

Estudio sobre la relación de eventos extremos de precipitación y temperatura en Argentina durante la época de verano

Melanie Meis^{1,2,3,4}, Ramiro Saurral^{1,2,3,4}, Mariela Sued^{1,5}

melanie.meis@cima.fcen.uba.ar

¹Universidad de Buenos Aires (UBA)

²Departamento de Ciencias de la Atmósfera y los Océanos (DCAO)

³Centro de Investigaciones del Mar y la Atmósfera (CONICET-UBA)

⁴CNRS – IRD – CONICET – UBA. Instituto Franco-Argentino para el Estudio del Clima y sus Impactos

⁵Instituto del Cálculo (CONICET-UBA)

Palabras clave: eventos extremos, relaciones bivariadas, procesos físicos.

1) INTRODUCCIÓN

Inundaciones, sequías, olas de calor y de frío resultan ser fenómenos complejos asociados a eventos extremos de precipitación y temperatura. Trabajos recientes han destacado la importancia de considerar el análisis conjunto de la precipitación y temperatura para analizar dichos eventos (Tencer et al. 2016; Bevacqua et al. 2022). Más aún, la necesidad de estudiar y profundizar en el análisis de eventos extremos radica en que un aumento en la intensidad y la frecuencia de estos es esperable para las próximas décadas (Hay et al., 2016; entre otros).

En particular, los trabajos de Tencer et al. (2016) y Olmo et al. (2020) son dos ejemplos del estudio de la covariabilidad entre la precipitación y la temperatura en la región del sur de Sudamérica. En el primer caso se han explorado los patrones de circulación atmosférica asociada con la ocurrencia conjunta de eventos extremos de precipitación y temperatura encontrando que los modelos climáticos regionales (RCMs) resultan, en general, una herramienta no muy eficiente para simular la relación entre las variables. Asimismo, en el segundo trabajo, los autores lograron identificar que la ocurrencia de una noche cálida o un día frío aumenta significativamente la probabilidad de ocurrencia de precipitación extrema en el sur de Chile como así también en la región del sudeste de Sudamérica.

En este trabajo se propone una metodología estadística para estudiar la covariabilidad entre la precipitación extrema y la temperatura durante la época de verano en la Argentina. Además, se mencionan los posibles procesos físicos involucrados.

2) DATOS Y METODOLOGÍA

Se contó con una base de datos diarios de precipitación, y temperatura máxima y mínima de 32 estaciones meteorológicas de la Argentina entre enero 1980 y diciembre 2019. Los datos fueron obtenidos del Servicio Meteorológico Nacional (SMN). En la Tabla I se muestra la ubicación y los nombres de las estaciones analizadas junto con sus acrónimos. Con respecto a la calidad de la información utilizada, los datos faltantes representaron menos del 15%.

Para estudiar la relación bivariada entre la precipitación extrema (Y) condicional a la temperatura (X) propusimos un modelo estadístico semi paramétrico. En este sentido, en primer lugar, se propone un modelo para estimar cuantiles extremos de precipitación (percentiles 0.90 y 0.95) condicionales a los valores de temperatura (Ec.1).

$$Q_{\tau}(X) = Q_{\tau}(F_{(Y|X)}) \quad (1)$$

Con τ igual a 0.90 y 0.95

Primeramente, separamos los datos en un conjunto de entrenamiento (el primer 80%) y otro de testeo (el 20% restante) preservando su orden temporal. Considerando el primer 80% de los

datos modelamos la variable temperatura mediante un modelo autoregresivo (AR) (Ec.2)

$$X_t = c + \sum_{i=1}^p \varphi_i X_{t-i} + \varepsilon_t \quad (2)$$

Con c una constante, φ_i los parámetros del modelo con $1 \leq i \leq p$ y ε_t un término de ruido blanco.

En el caso de la variable independiente permitimos que el parámetro del modelo asociado a la temperatura pueda contener la información de a lo sumo diez días atrás. En este sentido, pretendemos modelar los valores extremos de precipitación considerando una combinación de valores laggeados de temperatura mediante un modelo AR con un i máximo igual a 10.

Luego, incorporamos a un modelo de regresión polinómica por cuantiles como variable independiente a la temperatura ajustada por el modelo AR Ec.(1), y al logaritmo de la precipitación únicamente en los días que la precipitación fue mayor a cero como dependiente. De esta manera, dado un valor fijo del grado del polinomio (k) vamos a buscar los coeficientes $\widehat{\beta}_k$ que satisfacen que:

$$\widehat{\beta}_k = (\widehat{\beta}_0, \dots, \widehat{\beta}_k) = \underset{\beta_0, \dots, \beta_k}{\operatorname{argmin}} \sum_{i=1}^n \rho_\tau(Y_i - (\beta_0 + \beta_1 X + \dots + \beta_k X^k)) \quad (3)$$

Con ρ_τ asociada a la función de pérdida $\rho_\tau(u) = (\tau - 1)uI_{u < 0} + \tau uI_{u \geq 0}$

Para poder seleccionar los hiperparámetros del modelo propuesto (la cantidad de términos p del modelo AR y el grado del polinomio k) realizamos una validación cruzada empleando los datos de entrenamiento. Asimismo, para poder validar nuestros resultados comparamos el desempeño del modelo propuesto con un modelo nulo que únicamente considera los datos de precipitación.

Estación	Longitud	Latitud	Acrónimo
Aeroparque	-58.25	-34.34	AER
Bahía Blanca	-62.10	-38.44	BBL
Bariloche	-71.10	-41.09	BAR
Catamarca	-65.46	-28.36	CAT
Córdoba	-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
Río Cuarto	-64.10	-33.07	RCU
Río 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
Tucumán	-65.10	-26.85	TUC
Ushuaia	-68.31	-54.80	USH
Viedma	-63.00	-40.51	VIE

Tabla I: Nombre de la estación meteorológica, longitud, latitud y acrónimos para los nombres de las estaciones.

3) RESULTADOS

De acuerdo con la Sección 2 estimamos la proporción de veces que nuestro modelo era mejor que el modelo nulo para todas las combinaciones de variable predictora (temperatura máxima y mínima) junto con los dos posibles percentiles extremos a estimar (0.90 y 0.95) de

precipitación para la época de verano en todas las estaciones de medición consideradas. De esta forma se obtuvo que la estimación del percentil 0.90 de la precipitación y la temperatura máxima como variable independiente presentaron el mejor desempeño del modelo sobre el nulo un 44% de las veces.

De esta manera, en este trabajo se profundizará únicamente en este resultado. En la Figura 1 se observa la ubicación de las estaciones para las cuales el modelo de regresión propuesto fue

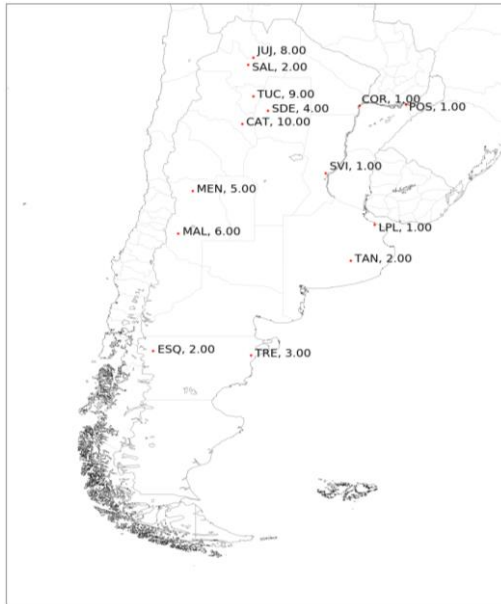


Figura 1: Estaciones que cumplen el criterio propuesto para el percentil 0.9 de la precipitación cuando la temperatura máxima es la variable predictor

mejor que el modelo nulo para el percentil 0.90 cuando la temperatura máxima fue la variable predictor. Asimismo, se exhibe el valor de p asociado a la cantidad de términos del modelo AR obtenido mediante validación cruzada. En particular, un mayor valor de p indica la existencia de mayor variabilidad en la serie de temperatura, es decir, que el proceso que explica el impacto en la precipitación debido a la temperatura es necesariamente más complejo. De la figura anterior se puede distinguir tres regiones muy notorias: la región del Noreste de Argentina (NEA), del Noroeste (NOA) y centro. La primera región compuesta por las estaciones de COR, POS y SVI con un valor de p igual a 1, indicando que el proceso que modela la temperatura para predecir eventos extremos de precipitación es poco complejo, siendo probablemente un proceso físico que ocurre de manera rápida sin una gran variabilidad en la temperatura (fenómeno del tipo tropical). Por otro lado, en la región del NOA y centro

fueron varias las estaciones que presentaron una mejora contra el modelo nulo (JUJ, SAL, TUC, SDE y CAT). Se puede observar que JUJ, TUC, CAT y SDE consideraron una mayor cantidad de términos p asociados al proceso AR que la región anterior. De esta manera, podríamos decir que en esta región se atraviesa un proceso físico más complejo y de mayor duración entre la temperatura y la precipitación extrema. Más aún, para la mayoría de estas últimas estaciones el modelo de regresión obtenido prácticamente exhibió una relación lineal entre la temperatura y los valores extremos de precipitación. En este sentido, podríamos asociar este resultado a un fenómeno de ola de calor, donde se espera que a mayor temperatura la atmósfera presente mayor capacidad de contener vapor de agua, y así dar lugar a mayor precipitación (relación de Clausius-Clayperon).

4) CONCLUSIONES

Mediante la metodología propuesta se logró implementar una herramienta útil que permitió analizar la covariabilidad entre la temperatura máxima y mínima diaria con percentiles extremos de precipitación. Más aún, el método estadístico nos permitió identificar regiones con ciertas relaciones entre las variables y enumerar posibles procesos físicos involucrados.

REFERENCIAS

- Tencer, B., Bettolli, M. L., y Rusticucci, M., 2016. Compound temperature and precipitation extreme events in southern South America: associated atmospheric circulation, and simulations by a multi-RCM ensemble. *Climate Research*, 68(2-3), 183-199.
- Olmo, M., Bettolli, M. L., y Rusticucci, M., 2020. Atmospheric circulation influence on temperature and precipitation individual and compound daily extreme events: Spatial variability and trends over southern South America. *Weather and Climate Extremes*, 29, 100267.
- Hay, J. E., Easterling, D., Ebi, K. L., Kitoh, A., y Parry, M., 2016. Introduction to the special issue: Observed and projected changes in weather and climate extremes. *Weather and climate extremes*, 11, 1-3.
- Bevacqua, E., Zappa, G., Lehner, F., y Zscheischler, J., 2022. Precipitation trends determine future occurrences of compound hot-dry events. *Nature Climate Change*, 12(4), 350-355.