por último, de acuerdo al valor de p clasificamos la dependencia temporal en tres categorías de complejidad de procesos de memoria temporal: bajo (1,2), mediano (3,4) y alto (5,6). También de acuerdo al orden polinomial de la serie de regresión distinguimos en cuatro casos: lineales, cuando los coeficientes de grado mayor a uno son cercanos a cero; cuadráticos cuando los grados mayores a dos son cercanos a cero; lineales-cuadráticos cuando la forma está asociada a una parte lineal y otra parte cuadrática; y por último ni lineal ni cuadrática cuando no abarca ninguna de las clasificaciones anteriores.

3) RESULTADOS

Utilizando el cuantil 0.9 de la precipitación y considerando la temperatura máxima diaria como variable predictora independiente, encontramos que el método propuesto supera al modelo nulo en aproximadamente el 47% de las estaciones durante la temporada de verano. Por otra parte, exhibimos para la época de verano la Fig. 1, donde hallamos una consistencia geográfica en los valores óptimos del parámetro p . Esta coherencia espacial es esperable, dado que los valores de p reflejan el tipo de relación entre la temperatura y los eventos extremos de precipitación en cada región. Por lo tanto, es razonable que regiones

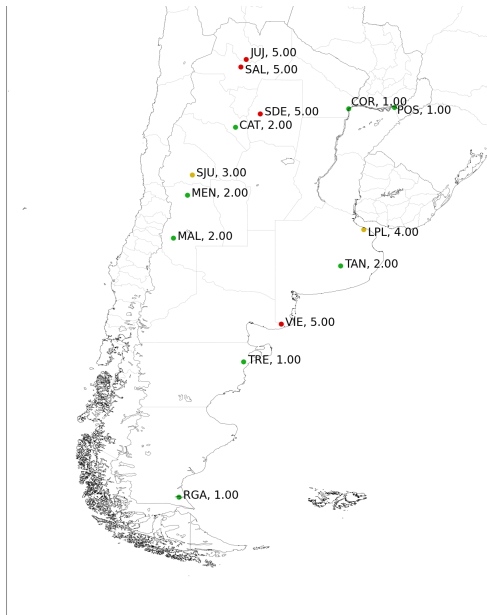


Fig 1: Valores de p para las estaciones que presentaron una performance mejor que el modelo nulo. La clasificación de colores es de acuerdo a la memoria del proceso, verde (proceso de baja complejidad; dorado y rojo . Meis, et al. 2024.

geográficamente cercanas, al compartir condiciones climáticas similares, presenten valores de p coherentes entre sí. A modo de ejemplo podemos describir la región Noroeste, en la misma se observa que la mayoría de las estaciones presentan un valor elevado de p , por lo cual podemos inferir que es una región donde los procesos físicos involucrados que afectan a la temperatura y la precipitación extrema son complejos. Esto podría estar relacionado con la Depresión del Noroeste Argentino donde el sistema de baja presión se intensifica durante el verano debido al origen termal-orográfico y las altas temperaturas dominan inhibiendo la precipitación. En cuanto a la relación obtenida entre temperatura y logaritmo de precipitación mediante el modelo de regresión polinomial, observamos que la mayoría de las relaciones identificadas son lineales o cuadráticas. En el primer caso podemos atribuir el patrón a la relación de Clausius-Clayperon, a mayor temperatura mayor es la capacidad de la atmósfera de contener vapor de agua, dando lugar a mayor posibilidad de

precipitación. En cuanto al segundo tipo de relación, se observa un crecimiento de precipitación hasta cierto umbral y luego los extremos de precipitación empiezan a disminuir, lo cual puede estar causado por un gran déficit de saturación inducido por la temperatura.

Durante la época de invierno distinguimos tres regiones: una al noreste (20°S - 35°S), otra en la zona este-central (35°S - 40°S) y una región al sur más allá de los 40°S . La primera región involucra a IGU, POS SVI, PAR y RES, en la cual hemos destacado la posible coexistencia de procesos complejos y de baja complejidad. La segunda región formada por AER, LAB, LPL y MDQ, presentan procesos de baja complejidad para las primeras dos estaciones y alta complejidad para las últimas dos. Esto podría estar asociado con procesos rápidos asociados a la temperatura mientras que en el caso de LPL y MDQ podría pensarse en sistemas frontales que resultan dominantes en la temporada de invierno en dichas regiones. Por último en la región sur, VIE, ESQ y BAR, observamos procesos de baja complejidad al oeste y mediana complejidad cercana a la costa. Además, en ESQ podría estar asociada a la presencia de los ríos atmosféricos donde los canales de humedad contribuyen a la generación de precipitación extrema.

4) CONCLUSIÓN

El método propuesto permite caracterizar la dependencia temporal entre la temperatura máxima diaria y la ocurrencia de precipitación extrema, identificando cuántos días previos de temperatura ejercen una influencia significativa en la ocurrencia de precipitaciones extremas en cada región. Esta aproximación facilita la regionalización, cuantificación y clasificación de la covariabilidad entre ambas variables meteorológicas en el sur de Sudamérica.

5) AGRADECIMIENTOS

PICT-2021-SerieA-4914 y UBA N°20020220400093BA de la Programación Científica 2023.

6) REFERENCIAS

- Hannart, A., Vera, C., Otto, F. E. L., Cerne, B. (2015). 9. Causal influence of anthropogenic forcings on the Argentinian heat wave of december 2013. Bulletin of the American Meteorological Society, 96(12), S41-S45.
- Meis, M., Sued, M., Saurral, R. I., Menéndez, P. (2024). A novel statistically-based approach to regionalize extreme precipitation events using temperature data. Natural Hazards, 1-23.
- Rivera, J., Otta, S., Lauro, C., Zazulie, N. (2021). A decade of hydrological drought in Central-Western Argentina. Frontiers in Water, 3.