



UNIVERSIDAD NACIONAL DE TUCUMÁN

Facultad de Ciencias Exactas y Tecnología

Departamento de Física

Forzantes naturales y antropogénicos de la variación a largo plazo de la precipitación extrema en el Noroeste Argentino

Tesis presentada para acceder al título de
“Doctor en Ciencias Exactas e Ingeniería”

Tesista: **Lic. Franco D. Medina**

Directora: Dra. Ana G. Elias

Lugar de trabajo: Laboratorio de Ionósfera, Atmósfera Neutra y Magnetósfera (LIANM), Departamento de Física, Facultad de Ciencias Exactas y Tecnología, Universidad Nacional de Tucumán.

San Miguel de Tucumán, 2024

Forzantes naturales y antropogénicos de la variación a largo plazo de la precipitación extrema en el Noroeste Argentino

Resumen

En este trabajo se analiza la variabilidad interanual y de más largo plazo de la precipitación extrema en el Noroeste Argentino (NOA) en relación a forzantes naturales y antropogénicos. El principal foco de esta tesis fue sobre la intensidad de la precipitación diaria, medida a través de la precipitación máxima diaria (Rx1) anual, a la vez que se incluyeron otras métricas a modo complementario.

Primero se realizó una caracterización espacio-temporal en el período 1982-2019 de 15 índices de precipitación relacionados a la intensidad, frecuencia y duración de la precipitación en la región utilizando datos diarios de lluvia medidos en estaciones meteorológicas (in situ), y datos reticulados basados en estimaciones satelitales (CHIRPS). Luego, para obtener una perspectiva de más largo plazo, para el periodo 1912-2019 se realizó una caracterización de la precipitación máxima diaria (Rx1) y total (TOT) anuales y estacionales, utilizando la serie de precipitación diaria de mayor extensión temporal de la región. Con esta serie, se llevó a cabo un análisis exploratorio de la correlación de Rx1 y TOT con El Niño Oscilación del Sur (ENSO), Modo Anular del Sur (SAM), Oscilación Decadal del Pacífico (PDO) y Oscilación Multidecadal del Atlántico (AMO) como forzantes naturales, y con la concentración global de CO₂ (uno de los principales gases de efecto invernadero, GHG) y de O₃ polar atmosféricos. En base a los resultados del análisis exploratorio se avanzó en un análisis más profundo de la relación Rx1-ENSO y Rx1-SAM en escalas interanuales, moduladas en escalas multidecadales por PDO y AMO. Esto se llevó a cabo mediante el análisis de correlaciones en múltiples ventanas temporales y proponiendo un enfoque basado en buscar la máxima significancia estadística. Luego, para dar soporte físico y determinar la representatividad espacial de este análisis se determinaron los patrones de anomalías de Rx1 con HadEX3 y de variables atmosféricas con ERA5 en la región Subtropical de Sudamérica para cada fase de ENSO y SAM bajo diferentes fases de PDO. Finalmente, con el fin de analizar la relación entre la precipitación y el aumento de GHG (relacionado al calentamiento global), se analizó el desempeño de modelos de la sexta fase del Proyecto de Intercomparación de Modelos Acoplados (CMIP6) para representar Rx1 y TOT y se analizaron las proyecciones hacia el futuro bajo dos escenarios de emisiones de GHG (uno intermedio y otro extremo).

Los resultados muestran que en la comparación entre observaciones in situ y CHIRPS, éste último muestra un bajo desempeño para representar la variabilidad y tendencias de la precipitación extrema en la región. Por otro lado, se encontró que la precipitación extrema en la región responde significativamente tanto a forzantes naturales (ENSO, SAM y PDO) como antropogénicos (aumento de GHG y posiblemente O₃ polar). Según las observaciones in situ, hay evidencia de un corrimiento del ciclo hidrológico anual en las últimas décadas que

consiste en un incremento de la frecuencia de ocurrencia de Rx1 anual durante el otoño en detrimento de la primavera. El corrimiento del ciclo hidrológico observado en las últimas décadas podría acentuarse en el futuro debido al aumento de GHG según los modelos del CMIP6. Como principal resultado de esta tesis, se determinó que la mayor intensidad de precipitación se observa bajo la fase cálida de PDO, donde la variabilidad interanual está relacionada a SAM, y por otra parte, bajo el escenario de mayor calentamiento global proyectado debido al aumento de GHG. En relación a este último forzante, las proyecciones de Rx1 hacia finales del siglo implican un aumento del riesgo de inundaciones en el verano y otoño. A su vez, las proyecciones futuras para TOT implican un aumento en el riesgo de ocurrencia de déficit hídricos en la primavera en respuesta al calentamiento global.

Palabras clave: lluvia, calentamiento global, cambio climático, El Niño Oscilación del Sur, Modo Anular del Sur,

Natural and anthropogenic forcings of long-term variations of extreme rainfall in Northwestern Argentina

Abstract

This work analyzes the interannual and longer-term variability of extreme precipitation in the Northwestern Argentina (NWA) concerning natural and anthropogenic forcings. The main focus of this thesis was on the intensity of daily precipitation, measured through the annual maximum daily rainfall (Rx1), while other metrics were included as complementary measures.

First, a space-time characterization was conducted for the 1982-2019 period, considering 15 precipitation indices related to intensity, frequency, and duration of precipitation in the region using daily rainfall data measured at meteorological stations (in situ), as well as gridded data based on satellite estimates (CHIRPS). Then, to obtain a longer-term perspective, a characterization of annual and seasonal maximum daily precipitation (Rx1) and total precipitation (TOT) for the 1912-2019 period was performed using the longest available daily precipitation series in the region. An exploratory analysis of the correlation of Rx1 and TOT with El Niño Southern Oscillation (ENSO), Southern Annular Mode (SAM), Pacific Decadal Oscillation (PDO), and Atlantic Multidecadal Oscillation (AMO) as natural forcings, and with global concentrations of CO₂ (one of the main greenhouse gases, GHG) and atmospheric polar O₃ was conducted. Based on the results of the exploratory analysis, a deeper analysis of the Rx1-ENSO and Rx1-SAM relationship on interannual scales, modulated on multidecadal scales by PDO and AMO, was undertaken. This was carried out through correlation analysis over multiple temporal windows, proposing an approach based on seeking maximum statistical significance. Subsequently, to provide physical support and determine the spatial representativeness of this analysis, Rx1 anomaly patterns with HadEX3 and atmospheric variables with ERA5 in the South American Subtropical region were determined for each ENSO and SAM phase under different PDO phases. Finally, to analyze the relationship between precipitation and greenhouse gas (GHG) increase (related to global warming), the performance of models from the sixth phase of the Coupled Model Intercomparison Project (CMIP6) to represent Rx1 and TOT was analyzed, and projections for the future under two GHG emission scenarios (one intermediate and one extreme) were examined.

The results show that, in the comparison between in situ observations and CHIRPS, the latter exhibits poor performance in representing the variability and trends of extreme precipitation in the region. On the other hand, it was found that extreme precipitation in the region significantly responds to both natural forcings (ENSO, SAM, and PDO) and anthropogenic forcings (increase in GHG and possibly polar O₃). According to in situ observations, there is evidence of a shift in the annual hydrological cycle in recent decades, consisting of an increase in the frequency of annual Rx1 occurrences during autumn at the expense of spring. The observed shift in the hydrological cycle in recent decades could be exacerbated in the future due to increased GHG according to CMIP6 models. As a key result of this thesis, it

was determined that the highest precipitation intensity is observed during the warm phase of PDO, where interannual variability is related to SAM, and on the other hand, under the scenario of projected global warming due to increased GHG. Regarding this latter forcing, R_{x1} projections towards the end of the century imply an increased risk of flooding in summer and autumn. Furthermore, future projections for TOT imply an increase in the risk of water deficits in spring in response to climate change.

Keywords: rainfall, global warming, climate change, El Niño Southern Oscillation, Southern Annular Mode

Agradecimientos

En primer lugar, agradezco al Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET) de la República Argentina por la Beca Interna Doctoral para Temas Estratégicos otorgada para realizar este doctorado.

También al Departamento de Física de la Facultad de Ciencias Exactas y Tecnología, de la Universidad Nacional de Tucumán, por el lugar que me brindó para realizar este trabajo de Tesis.

Agradezco especialmente a mi directora, la Dra. Ana G. Elias, por sus valiosos aportes a mi formación e incentivarme siempre a ser mejor, lo cual me ha permitido un gran crecimiento profesional en estos años.

Al Dr. Bruno S. Zossi por su colaboración en la obtención de algunos datos necesarios para esta tesis y por las sugerencias realizadas.

A los miembros de la Comisión de Supervisión, la Dra. Marta M. Zossi y el Dr. Carlos M. Figueroa por su labor realizada.

A mis padres que siempre me brindaron su apoyo y su ejemplo.

A mis amigos que siempre están, especialmente a Ariana por su compañía “virtual” de todos los días.

Índice

Resumen	1
Abstract	3
Agradecimientos	5
Índice	6
Capítulo 1: Introducción	9
Figuras (Cap. 1).....	14
Capítulo 2: Caracterización de la precipitación observada y las estimaciones de CHIRPS en el período 1982-2019	15
Resumen.....	15
2.1. Introducción.....	15
2.2. Región de estudio: Norte de Argentina (NA).....	18
2.3. Datos y metodología.....	19
2.3.1. Datos de estaciones meteorológicas.....	19
2.3.2. CHIRPS.....	20
2.3.3. Índices de precipitación.....	20
2.3.4. Evaluación de CHIRPS.....	21
2.4. Resultados.....	22
2.4.1. Precipitación mensual e índices anuales observados.....	22
2.4.2. Evaluación de CHIRPS para representar la lluvia diaria y mensual.....	23
2.4.3. Evaluación de CHIRPS para índices de precipitación anual.....	25
2.4.3.1. Valores medios y variabilidad interanual.....	25
2.4.3.2. Tendencias.....	26
2.5. Discusión.....	27
2.6. Conclusiones.....	29
Figuras y tablas (Cap. 2).....	30
Capítulo 3: Caracterización de la precipitación total y máxima diaria en San Miguel de Tucumán (Tucumán, Argentina) para el periodo 1912-2016 y análisis exploratorio de forzantes	49
Resumen.....	49
3.1. Datos.....	50
3.1.1. Datos diarios de precipitación.....	50
3.1.2. Campos de variables atmosféricas.....	51
3.1.3. Modos de variabilidad global.....	52
3.1.4. Forzantes antropogénicos.....	52
3.2. Metodología.....	53
3.2.1. Tendencias lineales, detección de saltos climáticos y relación Rx1-TOT.....	53
3.2.2. Análisis de correlación.....	53
3.3. Resultados.....	54
3.3.1. Tendencias lineales y saltos climáticos.....	54
3.3.2. Asociación con variables atmosféricas.....	55
3.3.3. Asociación con los modos de variabilidad global.....	57

3.3.4. Asociación con las concentraciones de CO ₂ global y O ₃ polar.....	60
3.3.5. Cuasi-periodicidad de ~20 años en TOT y P.....	60
3.4. Discusión final y conclusiones.....	61
Figuras y tablas (Cap. 3).....	63
Capítulo 4: Forzantes naturales de la precipitación extrema.....	73
Resumen.....	73
4.1. Introducción.....	73
4.2. Datos.....	76
4.2.1. Datos de precipitación de San Miguel de Tucumán.....	76
4.2.2. Datos de Rx1 para Sudamérica Subtropical.....	77
4.2.3. Modos de variabilidad global.....	77
4.2.4. Campos de variables atmosféricas.....	78
4.3. Metodología.....	79
4.3.1. Identificación de los periodos con las correlaciones más significativas.....	79
4.3.2. Composites de anomalías de Rx1 y variables atmosféricas.....	81
4.3.3. Determinación del rol de PDO y AMO en las asociaciones no estacionarias..	81
4.4. Resultados.....	82
4.4.1. Ciclo anual y variabilidad de Rx1.....	82
4.4.2. Correlación Rx1-ENSO y Rx1-SAM y obtención de PmPV y PMWL.....	82
4.4.3. Composites de anomalías de Rx1 en SSA.....	84
4.4.4. Composites de anomalías de variables atmosféricas para ENSO.....	85
4.4.5. Composites de anomalías de variables atmosféricas para SAM.....	87
4.4.6. Roles de PDO y AMO en las relaciones no estacionarias Rx1-ENSO y Rx1-SAM.....	88
4.5. Discusión y conclusiones.....	89
Figuras y tablas (Cap. 4).....	92
Capítulo 5: El aumento de gases de efecto invernadero como forzante antropogénico de la precipitación extrema y total.....	103
Resumen.....	103
5.1. Introducción.....	104
5.2. Datos de precipitación diaria.....	105
5.2.1. Observaciones.....	105
5.2.2. Modelos del CMIP6.....	106
5.3. Metodología.....	107
5.3.1. Evaluación y corrección de sesgo de modelos del CMIP6.....	107
5.3.2. Análisis de proyecciones de los modelos del CMIP6 bajo diferentes SSP....	108
5.3.3. Análisis de la relación entre Rx1 y TOT según las observaciones y los modelos del CMIP6.....	109
5.4. Resultados y discusión.....	109
5.4.1. Valores observados de Rx1 y TOT.....	109
5.4.2. Desempeño de los modelos para representar Rx1 y TOT.....	110
5.4.3. Cambios proyectados en Rx1.....	112
5.4.4. Cambios proyectados en TOT.....	114
5.4.5. Relación Rx1-TOT en el período histórico y las proyecciones a futuro.....	117
5.5. Conclusiones.....	118

Figuras y tablas (Cap. 5).....	120
Capítulo 6: Conclusiones generales y líneas futuras de investigación.....	132
Apéndice: Difusión de los resultados de esta tesis.....	135
Artículos publicados en revistas científicas (con referato).....	135
Trabajos presentados en congresos (formato póster).....	135
Bibliografía.....	136

Capítulo 1: Introducción

La variabilidad de la precipitación es una temática ampliamente estudiada debido a sus grandes impactos socioeconómicos. Según O'Neill et al. (2022) en el Sexto Informe de Evaluación (AR6) del Grupo Intergubernamental de Expertos sobre el Cambio Climático (IPCC), la precipitación está estrechamente relacionada con el riesgo a la seguridad hídrica, uno de los riesgos más importantes relacionados al agua, incluidas las sequías e inundaciones. Estos eventos tienen el potencial de ser severos y son generados por reducciones o aumentos sustanciales de la precipitación en una región. Por lo tanto, es de vital importancia estudiar la variabilidad de la misma para disminuir estos riesgos.

El estudio de las precipitaciones extremas en diferentes regiones del mundo es un tópico que ha adquirido gran relevancia en los últimos años en un contexto de calentamiento global. De acuerdo a la Organización Meteorológica Mundial (*World Meteorological Organization*, WMO) (2021), los principales desastres naturales son los asociados con tormentas e inundaciones y han implicado desde 1970 la muerte de más de 600 mil personas en el mundo. A su vez, las pérdidas económicas por estos desastres climáticos se multiplicaron por alrededor de 7, siendo los países en desarrollo los principales afectados. Globalmente, los registros disponibles desde 1950 muestran un aumento en la frecuencia de eventos de precipitación extrema y significan una fracción cada vez más grande de la precipitación total anual (Dunn et al., 2020). Además, las lluvias se han intensificado a nivel global en una tasa consistente con el incremento de la humedad atmosférica como consecuencia del calentamiento global ($\sim 7\% K^{-1}$), incluso con algunas regiones particulares superando estos incrementos (Fowler et al., 2021).

En el centro y norte de Argentina, o Argentina subtropical (STA), se observaron tendencias positivas en la precipitación de verano durante el siglo XX, especialmente desde la década de 1950 (Barros et al., 2000; Saurral et al., 2017). Esta es una de las regiones del mundo con la evidencia más consistente de aumentos de precipitación total estacional durante el siglo pasado (Vera y Diaz, 2015; Carvalho, 2020). Además de estos aumentos en la precipitación total, Robledo et al. (2020) reportaron tendencias positivas y con una importante componente no lineal en los extremos diarios de precipitación para el período 1962-2005.

El Noroeste Argentino (NOA), ubicado aproximadamente entre 22-30°S y 62-70°W (Figura 1-1), no estuvo exento de estas tendencias reportadas. Minetti et al. (2003) observaron una tendencia cuasi-lineal creciente en la precipitación anual en el período 1930-2000, con un “salto climático” en la década de 1950, y de otro similar en la de 1970. En relación a esto, Medina y Minetti (2004) postulan que dicho incremento observado se asocia a un cambio en los extremos diarios de precipitación. Por su parte, en un estudio más reciente, Ferrero y

Villalba (2019) analizan una gran cantidad de registros mensuales de precipitación del NOA, detectando que la lluvia total del semestre cálido tiene saltos positivos en las décadas de 1950 y 1970, y saltos negativos alrededor del 2010. Respecto a la distribución espacial de dichas tendencias y su reflejo en otros aspectos de precipitación, Castino et al. (2017) muestran que los mayores cambios en la duración, intensidad y frecuencia de la precipitación se observan en la zona de transición entre las elevaciones bajas e intermedias (~500 m sobre el nivel del mar) del NOA.

Respecto al comportamiento en décadas más recientes, Bazzano et al. (2019) en un estudio sobre Tucumán (zona central del NOA) observan un comportamiento variable en las tendencias de la lluvia. Ellos muestran un incremento significativo en la lluvia total anual y la cantidad de días con eventos de lluvias intensas en las estaciones con registros más extensos (1954-2015), mientras que observan tendencias negativas en los registros más cortos (1973-2015). En coincidencia, para las últimas 4 décadas, Castino et al. (2017) reportaron una disminución de la lluvia total anual y de la cantidad de días con lluvia en las zonas más bajas del NOA. Por lo tanto, más allá de la tendencia general de aumento en la lluvia en el siglo XX, hubo un cambio en la tendencia en las décadas recientes en la región.

Es necesario analizar las causas físicas de la variabilidad y tendencias de la precipitación en el NOA, debido a que los eventos de fuertes lluvias diarias han generado diversas problemáticas en los últimos años. Algunos de estos eventos fueron:

- abril del 2017, Lamadrid, Tucumán
(<https://www.infobae.com/sociedad/2017/04/04/la-madrid-el-pueblo-tucumano-que-queda-bajo-el-agua-y-tuvo-que-ser-evacuado-por-completo/>)

- enero del 2018, Gran San Miguel de Tucumán
(<https://www.diariopopular.com.ar/general/intenso-temporal-tucuman-un-electrocutado-y-cientos-evacuados-n339456>)

- marzo del 2022, Gran San Miguel de Tucumán
(https://www.clarin.com/sociedad/tucuman-sufrio-tormenta-feroz-calles-convertidas-rios-120-evacuados_0_LYvgbzdzGR.html)

- diciembre del 2023, Salta
(<https://www.infobae.com/sociedad/2023/12/19/un-temporal-azoto-la-provincia-de-salta-provoco-destrozos-e-inundaciones/>)

- enero 2024, Salta y Jujuy
(<https://www.pagina12.com.ar/703086-temporales-en-salta-y-jujuy-provocan-perdidas-materiales-en->)

-enero del 2024, Catamarca
(<https://www.ambito.com/sociedad/catamarca-impactante-alud-arraso-un-puente-peatonal-y-a-islo-una-localidad-entera-n5907096>)

En todos los casos, los reportes indican múltiples daños en viviendas, principalmente las correspondientes a los sectores sociales de menos recursos, debido a la precariedad de las mismas y/o su ubicación en zonas propensas a inundaciones. Además, se reportaron importantes anegamientos de calles, daños en rutas y puentes, daños en el sistema eléctrico, decesos, entre otras consecuencias.

Los estudios existentes indican la existencia de múltiples forzantes que generan variabilidad y tendencias de largo plazo (escalas temporales de 1 año y mayores) de la precipitación en la región STA. Sin embargo, los trabajos de investigación existentes sobre la temática se enfocan en el este de Argentina, mientras que los resultados para el NOA en muchos casos quedan relegados o directamente no se incluye esta región en el análisis. Entre los forzantes de origen natural con mayor impacto en la variabilidad de la precipitación en STA están El Niño Oscilación del Sur (ENSO), el Modo Anular del Sur (SAM), la Oscilación Decadal del Pacífico (PDO) y la Oscilación Multidecadal del Atlántico (AMO). Estos forzantes son modos de variabilidad global de la atmósfera y los océanos, y están asociados a la variabilidad interna del sistema climático. Por otro lado, también existen forzantes de origen antropogénico, entre los que se destacan el aumento en la concentración global de gases de efecto invernadero (GHG) y los cambios en la concentración de ozono (O₃) en la estratósfera polar.

El ENSO en su fase El Niño favorece la ocurrencia de fuertes lluvias en parte de STA, Uruguay y sur de Brasil, mientras que condiciones más secas prevalecen en su fase La Niña (Cai et al., 2020). Sin embargo, los estudios existentes sobre impactos del ENSO en la variabilidad interanual de la lluvia en el NOA no permiten concluir sobre su influencia en la región, ya que algunos indican impactos significativos (Trauth et al., 2003, Marwan et al. 2003), mientras otros indican influencia débil o inexistente (Vargas et al., 2002; Rivera y Penalba, 2015). Por otro lado, más allá de la variabilidad interanual, la variabilidad de más baja frecuencia del ENSO genera saltos en los valores de precipitación, tales como los que se observan en algunas series de precipitación de STA a mediados de la década de 1950 e inicios de la década de 1980 (Hurtado et al., 2020). El salto de la década de 1950 ha sido significativo en la precipitación total anual del NOA (Minetti y Vargas, 1997; Ferrero y Villalba, 2019). Además, existe un salto climático positivo en la precipitación de STA en 1976/1977 en asociación con un cambio de fase en PDO (Hurtado et al., 2020), mientras que también se postula que las fases de AMO en conjunción con PDO favorecen los aumentos de precipitación en STA (Barreiro et al., 2014). En este sentido, Robledo et al. (2020) muestran que la variabilidad multidecadal y las tendencias de la precipitación extrema en STA están asociados significativamente a la variabilidad que ocurre en los océanos tropicales.

Fuera de las zonas tropicales del Hemisferio Sur se observa el patrón de anomalías de SAM, el cual es un modo de variabilidad atmosférica que genera cambios de circulación en latitudes medias y altas (Thompson y Wallace, 2000; Fogt y Marshall, 2020). Los efectos de SAM en STA han sido menos estudiados que los efectos de ENSO, y en el caso del NOA se observa una correlación positiva con la precipitación total de verano, aunque los períodos de análisis no superan los 30 años (Cavalcanti et al., 2021; Garbarini et al., 2021). Además, sus impactos en la precipitación se observan en Argentina, Chile, Uruguay y Brasil, aunque con diferentes

signos y magnitudes de correlación (Vasconcellos and Cavalcanti, 2010; Garreaud et al., 2020; Reboita et al., 2021).

Además de las asociaciones descritas entre la precipitación y cada uno de los forzantes naturales descritos, los mismos interactúan entre sí, de manera tal que, por ejemplo, las diferentes fases de PDO y AMO influyen en los patrones de anomalías que se observan en las fases de ENSO y SAM (Kayano et al., 2019; Wachter et al., 2020). Por esta razón, un análisis sobre los efectos de estos forzantes en la precipitación debería tener en cuenta estas interacciones.

Respecto a los forzantes antropogénicos, múltiples estudios analizan los roles del aumento de GHG y los cambios en el ozono. Para el Sudeste de Sudamérica (SESA), que abarca el centro-este de STA, los modelos climáticos indican que el aumento de GHG es responsable de parte del incremento en la precipitación de verano observada en la segunda mitad del siglo XX (Vera y Díaz, 2015; Díaz et al., 2021). Por otra parte, existen modelos climáticos que muestran que la precipitación de verano en los subtrópicos del Hemisferio Sur aumenta significativamente debido a la disminución de O₃ en la estratosfera polar (Kang et al., 2011). Sin embargo, el peso relativo del aumento de GHG y la disminución de O₃ sobre las tendencias en la precipitación en SESA no está del todo claro aún (Varuolo-Clarke et al., 2021). Existen trabajos que indican que los cambios en el O₃ podrían igualar o superar los efectos de GHG (Gonzalez et al., 2014) o, en contraposición, que el O₃ tiene un impacto secundario frente a GHG (Mindlin et al., 2021). Cuantificar con más precisión el efecto de ambos forzantes es importante debido a que se proyecta que el O₃ estará completamente recuperado hacia el 2050, y su impacto en el clima del hemisferio sur sería opuesto al del incremento de GHG (Cai y Cowen, 2007).

Según lo descrito, existe la necesidad de estudiar la variabilidad de la precipitación extrema en el NOA debido a sus fuertes implicancias socio-económicas. Además, las relaciones entre la misma y los diferentes forzantes son complejas y aún no están suficientemente estudiadas en la región. Por lo tanto, el objetivo general de esta tesis es lograr una mejor comprensión física de las causas de la variabilidad interanual y de mayor plazo de los extremos diarios de precipitación en relación a algunos forzantes naturales (ENSO, SAM, AMO, PDO) y antropogénicos (cambios en las concentraciones de GHG y O₃). Se espera que los resultados de este trabajo contribuyan al conocimiento de las condiciones globales atmosféricas-oceánicas que favorecen la ocurrencia de los eventos de lluvia extrema.

El principal foco de esta tesis fue puesto sobre la precipitación máxima diaria (Rx1), ya que la misma puede ser utilizada como un proxy de la intensidad de la precipitación (de la Casa et al., 2019), particularmente de utilidad cuando no se disponen de datos con una resolución temporal menor a la diaria. En este sentido, la intensidad de la precipitación, como se mencionó, está asociada a las diversas problemáticas descritas en el NOA. Sin embargo, como complemento también se analizaron en algunos casos los totales estacionales/anuales para compararlos con Rx1, y a su vez, se caracterizaron diversos índices relacionados a la intensidad, duración y frecuencia de la precipitación para lograr una visión un poco más abarcativa de la distribución de la lluvia y sus cambios.

Para cumplir el objetivo general, el trabajo de esta tesis se diagramó de la siguiente manera:

- 1) Se realizó una caracterización de la precipitación en el NOA mediante la determinación de los patrones espacio-temporales de diferentes índices relacionados a la duración e intensidad de la precipitación para el periodo más reciente (1982-2019). Para esto se recopilaron datos de estaciones meteorológicas y se utilizó una base de datos reticulada denominada CHIRPS para comparación. (Capítulo 2)
- 2) Para obtener una perspectiva de más largo plazo, se realizó una caracterización de la precipitación total y máxima diaria anuales y de verano utilizando una serie de precipitación diaria que cubre el período 1911-2019. Esta serie es la más larga y con mejor calidad de datos disponible para el NOA. Además, se realizó a modo exploratorio un análisis de correlación con variables de circulación y con los diferentes forzantes naturales y antropogénicos. (Capítulo 3)
- 3) Se realizó un análisis más profundo de la relación de los forzantes naturales con la precipitación máxima diaria utilizando la serie de precipitación que cubre el período 1911-2019. Para esto se utilizó una metodología denominada representación de los triángulos y se propuso un nuevo enfoque para la misma. Además, se realizó un análisis espacial de Rx1 utilizando HadEX3 para determinar la representatividad de los resultados sobre Sudamérica Subtropical. Luego, se analizaron los cambios de circulación que sustentan físicamente las relaciones detectadas utilizando el reanálisis ERA5. (Capítulo 4)
- 4) Para analizar el efecto del aumento de GHG hacia el futuro, se analizaron simulaciones de modelos climáticos del CMIP6. Estas simulaciones corresponden a las históricas y a las proyecciones bajo diferentes escenarios de calentamiento global relacionados al aumento de GHG. Se buscó determinar los modelos que mejor representan la lluvia total y máxima diaria y determinar los cambios proyectados hacia finales del siglo XXI en la región. (Capítulo 5)
- 5) Se concluyó mediante los análisis realizados acerca de la variabilidad observada y proyectada de la precipitación extrema en la región y los forzantes asociados. Finalmente, se determinaron los tópicos sobre los cuales se debería profundizar en futuros trabajos. (Capítulo 6)

Figuras (Cap. 1)

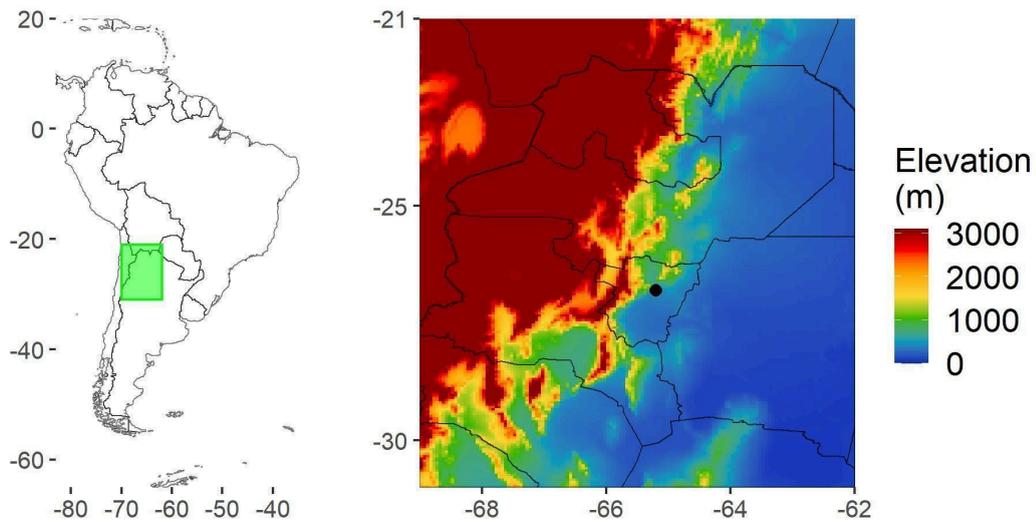


Figura 1-1: Ubicación del NOA en Sudamérica (figura izquierda, recuadro verde) y su relieve expresado en metros sobre el nivel del mar (figura derecha, color). Se indica la ubicación de San Miguel de Tucumán (figura derecha, punto negro), ciudad que cuenta con el registro de precipitación diaria mas extenso del NOA.

Capítulo 2: Caracterización de la precipitación observada y las estimaciones de CHIRPS en el período 1982-2019

Resumen

En este capítulo se muestra la distribución espacial media anual de 15 índices de precipitación en el Norte de Argentina (NA), región que incluye el Noroeste (NOA) y el Noreste Argentino (NEA). Debido a la incertidumbre observacional existente, en estudios de variabilidad climática es recomendable la incorporación de datos de diversas fuentes. Teniendo en cuenta esto, se recolectaron datos diarios de lluvia medidos in situ por diversos organismos nacionales y se realizó un exhaustivo control de calidad de los mismos. Por otra parte, se utilizaron datos reticulados de la base CHIRPS, la cual brinda datos diarios de lluvia con una gran resolución espacial. Con los datos medidos y los datos de CHIRPS se calcularon los índices de precipitación y se compararon los resultados para el periodo 1982-2019. Esta tarea tuvo dos objetivos: estudiar la variabilidad temporo-espacial observada de la precipitación regional en las décadas más recientes y determinar el acuerdo existente entre las observaciones in situ y CHIRPS en la representación de dicha variabilidad. El patrón espacial medio de lluvia mensual y de los índices de precipitación obtenidos muestran que las regiones con mayores lluvias corresponden al centro del NOA (provincia de Tucumán) y al este del NEA. CHIRPS no es adecuado para estudios en el NA relacionados con la precipitación que requieran una representación precisa de los valores medios, su variabilidad interanual y tendencias lineales, particularmente en índices extremos de precipitación. En general la mayor parte de las tendencias observadas ocurrieron en el NOA, donde predominan las tendencias compatibles con condiciones más secas. En general CHIRPS falla en detectar dichas tendencias, con excepción de CDD, para el cual muestra un mejor desempeño. Se puede afirmar con un alto grado de confianza, que en el NOA existe un incremento en CDD desde 1969 al menos, posiblemente relacionado al incremento en la duración de la estación seca.

2.1. Introducción

El monitoreo continuo de la precipitación es crucial para prevenir y mitigar adecuadamente los efectos de los desastres asociados a la misma. En este sentido, la disponibilidad de conjuntos de datos reticulados de alta resolución es un prerrequisito para la reducción y gestión del riesgo de desastres (Shrestha et al., 2021). Los conjuntos reticulados de poca resolución pueden fallar en la detección de características de menor escala que la de la

retícula, lo cual es una desventaja considerando que los eventos extremos diarios de precipitación suelen tener fuertes gradientes espaciales.

Entre las diferentes bases de datos de precipitación, las bases reticuladas son las más adecuadas dado que tienen la ventaja de contar con cobertura uniforme a lo largo de grandes regiones del mundo. Estas bases de datos pueden estar basadas en mediciones in situ (estaciones meteorológicas), reanálisis o datos satelitales, y tienen diferente cobertura y resolución temporal y espacial. Entre las desventajas de cada tipo de base reticuladas se pueden mencionar las deficiencias relacionadas a la cantidad y distribución espacial de estaciones meteorológicas en el primer caso, en los modelos de asimilación de datos en el segundo caso y en los algoritmos satelitales en el último caso (Sun et al., 2018).

En los últimos años el interés en los datos de precipitación derivados de satélites se ha incrementado debido a la gran cobertura espacial que ofrecen. Sin embargo, la precisión de los datos derivados de satélite debe ser evaluada y examinada en referencia a observaciones in situ, debido a que los datos pueden ser afectados por errores sistemáticos (Faiz et al., 2018).

Entre los conjuntos de datos derivados de satélite se destaca Climate Hazards Group InfraRed Precipitation with Station data (CHIRPS), debido a que tiene una cobertura temporal y espacial, latencia y resolución que son mejores que los productos globales similares existentes a la actualidad (Funk et al., 2015). El algoritmo de CHIRPS incorpora estimaciones de precipitación basadas en observaciones de Duración de Nubes Frías en infrarrojo, y además incorpora mediciones in situ de precipitación. Entre los propósitos de CHIRPS se encuentran el monitoreo de sequías, la detección de precipitación, el análisis de tendencias y su uso para modelado hidrológico. Más detalles sobre CHIRPS pueden encontrarse en Funk et al. (2015).

Estudios de validación de CHIRPS se han realizado para diversas regiones del mundo, por ejemplo, Argentina, Brasil, Chile, Italia, China, entre otras (Funk et al., 2015; Baez-Villanueva et al., 2018; Rivera et al., 2018; Cavalcante et al., 2020; y referencias allí). En el sur de Sudamérica, un estudio de Cerón et al. (2020) sobre la Cuenca del Plata (CdP) (Argentina, Brasil, Paraguay y Bolivia) encontró que CHIRPS representa mejor la precipitación mensual en la llanura este y región costera que en la región cercana a la Cordillera de los Andes. Además, como un punto fuerte, CHIRPS describe la mayor parte de variabilidad de la lluvia observada en CdP, especialmente sobre el semestre diciembre-mayo. Por otra parte, en los Andes centrales de Argentina, resultados de Rivera et al. (2018) indican que CHIRPS reproduce adecuadamente la variabilidad estacional e interanual y los patrones espaciales medios de precipitación; sin embargo, sobreestima la precipitación sobre elevaciones más altas (> 1000 m) con una consecuente disminución de la performance. Esta deficiencia ha sido atribuida en parte al número limitado de estaciones meteorológicas utilizado en la producción de CHIRPS. Rivera et al. (2019) determinaron que CHIRPS es adecuado para evaluar condiciones secas y húmedas en los Andes centrales de Argentina para escalas de tiempo mayores al mes y puede contribuir al proceso de toma de decisiones dentro de los servicios hidrometeorológicos. En coincidencia, Zambrano et al. (2017) encontraron

que CHIRPS es útil para caracterizar los patrones de precipitación y monitorear sequías en Chile.

Un interesante estudio de Cavalcante et al. (2020) en el Amazonas de Brasil comparó lluvia mensual, índices anuales de lluvia y sus tendencias utilizando CHIRPS y mediciones in situ. Ellos encontraron que las estimaciones de lluvia mensual de CHIRPS son similares a las mediciones in situ. Sin embargo, detectaron que CHIRPS tiene una performance baja para representar los índices de precipitación anuales más extremos y además no es útil para la detección de tendencias en su región de estudio.

En el presente capítulo, se realizó una comparación de la lluvia total mensual e índices de lluvia anuales, junto con sus tendencias, utilizando mediciones in situ y CHIRPS. La región de estudio fue el Norte de Argentina (NA) y se siguió el esquema del trabajo de Cavalcante et al. (2020). Si bien algunas de las estaciones meteorológicas analizadas aquí fueron incorporadas en la producción de CHIRPS, la mayoría de estaciones utilizadas en este trabajo no fueron incorporadas en dicho proceso, por lo que ambas bases analizadas pueden considerarse independientes.

Varios estudios sobre la precipitación en NA se han realizado, pero principalmente basados en mediciones in situ (Castino et al., 2017; Lovino et al., 2018; Ferrero and Villalba, 2019) y datos de CHIRPS (Cerón et al., 2021) separadamente. Solo un estudio de Cerón et al. (2020) compara las estimaciones de totales estacionales de CHIRPS con mediciones in situ en una región que abarca el NA. La importancia de realizar este tipo de análisis radica en que, debido a la incertidumbre observacional existente, es recomendable la incorporación de datos de precipitación de diversas fuentes para la obtención de conclusiones más confiables. La contribución novedosa de este Capítulo de la tesis es la extensión de la validación de CHIRPS al análisis de varios índices anuales de precipitación, algunos de los cuales están relacionados a eventos extremos, y a la detección de sus tendencias. Además, el trabajo realizado resultó en el armado de una base de datos de registros in situ de precipitación de calidad controlada que cubre las últimas 4 décadas. Esta base de datos será de utilidad en futuros trabajos de investigación sobre la precipitación, en escalas diarias y mayores, en la región.

Específicamente, los objetivos de este capítulo son:

- estudiar la variabilidad temporo-espacial observada de la precipitación en NA en las décadas más recientes,
- determinar la factibilidad de la utilización de CHIRPS para el estudio de la variabilidad de la precipitación, especialmente en el NOA que requiere de datos reticulados de alta resolución debido a su compleja topografía.

2.2. Región de estudio: Norte de Argentina (NA)

Para el análisis de este capítulo se seleccionó el NA en su totalidad, es decir, además del NOA se incluyó al Noreste Argentino (NEA). Esto debido a que se consideró de utilidad comparar los patrones de precipitación (observados y estimados) entre dos regiones vecinas cuyas características topográficas (ver Figura 2-1) y de variabilidad de la precipitación difieren drásticamente. Particularmente, es conocido que CHIRPS suele tener mejor desempeño en regiones cuyos relieves muestran una predominancia de llanuras, a diferencia de lo que ocurre con regiones montañosas (Funk et al., 2015). Por lo tanto, es de esperarse que el desempeño de CHIRPS sea mejor en el NEA que en el NOA debido a su topografía.

NA incluye el territorio de 11 provincias: Catamarca, Jujuy, La Rioja, Salta, Santiago del Estero y Tucumán conformando el NOA, y Chaco, Corrientes, Formosa, norte de Santa Fe y Misiones conformando el NEA. La región del NA está aproximadamente entre 21-31°S y 69-53°O (Figura 2-1) y abarca una superficie de 900 mil km². En ella habitan aproximadamente 10 millones de personas (Datos CENSO 2022, Instituto Nacional de Estadísticas y Censos, INDEC, <https://www.argentina.gob.ar/pais/provincias>), esto es un poco más del 20% de la población de Argentina. La región produce aproximadamente el 13% del producto bruto interno (datos de INDEC, <https://www.indec.gob.ar/indec/web/Nivel4-Tema-3-9-138>) en una economía fuertemente dependiente de la precipitación, ya que está basada principalmente en la producción de energía hidroeléctrica y en actividades agrícolas.

Los regímenes anuales de precipitación en el NOA y NEA son diferentes (Doyle, 2020), siendo el NOA una región con un régimen cuasi-monzónico en el cual la precipitación está fuertemente concentrada en los meses de verano, mientras que en el NEA existe un ciclo anual un poco menos marcado. En la Figura 2-2 se muestra el ciclo anual de lluvia para el NOA y NEA confirmando la diferencia de regímenes descripta. Sin embargo, a pesar de estas diferencias, en general en el NA los meses de verano registran más precipitación acumulada que los meses de invierno. Por otra parte, en esta región se encuentra la mayoría de las localidades con mayores precipitaciones de la Argentina (Llano, 2018).

La distribución espacial media anual de precipitación muestra diferencias entre el NOA y NEA. El NOA consta de un importante gradiente de precipitación en la dirección este-oeste debido a la presencia de la Cordillera de Los Andes. En dicha región, condiciones más lluviosas predominan en elevaciones entre los 300 y 3000 m sobre el nivel del mar, mientras que condiciones más secas predominan por encima de los 3000 m (Castino et al., 2017). El máximo de precipitación anual (> 3500 mm/año) se observa a una altura aproximada de 1300 m. En contraste con el NOA, en el NEA predominan principalmente las llanuras con elevaciones menores a 300 m sobre el nivel del mar y un gradiente de precipitación en la dirección oeste-este con valores entre 900-1900 mm/año (Lovino et al., 2018).

En el verano la precipitación del NA es regulada por el Monzón Sudamericano (Marengo et al., 2012). La circulación del Monzón provee un flujo de vapor, denominado low-level jet,

desde la región del Amazonas y el Océano Atlántico tropical hacia el NA (Vera et al., 2006). La precipitación en verano es frecuentemente organizada en grandes sistemas convectivos de mesoescala (Laing and Fritch, 2000). Fuera del verano, el low-level jet decae y la precipitación se concentra principalmente en NEA, la cual surge debido a actividad de escala sinóptica de latitudes medias (Vera et al., 2002).

Tendencias en algunos índices de lluvia fueron observadas en las últimas siete décadas en el NA de acuerdo a datos de estaciones meteorológicas. Particularmente, una revisión de Carvalho (2020) identificó que el NA es una de las dos regiones de América con la evidencia más consistente de aumentos en la precipitación total durante el siglo pasado. Sin embargo, particularmente en las últimas décadas, para el NOA se observó una disminución en la lluvia anual total y en la frecuencia de días con lluvia, y en contraste hubo un incremento en los extremos de lluvia relacionados al percentil 95 (Castino et al., 2017). Por otra parte, en el NEA se incrementó sostenidamente la ocurrencia de eventos de lluvia intensa en el periodo 1970-2000 con una estabilización posterior y, a la vez, desde entonces hubo un incremento en la duración de las rachas secas (días consecutivos sin lluvia) (Lovino et al., 2018). Por lo tanto, el monitoreo de la lluvia en el NA es muy necesario debido a que su comportamiento muestra gran variabilidad espacio-temporal en diferentes escalas.

2.3. Datos y metodología

2.3.1. Datos de estaciones meteorológicas

Se utilizaron registros diarios de lluvia del NA provistos por el Servicio Meteorológico Nacional (SMN, disponibles bajo requerimiento en <https://www.argentina.gob.ar/smn/institucional/contacto>), la Subsecretaría de Recursos Hídricos (disponibles en: www.argentina.gob.ar/subsecretaria-de-recursos-hidricos/base-de-datos-hidrologica-integrada) y el Instituto Nacional de Tecnología Agropecuaria (INTA, disponibles en: siga.inta.gob.ar). De un total de 170 estaciones medidoras de precipitación recopiladas para NA, sólo 50 (Tabla 2-1) fueron seleccionadas debido a su extensión temporal y calidad de los datos. La densidad es de 1 estación cada 17.000 km², pero no hay una distribución uniforme como se puede apreciar en la Figura 2-1. La mayoría de las estaciones están ubicadas a lo largo de los principales ríos y en aeropuertos de las ciudades más importantes, mientras unas pocas están en las principales zonas agrícolas.

El control de calidad de los datos se realizó siguiendo la metodología de Cavalcante et al. (2020). Primero las series diarias de precipitación fueron revisadas visualmente para detectar errores obvios tales como valores excesivamente altos o negativos. Luego, para cada mes se calcularon la lluvia total, la máxima diaria y la cantidad de días consecutivos sin precipitación. Aquellos valores obtenidos que se desviaban en 4 o más desviaciones estándar respecto al promedio del mes fueron detectados y comparados con valores de estaciones cercanas. Los valores considerados como sospechosos de ser erróneos fueron considerados como datos faltantes en las series de precipitación.

Aquellas estaciones cuyos registros mostraron finalmente una cantidad de meses faltantes menor al 20% en el periodo 1982-2019 fueron seleccionadas para el análisis. Un mes fue considerado faltante si contaba con más de 1 día sin datos. El periodo 1982-2019 fue seleccionado para que coincida con el periodo que abarca CHIRPS y que sea tal que se maximice la disponibilidad de estaciones meteorológicas para el análisis. Si bien algunas estaciones seleccionadas comenzaron sus registros algunos años posteriores al año 1982, fueron incluidas ya que las mismas cumplen con tener al menos el 80% de los meses con datos en el periodo 1982-2019. En base a este criterio, 120 de 170 estaciones fueron descartadas. La mayor densidad de estaciones seleccionadas se encuentra en la provincia de Tucumán (Figure 2-1), donde un fuerte gradiente de elevación y precipitación existe. En cuanto a la distribución regional, de las 50 estaciones seleccionadas, 35 se encuentran en el NOA y 15 en el NEA. Para realizar el cálculo de los índices de precipitación anual se utilizó el año hidrológico (del 1 de julio al 30 de junio del año siguiente), debido a que las máximas precipitaciones ocurren en los meses de verano. El año fue nombrado como el año calendario correspondiente al del periodo enero-junio.

2.3.2. CHIRPS

Se utilizaron estimaciones de lluvia diaria del *Climate Hazards Center InfraRed Precipitation with Station data* (CHIRPS) versión 2.0 (Funk et al., 2015) con una resolución horizontal de 0,05°. Los datos están disponibles en <https://coastwatch.pfeg.noaa.gov/erddap/griddap/chirps20GlobalDailyP05.html>. CHIRPS combina mediciones satelitales de Duración de Nube Fría (*Cloud Cold Duration*, CCD) calibradas con datos de la Misión de Medición de Lluvias Tropicales (*Tropical Rainfall Measuring Mission*, TRMM) y datos de estaciones meteorológicas. Previo a la producción de CHIRPS es derivado un campo que incluye únicamente mediciones satelitales (CHIRP). El primer paso para el cálculo del CHIRP es el pentad. Hay 6 pentad en un mes calendario, 5 pentad de 5 días cada uno, y el restante pentad con los restantes 3 a 6 días según el mes. Valores de CHIRP de cada pentad son luego desagregados a estimaciones de precipitación diaria basándose en campos de CFS (reanálisis del *Coupled Forecast System*) diarios, reescalados a una resolución de 0,05°. En cada pixel o punto de grilla, la precipitación pentadal de CHIRP es redistribuida en proporción a los valores diarios del CFS. La estimación final de CHIRPS es una combinación de datos de CHIRP no ajustados y ajustados por sesgo. El resultado es un producto diario reticulado de precipitación con una resolución horizontal de 0,05° que abarca el globo desde entre las latitudes 50°S-50°N.

2.3.3. Índices de precipitación

Se calcularon los totales mensuales y 15 índices de precipitación como en Cavalcante et al. (2020). Los índices de precipitación son listados y descritos en la tabla 2-2, de los cuales 11 de ellos corresponden a los índices de lluvia extrema definidos por el *Expert Team on Climate*

Change Detection and Indices (ETCCDI) (Karl et al., 1999), mientras los índices restantes son dos relacionados a percentiles considerando todos los días del año, otro al número de días con precipitación y otro al acumulado de precipitación en los 4 días con mayor precipitación. Todos los índices utilizados son relevantes para el monitoreo de la variabilidad climática ya que están relacionados con los distintos aspectos de la distribución de la precipitación diaria (frecuencia, duración e intensidad).

2.3.4. Evaluación de CHIRPS

Para la evaluación de CHIRPS se utilizó una metodología similar a la de Cavalcante et al. (2020). Se realizó una comparación “punto-pixel” entre las estimaciones de lluvia de CHIRPS y los datos de estaciones meteorológicas (OBS). Este análisis requirió obtener las series temporales de CHIRPS del punto de grilla (pixel) más cercano a la ubicación de cada estación meteorológica para luego realizar la comparación OBS vs CHIRPS. Los datos faltantes en OBS fueron considerados también faltantes en CHIRPS, por lo cual no se necesitó realizar un relleno de datos faltantes.

La lluvia total mensual y los 15 índices de lluvia anuales fueron comparados utilizando las siguientes métricas: coeficiente de correlación lineal de Pearson (RHO), error medio relativo (MRE), error medio absoluto (MAE) y la eficiencia de Nash-Sutcliffe (NSE), cuyas ecuaciones son listadas en la Tabla 2-3. En este trabajo, RHO mide la intensidad de la asociación lineal entre CHIRPS y OBS, o dicho de otro modo, muestra cuánto de la variabilidad de OBS es representada en CHIRPS. RHO puede tomar valores entre -1 y 1, donde 1 es el valor óptimo que indica que ambas series varían idénticamente. La significancia estadística de los valores de RHO se evaluó con el test t de Student a un nivel de significancia del 95%. Por su parte, MRE mide el sesgo o desviación promedio relativo de CHIRPS respecto a OBS, es decir indica si CHIRPS en promedio sobreestima ($MRE > 0$), subestima ($MRE < 0$) o coincide ($MRE = 0$) con los valores observados. Similarmente, MAE indica la desviación absoluta de CHIRPS respecto a OBS, su valor óptimo también es 0, pero a diferencia de MRE es una métrica dependiente de la escala. Finalmente, NSE determina la magnitud relativa de la varianza residual entre CHIRPS y OBS (llamada residual por analogía al análisis de regresión) comparado a la propia varianza de OBS (Nash y Sutcliffe, 1970). NSE varía entre $-\infty$ y 1. Un valor negativo de NSE corresponde a una pobre estimación de la precipitación por parte de CHIRPS e implica que el valor medio de OBS es un mejor predictor. Dicho de otro modo, un NSE negativo indica que las desviaciones de CHIRPS respecto a OBS son más grandes que las desviaciones de cada valor de OBS respecto a su promedio. Mientras que un NSE igual a cero indica que CHIRPS es tan preciso como la media de OBS; y NSE igual a uno (valor óptimo) implica una perfecta correspondencia entre la estimación de CHIRPS y los valores de OBS.

Además de las métricas mencionadas, se compararon las tendencias lineales de los 15 índices de precipitación según OBS y CHIRPS. Las tendencias fueron calculadas utilizando el estimador no paramétrico de Sen (Sen, 1968), el cual no requiere que los valores de las

variables provengan de una distribución Normal o Gaussiana. La significancia fue calculada con el test no paramétrico modificado de Mann-Kendall (Hamed y Rao, 1998; Kendall 1955; Mann, 1945) a un nivel de significancia del 95%.

Rivera et al. (2018) detectaron que en la producción de CHIRPS no están incluidos los datos de agencias argentinas diferentes al SMN. En este trabajo se verificó en el listado de estaciones incluidas en la producción de CHIRPS ([disponible en https://data.chc.ucsb.edu/products/CHIRPS-2.0/diagnostics/list_of_stations_used/](https://data.chc.ucsb.edu/products/CHIRPS-2.0/diagnostics/list_of_stations_used/)) y se encontró que de las 50 estaciones seleccionadas para este análisis, solo 16 fueron incorporadas. De las 34 estaciones no incluidas en CHIRPS, 26 corresponden al NOA y 8 al NEA. En este trabajo se realizó una distinción entre estaciones incluidas (denominadas “anchor” en inglés) y no incluidas (“no-anchor”) en CHIRPS. Esto se hizo para evitar sesgos que pueden surgir por no distinguir esta condición en los resultados y para determinar el efecto de la no inclusión de más estaciones en la producción de CHIRPS. En este trabajo, las expresiones “estaciones incluidas” o “estaciones no incluidas” hacen referencia a su inclusión o no en la producción de CHIRPS.

2.4. Resultados

2.4.1. Precipitación mensual e índices anuales observados

Para caracterizar climatológicamente la precipitación regional, en la Figura 2-3 se muestran los diagramas de caja de la lluvia total por estación del año según los datos de OBS en el periodo 1990-2019 (periodo climatológico). De los diagramas se deduce claramente que el invierno (trimestre junio-agosto, JJA) es la estación más seca del año en NA, mientras que el verano (trimestre diciembre-febrero, DJF) es la estación más lluviosa.

Para el NOA en todas las estaciones del año, se observa que las estaciones meteorológicas no incluidas en CHIRPS (“no anchor” en Figura 2-3) son las que registran mayor precipitación acumulada. En contraste, para el NEA la precipitación acumulada para las estaciones meteorológicas incluidas y no incluidas en CHIRPS es similar.

La distribución espacial de la lluvia total mensual promedio para 1990-2019 según OBS se muestra en la Figura 2-4. Los valores máximos de precipitación se observan en el centro del NOA en el periodo diciembre-marzo. Un máximo secundario se observa durante el mismo período en el este del NEA. En el resto del año, los máximos valores de precipitación se observan solamente en el este del NEA. En general, en NA los valores de precipitación son más bajos en el periodo mayo-agosto denotando la existencia de una estación seca, la cual es mucho más evidente en el NOA que en el NEA.

La distribución espacial de los valores promedios de los índices anuales de precipitación según OBS se muestra en la Figura 2-5. En el caso de PRCPTOT, el mismo es equivalente a la suma de los valores de la Figura 2-4. Las estaciones meteorológicas ubicadas en el extremo oeste del NOA tienen los valores más bajos de PRCPTOT, y a su vez, los valores más altos de CDD. En comparación, esta zona más seca de NA registra menos de la mitad de

PRCPTOT (< 500 mm) y más del doble de CDD (> 100 días/año) que el resto de NA. Por otra parte, dos zonas bien definidas con máximos valores de PRCPTOT pueden observarse: una en el centro del NOA, y otra en el este del NEA, en concordancia con el análisis mensual realizado. Para los otros índices de precipitación, excepto CWD, el patrón espacial es similar a PRCPTOT, es decir, con un fuerte gradiente longitudinal más que latitudinal. Mientras que en el caso de CWD, los máximos valores se observan en gran parte del NOA (~ 8 días/año). Distinguiendo entre estaciones incluidas y no incluidas en CHIRPS (Figura 2-6), para el NOA las estaciones no incluidas presentan los máximos valores en los índices de precipitación, mientras para el NEA valores similares se observan al comparar las incluidas y no incluidas.

2.4.2. Evaluación de CHIRPS para representar la lluvia diaria y mensual

La Figura 2-7 muestra los valores de lluvia total mensual estimada por CHIRPS versus los valores de OBS para todas las estaciones meteorológicas analizadas en el periodo 1982-2019. Los gráficos muestran los datos separados según la subregión (NOA y NEA) y si las estaciones están incluidas o no en la producción CHIRPS. Se observa que CHIRPS subestima fuertemente los valores de lluvia mensual por encima de ~ 250 mm en las estaciones no incluidas del NOA (Figura 2-7, panel inferior). Esto es evidente cuando se compara la distribución de puntos celestes respecto a la recta 1:1, los cuales se encuentran por debajo de la misma, indicando que los elevados valores en OBS son valores más bajos en CHIRPS. Para el resto de las estaciones meteorológicas, tanto del NEA como del NOA, se observa una subestimación por parte de CHIRPS de los valores de precipitación mensual por encima de los 400 mm aproximadamente, aunque dicha subestimación es menor que en el caso anterior.

Los valores de RHO al cuadrado (escritos en cada panel de la Figura 2-7), indican que CHIRPS representa con menos éxito la variabilidad de los valores de lluvia mensual en las estaciones no incluidas del NOA ($RHO^2 = 0,64$). En el resto de los casos (estaciones incluidas del NOA y todas las del NEA), RHO^2 es mayor a 0,72. Estas diferencias podrían explicarse considerando que las estaciones no incluidas del NOA están ubicadas en una región con importantes gradientes de elevación y precipitación, por lo que su no inclusión en CHIRPS genera problemas de representación allí y, por lo tanto, menor valor de RHO.

En la Figura 2-8 se muestran las funciones de densidad de probabilidad empírica para valores diarios de precipitación según OBS y las estimaciones de CHIRPS. CHIRPS subestima la frecuencia de ocurrencia de los valores más bajos y más altos de precipitación diaria observados, tanto para estaciones incluidas y no incluidas del NEA, como para las estaciones incluidas del NOA. Particularmente, en el NEA la frecuencia de ocurrencia de valores de precipitación inferiores a 20 (15) mm y superiores a 195 (190) mm en las estaciones incluidas (no incluidas) es subestimada, mientras que es sobreestimada entre dichos valores. En el caso de las estaciones incluidas del NOA, estos valores límites son 5 y 200 mm. Distinto es el caso de las estaciones no incluidas del NOA, donde la frecuencia de ocurrencia de valores inferiores a 30 mm y entre 70-200 mm es sobreestimada por CHIRPS, mientras que para

valores entre 30-70 mm y superiores a 200 mm se observa una subestimación. La subestimación de la frecuencia de ocurrencia de los valores de precipitación más elevados es un resultado esperado debido al proceso de producción de CHIRPS, el cual elimina los valores de precipitación más extremos observados (Funk et al., 2015), y también debido al proceso de desagregación de precipitación pentadal a diaria.

La distribución espacial de RHO y su correspondiente distribución empírica por región y según si los datos están incluidos o no en la producción de CHIRPS se muestra en la Figuras 2-9 y 2-10, respectivamente. En contraste, en el NEA los meses más secos (junio a septiembre) tienen mayores valores de RHO que los observados para meses más lluviosos (octubre a mayo). Mientras que para el NOA se observa la situación inversa, es decir los valores de RHO son mayores en los meses más lluviosos (octubre a abril) que para los meses más secos (mayo a septiembre). En el caso del NEA se observa que los valores de RHO son superiores a 0,5 para todos los meses del año. Mientras que para el NOA los mismos disminuyen fuertemente en algunos casos, especialmente en las estaciones no incluidas (Figura 2-10), que llegan a registrar valores tan bajos que no son estadísticamente significativos. Para las estaciones incluidas y no incluidas del NEA se observan valores de RHO similares entre ellas, mientras que para el NOA se observan diferencias más importantes (Figura 2-10). En este último caso, se observa que las distribuciones empíricas de RHO son marcadamente diferentes según las estaciones estén o no incluidas en la producción de CHIRPS, observándose una predominancia de bajos valores de RHO en las estaciones no incluidas del NOA.

Las Figuras 2-11 y 2-12 muestran los resultados para MRE en forma similar a como se mostraron para RHO. En el NEA se observa una mejor performance que en el NOA para las estimaciones de precipitación mensual de CHIRPS, en coincidencia con la evaluación realizada para RHO. Las estaciones del NEA, tanto las incluidas como no incluidas, muestran valores óptimos de MRE (cerca de cero) en los meses más lluviosos con valores entre -0,15 y 0,15. En el NOA se observan los peores valores de MRE en los meses más secos, con algunos casos de importante sobreestimación en los meses de abril, mayo y junio (puntos rojos en la Figura 2-11). La mejor performance en el NOA se observa para las estaciones incluidas en los meses de noviembre, diciembre, febrero y marzo, con valores de MRE entre -0,3 y 0,3 en la mayoría de los casos (Figura 2-12). Por otra parte, cuando solo se analizan las estaciones no incluidas del NOA, se observa una importante subestimación de CHIRPS con valores de MRE de hasta -1 en casi todos los meses (Figura 2-12).

Las Figuras 2-13 y 2-14 muestran los resultados para MAE. Es notable que para los meses más secos los valores de MAE son más bajos en el NA, lo cual es esperable debido a que MAE es una métrica dependiente de la escala y en esos meses la precipitación es más baja. La distribución espacial muestra que los valores de MAE son más cercanos a cero en el NEA que en el NOA durante los meses más lluviosos (noviembre a abril), y viceversa durante los meses más secos (mayo a agosto). El máximo MAE obtenido (247 mm) se observa en enero en una estación del centro del NOA, uno de los sectores más lluviosos del NA.

Finalmente, las Figuras 2-15 y 2-16 muestran los resultados para NSE. En coincidencia con las otras métricas, los valores obtenidos de NSE muestran una mejor performance de CHIRPS en el NEA que en el NOA. En el NEA los valores son óptimos (cerca de 1), tanto para estaciones incluidas como para las no incluidas (Figura 2-16). Para el NOA, las estaciones incluidas muestran mejores valores de NSE que las no incluidas, las cuales tienen valores de casi -2,5 en el peor de los casos. Excepto para las estaciones no incluidas del NOA, el resto de las estaciones del NA muestran valores de NSE en el rango 0-1, lo cual indica que la varianza residual entre CHIRPS y OBS es más baja que la propia varianza de OBS, con lo cual el desempeño de CHIRPS es aceptable en estos casos.

2.4.3. Evaluación de CHIRPS para índices de precipitación anual

2.4.3.1. Valores medios y variabilidad interanual

Los valores de RHO para los índices anuales de precipitación se muestran de forma similar al caso de la precipitación mensual (Figuras 2-9 y 2-10) en las Figuras 2-17 y 2-18. Para algunos índices relacionados con número de días con lluvia mayor a 1 mm (nP, CDD y CWD) y para índices muy extremos (por ejemplo, R99p y Rx1DAY) se observa una gran cantidad de valores de RHO no significativos (círculos no coloreados en Figura 2-17). En estos casos, los mayores valores de RHO (0,4 - 0,6) se observan en las estaciones incluidas del NEA (Figura 2-18). Por otra parte, los valores más altos de RHO se observan para PRCTOT, R95pad, R99pad, R10MM y R20MM para estaciones incluidas del NOA y del NEA (Figura 2-18), con máximos valores hacia el este del NEA (Figura 2-17). Para las estaciones no incluidas del NOA se observan los valores más bajos de RHO, entre los cuales varios son no significativos. Por ejemplo, para PRCPTOT, R95pad y R99pad la distribución empírica de RHO para estaciones no incluidas del NOA está centrada en $\sim 0,3$, valor que coincide con el umbral de significancia estadística, mientras que para las estaciones incluidas la distribución está centrada en $\sim 0,7$.

Los valores de MRE para PRCPTOT, R95pad y R99pad (Figuras 2-19 y 2-20) son cercanos a cero en la mayoría de las estaciones incluidas, en coincidencia con los buenos valores de RHO observados. En general, hay una subestimación de los índices de precipitación por parte de CHIRPS, siendo los mayores valores absolutos de MRE los obtenidos para los índices muy extremos (Rx1DAY, RTOP4, R99P y R95P) en las estaciones no incluidas del NOA (Figura 2-20). Los índices extremos, los cuales tienen gran variabilidad espacial en el NOA, pueden ser sensibles al uso de un número insuficiente de estaciones en la producción de CHIRPS, lo cual podría explicar los valores obtenidos de MRE.

Los resultados para MAE (Figuras 2-21 y 2-22) muestran que CHIRPS representa mejor los valores de CDD, CWD, nP y SDII (menor MAE) en las estaciones incluidas del NEA. En los demás índices, se obtuvo un menor MAE para las estaciones incluidas del NOA. Para las estaciones no incluidas del NA hay mayor dispersión entre los valores de MAE obtenidos (Figura 2-22). En concordancia con los resultados para MRE, los valores más cercanos a cero

se obtuvieron para PRCPTOT, R95pad y R99pad en las estaciones incluidas de ambas subregiones.

Los valores de NSE obtenidos (Figuras 2-23 y 2-24) son óptimos en general para PRCPTOT, R95pad y R99pad en todas las estaciones del NEA y las incluidas del NOA. Para las estaciones no incluidas del NOA existe una gran dispersión entre valores, lo cuales se apartan del rango más óptimo (0-1). Por ejemplo en el NEA se observa un máximo valor de NSE de 0,88 para PRCPTOT, en contraste con valores por debajo de -1 en algunas estaciones no incluidas del NOA. Para los demás índices de precipitación, en general los valores de NSE no son óptimos en el NA ($NSE < 0$).

2.4.3.2. Tendencias

Se observan tendencias lineales significativas (al 95% de nivel de confianza) para algunos índices en estaciones del NA (Figura 2-25) según OBS y CHIRPS en el periodo 1982-2019. Si bien en ambos conjuntos de datos se detectan tendencias, el acuerdo entre ellos es bajo. De 90 valores de tendencia significativa obtenidos (considerando cada índice en cada estación), solamente 2 ocurren simultáneamente en OBS y CHIRPS: una tendencia positiva en CDD y una tendencia negativa en R99P, ambas en la estación “Jujuy”, al norte del NOA. En el caso de Jujuy, el valor de la tendencia estimado a partir de la pendiente de Sen (Figura 2-26), es similar en CHIRPS y OBS para CDD (~ 1 día/año), mientras que para R99P la tendencia en OBS (-1 mm/año) es más grande que en CHIRPS ($-0,4$ mm/año).

Para CDD en general, si bien solo para Jujuy hay coincidencia en el signo y significancia de las tendencias en OBS y CHIRPS, en general ambos conjuntos de datos muestran tendencias positivas (0,4 - 1,5 días/año) concentradas en el norte del NOA sin coincidir en la ubicación exacta de las mismas (Figura 2-25). Más allá de esto, se observa en general un déficit en CHIRPS para representar las tendencias observadas en los demás índices. Esto se da tanto para estaciones incluidas como para las no incluidas, siendo 17 las tendencias sin detectar en CHIRPS para el primer caso y 15 para el segundo. nP es el índice con mayor cantidad de tendencias en OBS (9) que no fueron detectadas en CHIRPS.

CHIRPS muestra tendencias negativas que no están presentes en OBS en los índices Rx1DAY, R99P y RTOP4 en estaciones del NEA (Figura 2-25). Sin embargo, en el caso de Rx1DAY y RTOP4, la mayoría de esas tendencias tienen valores similares a los obtenidos con OBS (Figura 2-26), con la diferencia de que en OBS las mismas no llegan a ser estadísticamente significativas.

La Figura 2-27 muestra la distribución espacial de los valores de tendencias significativas según OBS solamente. En general la mayor parte de las tendencias se observan en el NOA, donde predominan las tendencias compatibles con condiciones más secas. Como se mencionó existe un incremento general en CDD en el NOA, a la vez que se observa una disminución de todos los índices en varias estaciones de dicha región, con excepción de R99P, RTOP4 y RX1DAY que muestran incrementos sobre el extremo norte, y de SDII y CWD que muestra

incrementos sobre el centro. En el caso particular de nP, predominan las tendencias negativas (-0,2 a -1,2 días/año) en NA, con algunas estaciones aisladas que muestran un aumento (0,6-0,8 días/año) del mismo.

2.5. Discusión

En la evaluación de CHIRPS se realizó una distinción entre estaciones incluidas y no incluidas en su producción, lo que permitió detectar que sus deficiencias se ven acentuadas cuando se evalúan las estimaciones para las estaciones no incluidas del NOA.

Se detectó que CHIRPS en general subestima la frecuencia de ocurrencia de los valores de precipitación más bajos y más altos a nivel diario. También se encontró que los valores de precipitación mensual más elevados son subestimados. Estos resultados concuerdan con los resultados de Cavalcante et al. (2020) para la región del Amazonas, una región de Sudamérica ubicada al norte del NA.

Los valores más bajos de RHO obtenidos corresponden al NOA, lo cual concuerda con resultados previos que indican una baja performance de CHIRPS en regiones montañosas (Funk et al., 2015; Gupta et al., 2019), donde la variabilidad espacial de la precipitación es importante y los sistemas de precipitación son de menor escala. Además, los bajos valores de RHO para los meses más secos en el NOA es una característica común observada en CHIRPS y productos similares (Liu et al., 2019; Zhang et al., 2022), debido a su baja capacidad de detección de precipitaciones más débiles. A su vez, este resultado para el NOA concuerda con resultados obtenidos para el norte de Chile (región contigua al NA) donde las estimaciones de CHIRPS fueron más precisas en los meses más lluviosos (noviembre a marzo) en contraste a lo observado en los otros meses. En contraste, en el NEA los mayores valores de RHO fueron obtenidos para los meses más secos, en concordancia con los resultados para el Amazonas reportados por de Moraes Cordeiro y Blanco (2021). En el NEA la disminución de la precipitación que ocurre en los meses más secos es menos pronunciada que en el NOA, y posiblemente por esto CHIRPS logra tener una mejor habilidad para la detección de precipitación en esos meses en el NEA. Además, la región del Amazonas provee un flujo sostenido de humedad hacia el NEA a lo largo de todo el año, por lo que resultados similares pueden esperarse debido a esta conexión entre ambas regiones. Por otra parte, en los meses más lluviosos existe una fuerte convección en el NA y nubes no asociadas a precipitación están presentes, lo cual incrementa la detección errónea de precipitación a partir de estimaciones satelitales. Por el contrario, en los meses más secos este efecto se ve reducido lo que redundará en una mejor detección de la precipitación por parte de CHIRPS en el NEA. En contraste, si bien en el NOA la convección y la presencia de nubes disminuyen, lo hacen de manera más abrupta que en el NEA, de manera que los valores de precipitación son muy bajos y por lo tanto difíciles de detectar por CHIRPS.

Una comparación del análisis mensual de este trabajo con los resultados de Cerón et al. (2020) para la Cuenca del Plata puede realizarse, ya que dicho trabajo incluye el NEA y parte del NOA. La diferencia con el análisis de esta tesis es que ellos analizan la precipitación total

por estación del año, mientras que en este caso analizamos cada mes por separado. Ellos calcularon RHO sin separar las estaciones del año, y debido a que la variabilidad estacional es mayor a la variabilidad interanual, sus valores de RHO son más altos que los obtenidos en esta tesis. Respecto a MRE, equivalente al “bias” calculado por Cerón et al. (2020), hay acuerdo en que CHIRPS muestra valores más bajos y, por lo tanto, mejor performance en el NEA. En el caso de MAE, es similar, pero no igual, al RMSE que calculan ellos. Ellos obtienen valores de 40 a 90 mm para el RMSE, con los máximos observándose sobre el NOA en verano y sobre el NEA en invierno, en coincidencia con los resultados de este trabajo.

Respecto a los índices anuales de precipitación, la literatura concuerda en general en que CHIRPS tiene una performance baja para los índices más extremos (e.g., Cavalcante et al., 2020; Paredes Trejo et al., 2016). En el caso de la baja performance de CHIRPS para nP e índices relacionados, Katsanos et al. (2016) lo atribuyen a deficiencias en el criterio utilizado en CHIRPS para definir un día con precipitación. Paredes Trejo et al. (2016) también señalan la baja capacidad de CHIRPS para detectar eventos de lluvia. Por otra parte, el mejor desempeño de CHIRPS para representar PRCPTOT y R95pad, en conjunto con la fuerte subestimación de los índices más extremos en el NA coincide con los resultados de Cavalcante et al. (2020) para el Amazonas.

En cuanto a las tendencias lineales de los índices de precipitación, las deficiencias detectadas en CHIRPS sobre el NA concuerdan con estudios similares realizados en otras regiones tales como Brasil y La India (Cavalcante et al., 2020; Bhattacharyya et al., 2022). Sin embargo, existen regiones del mundo, tales como África Subsahariana o Pakistán, donde CHIRPS es de los mejores conjuntos de datos para analizar los cambios de largo plazo en la precipitación extrema (Harrison et al., 2019; Nawaz et al., 2021). El análisis realizado aquí distinguiendo resultados para estaciones incluidas y no incluidas muestra que en ambos casos hay una importante incapacidad de CHIRPS para representar las tendencias observadas. De esta manera, se puede concluir que la incorporación de más estaciones en la producción de CHIRPS no garantiza necesariamente una buena representación de las tendencias observadas.

En general la mayor parte de las tendencias obtenidas se observan en el NOA, donde predominan las tendencias compatibles con condiciones más secas en concordancia con resultados obtenidos por otros autores para la precipitación total del año y algunos índices extremos (Castino et al., 2017; Bazzano et al., 2019; Ferrero y Villalba, 2019). En el caso del incremento observado de CDD en el NOA, los resultados obtenidos concuerdan con lo reportado por Skansi et al. (2013) para el período 1969-2009 y Balmaceda Huarte et al. (2021) para el periodo 1979-2017 en la región. Por lo tanto, puede concluirse que en el NOA, CDD muestra un incremento desde 1969 al menos, lo cual es un indicador de que hubo un incremento en la duración de la estación seca. Si bien CHIRPS falla en localizar con precisión la ubicación de los puntos con tendencias significativas observadas (Fig. 2-25), detecta el aumento de CDD en la región, aumentando la confianza en la capacidad del mismo para monitorear condiciones más secas en el largo plazo.

2.6. Conclusiones

El ciclo anual de precipitación en el NA muestra un periodo más lluvioso en los verano y uno más seco en los meses de invierno. Este ciclo es mucho más pronunciado en el NOA que en el NEA. El patrón espacial medio de lluvia mensual y para los índices de precipitación (excepto CDD y CWD), muestra que las regiones con mayores valores corresponden al centro del NOA, sobre la provincia de Tucumán, y sobre el este del NEA. En el caso de CDD, en los sectores mencionados se observan mínimos valores debido a que es un indicador de la ausencia de lluvia. En tanto, para CWD se observan los máximos valores sobre gran parte del NOA. Los patrones espaciales obtenidos muestran un importante gradiente longitudinal más que latitudinal.

Luego de determinar el patrón descrito, se realizó una evaluación de CHIRPS sobre el NA distinguiendo entre estaciones incluidas y no incluidas en su producción y comparando resultados para dos subregiones (NOA y NEA). La evaluación fue realizada sobre un periodo de 38 años, abarcando 1982-2019, y utilizando datos observados en 50 estaciones meteorológicas no usadas hasta la actualidad para este propósito. CHIRPS representa mejor la variabilidad interanual de la lluvia mensual en los meses más lluviosos (más secos) en el NOA (NEA). Sin embargo, los valores de precipitación mensual son subestimados en general sobre el NA, especialmente en el centro del NOA durante los meses más lluviosos y sobre las estaciones no incluidas en la producción de CHIRPS.

La variabilidad interanual de los índices de precipitación anual es mal representada por CHIRPS (bajos valores de RHO) para nP e índices relacionados (CDD, CWD) e índices muy extremos (por ej., R99P, Rx1DAY, R50MM). Solo para unas pocas estaciones en el este del NEA se observa una buena performance para estos índices. En cambio, CHIRPS representa aceptablemente la variabilidad interanual de los índices menos extremos, tales como PRCPTOT, R95pad, R10MM y R20MM en ambas regiones y sin importar si las estaciones están o no incluidas en la producción de CHIRPS. Por otra parte, CHIRPS subestima la mayoría de los índices en la mayoría de las estaciones analizadas, siendo más notable esto para las estaciones no incluidas del NOA.

En general la mayor parte de las tendencias obtenidas se observan en el NOA, donde predominan las tendencias compatibles con condiciones más secas. La mayoría de las tendencias observadas en los índices de precipitación no son representadas por CHIRPS, y esto parece no estar relacionado con el número de estaciones incluidas en la producción del mismo. Como una excepción, un desempeño relativamente mejor se observa para CDD, en el sentido de que CHIRPS detecta un aumento del mismo en el NOA, pero con deficiencias para detectar con precisión los puntos donde se observa esta tendencia. Por lo tanto, con un alto grado de confianza debido a las coincidencias entre estaciones y CHIRPS y a los antecedentes analizados, en el NOA CDD muestra un incremento desde 1969 al menos, lo cual es un indicador de un incremento en la duración de la estación seca.

En base a los resultados obtenidos, CHIRPS no es adecuado para estudios en el NA relacionados con la precipitación que requieran una representación precisa de los valores

medios, su variabilidad interanual y tendencias lineales. La inclusión de más estaciones en la producción de CHIRPS, especialmente del NOA, podría mejorar la representación de los valores medios y la variabilidad interanual, mientras esto no necesariamente ocurriría para las tendencias.

Figuras y tablas (Cap. 2)

Tabla 2-1: Listado de estaciones meteorológicas seleccionadas en este trabajo indicando su nombre, latitud (lat), longitud (lon), altura sobre el nivel del mar (H), porcentaje de datos diarios faltantes y subregión del NA a la que pertenece.

Nombre	Lat (°)	Lon (°)	H (m)	Faltantes (%)	Subregión
Aguas Blancas	-22.72	-64.35	407	0.4	NOA
Astillero	-22.37	-64.12	500	9.0	NOA
Balapuca	-22.48	-64.45	581	0.0	NOA
Bella Vista	-28.43	-58.92	57	0.2	NEA
Caimancito	-23.70	-64.53	356	1.8	NOA
Casa de Piedra	-27.28	-65.91	1200	19.1	NOA
Catamarca	-28.60	-65.80	470	0.2	NOA
Ceres	-29.88	-61.95	89	0.0	NEA
Chemical	-30.36	-66.31	470	0.7	NOA
Corrientes	-27.45	-58.77	61	0.0	NEA
Cuatro Cedros	-22.82	-64.52	484	0.7	NOA
S. M. de Tucumán	-26.80	-65.20	481	0.0	NOA
El Molino	-22.60	-65.15	2600	4.2	NOA
El Nogalito	-26.78	-65.47	1100	14.7	NOA
El Pabeyon	-22.55	-65.34	4265	9.0	NOA
Famailla	-27.05	-65.42	370	0.4	NOA
Formosa	-26.20	-58.23	63	0.0	NEA
Garruchos	-28.18	-55.64	78	13.6	NEA
Iguazu	-25.73	-54.47	256	0.0	NEA
Iruya	-22.80	-65.21	2741	3.3	NOA
Jujuy	-24.40	-65.10	910	1.1	NOA
La Paz	-22.40	-62.50	250	0.0	NOA
La Quiaca	-22.10	-65.60	3450	0.4	NOA
La Rioja	-29.34	-66.81	330	0.0	NOA
Las Breñas	-27.10	-61.10	104	0.4	NEA
Las Higueras	-22.75	-65.10	1972	3.7	NOA
Las Lomitas	-24.70	-60.58	134	0.0	NEA
Los Sosa	-27.10	-65.60	640	0.0	NOA
Mercedes	-29.17	-58.02	96	1.5	NEA
Nazareno	-22.51	-65.10	3101	7.0	NOA
Oran	-23.20	-64.30	360	0.0	NOA
Paltorco	-22.41	-65.09	3720	11.2	NOA
Posadas	-27.36	-55.96	81	0.0	NEA

Poscaya	-22.45	-65.08	3238	8.6	NOA
Potrero del Clavillo	-27.40	-66.10	1380	0.0	NOA
Pozo Sarmiento	-23.14	-64.20	326	17.5	NOA
Reconquista	-29.18	-59.70	49	0.4	NEA
Resistencia	-27.45	-59.05	54	0.4	NEA
Roque Saenz Peña	-26.87	-60.45	90	3.1	NEA
Ruta Provincial 11	-28.56	-59.36	46	1.1	NEA
Salta	-24.80	-65.30	1227	0.0	NOA
San Isidro	-22.76	-65.24	2956	6.6	NOA
San Jose	-22.87	-64.70	877	0.0	NOA
Santiago del Estero	-27.80	-64.30	201	0.0	NOA
Tartagal	-22.60	-63.80	450	1.8	NOA
Tres Bocas	-28.69	-59.63	43	9.2	NEA
Trigo Huaico	-22.37	-65.04	3300	9.0	NOA
Tuc Tuca	-22.40	-65.27	3950	3.3	NOA
Tucumán	-26.83	-65.10	450	0.0	NOA
Yampa II	-27.18	-65.84	1500	19.7	NOA

Tabla 2-2: Listado de los 15 índices de precipitación analizados y su definición, donde R refiere a la lluvia diaria acumulada.

Nombre	Descripción	Unidades
nP	Número de días con $R \geq 1$ mm	días
RX1DAY	Máximo valor de R	mm
SDII	Índice simple de intensidad de la precipitación: intensidad media diaria de precipitación en días con $R \geq 1$ mm	mm/día
RX5DAY	Precipitación máxima en 5 días consecutivos	mm
R10MM	Número de días con $R \geq 10$ mm	días
R20MM	Número de días con $R \geq 20$ mm	días
R50MM	Número de días con $R \geq 50$ mm	días
CDD	Máxima longitud de rachas secas: número máximo de días consecutivos con $R < 1$ mm	días
CWD	Máxima longitud de rachas húmedas: número máximo de días consecutivos con $R \geq 1$ mm	días
R95P	Precipitación total de días con $R >$ percentil 95, considerando solo días con $R \geq 1$ mm	mm
R99P	Precipitación total de días con $R >$ percentil 99, considerando solo días con $R \geq 1$ mm	mm

R95pad	Precipitación total de días con $R >$ percentil 95, considerando todos los días del año	mm
R99pad	Precipitación total de días con $R >$ percentil 99, considerando todos los días del año	mm
PRCPTOT	Precipitación total anual	mm
RTOP4	Suma de la precipitación acumulada en los 4 días con los mayores R	mm

Tabla 2-3: Ecuaciones de cada métrica de comparación de datos de CHIRPS (x) con datos de OBS (y); n corresponde al número de pares (x,y), es decir la longitud de cada serie de tiempo utilizada.

Métrica	Ecuación
Correlación lineal de Pearson (RHO)	$RHO = \frac{n(\sum xy) - (\sum x)(\sum y)}{\sqrt{[n\sum x^2 - (\sum x)^2][n\sum y^2 - (\sum y)^2]}}$
Error medio relativo (MRE)	$MRE = \frac{1}{n} \sum \frac{(x-y)}{y}$
Error medio absoluto (MAE)	$MAE = \frac{1}{n} \sum x - y $
Eficiencias de Nash-Sutcliffe (NSE)	$NSE = 1 - \frac{\sum (x-y)^2}{\sum (x - \frac{\sum x}{n})^2}$

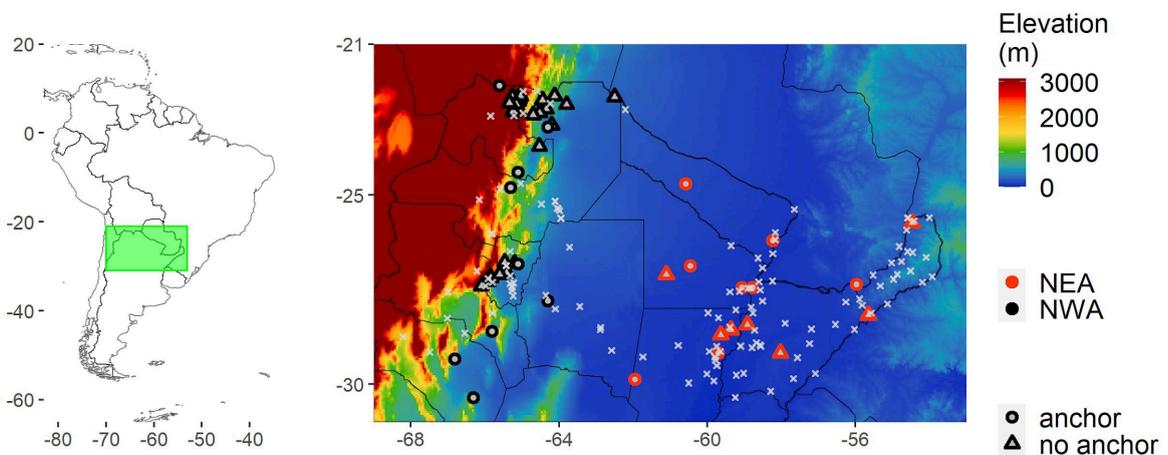


Figura 2-1: En la figura izquierda, se muestra la ubicación del NA (recuadro verde) en Sudamérica. A la derecha se muestra el mapa del NA con su relieve (colores), ubicación de las estaciones utilizadas (círculos: estaciones incluidas en CHIRPS, triángulos: estaciones no incluidas) y la subregión a la que pertenecen (negro: NOA, rojo: NEA). Cruces blancas indican la ubicación de las 120 estaciones que fueron rechazadas para el análisis.

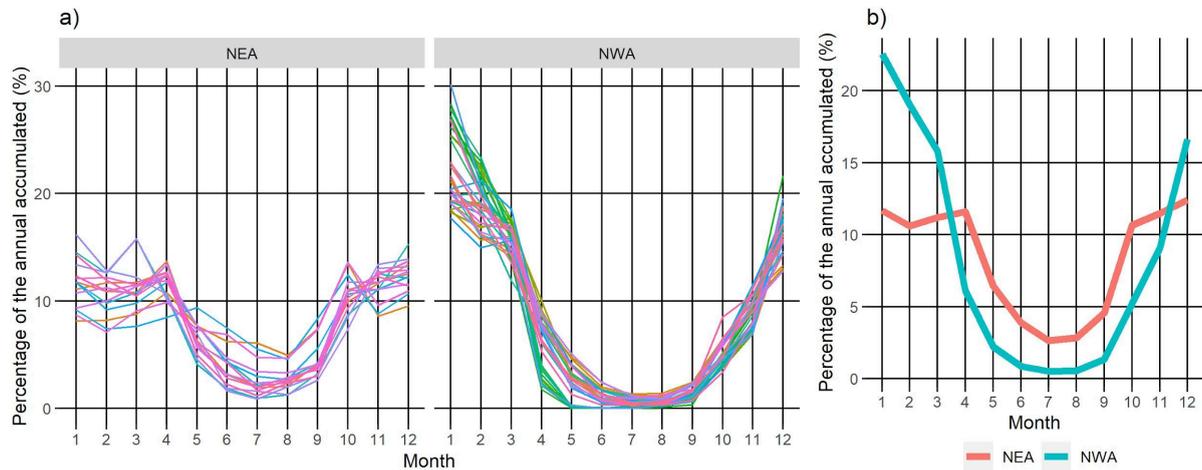


Figura 2-2: (a) Porcentaje de la lluvia total anual que ocurre en cada mes según las estaciones meteorológicas individuales analizadas en este trabajo, y (b) el promedio de ellas, separadas en ambos casos por subregión (NOA y NEA).

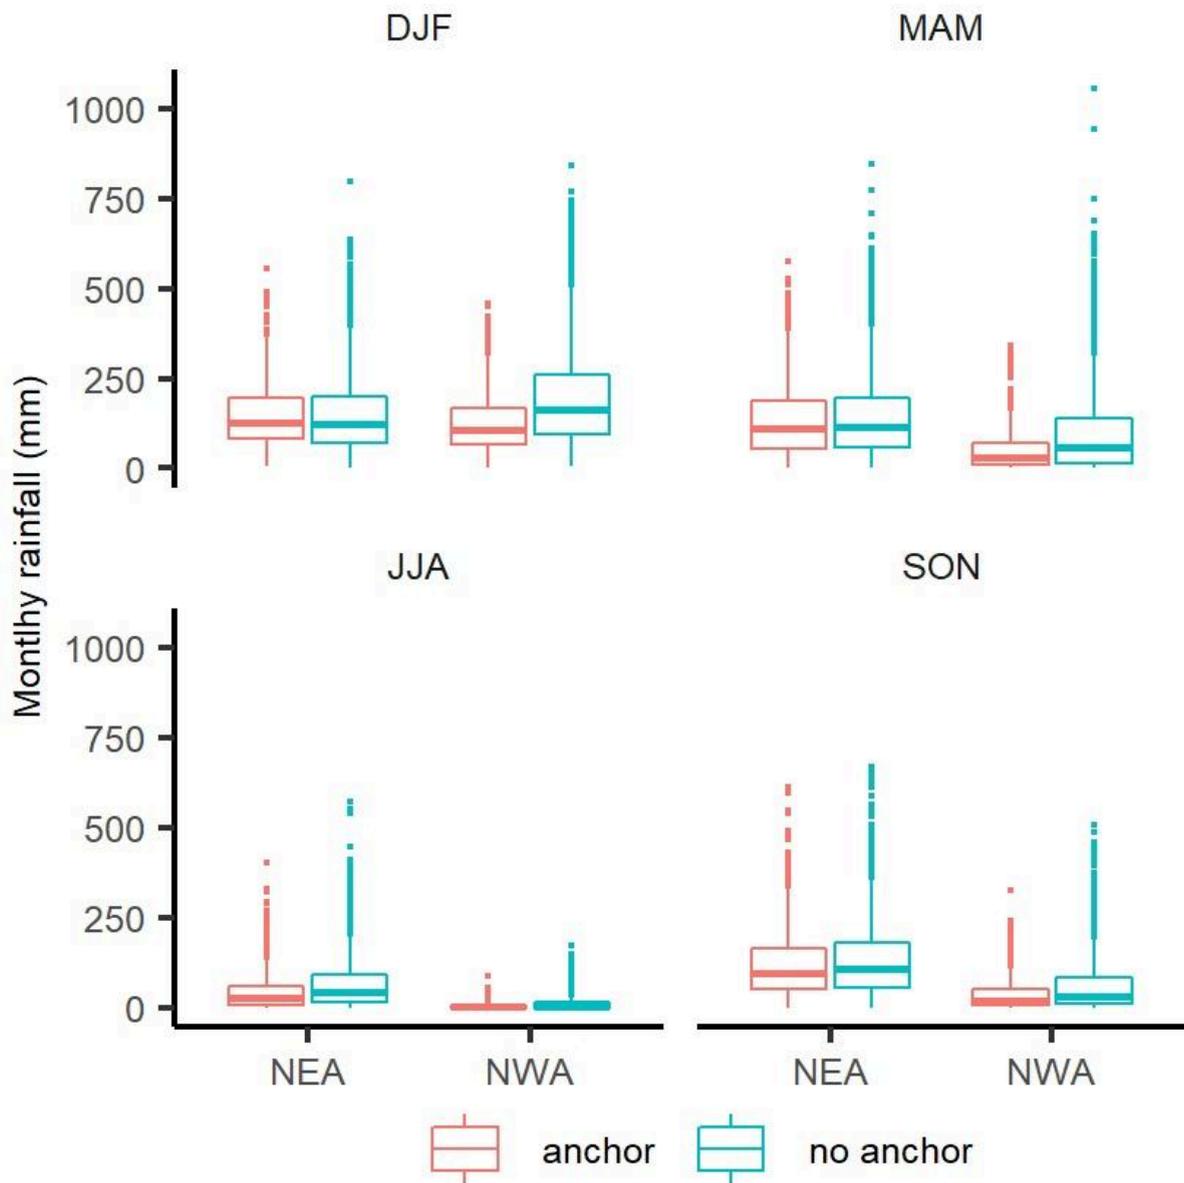


Figura 2-3: Diagrama de cajas de los valores de precipitación total por estación del año para el periodo 1990-2019. Los datos están separados por subregión de NA y de acuerdo a si las estaciones meteorológicas están incluidas (rosa) o no incluidas (celeste) en la producción de CHIRPS.

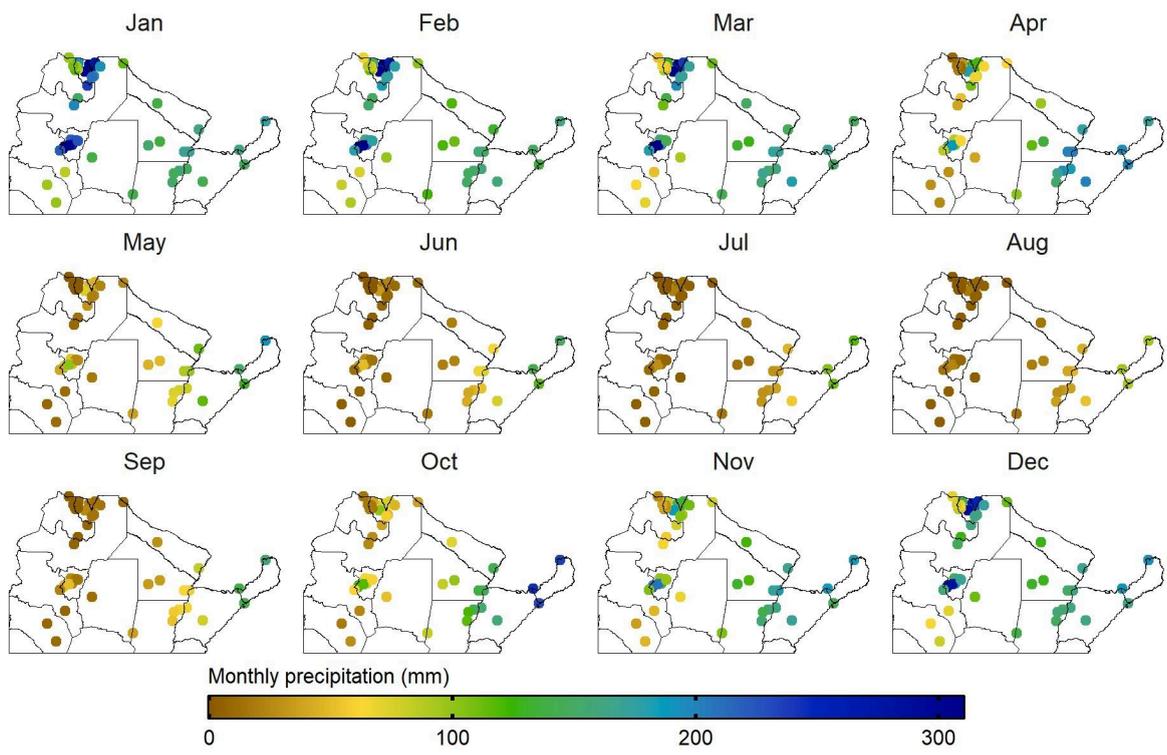


Figura 2-4: Distribución espacial de la lluvia total mensual promedio para el periodo 1990-2019 según OBS.

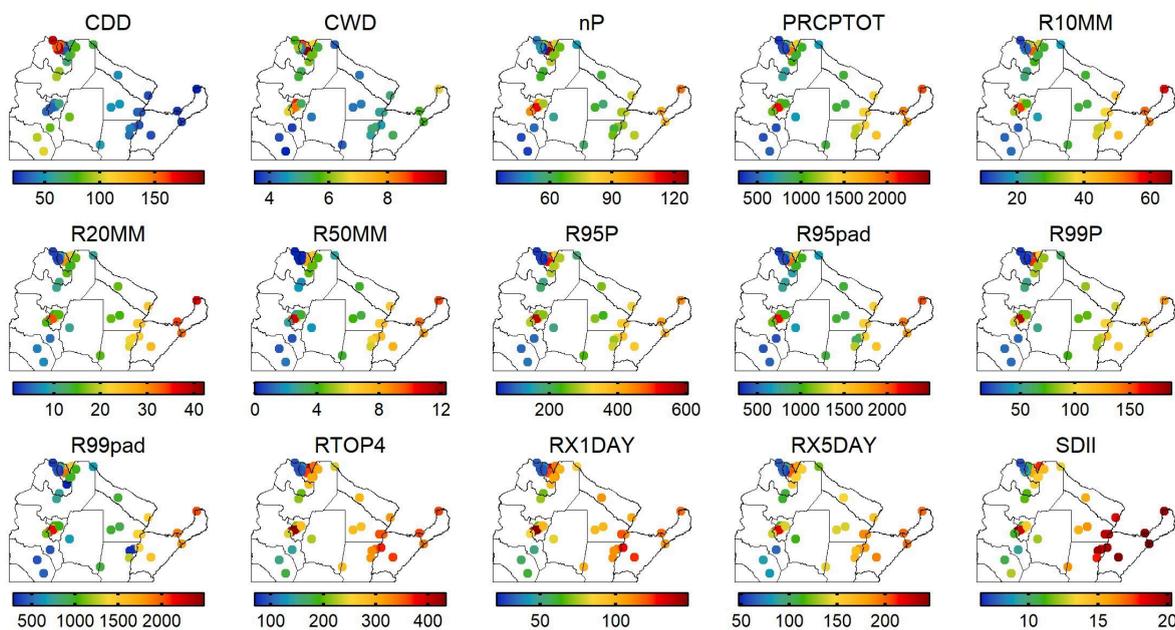


Figura 2-5: Distribución espacial de los índices de precipitación anuales promedio para el periodo 1990-2019 según OBS.

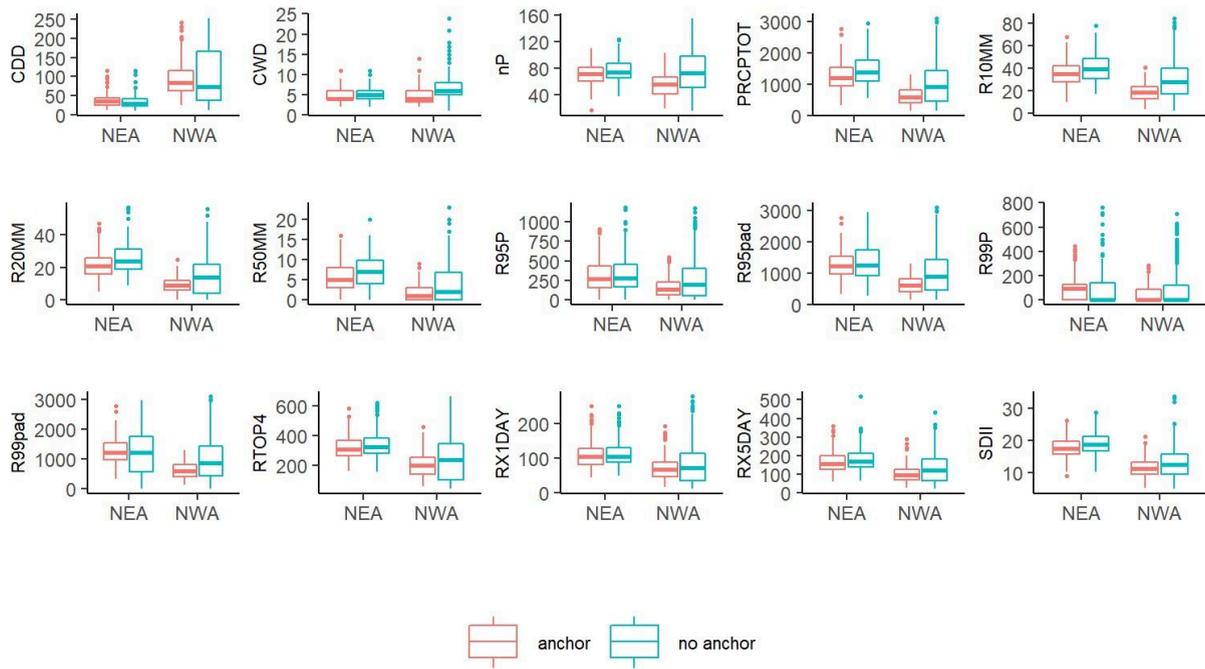


Figura 2-6: Diagrama de cajas de los valores de índices de precipitación anuales para el periodo 1990-2019. Los datos están separados por subregión del NA y de acuerdo a si las estaciones meteorológicas están incluidas (rosa) o no incluidas (celeste) en la producción de CHIRPS.

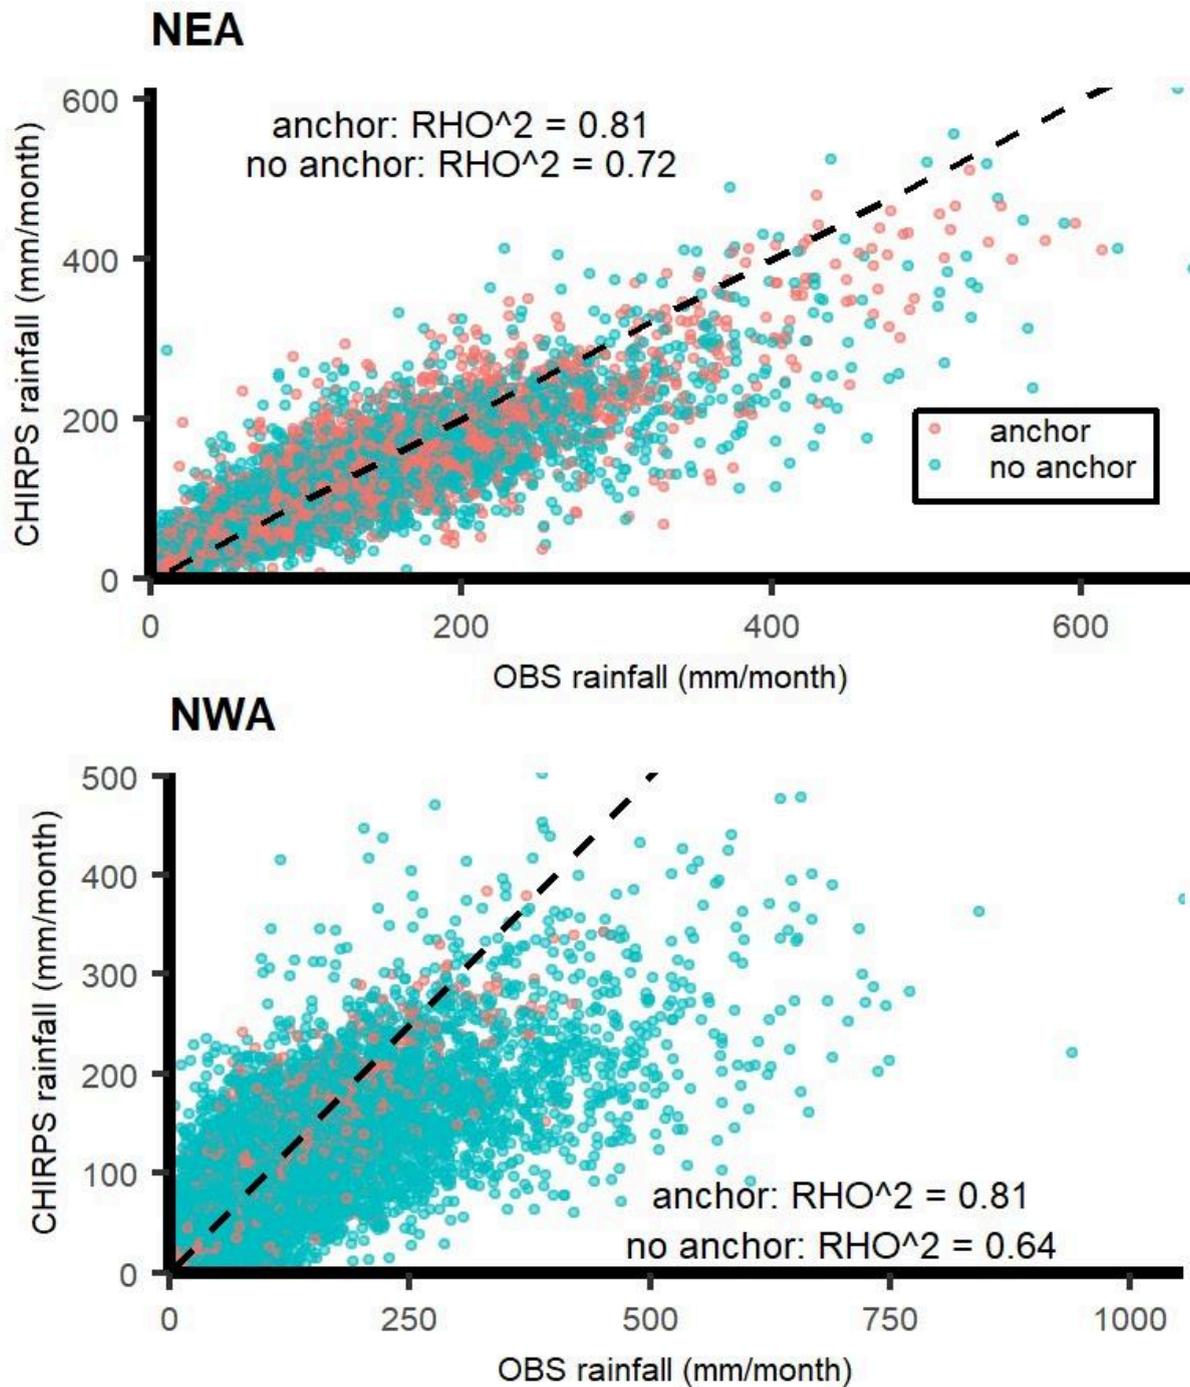


Figura 2-7: Lluvia mensual total estimada por CHIRPS (eje vertical) y los correspondientes valores según OBS (eje horizontal) para el periodo 1982-2019. Se muestran los datos separados para el NEA (panel superior) y el NOA (panel inferior), y si las estaciones están incluidas (puntos rosas) o no (puntos celestes) en la producción CHIRPS. La recta negra punteada corresponde a la recta 1:1, es decir la de coincidencia perfecta entre las estimación de CHIRPS y los valores de OBS. En cada gráfica se indica el correspondiente valor de RHO^2 .

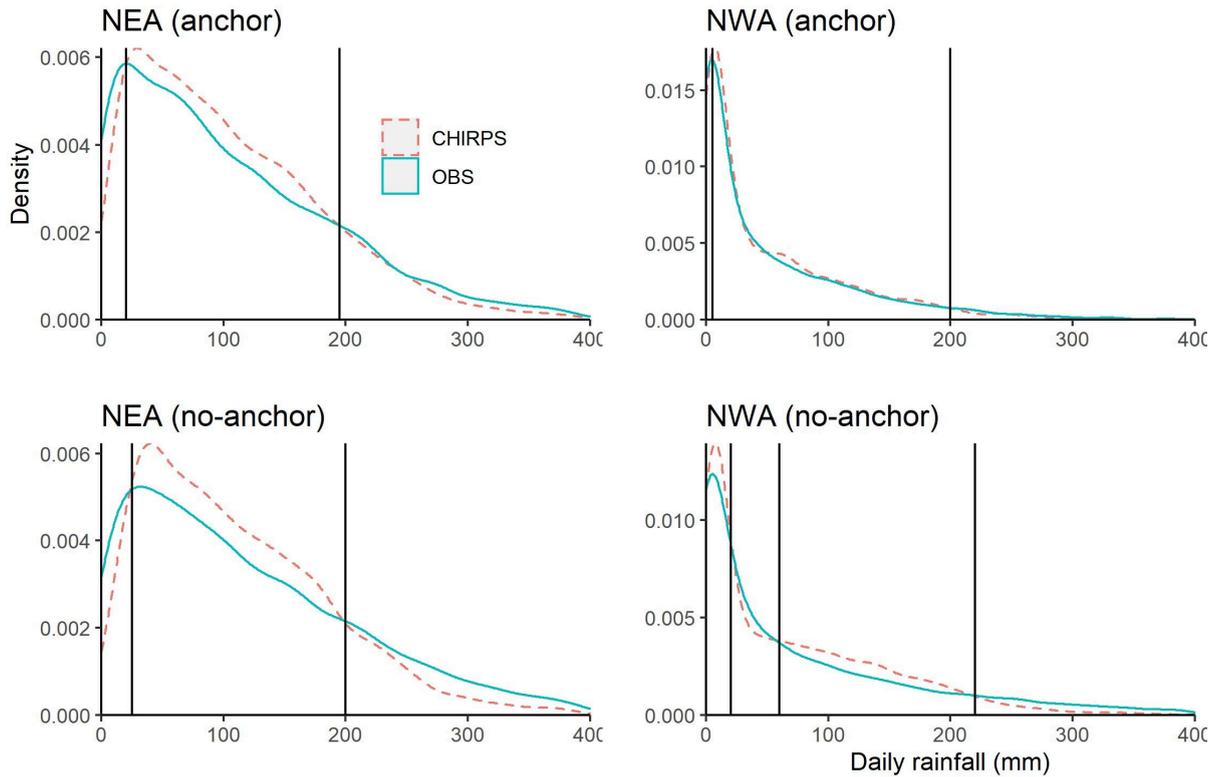


Figura 2-8: Funciones de densidad de probabilidad empírica (eje vertical) para valores diarios de precipitación (eje horizontal) según OBS (celeste) y las estimaciones de CHIRPS (rosa). Los datos fueron separados según la subregión NEA (panel izquierdo) y NOA (panel derecho), y según estén incluidos (panel superior) o no en la producción de CHIRPS (panel inferior). Las rectas verticales en cada gráfica indican los valores de precipitación en los cuales hay un cambio en la posición (arriba o abajo) de la curva de CHIRPS respecto a la curva de OBS.

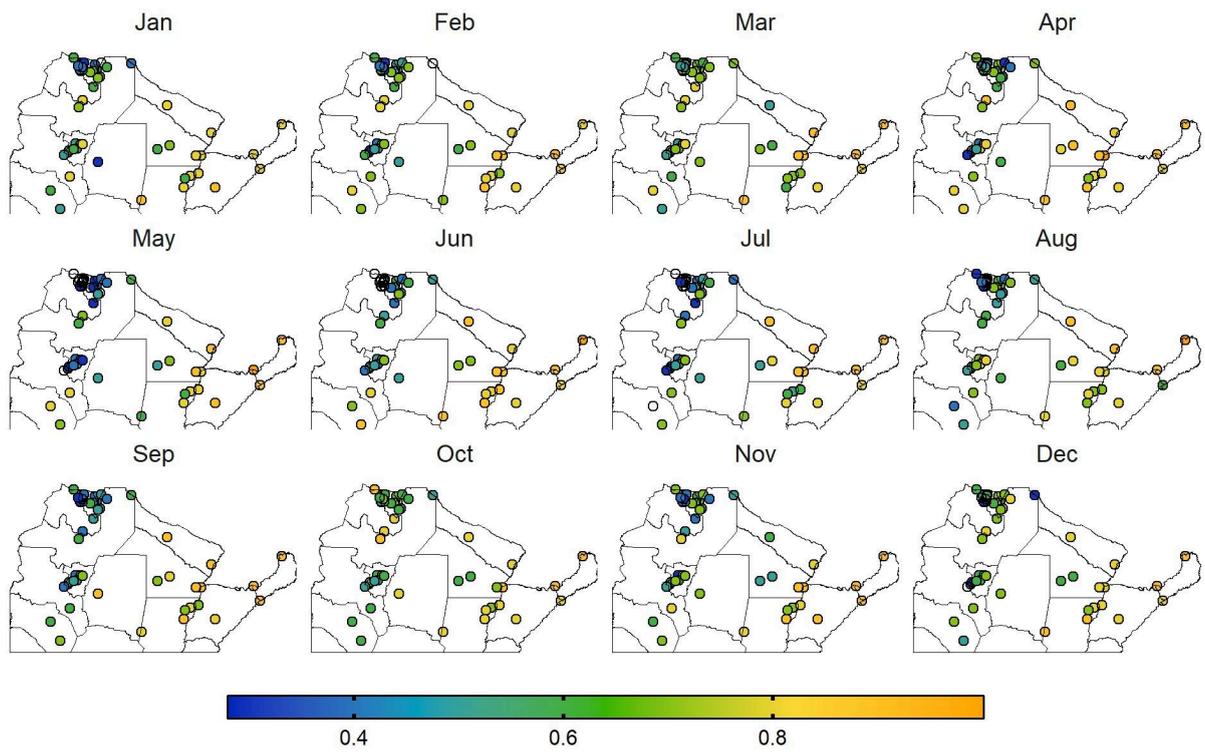


Figura 2-9: Distribución espacial de los valores de RHO (color) entre OBS y CHIRPS para la lluvia total mensual en el periodo 1982-2019. Valores de RHO no significativos se muestran como círculos no coloreados.

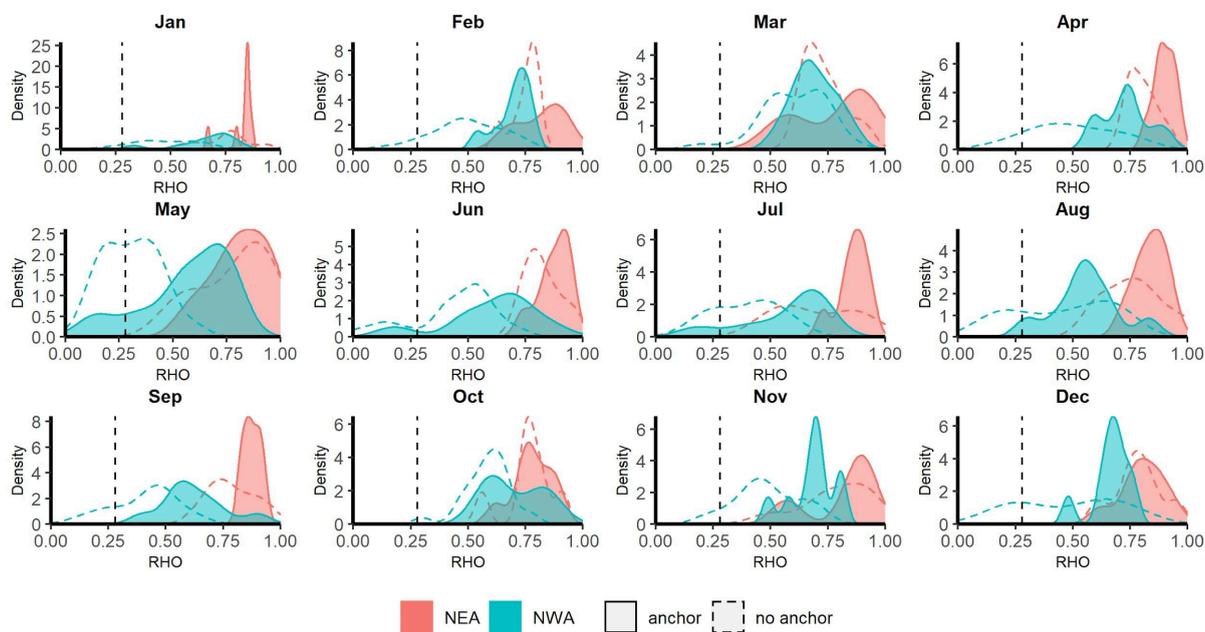


Figura 2-10: Distribución empírica de densidad de probabilidad para RHO entre OBS y CHIRPS considerando la lluvia mensual. Las curvas corresponden a los datos distinguiendo la región NEA (celeste) y NOA (rosa) y si las estaciones son incluidas (línea sólida) o no

incluidas (línea punteada) en la producción de CHIRPS. La línea vertical punteada indica el umbral de significancia del 95% para RHO.

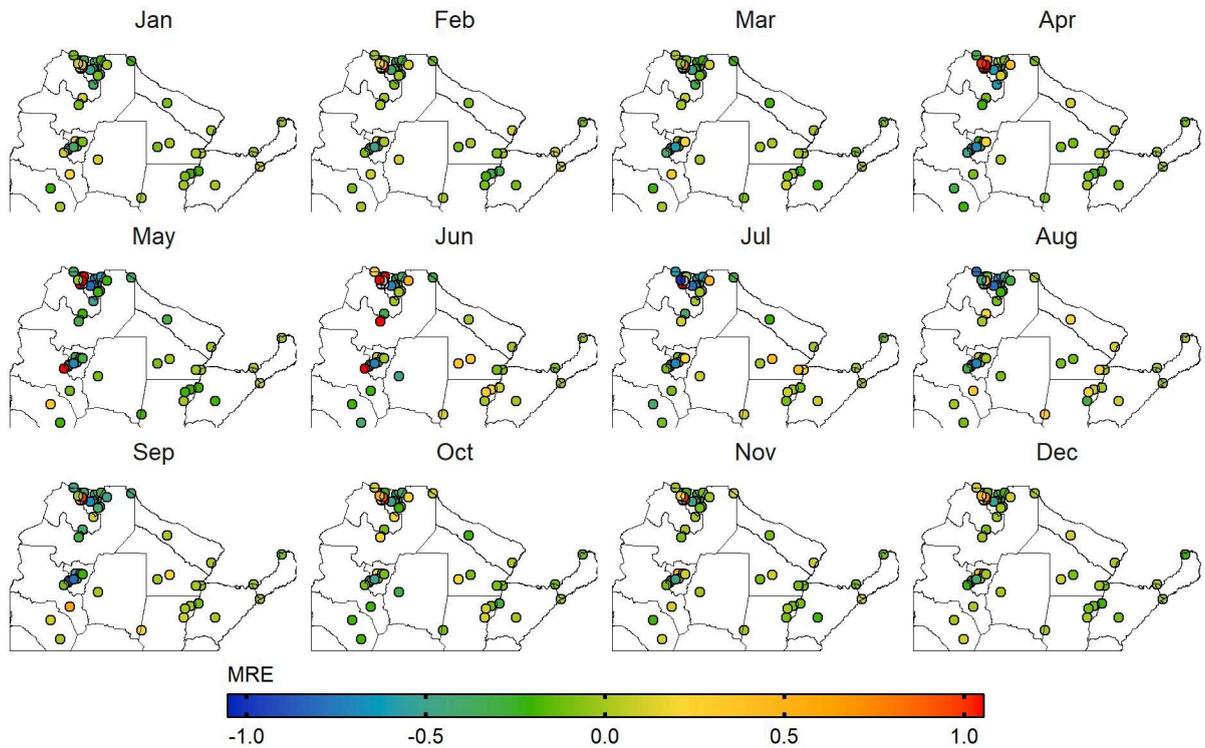


Figura 2-11: Como la Figura 2-9, pero para MRE.

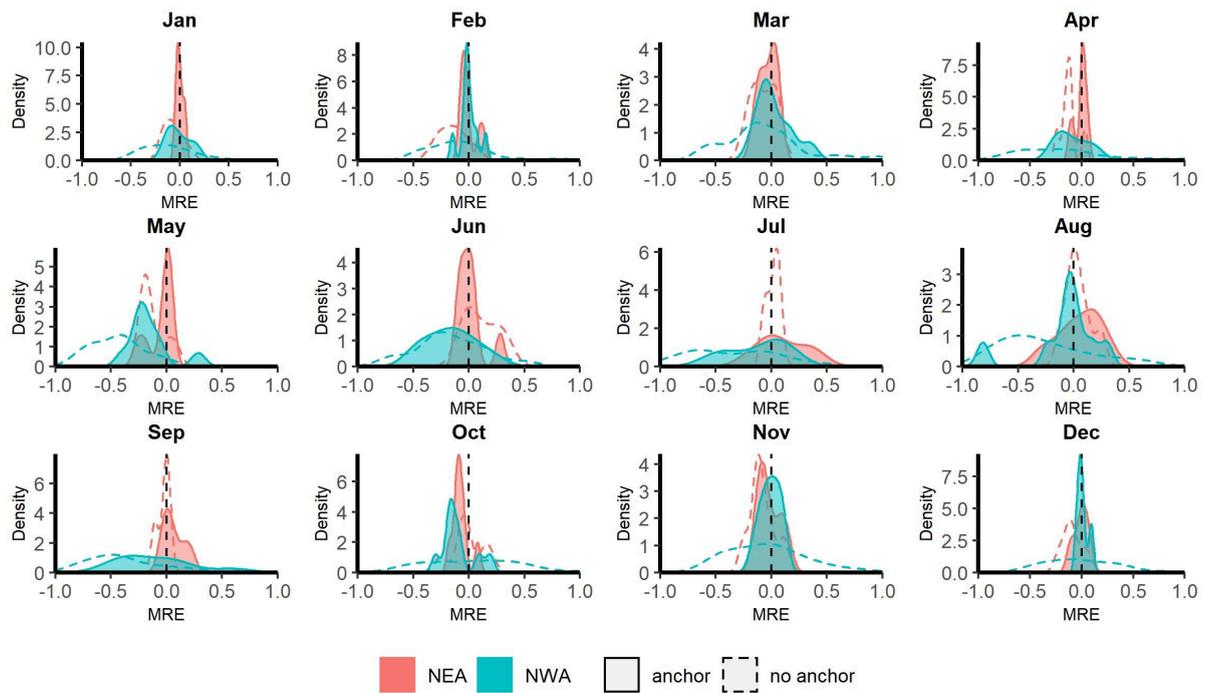


Figura 2-12: Como la Figura 2-10, pero para MRE.

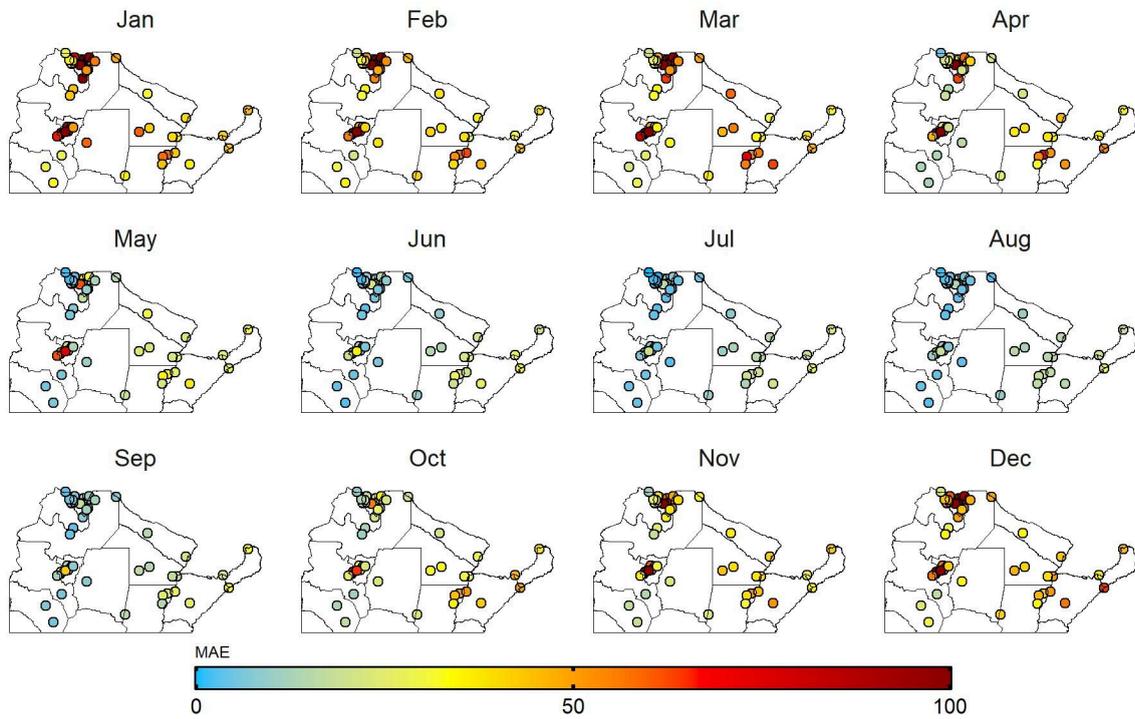


Figura 2-13: Como la Figura 2-9, pero para MAE.

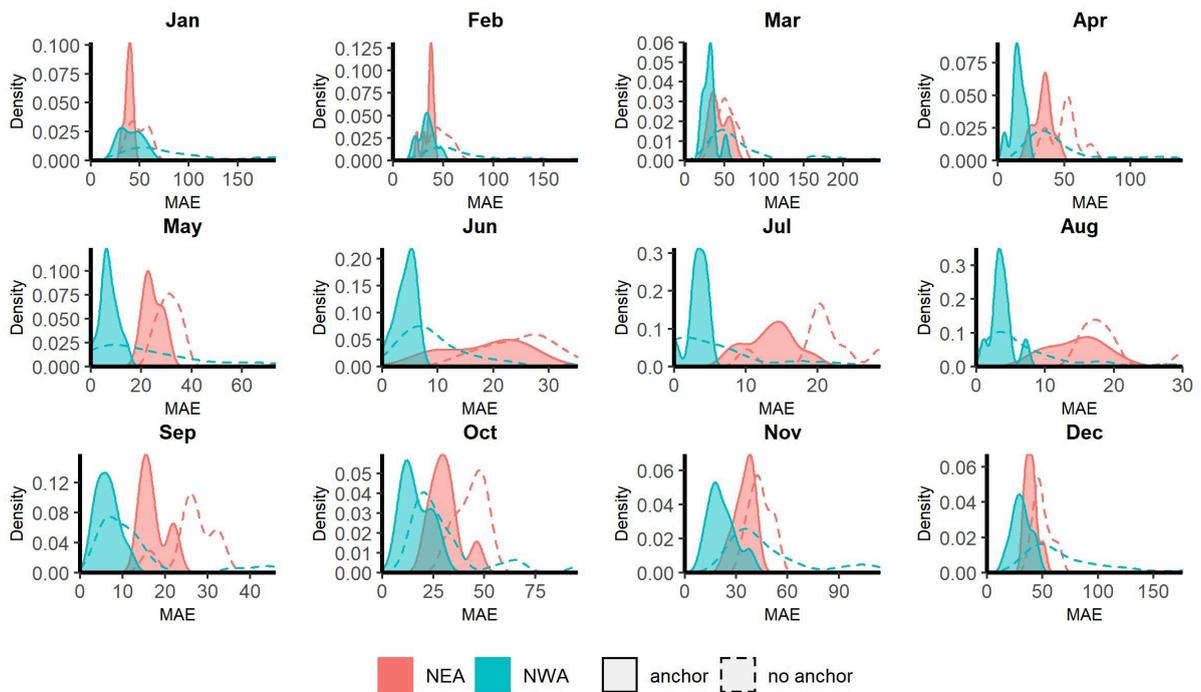


Figura 2-14: Como la Figura 2-10, pero para MAE.

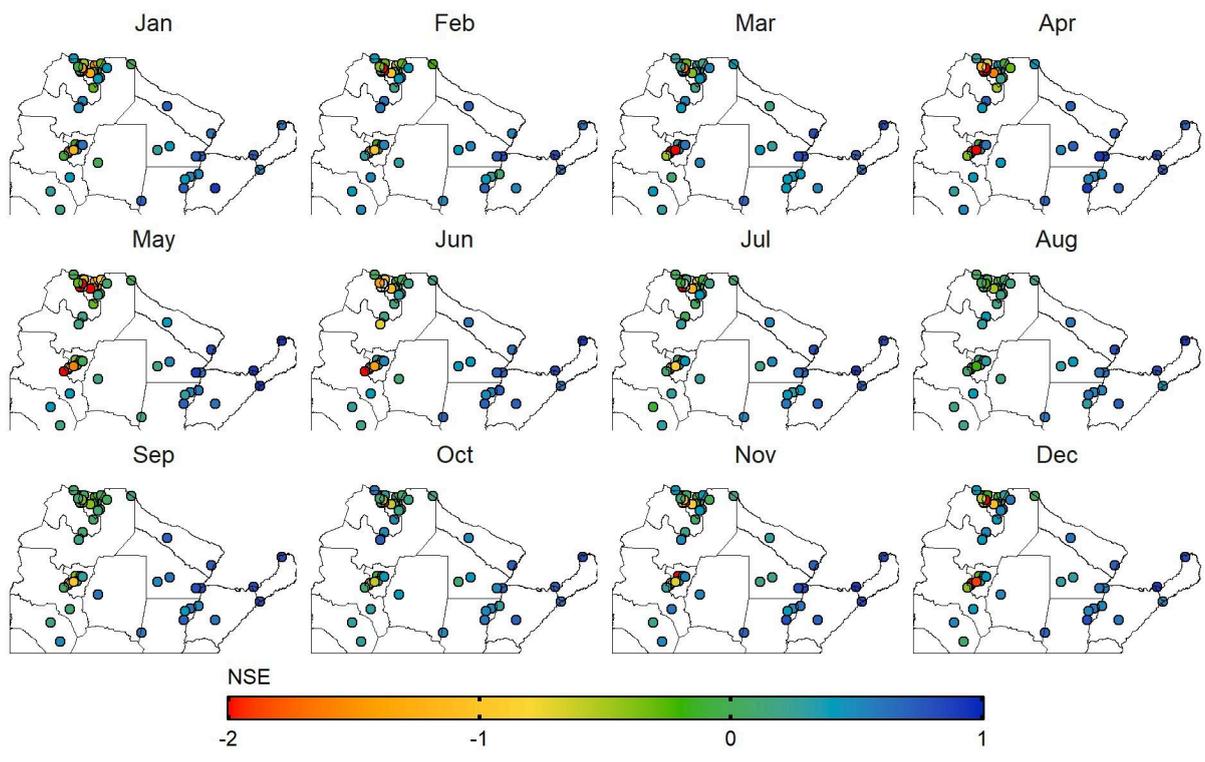


Figura 2-15: Como la Figura 2-9, pero para NSE.

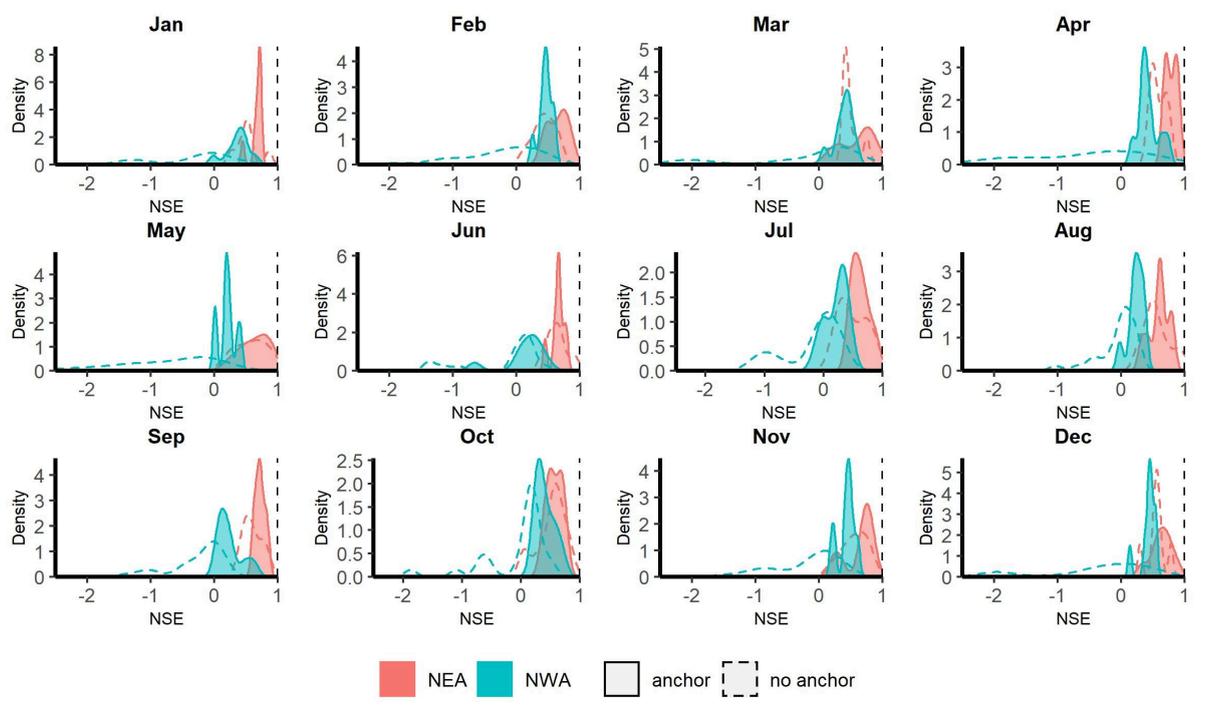


Figura 2-16: Como la Figura 2-10, pero para NSE.

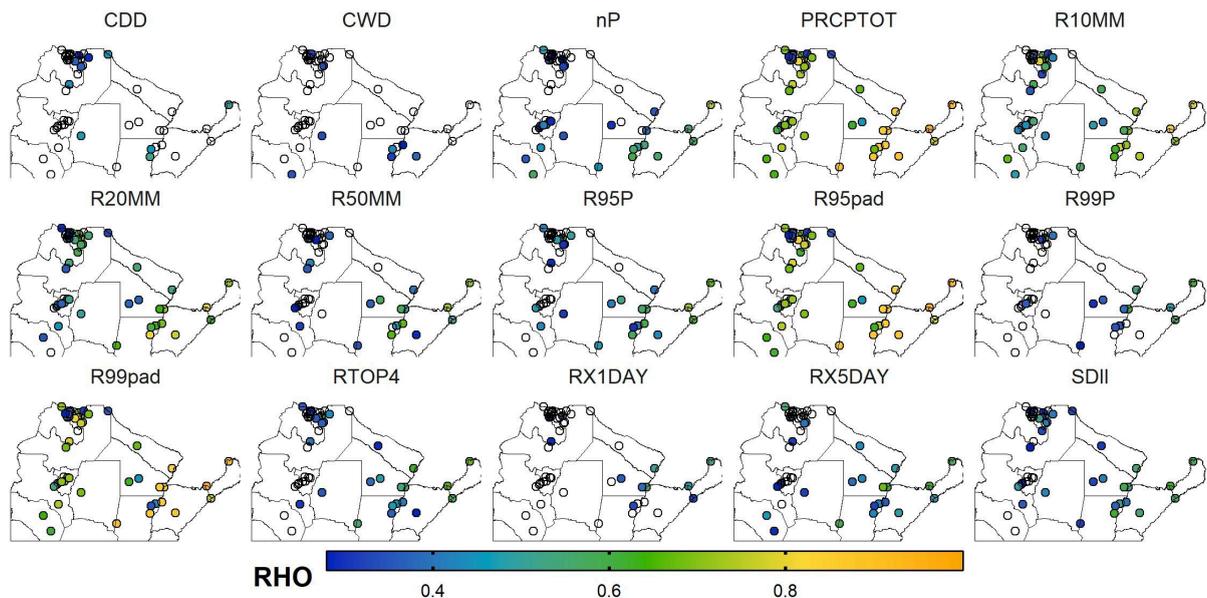


Figura 2-17: Distribución espacial de los valores de RHO (color) entre OBS y CHIRPS para los índices anuales de precipitación en el periodo 1982-2019. Valores de RHO no significativos se muestran como círculos no coloreados.

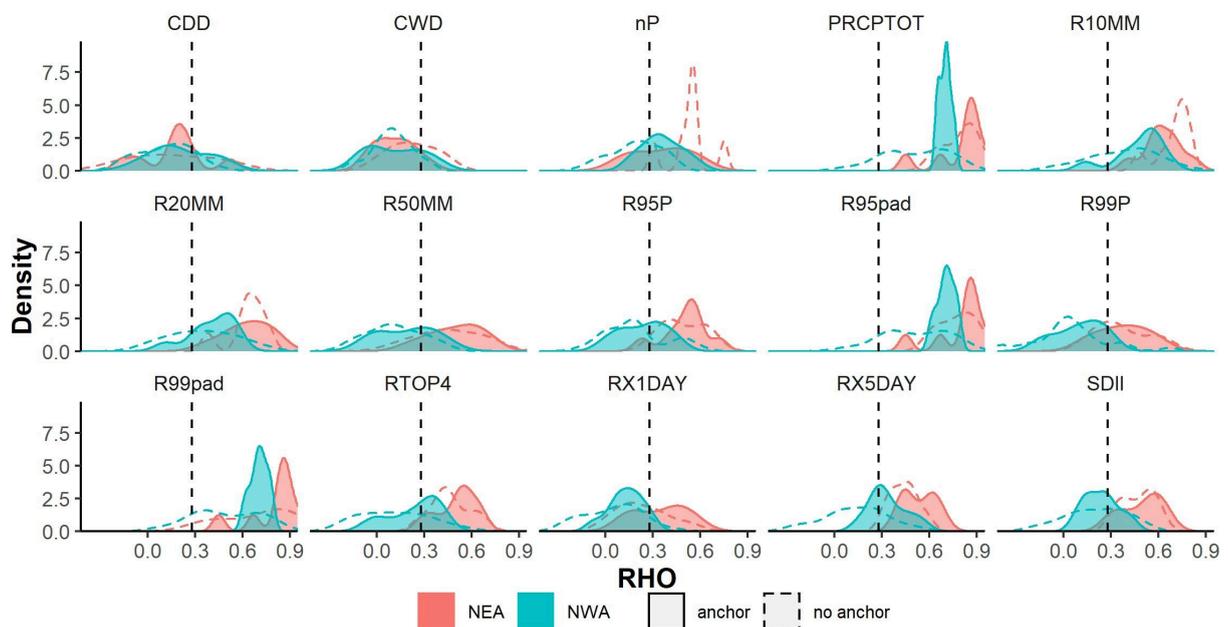


Figura 2-18: Distribución empírica de densidad de probabilidad para RHO entre OBS y CHIRPS considerando los índices de precipitación anual. Las curvas corresponden a los datos distinguiendo la región NEA (celeste) y NOA (rosa) y si las estaciones son incluidas (línea sólida) o no incluidas (línea punteada) en la producción de CHIRPS. La línea vertical punteada indica el umbral de significancia del 95% para RHO.

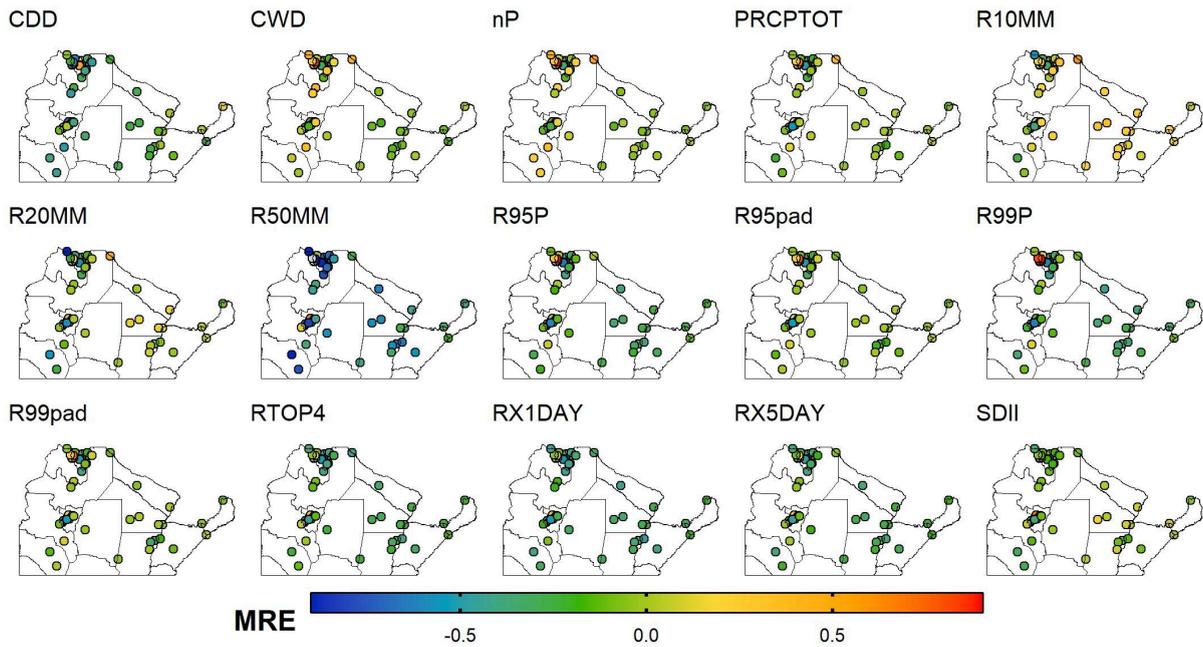


Figura 2-19: como la Figura 2-17, pero para MRE.

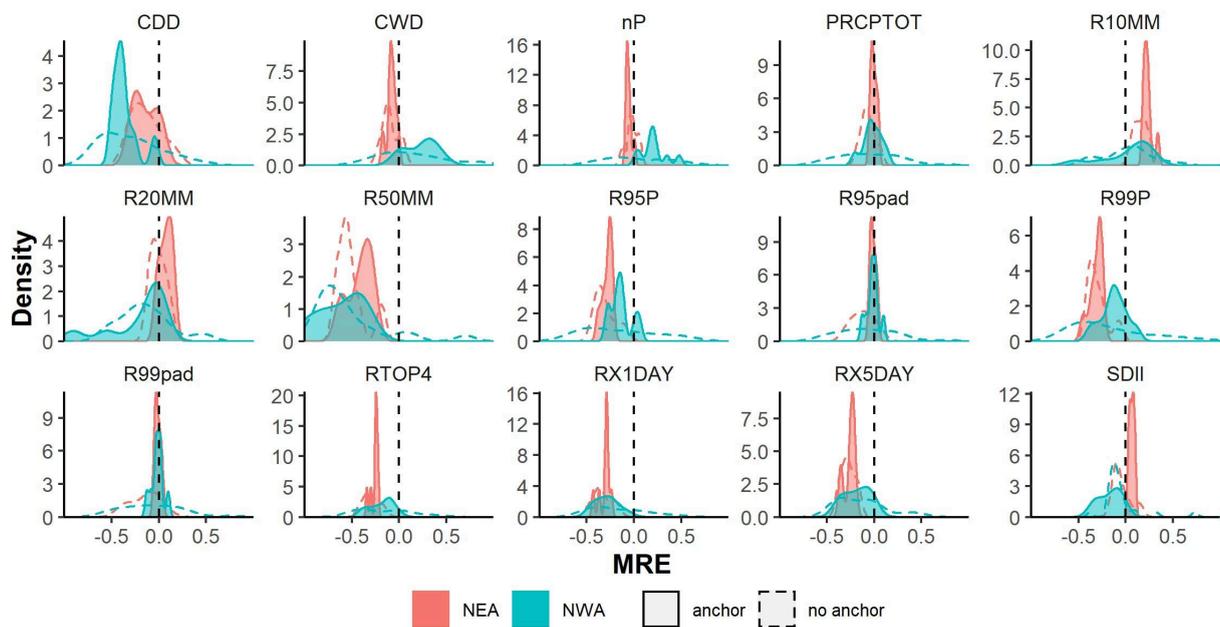


Figura 2-20: como la Figura 2-18, pero para MRE.

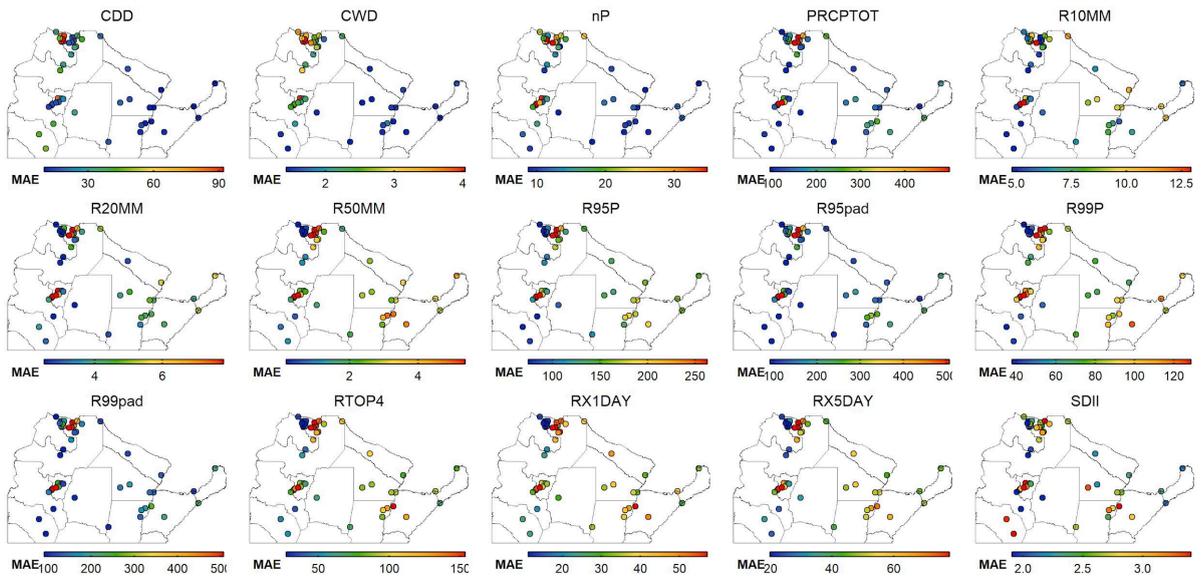


Figura 2-21: como la Figura 2-17, pero para MAE.

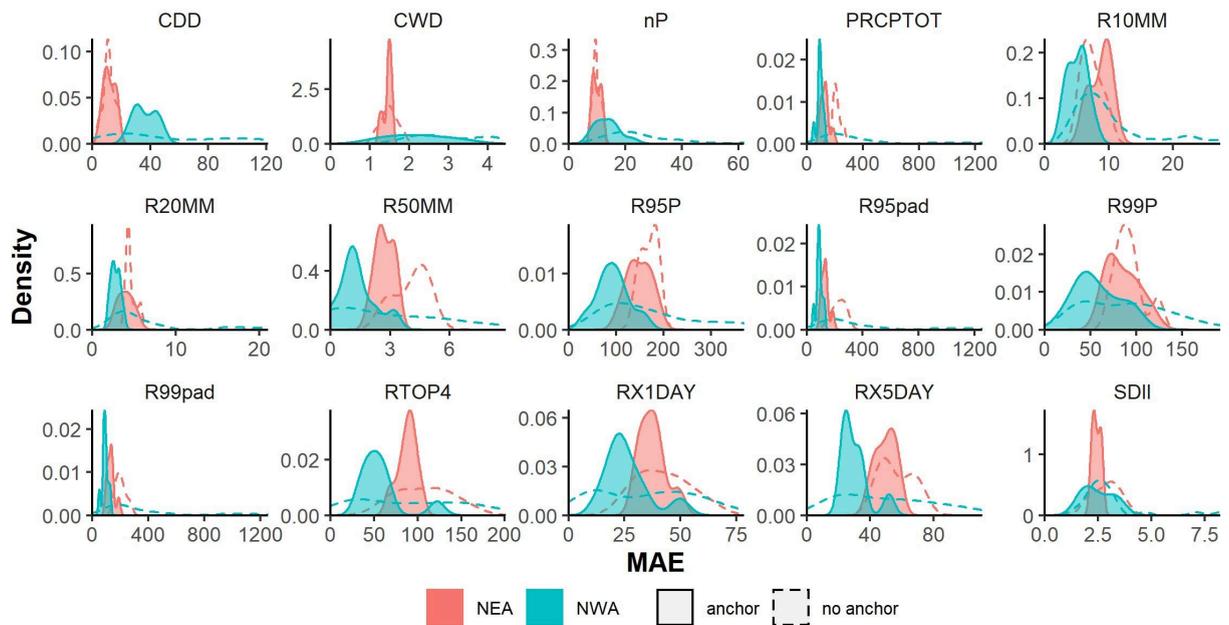


Figura 2-22: como la Figura 2-18, pero para MAE.

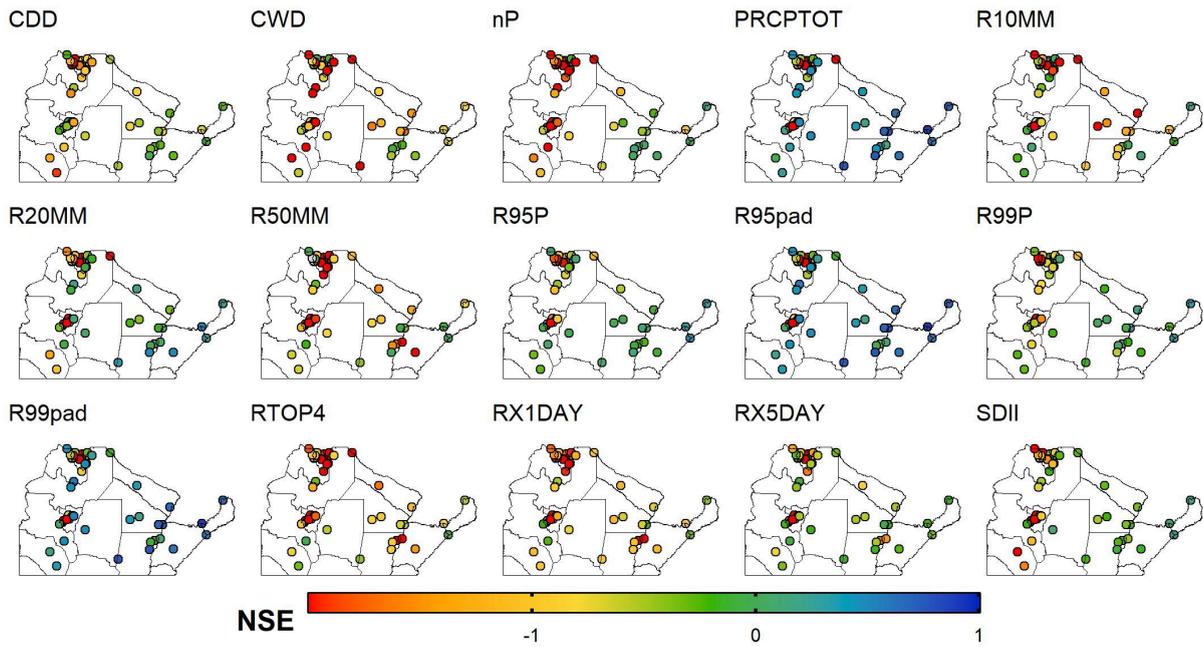


Figura 2-23: como la Figura 2-17, pero para NSE.

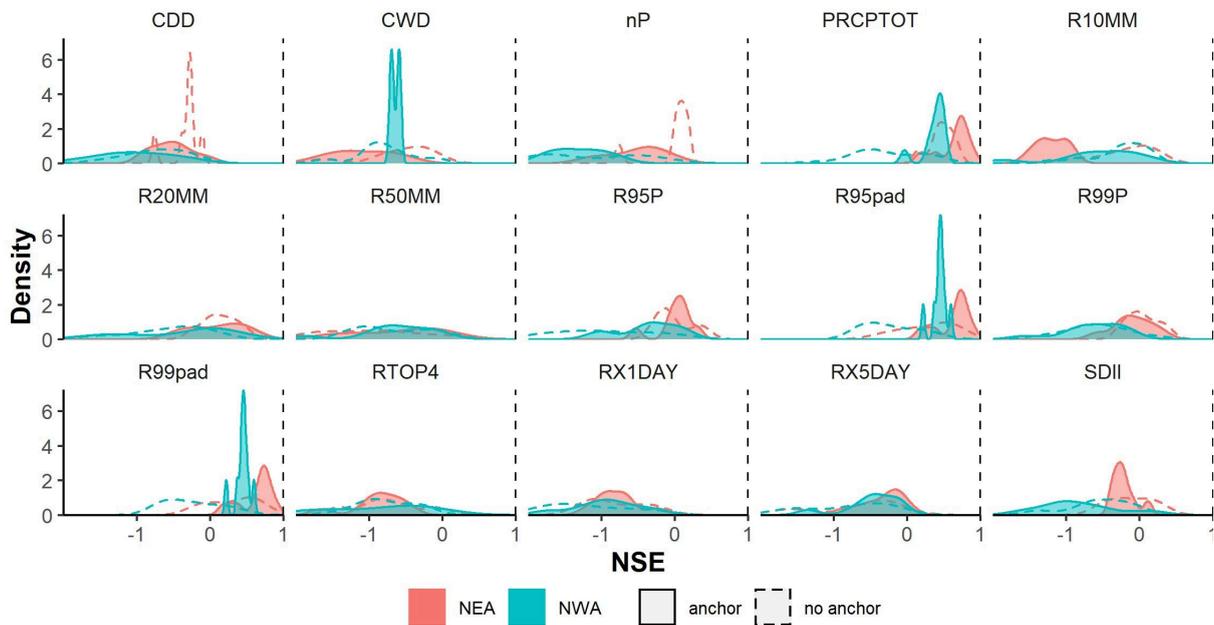


Figura 2-24: como la Figura 2-18, pero para NSE.

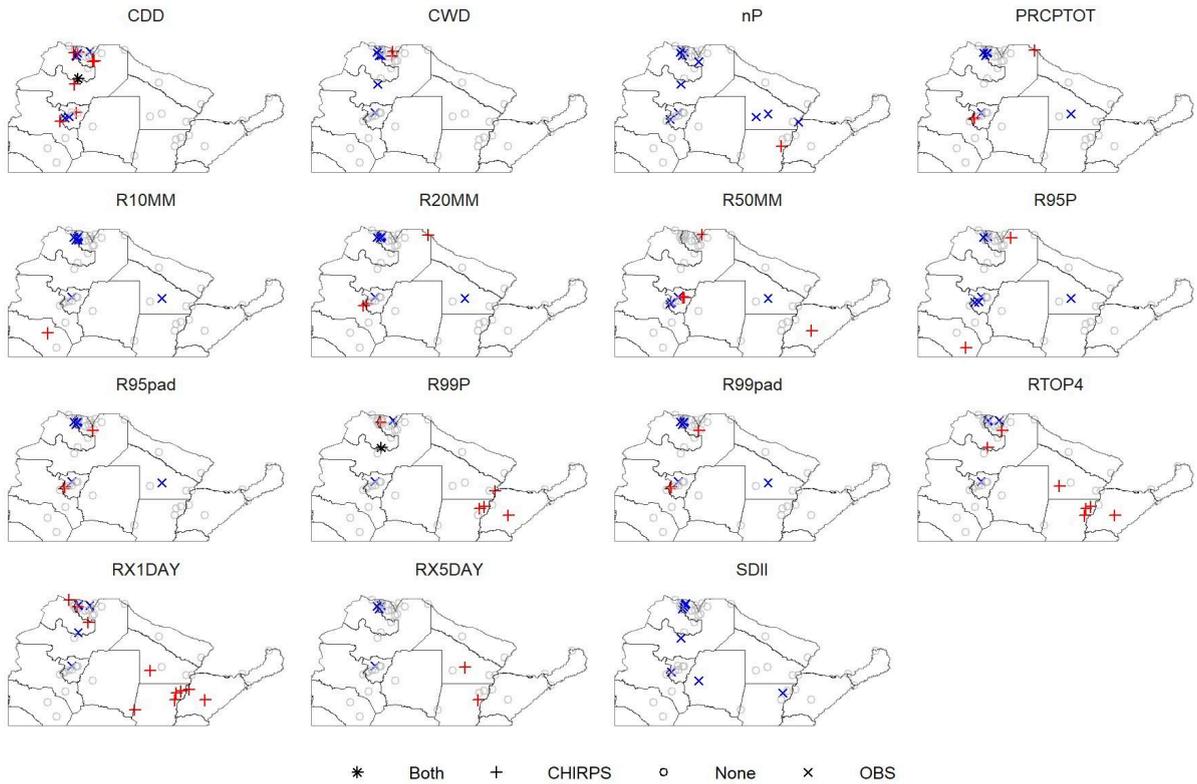


Figura 2-25: Estaciones con tendencia lineal significativa (al 95% de nivel de confianza) en los índices anuales de precipitación según OBS (“x” color azul), CHIRPS (“+” color rojo) y ambos conjuntos de datos (“*” color negro) en el periodo 1982-2019. Círculos grises indican estaciones con tendencias no significativas.

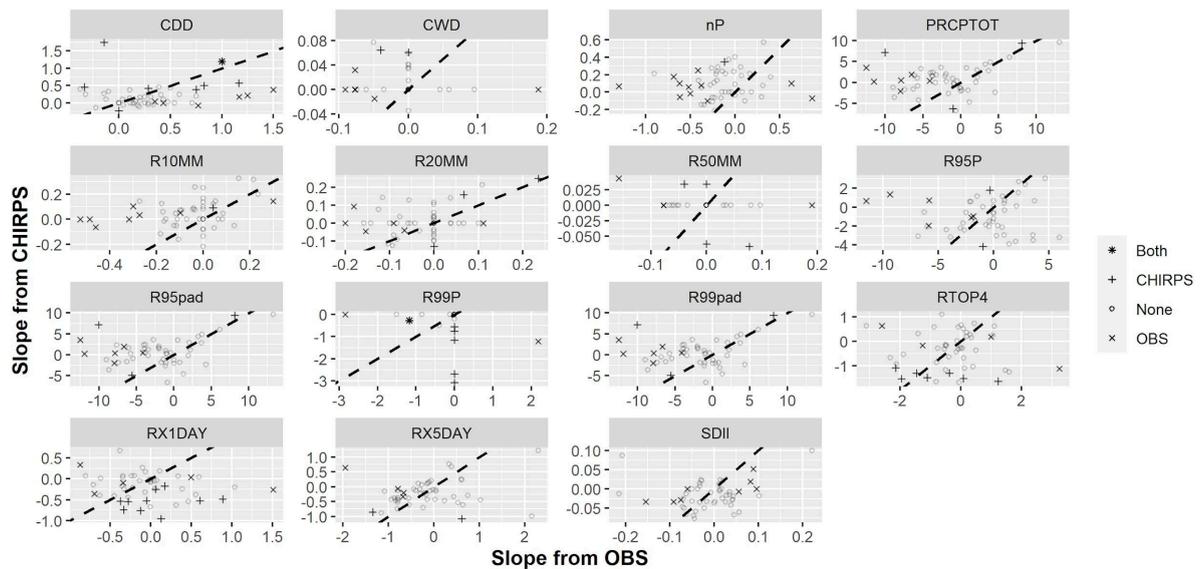


Figura 2-26: Pendiente de Sen para índices anuales de precipitación según CHIRPS (eje vertical) en función de su correspondiente valor en OBS (eje horizontal) para el periodo 1982-2019. (x) indica que la tendencia es significativa (al 95% de nivel de confianza) solamente para OBS, (+) para CHIRPS, (*) para ambos casos, (o) en ningún caso.

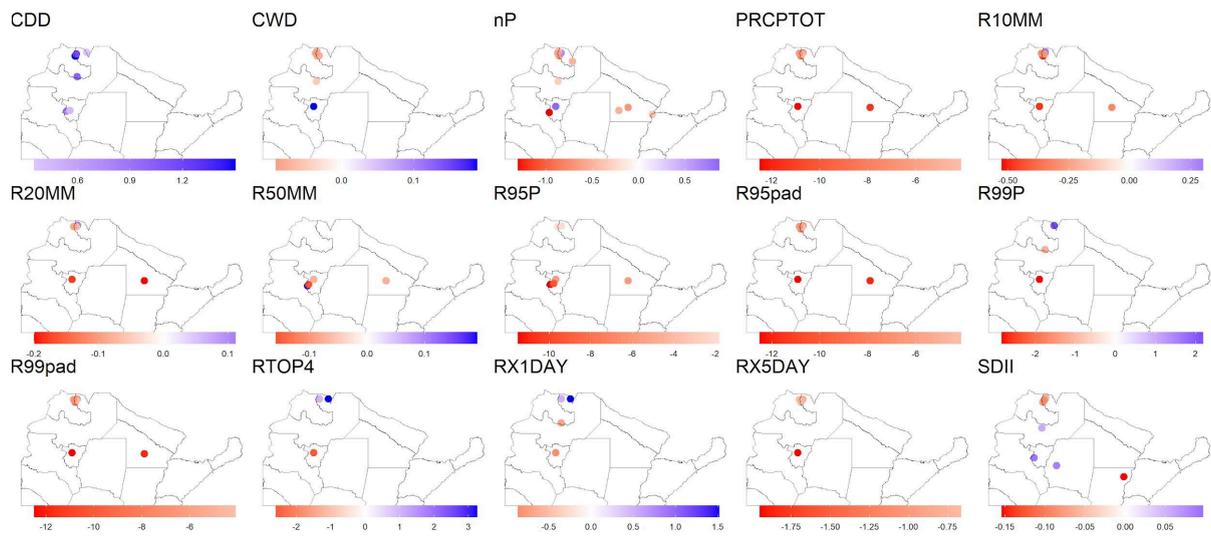


Figura 2-27: Distribución espacial de la pendiente de Sen para cada índice anual de precipitación según OBS en el período 1982-2019. Se muestran solamente los valores significativos al 95%.

Capítulo 3: Caracterización de la precipitación total y máxima diaria en San Miguel de Tucumán (Tucumán, Argentina) para el periodo 1912-2016 y análisis exploratorio de forzantes

Resumen

En este capítulo se analiza una serie centenaria de precipitación diaria correspondiente a San Miguel de Tucumán (Tucumán, Argentina), la cual cubre el periodo 1912-2016. Esta serie es la más larga del NOA, cuenta con una buena calidad de datos y es utilizada usualmente en la bibliografía como representativa de la precipitación en la región. El objetivo fue obtener una caracterización de la variabilidad temporal de la precipitación total (TOT) y máxima diaria (Rx1) en el NOA con una perspectiva de más largo plazo en comparación al análisis del capítulo anterior. Se analizó también la correlación lineal de las series con algunas variables atmosféricas relacionadas a la precipitación regional (presión a nivel del mar, viento zonal y meridional, temperatura superficial), y con algunos forzantes, tanto naturales (El Niño Oscilación del Sur -ENSO-, Modo Anular del Sur -SAM-, Oscilación Decadal del Pacífico -PDO- y Oscilación Multidecadal del Atlántico -AMO-), como antropogénicos (cambios en la concentración del CO₂ global y del O₃ estratosférico polar). Los resultados muestran que las series de TOT y Rx1 tienen una correlación no muy alta entre sí (~0,5), por lo que su variabilidad es diferente y ambas responden en parte a distintos forzantes. Se detectó un leve corrimiento del ciclo hidrológico anual en las últimas décadas, así como saltos positivos en los valores de TOT ~1956 y en Rx1 ~1977. Los parámetros de regiones oceánicas analizados (presión y temperatura superficial) muestran mayor correlación con TOT, mientras que los parámetros continentales (flujo zonal y meridional en capas bajas) adquieren importancia al estudiar Rx1. En cuanto al impacto de los modos de variabilidad global analizados, las series de precipitación y de las variables atmosféricas parecen estar moduladas por SAM y PDO, mientras SOI y AMO no muestran correlación con las series. Para el CO₂ y O₃ se obtuvieron correlaciones similares con las series de precipitación en el periodo 1912-2019 debido a la tendencia lineal general presente, mientras que en 1960-2012 la correlación para el O₃ es más elevada debido a una coincidencia entre la estabilización del mismo y de la precipitación. Además, para el caso de TOT y la presión a nivel del mar en el Atlántico tropical se encontró una cuasi-periodicidad común de ~20 años, la cual podría estar relacionada al movimiento del baricentro solar.

3.1. Datos

3.1.1. Datos diarios de precipitación

Se analiza la precipitación diaria en la Estación Experimental Agroindustrial Obispo Colombres (EEAOC), ubicada en San Miguel de Tucumán (TUC) en 26,8°S-65,2°O, provincia de Tucumán, Argentina. La EEAOC posee una estación meteorológica con registros continuos y controlados desde 1911. La estación fue manejada inicialmente por el Servicio Meteorológico Nacional y estuvo ubicada en el predio de la EEAOC hasta su reubicación en el aeropuerto de la provincia en 1981. Sin embargo, a partir de entonces la EEAOC continuó las mediciones en la primera ubicación dando continuidad al registro. Por lo tanto, la estación seleccionada, además de presentar un largo periodo, presenta la ventaja de no registrar cambios en su ubicación. Si bien existen trabajos que utilizan series más largas (Saurral et al., 2017; Ferrero y Villalba, 2019; Hurtado et al., 2020), las mismas corresponden a datos mensuales cuyos registros diarios no están disponibles (por ejemplo, La Quiaca cuenta con registros mensuales desde 1903, pero su datos diarios públicos disponibles empiezan en 1957) o son de baja calidad (por ejemplo, los registros diarios de la ciudad de Salta inician en 1930, pero tienen inhomogeneidades significativas según Hurtado et al., 2020). De esta forma, la serie seleccionada es la serie de precipitación diaria más extensa y de mejor calidad del NOA. Esta serie fue utilizada en algunos trabajos de los últimos años y pasó exitosamente el control de calidad de los datos según los autores (Penalba y Robledo, 2010; Scardilli et al. 2017; Saurral et al., 2017).

Más allá de los antecedentes mencionados, aquí también se realizó un control de calidad a los datos. Se utilizó la misma metodología de control que para las estaciones meteorológicas del Capítulo 2. Los únicos datos faltantes que presenta la serie corresponden al periodo julio-diciembre de 1943, lo cual representa solamente el 0,5% del registro completo. En cuanto a outliers (valores atípicos), no se encontraron para la lluvia total mensual, mientras solamente un valor fue detectado para la lluvia máxima diaria (3/3/1973), el cual fue confirmado como correcto mediante la comparación con una estación cercana (~ 40 km). En el caso de los días consecutivos sin lluvia, se detectaron outliers en enero de 1917 y marzo de 1933, rechazándose sólo el primer caso debido a que no pudo ser corroborado por la ausencia de estaciones cercanas en ese periodo. Sin embargo, aún con esta consideración, los datos faltantes solo representan el 0,6% del registro, por lo que no tienen impacto significativo en los resultados.

En este capítulo se analiza la serie diaria que abarca el periodo 1911-2016, a partir de la cual se calcularon la precipitación máxima diaria (Rx1) y la total (TOT) para el año hidrológico y para el verano (diciembre-enero-febrero, DJF). El año hidrológico abarca desde el 1 de julio de un año al 30 de junio del año siguiente y cada año hidrológico es numerado según el segundo año que lo conforma. Se decidió utilizar el año hidrológico, como en el Capítulo 2, debido a que los meses más lluviosos en la localidad corresponden al verano (austral), mientras en el invierno predominan las condiciones más secas. Por esta misma razón, se

decidió analizar además los meses de verano por aparte, ya que en los mismos está concentrado un gran porcentaje de la precipitación anual. En base a la consideración del año hidrológico, las series resultantes de Rx1 y TOT abarcan el periodo 1912-2016.

Las cuatro series obtenidas (TOT anual, TOT DJF, Rx1 anual y Rx1 DJF) se muestran en la Figura 3-1 a y b. Se observa que el comportamiento de las series (totales y máximos) anuales son similares a sus análogos de DJF dado el régimen monzónico de precipitación. Esto es así a pesar de la existencia de algunos valores de Rx1 anual fuera de DJF. La similitud de las curvas polinómicas ajustadas permite asumir que la precipitación de DJF constituye una buena representación de la precipitación anual, justificándose su elección para el análisis de correlación con forzantes propuesto en este capítulo.

3.1.2. Campos de variables atmosféricas

En base a los patrones medios de circulación que regulan la precipitación regional se seleccionaron campos de viento zonal en 200 hPa (U), viento meridional en 850 hPa (V), presión a nivel del mar (SLP) y temperatura a 2 m (T) en la región comprendida entre 10°N-90°S y 20-100°O (Sudamérica y alrededores). El objetivo fue determinar la relación entre la variabilidad de la precipitación y la circulación atmosférica regional. Se seleccionó U como variable representativa de la circulación en la troposfera superior, debido a que en la troposfera alta se encuentran la Alta de Bolivia y las Bajas del Atlántico Sur y Pacífico Sur con un flujo fundamentalmente zonal sobre la región (Chen et al., 1999). En cuanto a V su selección se basa en que en la troposfera inferior al este de los Andes existe un importante flujo meridional de vientos (con una velocidad de ~12 m s⁻¹ en 850 hPa a los 62°O) conocido como Jet de Niveles Bajos que transporta humedad desde el Amazonas hacia la región de estudio (Marengo et al., 2004). Los niveles de 200 hPa y 850 hPa son utilizados comúnmente en estudios climáticos, como es el caso del estudio de la circulación del Monzón Sudamericano realizada por Gan et al. (2005). Finalmente, SLP y T se seleccionaron debido a que a nivel superficial existe un patrón de altas presiones en los océanos subtropicales y una baja continental que surge como consecuencia del fuerte calentamiento continental en los meses de verano, formando lo que se conoce como el Monzón Sudamericano (Marengo et al., 2012).

Los campos fueron obtenidos del Reanálisis del siglo XX versión V2c (Twentieth Century Reanalysis V2c, 20CR V2c) (Compo et al., 2011) provisto por NOAA/OAR/ESRL PSD, Boulder, Colorado (disponibles en https://www.esrl.noaa.gov/psd/data/20thC_Rean/). 20CR V2c asimila observaciones de presión superficial y prescribe como condiciones de borde observaciones mensuales de temperatura superficial del mar y distribución de hielo marino. La versión V2c cubre el período 1851-2012 con una resolución espacial de 2,0° x 2,0° (lat x lon). Para el área del hemisferio Sur comprendida entre 20°S y 90°S el número de observaciones de presión entre 1900 y 1940 es de 50 (en promedio). Después de 1940 hay un sostenido aumento del número de observaciones disponibles, superando las 1000 desde el año 2000. A su vez, el error de las estimaciones de presión es el doble en la primera mitad del

siglo XX, respecto al error promedio después del 2000 (Compo et al., 2011), por lo que hay que tener en cuenta que los campos estimados para el inicio del siglo XX tienen mayor incertidumbre.

3.1.3. Modos de variabilidad global

Se utilizaron los siguientes índices mensuales, para el periodo 1912-2012, relacionados a modos de variabilidad global cuyo efecto sobre NA ha sido documentado en otros trabajos (Barreiro et al., 2014; Cai et al., 2020; Cavalcanti et al., 2021):

-El Niño Oscilación del Sur (ENSO, El Niño Southern Oscillation): se utilizó el Índice de Oscilación del Sur (SOI, Southern Oscillation Index) (de *Climate Research Unit*, CRU, disponible en: <https://crudata.uea.ac.uk/cru/data/soi/soi.dat>) el cual se define como la diferencia de presión normalizada entre Tahití y Darwin siguiendo la metodología de Ropelewski y Jones (1987);

-Modo Anular del Sur (Southern Annular Mode, SAM): se utilizó el índice SAM basado en datos del reanálisis 20CR V2c (de *National Oceanic and Atmospheric Administration*, NOAA, disponible en: https://psl.noaa.gov/data/20thC_Rean/timeseries/monthly/SAM/) el cual es calculado como la diferencia de presión media zonal a nivel del mar entre las latitudes de 40°S y 65°S siguiendo la metodología de Gong y Wang (1999);

-Oscilación Decadal del Pacífico (PDO, Pacific Decadal Oscillation): se utilizó el índice PDO definido como la primer componente principal de las anomalías mensuales de temperatura superficial del mar en el Océano Pacífico al norte de 20°N, y en el cual se elimina la señal de calentamiento global (de *University of Washington*, disponible a través de NOAA en: https://psl.noaa.gov/gcos_wgsp/Timeseries/Data/pdo.long.data) (Mantua et al., 1997; Zhang et al., 1997);

-Oscilación Multidecadal del Atlántico (AMO, Atlantic Multidecadal Oscillation): se utilizó el índice AMO, el cual consiste en el promedio areal de temperatura superficial del mar en el Atlántico Norte en la región comprendida entre 0°-70°N con la tendencia lineal removida (de NOAA, disponible en: <https://www.esrl.noaa.gov/psd/data/correlation/amon.us.long.data>) (Enfield et al., 2001).

3.1.4. Forzantes antropogénicos

Se analiza la serie de columna total de ozono polar (O₃) del mes de septiembre en la región comprendida entre 60°S-90°S obtenidas del 20CR V2c. Esta elección se basa en el análisis de Polvani et al. (2011), quienes mostraron que, si bien el mínimo de O₃ polar ocurre en el periodo primaveral austral, existe un retraso de dos meses para que la señal estratosférica se propague hacia la troposfera. De esta manera, el mínimo primaveral de O₃ afecta al clima de DJF más que a otras estaciones del año. Por otro lado, también se analiza la serie anual de

concentración global de dióxido de carbono (CO_2) del *Institute for Atmospheric and Climate Science* (IAC) (disponible en <https://www.co2.earth/historical-co2-datasets>) debido a que es uno de los principales gases de efecto invernadero (GHG). Ambas series se analizaron en el periodo 1912-2012.

3.2. Metodología

3.2.1. Tendencias lineales, detección de saltos climáticos y relación Rx1-TOT

Como primer paso se estimaron las tendencias lineales de las series de precipitación a través del estimador no paramétrico de Sen (Sen, 1968). La significancia estadística se evaluó con el test de Mann-Kendall de uso común en el análisis de tendencias en series de tiempo climáticas e hidrológicas (Hamed, 2008). Se utilizó el test de Pettitt (Pettitt, 1979) como método de detección de puntos de quiebre o saltos climáticos, ya sea por alteraciones en la media o en la varianza. Se analizaron el periodo 1911-2016 y el sub-periodo 1956-1994. Este último se eligió en base al salto climático de 1956 (Minetti y Vargas, 1997) y debido a que en la serie de TOT (Figura 3-1a) se observa visualmente una pendiente positiva a partir de ese año y hasta ~1994. Por otro lado, para Rx1 (Figura 3-1b) se observa también que hay una tendencia positiva desde 1956 hasta ~1994, cuando ocurre un pico superior a 160 mm. El objetivo fue evaluar la magnitud y la significancia de la pendiente en este sub-periodo en ambas series, para determinar en qué medida la tendencia en Rx1 está presente en TOT. Además, la asociación lineal Rx1-TOT fue evaluada mediante un diagrama de dispersión y el cálculo de RHO.

3.2.2. Análisis de correlación

Se realizaron mapas de correlación entre las series de precipitación de DJF y las series de V, U, P y T de DJF en la región comprendida entre 10°N-90°S y 20-100°O. La región seleccionada abarca Sudamérica y la zona Sur de los Océanos Atlántico y Pacífico. Para realizar los mapas se utilizó la aplicación Explorador Climático del KNMI (KNMI Climate Explorer: <https://climexp.knmi.nl/>), correspondiente al Real Instituto Meteorológico de los Países Bajos (*Koninklijk Nederlands Meteorologisch Instituut*, KNMI), que forma parte de la Organización Meteorológica Mundial (*World Meteorological Organization*, WMO). Esta aplicación contiene datos climáticos, incluyendo el 20CR V2c, y herramientas de análisis estadístico (temporal y espacial) generando resultados numéricos y gráficos (Van Oldenborgh et al., 2008; Trouet y Van Oldenborgh, 2013). Como en el Capítulo 2, se calcularon los valores de RHO y su significancia estadística se estimó utilizando el test t de Student.

Finalmente, se analizó la asociación de la variabilidad y tendencias a largo plazo de las series de precipitación con las series de V, U, P y T promediadas en determinadas regiones (recuadros en las Figuras 3-3a, c, e y g, respectivamente). La elección de estas regiones se

hizo en base a los mapas de RHO y a la posible conexión de las mismas con el monzón sudamericano.

Por otro lado, para evaluar la influencia de los modos de variabilidad global, se correlacionaron las series de precipitación, U, V y T con las series promedios anuales del SOI, SAM, PDO y AMO. En el caso del SOI, siguiendo la metodología de Barreiro et al. (2014), se filtró la influencia de la PDO mediante una regresión lineal. Se calculó la correlación para las series originales y para las series con un promedio móvil de 5 años para filtrar las frecuencias más altas. En tanto, se hizo lo mismo con las series de O₃ polar y CO₂ global para evaluar la influencia antropogénica. En el caso de las series con promedio móvil, el cálculo del estadístico t para estimar la significancia fue modificado teniendo en cuenta la pérdida de grados de libertad, lo cual ocurre por el proceso de promediar los años entre sí, siguiendo la metodología utilizada en Heredia et al. (2019).

En el análisis de correlación se analizaron los periodos 1912-2012 y el sub-periodo 1960-2012. La elección de este último se fundamenta en que ~1960 se observa un cambio de signo en la pendiente de la serie de O₃ y un aumento en la pendiente de la serie de CO₂. Con esto se busca evaluar la existencia de cambios en RHO cuando se analiza el periodo en que parece variar la tendencia de los forzantes antropogénicos.

3.3. Resultados

3.3.1. Tendencias lineales y saltos climáticos

La Tabla 3-1 muestra las pendientes de las series de precipitación de Tucumán y los años de posibles saltos climáticos según test de Pettit, con sus respectivas significancias estadísticas (valor p). Hay tendencias positivas significativas con nivel de confianza mayor a 99% en TOT DJF y anual, para Rx1 DJF solo al 94% y no hay tendencia significativa en Rx1 anual. Mediante el test de Pettitt, se encuentra que TOT anual muestra un salto significativo en 1956 y TOT DJF en 1957, en concordancia con el salto climático detectado por Minetti y Vargas (1997). Este salto presente en otras series de precipitación de Argentina se atribuye a un salto hacia una predominancia de fases positivas en el ENSO del Pacífico Central (uno de los tipos de ENSO, además de ENSO del Pacífico Este) alrededor de 1956 (Hurtado et al., 2020). La serie de Rx1 anual no presenta salto significativo según el test de Pettitt, mientras la serie de Rx1 DJF muestra un salto significativo sólo al 94%, posiblemente relacionado al ampliamente documentado salto climático en la PDO (Wang et al., 2017; Hurtado et al., 2020).

En la Figura 3-1, según el ajuste polinomial, se observa un sub-período (1956-1994) de tendencia positiva más marcada en TOT y Rx1, cuyos valores de pendiente se listan en la Tabla 3-1. La pendiente en dicho sub-período es significativa al 97% para Rx1 DJF y al 91% para Rx1 anual. La menor significancia estadística en Rx1 anual, comparada a Rx1 DJF, se debe a la presencia de algunos picos pronunciados en la anual que no están presentes en DJF (por ejemplo, en 1978), lo que aumenta el ruido de la serie y quita significancia a la tendencia

lineal. Respecto a esto, si bien el 72% de los valores de Rx1 anuales ocurren en DJF, existen algunos que ocurren fuera de dicho trimestre del año y, por lo tanto, hay diferencias en las series (Figura 3-1b). Por otro lado, en el caso de TOT si bien las series muestran tendencias positivas en el sub-periodo mencionado, las mismas están lejos de ser significativas (p mucho mayor a 0.1). En relación a esto último, el sub-periodo no tiene en cuenta el periodo más seco previo al salto de 1956, por lo que la ausencia de tendencia en el mismo puede ser indicativo de que la tendencia general en TOT en 1912-2016 se debe principalmente al salto climático de 1956.

En cuanto a la similitud entre las series de TOT y Rx1, en las Figuras 3-1 c y d se muestran los gráficos de dispersión de Rx1 vs TOT para las series anuales y de DJF, respectivamente. Si bien se observa una asociación lineal significativa, los valores de RHO no son tan altos, siendo 0,44 para el caso anual y 0,55 para DJF ($p < 0,01$). Estos valores de correlación indican que un valor elevado de TOT no implica un valor elevado de Rx1, y viceversa, tal como puede deducirse al observar la gran dispersión de los puntos alrededor de la recta de ajuste en las Figuras 3-1c y 3-1d. Por lo tanto, TOT no es un indicador fiable de la intensidad de la precipitación a nivel diario debido a su baja correlación con Rx1. Por otra parte, las diferencias entre las series de TOT y Rx1 indican que su variabilidad interanual y de más largo plazo podrían responder a diferentes forzantes. Esto último se ve claramente también en los años de los saltos climáticos observados, donde TOT muestra un salto en 1956-1957 (anual y DJF) y Rx1 en 1977 (solo DJF).

En cuanto al mes de ocurrencia del valor de Rx1 anual, la Figura 3-2 lo muestra para cada año hidrológico del periodo 1912-2016. Se observa que entre 1930 y 1970 hay 14 años en los cuales Rx1 anual se dio fuera del trimestre DJF. De esos 14 años, en 9 años el evento de Rx1 ocurrió en marzo, en 1 año ocurrió en abril y en los 4 años restantes los eventos de Rx1 ocurrieron en noviembre. En contraste, entre 1972 y 2012 el número de años en los que Rx1 ocurrió fuera de DJF fue 9, siendo 6 casos en marzo, 2 en abril y 1 en mayo, a la vez que no ocurrieron máximos previos a DJF. Por lo tanto, en las últimas décadas, Rx1 ocurrió entre los meses de diciembre y mayo en cada año hidrológico, a diferencia de la primera parte de la serie donde se observa que Rx1 ocurre entre noviembre y abril. Por lo tanto, se puede decir que hubo un “corrimiento” de Rx1 desde la primavera-verano hacia el verano-otoño, lo cual puede ser indicativo de un corrimiento en el ciclo hidrológico anual.

3.3.2. Asociación con variables atmosféricas

En la Figura 3-3 se muestran los mapas de RHO entre las series de precipitación de DJF y las series de V, U, P y T. Todos los valores coloreados tienen un nivel de confianza mayor a 95%. Hay correlación positiva entre V y TOT (Figura 3-3a) en la zona del Pacífico entre 40°-60°S y en el continente en la zona de la baja del Chaco, y negativa en una franja del Atlántico que llega hasta Brasil donde se ubica la Zona de Convergencia del Atlántico Sur. El mismo patrón de correlación, pero debilitado, se observa para Rx1 (Figura 3-3b). En el caso de U y TOT (Figura 3-3c) se observa correlación positiva con la zona de la Alta de Bolivia, el Atlántico

ecuatorial y la zona sur de los océanos Atlántico y Pacífico. Además, se observa correlación negativa con una zona del Pacífico entre los 35°S y 45°S. En el caso de Rx1 (Figura 3-3d), este patrón se ve casi desdibujado, excepto la correlación con las zonas sur de ambos océanos.

En el caso de P y TOT (Figura 3-3e) se observa una correlación positiva con valores de RHO entre 0,3 y 0,4 en la zona del Atlántico a la altura de Brasil, en la zona continental en Bolivia y región de Chaco y en una pequeña zona del Pacífico entre 40°-50°S. Se observa también correlación negativa con la zona Antártica. Este mismo patrón, aunque debilitado, aparece en el caso análogo con Rx1 (Figura 3-3f). En el caso de T y ambas series de precipitación (Figuras 3-3 g-h) hay correlación positiva con la temperatura en el Atlántico, hacia el Sur de 20°S, y en menor medida con la de la zona de la costa del Pacífico en el centro de Chile.

Se calcularon las series promedio en las regiones de recuadros en Figura 3-3 (como se mencionó en la sección 3) y se calculó RHO entre ellas y cada serie de precipitación. La Tabla 3-2 muestra los valores de RHO para las series originales y para las series filtradas con un promedio móvil de 5 años para los periodos 1912-2012 y 1960-2012. En dicha tabla se indican las variables correspondientes y la región a la que pertenecen: U (Alta de Bolivia), V (jet de niveles bajos), P y T (ambas del Atlántico Subtropical). Las Figuras 3-4 y 3-5 muestran TOT y Rx1 DJF, respectivamente, junto a las series con que mejor se correlacionan (P y T para la primera, U y T para la segunda). Todas las variables, excepto P, parecen presentar una tendencia lineal más monótona en el período completo (Figuras 3-4 y 3-5). Se observa que la correlación entre los valores de precipitación y de las otras variables es positiva en todos los casos. En el caso de V, el mismo tiene valores negativos en la región considerada por tener sentido hacia el sur (el sentido positivo es hacia el norte por convención). Así, la correlación positiva entre V y la precipitación indica que en periodos en que el viento meridional V fue de menor intensidad (menos negativo), la precipitación fue mayor. Esto descarta la posibilidad de que el comportamiento a largo plazo en la precipitación se explique por un aumento de la intensidad del jet de capas bajas, a diferencia de lo que ocurre en las llanuras del este de Argentina en los denominamos “eventos de jet de niveles bajos” (Nicolini et al., 2002). En los demás casos (U, P y T), la correlación positiva obtenida sugiere que el incremento en la precipitación estaría vinculado al Alta de Bolivia (un aumento de U) y a variabilidad en el Atlántico (aumento de P y T).

La correlación de TOT con P es alta y significativa en 1912-2012 y 1960-2012. A partir de ~1960 ambas series evidencian una periodicidad casi en fase del orden de ~20 años (Figura 3-4). Esta periodicidad corresponde a un patrón de variabilidad océano-continente denominado Oscilación Subtropical (OST) por Minetti y Leiva (2005) con impacto en el inicio de la estación lluviosa (noviembre-diciembre). Ellos postulan que en los meses posteriores (enero-febrero-marzo) la precipitación es principalmente afectada por factores continentales regionales y no tanto por la OST. Por otra parte, esta periodicidad hallada podría estar relacionada con la periodicidad en el movimiento del baricentro solar (Cionco y Pavlov, 2018), ya analizada en conexión con la precipitación total de Tucumán por Heredia et al. (2019). El baricentro afectaría la radiación solar, que a su vez tendría impacto en el clima mediante mecanismos dinámicos objeto de gran discusión y controversia que no son objeto

de este estudio. Heredia et al. (2019) argumentan la posibilidad de que este ciclo de ~20 años afecta más a las características de la superficie del mar que al continente, de manera que sería esperable esta oscilación en P (Figura 3-4), la cual corresponde al Océano Atlántico, y no a otras variables como U y V. Sin embargo, la variable T también corresponde al promedio de un área íntegramente en el Atlántico, pero no evidencia esta ciclicidad. En relación a esto, Heredia et al. (2019), quienes analizan T de Tucumán (es decir continental), encuentran una baja correlación lineal con parámetros del baricentro solar del orden $\sim 0,1$. La serie de T muestra una predominancia de una tendencia lineal (Figura 3-4) cuyo origen no está relacionado al baricentro solar, por lo que el efecto del baricentro podría quedar enmascarado por otro forzante que genera dicha tendencia.

Los valores de RHO de Rx1 vs U, V y T se mantienen similares en los dos periodos analizados (Tabla 3-2). Con P la correlación es variable según el período, y pierde significancia en 1960-2012 por la ausencia de la variación bidecadal en Rx1. Como se puede observar en la Figura 3-5 el comportamiento a largo plazo de Rx1 en Tucumán fue similar al comportamiento de las series de T y U. Sin embargo, se encuentran ciertos desfases en las variaciones de menor amplitud. Ambos resultados estarían de acuerdo con la hipótesis de que una intensificación de la Alta de Bolivia y mayores temperaturas en el océano Atlántico estarían asociadas con más lluvia en la región. Por otra parte, se debe tener en cuenta que un análisis estadístico, sin el acompañamiento del estudio físico que explique una asociación o causa-consecuencia, no permite discriminar si las variaciones similares observadas corresponden a una relación física real existente entre las variables o si son consecuencia simplemente de una fuente externa común a ambas variables.

Las variables U, V, P y T no son todas independientes entre sí. La correlación entre U y V es de $\sim 0,7$, tal como se esperaría, ya que las áreas promediadas corresponden a un mismo sistema integrado por la Alta de Bolivia, la Baja del Chaco y el jet de niveles bajos. Por otra parte, la correlación de P con U, V y T es baja ($r < 0,5$ en todos los casos) y no significativa estadísticamente, por lo que P sería independiente de ellas. Físicamente podría pensarse que P evidenció cambios relacionados a la expansión de la Celda de Hadley (Lucas et al., 2014), los cuales en U y V podrían ser menores comparados con aquellos cambios que surgen de otros factores, tales como los relacionados a procesos continentales. En relación a esto último, Vera et al. (2019) analizan la relación entre U en la región 15°S - 20°S y la expansión de la Celda de Hadley global, y encuentran que no hay correlación estadísticamente significativa, postulando que la circulación podría ser influenciada por otros mecanismos independientes de la expansión tropical, tales como los relacionados al Monzón Sudamericano. La baja correlación de P con U, V y T se debe a que P presenta una cuasi-periodicidad de ~20 años, la cual está ausente (o es muy débil) en las otras variables.

3.3.3. Asociación con los modos de variabilidad global

La Figura 3-6a muestra las series de PDO, AMO, SAM y SOI. No hay correlaciones significativas para la precipitación con AMO y SOI (Tablas 3-3 y 3-4). Para las series

originales (es decir, sin promedio móvil) se encontraron correlaciones significativas al 95% en el periodo 1912-2012 entre SAM-Rx1 y SAM-TOT (Tabla 3-3), aunque los valores son bajos ($< 0,25$). También se observan correlaciones con valores bajos, significativas al 90%, para PDO-Rx1 y PDO-TOT en 1960-2012. Para los otros modos de variabilidad no se encontraron correlaciones estadísticamente significativas. Por otra parte, para las series con promedio móvil de 5 años (Tabla 3-4) se encontraron correlaciones significativas para SAM-TOT y SAM-Rx1 en el periodo 1911-2012 con 95% de significancia y en el periodo 1960-2012 con 90% de significancia. También se encontró correlación significativa para PDO-Rx1 y PDO-TOT con 90% de significancia en 1960-2012. En la Figura 3-6 se muestran las series con promedio móvil de 5 años para TOT, PDO y SAM (6b) y para Rx1, PDO y SAM (6c), que son las series que mejor se correlacionan entre sí. Se observa que después de ~1950 las series de precipitación siguen a la serie de PDO en las variaciones de mayor magnitud (por ejemplo, en el rápido incremento entre 1975 y 1980, Figuras 6b y 6c) dando la apariencia de una modulación de la precipitación por parte de PDO. Sin embargo, hay variaciones de menor amplitud que no son compartidas y también algunos desfases entre las series indicando la presencia de otros forzantes de la variabilidad además de PDO. En el caso de SAM, la correlación parece estar explicada por una co-variabilidad de baja frecuencia con las series de precipitación, consistente en valores más bajos en las series antes de la década de 1980 y valores más altos posterior a ella, y también con algunos picos importantes en ambas series ocurriendo alrededor de 1960, 1980 y 2000.

En cuanto a SOI, su coeficiente de correlación con las series de precipitación no supera el valor 0,20 y no es significativo en los dos periodos considerados. Esto coincide con el resultado del análisis de Minetti y Leiva (2005), quienes muestran que el ENSO tiene débiles efectos en el NOA. En el largo plazo, en la variabilidad de las series interanuales con y sin promedio móvil de 5 años, ENSO no muestra influencia significativa en los periodos analizados, por lo que el rol del Pacífico podría estar relacionado a PDO. Sin embargo, el efecto del ENSO parece estar presente en el salto de 1956 y 1957 detectados en las series de TOT anual y TOT DJF, salto analizado por Hurtado et al. (2020), y también puede ocurrir que exista relación en subperiodos no considerados aquí (ver Capítulo 4).

En relación a la PDO, Barreiro et al. (2014) mostraron que la combinación de un Océano Pacífico ecuatorial con anomalías cálidas y un Océano Atlántico ecuatorial con anomalías frías (relacionado con AMO) estuvo asociada al marcado incremento en las precipitaciones en el NA en la década de 1970. La transición de la temperatura del Atlántico alrededor de la década del '70 favoreció el incremento de la precipitación y a partir de la década del '80 el cambio de fase de la PDO ayudó a mantener las anomalías positivas de lluvias a partir de entonces. El mecanismo físico propuesto en su trabajo consiste en un aumento del flujo de humedad del Atlántico al Amazonas inducido por un Pacífico ecuatorial más cálido y un Atlántico ecuatorial más frío. Este flujo de humedad es desviado debido a los Andes, y en combinación con un anticiclón en niveles altos centrado en $40^{\circ}\text{S} - 40^{\circ}\text{O}$ favorece la convergencia de humedad en el NA. La combinación de un índice AMO negativo con la PDO positiva se da antes de ~1920 y posterior a ~1970, coincidiendo con los mayores valores de precipitación. Esta combinación podría favorecer un Pacífico ecuatorial más cálido y un

Atlántico ecuatorial más frío. A su vez, esto podría explicar que el coeficiente de correlación entre la precipitación y PDO sea significativo en la segunda mitad del siglo XX y no en el periodo 1911-2012. Así, el argumento de Barreiro et al. (2014) sobre la influencia del Atlántico-Pacífico explicaría parte del comportamiento de la precipitación en Tucumán. El salto de la precipitación total en 1956 no sería explicable con este mecanismo. Los resultados de este trabajo muestran que desde mediados del siglo XX la precipitación presenta a grandes rasgos variaciones similares a la PDO, aunque previo a esto las series prácticamente no muestran co-variabilidad.

En relación a SAM, sus diferentes fases afectan la distribución de presión entre latitudes medias y altas y afecta el pasaje de frentes fríos en latitudes más bajas (Thompson y Wallace, 2000; Fogt y Marshall, 2020). Por lo tanto, los efectos de SAM en la precipitación son esperables en cuanto el mismo afecta los patrones de circulación. En el análisis realizado en este capítulo se encontró que SAM es el modo de variabilidad global, entre los analizados, que mejor se correlaciona con las series de precipitación. Los mecanismos físicos que explican la relación entre SAM y la precipitación son explorados en profundidad en el capítulo 4.

Análogamente a la precipitación, se calculó la correlación de PDO, AMO, SOI y SAM con las variables U, V, P y T, para las series originales (Tabla 3-3) y las series con un promedio móvil de 5 años (Tabla 3-4). Para las series originales se obtuvieron correlaciones significativas para SAM con P, T y V en 1911-2012, y con P y T en 1960-2012, con valores de 0,30 a 0,44. En el caso de AMO, no hay correlaciones significativas en ningún caso. Para SOI se observan correlaciones significativas con P y U en ambos periodos, con valores entre -0,32 y -0,48. En tanto para PDO, las correlaciones significativas se observan para P en ambos periodos y para U en 1960-2012, aunque en todos los casos los valores son bajos ($< 0,28$). Por otra parte, para las series con promedio móvil se observa que para 1911-2012 SAM muestra correlación significativa con todas las variables (P, T, U y V), con el valor más bajo correspondiente a U (0,41) y el más alto a T (0,67). Sin embargo, las correlaciones dejan de ser significativas cuando se analiza el periodo 1960-2012, excepto para T que se mantiene en un valor alto (0,79) y significativo al 95%. Como se mencionó, SAM afecta la circulación, por lo que su relación a las variables P, U y V es esperable, mientras en el caso de T el mismo podría también verse afectado por esos cambios de circulación, aunque el análisis en profundidad de esto escapa a los objetivos de este capítulo. En el caso de PDO, tiene correlación significativa solo con U (0,68) y V (0,61) en el periodo 1960-2012. De esta manera, la influencia de la PDO en la circulación podría ser en el viento zonal y meridional de la zona continental, aunque con importancia sólo desde la segunda mitad del siglo XX. Esto podría estar relacionado a los cambios en la circulación inducidos por la PDO, tales como el anticiclón en niveles altos centrado en 40°S 40°O mencionado en el trabajo de Barreiro et al. (2014), que favorecen la convergencia de humedad en el NA y afectan a la precipitación. En la Figura 3-6d se observa claramente una importante co-variabilidad entre U y PDO desde mediados del siglo XX, lo cual explica el alto valor de correlación. Para el caso de V y PDO se observa una co-variabilidad muy similar al caso anterior (no se muestra), lo cual es esperable debido al valor similar de correlación obtenido.

3.3.4. Asociación con las concentraciones de CO₂ global y O₃ polar

Las Figuras 3-7 y 3-8 muestran las series estandarizadas de CO₂ global y O₃ polar junto con TOT y Rx1, respectivamente. La correlación lineal del CO₂ y O₃ polar con TOT, Rx1, U, V, P y T se listan en las Tablas 3-3 y 3-4 para las series originales y con promedio móvil de 5 años, respectivamente.

El CO₂ presenta una variación monótona creciente, casi lineal, que es también la tendencia general de todas las variables analizadas, excepto al final de la serie, donde las variables se estabilizan o disminuyen sus valores. Esto hace que haya una correlación significativa en casi todos los casos en el periodo 1911-2012. En el caso del O₃, donde se observa una correlación negativa, los valores son altos porque el O₃ presenta un cambio de tendencia general ~1960 que coincide con el cambio de tendencia en las series de precipitación y con la estabilización en los últimos años de las mismas. Los valores de correlación obtenidos para TOT y Rx1 con O₃ y CO₂ no difieren demasiado, por lo que no puede asegurarse que haya un peso mayor de un forzante por sobre otro.

Si analizamos sólo el sub-periodo 1960-2012, la correlación de las series es más alta con el O₃ que con el CO₂ en todos los casos. Esto es debido a que, como se mencionó, además de tener una importante tendencia lineal, la serie de O₃ al final se estabiliza y esto coincide con tendencia menos marcada o casi nula en las series de precipitación. Las notables cuasi-periodicidades interdecadales de las series de P, de U y de V hace que la correlación en estos casos sea menor, ya que son oscilaciones totalmente ausentes en el CO₂ y débiles en el O₃. En cambio, en T predomina tendencia monótona, lo que provoca como resultado una alta correlación (mayor a 0,8) con las series de CO₂ y O₃; esto concuerda con el aumento de temperatura global de origen antropogénico.

3.3.5. Cuasi-periodicidad de ~20 años en TOT y P

Para evaluar estadísticamente la cuasi-periodicidad mencionada, se calculó la transformada de wavelet (TW), la coherencia de wavelet (CW) y el espectro cruzado de wavelet (ECW) entre P y TOT (ambas sin promedio móvil). TW, a diferencia del espectro de Fourier, es una técnica capaz de detectar periodicidades variables en el tiempo. CW mide las oscilaciones comunes en ambas series y ECW mide la correlación entre estas oscilaciones, ambos en términos de frecuencia. Se siguió el mismo procedimiento de Heredia et al. (2019), utilizando el algoritmo desarrollado por Torrence y Compo (1998) y el software desarrollado por Aslak Grinsted (disponible en <http://www.glaciology.net/wavelet-coherence/>) (Grinsted et al., 2004). Se observa una clara periodicidad común y en fase de ~20 años a partir de ~1960 (Figura 3-9b) con una correlación mayor a 0,8 (Figura 3-9a) y 95% de nivel de confianza. Por lo tanto, TOT muestra variaciones periódicas de ~20 años presentes en P, y el forzante detrás de estos cambios podría responder a la dinámica del movimiento del baricentro solar, aunque

el mecanismo subyacente que sustentaría el buen acuerdo estadístico hallado escapa al objetivo de este trabajo.

3.4. Discusión final y conclusiones

Las diferencias entre las series de TOT y Rx1, cuya correlación no es muy alta ($\sim 0,5$), indican que su variabilidad interanual y de más largo plazo responden a diferentes forzantes. Esto se ve claramente en los años de los saltos climáticos observados, donde TOT muestra un salto significativo en 1956-1957 (anual y DJF) y Rx1 en 1977 (solo DJF). Por otra parte, las series de TOT anual y de DJF tienen una tendencia lineal positiva y significativa en el periodo completo, mientras que Rx1 no muestra esto. Por lo tanto, TOT no es un indicador fiable de la intensidad de la precipitación a nivel diario, y por ende, la variabilidad de ambas métricas de la precipitación debe ser estudiada por separado.

La serie de TOT DJF con promedio móvil presenta correlaciones altas ($> 0,70$) y significativas en el período 1911-2012 con U, V, P y T, siendo el mayor valor el correspondiente a T (0,76). Para el sub-período 1960-2012 la correlación con P casi no cambia ($r = 0,72$) y con T disminuye ($r = 0,44$), en tanto pierden la significancia estadística para U y V. En la Figura 3 se ve claramente que en el sub-período, si bien TOT tiene una tendencia lineal similar a la de T, es más importante la cuasi-periodicidad de ~ 20 años que tiene en común con P, por lo que la correlación con esta última es más elevada con P. La cuasi-periodicidad podría estar relacionada al movimiento del baricentro solar.

En cuanto a la buena correlación obtenida entre TOT y T, la misma es fuertemente dependiente del periodo analizado, como se observa en los coeficientes de correlación presentados anteriormente. La buena correlación podría deberse a que ambas presentan tendencia lineal positiva y no a que haya una conexión física real. La tendencia lineal en T desde la segunda mitad del siglo XX es muy similar a la tendencia de CO_2 y posiblemente debida al calentamiento global de las últimas décadas. En el caso de Rx1 DJF, la mayor correlación se observa con las series de T, U y V, con valores similares (de 0,5 a 0,6) tanto el periodo completo como en el sub-periodo. Lo expuesto anteriormente está de acuerdo con el efecto de las condiciones del Atlántico (T) sobre la precipitación en el NOA y también con el del sistema cuasi-monzónico (U, V) en la región NA, Bolivia y Brasil. Como conclusión general sobre las variables atmosféricas, los parámetros de regiones oceánicas analizados (P y T) muestran mayor correlación con TOT, mientras que los parámetros continentales (U y V) adquieren importancia al estudiar Rx1.

En cuanto al impacto de los modos de variabilidad global analizados, las series de precipitación y de las variables atmosféricas parecen estar moduladas por SAM y PDO, mientras SOI y AMO no muestran correlación con las series. Comparando los resultados de este capítulo con los de Hurtado et al. (2020), el ENSO (representado aquí por SOI) está vinculado al salto climático observado en TOT anual en 1956 y TOT DJF en 1957, pero no muestra efecto en la variabilidad de más corto plazo, al menos cuando se correlacionan los periodos completos 1911-2012 y 1960-2012. En el análisis realizado en este capítulo se encontró que SAM es el modo de variabilidad global, entre los analizados, que mejor se

correlaciona con las series de precipitación y las variables atmosféricas. En el caso de la PDO, además de los efectos en la precipitación, también se observa una covariabilidad con las series de U y V, aunque en menor medida que en el caso de SAM. Principalmente el acoplamiento entre las series y PDO se observa desde la segunda mitad del siglo XX, lo cual podría estar relacionado con la transición en AMO desde la década del 70, en una forma en que una fase positiva de PDO en conjunción con una negativa en AMO generan cambios de circulación que favorecen el aumento de precipitación en el NA (Barreiro et al., 2014). Teniendo en cuenta estos resultados obtenidos, los mecanismos físicos que explican la relación entre SAM, la precipitación y los campos atmosféricos son explorados en profundidad en el capítulo 4, analizando además el rol de la PDO y AMO en estas relaciones. Además, en el capítulo 4 se profundiza también en la relación con el ENSO, en vista de que el mismo si bien no muestra correlación significativa con las series de precipitación, hay evidencia de que influyó en el salto climático de 1956.

Otro resultado de este capítulo, es la detección de un leve corrimiento en los meses en que suele ocurrir el Rx1 anual, lo podría ser indicador de un corrimiento en el ciclo anual de lluvias. Esto podría estar relacionado al aumento de la duración del monzón sudamericano observado, documentado por Carvalho et al. (2011), quienes lo asocian a la transición climática de la década del 70 relacionada a la PDO. Así, PDO y AMO tendrían un rol importante sobre la precipitación en la región.

Respecto a la buena correlación con el CO₂, esto es esperable considerando que el aumento de GHG provocaría un aumento de las precipitaciones debido a la intensificación del ciclo hidrológico (Meehl et al., 2007). En este sentido, Vera y Díaz (2015) encontraron que los modelos que consideran el aumento de GHG como único forzante son capaces de reproducir sólo parcialmente las tendencias en la región. Los resultados estadísticos de este capítulo sugieren que otros forzantes como el O₃ y el movimiento del baricentro solar podrían también impactar en el comportamiento a largo plazo de la precipitación, aunque un análisis más exhaustivo es necesario para determinar esto. Específicamente respecto al O₃, las correlaciones negativas encontradas estarían de acuerdo con los resultados de Kang et al. (2011) y Gonzalez et al. (2014) quienes señalan que una disminución de ozono polar induce un aumento en la precipitación en diversas regiones de Sudamérica. Precisamente, Cai y Cowen (2007) remarcaron la importancia de contar con modelos que cuantifiquen la contribución del O₃, debido a que se proyecta que el O₃ estará completamente recuperado hacia el 2050, y su impacto en el clima del hemisferio sur sería opuesto al del incremento del CO₂. El peso relativo del CO₂ y el O₃ sobre las tendencias en la precipitación en el sudeste de Sudamérica no está del todo claro aún (Varuolo-Clarke et al., 2021), aunque se sugiere que este último tiene un impacto secundario (Mindlin et al., 2021). Los resultados estadísticos de este capítulo no son concluyentes al respecto, debido a que las correlaciones obtenidas para la precipitación con CO₂ y O₃ son similares en el período más largo (1912-2012).

Retornando a las variables de circulación, como un agregado, en la Figura 3-10 se muestran las series estandarizadas de U, V y velocidad vertical en 500 hPa (indicador de circulación vertical en la troposfera media) en la región en la que se analizó U, según el reanálisis 20 CR V2c. Se observa un buen acuerdo entre dichas series, con valores de correlación con la

velocidad vertical de 0,6 con U y 0,7 con V (sin suavizado). Estas correlaciones elevadas y positivas confirman que los aumentos en los valores de U están asociados a un aumento en la actividad convectiva en esta región perteneciente al Alta de Bolivia, y a su vez, a una disminución en el flujo meridional de vientos en capas bajas (V) en el NA. Así, la variabilidad de Rx1, que presenta buena correlación con U y V, no estaría asociada a cambios en la advección meridional de vapor mediante el jet de niveles bajos (el valor absoluto de V disminuyó), sino más bien a las variaciones en la convección regional. En relación a esto último, un aumento de la convección en la parte subtropical de Sudamérica en la segunda mitad del siglo XX fue reportado por Saurral et al. (2017), en concordancia con el presente análisis que muestra un aumento en los valores de velocidad vertical (Figura 3-10). A su vez este aumento en la actividad convectiva está en acuerdo con el aumento en la misma esperado por el aumento de la temperatura global, y que aquí se observa con una alta correlación entre U y el CO₂. En este sentido, Chen et al. (2020) encuentran un aumento generalizado a nivel global en el valor medio de la energía potencial convectiva disponible (CAPE, Convective Available Potential Energy) en DJF como consecuencia del calentamiento global generado por el aumento del CO₂. En el centro y NA el mayor aumento del CAPE se observaría en el NOA. Ellos postulan que el aumento del CAPE incrementa la probabilidad de ocurrencia de eventos de convección profunda, de tal manera que en nuestra región podríamos esperar un aumento en Rx1 ante el aumento de CO₂.

Es importante destacar que TOT y Rx1 tienen gran variabilidad interanual e interdecadal. En particular la variación bidecadal en TOT a partir de ~1960 y en P en el período completo parece vinculada a la posición del baricentro solar. Hay otras variaciones también en TOT, Rx1, U, y V que podrían estar relacionadas a la PDO y AMO. Si bien se detectaron correlaciones altas con las variables mencionadas, se necesita un “sustento físico” para el análisis estadístico, en especial en relación a la influencia del baricentro. Por otra parte, se debería evaluar el efecto (refuerzo o atenuación) que los forzantes antropogénicos podrían tener en PDO y AMO considerando que estas oscilaciones parecen tener fuerte influencia en la precipitación. La profundización en el estudio de los mecanismos subyacentes podría ser clave para mejores proyecciones de la precipitación a largo plazo en escala local y regional. En el siguiente capítulo, en base a este análisis exploratorio, se profundiza en el análisis de las relaciones entre Rx1, las variables de circulación y los modos de variabilidad global.

Figuras y tablas (Cap. 3)

Tabla 3-1: Pendiente de Sen (s) y su significancia (p) de acuerdo al test de Mann-Kendall para las series de TOT y Rx1, para el período 1912-2016 y sub-período 1956-1994. Año del salto climático según test de Pettit (A) y su significancia (p) para el periodo 1912-2016. Se remarcan en negrita todos los valores con nivel de confianza mayor al 95% ($p < 0,05$).

Serie de precipitación	1912-2016		1956-1994		1912-2016	
	s (mm/año)	p	s (mm/año)	p	A	p
Rx1 anual	0,11	0,22	0,62	0,09	1957	0,18
Rx1 DJF	0,15	0,08	0,85	0,03	1977	0,06
TOT anual	2,66	< 0,001	1,34	0,70	1956	<0,001
TOT DJF	1,61	0,001	3,34	0,26	1957	<0,001

Tabla 3-2: Coeficientes de correlación (RHO) entre las series de precipitación y las variables troposféricas U, V, P y T, para los periodos 1912-2012 y 1960-2012. El valor superior en cada celda corresponde a las series originales (1 valor por año) y el inferior a las series que previamente fueron filtradas con un promedio móvil de 5 años. En negrita se marcan los coeficientes significativos al 95% según el test t de Student.

Variable / Período	Variable / Región promediada			
	U (200 hPa) / 15-25°S, 60-90°O	V (850 hPa) / 15-25°S, 50-70°O	P / 10-30°S, 0-20°O	T / 20-50°S, 30-50°O
TOT DJF / 1911-2012	0,23 0,71	0,25 0,70	0,35 0,70	0,46 0,76
TOT DJF / 1960-2012	0,01 0,22	0,01 0,17	0,29 0,72	0,36 0,44
Rx1 DJF / 1911-2012	0,08 0,57	0,12 0,58	0,20 0,39	0,38 0,59
Rx1 DJF / 1960-2012	-0,01 0,50	-0,02 0,55	0,15 0,30	0,39 0,57

Tabla 3-3: Coeficientes de correlación lineal (RHO) de las series de PDO, AMO y SOI promedio de DJF, CO₂ global anual y O₃ polar promedio (entre 60 y 90°S) de septiembre con las series de precipitación de Tucumán y las variables U, V, P y T de DJF. En negrita se marcan los coeficientes significativos al 95% según el test t de Student, mientras los valores subrayados corresponden a aquellos significativos al 90%.

	PDO		AMO		SOI		SAM		CO ₂		O ₃	
	1912-2012	1960-2012	1912-2012	1960-2012	1912-2012	1960-2012	1912-2012	1960-2012	1912-2012	1960-2012	1912-2012	1960-2012
P	0,23	0,24	-0,11	0,01	-0,32	-0,45	0,33	0,28	0,21	0,07	-0,13	-0,10
T	0,05	0,12	0,04	0,21	-0,08	0,14	0,44	0,44	0,77	0,58	-0,47	-0,42
U	0,13	<u>0,28</u>	-0,04	-0,02	-0,43	-0,48	0,08	-0,14	0,47	0,07	-0,27	-0,10
V	-0,03	0,04	-0,05	0,01	-0,11	-0,08	0,30	0,07	0,59	0,03	-0,35	-0,06
Rx1	0,15	<u>0,24</u>	-0,13	0,09	-0,03	0,04	0,24	<u>0,29</u>	0,26	0,19	-0,29	<u>-0,26</u>
TOT	0,15	<u>0,25</u>	-0,08	0,07	-0,09	-0,02	0,23	0,16	0,34	0,13	-0,22	-0,15

Tabla 3-4: Como la Tabla 3-3 pero para las series filtradas previamente con un promedio móvil de 5 años.

	PDO		AMO		SOI		SAM		CO ₂		O ₃	
	1911-2012	1960-2012	1911-2012	1960-2012	1911-2012	1960-2012	1911-2012	1960-2012	1911-2012	1960-2012	1911-2012	1960-2012
P	0,24	0,47	-0,25	0,04	-0,12	-0,04	0,51	0,49	0,38	0,15	-0,36	-0,31
T	0,09	0,45	-0,02	0,07	-0,27	0,28	0,67	0,79	0,89	0,81	-0,69	-0,86
U	0,12	0,68	-0,10	-0,05	-0,43	-0,25	0,41	0,04	0,71	0,21	-0,46	-0,31
V	0,10	0,61	-0,11	-0,08	-0,36	-0,22	0,45	0,01	0,74	0,22	-0,50	-0,30
Rx1	0,29	<u>0,60</u>	-0,27	0,07	-0,15	-0,04	0,46	<u>0,50</u>	0,59	<u>0,50</u>	-0,65	-0,63
TOT	0,19	<u>0,50</u>	-0,14	0,17	-0,14	0,20	0,61	<u>0,50</u>	0,69	0,36	-0,56	-0,45

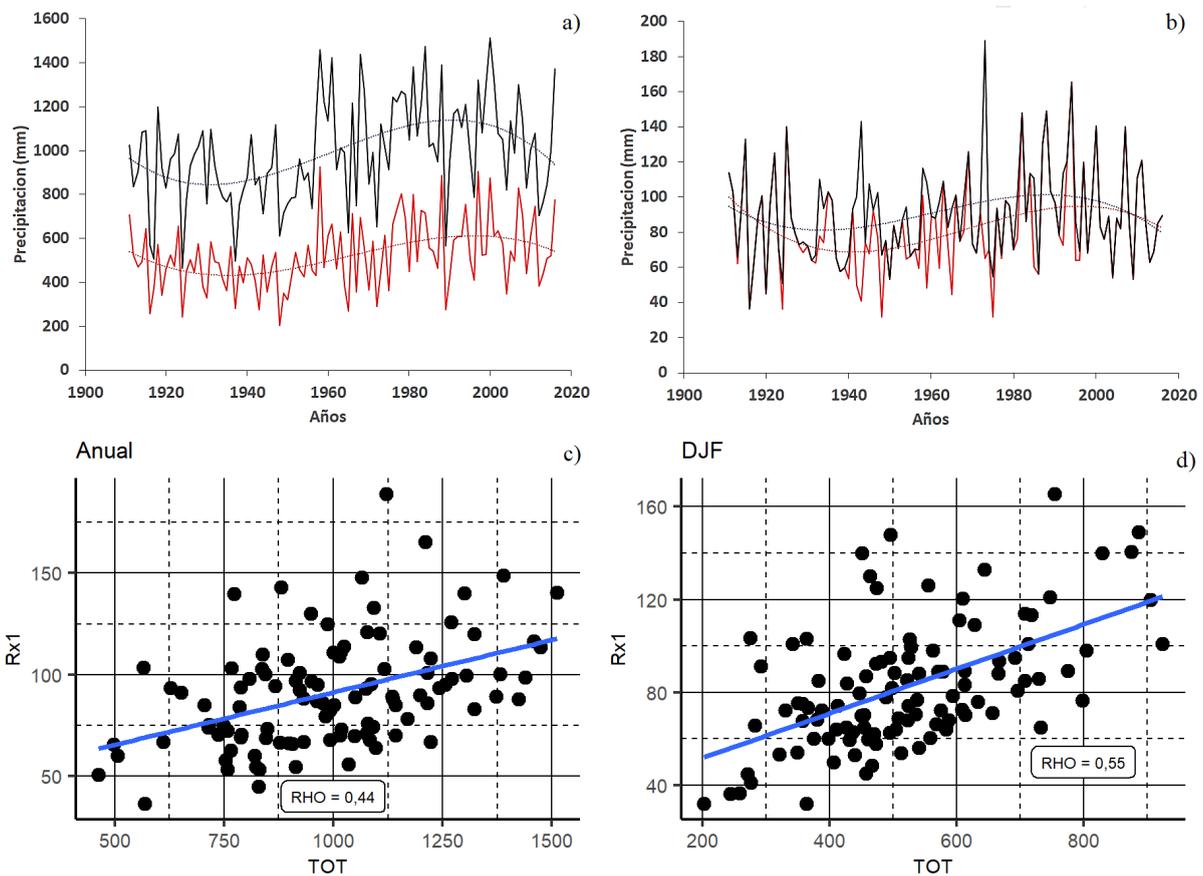


Figura 3-1: Series de precipitación anuales (línea negra) y de verano (Diciembre-Enero-Febrero, DJF) (línea roja) y ajuste polinómico de grado 3 (líneas de trazos) para: a) TOT y b) Rx1. Dispersión de Rx1 vs TOT (puntos), valores en mm, su ajuste lineal con mínimos cuadrados (recta azul) y el correspondiente valor de RHO para las series: c) anuales y d) de DJF.

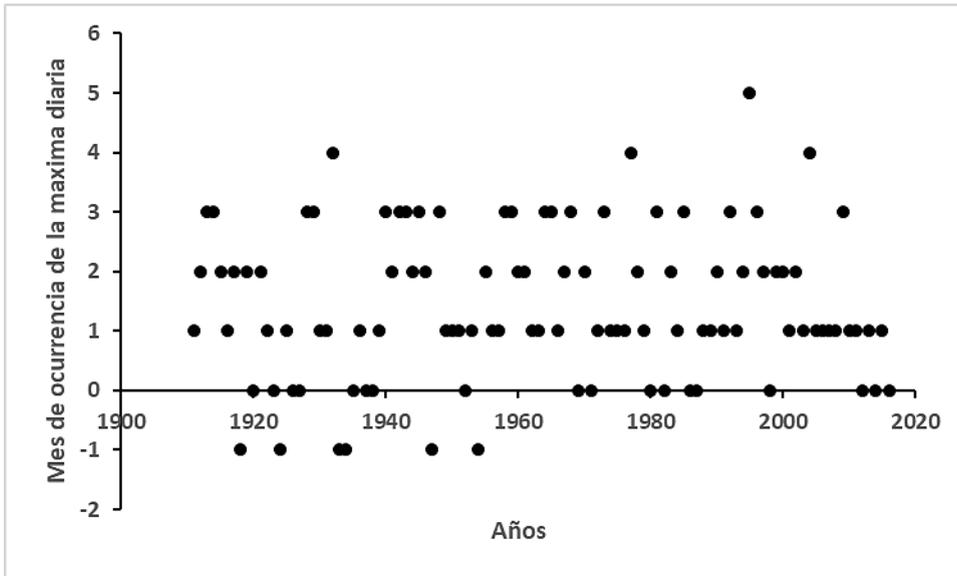


Figura 3-2: Mes de ocurrencia de Rx1 para cada año. Los meses corresponden a: -1 = noviembre, 0 = diciembre, 1 = enero, 2 = febrero, 3 = marzo, 4 = abril, 5 = mayo.

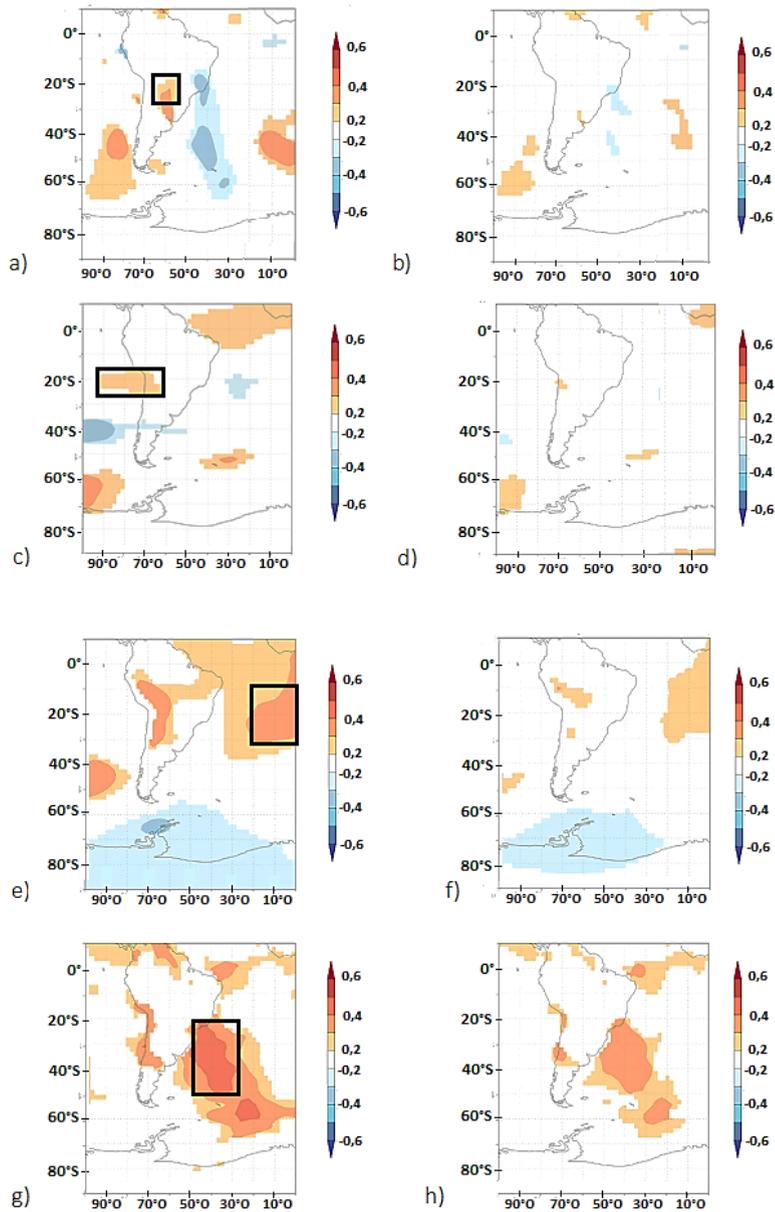


Figura 3-3: Mapas de correlación de: a)-b) V (viento meridional a 850 hPa), c)-d) U (viento zonal a 200 hPa), e)-f) P (presión a nivel del mar), g)-h) T (temperatura media del aire de 2 a 10 m), con las series de TOT (columna izquierda) y Rx1 (columna derecha) de DJF. Zonas con color corresponden a valores de RHO con nivel de confianza mayor a 95%. Figura obtenida con el Explorador Climático KNMI. Los recuadros negros indican las regiones promediadas para V, U, P y T para un posterior análisis.

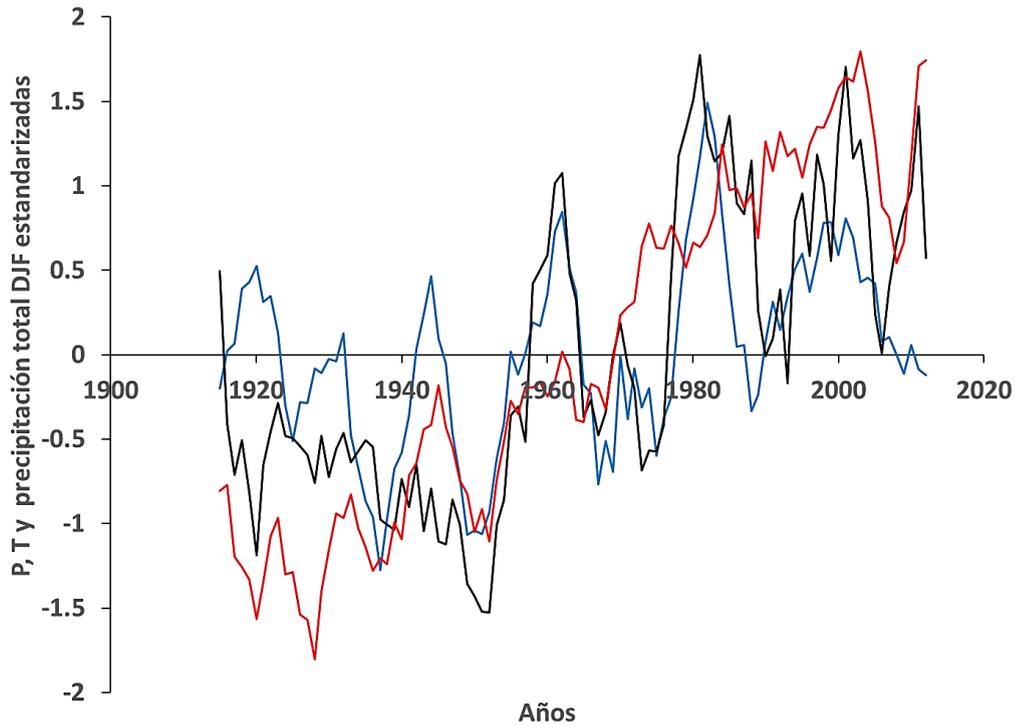


Figura 3-4: Series de TOT (línea negra), P promedio del área comprendida entre 10°S-30°S y 0°O-20°O (línea azul) y T promedio del área comprendida entre 20°S-50°S y 30°O-50°O (línea roja), correspondientes a DJF. Las series son estandarizadas y suavizadas con promedio móvil de 5 años.

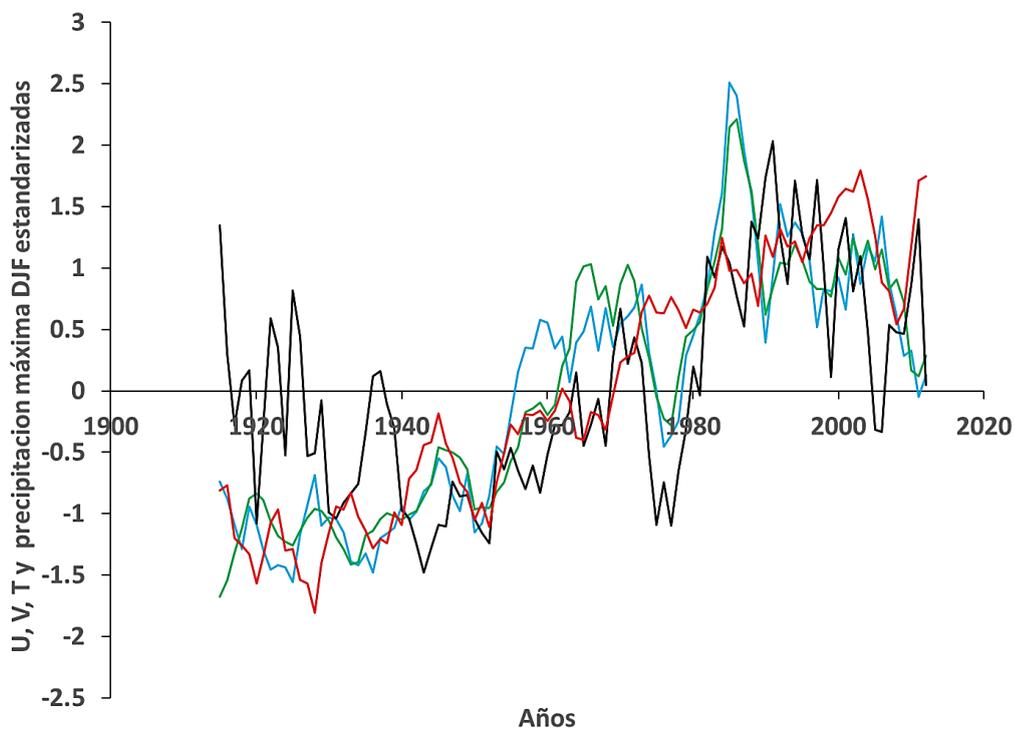


Figura 3-5: Series de Rx1 (línea negra), U promedio del área comprendida entre 15°S-25°S y 60°O-90°O (línea celeste), V promedio del área comprendida entre 15°S-25°S y 50°O-70°O, (línea verde) y T promedio del área comprendida entre 20°S-50°S y 30°O-50°O (línea roja), correspondientes a DJF. Las series son estandarizadas y suavizadas con promedio móvil de 5 años.

correspondientes a DJF. Las series son estandarizadas y suavizadas con promedio móvil de 5 años.

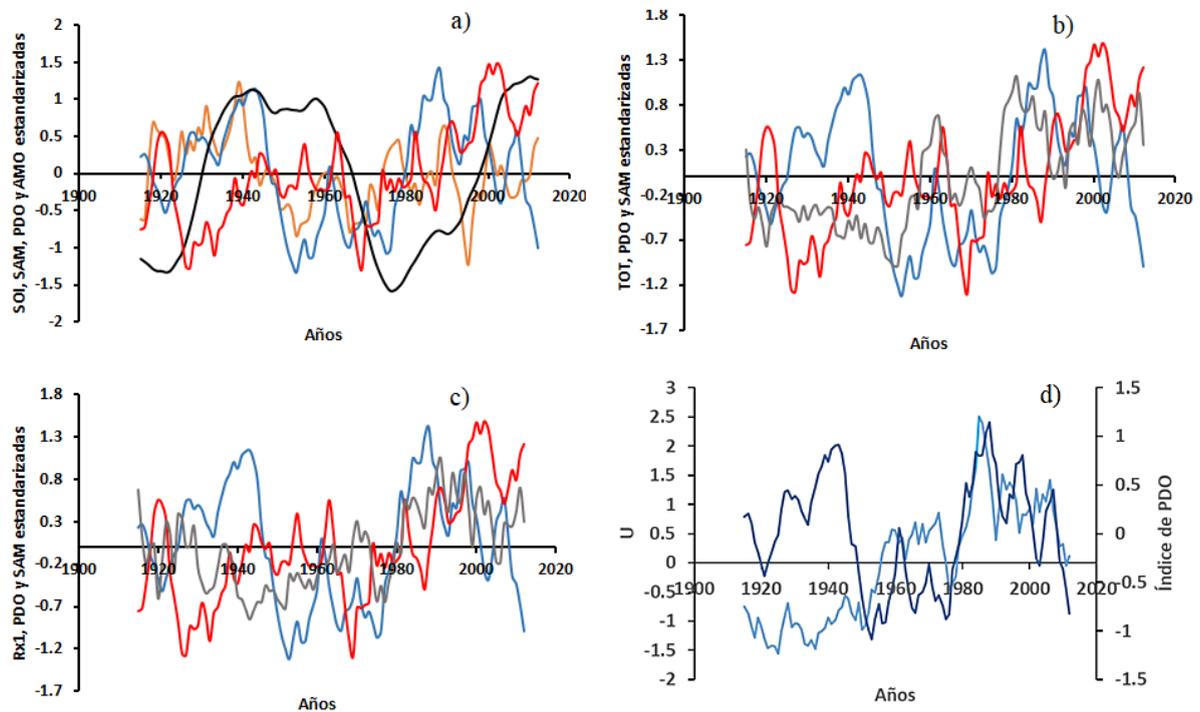


Figura 3-6: Series estandarizadas y con promedio móvil de 5 años de: a) PDO (línea azul), AMO (línea negra), SOI (línea naranja) y SAM (línea roja), b) TOT DJF (línea gris), SAM (línea roja) y PDO (línea azul), c) Rx1 DJF (línea gris) y PDO (línea azul), d) U (línea celeste) y de PDO (línea azul).

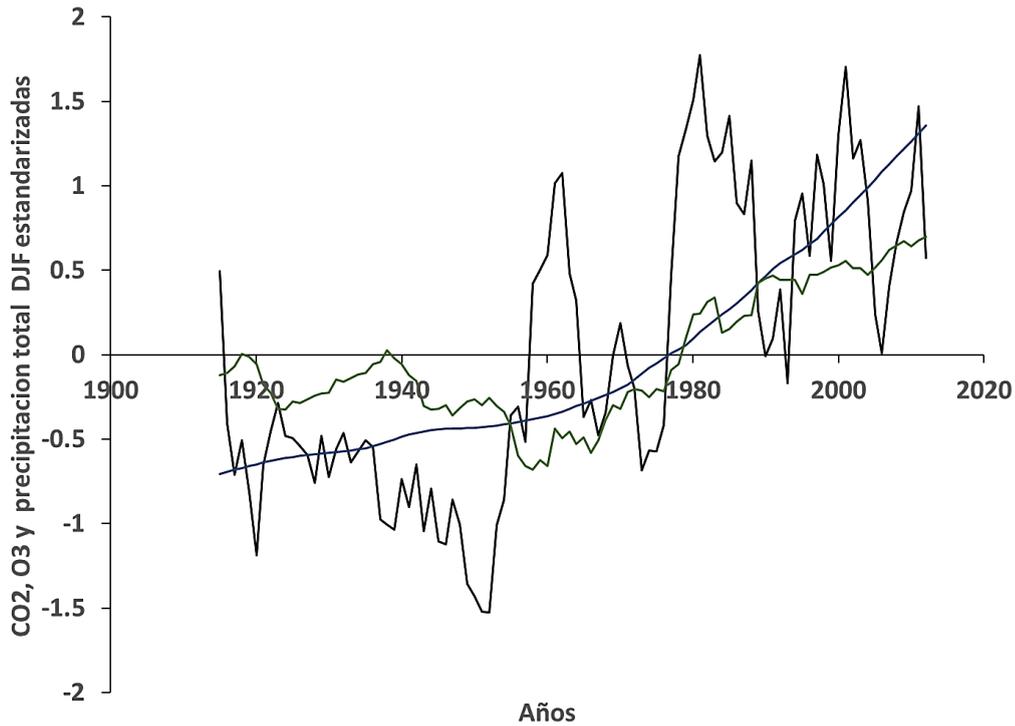


Figura 3-7: Series estandarizadas y suavizadas con promedio móvil de 5 años de: TOT DJF (línea negra), CO2 global anual (línea azul) y columna total de O3 polar de septiembre (multiplicada por -1 para una “visión directa”, línea verde).

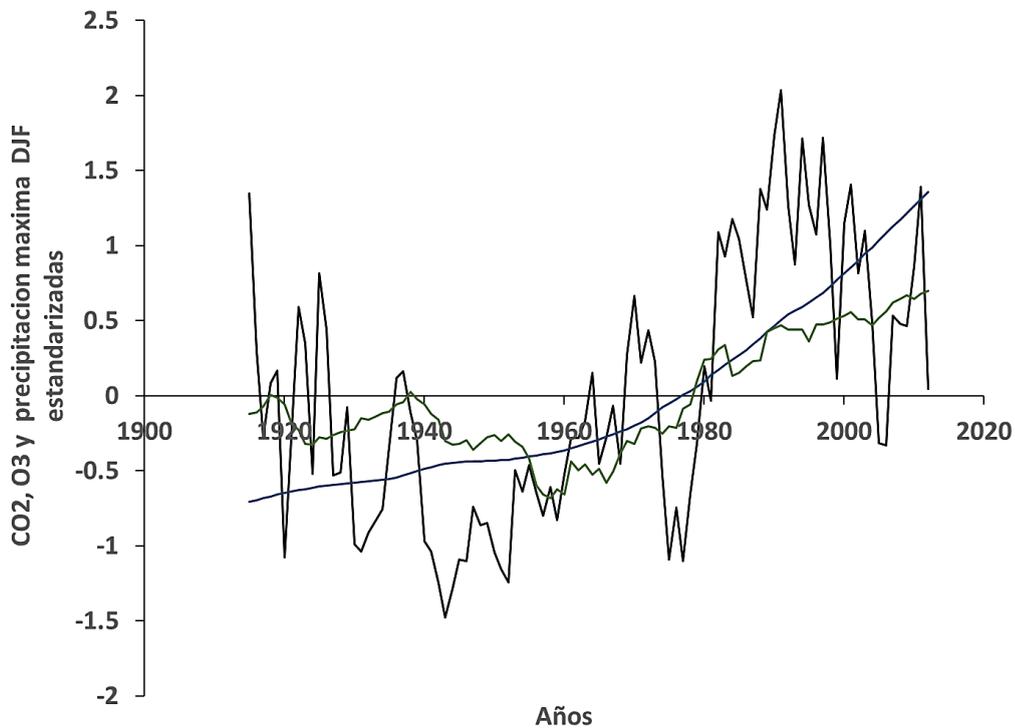


Figura 3-8: Series estandarizadas y suavizadas con promedio móvil de 5 años de: Rx1 DJF (línea negra), CO2 global anual (línea azul) y columna total de O3 polar de septiembre (multiplicada por -1 para una “visión directa”, línea verde).

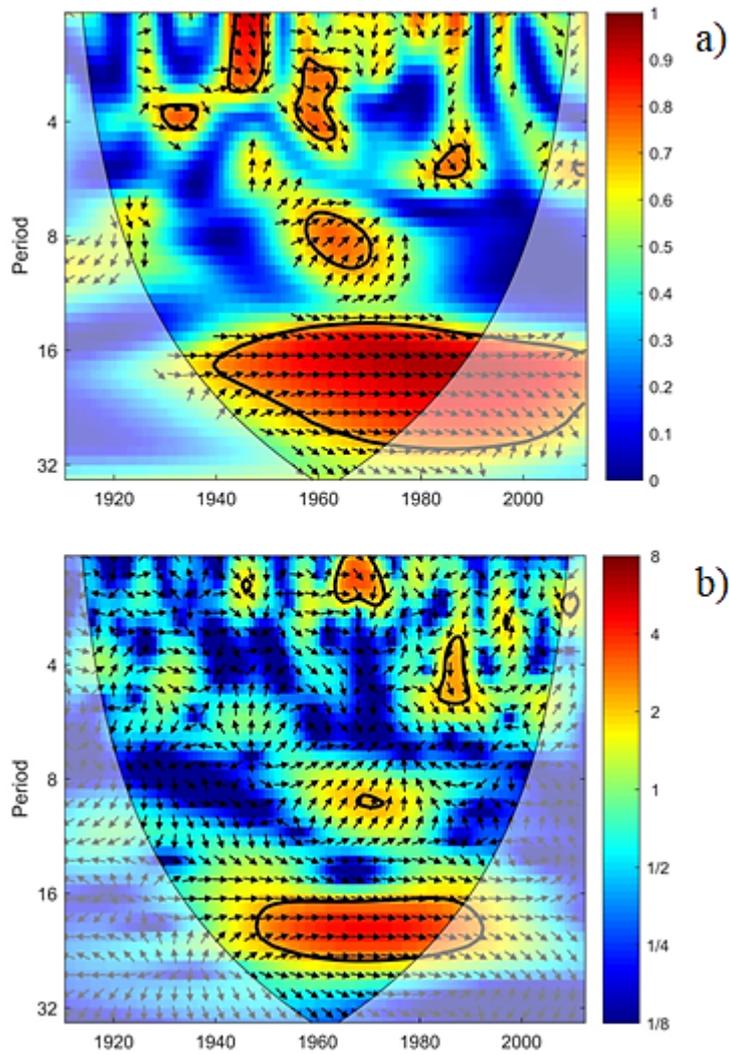


Figura 3-9: (a) Coherencia de wavelet y (b) espectro cruzado de wavelet entre P y TOT DJF.

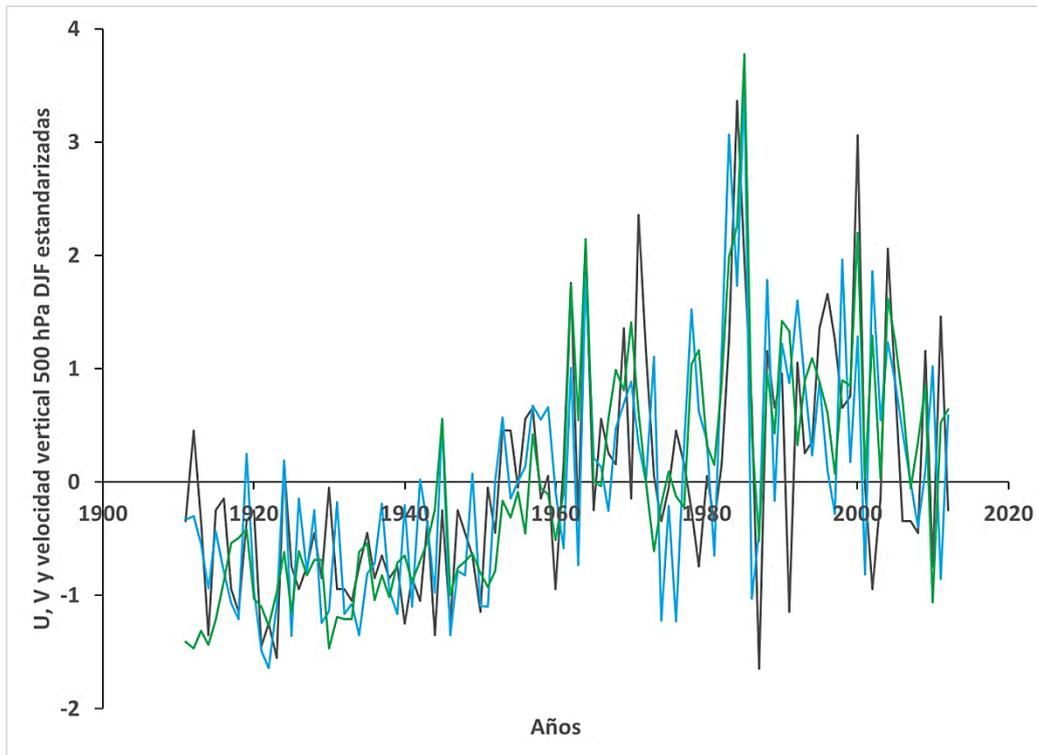


Figura 3-10: Series estandarizadas de: U promedio del área comprendida entre 15°S-25°S y 60°O-90°O (línea celeste), V promedio del área comprendida entre 15°S-25°S y 50°O-70°O (línea verde) y velocidad vertical en 500 hPa de la misma región que U (línea gris).

Capítulo 4: Forzantes naturales de la precipitación extrema

Resumen

En este capítulo se analiza la relación entre la precipitación máxima diaria (Rx1) en San Miguel de Tucumán (Tucumán, Argentina) y algunos modos de variabilidad global en el periodo 1912-2019. Se seleccionó la misma serie que en el Capítulo 3, debido a que la misma es la más larga y de mejor calidad disponible en el NOA, lo cual facilita tener una visión más certera y de largo plazo (108 años). El análisis se enfoca en la variabilidad interanual y de más largo plazo, considerando El Niño Oscilación del Sur (ENSO) y Modo Anular del Sur (SAM) como forzantes en la escala interanual, mientras que se considera a la Oscilación Decadal del Pacífico (PDO) y la Oscilación Multidecadal del Atlántico (AMO) como forzantes que modulan la relación Rx1-ENSO y Rx1-SAM en escalas multidecadales. Se plantea la hipótesis de que las relaciones Rx1-ENSO y Rx1-SAM son no estacionarias, tal como se demostrará en este capítulo, y dicha no estacionariedad es provocada por las fases de la PDO y/o AMO. Además, se evalúa la representatividad espacial de los resultados obtenidos utilizando una base de datos de Rx1 global (HadEX3) y, mediante reanálisis (ERA5), se exploran los patrones de anomalías de circulación que sustentan físicamente los resultados encontrados. El objetivo de este capítulo es detectar los subperiodos en que las relaciones Rx1-ENSO y Rx1-SAM son significativas en la localidad y en la región, así como las causas de la variabilidad de las mismas. Los resultados muestran una transición de una asociación más estrecha Rx1-ENSO en 1945-1974 hacia una asociación Rx1-SAM en 1974-2007. El primer periodo coincide con la fase fría de PDO, mientras que el segundo coincide con una fase cálida de PDO, indicando su impacto significativo en las relaciones de Rx1. El análisis con HadEX3 revela una relación no estacionaria Rx1-ENSO sobre el NOA, en contraste con lo observado en el este de Argentina, donde la relación es sostenida en el tiempo. También, se encontró una asociación positiva significativa Rx1-SAM sobre el NOA, el oeste de Paraguay, el este de Bolivia y el centro de Brasil durante la fase positiva de PDO. Se muestra que los cambios en Rx1 surgen en respuesta a cambios en las teleconexiones de ENSO y SAM impulsadas por PDO. Por lo tanto, los resultados evidencian el rol de los modos de variabilidad global como forzantes de la precipitación extrema.

4.1. Introducción

El régimen de precipitación del NOA está regulado por el Monzón Sudamericano, cuya variabilidad interanual está regulada en parte por las anomalías de temperatura del Océano

Pacífico Tropical (Garreaud y Aceituno, 2001; Mantua y Hare, 2002; Ferrero y Villalba, 2019). El Pacífico tropical tiene dos modos de variabilidad dominantes: El Niño Oscilación del Sur (ENSO) y la Oscilación Decadal del Pacífico (PDO). ENSO es un fenómeno acoplado atmósfera-océano (Wang et al., 2017; Cai et al., 2020) con una periodicidad de 2 a 7 años que consiste en una alternancia entre anomalías frías (La Niña, ENSO-) y cálidas (El Niño, ENSO+) sobre el centro del Pacífico ecuatorial (Wang et al., 2017; Krepper y Garcia, 2004). Variaciones de más baja frecuencia están también presentes en ENSO (Hurtado et al., 2020), aunque las mismas recibieron menos atención en la literatura. Por otra parte, PDO tiene fluctuaciones multidecadales (Newman et al., 2016; Wang et al., 2017), con condiciones relativamente más frías en los períodos 1910-1925 y 1947-1976 (PDO en fase negativa, PDO-) y condiciones más cálidas en 1926-1945 y 1977-1998 (PDO en fase positiva, PDO+) durante el siglo pasado (Wang et al., 2017).

Previos estudios sobre la variabilidad de la lluvia en Argentina se han enfocado principalmente en la asociación con ENSO. En una revisión reciente, Cai et al. (2020) analizaron los impactos de ENSO sobre Sudamérica. Durante los eventos El Niño, un patrón de tren de ondas de Rossby estacionarias promueve fuertes lluvias e inundaciones a lo largo de Brasil, Uruguay y norte de Argentina (NA). En NA, la relación entre ENSO y la precipitación es más marcada de septiembre a enero, esto es, entre el fin de la estación más seca y el inicio de la estación más húmeda (Hurtado and Agosta, 2021; Montecinos et al., 2000). Sin embargo, pocos estudios han analizado la relación en baja frecuencia entre ENSO y la precipitación. En un estudio reciente, Hurtado et al. (2020) identificaron saltos climáticos en la precipitación total del semestre cálido en Argentina a mediados de la década de 1950, 1976/1977 y al inicio de la década de 1980. Ellos asociaron los saltos de las décadas de 1950 y 1980 con cambios de baja frecuencia en los tipos de ENSO, mientras que el salto de 1976/1977 lo asociaron con un cambio de fase PDO. La mayoría de los trabajos existentes sobre la relación ENSO-precipitación se han enfocado en la lluvia total mensual/estacional en el centro-este de Argentina, donde la relación es más fuerte y sostenida en el tiempo. Por lo tanto, es necesario realizar un análisis profundo de la relación ENSO-precipitación en el NOA para suplir esta carencia en el conocimiento.

La serie de precipitación diaria más extensa del NOA corresponde a San Miguel de Tucumán (TUC) como se explicó en el Capítulo 3, la cual cuenta con registros completos desde 1911. La serie de TUC no está disponible públicamente y, en consecuencia, ha sido menos analizada que otras series en la literatura. Scardilli et al. (2017) analizaron la lluvia total, número de días con lluvia y las rachas húmedas utilizando los datos diarios de TUC e identificaron variaciones interdecadales que resultan en tendencias generales positivas, aunque no analizan las causas de las mismas. También detectaron saltos climáticos entre 1954 y 1956 que concuerdan con resultados reportados para la lluvia total anual en NA (Minetti y Vargas, 1997; Hurtado et al., 2020). En este sentido, para el NOA Ferrero y Villalba detectaron saltos positivos en registros mensuales centenarios entre 1956 y 1960 y entre 1973 y 1979, así como saltos negativos entre 2008 y 2013. Comparando estos resultados con los de Hurtado et al. (2020), se puede decir que los mismos están posiblemente relacionados a saltos en ENSO y PDO.

La influencia de ENSO en la variabilidad interanual de la lluvia en el NOA aún no está del todo clara. Rivera y Penalba (2015) utilizando el Índice de Precipitación Estandarizado para el período 1961-2008 concluyeron que el NOA no muestra ninguna relación con ENSO. En contraste, Marwan et al. (2003) mostraron para el período 1979-1999 que las anomalías de precipitación durante los eventos ENSO tienen una estructura dipolar en el NOA. Este dipolo consta de anomalías positivas de precipitación en el este de la región y negativas sobre el oeste durante El Niño, y viceversa durante La Niña. Si se observa el patrón descrito (Figuras 1 y 2 de Marwan et al., 2003), TUC está ubicado en la zona de transición entre las anomalías positivas y negativas, y por lo tanto, tiene una respuesta débil a ENSO durante el período 1979-1999. Sin embargo, Trauth et al. (2003) detectaron que durante los eventos El Niño de 1965-1966, 1969-1970 y 1982-1983 la lluvia anual total de TUC fue significativamente más alta que lo normal. Por lo tanto, hay evidencia de que ENSO influye en la variabilidad de la precipitación en TUC y el NOA y podría ser un predictor de la misma, aunque esto parece depender del período e índice analizado. Por lo tanto, el análisis del registro centenario de lluvias de TUC puede ser útil para detectar periodos en los cuales ENSO exhibe una asociación más fuerte con la precipitación en la región.

A diferencia de la lluvia total anual y estacional, existen una menor cantidad de trabajos que analizan la asociación entre la precipitación extrema y ENSO. Entre ellos, Grimm y Tedeschi (2009) analizaron un gran conjunto de registros de lluvia de estaciones meteorológicas y encontraron que los cambios en la frecuencia de eventos de lluvia extrema diaria relacionados a ENSO son generalmente coherentes con los cambios observados a nivel mensual. Sin embargo, ellos sostienen que los extremos diarios de precipitación son más sensibles a ENSO que los acumulados mensuales, ya que los cambios en los primeros son más extensos espacialmente. Li et al. (2020) analizando datos horarios de lluvia en un análisis global detectaron que ENSO modula la precipitación mediante una regulación de las horas con lluvia. Por lo tanto, a diferencia de la lluvia total estacional o anual, podría haber una asociación significativa entre ENSO y Rx1 de TUC.

Menos estudiado que ENSO, otro forzante de la lluvia en la región es el Modo Anular del Sur (SAM), el cual es conocido por afectar el clima del Hemisferio Sur (Thompson y Wallace, 2000; Fogt y Marshall, 2020). La fase positiva de SAM (SAM+) está asociada con anomalías negativas de presión atmosférica sobre la Antártida y positivas sobre latitudes medias del Hemisferio Sur, y viceversa en su fase negativa (SAM-). El mismo altera la intensidad y posición de los frentes fríos y los sistemas de tormentas de latitudes medias (González et al., 2017), en una forma tal que durante SAM+ (SAM-) se inhibe (favorece) el pasaje de frentes fríos sobre Argentina. La relación entre SAM y la precipitación de verano es diferente en el este y oeste de Argentina. Cavalcanti et al. (2021) analizaron composites de anomalías de precipitación durante las dos fases de SAM durante el periodo 1999-2010 y encontraron que las anomalías tienen una estructura dipolar en el NA. En SAM+ existen anomalías positivas de lluvia total de verano en el NOA y negativas sobre el NEA, y viceversa en SAM-. Resultados similares fueron encontrados por Garbarini et al. (2021), quienes analizaron la relación entre la intensidad del anticiclón del Pacífico Sur y la precipitación en el período 1979-2012. Ellos encontraron que la intensidad del anticiclón es modulada por SAM, en una

forma tal que SAM– implica un debilitamiento del anticiclón y anomalías de negativas (positivas) de precipitación en el NOA (NEA). Efectos de SAM en la lluvia fueron detectados también en regiones vecinas, tales como Uruguay, Brasil y el centro de Chile (Vasconcellos and Cavalcanti, 2010; Garreaud et al., 2020; Reboita et al., 2021).

En escala multidecadal existe la Oscilación Multidecadal del Atlántico (AMO), la cual es análoga a PDO pero en el Atlántico Norte (Knight et al., 2006), y por ende consta de fase cálida (PDO+) y fría (AMO–). Cambios en la precipitación extrema en Argentina fueron influidos significativamente por cambios en baja frecuencia en PDO y AMO (Robledo et al., 2020). La interacción entre PDO+ y AMO– (PDO– y AMO+) aumenta (disminuye) el transporte de humedad desde los trópicos hacia NA y genera anomalías positivas (negativas) de precipitación en la región (Barreiro et al., 2014). Además, existe evidencia que PDO y AMO modulan los patrones de teleconexión de ENSO y SAM, lo que a su vez afecta los patrones de anomalías de precipitación que generan ambos (Kayano et al., 2019; Wachter et al., 2020).

Teniendo en cuenta la relevancia regional de Rx1 debido a sus impactos socio-económicos y a la necesidad de mejorar el conocimiento sobre las causas de su variabilidad temporal, los objetivos de este capítulo son:

- analizar las relaciones Rx1-ENSO y Rx1-SAM en TUC identificando períodos con correlación significativa
- determinar los sub-periodos en los cuales las relaciones Rx1-ENSO y Rx1-SAM en TUC son más significativas aplicando un nuevo enfoque basado en buscar la máxima significancia estadística en la correlación
- analizar la coherencia de los resultados obtenidos con las anomalías de Rx1 y variables atmosféricas observadas en Sudamérica Subtropical (SSA)
- determinar si las fases de PDO y AMO afectan (favoreciendo o inhibiendo) las asociaciones Rx1-ENSO y Rx1-SAM.

4.2. Datos

4.2.1. Datos de precipitación de San Miguel de Tucumán

Como en el Capítulo 3, se utilizó la serie de precipitación diaria de TUC, debido a su longitud temporal y calidad de los datos. La serie de precipitación al momento de realizar el análisis del presente capítulo fue actualizada hasta el año 2019, por lo que la serie utilizada aquí cubre el periodo 1911-2019, que considerando años hidrológicos, abarca 1912-2019. Esta serie es útil para cumplir el objetivo de este capítulo, ya que cuenta con una longitud de 108 años hidrológicos (109 años calendario), lo cual permite abarcar al menos un periodo completo de la AMO y casi dos períodos completos de la PDO. La figura 4-1a muestra la cantidad de valores de Rx1 anual según su mes de ocurrencia en el periodo 1911-2019. Enero tiene la frecuencia de ocurrencia más elevada con 35 de 109 valores de Rx1 anual ocurriendo en este

mes. Otros meses con elevada frecuencia de ocurrencia de Rx1 anual son febrero, marzo y diciembre, en ese orden. En total, en el cuatrimestre diciembre-enero-febrero-marzo (DJFM) ocurrieron el 88% de los valores de Rx1 anual en el registro de precipitación, por lo que se decidió analizar en este capítulo el Rx1 de DJFM, en lugar del anual. Esta decisión se fundamenta por un lado en el alto porcentaje de ocurrencia de Rx1 anual en DJFM. Por el otro, al seleccionar un periodo de pocos meses del año se espera que el análisis de correlación con las diferentes variables de estudio arroje mejores resultados que utilizando valores anuales, ya que la física del sistema climático cambia a lo largo del año. Por otra parte, a diferencia del Capítulo 3 donde se analizó el trimestre DJF, en este capítulo se incluye también el mes de marzo para abarcar un mayor número de eventos de Rx1 anual, y debido a que en el anterior capítulo se mostró que existe un leve corrimiento de la ocurrencia del Rx1 anual hacia el otoño. Como en el Capítulo 3, cada año para Rx1 DJFM es asignado como el año correspondiente al año calendario del trimestre enero-febrero-marzo, con lo cual la serie obtenida abarca el período 1912-2019 (108 años).

4.2.2. Datos de Rx1 para Sudamérica Subtropical

Para evaluar la coherencia espacial de los resultados obtenidos para TUC, se utilizaron datos globales mensuales de Rx1 correspondientes a HadEX3 (Dunn et al., 2020) en el área comprendida entre 15-40°S y 75-30°O, la cual contiene a SSA. Los datos son provistos por *Met Office Hadley Centre* (<https://www.metoffice.gov.uk/hadobs/hadex3/download.html>). HadEX3 está basado en observaciones de 17 mil estaciones meteorológicas medidoras de precipitación diaria ubicadas alrededor del mundo. Provee 12 índices de precipitación recomendados por el ETCCDI, entre los cuales se encuentra Rx1. Los índices mensuales y anuales calculados en cada ubicación son interpolados en una retícula de 1,25° x 1,875° (latitud x longitud) utilizando el esquema de Distancia Inversa Ponderada. En su construcción, HadEX3 considera estaciones con al menos 20 años de datos completos y cuya cobertura llega hasta el año 2009 al menos para evitar inhomogeneidades al final del período de cobertura que podrían afectar el análisis de largo plazo. El periodo de cobertura de Hadex es 1901-2019, sin embargo, debido a la falta de observaciones existen puntos de grilla sin datos disponibles al inicio del periodo. Teniendo en cuenta esto, aquí se utilizaron los datos de Rx1 DJFM del período 1962-2019, ya que en el mismo se dispone de datos para todos los puntos de grilla (en tierra) del área seleccionada para el análisis. La representación de los índices con HadEX3 concuerda con productos similares existentes previamente (Hadex, HadEX2 y GHCNDEX), y en comparación cuenta con mayor cantidad de puntos de grilla con datos completos en el período que cubre (Dunn et al., 2020)

4.2.3. Modos de variabilidad global

Se analizaron los mismos modos de variabilidad global que en el capítulo anterior: ENSO, SAM, PDO y AMO, aunque con un enfoque diferente y algunos cambios en las series

seleccionadas. Las series utilizadas son mensuales, cubren el período 1912-2019 y fueron promediadas en DJFM, en coincidencia con la serie de Rx1. Las series son:

-ENSO: se seleccionaron los índices Niño 1.2 y Niño 3.4, teniendo en cuenta que existen dos tipos de eventos ENSO. Estos eventos son el ENSO del Pacífico Central y el del Pacífico Este (Hurtado y Agosta, 2021). Los resultados de Hurtado et al. (2020) indican que el ENSO del Pacífico Este es bien representado por el índice Niño 1.2, mientras Hurtado y Agosta (2021) muestran que el del Pacífico Central es bien representado por el índice Niño 3.4. Con esta consideración, se tiene en cuenta que los diferentes tipos de ENSO pueden impactar de forma diferente en la precipitación. Los índices Niño 1.2 y Niño 3.4 corresponden a las anomalías de temperatura en las regiones del Pacífico ecuatorial en las regiones delimitadas por 0-10°S y 90-80°O para ENSO+ 1.2, y 5°N-5°S y 170-120°O para ENSO+ 3.4 (de NOAA, disponibles en: https://psl.noaa.gov/gcos_wgsp/Timeseries/). Las anomalías son calculadas utilizando el conjunto de datos HadISST1 (Rayner et al., 2003) con el periodo base 1981-2010. También se tuvo en cuenta el índice SOI utilizado en el capítulo anterior, pero los resultados no se incluyeron en la tesis debido a que, al aplicar la metodología propuesta más adelante en este capítulo, Rx1 mostró mejor relación con los índices Niño 1.2 y Niño 3.4;

-SAM: tres series fueron consideradas: (1) SAM-20, del 20CR V2c que abarca el periodo 1912-2012, la misma utilizada en el capítulo anterior; (2) SAM-M, correspondiente al índice SAM de Marshall basado en medición de presión atmosférica en estaciones meteorológicas (Marshall, 2003) abarcando el periodo 1957-2019 (British Antarctic Survey, <https://legacy.bas.ac.uk/met/gjma/sam.html>); y (3) una serie concatenada utilizando SAM-20 en el periodo 1912-1956 y SAM-M para 1957-2019. Tanto SAM-20 como SAM-M son calculadas como la diferencia en la media zonal de la presión a nivel del mar entre 40°S y 65°S. La diferencia radica en que SAM-20 corresponde a datos reticulados provenientes de un reanálisis, mientras que SAM-M se basa en mediciones en 6 estaciones desigualmente espaciadas. Se aplicó la metodología propuesta en este capítulo utilizando las tres series, y los resultados fueron similares. Sin embargo, se seleccionó la serie concatenada debido a que mostró relativamente mejores resultados y tiene la mayor cobertura temporal entre las tres;

-PDO y AMO: se utilizaron las mismas series que en el capítulo anterior, pero cubriendo el periodo 1912-2019.

4.2.4. Campos de variables atmosféricas

Campos mensuales de múltiples variables atmosféricas relacionadas con la circulación y la precipitación regionales (altura geopotencial, humedad específica en niveles bajos y viento meridional y zonal en diferentes niveles de presión) de la 5ta Generación de reanálisis del ECMWF (ERA5) fueron utilizados (Hersbach et al., 2020). ERA5 es un reanálisis de cobertura global con una resolución horizontal de 0,25x0,25° y 137 niveles de presión desde la superficie hasta una altura de 80 km. En este trabajo se utilizaron los datos mensuales del

ERA5 para el periodo 1940-2019 obtenidos de *Climate Data Store* del *Copernicus Climate Change Service* (disponible en: <https://cds.climate.copernicus.eu/>).

4.3. Metodología

Como se explicó en la introducción, la precipitación en el NOA es afectada por patrones de circulación global inducidos por ENSO y SAM. Además, estos patrones de circulación pueden ser afectados en escala multidecadal por PDO y AMO. Para detectar estas asociaciones, calcular el valor de RHO tomando simplemente el periodo completo de dos series (108 años en este caso) es el análisis más simple para detectar asociación lineal. Particularmente, para la serie de Rx1 analizada en este capítulo, el valor de RHO, removiendo previamente las tendencias lineales, es muy bajo para Rx1-ENSO y Rx1-SAM (0,08 y 0,19, respectivamente). Incluso aún sin remover las tendencias lineales, la correlación es baja según los resultados del capítulo anterior. Hay algunas razones que pueden explicar el bajo valor de RHO obtenido. Una podría ser una débil naturaleza de la asociación Rx1-ENSO y Rx1-SAM. Otra razón puede ser la ausencia de estacionariedad en las relaciones debido a interacciones con otros forzantes, es decir, debido a una no linealidad en la respuesta del sistema. Por lo tanto, metodologías más complejas que un simple análisis de correlación deben ser utilizadas para detectar estadísticamente las asociaciones. En base a esto, con la metodología propuesta a continuación, se busca determinar si las relaciones Rx1-ENSO y Rx1-SAM son no estacionarias, y, por otra parte, si esta no estacionariedad es modulada por las fases de PDO y/o AMO.

Primero, el problema se aborda con un nuevo enfoque al método conocido como representación de los triángulos utilizado Fink et al. (2010) y Bahaga et al. (2019). El nuevo enfoque propuesto busca detectar subperíodos de las series (Rx1, ENSO y SAM) donde existe una correlación lineal más significativa entre ellas. Luego de este análisis, se evaluó la representatividad espacial de los resultados anteriores mediante la construcción de composites de anomalías de Rx1 utilizando datos de HadEX3 en los subperíodos detectados y distinguiendo fases de ENSO y SAM. Similarmente, se realizaron composites de anomalías de las variables atmosféricas del ERA5 con el objetivo de dar soporte físico a las relaciones Rx1-ENSO y Rx1-SAM detectadas. Finalmente, los roles de PDO y AMO fueron evaluados con un análisis de correlación móvil, y por otra parte, separando los datos de Rx1, ENSO y SAM de acuerdo a las fases de PDO y AMO. Los resultados de estos análisis propuestos fueron evaluados en su conjunto para concluir acerca de las relaciones Rx1-ENSO y Rx1-SAM a nivel local y regional, las anomalías de circulación asociadas y el rol de PDO y AMO. A continuación, se describen detalladamente estos análisis propuestos.

4.3.1. Identificación de los periodos con las correlaciones más significativas

Para detectar subperíodos con asociaciones significativas entre dos series temporales, un método común es emplear una ventana móvil de una determinada longitud, más corta que la

longitud de las series, y calcular RHO. Esta longitud de ventana (WL) se selecciona usualmente basándose en una periodicidad identificada en las series temporales o en algún otro conocimiento del sistema bajo estudio. En lugar de usar este método convencional, aquí se decidió calcular la correlación móvil para todos los valores posibles de WL dentro de la longitud de las series de tiempo. Esta metodología se conoce como representación de los triángulos, debido a la forma en que se grafican los resultados, utilizada por Fink et al. (2010) y Bahaga et al. (2019). En esta tesis se decidió utilizar esta metodología, pero con otro enfoque: analizar el valor p , en lugar de solamente observar los valores de correlación. Como en los capítulos anteriores, se utilizó el coeficiente de correlación lineal de Pearson (RHO), mientras que los valores p se calcularon mediante el t-test de Student. Para cada WL, se eliminó la tendencia lineal de las series temporales resultantes previo al cálculo de RHO y p . La WL más corta considerada es 20 años, debido a que se busca detectar una señal más sostenida en el tiempo, mientras que la más larga coincide con la longitud de las series completas, es decir 108 años.

Como primer paso, se construyó una matriz de 4 columnas basada en la correlación entre Rx1 y cada serie de ENSO y SAM. La primera columna contiene el año inicial de la ventana, la segunda su correspondiente WL, la tercera el valor de RHO y la cuarta el valor p . Dentro de la matriz, el valor p más bajo de todos los obtenidos corresponde a una determinada WL con un dado año inicial y final, lo cual delimita el subperíodo de mínimo valor p (PmPV). Por definición, el valor de RHO para el PmPV tiene la mayor significancia estadística entre todos los valores de RHO obtenidos (menor p , mayor significancia). Esto significa que el PmPV es el subperíodo de las series donde es más probable que exista una relación entre Rx1 y ya sea ENSO o SAM, esto es, es menos probable que la correlación se debe al azar. La ventaja de utilizar este criterio en lugar de buscar el máximo valor de RHO, es que el máximo RHO podría corresponder a períodos menos longitud temporal y significancia que el PmPV.

También se identificó el período correspondiente a la ventana de máxima longitud (PMWL) para la cual se obtiene un valor de RHO significativo al 95%, esto es un p de 0,05. En general, el PMWL contiene al PmPV y tiene el mismo signo de RHO asociado, indicando que un valor de RHO significativo puede obtenerse en períodos más largos que el PmPV, aunque con menos significancia y con menor valor de RHO. La diferencia en longitud entre el PmPV y el PMWL es un indicador de la rapidez con que se debilita la relación entre Rx1 y ENSO o SAM, según el caso. Por otra parte, puede ocurrir que el PmPV no esté contenido en el PMWL e incluso que el signo asociado resulte distinto. En esos casos, puede concluirse que la relación entre Rx1 y ENSO o SAM es caótica o podría no existir. Además de el PmPV y PMWL, las representaciones de triángulos para Rx1-ENSO y Rx1-SAM son graficadas para mostrar todos los valores de RHO, p y sus variaciones temporales según las diferentes WL posibles.

4.3.2. Composites de anomalías de Rx1 y variables atmosféricas

Para determinar los patrones regionales de anomalías de Rx1 resultantes de las relaciones Rx1-ENSO y Rx1-SAM en los PmPV detectados y fuera de ellos, se realizaron composites utilizando HadEX3. Se analizó Rx1 respecto a la climatología 1962-2019 (período completo de Hadex3) en SSA bajo las diferentes fases de ENSO y SAM. A su vez se calcularon las diferencias de Rx1 entre las fases positivas y negativas. En todos los casos, la significancia estadística de las diferencias se evaluó mediante el test t de Student para diferencias en la media de muestras con varianzas desiguales. Se compararon resultados dentro y fuera de los PmPV para determinar si los cambios en la relación Rx1-ENSO y Rx1-SAM observada para TUC es también observada sobre SSA. Para ENSO y SAM, se definió una fase positiva (negativa) cuando el valor promedio de DJFM de ENSO o SAM estuvo por encima (por debajo) del percentil 75 (25) de la serie en el período 1912-2019. En la Tabla 4-1 se muestran los años clasificados según las fases de ENSO y SAM.

Por otra parte, para explorar los patrones de circulación asociados a ENSO y SAM en los PmPV y fuera de ellos, se realizaron mapas de anomalías de las variables atmosféricas del ERA5. Se muestran los composites de anomalías de altura geopotencial en 500 hPa (z500) y 850 hPa (z850), así como también el vector viento y la humedad específica en 850 hPa (q850). Estas variables muestran mejores resultados entre las consideradas y están estrechamente relacionadas a la precipitación regional. Se utilizaron en todos los casos los valores promedios del cuatrimestre DJFM y se utilizó como climatología el periodo completo disponible en ERA5 (1941-2019). El objetivo de comparar los patrones en los PmPV y fuera de ellos fue determinar si los cambios en la relación Rx1-ENSO y Rx1-SAM están relacionados a cambios en los patrones de circulación según el sub-periodo analizado. Además de las anomalías respecto al período climatológico, se calcularon las diferencias entre los campos según las fases de ENSO y SAM.

4.3.3. Determinación del rol de PDO y AMO en las asociaciones no estacionarias

Las asociaciones Rx1-ENSO y Rx1-SAM son no estacionarias si se observa que la correlación es significativa sólo durante ciertos periodos de las series analizadas. En este caso, la no estacionariedad puede ser inducida por un forzante adicional que genera asociaciones cambiantes en Rx1. La evaluación más sencilla para determinar el posible rol de un forzante adicional sería una correlación lineal múltiple. Sin embargo, si el forzante adicional tiene una interacción no lineal con Rx1, este método podría ser insuficiente. En el caso de Rx1, los dos posibles forzantes adicionales que podrían favorecer o inhibir las relaciones Rx1-ENSO y Rx1-SAM son PDO y AMO. Como se mencionó en la introducción, PDO y AMO generan variabilidad multidecadal en el NA, por lo cual también puede pensarse que generan variabilidad en los patrones de teleconexión asociados a ENSO y SAM.

Un método propuesto es verificar si las correlaciones móviles entre Rx1-ENSO y Rx1-SAM se vuelven significativas y con un determinado signo a lo largo de cierta fase de PDO y/o AMO. Esto se realizó graficando la correlación móvil de 20 años simultáneamente a las series de PDO y AMO filtradas con un promedio móvil de 10 años para eliminar las variaciones menores a las decadales.

Un segundo método propuesto es evaluar las correlaciones (no móviles) Rx1-ENSO y Rx1-SAM de acuerdo a las fases de PDO y AMO. Esto es, separar las series de acuerdo a las fases de PDO, de AMO y según sus combinaciones (PDO+ y AMO+, PDO+ y AMO-, PDO- y AMO-, PDO- y AMO+) que ocurrieron en cada trimestre DJFM en el periodo 1912-2019. Después de separar las series, RHO se evaluó para cada caso. Por ejemplo, si PDO y/o AMO favorecen o inhiben el efecto de ENSO en Rx1, entonces un valor de RHO significativo debe ser obtenido para una de las fases, y otro nulo o no significativo para la fase contraria. Este análisis es similar al que usaron Labitzke (1987) y Labitzke y van Loon (1988) para detectar el rol no lineal de la QBO en la asociación entre la temperatura estratosférica polar en invierno y la actividad solar. Para determinar las fases de PDO y AMO, se realizó un promedio móvil de 10 años para filtrar la variabilidad de más alta frecuencia, esto es para enfocarse en la variabilidad decadal y mayores. Los años correspondientes a cada fase de PDO y AMO se listan en la Tabla 4-2. Los años iniciales son 1916 y 2014, en lugar de 1912 y 2019, debido a que en el proceso de promedio móvil con ventana centrada la mitad de la WL se pierde en el inicio de la serie y la otra mitad al final.

4.4. Resultados

4.4.1. Ciclo anual y variabilidad de Rx1

La Figura 4-1b muestra la serie de Rx1 DJFM, denominada simplemente “Rx1” a partir de ahora en este capítulo. Se observa una gran variabilidad interanual en la serie, con un valor promedio de Rx1 de 89 mm, y valores extremos de 189 mm (marzo de 1973) y 36,5 mm (febrero de 1916). La variación relativa de Rx1, estimada como el cociente entre la desviación estándar y el promedio de la serie, es 31%. Por otra parte, en la Figura 4-1c se muestra la serie de anomalías (climatología 1912-2019), la cual exhibe una alternancia de años con valores de Rx1 por encima y por debajo del promedio. Existe una mayor predominancia de anomalías positivas a partir de la década de 1950. Finalmente, en la Figura 4-1d se muestra la serie de anomalías con un promedio móvil de 10 años, observándose la presencia de variabilidad multidecadal que consiste de elevados valores de Rx1 en la segunda mitad del siglo XX, especialmente en las décadas de 1980 y 1990. Por otra parte, desde el 2010 aproximadamente la serie muestra un retorno hacia valores de Rx1 más bajos.

4.4.2. Correlación Rx1-ENSO y Rx1-SAM y obtención de PmPV y PMWL

La representación de triángulos de los valores de RHO se muestra en la Figura 4-2. Para Niño 1.2 y Niño 3.4, en WL = 20 años, se obtuvieron valores de RHO entre 0,6-0,8 para las

ventanas cuyos años iniciales corresponden a la década de 1950. A medida que WL se incrementa, valores positivos de RHO se observan para años iniciales antes de la década de 1950, debido a que esas ventanas incluyen a la mencionada década donde una importante correlación existe. Para $WL > 30$ años, los valores de RHO tienden a decaer sostenidamente por debajo de 0,6 hasta perder la significancia estadística. Por otra parte, se observan períodos más cortos con valores de RHO negativos para Niño 1.2 y Niño 3.4. Para ENSO+ 1.2 en el periodo 1987-2006 y para ENSO+ 3.4 en el periodo 1923-1942, se observan valores de RHO $\sim -0,4$. Por lo tanto, aunque los índices de ENSO muestran principalmente correlaciones positivas, valores negativos con menores valores absolutos se observan en períodos con menor extensión temporal.

Para el índice SAM todos los valores significativos de RHO son positivos según la Figura 4-2. Para $WL = 20$ años, el año inicial con valores de RHO significativos (entre 0,4-0,6) está principalmente en las décadas de 1970 y 1980. A medida que WL se incrementa hasta el máximo valor posible (108 años), los valores de RHO se mantienen por arriba de 0,4 solamente para valores de año inicial correspondientes a la década de 1970. Esto significa que desde alrededor de la década de 1970 hasta casi el final de la serie, valores significativos y positivos de RHO existen entre Rx1 y SAM.

Para resumir la información provista por la representación de triángulos de la Figura 4-2, en la Figura 4-3 se muestran los PmPV y PMWL para comparar los períodos con influencia más notable de ENSO y SAM en Rx1. Los resultados de PmPv muestran claramente que hay dos periodos separados, uno caracterizado por una significativa relación Rx1-ENSO (1945-1974) y otro por Rx1-SAM (1974-2007). Para ambos casos el valor de RHO es de alrededor de 0,6. Teniendo en cuenta los PmPV, alrededor de 1974 hubo un cambio en las teleconexiones que afectan la variabilidad de Rx1, cambiando de ENSO a SAM. Por otra parte, en concordancia con la representación de los triángulos, los PMWL de la Figura 4-3 muestran que para valores de WL más grandes que la longitud del PmPV los valores de RHO caen abruptamente. Esto es debido a que, a medida que WL se incrementa, los años para los cuales la correlación es más baja e incluso no significativa son incorporados a la ventana disminuyendo la correlación del período. Esta comparación entre PmPV y PMWL confirma que la principal influencia de ENSO y SAM son confinados especialmente a sus respectivos PmPV.

Las representaciones de los triángulos de la Figura 4-2 y los PmPV de la Figura 4-3 demuestran que existe una relación no estacionaria entre Rx1-ENSO y Rx1-SAM. Además, las figuras muestran que los subperíodos con correlación positiva en ambos casos son diferentes. En el caso de ENSO+ 1.2, el mismo muestra un pequeño periodo con un valor de RHO negativo dentro del PmPV de SAM, sin embargo, este tiene menor extensión temporal que el de SAM y una magnitud de RHO más baja.

Las asociaciones Rx1-ENSO y Rx1-SAM detectadas en los PmPV corresponden a la escala interanual y las mismas decaen cuando se considera el periodo completo 1912-2019. Esto puede verse claramente en las series individuales (Figuras 4-4a-b, y 4-5a-b) y los gráficos de dispersión de Rx1 vs Niño 3.4 y Rx1 vs SAM (Figuras 4-4c-d, y 4-5c-d). Además, se muestran los diagramas de caja de Rx1 separando las fases de ENSO (Figuras 4-4e-f) y las

fases de SAM (Figuras 4-5e-f). Para el PmPV de ENSO (Fig. 4-4e), los años definidos como ENSO+ tienen para Rx1 una mediana de 125 mm, 70 mm para el caso de años ENSO- y 90 mm para el caso de años neutrales (ENSO N). En contraste, para el periodo completo 1912-2019 (Fig. 4.4f) las diferencias entre fases ENSO se debilitan fuertemente, de forma tal que no se observan diferencias en la mediana de Rx1 bajo ENSO- y ENSO N (~80 mm), mientras que para años ENSO+ la mediana es ligeramente superior (~90 mm). En el caso de SAM, también se observan notables diferencias en la mediana de Rx1 en el PmPV según la fase (Figura 4-5e), siendo 90 mm para SAM positivo (+), 87 mm para SAM neutral (N) y decrece a 50 mm para SAM negativo (-). Para el período completo 1912-2019 (Figura 4-5f), las diferencias en la mediana de Rx1 según la fase de SAM es más pequeña, siendo ~90 mm para SAM+ y SAM N, y ~80 mm para SAM-.

4.4.3. Composites de anomalías de Rx1 en SSA

En la Figura 4-6 se muestran las anomalías de Rx1 en SSA según las diferentes fases de ENSO en un período comprendido dentro de su PmPV (1962-1973) y otro fuera del mismo (1975-2007). No se incluye el año 1974 debido a que el mismo está presente en los PmPV de ENSO y SAM simultáneamente, y se buscó comparar sus patrones en periodos independientes. El primer período (1962-1973) no coincide exactamente con el PmPV de ENSO debido a que no hay datos suficientes en HadEX3 previo a 1962. Por otra parte, el segundo período (1975-2007) se eligió coincidente con el PmPV de SAM para comparar los cambios en la señal del ENSO en ese mismo periodo.

En coincidencia con lo encontrado anteriormente para TUC, durante el PmPV en fase ENSO- existen valores más bajos de Rx1 (anomalías negativas) en gran parte del centro y norte de Argentina, norte de Bolivia y centro de Brasil (Figura 4-6a). Por otra parte, durante ENSO- predominan valores más elevados de Rx1 en gran parte del centro y norte de Argentina (Figura 4-6b). En ambos casos, las diferencias son estadísticamente significativas al 95% en regiones cercanas a TUC (punto verde en las figuras). Las diferencias entre ENSO+ y ENSO- dentro del PmPV (Figura 4-6c) muestran valores positivos significativos en gran parte del centro-oeste y norte de Argentina y sobre el centro de Brasil. En contraste, cuando se analiza el periodo fuera del PmPV, las anomalías durante ENSO- se debilitan y no son estadísticamente significativas en gran parte de la región (Figura 4-6d), excepto sobre el centro-oeste de Argentina. Durante ENSO+ (Figura 4-6e) aparece un dipolo que consta de anomalías significativas positivas sobre el este de Argentina y sur de Brasil, y negativas sobre el sur de Bolivia, norte de Chile y extremo noroeste de Argentina, en una forma tal que TUC queda en una zona de transición sin anomalías significativas. Similarmente, cuando se calcula la diferencia de Rx1 entre ENSO+ y ENSO- fuera del PmPV (Figura 4-6f), se observa el dipolo con más intensidad y con una extensión de las anomalías positivas hacia el norte de Uruguay, sur de Brasil y norte de Bolivia. En conclusión, los patrones de anomalías de Rx1 entre los períodos muestran que las anomalías inducidas por ENSO han modificado su distribución espacial en la región.

Análogamente, en la Figura 4-7 se muestran los resultados para SAM. Fuera del PmPV de SAM, bajo SAM- (Figura 4-7a) solo se observan anomalías significativas y positivas de Rx1 en el sudeste de Brasil, mientras que bajo SAM+ (Figura 4-7b) en general no hay anomalías significativas en la región. La diferencia entre SAM+ y SAM- fuera del PmPV (Figura 4-7c) muestra que Rx1 es significativamente más elevado durante SAM+ sobre el centro-oeste de Argentina, y más bajo sobre norte de la Patagonia y centro de Chile. Por otro lado, durante el PmPV en SAM- (Figura 4-7d) se observa una extensa región de anomalías negativas significativas sobre el centro-oeste de Brasil, oeste de Paraguay y NOA hasta la ubicación de TUC aproximadamente, lo cual es coherente con lo ya analizado para dicha localidad. Para SAM+ (Figura 4-7e), las anomalías en las regiones mencionadas se tornan positivas como es de esperarse según lo analizado para TUC, aunque no son estadísticamente significativas, mientras que aparecen anomalías negativas significativas hacia el centro-oeste de Argentina. Cuando se calcula la diferencia entre SAM+ y SAM- durante el PmPV (Figura 4-7f), se observa que los valores de Rx1 son significativamente más altos en SAM+ sobre el centro-oeste de Brasil y oeste de Paraguay, mientras que son más bajos sobre el sur de Brasil, norte de Chile y oeste de Bolivia. En coincidencia con lo observado para ENSO, el patrón de anomalías de Rx1 promovido por SAM cambia según el sub-período analizado.

Por lo tanto, las relaciones Rx1-ENSO y Rx1-SAM detectadas durante los PmPV para TUC son coherentes con patrones de anomalías de Rx1 en SSA, los cuales cambian según el sub-periodo que se analice. Los resultados de este análisis muestran que la relación significativa Rx1-ENSO encontrada en el PmPV se observa en gran parte del centro y norte de Argentina, norte de Bolivia y centro de Brasil. Esta relación implica mayores (menores) valores de Rx1 durante eventos ENSO+ (ENSO-). Por otra parte, en el caso de la relación Rx1-SAM, la misma es coherente con la relación que se observa sobre el NOA, el oeste de Paraguay y el centro-oeste de Brasil. En este caso, hay valores más altos (bajos) de Rx1 durante SAM+ (SAM-).

4.4.4. Composites de anomalías de variables atmosféricas para ENSO

Durante ENSO- en su PmPV (Figura 4-8a) se observa un patrón de anomalías de z500 similar a una onda de Rossby proveniente del Pacífico tropical, y otra que parece emanar desde el Océano Índico. El patrón de anomalías de z500 establecido consta de un dipolo con anomalías negativas sobre el sur de Sudamérica y anomalías positivas sobre el sudeste de Brasil y Atlántico circundante. Esto también se observa en el patrón de anomalías de z850 (Figura 4-9a), lo cual genera una circulación ciclónica sobre gran parte de Argentina y anomalías negativas de q850 allí (Figura 4-10a). Esto último explica la existencia de valores más bajos de Rx1 durante ENSO- en el PmPV en gran parte del centro y norte de Argentina. A su vez, hay anomalías anticiclónicas entre 10-30°S sobre el continente que promueven anomalías negativas de q850 sobre el centro de Brasil y norte de Bolivia, lo que explica los valores más bajos de Rx1 observados. Simultáneamente, las anomalías de circulación descritas generan una convergencia de q850 sobre Paraguay, donde existen valores más elevados de Rx1.

Durante ENSO+ en su PmPV las anomalías de z500 (Figura 4-8b) también muestran un patrón similar a una onda de Rossby que emana desde el Pacífico tropical y otra que proviene desde el este del Océano Índico y norte de Australia. Este patrón consta de anomalías positivas de z500 sobre el Sur de Sudamérica, contrario a lo observado en ENSO-. El patrón de z850 (Figura 4-9b) muestra anomalías negativas sobre el Océano Atlántico entre 20-60°S frente a las costas de Argentina, y otro centro de anomalías negativas sobre el NOA. Este patrón promueve un fortalecimiento del flujo de q850 (Figura 4-10b) desde el norte sobre gran parte del centro y norte de Argentina, lo cual genera valores más elevados de Rx1.

Fuera del PmPV, durante ENSO- el patrón de anomalías de z500 (Figura 4-8c) se modifica con respecto a lo observado dentro del PmPV (Figura 4-8a). Nuevamente se observan patrones similares a ondas de Rossby provenientes del Pacífico e Índico tropicales. Sin embargo, la configuración en este caso consta de un alejamiento de las anomalías negativas de z500 fuera del sur de Sudamérica, la aparición de anomalías positivas sobre el Atlántico alejado de las costas de Argentina y anomalías negativas sobre el centro y sur de Brasil y Atlántico circundante. Este patrón también se observa en z850 (Figura 4-9d) y genera que las anomalías negativas de q850 (Figura 4-10d) se debiliten respecto a lo observado en el PmPV, provocando valores de Rx1 significativamente más bajos únicamente hacia el centro-oeste de Argentina (Figura 4-6d).

Durante ENSO+ fuera del PmPV el patrón similar a ondas de Rossby que emanan del Pacífico e Índico tropicales observado en z500 (Figura 4-8d) también se ve modificado respecto al PmPV (Figura 4-8b). El mismo consta de anomalías positivas sobre el sur de Sudamérica, corridas un poco más al norte respecto al PmPV, y la aparición de anomalías positivas frente a las costas de Brasil. Esto también se observa en el patrón de z850 (Figura 4-9e), lo que promueve el flujo anómalo de q850 hacia el noreste de Argentina, Uruguay y sur de Brasil, donde existen valores más elevados de Rx1 (Figura 4-6e); a su vez hay un debilitamiento de este flujo sobre el oeste del NOA, sur de Bolivia y norte de Chile donde consecuentemente hay valores más bajos de Rx1.

En coincidencia con lo descrito, la diferencia entre los patrones de ENSO+ y ENSO- durante el PmPV muestra que durante el ENSO+ existen anomalías positivas de z850 (Figura 4-9c) sobre el sur de Argentina y Chile, y anomalías negativas sobre el Atlántico lejos de la costa de Sudamérica. Esto promueve un fortalecimiento del flujo de q850 sobre el centro y norte de Argentina en ENSO+ (Figura 4-10c), explicando la existencia de valores más altos de Rx1 allí. La diferencia entre ENSO+ y ENSO- fuera del PmPV muestra que en ENSO+ las anomalías positivas de z850 (Figura 4-9f) se corren al sur respecto al PmPV, y aparecen anomalías positivas sobre Brasil. Esto promueve anomalías positivas de q850 (Figura 4-10f) sobre el noreste de Argentina, Uruguay y Brasil, con valores más altos de Rx1 (Figura 4-6f), y la disminución del flujo de q850 sobre el oeste del NOA, sur de Bolivia y norte de Chile, con valores más bajos de Rx1.

4.4.5. Composites de anomalías de variables atmosféricas para SAM

Las anomalías de $z500$ durante SAM– fuera de su PmPV (Figura 4-11a) muestra un patrón con anomalías negativas entre 30-50°S, destacándose tres centros ciclónicos importantes sobre el sur del Índico, sudeste de Australia y en el Atlántico frente a las costas de Argentina y sur de Brasil. De manera similar, este patrón de anomalías se observa en $z850$ (Figura 4-12a), lo que provoca anomalías negativas de $q850$ sobre el este de Argentina consecuencia del debilitamiento del flujo de humedad desde el norte (Figura 4-13a). Este patrón a su vez muestra anomalías positivas de $q850$ sobre el sudeste de Brasil, donde se observan valores significativamente más elevados de $Rx1$ en estas condiciones (Figura 4-7a).

En el caso de SAM+ fuera del PmPV, el patrón de $z500$ (Figura 4-11b) consta de anomalías positivas entre 30-60°S y negativas en el resto de las bandas latitudinales, entre las cuales se destaca un centro ciclónico anómalo sobre el este de Argentina y sur de Brasil. En el patrón de $z850$ (Figura 4-12b) se observa este centro de anomalías negativas principalmente sobre el sur de Brasil y el Atlántico frente a la costa Argentina. Esto promueve una circulación ciclónica en la región y anomalías negativas de $q850$ (Figura 4-13b), principalmente sobre el norte de la Patagonia Argentina y centro de Chile, con valores más bajos de $Rx1$ en algunos sectores (Figura 4-7b).

Durante SAM– en el PmPV se ve un patrón de anomalías de $z500$ (Figura 4-11c) un poco modificado respecto al observado fuera del PmPV (Figura 4-11a). Si bien hay en general anomalías negativas entre 30-50°S, el centro de anomalías negativas observado antes sobre el Atlántico se ve desplazado hacia el noreste, y como contraparte, aparece una anomalía positiva que se extiende desde la Antártida hacia el sur de Sudamérica. Este patrón se ve reflejado también en $z850$ (Figura 4-12d), con la adición de anomalías positivas sobre el sur de Brasil, lo cual promueve anomalías anticiclónicas entre 10-40°S (Figura 4-13d). Este patrón produce anomalías negativas de $q850$ (Figura 4-13d) sobre el NOA, oeste de Paraguay y centro-oeste de Brasil en coincidencias con valores significativamente más bajos de $Rx1$ (Figura 4-7d), mientras que lo contrario se observa sobre el sur de Brasil.

En SAM+ durante el PmPV predominan las anomalías positivas de $z500$ (Figura 4-11d) principalmente entre 30-60°S, y las mismas son más extensas zonalmente en comparación a lo que ocurría fuera del PmPV. Se destaca la aparición de anomalías positivas de $z500$ sobre el Atlántico frente a las costas de Argentina que no se observan fuera del PmPV. Este patrón se replica en $z850$ (Figura 4-12e), promoviendo un flujo anticiclónico sobre el Atlántico y un flujo ciclónico entre 15-40°S sobre el continente. Esto genera anomalías negativas de $q850$ sobre el centro-oeste de Argentina (Figura 4-13e), donde se observan también valores más bajos de $Rx1$ en estas condiciones (Figura 4-7e).

La diferencia entre SAM+ y SAM– fuera del PmPV muestra que en SAM– predominan las anomalías negativas de $z850$ (Figura 4-12c) sobre el Atlántico frente a las costas de Brasil y Argentina. Esto promueve una disminución de $q850$ (Figura 4-13c) sobre el este de Argentina y un aumento hacia el sudeste de Brasil, donde se favorecen los valores más elevados de $Rx1$ en estas condiciones. Dentro del PmPV la diferencia entre SAM+ y SAM– muestra que las

anomalías de z_{850} (Figura 4-12f) sobre el Atlántico frente a Argentina y Brasil invierten su signo según la fase de SAM, lo cual genera anomalías ciclónicas en SAM+ entre 10-40°S sobre el continente (Figura 4-13f). Este patrón genera valores de q_{850} más elevados en SAM+ que en SAM- (Figura 4-13f), principalmente sobre el centro de Brasil, oeste de Paraguay, este de Bolivia y sectores del NOA, lo cual explica los valores más altos de Rx1 observados en SAM+ respecto a SAM- (Figura 4-7f), y una situación inversa en el sur de Brasil.

4.4.6. Roles de PDO y AMO en las relaciones no estacionarias Rx1-ENSO y Rx1-SAM

Según los resultados que se muestran a continuación, la relación Rx1-ENSO (Rx1-SAM) se ve favorecida durante la fase fría (cálida) de la PDO. La Figura 4-9 muestra los valores de RHO para una correlación móvil de 20 años para Rx1-Niño 1.2, Rx1-Niño 3.4 y Rx1-SAM. Se seleccionó 20 años como longitud de la ventana debido a que es la duración aproximada de cada fase de PDO (ver periodos de PDO+ y PDO- en Tabla 4-2). También en la Figura 4-9, se muestran las fases de PDO, las cuales fueron obtenidas aplicando una media móvil de 10 años, tal como se explicó en la sección Metodología. Se observa que durante el período de PDO- (1945-1977 aproximadamente), hay correlaciones significativas y positivas entre Rx1 y los índices del ENSO (puntos rojos y azules), mientras no hay correlación significativa con SAM. Por el contrario, durante el segundo periodo de +PDO (1978-2007 aproximadamente), la correlación se vuelve significativa y positiva para Rx1 vs SAM (puntos verdes), y se observa una débil correlación negativa apenas superando el umbral de significancia para Rx1 vs Niño 1.2 (puntos azules). Para el primer período de +PDO (1922-1944 aproximadamente), se observa una débil correlación para Rx1 vs Niño 3.4 (puntos rojos), mientras que no se observan correlaciones significativas para Rx1 vs SAM. No se observa un patrón definido cuando se consideran AMO en lugar de PDO (no se muestra).

Por otra parte, en la Tabla 4-3 se muestran los valores de RHO cuando las series de Rx1, ENSO y SAM se separan de acuerdo a las fases de PDO, AMO y sus combinaciones. Los resultados corroboran que durante la fase fría de PDO se favorece la correlación positiva Rx1-ENSO. Por otra parte, la fase cálida de PDO favorece una correlación mucho más débil y negativa para Rx1-ENSO. Además, en la fase cálida de PDO aparece una correlación positiva para Rx1-SAM, aunque con valores más bajos que los obtenidos en el análisis de la Figura 4-9, posiblemente debido a que en el proceso de separar las series se incluyen años donde no hay una correlación significativa Rx1-SAM (por ejemplo, al inicio de las series en la primer fase cálida de PDO). Cuando las series se separan de acuerdo a las fases de AMO, los resultados no indican que AMO favorezca alguna de las relaciones objeto de este estudio. Por otra parte, cuando se analiza considerando las combinaciones de PDO y AMO, solo los índices del ENSO muestran correlaciones significativas en el caso de PDO- pero sin importar el signo de AMO. Por lo tanto, los resultados indican que AMO no influye en las asociaciones Rx1-ENSO y Rx1-SAM.

El análisis de la Figura 4-9 y la Tabla 4-3 muestra que PDO es posiblemente el forzante que puede explicar las relaciones no estacionarias Rx1-ENSO y Rx1-SAM. La fase fría de PDO favorece la correlación positiva Rx1-ENSO, y la fase cálida favorece una correlación positiva Rx1-SAM y negativa, pero débil, Rx1-ENSO. En el caso de SAM, sin embargo, no se encontró correlación significativa para el primer período cálido de la serie de PDO (1922-1944), lo cual podría deberse a deficiencias en la serie de SAM utilizada o a una ausencia de relación. En relación a la primera hipótesis, se observa claramente que la correlación significativa Rx1-SAM aparece en la fase cálida de PDO en un periodo donde existe disponibilidad de datos correspondientes al índice SAM de Marshall basado en estaciones meteorológicas (desde 1957), mientras que para datos correspondientes al reanálisis 20CR v2c (previo a 1957) no se observa correlación. Es conocido que la sensibilidad de la precipitación a SAM puede variar según el índice de SAM que se selecciona para el análisis y el conjunto de datos que se utiliza para calcularlo (Ho et al., 2012).

4.5. Discusión y conclusiones

Los resultados de este capítulo corresponden al análisis de la serie diaria de precipitación más larga y de mejor calidad disponible en el NOA, la cual ha sido poco analizada en la literatura. Los resultados obtenidos a nivel local con esta serie son coherentes con el comportamiento regional de Rx1 según HadEX3. El método propuesto de determinación del PmPV, como un nuevo enfoque del análisis de correlación y la representación de los triángulos, permitió detectar relaciones no estacionarias entre Rx1-ENSO y Rx1-SAM. Específicamente, se detectó una transición de una relación más estrecha Rx1-ENSO (1945-1974) hacia una relación más estrecha Rx1-SAM (1974-2007). En principio, podría decirse que esta transición en 1974 está relacionada con el cambio de fase de PDO, y cuyo impacto ha sido detectado en varias series de precipitación de Argentina (Hurtado et al., 2020). Hasta ahora, según la búsqueda bibliográfica realizada, Rx1 es una variable que no había sido estudiada con este enfoque en el NOA y en SSA. En este sentido, la principal contribución de este capítulo es el hallazgo de posibles impactos de PDO en las relaciones Rx1-ENSO y Rx1-SAM.

Específicamente, el PmPV de los índices ENSO coincide con la fase fría de PDO, mientras que el PmPV de SAM coincide con una fase cálida de PDO. Fuera de los PmPV las relaciones Rx1-ENSO y Rx1-SAM decaen abruptamente. El carácter no estacionario de estas relaciones detectadas es la razón por la cual algunos trabajos que analizan la variabilidad de la precipitación en el NOA no encuentran correlaciones significativas con ENSO o SAM (Rivera y Penalba, 2015; Medina et al., 2021).

El decaimiento en la asociación entre la precipitación y ENSO desde la década de 1970 fue también observado en otras regiones del mundo, por ejemplo, en La India (Kucharski et al., 2007). Por otra parte, de acuerdo a Torralba et al. (2015), en el Noreste de Brasil la relación entre la precipitación y ENSO se ha fortalecido desde la década de 1970. Por lo tanto, un cambio global en la década de 1970 ha modificado los patrones de teleconexión del ENSO afectando su relación con la variabilidad de la precipitación en diferentes regiones del mundo.

En este sentido, Barreiro et al. (2014) indican que la influencia del Pacífico y del Atlántico pueden explicar una buena parte de la transición de décadas más secas a décadas más húmedas sobre el NA durante la mencionada década. Según los resultados obtenidos en este capítulo, el cambio global mencionado también se observa en Rx1 sobre SSA, aunque el foco aquí no estuvo en los valores medios, sino sobre las relaciones Rx1-ENSO y Rx1-SAM. Se mostró que con PDO es suficiente para explicar los cambios en las relaciones mencionadas, es decir, AMO no tiene efecto según los resultados.

Los patrones de anomalías regionales de Rx1 (Figuras 4-6 y 4-7) y anomalías atmosféricas (Figuras 4-8 a 4-13) promovidos por ENSO y SAM cambiaron entre fases de PDO. Estos resultados indican que la no estacionariedad de las relaciones Rx1-ENSO y Rx1-SAM se debe a cambios en los patrones de circulación inducidos por ENSO y SAM entre fases de PDO. Es conocido que los patrones de temperatura superficial del mar y de circulación atmosférica en el Pacífico tropical relacionados a PDO son similares a los del ENSO, aunque con una mayor extensión meridional en el lado este del Pacífico (Mantua y Hare, 2002). Por lo tanto, es esperable una modificación de la respuesta de la circulación global y los patrones de lluvia al ENSO bajo diferentes fases de PDO. En este sentido, Andreoli y Kayano (2005) muestran que las diferencias en la relación entre la precipitación y ENSO en Sudamérica bajo diferentes fases de PDO, se explica mediante cambios en la función de corriente de 200 hPa. Ellos muestran que en los eventos ENSO+ durante las fases frías de PDO una fuerte circulación ciclónica se establece en el sur de Sudamérica. En cambio, en eventos ENSO+ durante las fases cálidas de PDO existen un centro ciclónico sobre el este de Brasil y un débil centro anticiclónico sobre el Sudeste de Sudamérica. Estas diferencias en los patrones inducidos durante ENSO+ en diferentes fases de PDO implican un desplazamiento de la región donde se favorecen las anomalías de precipitación media según las fases de PDO. Los resultados presentados en este capítulo concuerdan con estos patrones descritos (Figuras 4-8 a 4-10). El aporte novedoso del análisis realizado aquí es que, en lugar de analizar la precipitación media, se han relacionado estos patrones a cambios en la relación Rx1-ENSO en SSA. Particularmente, el reanálisis ERA5 muestra que durante PDO- en ENSO+ existen anomalías positivas de z500 y z850 sobre el extremo sur de Sudamérica y anomalías negativas sobre el Atlántico y el NOA que fortalecen el flujo de humedad en capas bajas sobre gran parte del centro y norte de Argentina y promueve altos valores de Rx1. En cambio, en PDO+ hay un corrimiento al norte de las anomalías positivas de z500 y z850 en el sur de Sudamérica y la aparición de anomalías positivas frente a las costas de Brasil, que en su conjunto favorecen la convergencia de humedad hacia el noreste de Argentina, Uruguay y sur de Brasil y altos valores de Rx1.

Respecto a SAM, su relación con Rx1 se ve favorecida durante la fase cálida de PDO. Las fases de PDO modifican los patrones de anomalías de circulación en el Hemisferio Sur asociados a SAM. Por ejemplo, según Wachter et al. (2020), PDO modifica las anomalías de z500 en la región comprendida entre la Antártida y el sur de Sudamérica, en una forma tal que se fortalecen las anomalías positivas en PDO+ en coincidencia con lo que se observa en la Figura 4-11c. Por otra parte, ellos también mostraron que PDO+ promueve anomalías negativas en el Atlántico Sur frente al sur de Sudamérica en coincidencia con lo que muestra

la Figura 4-11c. En este capítulo se mostró que en PDO+ bajo SAM+ las anomalías de z850 consisten de anomalías ciclónicas entre 10-40°S sobre el continente y un aumento de la humedad en capas bajas y de los valores de Rx1 sobre el centro de Brasil, oeste de Paraguay, este de Bolivia y sectores del NOA; lo inverso se observa en el sur de Brasil. Durante PDO- bajo SAM- predominan las anomalías negativas de z850 sobre el Atlántico frente a las costas de Brasil y Argentina promoviendo una disminución de humedad en capas bajas sobre el este de Argentina con valores más bajos de Rx1, mientras que hay un aumento de humedad y valores de Rx1 hacia el sudeste de Brasil.

En ambas fases de PDO se observa que existe una relación Rx1-ENSO sobre el este de Argentina, la cual concuerda con la relación conocida para la precipitación media, estos es, bajo ENSO+ existe mayores precipitaciones, y viceversa durante ENSO-. Hacia el oeste de Argentina, la intensidad de la relación Rx1-ENSO varía entre fases de PDO, siendo más estrecha en PDO-, cuando el flujo de humedad desde el norte se encuentra fortalecido allí. En el análisis para TUC, no se observaron diferencias entre los resultados utilizando los índices Niño 1.2 y Niño 3.4 durante PDO-. Contrariamente, durante PDO+ se observó que en el primer período cálido existe una débil correlación negativa de Rx1 con Niño 3.4 y en el segundo con Niño 1.2. Sin embargo, estas correlaciones son bajas, y en periodos más cortos, comparadas con las obtenidas para SAM, por lo cual en este trabajo se decidió no profundizar el análisis de este resultado.

Los resultados obtenidos para Rx1-SAM en PDO+ son coherentes con la asociación positiva observada entre la precipitación media y SAM sobre el NOA (Cavalcanti et al., 2021; Garbarini et al., 2021) y Brasil (Vasconcellos y Cavalcanti, 2010; Reboza et al., 2021). En PDO+ se establecen anomalías ciclónicas (anticiclónicas) en SAM+ (SAM-) sobre estas regiones que favorecen (inhiben) el aumento de la humedad en capas bajas y afectan a Rx1. Los resultados de este capítulo contribuyen al conocimiento sobre la influencia de SAM sobre la intensidad de la precipitación en SSA, una región del mundo donde el principal foco de los trabajos de investigación está sobre la variabilidad relacionada con ENSO.

Rx1 muestra una importante variabilidad interanual e interdecadal en TUC. La variabilidad interanual se explica parcialmente por la influencia de ENSO y SAM en una relación no estacionaria condicionada por las fases de PDO. Respecto a la variabilidad multidecadal, se observa claramente un cambio de años con valores más bajos de Rx1 hacia valores más elevados desde finales de la década de 1950, y especialmente en las décadas de 1980 y 1990, y con un aparente retorno hacia valores más bajos en la década del 2010. Estos resultados concuerdan con los resultados de Ferrero y Villalba (2019) para la precipitación total de los meses de mayores lluvias en el NOA. Ellos detectaron un salto no significativo hacia mayores lluvias a finales de la década de 1950, un notable salto hacia un período más lluvioso en la década de 1970 y el inicio de un período más seco comenzando entre el 2008 y el 2013. Aunque en este capítulo no se analizó en profundidad este comportamiento multidecadal, se observa que las décadas con lluvias más intensas (1980 y 1990) coinciden con la fase cálida de PDO. En esas décadas, los valores de Rx1 muestran una correlación positiva con SAM y una débil correlación negativa con Niño 1.2. El posterior retorno a

valores de lluvias más débiles coincide con un cambio de fase cálida a fase fría de PDO (promedio de DJFM) a finales de la década del 2000.

Se debe destacar la importancia de analizar la relación entre la variabilidad de la precipitación y los forzantes climáticos, teniendo en cuenta la posible no estacionariedad de las relaciones. Esto se ve claramente en el caso de la serie de precipitación analizada en este capítulo, para la cual cuando se correlaciona Rx1 sin separar la serie en subperíodos, no se obtienen correlaciones estadísticamente significativas o se obtienen valores muy bajos.

Finalmente, en este capítulo se analizaron los datos correspondientes a una única estación meteorológica del NOA debido a su longitud y calidad; sin embargo, se mostró mediante HadEX3 y ERA5, que los cambios en las relaciones Rx1-ENSO y Rx1-SAM y el rol de PDO son parte de cambios observados en una escala mucho mayor a la de la localidad analizada. Por lo tanto, los resultados indican que la variabilidad de la intensidad de la precipitación en la región es generada, en parte, por modos de variabilidad global.

Figuras y tablas (Cap. 4)

Tabla 4-1: Años clasificados según las fases de ENSO (utilizando el índice Niño 3.4) y SAM. La fase fue determinada como positiva (negativa) si el valor promedio de DJFM era mayor (menor) que el percentil 75 (25) de la serie completa (1912-2019).

	Fase negativa (-)	Fase positiva (+)
ENSO	1917 1918 1923 1925 1934 1939 1943 1950 1951 1955 1956 1971 1974 1976 1984 1985 1989 1996 1999 2000 2001 2006 2008 2009 2011 2012 2018	1912 1914 1915 1919 1924 1926 1931 1940 1941 1942 1958 1966 1969 1973 1977 1978 1983 1987 1988 1992 1995 1998 2003 2010 2015 2016 2019
SAM	1912 1913 1914 1917 1919 1922 1923 1924 1925 1926 1929 1931 1932 1933 1937 1939 1943 1945 1949 1950 1958 1965 1966 1967 1969 1975 1977	1951 1955 1960 1962 1963 1974 1982 1989 1990 1994 1995 1996 1997 1998 1999 2000 2002 2007 2008 2009 2012 2013 2014 2015 2016 2018 2019

Tabla 4-2: Períodos de fases positivas y negativas de PDO y AMO individualmente y sus combinaciones.

Fases de PDO y AMO	Períodos	Fases de PDO y AMO	Períodos
PDO+ (56 años)	1922-1944 1978-2006 2011-2014	PDO+ & AMO+ (27 años)	1930-1944 1999-2006 2011-2014

PDO– (43 años)	1916-1921 1945-1977 2007-2010	PDO+ & AMO– (29 años)	1922-1929 1978-1998
AMO+ (51 años)	1930-1964 1999-2014	PDO– & AMO+ (24 años)	1945-1964 2007-2010
AMO– (48 años)	1916-1929 1965-1998	PDO– & AMO– (19 años)	1916-1921 1965-1977

Tabla 4-3: Valores de RHO para Rx1-Niño 1.2, Rx1-Niño 3.4 y Rx1-SAM considerando el periodo 1912-2019 y los subperiodos determinados por: fases de PDO (PDO+ y PDO–), fases de AMO (AMO+ y AMO–) y sus 4 combinaciones. La cantidad de años utilizada para el cálculo de RHO se indica entre paréntesis en cada caso. Solo los valores significativos al 95% se muestran.

Serie considerada	Rx1 vs. Niño 1.2	Rx1 vs. Niño 3.4	Rx1 vs. SAM
Serie completa 1912-2019	-	-	-
PDO+ (56 años)	-0.29	-0.30	0.28
PDO– (43 años)	0.48	0.43	-
AMO+ (51 años)	-	-	-
AMO– (48 años)	-	-	-
PDO+ & AMO– (29 años)	-	-	-
PDO– & AMO+ (24 años)	0.65	0.45	-
PDO+ & AMO+ (27 años)	-	-	-
PDO– & AMO– (19 años)	0.44	0.46	-

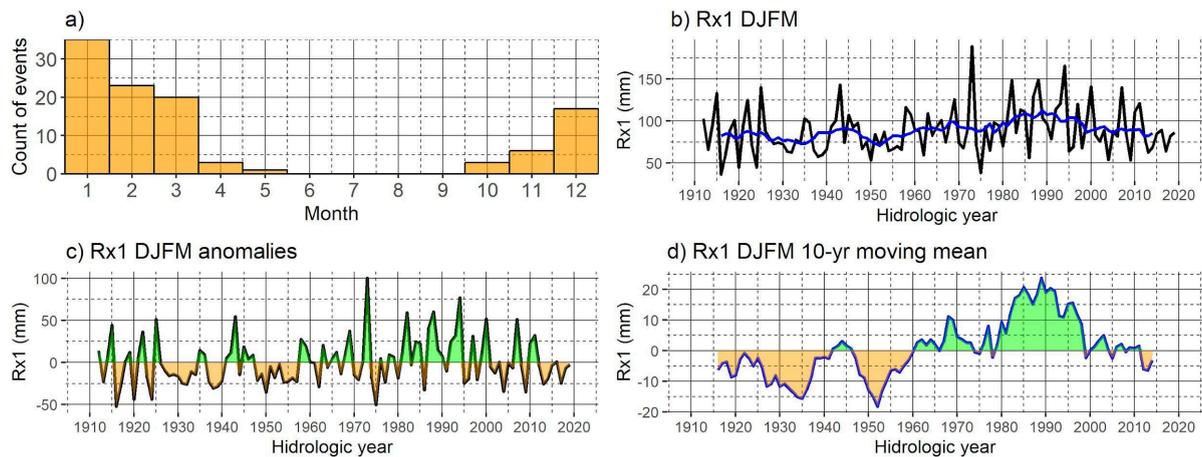


Figura 4-1: a) Cantidad de valores de Rx1 anual según su mes de ocurrencia en la serie 1911-2019. b) Rx1 DJFM (línea negra) y la misma con promedio móvil de 10 años (línea azul). c) Anomalías de Rx1 DJFM (climatología 1912-2019), donde el color indica el signo de las anomalías (naranja = negativa, verde = positiva). d) Como en c), pero para la serie con promedio móvil de 10 años.

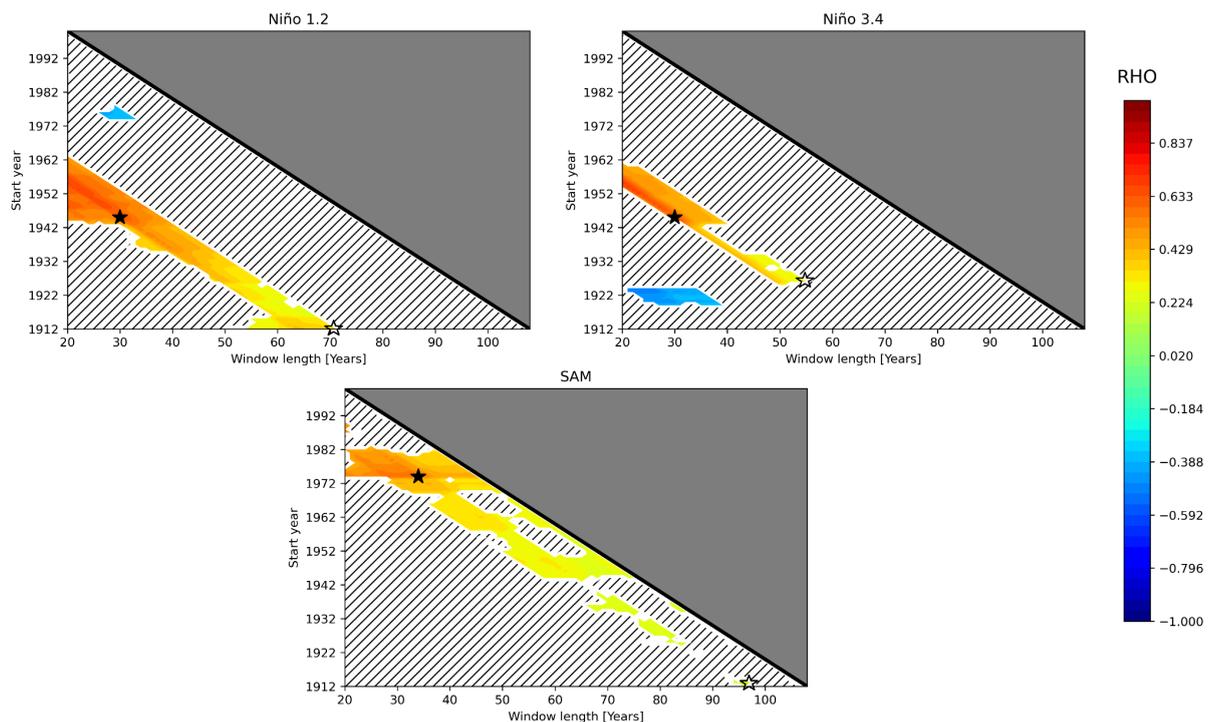


Figura 4-2: Representación de los triángulos para Rx1 vs Niño 1.2 (arriba-izquierda), Rx1 vs Niño 3.4 (arriba-derecha) y Rx1 vs SAM (abajo). En el eje vertical se indica el año inicial de la ventana y en el horizontal se indica la longitud de la misma. El color indica los valores de RHO en cada caso. La estrella color negro indica la ubicación del PmPV y la estrella no coloreada corresponde a la ubicación del PMWL. Solo los valores de RHO significativos al 95% se muestran en color.

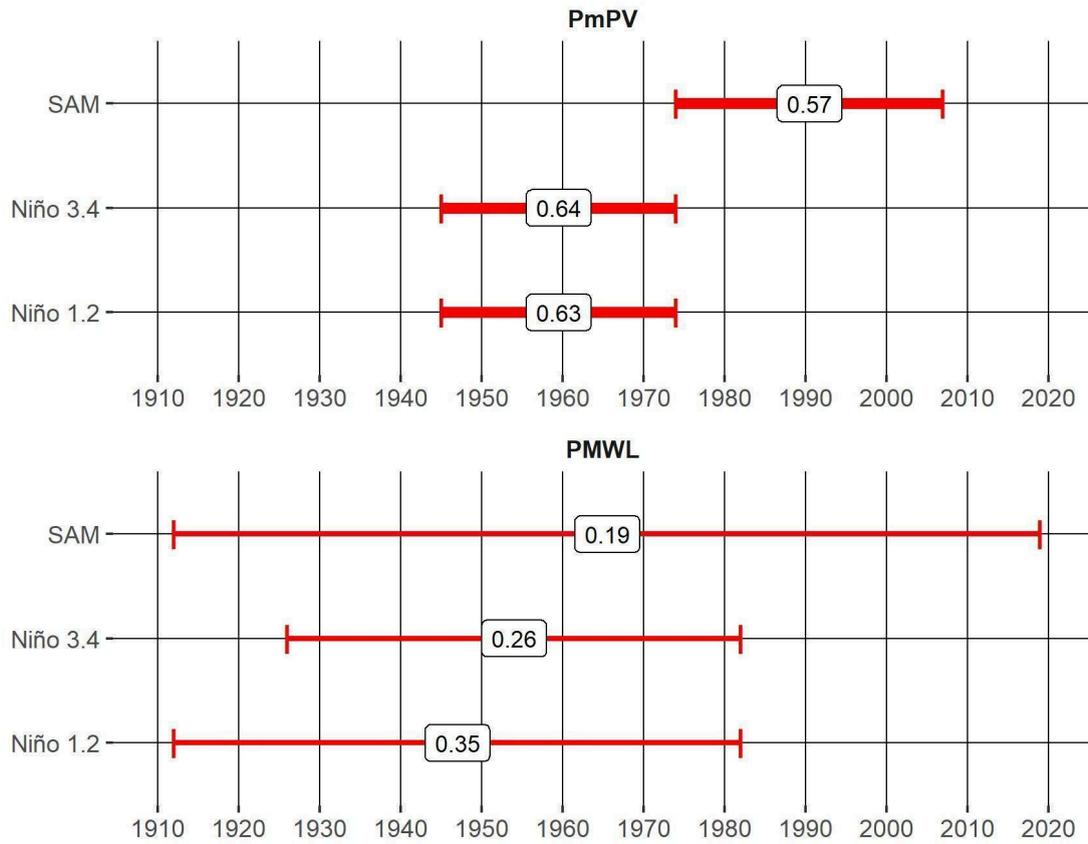


Figura 4-3: PmPV (arriba) y PMWL (abajo) obtenidos de las matrices de correlación móvil (también indicados con estrellas en la Figura 3-2) para Rx1 vs Niño 1.2, Rx1 vs Niño 3.4 y Rx1 vs SAM. El inicio y el final de la línea roja indican el inicio y el final de cada periodo (PmPV y PMWL en cada caso). Sobre las líneas se indica el valor de RHO para cada periodo.

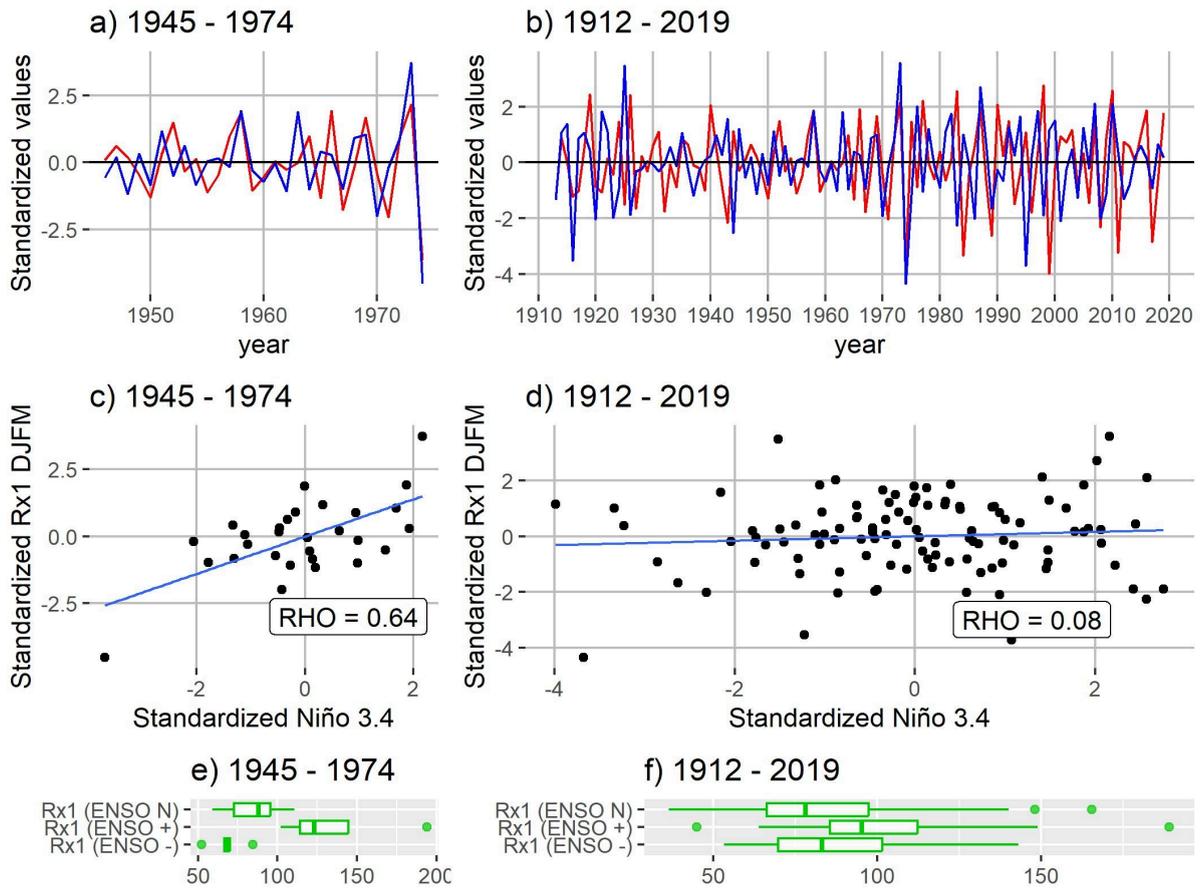


Figura 4-4: Series estandarizadas de Rx1 (azul) y Niño 3.4 (rojo) durante: a) PmPV, y b) el periodo completo. Dispersión de Rx1 vs Niño 3.4 estandarizados y con sus correspondientes ajustes lineales para: c) PmPV, y d) el periodo completo. Las tendencias lineales de Rx1 y Niño 3.4 fueron removidas previo a graficarlas y correlacionar entre sí. Diagramas de caja para Rx1, separando los valores según las fases del ENSO (N: neutral, +: ENSO+ y - : ENSO-), para: e) PmPV, f) el periodo completo.

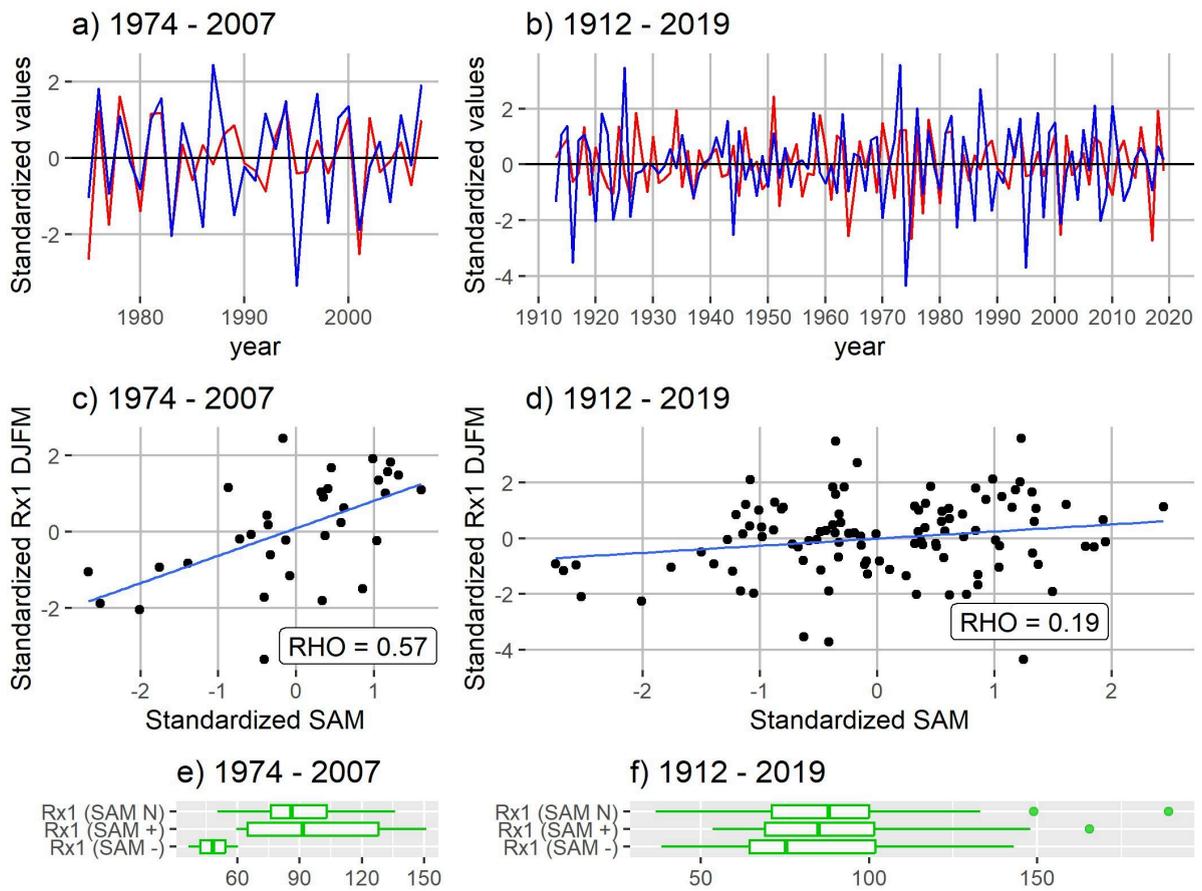


Figura 4-5: como en la Figura 3-4, pero para Rx1 vs SAM.

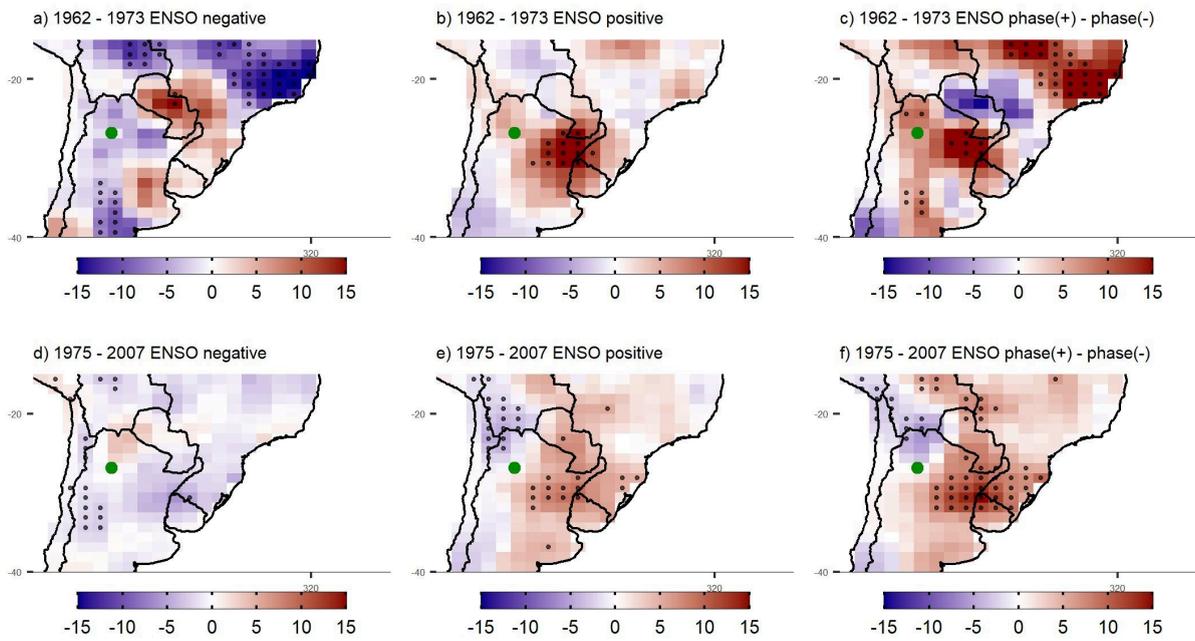


Figura 4-6: Anomalías de Rx1 (climatología 1962-2019) según las fases de ENSO para los períodos: (a,b) 1962-1973 y (d,e) 1975-2007, según HadEX3. Diferencias entre Rx1 para ENSO+ y ENSO- en los períodos: (c) 1962-1973 y (f) 1975-2007. Los puntos indican zonas donde la diferencia es estadísticamente significativa al 95% según test t de Student para diferencias en la media de dos muestras con varianzas desiguales. El punto verde indica la ubicación de TUC.

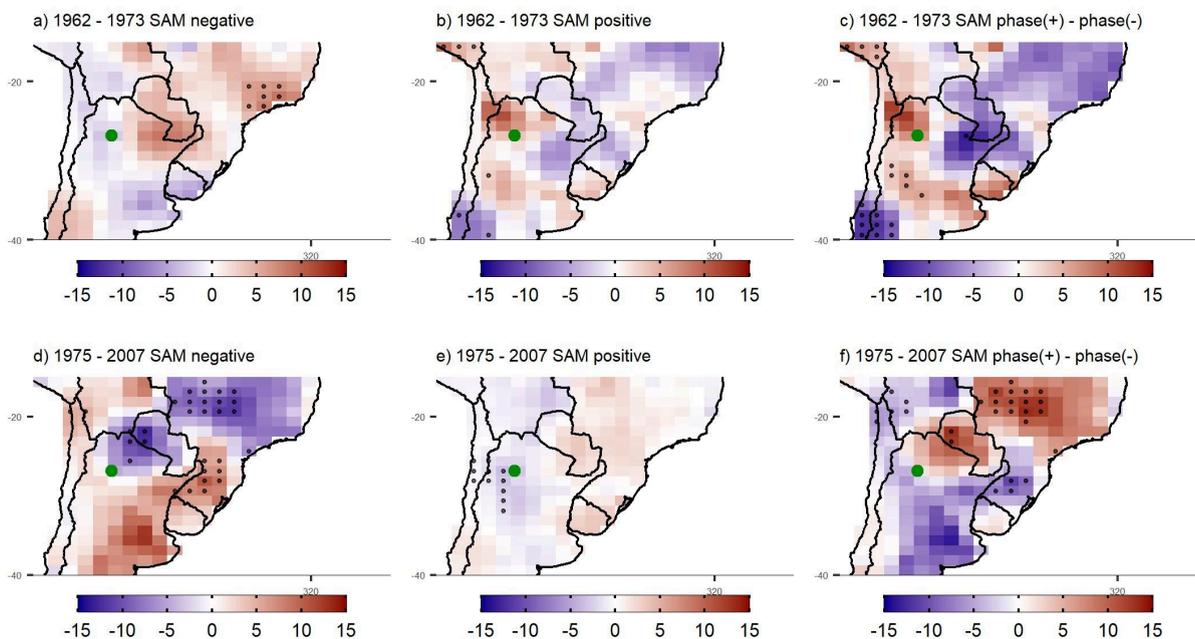


Figura 4-7: como la Figura 4-6, pero para SAM.

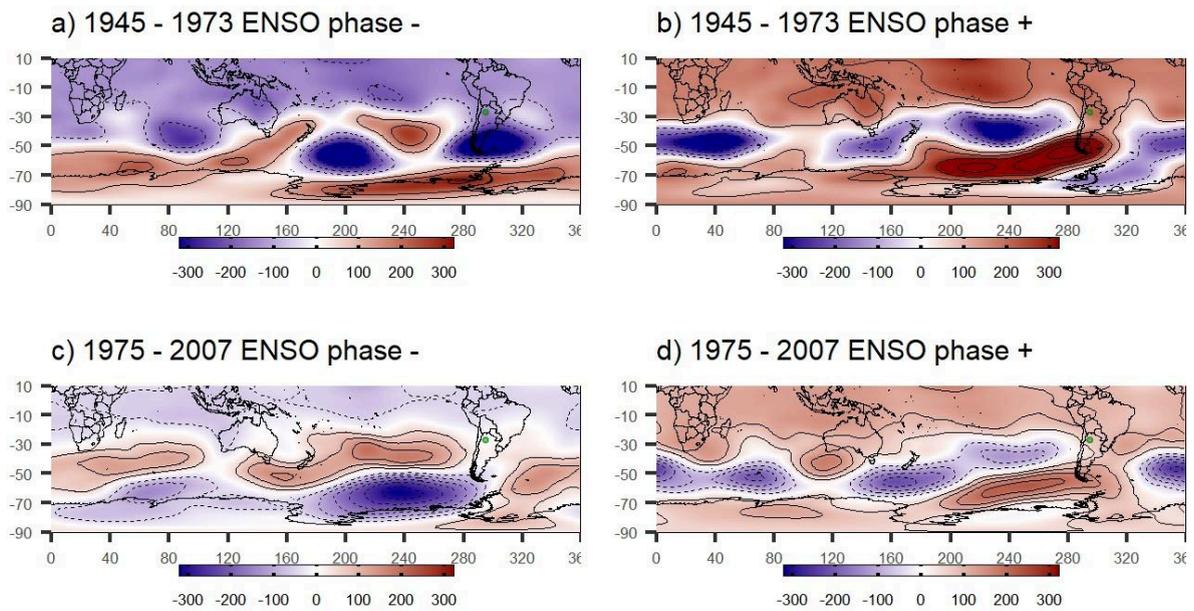


Figura 4-8: Anomalías de z500 (climatología 1941-2019) según las fases de ENSO para los períodos: (a,b) 1945-1973 y (c,d) 1975-2019, según ERA5. El punto verde indica la ubicación de TUC.

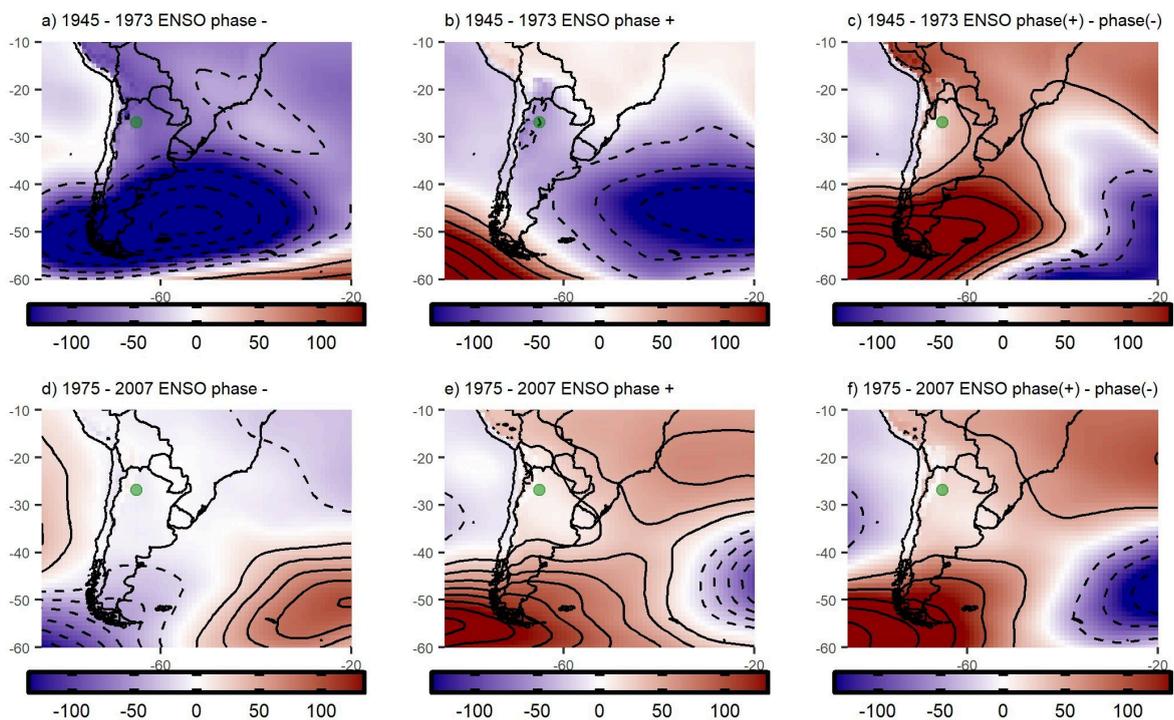


Figura 4-9: (a,b,d,e) Como la Figura 4-8, pero para anomalías de z850; (c,f) Diferencias de z850 entre ENSO+ y ENSO-.

Figura 4-10: Como la Figura 4-9, pero para anomalías de q850 (color) y del vector viento en 850 hPa (flechas).

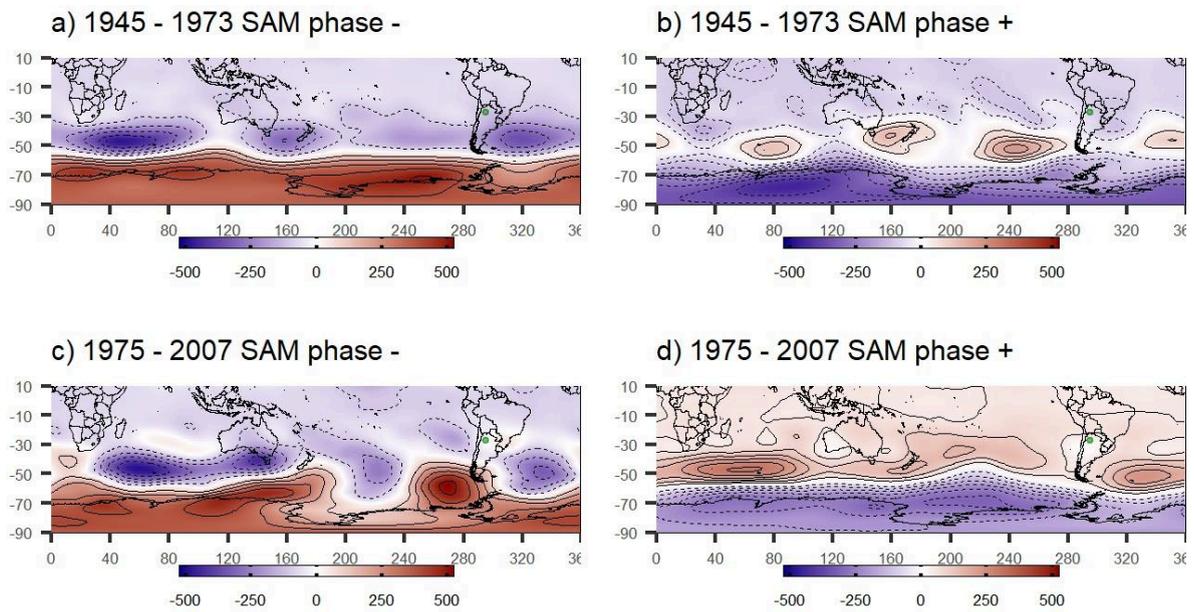


Figura 4-11: Anomalías de z500 (climatología 1941-2019) según las fases de SAM para los periodos: (a,b) 1945-1973 y (c,d) 1975-2019, según ERA5. El punto verde indica la ubicación de TUC.

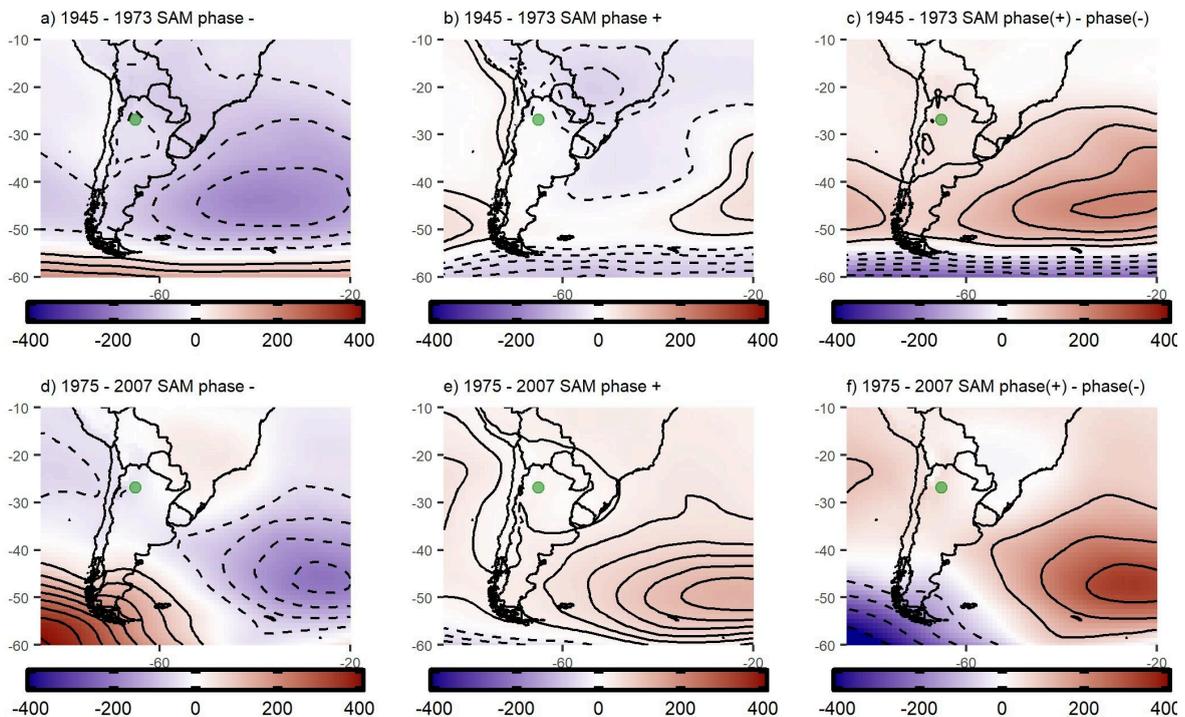


Figura 4-12: (a,b,d,e) Como la Figura 4-11, pero para anomalías de z_{850} ; (c,f) Diferencias de z_{850} entre SAM+ y SAM-.

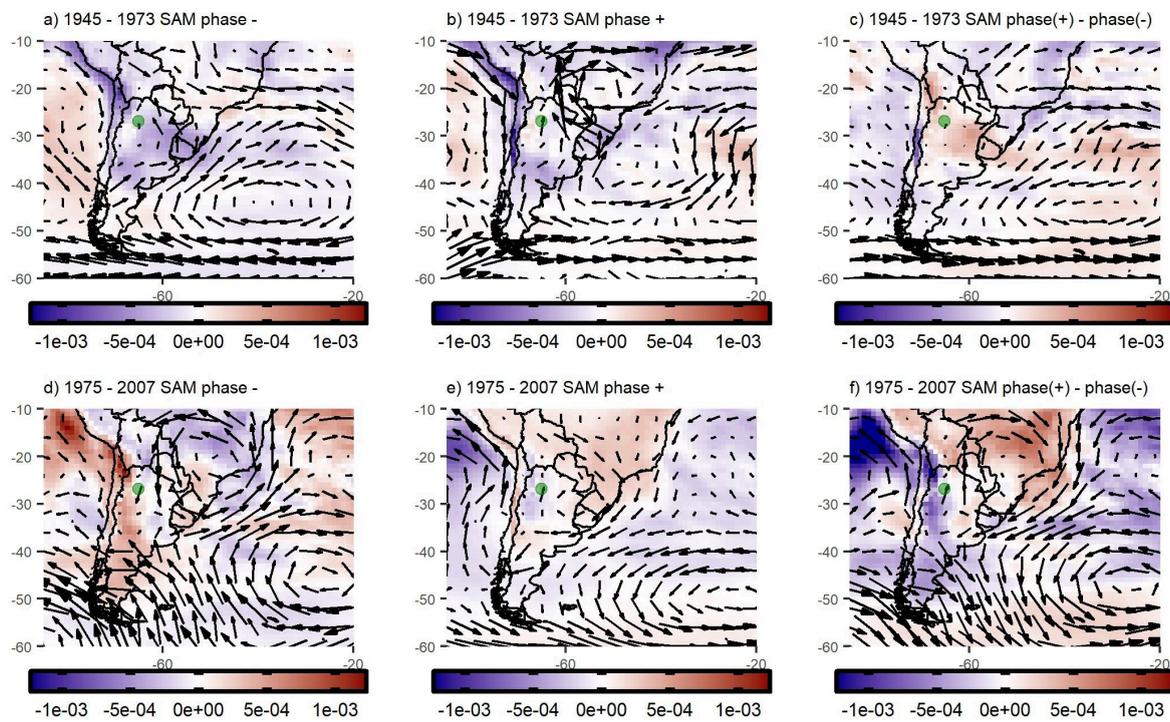


Figura 4-13: Como la Figura 4-12, pero para anomalías de q_{850} (color) y del vector viento en 850 hPa (flechas).

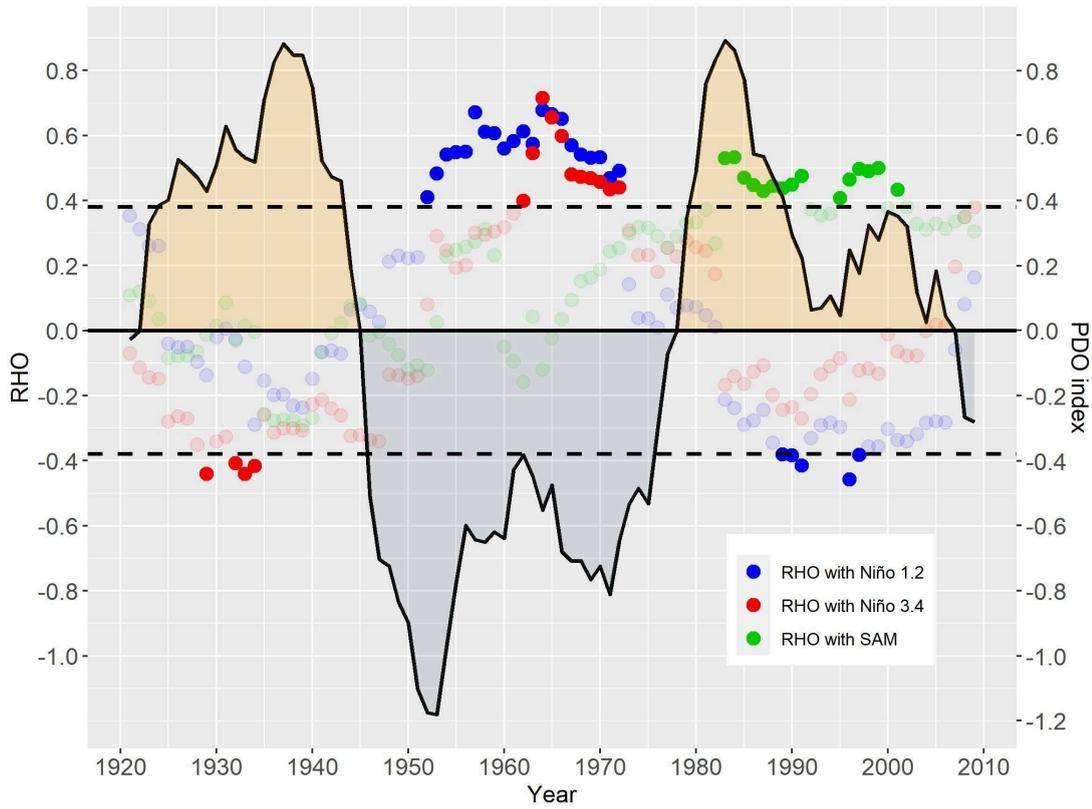


Figura 4-14: Valores de RHO (eje vertical izquierdo) según correlación móvil de 20 años para Rx1 vs Niño 1.2 (puntos azules), Rx1 vs Niño 3.4 (puntos rojos) y Rx1 vs SAM (puntos verdes). Las líneas horizontales punteadas indican el umbral de significancia del 95%, es decir, los valores de RHO entre esas líneas no son significativos y se muestran coloreados ligeramente. Además, se muestra la serie de PDO (eje vertical derecho) con un promedio móvil de 10 años (línea negra), indicando con colores las dos fases (PDO+ y PDO-).

Capítulo 5: El aumento de gases de efecto invernadero como forzante antropogénico de la precipitación extrema y total

Resumen

En este capítulo se analizan datos de precipitación diaria simulados por 16 modelos de circulación global pertenecientes a la 6ta fase del Proyecto de Intercomparación de Modelos Acoplados (CMIP6). Primero se realizó una evaluación de la capacidad de los modelos para representar los valores climatológicos promedios de precipitación máxima diaria (Rx1) y la total (TOT) estacional y anual en el NOA. El objetivo fue evaluar el desempeño de los modelos y seleccionar aquellos que resultaron mejores. Luego de esto, se obtuvieron las proyecciones de precipitación hasta finales del siglo XXI bajo dos trayectorias socioeconómicas compartidas (SSP) en relación al aumento de gases de efecto invernadero (GHG). Los dos SSP están relacionados a un calentamiento global intermedio y elevado, respectivamente. El objetivo fue determinar la respuesta de la precipitación ante diferentes niveles de aumento de GHG. Se compararon resultados obtenidos según los mejores modelos y según los de bajo desempeño, con el objetivo de determinar si seleccionando los mejores modelos se reduce la incerteza que surge por las discrepancias en el signo y magnitud de las proyecciones de los mismos. Finalmente, se analizó la relación entre Rx1 y TOT, tanto para el período climatológico como para las proyecciones a futuro, para determinar si los cambios en una métrica se traducen en cambios en la otra. Los resultados muestran que para Rx1 y TOT hay una tendencia de los modelos a sobreestimar sus valores en el NOA y que solo el modelo IPSL-CM6A-LR muestra un mejor desempeño para ambas métricas de precipitación simultáneamente. En algunos casos, el acuerdo entre los modelos acerca de los cambios proyectados hacia el futuro mejora al filtrar los de menor desempeño y al considerar el escenario de mayor calentamiento global. Hacia finales del presente siglo, se proyecta un aumento generalizado de Rx1 en la región, lo que implica un aumento en el riesgo de inundaciones. A su vez, se proyecta una disminución de TOT en invierno y primavera, lo cual implica un aumento del riesgo por déficits hídricos para actividades socio-económicas dependientes de la precipitación en la transición de la estación seca a la estación húmeda. Comparativamente, se encontró que Rx1 es una variable más sensible a incrementarse como consecuencia del calentamiento global, por lo que se espera que su aporte a TOT aumente hacia finales de siglo.

5.1. Introducción

En términos generales, los modelos climáticos predicen que, junto con el aumento de la temperatura global, habrá una intensificación general del ciclo hidrológico, lo que resultará en un incremento de la precipitación en la mayor parte del planeta. Sin embargo, también indican una disminución de la precipitación en ciertas áreas subtropicales (Meehl et al., 2007). De esta manera, regiones con cuantiosas lluvias podrían volverse aún más lluviosas, mientras que en las zonas áridas se acentuará la aridez (Biasutti, 2013). Particularmente, los eventos de precipitación extrema están experimentando un aumento global en consonancia con el incremento de la humedad atmosférica asociado al calentamiento global, e incluso algunas regiones están superando las tasas esperadas (Fowler et al., 2021). En este contexto, las ciudades del NOA podrían estar más expuestas a los riesgos asociados a estos eventos extremos, ya que las mismas son vulnerables a sufrir inundaciones. Por lo tanto, para reducir los riesgos a futuro, los tomadores de decisiones de la región requieren de proyecciones confiables acerca de los cambios en la precipitación en respuesta al calentamiento global. En este sentido, el Proyecto de Intercomparación de Modelos Acoplados (CMIP) ofrece una gran oportunidad para obtener proyecciones de variables climáticas hasta el final del presente siglo en respuesta al incremento de emisiones de GHG y el consecuente calentamiento global.

La fase más reciente del CMIP es su Sexta fase (CMIP6; Eyring et al., 2016), la cual incorpora importantes mejoras respecto a la fase 5 (CMIP5). Estas mejoras incluyen mayores resoluciones horizontales y verticales, mejoras en la representación de procesos físicos y ciclos biogeoquímicos, esquemas de parametrización refinados y nuevos escenarios de emisión para proyecciones futuras.

A la fecha, no se ha realizado una evaluación de los modelos climáticos del CMIP con foco exclusivamente en el NOA y en la precipitación extrema. En los últimos años, se han realizado algunos estudios sobre tendencias en la precipitación en regiones de Argentina utilizando CMIP5 (Vera and Diaz, 2015; Diaz and Vera, 2017; Lovino et al., 2018; Gulizia et al., 2022), los cuales fueron principalmente enfocados sobre el Sudeste de Sudamérica (SESA). Mindlin et al. (2023) identificaron que la definición de SESA es bastante diversa entre los trabajos existentes y abarca principalmente el este de Argentina (e.g., Vera and Diaz, 2015; Mindlin et al. 2021). Sin embargo, el NOA tiene un régimen de precipitación diferente al del este de Argentina (Capítulo 2) y, por lo tanto, es necesaria una evaluación regional de los modelos. Esto es debido a que no todos los modelos tienen necesariamente una buena performance para representar la precipitación en la región. Un ejemplo de esto puede verse en Penalba y Rivera (2016), donde se muestra que los cambios proyectados en la precipitación en el NOA tienen grandes incertidumbres debido a las discrepancias existentes entre los diferentes modelos del CMIP5. Ellos argumentan que esto puede atribuirse a los sesgos existentes en la representación de los valores medios y la estacionalidad de la precipitación.

Respecto a SESA, importantes tendencias en la precipitación de verano han sido observadas durante el siglo XX y fueron atribuidas en parte a la influencia humana (Vera and Díaz, 2015; Díaz et al., 2021). En un trabajo reciente de Midlin et al. (2023), se muestra que hay una gran discrepancia entre los modelos del CMIP6 acerca de los signos y magnitud de los cambios

proyectados bajo el escenario de mayor calentamiento global. Como resultado de esto, la señal de cambio es robusta solo en unos pocos puntos de grilla. Ellos muestran que en SESA la media del ensamble multimodelo (MME) indica un aumento de la precipitación, pero, en contraste, existen algunos modelos que muestran una disminución de la misma. Respecto a estas discrepancias, de acuerdo a Knutti (2010) y Díaz et al. (2021), remover los modelos que tienen una baja performance para representar el clima actual mejora el acuerdo, lo que resulta en tendencias más robustas acerca de los cambios futuros.

El objetivo general de este capítulo es contribuir al conocimiento acerca del desempeño y las proyecciones de los modelos del CMIP6 respecto a la precipitación en el NOA. Los objetivos específicos son:

- evaluar la capacidad de los modelos del CMIP6 para simular la climatología de Rx1 y TOT estacional y anual
- determinar los cambios proyectados en los valores medios bajo diferentes escenarios de calentamiento global, distinguiendo entre modelos con alto y bajo desempeño
- analizar las coincidencias y discrepancias entre los cambios proyectados por los modelos para obtener una medida de la incertidumbre en las proyecciones
- determinar si filtrando los mejores modelos disminuye la incertidumbre asociada a las discrepancias entre signo y magnitudes de las proyecciones

5.2. Datos de precipitación diaria

5.2.1. Observaciones

Se utilizaron datos reticulados de precipitación diaria correspondientes al *CPC Global Unified Gauge-Based Analysis of Daily Precipitation* (CPC) del *Climate Prediction Center* de la NOAA (disponible en <https://psl.noaa.gov/data/gridded/data.cpc.globalprecip.html>). Se seleccionó este conjunto de datos como referencia para evaluar la performance de los modelos correspondientes al CMIP6 para representar los patrones de precipitación media de Rx1 y TOT en el NOA. CPC (Xie et al., 2010) es un conjunto de cobertura global (solo en tierra) basado en observaciones de precipitación de estaciones meteorológicas, con una resolución horizontal de 0,5° x 0,5° y con cobertura temporal diaria desde el 1 de enero de 1979 a la actualidad. CPC reproduce adecuadamente los cambios de largo plazo observados en la precipitación, a pesar de que la cantidad de estaciones utilizadas para su construcción cambia en el tiempo (Xie et al., 2010). Particularmente en el NOA, CPC muestra un acuerdo aceptable con los datos observados en estaciones meteorológicas en las elevaciones por debajo de los 3000 m, mientras que existen discrepancias por encima de dicha altitud (Castino et al., 2017). Esta limitación en zonas elevadas puede estar relacionada a la falta de observaciones en las zonas más elevadas del oeste del NOA (ver Capítulo 2). Olmo y Bettolli (2021) compararon diversos conjuntos observacionales (estaciones meteorológicas, CHIRPS, CPC y MSWEP) para representar algunos índices de precipitación, y concluyeron que para el

NOA CPC muestra la mejor performance con correlaciones más altas y menor sesgo. Por lo tanto, CPC es un conjunto adecuado para ser utilizado como referencia observacional en la región. El análisis de este capítulo se realizó para una subregión del NOA por debajo de los 3000 m (Figura 5-1, recuadro blanco), donde los datos de CPC son más confiables.

5.2.2. Modelos del CMIP6

Se utilizaron datos de precipitación diaria simulados por 16 modelos (Tabla 5-1) de la 6ta fase del Proyecto de Intercomparación de Modelos Acoplados (*Coupled Model Intercomparison Project*, CMIP6). Se analizó el periodo 1980-2014 correspondiente a las corridas históricas de los modelos (*Historical runs*) y las proyecciones para el período 2015-2099 bajo dos Trayectorias Socioeconómicas Compartidas (Shared Socioeconomic Pathways, SSP). El criterio para incluir un determinado modelo en este trabajo fue que contaran con las corridas históricas, SSP2-4.5 y SSP5-8.5 con la inicialización r1i1p1f1. La corrida histórica es útil para evaluar la capacidad de un modelo para simular el clima, incluyendo su variabilidad y las tendencias en escala centenaria (Eyring et al., 2016). Por otra parte, cada SSP representa un escenario integrado de cambios socioeconómicos y clima futuro (Lovino et al., 2021). El SSP2-4.5 supone un desarrollo económico de término intermedio entre los posibles, con un forzante radiativo de 4,5 W/m² en el año 2100 como una consecuencia del aumento de GHG. Por su parte, el SSP5-8.5 supone un mayor desarrollo basado fuertemente en combustibles fósiles con un mayor forzante radiativo de 8,5 W/m². Los SSP2-4.5 y SSP5-8.5 fueron seleccionados debido a que proyectan un calentamiento global intermedio y fuerte, respectivamente, y los mismos están en línea con las tendencias de calentamiento global observadas (de Medeiros and de Oliveira, 2022). Solamente se consideró la corrida r1i1p1f1 por una cuestión de volumen de datos a procesar y, además, porque el objetivo fue obtener una primera aproximación a las proyecciones de los modelos en la región. Los datos fueron obtenidos, en la mayoría de los casos, del *Earth System Grid Federation* (ESGF, <https://esgf-node.llnl.gov/projects/cmip6/>), y en algunos casos del *Copernicus Climate Data Store* (<https://cds.climate.copernicus.eu/>), según la disponibilidad de los modelos. Debido a las diferentes resoluciones espaciales entre los modelos y CPC, se calcularon primero las series de tiempo de Rx1 y TOT para cada modelo en cada punto de grilla, y luego cada uno fue re-grillado a la retícula de CPC mediante una interpolación bilineal, para luego poder realizar una comparación directa. Esta técnica es ampliamente utilizada para comparar simulaciones de precipitación con conjuntos observacionales reticulados (por ejemplo, Penalba y Rivera, 2016; Lovino et al., 2021; de Medeiros y de Oliveira, 2022). Los modelos utilizados se enlistan en la Tabla 5-1.

5.3. Metodología

5.3.1. Evaluación y corrección de sesgo de modelos del CMIP6

Los modelos numéricos que simulan el clima son usualmente afectados por errores sistemáticos, denominados usualmente sesgos, que surgen debido a una incorrecta representación de los procesos físicos, diferentes respuestas a las variaciones de un forzante externo y a errores en las condiciones iniciales (Díaz et al., 2021). Para evaluar la capacidad de los modelos para simular los valores promedios de Rx1 y TOT observados según CPC, se estimó el sesgo de los modelos mediante el error cuadrático medio (RMSE). El RMSE es una métrica comúnmente utilizada en trabajos similares (Lovino et al., 2021; de Medeiros y de Oliveira, 2022), la cual es un indicador de la desviación promedio; la misma da más peso a las desviaciones más grandes sin importar su signo, es decir, sin importar si son desviaciones por exceso o por defecto. Así, los mejores modelos fueron seleccionados como aquellos con los valores más bajos de RMSE, es decir, aquellos con las desviaciones más pequeñas respecto a los valores observados. La selección de los mejores modelos fue realizada por separado para Rx1 y para TOT. El RMSE se define como:

$$RMSE = \left[\frac{1}{n} \sum_{i=1}^n (m_i - o_i)^2 \right]^{1/2}$$

donde:

n = cantidad de puntos de grilla comparados

m_i = valor medio de Rx1 o TOT en el punto de grilla i -ésimo según un dado modelo en su corrida histórica

o_i = valor medio de Rx1 o TOT en el punto de grilla i -ésimo según CPC

Posterior a la evaluación del RMSE, se obtuvieron las proyecciones de Rx1 y TOT en los diferentes SSP. Previo a la estimación de los cambios proyectados, los errores sistemáticos en los valores de Rx1 y TOT de los modelos en las corridas históricas y bajo los SSP fueron corregidos mediante un método de escalado utilizado por Lovino et al. (2021) y de Medeiros y de Oliveira (2022). La corrección fue realizada para cada valor en cada punto de grilla y en cada estación del año. Para corregir los valores de la corrida histórica se utilizó la ecuación:

$$y_i^h = x_{mod,i}^h \frac{y_{obs}^{-h}}{x_{mod}^{-h}}$$

donde:

y_i^h = valor corregido de Rx1 o TOT del año i -ésimo en el período histórico

$x_{mod,i}^h$ = valor de Rx1 o TOT del año i -ésimo de un dado modelo en el período histórico

y_{obs}^{-h} = valor promedio de Rx1 o TOT en el periodo histórico según CPC

x_{mod}^{-h} = valor promedio de Rx1 o TOT en el periodo histórico según un dado modelo

La corrección se basa simplemente en multiplicar un dado valor modelado por un coeficiente que indica la razón entre el valor promedio observado y el promedio modelado durante el período histórico. Este coeficiente es el mismo que se utiliza para el período futuro bajo los SSP, suponiendo que dicho coeficiente no cambiará a pesar de los cambios proyectados en el sistema climático. Por lo tanto, la corrección del error sistemático para los valores futuros se realiza con la siguiente ecuación:

$$y_i^f = x_{mod,i}^f \frac{y_{obs}^{-h}}{x_{mod}^{-h}}$$

donde:

y_i^f = valor corregido de Rx1 o TOT del año i-ésimo en el período futuro bajo un dado SSP

$x_{mod,i}^f$ = valor de Rx1 o TOT del año i-ésimo de un dado modelo en el período futuro bajo un dado SSP.

5.3.2. Análisis de proyecciones de los modelos del CMIP6 bajo diferentes SSP

Se calculó el porcentaje de cambio en los valores medios de Rx1 y TOT en cada punto de grilla y en el promedio regional, tanto para cada modelo como para el ensamble multimodelo (MME). El MME refiere al conjunto total de modelos, y la media del MME se obtiene al promediar los valores simulados por los mismos, resultando en una única serie temporal. Los cambios proyectados se calcularon para la media del futuro cercano (*near-future*, 2025-2049) y para el futuro lejano (*far-future*, 2075-2099) con respecto a la media del período climatológico de referencia (1981-2010). La significancia de los cambios proyectados por cada modelo en cada punto de grilla fue evaluada utilizando test t de Student de diferencia de medias para varianzas desiguales. Por otra parte, fue evaluada la concordancia entre el signo y magnitud de los cambios proyectados por los diferentes modelos y esto se consideró un indicador del grado de incertidumbre en las proyecciones.

5.3.3. Análisis de la relación entre Rx1 y TOT según las observaciones y los modelos del CMIP6

Se analizó la relación entre Rx1 y TOT en el periodo de referencia según las observaciones (CPC) y las simulaciones de los modelos del CMIP6, además se evaluó la evolución de esas relaciones en el futuro bajo los dos SSP considerados. Para esto se compararon los porcentajes de cambio de Rx1 y TOT en cada modelo, en el MME de los modelos seleccionados y en el MME de los no seleccionados bajo los diferentes SSP para determinar si los cambios en ambas variables son similares o no. Por otra parte, se calculó el cociente entre Rx1 y TOT para determinar el porcentaje que Rx1 aporta a TOT en las observaciones y las proyecciones a futuro de esta relación, para determinar si cambiará o no la concentración de la precipitación.

5.4. Resultados y discusión

5.4.1. Valores observados de Rx1 y TOT

En la Figura 5-1 se muestra el NOA (recuadro negro punteado) y una subregión del NOA que fue seleccionada (recuadro blanco) debido a que allí CPC muestra mejor desempeño para representar la precipitación, tal como fue mencionado anteriormente. La subregión seleccionada corresponde a las elevaciones más bajas de la región, principalmente por debajo de los 3000 m, y fue elegida visualmente de manera que abarque la mayor parte de zonas de bajas elevaciones y, a su vez, a las principales ciudades del NOA (puntos negros).

En las Figuras 5-2 y 5-3 se muestra la distribución espacial de los valores medios de Rx1 y TOT en el NA según CPC para el período climatológico de referencia. El rectángulo rojo en las figuras indica la subregión que fue seleccionada para el análisis. En esta subregión se observan los mayores valores de Rx1 y TOT anual, DJF y SON en comparación al resto del NOA; en el NEA se observan valores similares a la subregión del NOA en DJF, mientras que en las otras estaciones del año los valores en el NEA son más elevados, denotando los diferentes ciclos anuales. De aquí en adelante, la expresión “NOA” se utilizará para referir a la subregión del NOA bajo análisis en este capítulo. En la Figura 5-4 se muestra el ciclo anual medio observado de Rx1 y TOT para el período climatológico de referencia en cada punto de grilla del NOA (líneas de colores) y el ciclo promedio regional (línea negra). Se observa que en todos los puntos de grilla existe un ciclo similar, esto es, los mayores valores ocurren en DJF y los menores en JJA.

La Figura 5-2 muestra que los valores anuales de Rx1 en el NOA están entre 20-87 mm en promedio, con los valores más altos sobre el centro y hacia el norte, en concordancia con los resultados del Capítulo 2. Este acuerdo muestra la capacidad de CPC para representar el patrón espacial medio de precipitación observado en la región. Desde un punto de vista estacional, las Figuras 5-2 y 5-4 muestran que sobre el NOA se observa una predominancia de elevados valores (20-80 mm) para Rx1 DJF, similares a los valores anuales, mientras que valores un poco más bajos se observan en MAM (13-58 mm) y SON (9-48 mm) con una

distribución espacial similar. Para JJA, los valores de Rx1 decaen abruptamente (3-20 mm). En cuanto a TOT (Figuras 5-3 y 5-4), los valores anuales están entre 300-1600 mm en el NOA, con el mayor acumulado ocurriendo en DJF (180-680 mm), seguido por MAM (60-410 mm), SON (50-310 mm) y JJA (8-140 mm), con distribuciones espaciales similares a Rx1.

5.4.2. Desempeño de los modelos para representar Rx1 y TOT

En la Figura 5-5 se muestran los diagramas de caja de los valores medios regionales de Rx1 y TOT simulados por los diferentes modelos. Se observa que la mediana de los modelos coincide con los valores medios observados según CPC (puntos azules) solo para Rx1 anual, DJF y MAM. Por lo tanto, en esos casos, la cantidad de modelos que subestiman los valores de Rx1 es la misma que las que sobreestiman y la mediana de los modelos es una buena representación. Para Rx1 JJA y SON, y para TOT en todas las estaciones del año, la mayoría de los modelos sobreestiman los valores observados según CPC (los puntos azules quedan por debajo de la mediana en la Figura 5-5). Por lo tanto, en esos casos se puede afirmar que en general los modelos del CMIP6 simulan condiciones más lluviosas que las observadas según CPC. Esto fue observado también en el CMIP5 para el oeste de Argentina y podría estar relacionado a una mala representación de la topografía o de los flujos de humedad en los modelos (Gulizia y Camilioni, 2015; Penalba y Rivera, 2016). Sin embargo, esto es contrario a lo observado para las llanuras del este de Argentina donde la mayoría de los modelos del CMIP5 y CMIP6 subestiman la precipitación (Díaz y Vera, 2017; Díaz et al., 2021). La cantidad de modelos que sobreestiman los valores es más notable para Rx1 JJA y para TOT anual y SON. Además, algunos valores atípicos (*outliers*) se observan en los boxplots denotando la existencia de algunos modelos con una gran sobreestimación de los valores para Rx1 anual, DJF y MAM, y para TOT DJF y SON.

En la Figura 5-6 se muestra la diferencia entre la media regional observada según CPC y la simulada por cada modelo para Rx1 y TOT. El modelo CanESM5 sobreestima notablemente los valores de Rx1 y TOT DJF en comparación con los otros modelos, con una diferencia respecto a las observaciones de 90 mm para Rx1 y 420 mm para TOT. Por otra parte, CMCC-ESM2 muestra una importante sobreestimación para TOT y Rx1 DJF, MAM y SON. El ACCESS-ESM1.5 muestra una sobreestimación significativa para TOT DJF, MAM y SON, pero en el caso de Rx1 la sobreestimación es más baja en comparación a otros modelos. Los modelos EC-EARTH3-CC y EC-EARTH3-Veg-LR también muestran una importante sobreestimación de los valores de TOT (90-150 mm) en todas las estaciones del año, mientras que tienen un sesgo muy bajo para Rx1 MAM y SON (~2 mm), subestiman moderadamente Rx1 DJF (~10 mm) y sobreestiman Rx1 JJA (~10 mm). Por el contrario, los modelos MPI-ESM1.2-LR y NESM3 muestran una subestimación pequeña de TOT DJF (~20 mm), mientras que subestiman significativamente Rx1 DJF (~25 mm). Para el resto de los casos los sesgos son más bajos. Los resultados descritos muestran que algunos modelos tienen un bajo desempeño para simular la media regional observada de Rx1 y/o TOT. Por lo

tanto, previo a analizar las proyecciones bajo diferentes SSP, los mismos deberían ser filtrados para obtener proyecciones más confiables.

En la Figura 5-7 se muestran los valores de RMSE para Rx1 y TOT para cada modelo y estación del año. El RMSE propuesto tiene en cuenta el sesgo de los modelos en cada punto de grilla del NOA, por lo cual es una métrica más adecuada que simplemente analizar el sesgo en la media regional como se hizo para la Figura 5-6. La mayoría de los modelos muestran el mayor RMSE para DJF, la cual es la estación más lluviosa. En la mayoría de los casos, los valores de RMSE para Rx1 DJF están entre 10-20 mm, excepto para 4 modelos que tienen valores entre 20-30 mm (CMCC-ESM2, GFDL-ESM4, MPI-ESM1-2-LR y NESM3) y 1 que tiene 60 mm (CanESM5). Las distribuciones de los RMSE para los modelos en las otras estaciones del año son similares, aunque con valores más bajos a medida que la estación es más seca (MAM 8-23 mm, SON 6-24 mm y JJA 3-14 mm de RMSE). Por lo tanto, en general para Rx1, mientras más lluviosa es la estación del año, mayor RMSE tienen las simulaciones de los modelos. Como regla para seleccionar los modelos con el mejor desempeño para representar los valores climatológicos de Rx1, se decidió elegir aquellos con al menos 2 estaciones del año donde el RMSE esté por debajo de 10 mm y las restantes estaciones con RMSE por debajo de 20 mm. Estos umbrales fueron determinados mediante una inspección visual de la distribución de puntos en la Figura 5-7 y teniendo en cuenta que el desempeño debe ser aceptable para todas las estaciones del año. Por lo tanto, siguiendo este criterio, los modelos seleccionados por su desempeño para Rx1 fueron EC-Earth3-CC, EC-Earth3-Veg-LR e IPSL-CM6A-LR (flechas en Figura 5-7). Los dos primeros tienen valores similares de RMSE (6-15 mm), con los valores más bajos para SON, seguido por MAM, JJA y DJF, en ese orden. Mientras tanto, el modelo IPSL-CM6A-LR tiene valores de RMSE entre 4-15 mm, pero con los valores más bajos para JJA, seguido por SON, DJF y MAM.

Como para Rx1, en el caso de TOT la mayoría de los modelos tienen los mayores RMSE para las estaciones más lluviosas, especialmente en DJF. Para DJF, 7 modelos tienen un RMSE entre 100-200 mm, otros 7 entre 200-300 mm y 2 modelos un RMSE de alrededor de 500 mm (CanESM5 y CMCC-ESM2). Las otras estaciones del año tienen valores más bajos de RMSE, siendo de 60-250 mm para MAM, 50-310 mm para SON y 20-170 mm para JJA. Observando la distribución de los valores de RMSE para seleccionar los modelos con el mejor desempeño para TOT, se decidió elegir aquellos modelos con al menos 3 estaciones del año (MAM, JJA y SON) con RMSE por debajo de 100 mm, y 1 estación (DJF) por debajo de 200 mm. Los modelos seleccionados resultaron GFDL-ESM4, INM-CM4-8, INM-CM5-0 e IPSL-CM6A-LR. Los 4 modelos seleccionados tienen valores de RMSE de ~30 mm para JJA, mientras que un RMSE entre 50-100 mm para MAM y SON, y entre 110-180 mm para DJF.

Según lo descrito, el desempeño de los modelos en el NOA depende de la métrica de precipitación analizada. Se debe destacar que el modelo IPSL-CM6A-LR, a diferencia de los otros modelos, es el único que muestra un desempeño relativamente mejor tanto para Rx1 como para TOT, por lo que es el modelo más recomendable para estudiar simultáneamente estas métricas de precipitación en el NOA; aunque a pesar de esto se debe tener cuidado

debido al sesgo que presenta el mismo. Este resultado coincide con los resultados de Penalba y Rivera (2016) y Díaz et al. (2021), quienes muestran que el IPSL-CM5A-LR (versión anterior de IPSL-CM6A-LR) tiene un sesgo más bajo que otros modelos para representar TOT en el NOA y zonas cercanas. Similarmente, Díaz et al. (2021) encuentran que el GFDL-ESM2 también tiene un desempeño mejor que otros modelos para representar TOT DJF, en coincidencia con el resultado obtenido aquí para la nueva versión de este modelo (GFDL-ESM4). En cuanto a los modelos EC-EARTH3-CC y EC-EARTH3-Veg-LR, Díaz et al. (2021) indican que el EC-EARTH3 (de la misma familia de los modelos mencionados) subestima significativamente TOT DJF sobre el este de Argentina, mientras que en este trabajo enfocado sobre el NOA se observa que hay una sobreestimación. Por otra parte, aquí se obtuvo que dichos modelos están entre los que tienen menor sesgo al representar Rx1 en el NOA. Finalmente, el modelo INM-CM-4-8 en el CMIP6 muestra buen desempeño en coincidencia con los resultados de Penalba y Rivera (2016) que realizaron el análisis usando datos del CMIP5; adicionalmente aquí se encontró que el INM-CM-5-0 también tiene un buen desempeño. La búsqueda de las causas del mejor desempeño de algunos modelos por sobre otros debe ser abordada en futuros trabajos, debido a que esto excede al objetivo propuesto aquí. Esto podría realizarse, por ejemplo, mediante un análisis de la representación en los modelos de los patrones típicos de circulación asociados a la precipitación (Olmo et al., 2022).

5.4.3. Cambios proyectados en Rx1

En la Figura 5-8 se muestran los cambios proyectados en la media regional de Rx1 para el futuro cercano (2025-2049) y el futuro lejano (2075-2099) respecto al período climatológico de referencia (1981-2010); se muestra para los SSP2-4.5 y SSP5-8.5, y distinguiendo los modelos seleccionados por su buen desempeño, de los no seleccionados. Para el futuro cercano hay discrepancias entre los modelos para Rx1 anual y DJF. En estos casos, algunos modelos proyectan un incremento y otros no proyectan cambios. La excepción son los modelos seleccionados en el SSP5-8.5, los cuales concuerdan en proyectar que no habrá cambios en la media de Rx1 DJF. Por otra parte, para Rx1 MAM, JJA y SON, en ambos SSP, existe un mayor acuerdo entre los modelos en no proyectar cambios en la media. Para el futuro cercano, en general, el acuerdo entre los modelos sobre el signo y magnitud de los cambios proyectados no cambia cuando se consideran los modelos seleccionados (puntos azules en Figura 5-8).

Por otra parte, para el futuro lejano, los 3 modelos seleccionados proyectan un incremento de Rx1 anual bajo ambos SSP; en cambio, los modelos no seleccionados muestran discrepancias, proyectando un incremento en la mayoría de los casos (8 de 13) y cambios nulos en los restantes (5 de 13). Los incrementos proyectados en Rx1 anual están entre 8-16% en los modelos seleccionados bajo el SSP2-4.5 y entre 17-35% bajo el SSP5-8.5. Por lo tanto, la magnitud del incremento proyectado por los modelos seleccionados se duplica aproximadamente en el escenario de mayor calentamiento global respecto al escenario de calentamiento intermedio. En cuanto a Rx1 DJF, los modelos seleccionados concuerdan en la

proyección de un incremento, pero solamente para el escenario de mayor calentamiento, esto es, el SSP5-8.5, con una magnitud similar al caso de Rx1 anual. En el caso de los no seleccionados, la mayoría proyecta un incremento en Rx1 DJF en ambos SSP, especialmente en el SSP5-8.5 (10 de 13 modelos), con magnitudes similares a los seleccionados. Para Rx1 MAM y SON existen mayores discrepancias acerca de los cambios proyectados, tanto en los modelos seleccionados como no seleccionados, por lo que prevalece la incertidumbre. Para Rx1 JJA bajo el SSP2-4.5 los modelos seleccionados concuerdan en proyectar cambios nulos, pero para los modelos no seleccionados no hay acuerdo; en cuanto al SSP5-8.5 hay discrepancias tanto en modelos seleccionados como no seleccionados. Se puede concluir que, para el promedio regional, al filtrar del análisis los modelos con bajo desempeño se observó una mejora en el consenso entre las las proyecciones de cambios solo para Rx1 anual y DJF hacia el futuro lejano.

En la Figura 5-9 se muestra la distribución espacial de la media del MME de los cambios proyectados para el futuro lejano en ambos SSP, distinguiendo modelos seleccionados y no seleccionados. Se muestra el futuro lejano ya que es el que muestra mayores cambios proyectados y con mayor consenso según el análisis anterior. Los modelos seleccionados concuerdan en un incremento en Rx1 anual en ambos SSP en la mayor parte de la región; en el SSP5-8.5, el de mayor calentamiento global, el incremento abarca a toda la región y tiene una mayor magnitud promedio (25-50%) en comparación al SSP2-4.5 (10-22%). En el caso de los modelos no seleccionados, la mayoría de los modelos proyecta un incremento de Rx1 anual en la mayor parte de la región en ambos SSP, siendo 5-13% en el SSP2-4.5 y de 11-23% en el SSP5-8.5. En ambos casos, para modelos seleccionados y no seleccionados, se observa que en el escenario de mayor calentamiento global hay un incremento en la extensión espacial y magnitud de los aumentos de Rx1 anual. Por otra parte, los modelos seleccionados proyectan incrementos porcentuales de casi el doble que los modelos no seleccionados. En el caso de Rx1 DJF, los resultados son similares al caso de Rx1 anual. Para Rx1 MAM, el patrón espacial es similar al de Rx1 anual, pero con menor extensión y una disminución en la cantidad de puntos de grilla en los cuales el 100% de los modelos coincide en proyectar incrementos. En el caso de SON, se proyectan aumentos de Rx1 en el norte de la región, principalmente en el SSP5-8.5, y como en los casos anteriores, el incremento promedio es mayor según los modelos seleccionados (11-33%) que según los no seleccionados (7-14%). En cuanto a Rx1 JJA, en su mayoría los modelos seleccionados y no seleccionados proyectan una disminución en el norte y este de la región principalmente en el SSP5-8.5, con valores de 17-38% según los modelos seleccionados y de 10-24% según los modelos no seleccionados. Los resultados obtenidos para Rx1 DJF, MAM y SON son coherentes con otros resultados reportados para el este de Argentina que indican un incremento de la lluvia máxima de 5 días consecutivos (Rx5) debido al calentamiento global (Gulizia et al., 2022). Por otro lado, se observan algunas discrepancias entre el análisis del promedio regional y el análisis espacial, debido a que en algunos casos (Rx1 MAM y SON) los cambios están acotados a solo algunos sectores del NOA. Por lo tanto, es recomendable complementar el análisis promedio regional con un análisis sobre la distribución espacial de los cambios, tal como se mostró aquí.

Por lo tanto, para Rx1 en todas las estaciones del año, el análisis espacial muestra que el consenso entre los modelos y la extensión de los cambios proyectados aumenta en el escenario de mayor calentamiento global (SSP5-8.5), y además, que la magnitud promedio de los cambios proyectados es mayor en el MME de los modelos seleccionados. Estos resultados indican que a mayor calentamiento global existirán mayores riesgos futuros asociados a Rx1, y por otro lado, que estos riesgos podrían ser subestimados si no se realiza una preselección de los modelos con mejor desempeño en la región. La proyección de incrementos de Rx1 implica que aumentará el riesgo de inundaciones sobre casi todo el NOA en DJF y en menor medida en MAM, mientras que en SON esto se espera solo en el norte bajo el escenario de mayor calentamiento.

El mayor porcentaje de incremento en Rx1 regional corresponde a los valores anuales en el SSP5-8.5 hacia el futuro lejano con valores de 17-35% según los modelos seleccionados, la cual es una tasa de incremento similar a la proyectada en zonas de tierra del hemisferio sur (12-39%) en modelos del CMIP6 (Seungmok et al., 2023). Sin embargo, cuando se analizan los puntos de grilla individualmente, las tasas de incremento son superiores a estos valores, indicando la existencia de importantes variaciones locales. Las causas físicas del incremento de la precipitación como efecto del calentamiento global antropogénico son las asociadas al aumento de la humedad atmosférica (contribución termodinámica) y a los cambios en la circulación (contribución dinámica) (Pfahl et al., 2017). La primera contribución genera un patrón global homogéneo de aumento de la precipitación en una tasa similar al aumento de la humedad atmosférica, mientras que la segunda contribución genera diversas respuestas regionales que refuerzan o atenúan los impactos de la primera. El promedio regional de aumento de Rx1 anual en el NOA está en línea con los resultados de Seungmok et al. (2023) para el promedio de zonas de tierra del hemisferio sur. Ellos además muestran que la principal contribución a las tendencias corresponde a la contribución termodinámica, con una menor contribución dinámica. Las coincidencias en las tasas de incremento proyectadas para el promedio regional del NOA con las del hemisferio sur implican que ambas responden a las mismas causas, esto es, los aumentos proyectados para Rx1 se deben en gran medida al aumento de la humedad consecuencia del calentamiento global.

5.4.4. Cambios proyectados en TOT

En la Figura 5-10 se muestran los cambios proyectados en la media regional de TOT. Para TOT anual en el SSP2-4.5, existen grandes discrepancias en el signo del cambio proyectado entre los modelos tanto seleccionados como no seleccionados. Por otra parte, para el SSP5-8.5 la mayoría de los modelos no seleccionados proyecta un incremento de TOT anual en el futuro cercano (8 de 12 modelos) con valores de 2-7% y para el futuro lejano (10 de 12 modelos) de 3-21%, evidenciando una gran dispersión entre ellos; en el caso de los modelos seleccionados, los mismos no muestran acuerdo acerca del signo de los cambios proyectados.

Para TOT DJF, la mayoría de los modelos, seleccionados y no seleccionados, proyectan un incremento en el SSP5-8.5 en ambos períodos futuros; los valores proyectados tienen menos

dispersión en el caso de los modelos seleccionados que muestran un incremento de 3-10% en ambos períodos, mientras los no seleccionados muestran valores de 3-25% según el modelo. En cambio, para el SSP2-4.5, solo en el caso del futuro lejano en los modelos no seleccionados hay un acuerdo acerca de un incremento de entre 2-11%, mientras los seleccionados no muestran acuerdo entre ellos.

Para TOT MAM, los modelos no seleccionados concuerdan en su mayoría en proyectar un incremento de los valores en ambos SSP y períodos futuros, con los mayores cambios hacia el futuro lejano bajo el SSP5-8.5 (5-30%); sin embargo, los modelos seleccionados proyectan un incremento de 4-20% en el SSP2-4.5, pero muestran importantes discrepancias en el SSP5-8.5. En el caso de TOT JJA, la mayoría de los modelos, seleccionados y no seleccionados, proyectan una disminución de los valores, aunque con una gran dispersión, especialmente hacia el futuro lejano bajo el SSP5-8.5 con valores entre 10-100% para los seleccionados y de 80-250% para los no seleccionados. En cuanto a TOT SON, la mayoría de los modelos proyecta una disminución de los valores, siendo en el futuro cercano entre 5-20% para en ambos SSP, mientras que en el lejano del 5-30% en el SSP2-4.5 y del 15-50% en el SSP5-8.5.

Por lo tanto, en el promedio regional, para TOT anual y DJF en general no se observa una mejora en el consenso entre los modelos acerca del signo y magnitud de los cambios proyectados al seleccionar solo los mejores modelos. Similar es el caso de TOT MAM, excepto para los modelos seleccionados en el SSP2-4.5 hacia el futuro lejano donde se proyecta un incremento según todos los modelos, aunque con gran dispersión en la magnitud. Para TOT JJA y SON, hay un buen consenso acerca de una disminución en todos los casos, pero hay gran dispersión en los valores proyectados según los diferentes modelos.

En la Figura 5-11 se muestra la distribución espacial de la media del MME de los cambios proyectados en TOT. Solo en el SSP5-8.5 se observa cierto consenso entre los modelos en las proyecciones de cambios de TOT anual, aunque el signo de cambio depende de si se analizan los modelos seleccionados o no seleccionados. Los modelos seleccionados proyectan una disminución del 11% de TOT anual hacia el extremo noreste (según 3 de los 4 modelos); mientras que por el contrario, al menos 8 de los 12 modelos no seleccionados proyectan un aumento de 5-10% en casi toda la región. Por otro lado, para TOT DJF en el SSP5-8.5, los modelos no seleccionados proyectan un incremento de 3-14% en el oeste y sur de la región; en el caso de los modelos seleccionados, se proyecta un incremento de 5-17% (4-7%) en el centro y sur de la región en el SSP5-8.5 (SSP2-4.5), y una disminución de 7-12% en el extremo noreste, observándose en algunos puntos de grilla que los 4 modelos seleccionados concuerdan en el signo del cambio. Al igual que para TOT anual, para TOT DJF los principales cambios proyectados en magnitud y extensión espacial corresponden al escenario de mayor calentamiento.

En el caso de TOT MAM en los modelos no seleccionados se observa acuerdo sobre un incremento de 4-7% en el oeste en el SSP2-4.5, mientras que se proyecta un incremento de 8-21% sobre toda la región en el SSP5-8.5; en cambio, en el caso de los seleccionados en el SSP2-4.5, se observa que los 4 modelos proyectan un incremento de 9-17% en gran parte de

la región, aunque en el SSP5-8.5 el consenso desaparece en gran medida y solo 3 de los 4 modelos proyectan un incremento del 16% en el sudoeste de la región. Para TOT JJA, los modelos no seleccionados proyectan cambios en muy pocos puntos de grilla; en contraste, los modelos seleccionados concuerdan en su mayoría en una disminución de 20-30% en el norte de la región en el SSP2-4.5, mientras que en el SSP5-8.5 la disminución se extiende a toda la región con valores de 20-55%, con los 4 modelos mostrando un acuerdo en el norte de la región. Finalmente, para TOT SON, los modelos no seleccionados proyectan una disminución de 5-13% en gran parte de la región en el SSP2-4.5, pero el patrón se debilita en el SSP5-8.5; por el contrario, los modelos seleccionados proyectan una disminución de 9-17% en el oeste de la región en el SSP2-4.5, que se extiende hacia la mayor parte de la región en el SSP5-8.5 con disminuciones de 16-25%.

Por lo tanto, para TOT JJA y SON se observa un mejor consenso entre los modelos y una mayor extensión espacial de los cambios proyectados al filtrar los modelos de bajo desempeño y al considerar el escenario de mayor calentamiento. Sin embargo, esto no se observa en TOT anual, DJF y MAM, donde los patrones proyectados por el MME de los modelos seleccionados muestran menos consenso y menor extensión espacial en comparación a los no seleccionados. Como en el caso de Rx1, el análisis espacial y el promedio regional muestran algunas diferencias, debido a que algunos cambios proyectados están acotados solo a algunos sectores específicos del NOA.

Los resultados obtenidos según los mejores modelos muestran que se proyecta una disminución de TOT en el invierno y la primavera, estaciones que se caracterizan por ser más secas, acentuando el déficit hídrico de esos meses. Particularmente la disminución de la precipitación de primavera afecta directamente a los cultivos, por ejemplo, a la fase inicial de crecimiento de caña de azúcar (Digonzelli y Romero, 2013), o a la recuperación del caudal de ríos y embalses que se utilizan para proveer agua potable, riego, electricidad y producción industrial (Adler, 2006; Subsecretaría de Recursos Hídricos de la Nación, 2010), ya que en esta estación ocurren las primeras lluvias de importancia luego de la estación seca. En cuanto al verano, especialmente en el escenario de mayor calentamiento, hay proyecciones de mayor (menor) precipitación total en el centro y sur (noreste) del NOA aumentando el riesgo de excesos (déficit) hídricos allí. En otoño hay una proyección de aumento de la precipitación total en gran parte la región solo en el escenario de calentamiento intermedio, aumentando el riesgo de excesos hídricos especialmente hacia el centro-sur que tendrá mayores volúmenes de precipitación desde el verano. Las tendencias de aumento de TOT en verano en el centro-sur del NOA son coherentes con las proyecciones obtenidas para el este de Argentina en los modelos del CMIP5 (Díaz y Vera, 2017) y CMIP6 (Díaz et al., 2021). En dicho caso, los valores obtenidos son similares al promedio global de aumento proyectado en TOT de ~10% (~5%) bajo el SSP5-8.5 (SSP2-4.5) hacia finales del siglo (Du et al., 2022). Por otro lado las proyecciones de disminución de TOT de verano en el extremo noreste son coherentes con la disminución proyectada en el oeste del Chaco semiárido según modelos del CMIP6 (Lovino et al., 2021). Los resultados acerca de la disminución de la precipitación en invierno son opuestos a los obtenidos por Penalba y Rivera (2016) sobre el NOA usando el CMIP5 y algunos modelos diferentes a los utilizados aquí, pero están en línea con la disminución de la

precipitación de invierno proyectada en el noreste de Argentina (región vecina) reportada por ellos.

Entre las causas físicas, como en el caso de Rx1, se proyecta un incremento de TOT en el promedio global como consecuencia del aumento de la humedad atmosférica en respuesta al calentamiento global (contribución termodinámica). Sin embargo, la disminución de TOT en gran parte del NOA en los meses de invierno y primavera, y sobre el extremo noreste en verano, sugieren un rol significativo de los cambios de circulación (contribución dinámica) en las tendencias, contrarrestando la contribución termodinámica en estos casos. Respecto a esta contribución dinámica, el Sur de Sudamérica se vería afectado por algunos fenómenos tales como la expansión de la Celda de Hadley y cambios en la posición e intensidad de las corrientes en chorro. Esto se postula que es una consecuencia de una interacción entre un calentamiento de la troposfera alta tropical, un retraso en la ruptura del vórtice polar, y patrones asimétricos de calentamiento en el Pacífico tropical (Mindlin et al., 2023). Un análisis más profundo en futuros trabajos es necesario para dilucidar las causas físicas de los cambios proyectados que se mostraron en este trabajo.

5.4.5. Relación Rx1-TOT en el período histórico y las proyecciones a futuro

En la Figura 5-12 se muestra el porcentaje de cambio proyectado en la media regional hacia el futuro lejano según de los modelos seleccionados anteriormente, la media del MME de ellos (MME-best models) y de los no seleccionados (MME-remaining) para los dos SSP. En general se proyecta que los valores promedios regionales anuales, de DJF y de MAM para Rx1 y TOT aumenten. La única excepción a esto es el modelo IPSL-CM6A-LR, que proyecta una disminución de TOT de ~10% y un aumento de Rx1 de 15-20%; se debe destacar que éste el único modelo que muestra un buen desempeño para Rx1 y TOT simultáneamente, por lo cual sus resultados serían más confiables que en los otros casos. Por otro lado, para JJA se proyectan en general disminuciones de Rx1 y TOT, mientras que para SON los modelos proyectan un aumento de Rx1 y una disminución de TOT.

Comparando las variables, Rx1 es más sensible al calentamiento global, ya que los porcentajes de cambio proyectados en la misma son notablemente mayores que para TOT en la mayoría de los modelos y estaciones del año. Como una excepción a esto, en el NOA en JJA, la estación del año con menores lluvias, se proyectan disminuciones similares en ambas variables, e incluso en los modelos GFDL-ESM4 e IPSL-CM6A-LR en el SSP5-8.5 la disminución en TOT supera ampliamente la disminución de Rx1. La mayor sensibilidad de Rx1 en el NOA en el CMIP6 coincide con resultados globales del CMIP5 que indican que Rx1 se incrementa más rápido que TOT (Sillman et al., 2013). Esta diferencia en la sensibilidad de las variables podría deberse a que la intensidad de la precipitación (Rx1) responde a condiciones locales y diarias de incremento en la humedad relacionadas al aumento de la capacidad del aire de contener vapor ante el calentamiento (~7%/°C); por el contrario, la precipitación total estacional/anual (TOT) responde a condiciones globales de

incremento en la evaporación en escalas temporales mayores, la cual tiene una tasa más baja ($\sim 2\%/^{\circ}\text{C}$) (Giorgi et al., 2019).

Comparando las medias de los modelos, el cambio proyectado según el promedio de los modelos seleccionados (MME-best models en la Figura 5-12) es mayor que la de los modelos no seleccionados (MME-remaining en la Figura 5-12) en todas las estaciones del año. Es decir, cuando sólo se analizan los mejores modelos, la señal de cambio de Rx1 y TOT al calentamiento global es mayor, en coincidencia con los análisis de las subsecciones anteriores.

En la Figura 5-13 se muestra el porcentaje que representa Rx1 en TOT para el período de referencia y para el futuro lejano bajo ambos SSP. En el periodo de referencia, las observaciones (CPC) muestran que Rx1 aporta significativamente a TOT, siendo su aporte el 7% para el anual, el 13% para DJF, 16% para MAM, 22% para SON y 33% para JJA. En el periodo de referencia, para todas las estaciones del año, el promedio de los mejores modelos muestra un cociente Rx1/TOT similar al observado, mientras que el promedio de los no seleccionados tiene mayores diferencias. Individualmente, los modelos muestran un cociente Rx1/TOT más alejado de las observaciones que en el caso del promedio de los modelos, con una importante dispersión entre los valores simulados por los mismos especialmente en MAM, JJA y SON (diferencias de 10-20%). El modelo IPSL-CM6A-LR, muestra valores simulados más cercanos a las observaciones en todas las estaciones, excepto JJA, tal como es de esperarse dado que un modelo que simula mejor tanto Rx1 como TOT.

En general se proyecta que Rx1 aumente su porcentaje de aporte a TOT hacia el futuro lejano en ambos SSP, indicando que la concentración de la precipitación aumentará, excepto en los modelos INM-CM4-8 e INM-CM5-0 en MAM y JJA. Este incremento del aporte de Rx1 a TOT es consecuencia de que el aumento porcentual de Rx1 como respuesta al calentamiento global es superior al de TOT en el NOA. Este resultado está en línea con las proyecciones globales obtenidas en el CMIP5 que indican una mayor contribución de los extremos diarios a la precipitación total anual (Sillman et al., 2023). En general los aumentos del cociente Rx1/TOT son de $\sim 1-2\%$, con los mayores incrementos en el SSP5-8.5. Sin embargo, para el modelo IPSL-CM6A-LR los incrementos proyectados son notablemente mayores que en los demás modelos en ambos SSP, siendo en el caso anual de 2-3%, DJF 1-3%, MAM 1-10% y SON 10%, lo cual es coherente con los resultados anteriores que indican que al seleccionar los mejores modelos, los cambios proyectados se intensifican.

5.5. Conclusiones

Se evaluó el desempeño de 16 modelos del CMIP6 para representar los patrones medios espaciales de Rx1 y TOT en el NOA para el período 1981-2010. El desempeño de los modelos en general depende de la métrica de precipitación analizada, aunque el modelo IPSL-CM6A-LR muestra un mejor desempeño que otros para Rx1 y TOT simultáneamente, siendo el modelo más recomendable entre los analizados.

En cuanto al comportamiento según las estaciones del año, en las más lluviosas el sesgo de los modelos es mayor, y en general, hay una tendencia de los modelos a sobreestimar Rx1 y TOT en el NOA. El sesgo de algunos modelos fue muy superior al de otros, por lo cual se remarca la necesidad de filtrar los mismos antes de obtener proyecciones más confiables. Además, los resultados del RMSE indican que a pesar de que hay modelos con un mejor desempeño que otros, todos los modelos deben mejorar su representación de los patrones climatológicos medios. En futuros trabajos se debería avanzar en un análisis más detallado de las causas de los sesgos en los modelos e indagar por qué algunos tienen un mejor desempeño. Esto podría realizarse, por ejemplo, mediante un análisis de la representación en los modelos de los patrones de circulación típicos asociados a la precipitación.

En cuanto al análisis de las proyecciones, se observa que cuando se analizan los mejores modelos la señal de cambio esperada en Rx1 y TOT en respuesta al calentamiento global es mayor. Esto implica que los riesgos futuros podrían ser subestimados si no se realiza una preselección de los modelos con mejor desempeño.

Se proyecta un aumento generalizado de Rx1 en la región en los casos anual y de verano, y en menor medida en otoño, lo que implica un aumento en el riesgo de inundaciones. Por otra parte, se proyecta una disminución de TOT en las estaciones más secas del año (invierno y primavera), acentuando el déficit hídrico de esos meses, lo cual implica un aumento del riesgo para actividades económicas dependientes de la precipitación en la transición de la estación seca a la estación húmeda (agricultura, industria y generación de energía). En cuanto al verano, las proyecciones de TOT son diferentes en el centro-sur y en el noreste, con un aumento y disminución respectivamente, y con mayor magnitud en el escenario de mayor calentamiento. Particularmente, en el otoño solo en el escenario de calentamiento intermedio se observa un aumento del riesgo de excesos hídricos en el centro-sur, debido a que desde el verano previo se proyecta un aumento de TOT.

La tasa de aumento de Rx1 en el promedio regional está en línea con lo esperado debido al incremento de la capacidad del aire de contener vapor (contribución termodinámica) como respuesta al calentamiento global. En contraste, las proyecciones de disminución o cambios nulos para TOT no están en línea con esta hipótesis de la contribución termodinámica, sugiriendo un rol significativo de los cambios de circulación (contribución dinámica) en las tendencias. Por otro lado, las proyecciones de aumento de TOT son relativamente menores a las de Rx1, debido a que TOT depende de la tasa promedio de evaporación global, la cual es menor a la tasa de aumento de la capacidad del aire de contener vapor. Así, el análisis comparativo muestra que Rx1 es más sensible al calentamiento global que TOT según la mayoría de los modelos y en la mayoría de las estaciones del año. Esto resultará en un aumento del aporte de Rx1 a TOT a futuro, lo cual implica que aumentará la concentración de la precipitación. La comparación de resultados para Rx1 y TOT indica que los procesos físicos que regulan a cada métrica de precipitación responden de manera diferente al calentamiento global. En futuros trabajos es necesario realizar un análisis más profundo para dilucidar las causas físicas de los cambios proyectados.

Figuras y tablas (Cap. 5)

Tabla 5-1: Modelos del CMIP6 utilizados, su resolución horizontal y la referencia correspondiente.

Modelo	Resolución (lat x lon)	Referencia
ACCESS-CM2	1,25° x 1,875°	Daohua Bi et al. (2020)
ACCESS-ESM1.5	1,25° x 1,875°	Ziehn Tilo et al. (2020)
CanESM5	~ 2,8° x 2,8°	Swart et al. (2019)
CESM2-WACCM	~ 0,9° x 1,25°	Danabasoglu et al. (2020)
CMCC-ESM2	0,9° x 1,25°	Lovato et al. (2022)
EC-Earth3-CC	~0,7° x 0,7°	Döscher et al. (2022)
EC-Earth3-Veg-LR	~1,1° x 1,1°	Döscher et al. (2022)
FGOALS-g3	~2° x 2°	Li et al. (2020)
GFDL-ESM4	1° x 1,25°	Dunne et al. (2020)
INM-CM4-8	1,5° x 2°	Volodin et al. (2018)
INM-CM5-0	1,5° x 2°	Volodin et al. (2017)
IPSL-CM6A-LR	1,25° x 2,5°	Boucher (2020)
MIROC6	~1,4° x 1,4°	Tatebe et al. (2019)
MPI-ESM1.2-LR	~1,9° x 1,9°	Mauritsen et al. (2019)
MRI-ESM2	~1,1° x 1,1°	Yukimoto et al. (2019)
NESM3	~1,9° x 1,9°	Cao et al. (2018)

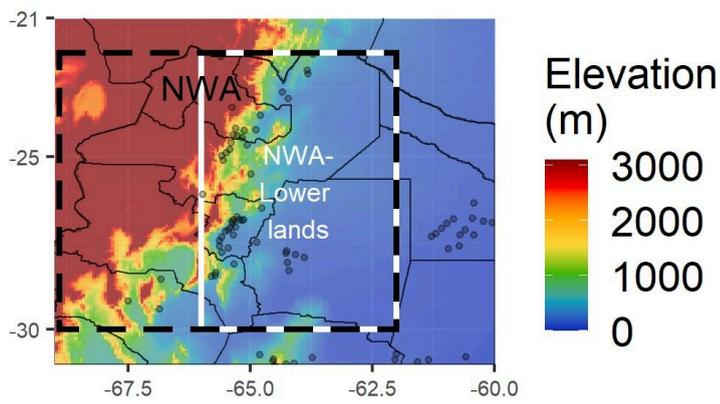


Figura 5-1: Topografía del NOA (color) y ubicación de las principales ciudades (puntos negros). El recuadro negro punteado delimita el NOA, mientras el recuadro blanco delimita la subregión del NOA seleccionada para el análisis de este capítulo compuesta principalmente por elevaciones por debajo de los 3000 m sobre el nivel del mar.

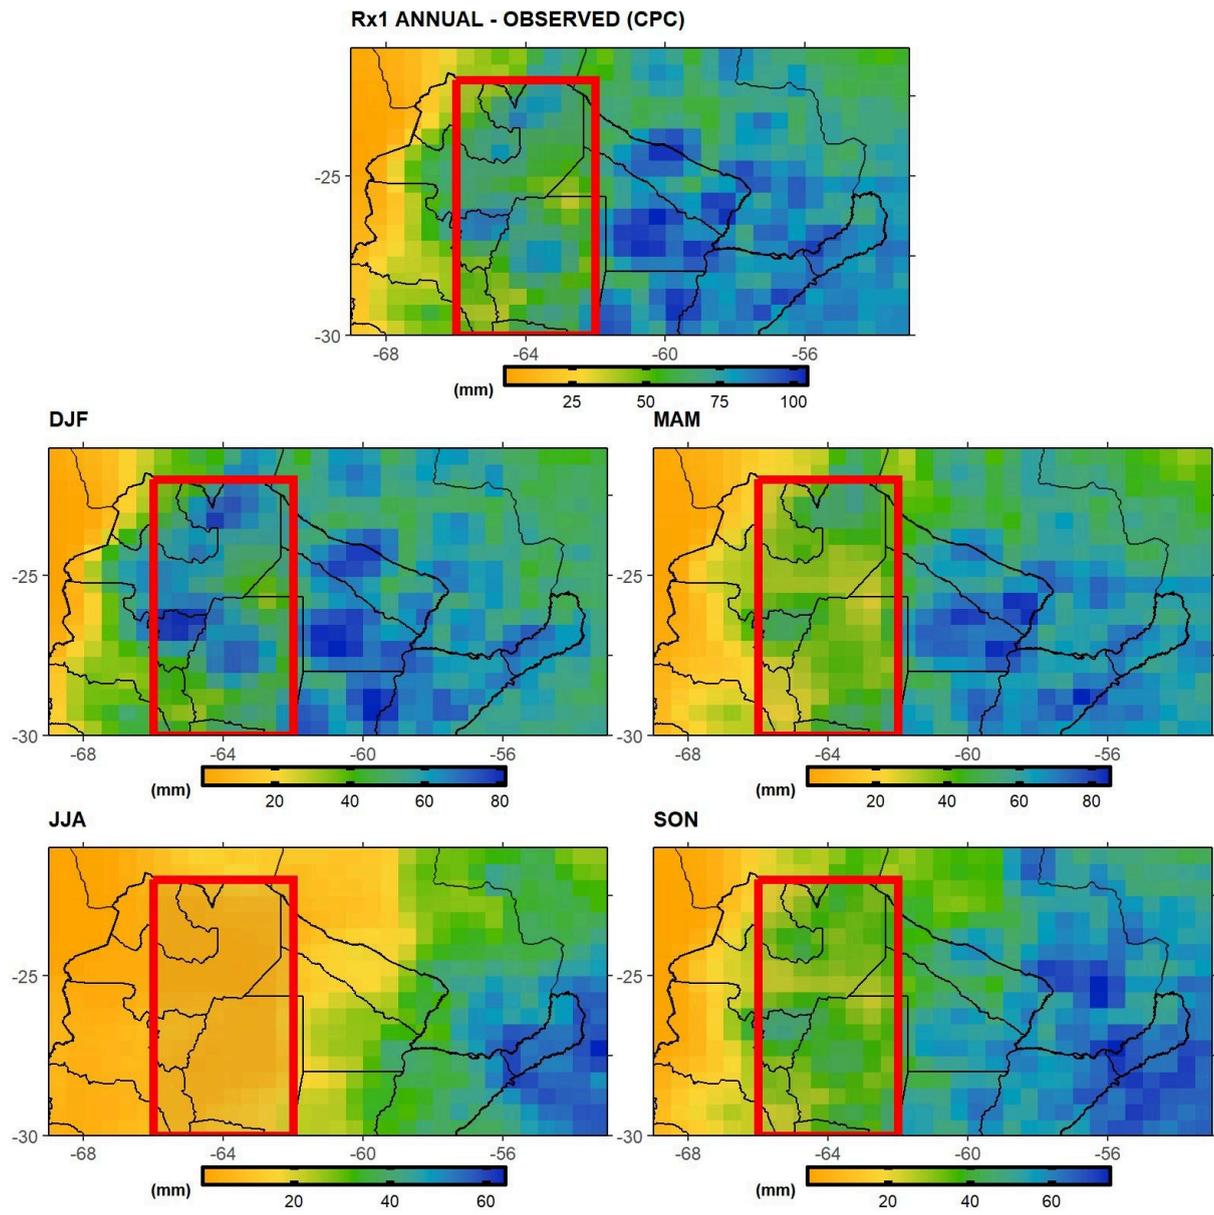


Figura 5-2: Distribución espacial de los valores medios observados según CPC de Rx1 anual, DJF, MAM, JJA y SON. El recuadro rojo delimita la subregión del NOA analizada en este capítulo.

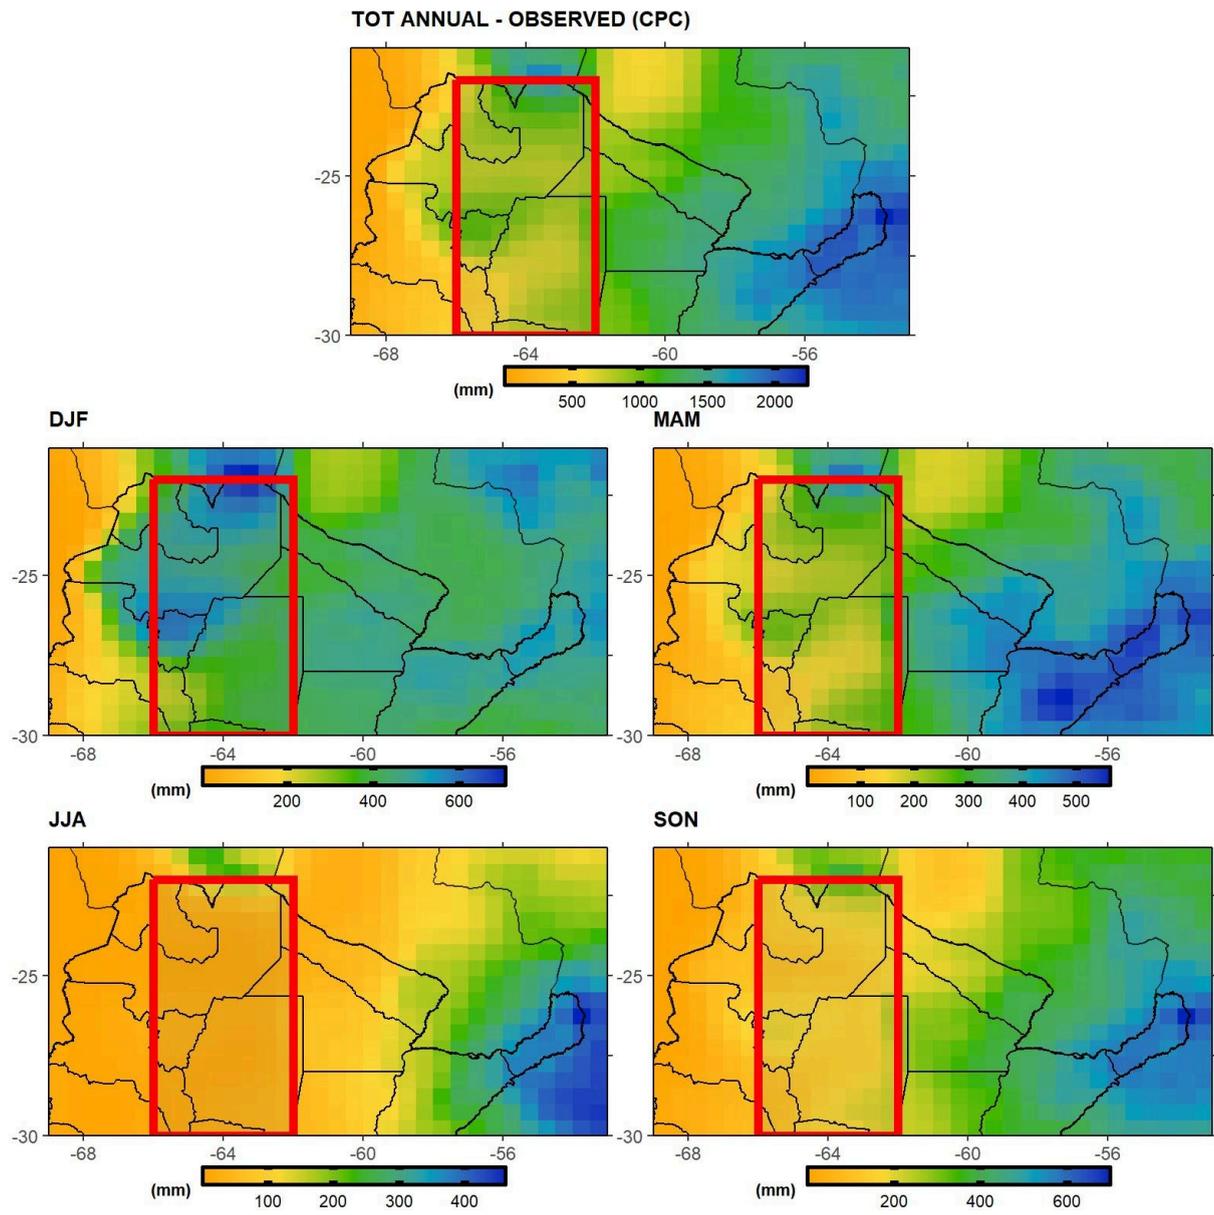


Figura 5-3: Distribución espacial de los valores medios observados según CPC de TOT anual, DJF, MAM, JJA y SON. El recuadro rojo delimita la subregión del NOA analizada en este capítulo.

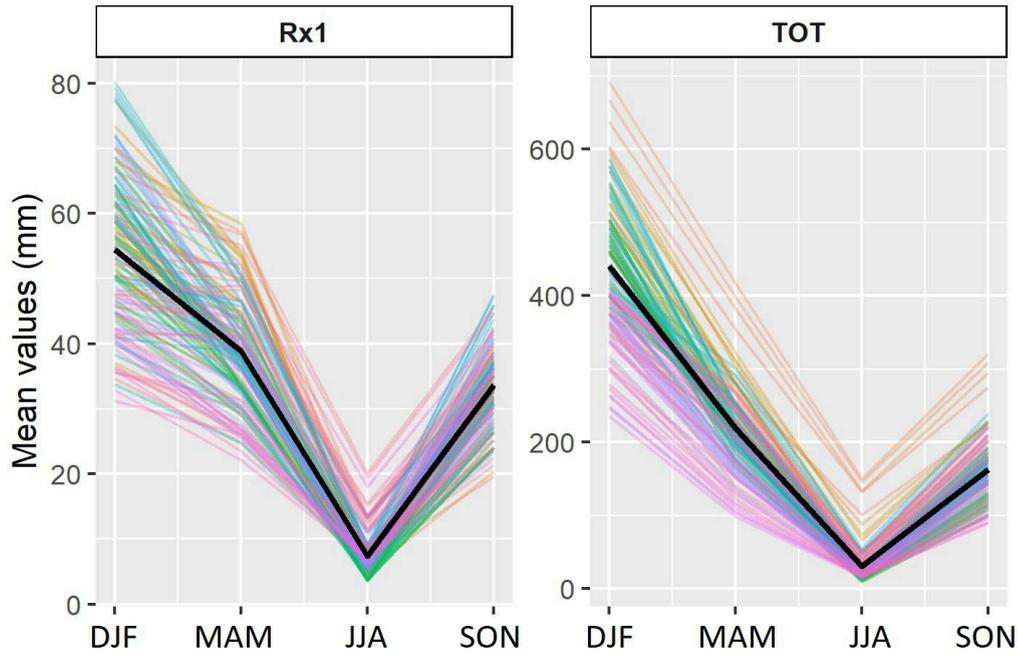


Figura 5-4: Ciclo anual medio de Rx1 y TOT observado en cada punto de grilla para el período climatológico de referencia en cada punto de grilla de la subregión seleccionada (líneas de colores) y el ciclo promedio (línea negra).

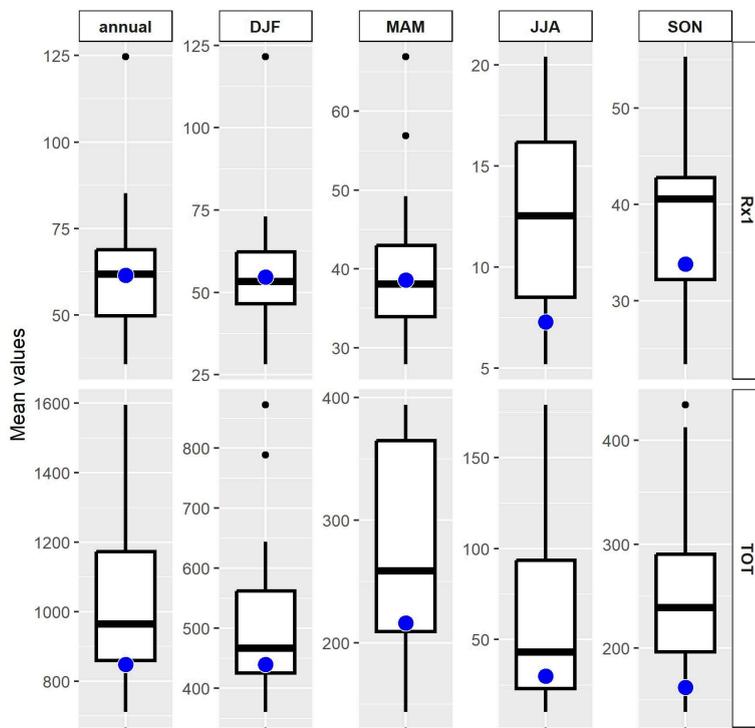


Figura 5-5: Diagrama de cajas de los valores medios regionales de Rx1 y TOT simulados por los diferentes modelos. Los puntos azules corresponden al valor medio observado según CPC. Ciclo anual by each model

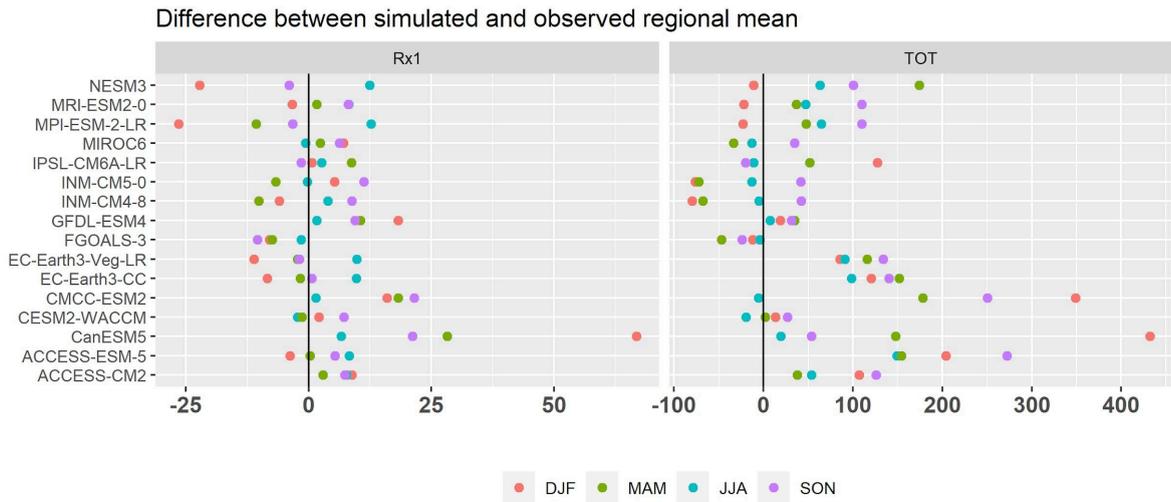


Figura 5-6: Diferencia (en mm) entre la media observada según CPC y la simulada según cada modelo del CMIP6 para Rx1 (izquierda) y TOT (derecha), separadas por estación del año (colores).

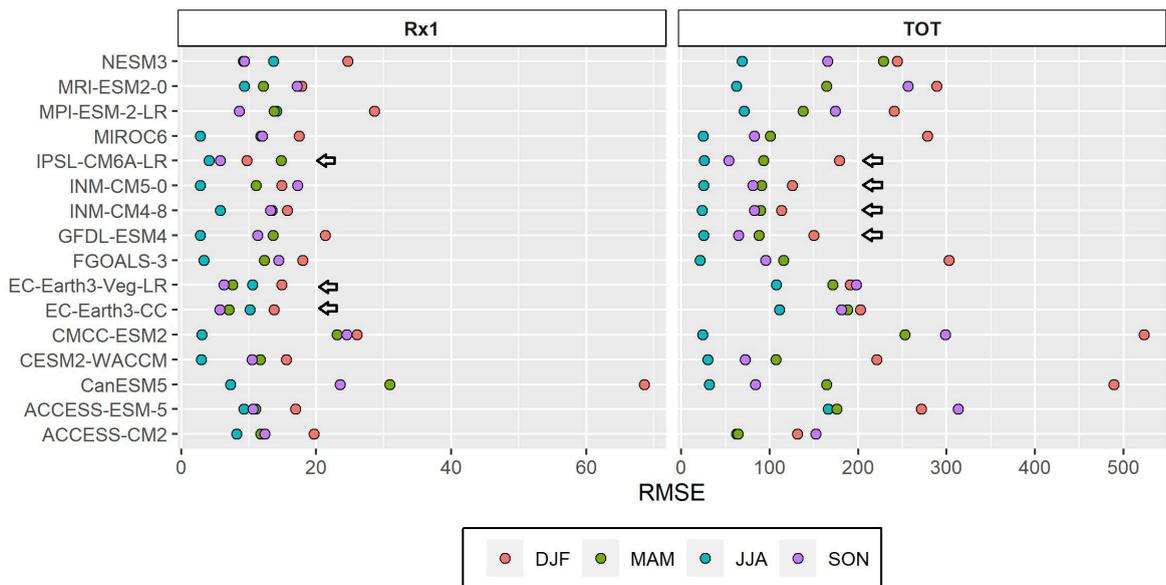


Figura 5-7: Valores de RMSE para Rx1 y TOT para cada modelo, separados por estación del año (color). Las flechas indican los modelos con mejor desempeño según sus valores de RMSE.

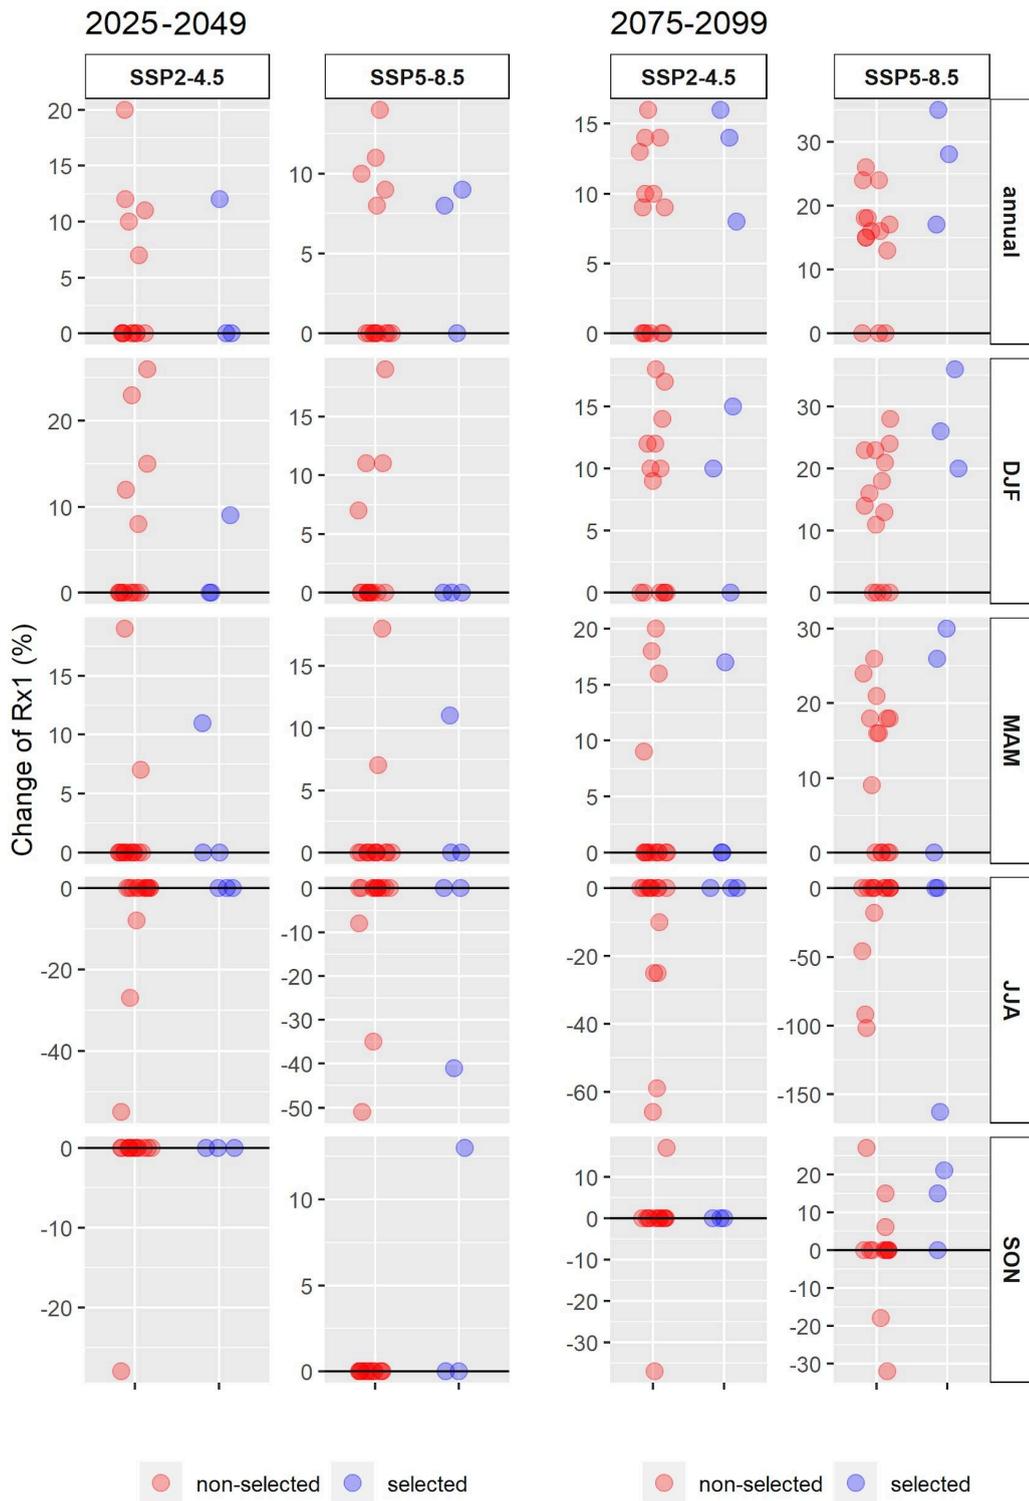


Figura 5-8: Cambios proyectados en la media regional de Rx1 para el futuro cercano (2025-2049) y el futuro lejano (2075-2099) respecto al periodo climatológico de referencia (1981-2010) bajo diferentes SSP. Se distinguen los modelos seleccionados por su mejor desempeño (puntos azules) de los no seleccionados (puntos rojos). Todos los cambios no significativos estadísticamente fueron considerados cero, de manera que los valores no nulos que se muestran son todos significativos al 95% de nivel de confianza.

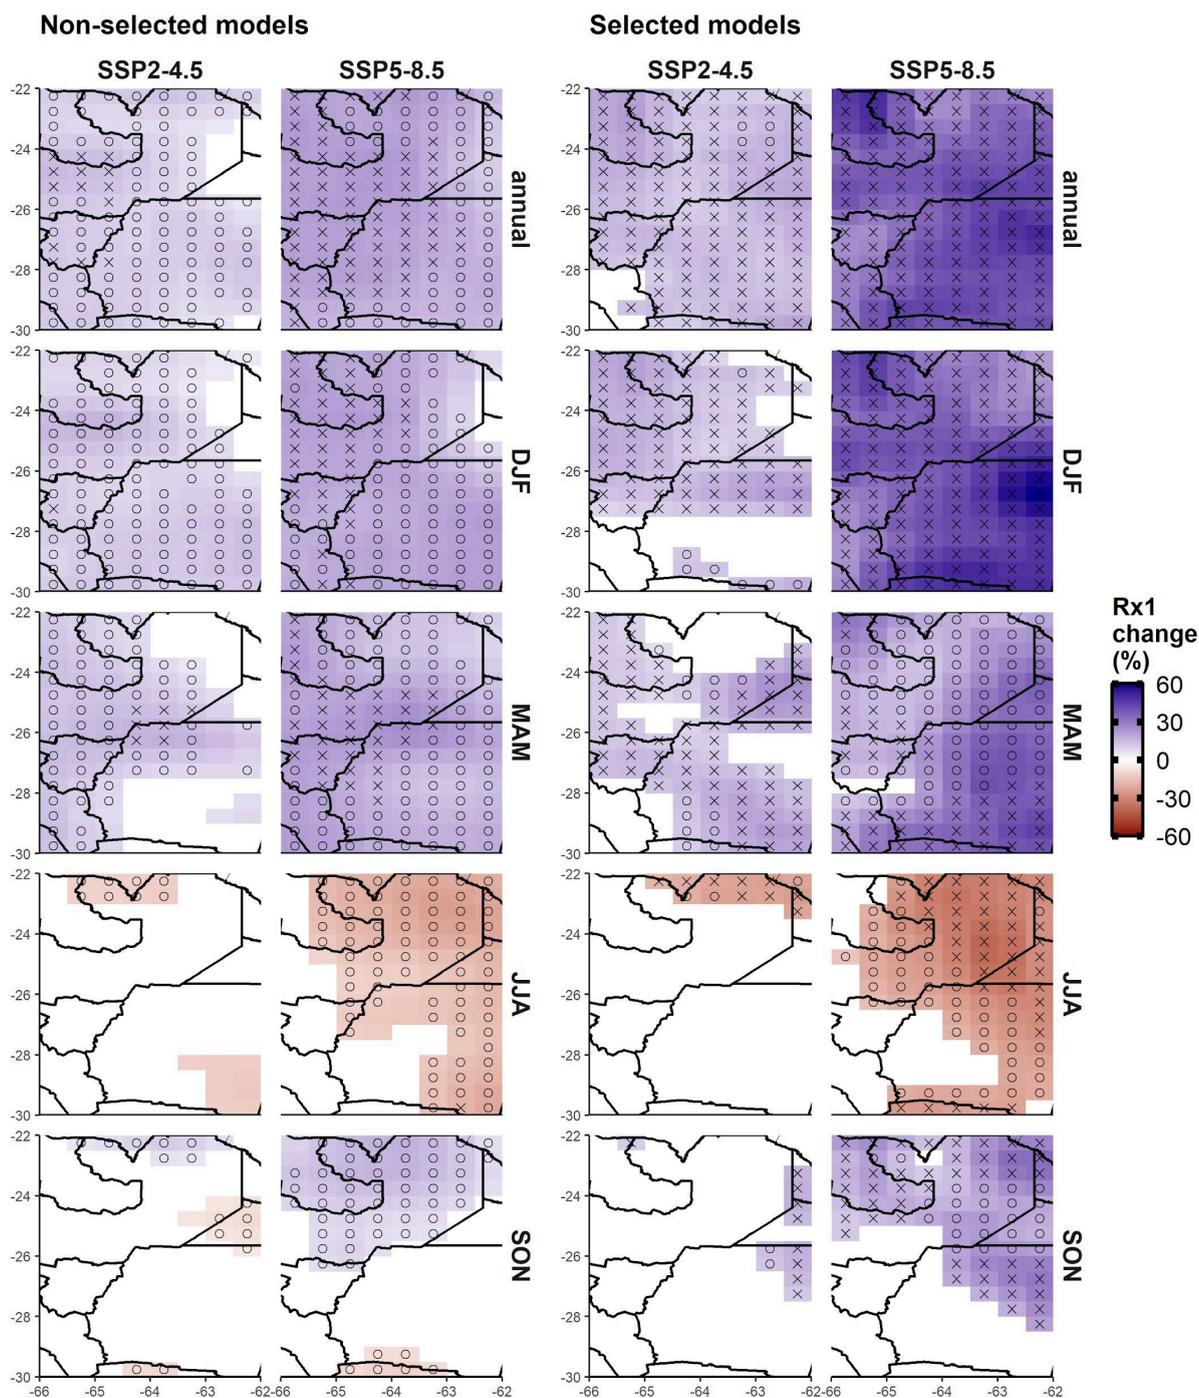


Figura 5-9: Distribución espacial de los cambios proyectados en Rx1 para el futuro lejano bajo los SSP2-4.5 y SSP5-8.5 para los modelos seleccionados (columnas derechas) y no seleccionados (columnas izquierda). En color se indica el porcentaje promedio de cambio de los modelos considerados. En círculos (cruces) se indican los puntos de grilla donde al menos el 66% (100%) de los modelos proyectan un cambio estadísticamente significativo al 95% y que concuerdan entre sí en el signo del mismo.

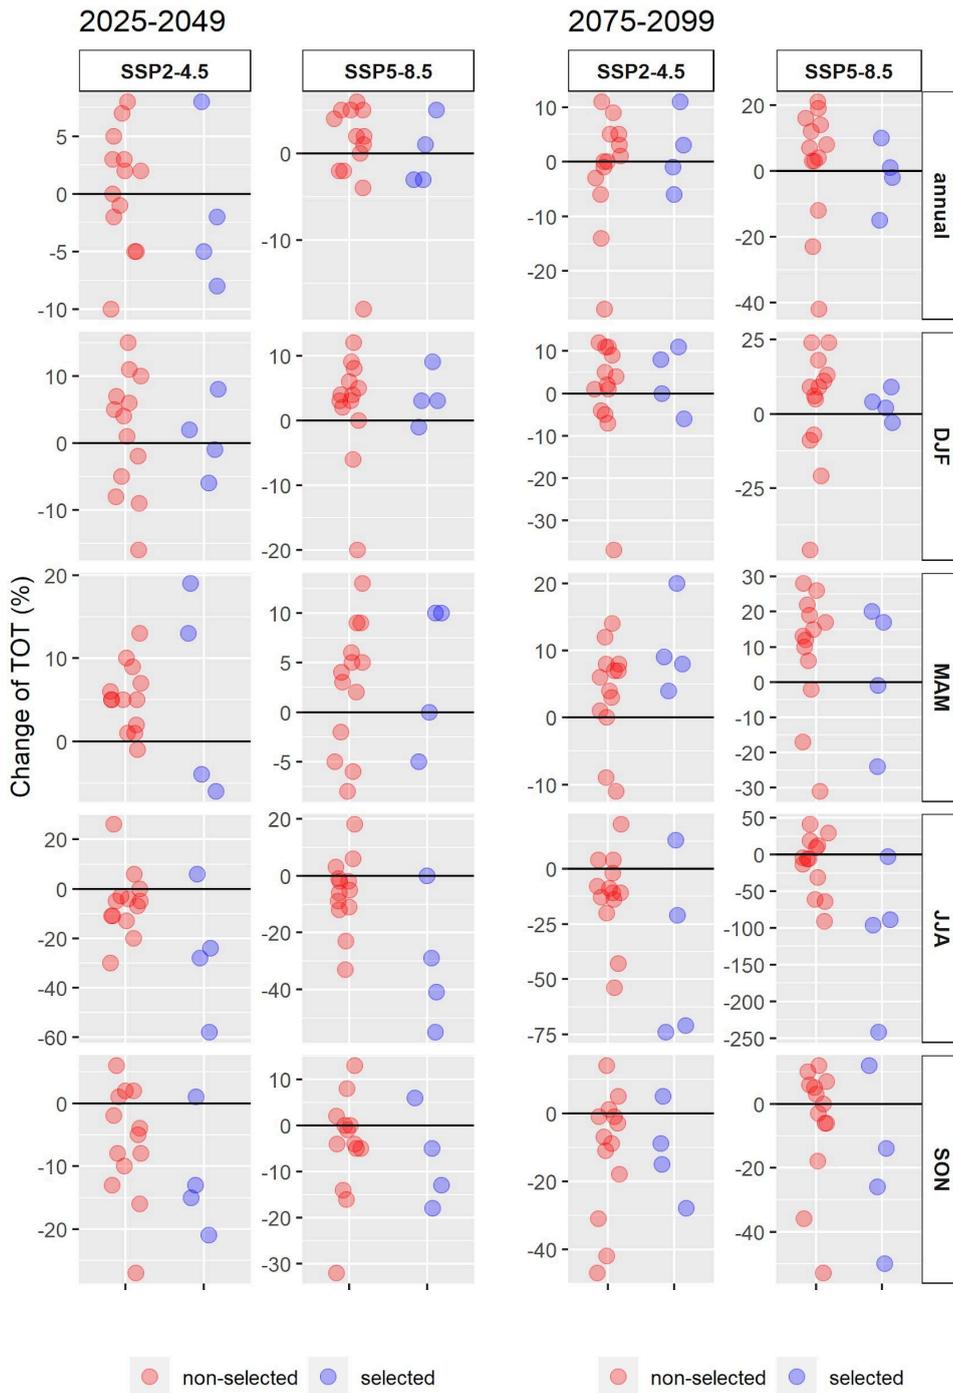


Figura 5-10: Como la Figura 5-8, pero para TOT.

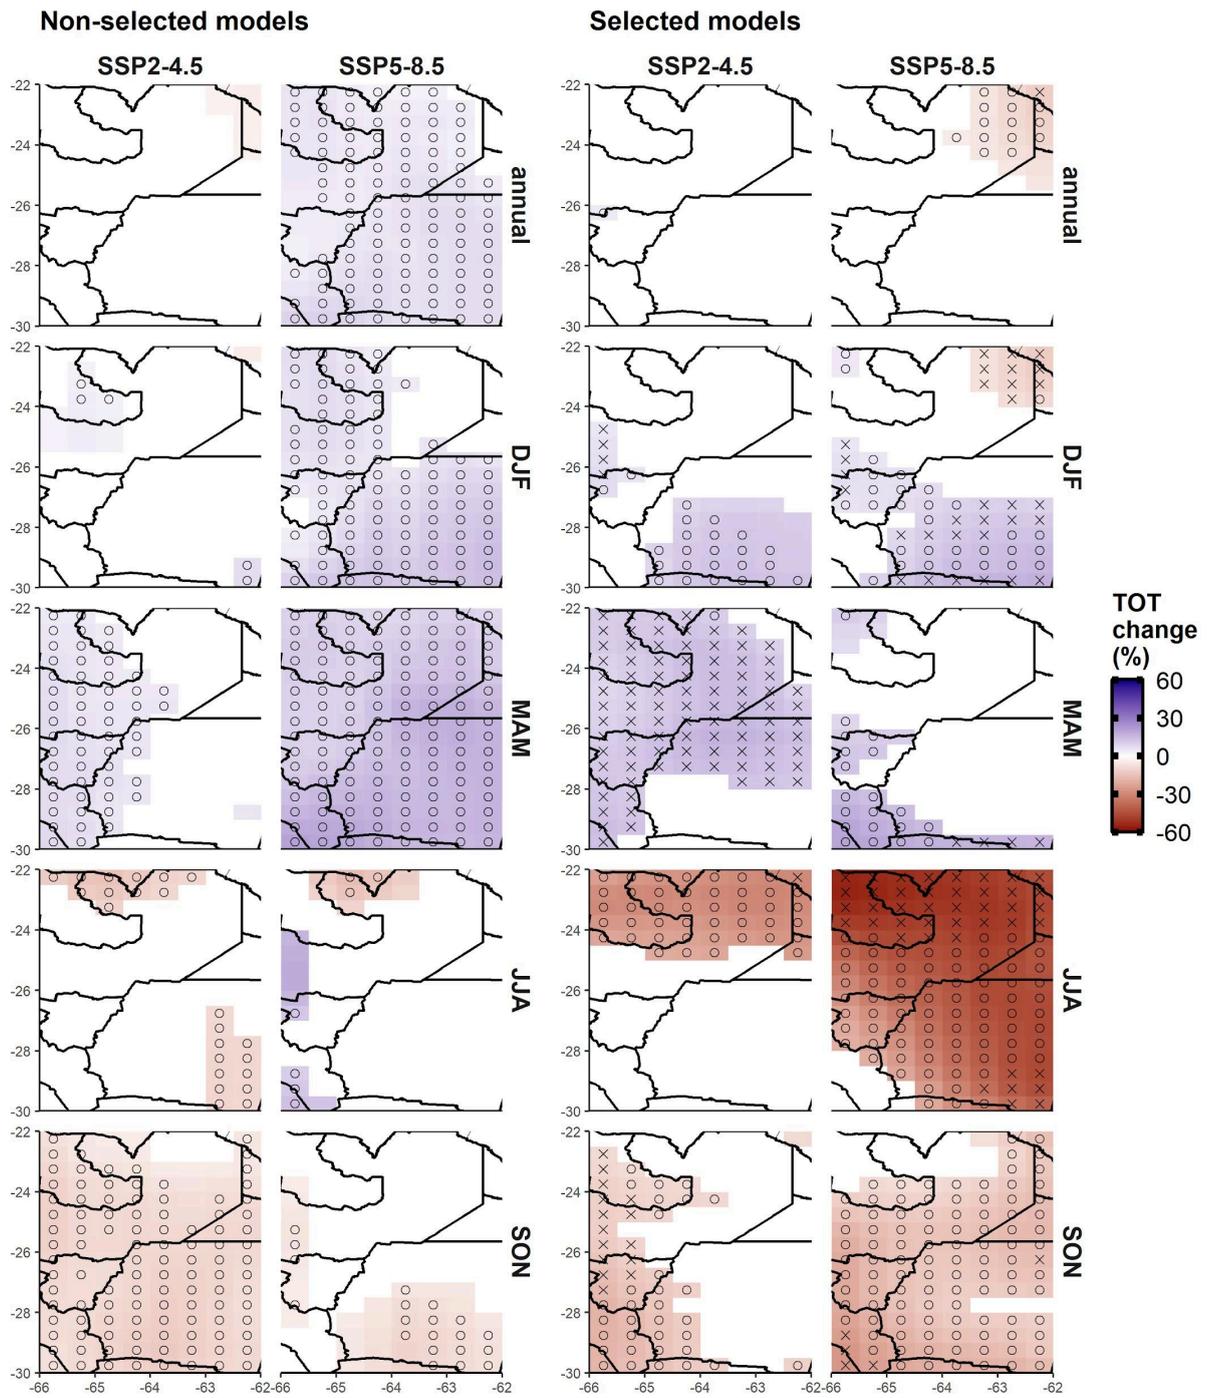


Figura 5-11: Como la Figura 5-9, pero para TOT.

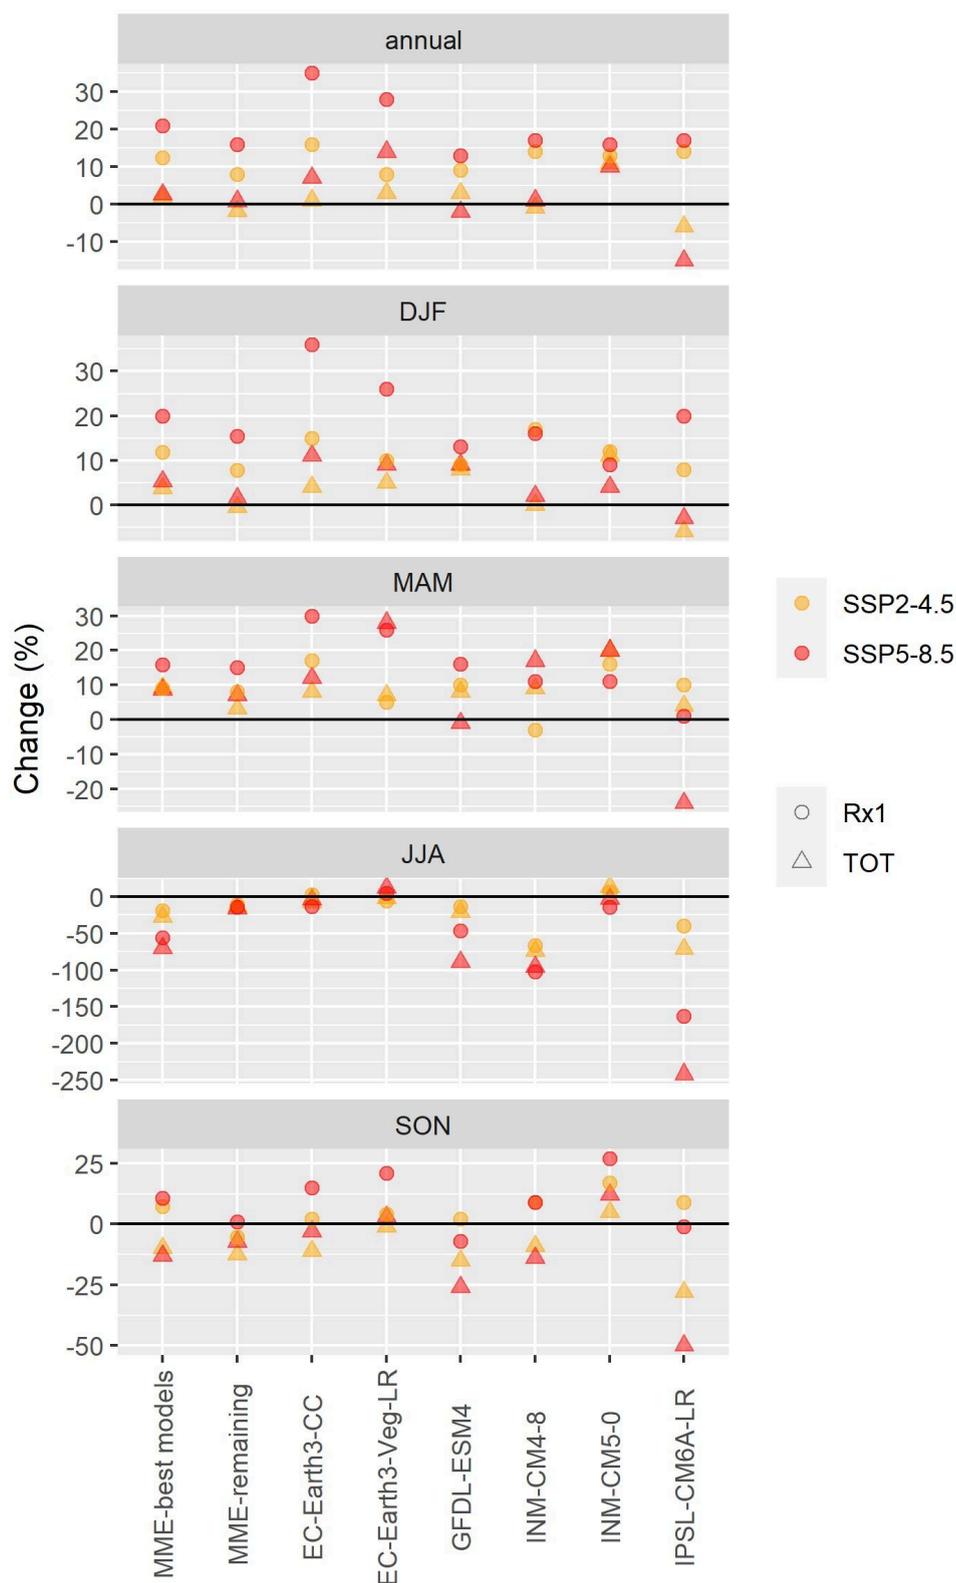


Figura 5-12: Cambios proyectados en la media regional de Rx1 (círculos) y TOT (triángulos) para el futuro lejano (2075-2099) respecto al periodo climatológico de referencia (1981-2010) en el SSP2-4.5 (naranja) y SSP5-8.5 (rojo). Se muestra el cambio proyectado según cada uno de los modelos seleccionados anteriormente por su buen desempeño, para la

media de los mismos (MME-best models) y la media de los modelos no seleccionados (MME-remaining).

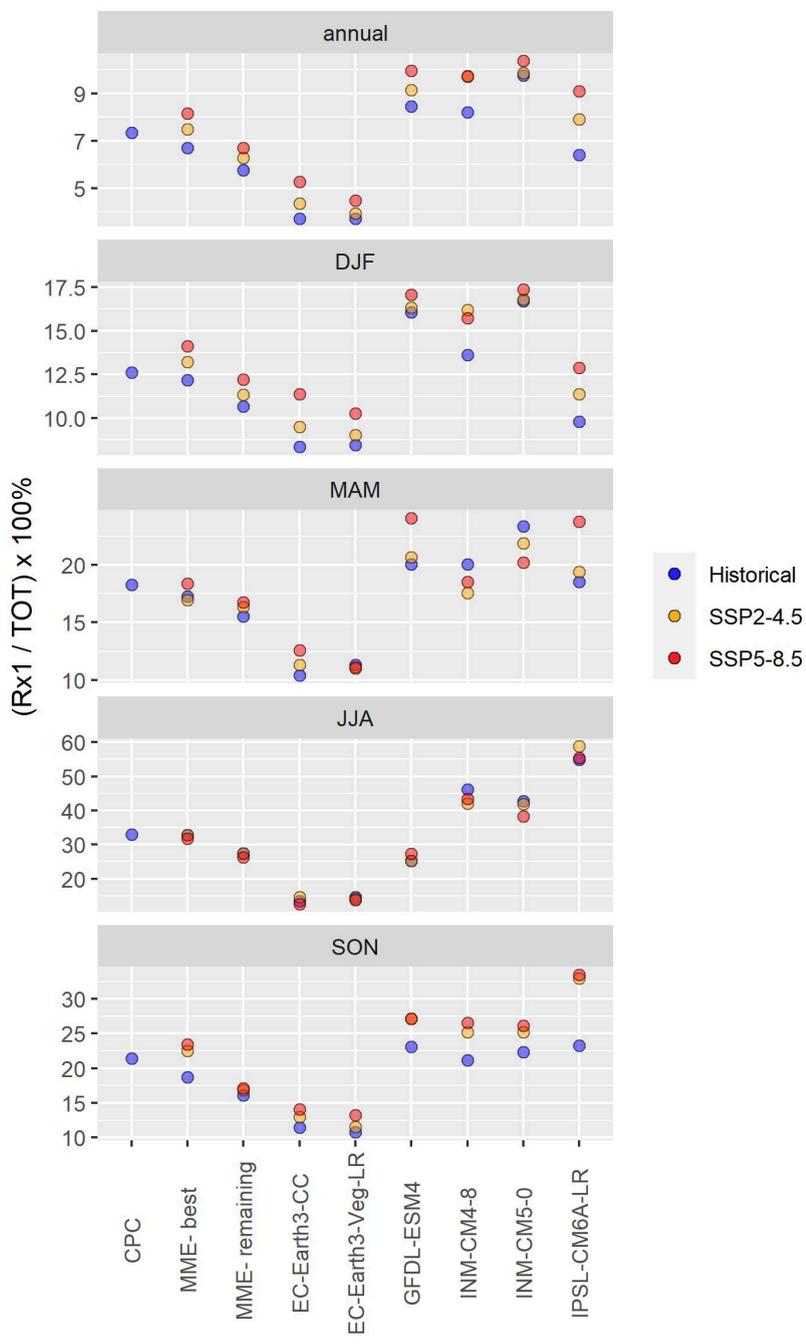


Figura 5-13: Porcentaje que representa Rx1 en TOT ($Rx1/TOT \times 100\%$; medias regionales) para el período de referencia (1981-2010, azul), y el futuro lejano (2075-2099) bajo el SSP2-4.5 (naranja) y el SSP5-8.5 (rojo). Se muestran resultados para las observaciones (CPC), para cada uno de los modelos seleccionados anteriormente por su buen desempeño, para la media de los mismos (MME-best models) y para la media de los modelos no seleccionados (MME-remaining).

Capítulo 6: Conclusiones generales y líneas futuras de investigación

En esta tesis se analizó la variabilidad interanual y de más largo plazo de la precipitación extrema en el NOA, relacionada en este trabajo con la intensidad de la precipitación diaria, para lo cual se utilizó la precipitación máxima diaria (Rx1) estacional/anual como indicador de la misma. Además, a modo complementario, se analizaron la precipitación total (TOT) y algunos otros índices relacionados a la frecuencia, duración e intensidad de la precipitación. Parte de los resultados de este trabajo se publicaron en importantes revistas científicas y congresos del área de las ciencias de la atmósfera (ver Apéndice).

Esta tesis intentó contribuir al conocimiento de las condiciones globales atmosféricas-oceánicas que favorecen la ocurrencia de los eventos de lluvia extrema. En este sentido, el objetivo general de esta tesis fue lograr una mejor comprensión física de las causas de la variabilidad interanual y de mayor plazo de los extremos diarios de precipitación en relación a algunos forzantes naturales (ENSO, SAM, AMO, PDO) y antropogénicos (cambios en las concentraciones de GHG y O₃).

En un primer paso se caracterizó la variabilidad temporo-espacial de la precipitación en el NOA mediante algunos índices de precipitación en el periodo 1982-2019 mediante el uso de dos bases de datos: observaciones in-situ y CHIRPS. A continuación, se realizó un análisis temporalmente más extenso, cubriendo un período de 108 años (1912-2019), mediante el análisis de datos de precipitación diaria medidos en San Miguel de Tucumán (TUC). Con los mismos, primero se realizó un análisis exploratorio de la relación de Rx1 y TOT en TUC con los forzantes naturales y antropogénicos. Los resultados obtenidos para los forzantes naturales fueron profundizados en un posterior análisis y enmarcados regionalmente mediante el uso de datos de HadEX3 en SSA y la construcción de composites de variables atmosféricas utilizando el reanálisis ERA5. Finalmente, se continuó con el análisis del aumento de GHG como forzante antropogénico mediante el uso de modelos climáticos pertenecientes al CMIP6. En este último caso, previa evaluación del desempeño de los modelos para simular la climatología de la precipitación, se evaluaron las proyecciones de la misma hasta finales del siglo XXI para determinar su respuesta al aumento de GHG.

Los resultados de la caracterización de los índices de precipitación en el NOA muestran que las mayores precipitaciones se observan sobre el centro de la región. CHIRPS tiene un bajo desempeño para representar la variabilidad y tendencias de los índices de precipitación más extrema en comparación a las observaciones in situ. Como excepción, hay una coincidencia acerca de un incremento en la máxima cantidad anual de días consecutivos sin precipitación (CDD) en el NOA desde 1982, lo cual ocurre al menos desde 1969 si se compara con resultados de otros autores. Este incremento en CDD indica un incremento de la duración de

la estación seca. Si solo se analizan los datos in situ, para 1982-2019 la mayor parte de las tendencias obtenidas en el NOA son compatibles con un cambio reciente hacia condiciones más secas.

Por otro lado, en el análisis del período 1912-2019 se encontró que hay evidencia de un corrimiento del ciclo hidrológico anual en las últimas décadas, que consiste en un incremento de la frecuencia de ocurrencia de Rx1 anual durante el otoño en detrimento de la primavera. En relación a esto, las proyecciones de los modelos del CMIP6 indican que este corrimiento del ciclo hidrológico observado en las últimas décadas podría acentuarse en el futuro debido al calentamiento global. Hacia finales del siglo XXI, según los modelos que mejor simulan la precipitación en la región, se proyecta bajo los dos escenarios de calentamiento global analizados una disminución de TOT de invierno y primavera en gran parte del NOA, y a su vez un aumento de TOT de verano y otoño, particularmente en la zona centro-sur. Este cambio en el ciclo anual de lluvias consiste en una disminución de la precipitación en la transición (primavera) de la estación seca a la estación húmeda.

La extensión de la duración en la estación seca obtenida con datos in situ y CHIRPS es un resultado coherente con la observación de una disminución de la ocurrencia de Rx1 en la primavera con los datos de TUC y las proyecciones del corrimiento del ciclo anual de lluvias en los modelos del CMIP6. Esta coherencia entre los resultados obtenidos mediante diferentes bases de datos observacionales y simuladas en diferentes periodos temporales, indican que las conclusiones mencionadas tienen un alto grado de confianza. La extensión de la duración de la estación seca implica un aumento en los riesgos en el NOA para la producción agrícola, la generación de energía hidroeléctrica, el abastecimiento de agua para la población y la producción industrial durante la primavera. Como trabajo futuro, es necesario realizar un análisis específico de los cambios proyectados en la duración de la estación seca, considerando por ejemplo, la fecha de ocurrencia de la primera precipitación de importancia en el año hidrológico para lograr una cuantificación más precisa que sea de utilidad para los tomadores de decisión. También se debería evaluar la relación entre dicha duración y los modos de variabilidad global con el fin de evaluar la predictibilidad de la misma.

Respecto a la relación entre Rx1 y TOT, existen diferencias entre las series observadas en el periodo 1912-2016 con una correlación no muy alta entre las mismas ($\sim 0,5$). Esto indica que su variabilidad interanual y de más largo plazo responden a diferentes forzantes, y que la intensidad diaria de la precipitación no está estrechamente relacionada a los acumulados estacionales/anuales. Las series de TOT anual y de DJF observadas tienen una tendencia lineal positiva y significativa en el periodo mencionado, mientras que Rx1 no muestra esto. Las series muestran saltos climáticos hacia condiciones más húmedas en la segunda mitad del siglo pasado, ocurriendo alrededor de 1956 para TOT anual y DJF en relación a ENSO, y hacia 1977 para Rx1 DJF en relación a PDO. Por otro lado, las series observadas de Rx1 y TOT muestran correlaciones significativas con las series de concentración global de CO₂ y de O₃ polar, positiva en el primer caso y negativa en el segundo, con magnitudes similares. Esto indica que, al menos basados en la correlación, no hay un peso mayor de un forzante antropogénico por sobre el otro. Sin embargo, el rol relativo de ambos sobre la precipitación

es aún controvertido en la literatura existente, mientras que los resultados del análisis exploratorio de esta tesis no son concluyentes al respecto.

Particularmente en relación a los forzantes naturales, Rx1 muestra una importante variabilidad interanual e interdecadal, explicada parcialmente en el primer caso con ENSO y SAM en una relación no estacionaria condicionada por las fases de PDO. Se detectó una transición de una relación más estrecha Rx1-ENSO (1945-1974) hacia una relación más estrecha Rx1-SAM (1974-2007). Estos resultados se reflejan no solo en TUC, sino también en el NOA y otros sectores de SSA según el análisis realizado con HadEX3. Por otro lado, mediante ERA5 se mostró que la no estacionariedad de las relaciones se debe a diferencias en los patrones de circulación inducidos por ENSO y SAM entre fases de PDO. En cuanto a la variabilidad multidecadal, se encontró que las décadas con lluvias más intensas (1980 y 1990) coinciden con la fase cálida de PDO y con una estrecha relación Rx1-SAM en la escala interanual. Los resultados indican que los procesos involucrados en la variabilidad de la intensidad de la precipitación en la región están parcialmente relacionados a modos de variabilidad global (ENSO, SAM y PDO), es decir, no dependen únicamente de factores locales. Dado este resultado, futuros trabajos podrían enfocarse en buscar si existe cierta predictibilidad de Rx1, o algunos otros índices de precipitación, en relación a estos forzantes. Por otra parte, se debe avanzar en el análisis de datos de más estaciones meteorológicas con la metodología del PmPV para evaluar mejor los alcances y las limitaciones de dicho método, así como para extender con mayor confianza, y mayor resolución espacial que la de HadEX3, las conclusiones obtenidas.

Las proyecciones hacia finales del siglo XXI muestran en gran parte de la región un incremento de Rx1 anual y de verano, y en menor medida de otoño, lo que implica un aumento del riesgo de inundaciones. Los incrementos proyectados son superiores cuando se analizan los mejores modelos y el escenario de mayor calentamiento global. Lo primero implica que si no se filtran los modelos con bajo desempeño previo al análisis de proyecciones, los riesgos asociados a los cambios en la precipitación extrema pueden ser subestimados significativamente. Lo segundo implica que los riesgos se incrementan a medida que se incrementa la emisión de GHG. Se observa que Rx1 es la variable más sensible al calentamiento global en comparación con TOT. Esto es posiblemente porque la primera responde directamente al incremento de la capacidad del aire de contener vapor debido al calentamiento global, mientras que para la segunda parece haber un efecto de atenuación o reversión de esto mediante cambios de circulación y por su dependencia con la tasa promedio de evaporación global en escalas mucho mayores a las diarias. Como resultado de estos cambios dispares en Rx1 y TOT, se proyecta un incremento de la concentración de la precipitación, esto es, Rx1 aportará más a TOT. Dicho de otra forma, esto último indica que se espera que la lluvia diaria más fuerte tenga mayores acumulados, mientras que los eventos de precipitación de menor intensidad serán más débiles. Futuros trabajos deben indagar en profundidad sobre las causas físicas asociadas a los cambios proyectados en Rx1 y TOT en el NOA, y además, en determinar las causas de los sesgos en los modelos en la representación de los valores climatológicos medios. Respecto a esto último, es necesario complementar el análisis realizado con un enfoque diferente y más completo al utilizado aquí, el cual consiste

en seleccionar los mejores modelos mediante el análisis de su capacidad de representar los patrones típicos de circulación asociados a la precipitación (por ej., Olmo et al., 2022). Más allá de esto, los resultados presentados aquí son útiles como una primera aproximación al estudio de las proyecciones climáticas en escenarios de calentamiento global en la región.

Como conclusión general, esta tesis muestra que la precipitación extrema en el NOA responde significativamente tanto a forzantes naturales (ENSO, SAM y PDO) como antropogénicos (aumento de GHG y posiblemente O₃ polar). Se determinó que la mayor intensidad de precipitación se observa bajo la fase cálida de PDO, donde la variabilidad interanual está relacionada a SAM, y por otra parte, la precipitación se proyecta más intensa bajo el escenario de mayor calentamiento global proyectado en relación al aumento de GHG.

Esta tesis realiza un aporte al conocimiento de los forzantes naturales y antropogénicos de la variabilidad de la precipitación extrema en el NOA, una región donde a la fecha había muy pocos estudios realizados en este sentido. La importancia de la temática de esta tesis se ve aumentada debido a la confluencia de una variabilidad natural del clima con un escenario de calentamiento global. En este sentido, esta tesis provee una base desde la cual se proponen futuras líneas de investigación para profundizar en el conocimiento de los forzantes de la precipitación en la región, con el fin último de lograr proyecciones con la menor incertidumbre posible y disminuir los riesgos para la sociedad.

Apéndice: Difusión de los resultados de esta tesis

Artículos publicados en revistas científicas (con referato)

1- Medina, F., Bazzano, F., Heredia, T., Elias, A., 2021. *Posibles forzantes de variaciones de largo plazo de la precipitación de verano en Tucumán, Argentina*. Meteorológica; 46; 1;26-47. <https://doi.org/10.24215/1850468Xe003>

2- Medina, F., Zossi, B., Bossolasco, A., Elias, A., 2023. *Performance of CHIRPS dataset for monthly and annual rainfall-indices in Northern Argentina*. Atmospheric Research, Volume 283, 2023, 106545, ISSN 0169-8095. <https://doi.org/10.1016/j.atmosres.2022.106545>

Trabajos presentados en congresos (formato póster)

1- Medina, F., Zossi, B., Bossolasco, A., Elias, A. *Evaluación de la base de datos CHIRPS para reproducir la variabilidad interanual de índices de precipitación en el Norte de Argentina*. XIV Congreso Argentino de Meteorología (CONGREGMET 2022), Buenos Aires, Argentina, 7-11 de noviembre de 2022. http://cenamet.org.ar/congremet/wp-content/uploads/2023/02/LibroActas_compressed.pdf

2- Medina, F., Zossi, B., Elias, A. *ENSO y SAM como forzantes de la variabilidad interanual de la intensidad de la precipitación en Tucumán (Argentina)*. XXX Reunión de la Asociación de Geofísicos y Geodestas (AAGG 2024), Buenos Aires, Argentina, 15-19 de Abril, 2024.

Bibliografía

Adler, F. J., 2006. Los Embalses y los Recursos Hídricos Superficiales. CET. Revista de la Facultad de Ciencias Exactas y Tecnología de la Universidad Nacional de Tucumán, 27, 12. <http://www.ecopuerto.com/bicentenario/informes/EMBALSESYRECHIDRIC.pdf>

Andreoli RV, Kayano MT., 2005. ENSO-related rainfall anomalies in South America and associated circulation features during warm and cold Pacific decadal oscillation regimes. *International Journal of Climatology* 25: 2071–2030. <https://doi.org/10.1002/joc.1222>

Bahaga, TK, Fink, AH, Knippertz, P., 2019. Revisiting interannual to decadal teleconnections influencing seasonal rainfall in the Greater Horn of Africa during the 20th century. *Int J Climatol.*, 39: 2765– 2785. <https://doi.org/10.1002/joc.5986>

Balmaceda Huarte, R., Olmo, M.E., Bettolli, M.L., Poggi, M.M., 2021. Evaluation of multiple reanalyses in reproducing the spatio-temporal variability of temperature and precipitation indices over southern South America. *Int J Climatol.* 41: 5572– 5595. <https://doi.org/10.1002/joc.7142>

Baez-Villanueva, O.M., Zambrano-Bigiarini, M., Ribbe, L., Nauditt, A., Giraldo-Osorio, J.D., Xuan, N., & Thinh, N.X., 2018. Temporal and spatial evaluation of satellite rainfall estimates over different regions in Latin-America, *Atmos. Res.*, 213, 34-50. <https://doi.org/10.1016/j.atmosres.2018.05.011>

Barreiro, M., Diaz, N., Renom, M., 2014. Role of the global oceans and land-atmosphere interaction on summertime interdecadal variability over northern Argentina. *Climate Dynamics*, 42, 1733-1753. <https://doi.org/10.1007/s00382-014-2088-6>

Barros, V., Castañeda M. E., Doyle M., 2000. Recent Precipitation Trends in Southern South America East of the Andes. An Indication of Climatic Variability. In: Smolka P., Volkheimer W. (eds) *Southern Hemisphere Paleo- and Neoclimates*. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-59694-0_13

Bazzano, F. M., Heredia, T., Elías, A. G., Lamelas, C. M., & Forciniti, J., 2019. Tendencias en la precipitación en Tucumán bajo efecto del cambio climático. *Meteorologica*, 44(2), 1-14.

Bhattacharyya, S., Sreekesh, S., King, A., 2022. Characteristics of extreme rainfall in different gridded datasets over India during 1983–2015. *Atmospheric Research*, 267, 105930. <https://doi.org/10.1016/j.atmosres.2021.105930>

Biasutti, M., 2013. Climate change, future rise in rain inequality. *Nature Geoscience* 6, 337–338. <https://doi.org/10.1038/ngeo1814>

Boucher, O., Servonnat, J., Albright, A. L., Aumont, O., Balkanski, Y., & Bastrikov, V., et al., 2020. Presentation and evaluation of the IPSL-CM6A-LR climate model. *Journal of Advances in Modeling Earth Systems*, 12, e2019MS002010. <https://doi.org/10.1029/2019MS002010>

Cai, W., Cowan, T., 2007. Trends in Southern Hemisphere Circulation in IPCC AR4 Models over 1950–99. *Ozone Depletion versus Greenhouse Forcing J. Climate*, 20,681–693. <https://doi.org/10.1175/JCLI4028.1>

Cai, W., McPhaden, M.J., Grimm, A.M. et al., 2020. Climate impacts of the El Niño–Southern Oscillation on South America. *Nat Rev Earth Environ* 1, 215–231 (2020). <https://doi.org/10.1038/s43017-020-0040-3>

Cao, J., Wang, B., Yang, Y.-M., Ma, L., Li, J., Sun, B., Bao, Y., He, J., Zhou, X., and Wu, L., 2018. The NUIST Earth System Model (NESM) version 3: description and preliminary evaluation, *Geosci. Model Dev.*, 11, 2975–2993. <https://doi.org/10.5194/gmd-11-2975-2018>

Carvalho, L.M.V., Jones, C., Silva, A.E., Liebmann, B. and Silva Dias, P.L., 2011. The South American Monsoon System and the 1970s climate transition. *Int. J. Climatol.*, 31: 1248-1256. <https://doi.org/10.1002/joc.2147>

Carvalho, L.M.V., 2020. Assessing precipitation trends in the Americas with historical data: A review. *WIREs Clim Change*. 2020; 11:e627. <https://doi.org/10.1002/wcc.627>

Castino, F., Bookhagen, B., Strecker, M. R., 2017. Rainfall variability and trends of the past six decades (1950–2014) in the subtropical NW Argentine Andes. *Climate Dynamics*, 48(3), 1049-1067. <https://doi.org/10.1007/s00382-016-3127-2>

Cavalcante, R.B.L., da Silva Ferreira, D.B., Pontes, P.R.M., Tedeschi, R.G., da Costa, C.P.W., de Souza, E.B., 2020. Evaluation of extreme rainfall indices from CHIRPS precipitation estimates over the Brazilian Amazonia. *Atmospheric Research*, 238, 104879. <https://doi.org/10.1016/j.atmosres.2020.104879>

Cavalcanti, I. F. A., Barreto, N. J. C., Alvarez, M. S., Osman, M., & Coelho, C. A. S., 2021. Teleconnection patterns in the Southern Hemisphere represented by ECMWF and NCEP S2S project models and influences on South America precipitation. *Meteorological Applications*, 28(4), e2011. <https://doi.org/10.1002/met.2011>

Cerón, W.L., Kayano, M.T., Andreoli, R.V., Avila-Diaz, A., Ayes, I., Freitas, E.D., Martins, J.A., Souza, R.A.F., 2021. Recent intensification of extreme precipitation events in the La Plata Basin in Southern South America (1981–2018). *Atmospheric Research*, Volume 249, 2021, 105299, ISSN 0169-8095. <https://doi.org/10.1016/j.atmosres.2020.105299>

Cerón, W.L., Molina-Carpio, J., Ayes Rivera, I., et al, 2020. A principal component analysis approach to assess CHIRPS precipitation dataset for the study of climate variability of the La Plata Basin, Southern South America. *Nat Hazards*, 103, 767–783. <https://doi.org/10.1007/s11069-020-04011-x>

de Moraes Cordeiro, A.L., Blanco, C.J.C., 2021. Assessment of satellite products for filling rainfall data gaps in the Amazon region. *Natural Resource Modeling*. 34:e12298. <https://doi.org/10.1111/nrm.12298>

Chen, T. S., Weng, S., Schubert, S., 1999. Maintenance of Austral Summertime Upper-Tropospheric Circulation over Tropical South America. The Bolivian High–Nordeste Low System. *J. Atmos. Sci.*, 56, 2081–2100, [https://doi.org/10.1175/1520-0469\(1999\)056<2081:MOASUT>2.0.CO;2](https://doi.org/10.1175/1520-0469(1999)056<2081:MOASUT>2.0.CO;2)

Chen, J., Dai, A., Zhang, Y., Rasmussen, K.L., 2020. Changes in Convective Available Potential Energy and Convective Inhibition under Global Warming. *J. Climate*, 33, 2025–2050, <https://doi.org/10.1175/JCLI-D-19-0461.1>

Cionco, R. G., Pavlov, D. A., 2018: Solar barycentric dynamics from a new solar-planetary ephemeris. *Astron. Astrophys.* 615, A153. <https://doi.org/10.1051/0004-6361/201732349>

Compo, G. P., Whitaker, J. S., Sardeshmukh, P. D., Matsui, N., Allan, R. J., Yin, X., et al., 2011. The Twentieth Century Reanalysis Project. *Quarterly J. Roy. Meteorol. Soc.*, 137, 1-28. <https://doi.org/10.1002/qj.776>

Danabasoglu, G., Lamarque, J.-F., Bacmeister, J., Bailey, D. A., DuVivier, A. K., Edwards, J., et al., 2020. The Community Earth System Model Version 2 (CESM2). *Journal of Advances in Modeling Earth Systems*, 12, e2019MS001916. <https://doi.org/10.1029/2019MS001916>

Daohua Bi, Martin Dix, Simon Marsland, Siobhan O'Farrell, Arnold Sullivan, et al., 2020. Configuration and spin-up of ACCESS-CM2, the new generation Australian Community Climate and Earth System Simulator coupled model. *Journal of Southern Hemisphere Earth Systems Science*, 70 (1) : 225–251. <https://doi.org/10.1071/ES19040>

de la Casa, A.C., Ovando, G.G., Díaz, G.J, 2019. Interannual variability of seasonal rainfall in Cordoba, Argentina, evaluated from ENSO and ENSO Modoki signals and verified with MODIS NDVI data. *SN Appl. Sci.* 1, 1624. <https://doi.org/10.1007/s42452-019-1650-6>

de Medeiros, F. J., and de Oliveira, C. P., 2022. Assessment of dry and heavy rainfall days and their projected changes over Northeast Brazil in Coupled Model Intercomparison Project Phase 6 models. *International Journal of Climatology*, 42(16), 8665–8686. <https://doi.org/10.1002/joc.7759>

Díaz, L. B., Saurral, R. I. and C. S. Vera, 2021. Assessment of South America summer rainfall climatology and trends in a set of global climate models large ensembles. *International Journal of Climatology*, 41 (S1), E59–E77. <https://doi.org/10.1002/joc.6643>

Díaz, L.B. and Vera, C.S., 2017. Austral summer precipitation interannual variability and trends over Southeastern South America in CMIP5 models. *Int. J. Climatol*, 37: 681-695. <https://doi.org/10.1002/joc.5031>

Digonzelli, P., & Romero, E. R., 2013. La caña de azúcar y la disponibilidad hídrica. *Avance Agroindustrial*, 34, 14-15.

Döscher, R., Acosta, M., Alessandri, A., Anthoni, P., Arsouze, T., Bergman, T., et al., 2022. The EC-Earth3 Earth system model for the Coupled Model Intercomparison Project 6, *Geosci. Model Dev.*, 15, 2973–3020. <https://doi.org/10.5194/gmd-15-2973-2022>

Doyle, ME, 2020. Observed and simulated changes in precipitation seasonality in Argentina. *Int J Climatol*. 2020; 40: 1716– 1737. <https://doi.org/10.1002/joc.6297>

Du, Y., Wang, D., Zhu, J., Wang, D., Qi, X., & Cai, J., 2022. Comprehensive assessment of CMIP5 and CMIP6 models in simulating and projecting precipitation over the global land. *International Journal of Climatology*, 42(13), 6859–6875. <https://doi.org/10.1002/joc.7616>

Dunn, R. J. H., Alexander, L. V., Donat, M. G., Zhang, X., Bador, M., Herold, N., et al., 2020. Development of an updated global land in situ-based data set of temperature and precipitation extremes: HadEX3. *Journal of Geophysical Research: Atmospheres*, 125, e2019JD032263. <https://doi.org/10.1029/2019JD032263>

Dunne, J. P., Horowitz, L. W., Adcroft, A. J., Ginoux, P., Held, I. M., John, J. G., et al., 2020. The GFDL Earth System Model Version 4.1 (GFDL-ESM 4.1): Overall coupled model description and simulation characteristics. *Journal of Advances in Modeling Earth Systems*, 12, e2019MS002015. <https://doi.org/10.1029/2019MS002015>

Enfield, D.B., A.M. Mestas-Nunez, and P.J. Trimble, 2001. The Atlantic Multidecadal Oscillation and its relationship to rainfall and river flows in the continental U.S., *Geophys. Res. Lett.*, 28: 2077-2080. <https://doi.org/10.1029/2000GL012745>

Eyring, V., Bony, S., Meehl, G. A., Senior, C. A., Stevens, B., Stouffer, R. J., and Taylor, K. E., 2016. Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization, *Geosci. Model Dev.*, 9, 1937–1958, <https://doi.org/10.5194/gmd-9-1937-2016>

Faiz, M.A., Liu, D., Fu, Q., Sun, Q., Li, M., Baig, F., Li, T & Cui, S., 2018. How accurate are the performances of gridded precipitation data products over Northeast China?. *Atmospheric Research*, 211, 12-20. <https://doi.org/10.1016/j.atmosres.2018.05.006>

Fernández, D., Lutz, M., 2010. Urban flood hazard zoning in Tucumán Province, Argentina, using GIS and multicriteria decision analysis. *Engineering Geology*, Volume 111, Issues 1–4, 2010, Pages 90-98, ISSN 0013-7952. <https://doi.org/10.1016/j.enggeo.2009.12.006>

Ferrero, M.A., Villalba R., 2019. Interannual and Long-Term Precipitation Variability Along the Subtropical Mountains and Adjacent Chaco ,22–29° S: in Argentina, *Front. Earth Sci.*, 7, 148. <https://doi.org/10.3389/feart.2019.00148>

Fink, A.H., Schrage, J.M., Kotthaus, S., 2010. On the potential causes of the nonstationary correlations between West African precipitation and Atlantic hurricane activity. *Journal of Climate*, 23, 5437–5456. <https://doi.org/10.1175/2010JCLI3356.1>

Fogt, RL, Marshall, GJ, 2020. The Southern Annular Mode: Variability, trends, and climate impacts across the Southern Hemisphere. *WIREs Clim Change*. 2020; 11:e652. <https://doi.org/10.1002/wcc.652>

Fowler, H.J., Lenderink, G., Prein, A.F. et al., 2021. Anthropogenic intensification of short-duration rainfall extremes. *Nat Rev Earth Environ* 2, 107–122. <https://doi.org/10.1038/s43017-020-00128-6>

Funk, C., Peterson, P., Landsfeld, M. et al, 2015. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Sci Data* 2, 150066. <https://doi.org/10.1038/sdata.2015.66>

Gan, M.A., Rao, V.B., Moscati, M.C.L., 2005. South American monsoon indices. *Atmosph. Sci. Lett.*, 6. 219-223. <https://doi.org/10.1002/asl.119>

Garbarini, EM, González, MH, Rolla, AL, 2021. Modulation of seasonal precipitation in Argentina by the South Pacific high. *Int J Climatol.*; 41 (Suppl. 1): E3279–E3297. <https://doi.org/10.1002/joc.6924>

Garreaud R., Aceituno P., 2001. Interannual rainfall variability over the South American Altiplano. *J Clim* 14:2779–2789. [https://doi.org/10.1175/1520-0442\(2001\)014<2779:IRVOTS>2.0.CO;2](https://doi.org/10.1175/1520-0442(2001)014<2779:IRVOTS>2.0.CO;2)

Garreaud, RD, Boisier, JP, Rondanelli, R, Montecinos, A, Sepúlveda, HH, Veloso-Aguila, D, 2020. The Central Chile Mega Drought (2010–2018): A climate dynamics perspective. *Int J Climatol.* 40, 421– 439. <https://doi.org/10.1002/joc.6219>

Giorgi, F., Raffaele, F., and Coppola, E., 2019. The response of precipitation characteristics to global warming from climate projections, *Earth Syst. Dynam.*, 10, 73–89. <https://doi.org/10.5194/esd-10-73-2019>

Gong, D., Wang, S., 1999. Definition of Antarctic oscillation index. *Geophysical research letters*, 26(4), 459-462.

González, M., Garbarini, E., Rolla, A. and Eslamian, S., 2017. Meteorological drought indices: rainfall prediction in argentina. In: Eslamian, S. (Ed.) *Handbook of Drought and Water Scarcity. Principle of Drought and Water Scarcity*. Vol. 1. Chapter 29. Abingdon, England: Taylor & Francis Publishing (CRC Group), pp. 540–567.

Gonzalez, M., Polvani, L.M., Seager, R., 2014. Stratospheric ozone depletion. a key driver of recent precipitation trends in South Eastern South America *Clim Dyn*: 42, 1775. <https://doi.org/10.1007/s00382-013-1777-x>

Grimm, A. M., and Tedeschi, R. G., 2009. ENSO and Extreme Rainfall Events in South America, *Journal of Climate*, 22(7), 1589-1609. <https://doi.org/10.1175/2008JCLI2429.1>

Grinsted, A., Moore, J., Jevrejeva, S., 2004. Application of the cross wavelet transform and wavelet coherence to geophysical time series. *Nonlinear Process Geophys*. 11, 561–566. <https://doi.org/10.5194/npg-11-561-2004>

Gulizia, C. and Camilloni, I., 2015. Comparative analysis of the ability of a set of CMIP3 and CMIP5 global climate models to represent precipitation in South America. *Int. J. Climatol.*, 35: 583-595. <https://doi.org/10.1002/joc.4005>

Gulizia, C.N., Raggio, G.A., Camilloni, I.A. et al., 2022. Changes in mean and extreme climate in southern South America under global warming of 1.5 °C, 2 °C, and 3 °C. *Theor Appl Climatol* 150, 787–803. <https://doi.org/10.1007/s00704-022-04199-x>

Gupta, V., Jain, M.K., Singh, P.K., Singh, V., 2019. An assessment of global satellite-based precipitation datasets in capturing precipitation extremes: a comparison with observed precipitation dataset in India. *Int. J. Climatol.* <https://doi.org/10.1002/joc.6419>

Hamed, K.H., Rao, A.R., 1998. A modified Mann-Kendall trend test for autocorrelated data. *J. Hydrol.* 204 (1–4), 182–196. [https://doi.org/10.1016/S0022-1694\(97\)00125-X](https://doi.org/10.1016/S0022-1694(97)00125-X)

Hamed, K.H., 2008. Trend detection in hydrologic data. The Mann–Kendall trend test under the scaling hypothesis. *J. Hydrol.* 349, 350– 363, <https://doi.org/10.1016/j.jhydrol.2007.11.009>

Harrison, L., Funk, C., Peterson, P., 2019. Identifying changing precipitation extremes in Sub-Saharan Africa with gauge and satellite products. *Environ. Res. Lett.* 14, 085007. <https://doi.org/10.1088/1748-9326/ab2cae>

Hersbach, H, Bell, B, Berrisford, P, et al., 2020. The ERA5 global reanalysis. *Q J R Meteorol Soc.*, 146: 1999–2049. <https://doi.org/10.1002/qj.3803>

Heredia T., Bazzano F. M., Cionco R.G., Soon W, Medina F. D., Elias A. G., 2019: Searching for solar-like interannual to bidecadal effects on temperature and precipitation over a Southern Hemisphere location. *Journal of Atmospheric and Solar-Terrestrial Physics*, Volume 193, 2019, 105094, ISSN 1364-6826, <https://doi.org/10.1016/j.jastp.2019.105094>

Ho, M., Kiem, A. S., and Verdon-Kidd, D. C., 2012. The Southern Annular Mode: a comparison of indices. *Hydrol. Earth Syst. Sci.*, 16, 967–982, <https://doi.org/10.5194/hess-16-967-2012>

Hurtado, S., Zaninelli, P., Agosta, E., 2020. A multi-breakpoint methodology to detect changes in climatic time series. An application to wet season precipitation in subtropical Argentina, *Atmospheric Research*, Volume 241, 2020, 104955, ISSN 0169-8095, <https://doi.org/10.1016/j.atmosres.2020.104955>

Hurtado, SI, Agosta, EA., 2021. El Niño Southern Oscillation-related precipitation anomaly variability over eastern subtropical South America: Atypical precipitation seasons. *Int J Climatol.* 2021; 41: 3793– 3812. <https://doi.org/10.1002/joc.6559>

Kang, S. M., Polvani, L. M., Fyfe J. C., Sigmond M., 2011. Impact of Polar Ozone Depletion on Subtropical Precipitation. *Science.* 332, 6032, 951-954. <https://doi.org/10.1126/science.1202131>

Karl, T. R., Nicholls, N., & Ghazi, A., 1999. Clivar/GCOS/WMO workshop on indices and indicators for climate extremes workshop summary. *Weather and climate extremes*, pp. 3-7. Springer, Dordrecht. https://doi.org/10.1007/978-94-015-9265-9_2

Katsanos, D., Retalis, A., Tymvios, F., et al., 2016. Analysis of precipitation extremes based on satellite (CHIRPS) and in situ dataset over Cyprus. *Nat Hazards* 83, 53–63. <https://doi.org/10.1007/s11069-016-2335-8>

Kayano, MT, Andreoli, RV, Souza, Rodrigo Augusto Ferreira de, 2019. El Niño–Southern Oscillation related teleconnections over South America under distinct Atlantic Multidecadal Oscillation and Pacific Interdecadal Oscillation backgrounds: La Niña. *Int J Climatol.* 39: 1359–1372. <https://doi.org/10.1002/joc.5886>

Kendall, M.G., 1955. *Rank Correlation Methods*. Griffin, London.

Knight, J. R., Folland, C. K., and Scaife, A., 2006. Climate impacts of the Atlantic Multidecadal Oscillation. *Geophys. Res. Lett.*, 33, L17706. <https://doi.org/10.1029/2006GL026242>

Knutti, R., 2010. The end of model democracy? *Climate Change*, 102(2), 395–404. <https://doi.org/10.1007/s10584-010-9800-2>

Krepper, C.M. and García, N.O., 2004. Spatial and temporal structure of trends and interannual variability of precipitation over La Plata Basin. *Quaternary International*, 114, 11–21. [https://doi.org/10.1016/S1040-6182\(03\)00038-7](https://doi.org/10.1016/S1040-6182(03)00038-7)

Kucharski, F., A. Bracco, J. H. Yoo, and F. Molteni (2007). Low-frequency variability of the Indian monsoon–ENSO relationship and the tropical Atlantic: The “weakening” of the 1980s and 1990s. *J. Clim.*, 20, 4255– 4266. <https://doi.org/10.1175/JCLI4254.1>

Labitzke, K., 1987. Sunspots, the QBO, and the stratospheric temperature in the north polar region, *Geophys. Res. Lett.* 14, 135-137. <https://doi.org/10.1029/GL014i005p00535>

Labitzke, K. and H. van Loon, 1988. Associations between the 11-year solar cycle, the QBO and the atmosphere. Part I: the troposphere and stratosphere in the northern hemisphere in winter. *J. Atmos. Terr. Phys.*, 50, 197-206. [https://doi.org/10.1016/0021-9169\(88\)90068-2](https://doi.org/10.1016/0021-9169(88)90068-2)

Laing, A. G., Fritch, J. M., 2000. The large-scale environments of the global populations of mesoscale convective complexes. *Mon. Wea. Rev.*, 128, 2756-2776. [https://doi.org/10.1175/1520-0493\(2000\)128<2756:TLSEOT>2.0.CO;2](https://doi.org/10.1175/1520-0493(2000)128<2756:TLSEOT>2.0.CO;2)

Li, L., Yu, Y., Tang, Y., Lin, P., Xie, J., Song, M., et al., 2020. The flexible global ocean-atmosphere-land system model grid-point version 3 (fgoals-g3): description and evaluation. *Journal of Advances in Modeling Earth Systems*, 12, e2019MS002012. <https://doi.org/10.1029/2019MS002012>

Li, XF., Blenkinsop, S., Barbero, R. et al., 2020. Global distribution of the intensity and frequency of hourly precipitation and their responses to ENSO. *Clim Dyn* 54, 4823–4839. <https://doi.org/10.1007/s00382-020-05258-7>

Liu, J., Shangguan, D., Liu, S., Ding, Y., Wang, S., Wang, X., 2019. Evaluation and comparison of CHIRPS and MSWEP daily-precipitation products in the Qinghai-Tibet Plateau during the period of 1981–2015. *Atmospheric Research*, Volume 230, 104634, ISSN 0169-8095. <https://doi.org/10.1016/j.atmosres.2019.104634>

Llano, M.P., 2018. Spatial distribution of the daily rainfall concentration index in Argentina: comparison with other countries. *Theor Appl Climatol* 133, 997–1007. <https://doi.org/10.1007/s00704-017-2236-0>

Lovato, T., Peano, D., Butenschön, M., Materia, S., Iovino, D., Scoccimarro, E., et al., 2022. CMIP6 simulations with the CMCC Earth System Model (CMCC-ESM2). *Journal of Advances in Modeling Earth Systems*, 14, e2021MS002814. <https://doi.org/10.1029/2021MS002814>

Lovino, M.A., Müller, O.V., Berbery, E.H., Müller, G.V., 2018. How have daily climate extremes changed in the recent past over northeastern Argentina?. *Global and Planetary Change*, 168, 78-97. <https://doi.org/10.1016/j.gloplacha.2018.06.008>

Lovino, M.A., Pierrestegui, M.J., Müller, O.V., Berbery, E.H., Müller, G.V. and Pasten, M., 2021. Evaluation of historical CMIP6 model simulations and future projections of temperature and precipitation in Paraguay. *Climatic Change*, 164, 46. <https://doi.org/10.1007/s10584-021-03012-4>

Lucas C., Timbal B., Nguyen, H., 2014. The expanding tropics. a critical assessment of the observational and modeling studies. *WIREs Clim Change*, 5. 89-112. <https://doi.org/10.1002/wcc.251>

Mann, H.B., 1945. Nonparametric tests against trend. *Econometrica* 13. <https://doi.org/10.2307/1907187>

Mantua, N.J., S.R. Hare, Y. Zhang, J.M. Wallace, and R.C. Francis, 1997. A Pacific interdecadal climate oscillation with impacts on salmon production. *Bulletin of the American Meteorological Society*, 78, pp. 1069-1079.

Mantua N. and Hare S., 2002. The Pacific decadal oscillation. *Journal of Oceanography*, 58, 35–44.

Marengo, J.A., Soares, W.R., Saulo, C., Nicolini, M., 2004. Climatology of the Low-Level Jet East of the Andes as Derived from the NCEP–NCAR Reanalyses. *Characteristics and Temporal Variability. J. Climate*, 17, 2261–2280. <https://doi.org/10.1175/1520-0442,2004:017<2261.COTLJE>2.0.CO;2>

Marengo, J.A., Liebmann, B., Grimm, A.M., Misra, V., Silva Dias, P.L., Cavalcanti, I.F.A., Carvalho, L.M.V., et al., 2012. Recent developments on the South American monsoon system. *Int. J. Climatol.*, 32: 1-21. <https://doi.org/10.1002/joc.2254>

Marwan, N., Trauth, M.H., Vuille, M. et al., 2003. Comparing modern and Pleistocene ENSO-like influences in NW Argentina using nonlinear time series analysis methods. *Climate Dynamics* 21, 317–326. <https://doi.org/10.1007/s00382-003-0335-3>

Marshall, G. J., 2003. Trends in the Southern Annular Mode from observations and reanalyses. *J. Clim.*, 16, 4134-4143, <https://doi.org/10.1175/1520-0442%282003%29016<4134%3ATITSAM>2.0.CO%3B2>

Mauritsen, T., Bader, J., Becker, T., Behrens, J., Bittner, M., Brokopf, R., et al., 2019. Developments in the MPI-M Earth System Model version 1.2 (MPI-ESM1.2) and its response to increasing CO₂. *Journal of Advances in Modeling Earth Systems*, 11, 998–1038. <https://doi.org/10.1029/2018MS001400>

Medina, E. R. y. Minetti, J. L., 2004: El salto climático y su impacto en la frecuencia de precipitaciones máximas diarias en San Miguel de Tucumán. X Reunión y LV Latinoamericana de Agrometeorología. Mar del Plata, Argentina.

Meehl, G.A., Stocker, T. F., Collins, W. D., Friedlingstein, P., Gaye, T., Gregory, J. M., et al., 2007. Global Climate Projections. In *Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*, Cambridge University Press, pp 747-846

Mindlin, J., T. G. Shepherd, C. Vera, and M. Osman, 2021. Combined Effects of Global Warming and Ozone Depletion/Recovery on Southern Hemisphere Atmospheric Circulation and Regional Precipitation. *Geophysical Research Letters*, 48 (12). <https://doi.org/10.1029/2021GL092568>

Mindlin, J., C. S. Vera, T. G. Shepherd, and M. Osman, 2023. Plausible Drying and Wetting Scenarios for Summer in Southeastern South America. *J. Climate*, 36, 7973–7991, <https://doi.org/10.1175/JCLI-D-23-0134.1>

Minetti, J. L., Leiva, M. del V., 2005. Variabilidad y Cambio Climático en el Noroeste Argentino. Cap. 12 en *El Clima en el NOA*. 410 páginas. ISBN: 987-9390-66-0. Edit. Magna. S Miguel de Tucumán. Tucumán. Argentina.

Minetti, J. L.; Vargas, W. M., 1997. Trends and jumps in the annual precipitation in South America, south of the 15°S. *Atmósfera*, ISSN 0187-6236, 11, 4, 205-221

Minetti, J.L., Vargas, W.M., Poblete, A.G., Acuña, L.R., Casagrande, G., 2003. Non-linear trends and low frequency oscillations in annual precipitation over Argentina and Chile, 1931-1999, *Atmósfera*, 16, 119-135.

Montecinos, A., Díaz, A., Aceituno, P., 2000. Seasonal Diagnostic and Predictability of Rainfall in Subtropical South America Based on Tropical Pacific SST, *Journal of Climate*, 13(4), 746-758. [https://doi.org/10.1175/1520-0442\(2000\)013<0746:SDAPOR>2.0.CO;2](https://doi.org/10.1175/1520-0442(2000)013<0746:SDAPOR>2.0.CO;2)

Nawaz, M., Iqbal, M.F., Mahmood, I., 2021. Validation of CHIRPS satellite-based precipitation dataset over Pakistan. *Atmospheric Research*, 248. <https://doi.org/10.1016/j.atmosres.2020.105289>

Newman, M., Alexander, M. A., Ault, T. R., Cobb, K. M., et al., 2016. The Pacific Decadal Oscillation, Revisited. *Journal of Climate*, 29(12), 4399-4427. <https://doi.org/10.1175/JCLI-D-15-0508.1>

Nicolini M, Saulo A., Torres J., Salio P., 2002. Enhanced precipitation over Southeastern South America related to strong low-level jet events during austral warm season. *Meteorologica, Special Issue for the South American Monsoon System*. 27.

Paredes Trejo, F.J., Alves Barbosa, H., Peñaloza-Murillo, M.A., Moreno, M.A., & Farías, A., 2016. Intercomparison of improved satellite rainfall estimation with CHIRPS gridded product and rain gauge data over Venezuela. *Atmósfera*, 29 (4), 323-342.

Penalba, O.C. and Rivera, J.A., 2016. Regional aspects of future precipitation and meteorological drought characteristics over Southern South America projected by a CMIP5 multi-model ensemble. *Int. J. Climatol.*, 36: 974-986. <https://doi.org/10.1002/joc.4398>

Pettitt A. N., 1979. A non-parametric approach to the change-point problema. *Appl. Stat.* 28. 126–135

Polvani, L.M., Waugh, D.W., Correa, G.J., Son S., 2011. Stratospheric Ozone Depletion: The Main Driver of Twentieth-Century Atmospheric Circulation Changes in the Southern Hemisphere. *J. Climate*, 24, 795–812, <https://doi.org/10.1175/2010JCLI3772.1>

Olmo, M.E., Bettolli, M.L., 2021. Extreme daily precipitation in southern South America: statistical characterization and circulation types using observational datasets and regional climate models. *Clim Dyn* 57, 895–916. <https://doi.org/10.1007/s00382-021-05748-2>

Olmo, M. E., Espinoza, J.-C., Bettolli, M. L., Sierra, J. P., Junquas, C., Arias, P. A., et al., 2022. Circulation patterns and associated rainfall over south tropical South America: GCMs evaluation during the dry-to-wet transition season. *Journal of Geophysical Research: Atmospheres*, 127, e2022JD036468. <https://doi.org/10.1029/2022JD036468>

O'Neill, B., van Aalst, M., Zaiton Ibrahim, Z., Berrang Ford, L., Bhadwal, S., Buhaug, H. et al., 2022. Key Risks Across Sectors and Regions. In: *Climate Change 2022: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change* [H.-O. Pörtner, D.C. Roberts, M. Tignor, et al. (eds.)]. Cambridge University Press, Cambridge, UK and New York, NY, USA, pp. 2411–2538. <https://doi.org/10.1017/9781009325844.025>

Penalba O. and Robledo F., 2010. Spatial and temporal variability of the frequency of extreme daily rainfall regime in the La Plata Basin during the 20th century. *Clim. Change* 98: 531–550. <https://doi.org/10.1007/s10584-009-9744-6>

Pfahl, S., O’Gorman, P. A., & Fischer, E. M., 2017. Understanding the regional pattern of projected future changes in extreme precipitation. *Nature Climate Change*, 7(6), 423-427. <https://doi.org/10.1038/nclimate3287>

Poblete AG, Minetti JL, Sierra AM., 1989. La Influencia del Régimen Hidrico Andino-Puneño en el Oasis del Noroeste Argentino y Cuyo. *Rev de geofisica*, 30, 137-149

Rayner N. A., D. E. Parker, E. B. Horton, C. K. Folland, L. V. Alexander, D. P. Rowell, E. C. Kent, A., 2003. Kaplan, Global analyses of sea surface temperature, sea ice, and night marine air temperature since the late nineteenth century, *J. Geophys. Res.*, 108 (D14), 4407, <https://doi.org/10.1029/2002JD002670>

Reboita, M.S., Ambrizzi, T., Crespo, N.M., Dutra, L.M.M., Ferreira, G.W.d.S., et al., 2021. Impacts of teleconnection patterns on South America climate. *Ann. N.Y. Acad. Sci.*, 1504: 116-153. <https://doi.org/10.1111/nyas.14592>

Rivera, J. A., Hinrichs, S., Marianetti, G., 2019. Using CHIRPS Dataset to Assess Wet and Dry Conditions along the Semiarid Central-Western Argentina. *Advances in Meteorology*. <https://doi.org/10.1155/2019/8413964>

Rivera, J.A., Marianetti, G., Hinrichs, S., 2018. Validation of CHIRPS precipitation dataset along the Central Andes of Argentina. *Atmospheric Research*, Volume 213, pp 437-449, ISSN 0169-8095. <https://doi.org/10.1016/j.atmosres.2018.06.023>

Rivera, J. A., Penalba, O. C., 2015. El Niño/La Niña events as a tool for regional drought monitoring in Southern South America. *Drought: research and science-Policy interfacing*, 293-299. <https://doi.org/10.1201/b18077-50>

Robledo, F, Vera, C, Penalba, O, 2020. Multi-scale features of the co-variability between global sea surface temperature anomalies and daily extreme rainfall in Argentina. *Int J Climatol.*; 40: 4289– 4299. <https://doi.org/10.1002/joc.6462>

Ropelewski, C.F. and Jones, P.D., 1987. An extension of the Tahiti-Darwin Southern Oscillation Index. *Monthly Weather Review* 115, 2161-2165. doi: 10.1175/1520-0493(1987)115%3C2161:AEOTTTS%3E2.0.CO;2

Saurral, R. I., Camilloni, I. A., Barros, V. R., 2017. Low-frequency variability and trends in centennial precipitation stations in southern South America. *Int. J. Climatol.*, 37. 1774-1793. <https://doi.org/10.1002/joc.4810>

Sen, P.K., 1968. Estimates of the regression coefficient based on Kendall's tau. *J. Am. Statist. Assoc.* 63, 1379–1389.

Seungmok Paik, Soon-II An, Seung-Ki Min, Andrew D. King, Soong-Ki Kim, 2023. Emergent constraints on future extreme precipitation intensification: from global to continental scales. *Weather and Climate Extremes*, Volume 42, 100613, ISSN 2212-0947, <https://doi.org/10.1016/j.wace.2023.100613>

Scardilli, A.S., Llano, M.P. & Vargas, W.M., 2017. Temporal analysis of precipitation and rain spells in Argentinian centenary reference stations. *Theor Appl Climatol* 127, 339–360. <https://doi.org/10.1007/s00704-015-1631-7>

Shrestha, D., Sharma, S., Hamal, K., Jadoon, U.K., Dawadi, B, 2021. Spatial Distribution of Extreme Precipitation Events and Its Trend in Nepal. *Applied Ecology and Environmental Sciences*. Vol. 9, No. 1, pp 58-66. <http://pubs.sciepub.com/aees/9/1/8>

Skansi, M., Brunet, M., Sigró, J., Aguilar, E., Arevalo, J.A.G., Bentancur, O.J., et al., 2013. Warming and wetting signals emerging from analysis of changes in climate extreme indices over South America. *Global and Planetary Change*. Volume 100, 2013, Pages 295-307, ISSN 0921-8181. <https://doi.org/10.1016/j.gloplacha.2012.11.004>

Subsecretaría de Recursos Hídricos de la Nación, 2010. Inventario de presas y centrales de la República Argentina. 1a ed. Buenos Aires : Ministerio de Planificación Federal, Inversión Pública y Servicios, 2010. 90 p. ISBN 978-987-23585-8-7

Sun, Q., Miao, C., Duan, Q., Ashouri, H., Sorooshian, S., & Hsu, K.-L., 2018. A review of global precipitation data sets: Data sources, estimation, and intercomparisons. *Reviews of Geophysics*, 56, 79– 107. <https://doi.org/10.1002/2017RG000574>

Swart, N. C., Cole, J. N. S., Kharin, V. V., Lazare, M., Scinocca, J. F., Gillett, N. P., Anstey, J., et al., 2019. The Canadian Earth System Model version 5 (CanESM5.0.3). *Geosci. Model Dev.*, 12, 4823–4873. <https://doi.org/10.5194/gmd-12-4823-2019>

Tatebe, H., Ogura, T., Nitta, T., Komuro, Y., Ogochi, K., Takemura, T., et al., 2019. Description and basic evaluation of simulated mean state, internal variability, and climate sensitivity in MIROC6, *Geosci. Model Dev.*, 12, 2727–2765. <https://doi.org/10.5194/gmd-12-2727-2019>

Thompson, D. and Wallace, J., 2000. Annular Modes in the Extratropical Circulation. Part I: Month-to-Month Variability, *Journal of Climate*, 13(5), 1000-1016. [https://doi.org/10.1175/1520-0442\(2000\)013<1000:AMITEC>2.0.CO;2](https://doi.org/10.1175/1520-0442(2000)013<1000:AMITEC>2.0.CO;2)

Torralba, V., Rodríguez-Fonseca, B., Mohino, E., & Losada, T., 2015. The non-stationary influence of the Atlantic and Pacific Niños on North Eastern South American rainfall. *Frontiers in Earth Science*, 3, 55. <https://doi.org/10.3389/feart.2015.00055>

Torrence, C., Compo, G.P., 1998: A practical guide to wavelet analysis. *Bull. Am. Met. Soc.* 79, 61–78. <https://doi.org/10.1175/1520-0477,1998:079<0061:APGTWA>2.0.CO;2>

Trauth, M., Bookhagen, B., Marwan, N., Strecker, M., 2003. Multiple landslide clusters record Quaternary climate changes in the northwestern Argentine Andes. *Palaeogeography*,

Palaeoclimatology, Palaeoecology, Volume 194, Issues 1–3, 109-121, ISSN 0031-0182, [https://doi.org/10.1016/S0031-0182\(03\)00273-6](https://doi.org/10.1016/S0031-0182(03)00273-6)

Trouet, V., Van Oldenborgh, G. J., 2013: KNMI Climate Explorer. a web-based research tool for high-resolution paleoclimatology, *Tree-Ring Research*, 69, 3-14. <https://doi.org/10.3959/1536-1098-69.1.3>

Van Oldenborgh, G.J., Coelho, C.A.S., Doblas-Reyes, F. J., 2008. Exploratory analysis and verification of seasonal forecasts with the KNMI climate explorer, *ECMWF Newsletter* 116, 4-5. <https://www.ecmwf.int/sites/default/files/elibrary/2008/14609-newsletter-no116-summer-2008.pdf>

Vargas, W., Minetti, J. and Poblete, 2002. A. Low-frequency oscillations in climatic and hydrological variables in southern South America's tropical-subtropical regions. *Theor Appl Climatol* 72, 29–40. <https://doi.org/10.1007/s007040200010>

Varuolo-Clarke, A. M., J. E. Smerdon, A. P. Williams, and R. Seager, 2021. Gross Discrepancies between Observed and Simulated Twentieth-to-Twenty-First-Century Precipitation Trends in Southeastern South America. *J. Climate*, 34, 6441–6457. <https://doi.org/10.1175/JCLI-D-20-0746.1>

Vasconcellos, F.C. and Cavalcanti, I.F., 2010. Extreme precipitation over Southeastern Brazil in the austral summer and relations with the Southern Hemisphere annular mode. *Atmosph. Sci. Lett.*, 11: 21-26. <https://doi.org/10.1002/asl.247>

Vera, C., Baez, J., Douglas, M., Emmanuel, C. B., Marengo, J., Meitin, J., Nicolini, M., et al., 2006. The South American Low-Level Jet Experiment. *Bulletin of the American Meteorological Society*, 87(1), 63-78. <https://doi.org/10.1175/BAMS-87-1-63>

Vera C., Díaz, L., 2015. Anthropogenic influence on summer precipitation trends over South America in CMIP5 models. *Int. J. Climatol.*, 35. 3172-3177. <https://doi.org/10.1002/joc.4153>

Vera C., Díaz L., Saurral R., 2019. Influence of Anthropogenically-Forced Global Warming and Natural Climate Variability in the Rainfall Changes Observed Over the South American Altiplano. *Front. Environ. Sci.* 7:87. <https://10.3389/fenvs.2019.00087>

Vera, C., Vigliarolo, P. K., Berbery, E.H., 2002. Cold season synoptic scale waves over subtropical South America. *Mon. Wea. Rev.*, 130, 684-699. [https://doi.org/10.1175/1520-0493\(2002\)130<0684:CSSSWO>2.0.CO;2](https://doi.org/10.1175/1520-0493(2002)130<0684:CSSSWO>2.0.CO;2)

Volodin, E. M., et al., 2018. Simulation of the modern climate using the INM-CM48 climate model, *Russ. J. Numeric. Anal. Mathematic. Model.*, 33(6). <https://doi.org/10.1515/rnam-2018-0032>

Volodin, E. M., et al., 2017. Simulation of the present-day climate with the climate model INMCM5, *Climate Dyn.*, 49, 3715-3734. <https://doi.org/10.1007/s00382-017-3539-7>

Wachter, P., Beck, C., Philipp, A., Höppner, K., & Jacobeit, J., 2020. Spatiotemporal variability of the Southern Annular Mode and its influence on Antarctic surface temperatures. *Journal of Geophysical Research: Atmospheres*, 125, e2020JD033818. <https://doi.org/10.1029/2020JD033818>

Wang, C., Deser, C., Yu, J.Y., DiNezio, P. and Clement, A., 2017. El Niño and southern oscillation (ENSO): a review. *Coral Reefs of the Eastern Tropical Pacific*. Dordrecht: Springer, 85–106. https://doi.org/10.1007/978-94-017-7499-4_4

World Meteorological Organization (WMO), 2021. WMO Atlas of Mortality and Economic Losses from Weather, Climate and Water Extremes (1970–2019). WMO-No. 1267. https://library.wmo.int/doc_num.php?explnum_id=10989

Xie P, Chen M, Shi W., 2010. CPC global unified gauge-based analysis of daily precipitation. Preprints, 24th conf. on hydrology, Atlanta, GA, Amer. Meteor. Soc, p 2.

Yukimoto, S., Kawai, H., Koshiro, T., Oshima, N., Yoshida, K., Urakawa, S., et al., 2019. The Meteorological Research Institute Earth System Model version 2.0, MRI-ESM2. 0: Description and basic evaluation of the physical component. *Journal of the Meteorological Society of Japan*. Ser. II, 97(5), 931-965.

Zambrano, F., Wardlow, B., Tadesse, T., Lillo-Saavedra, M., Lagos, O., 2017. Evaluating satellite-derived long-term historical precipitation datasets for drought monitoring in Chile. *Atmospheric Research*, 186, 26-42, ISSN 0169-8095. <https://doi.org/10.1016/j.atmosres.2016.11.006>

Zhang, Y., J.M. Wallace, D.S. Battisti, 1997: ENSO-like interdecadal variability: 1900-93. *J. Climate*, 10, 1004-1020.

Zhang, Y., Wu, C., Yeh, P.J.F., Li, J., Hu, B.X., Feng, P., Jun, C., 2022. Evaluation and comparison of precipitation estimates and hydrologic utility of CHIRPS, TRMM 3B42 V7 and PERSIANN-CDR products in various climate regimes. *Atmospheric Research*, 265, ISSN 0169-8095. <https://doi.org/10.1016/j.atmosres.2021.105881>

Ziehn Tilo, C., Law, R., Lenton, A., Bodman, R., et al., 2020. The Australian Earth System Model: ACCESS-ESM1.5. *Journal of Southern Hemisphere Earth Systems Science* 70, 193-214. <https://doi.org/10.1071/ES19035>