

1
2 **EVALUACIÓN DEL MÉTODO DE ANÁLOGOS PARA SIMULACIÓN**
3 **DE LA PRECIPITACIÓN DIARIA EN UNA REGIÓN DE OROGRAFÍA**
4 **COMPLEJA**
5

6 **Federico Gomez^{1,2} y María Laura Bettolli^{2,3,4}**
7

8 **¹Instituto Argentino de Nivología, Glaciología y Ciencias Ambientales, CONICET CCT**
9 **Mendoza, Argentina.**

10 **² Universidad de Buenos Aires, Facultad de Ciencias Exactas y Naturales,**
11 **Departamento de Ciencias de la Atmósfera y los Océanos, Buenos Aires, Argentina**

12 **³Consejo Nacional de Investigaciones Científicas y Técnicas, CONICET, Buenos Aires,**
13 **Argentina**

14 **⁴Instituto Franco-Argentino de Estudios sobre el Clima y sus Impactos (IRL 3351**
15 **IFAECI/CNRS-IRD-UBA), Buenos Aires, Argentina**
16

17 **Autor correspondiente: Federico Gomez, fegomez@mendoza-conicet.gob.ar**
18

19 Manuscrito recibido el 17 de noviembre de 2023, en su versión final el 22 de febrero de 2024
20

21 **RESUMEN**
22

23 Los Modelos Climáticos Globales (GCM) son la principal herramienta disponible
24 para realizar predicciones sobre el clima en escenarios futuros, sin embargo, los mismos
25 presentan un desempeño bajo para reproducir el clima local debido a su resolución espacial
26 limitada. Esta característica se acentúa en regiones de orografía compleja. En el presente
27 trabajo, se exploró la posibilidad de añadir valor agregado al modelado de la precipitación
28 diaria a través de un método estadístico de reducción de escala (*downscaling*) en la región de
29 los Andes Centrales. Se utilizó la precipitación diaria de 83 estaciones de la región durante el
30 periodo 1981-2015 para calibrar el método de análogos utilizando el reanálisis ERA-Interim.
31 Las series construidas a partir de los modelos de *downscaling* estadístico mostraron



Artículo en edición

32 resultados más fidedignos en comparación con datos crudos del reanálisis, especialmente en
 33 el cálculo de valores medios y de estadísticos de escala diaria. En líneas generales, los
 34 modelos basados en la información de predictores atmosféricos locales obtuvieron un mejor
 35 desempeño que los constituidos utilizando la información de gran escala simplificada en base
 36 a un análisis de componentes principales. El desempeño de los modelos de *downscaling* a lo
 37 largo del dominio no fue uniforme, obteniéndose mejores resultados en las estaciones
 38 chilenas del sector sur. Esto posiblemente fue debido a que el forzante sinóptico dominante es
 39 bien capturado por los modelos de *downscaling*. Los distintos aspectos temporales de la
 40 variabilidad de la precipitación (intraanual, interanual y tendencias de largo plazo) fueron
 41 hábilmente reproducidos por los modelos estadísticos.

42

43 **Palabras claves:** Downscaling estadístico, ERA-Interim, Andes Centrales, Argentina,
 44 Chile

45

46 **EVALUATION OF THE ANALOG METHOD FOR DAILY**
 47 **PRECIPITATION SIMULATION IN A COMPLEX OROGRAPHY**
 48 **REGION**

49

50 **ABSTRACT**

51

52 Global Climate Models (GCMs) are the main tool available to predict future climate
 53 scenarios, nevertheless their performance might be hindered in complex orography regions by
 54 their limited spatial resolution. In this paper, the added value of statistical downscaling
 55 modeling for daily precipitation in Central Andes region was explored. Data from 83 rain
 56 gauge stations in the period 1981-2015 was used in order to calibrate an analog method
 57 employing ERA-Interim reanalysis. Statistical downscaling models proved to be more
 58 accurate than reanalysis precipitation raw data, particularly for mean precipitation values
 59 (annual and seasonal) and metrics built on a daily basis. Models based on information from
 60 local atmospheric predictors showed better performances than those built on large scale data
 61 using principal component analysis. Performance of downscaling models was not even
 62 throughout the domain, showing more accurate results in Southern Chilean stations. This was
 63 probably due to synoptic forcing being well captured by downscaling models. Precipitation

Artículo en edición

64 variability at different time scales (intraannual, interannual and long-term tendencies) was
65 successfully replicated by statistical models.

66

67 **Key Words:** Statistical downscaling, ERA-Interim, Central Andes, Argentina, Chile

68

69

70 **1. INTRODUCCIÓN**

71

72 La Cordillera de los Andes es el cordón montañoso más largo del mundo,
73 extendiéndose a lo largo de 8500 km entre Tierra del Fuego y el istmo de Panamá. Los Andes
74 actúan como barrera atmosférica debido a su altura promedio de 3500 msnm, con un máximo
75 de 6960 msnm en el cerro Aconcagua. La región de los Andes Centrales (AC), situada entre
76 28°S-38°S y 68°O-73°O (Figura 1) alberga a dos tercios de la población chilena (INE, 2018)
77 y casi 3 millones de personas en el lado argentino (INDEC, 2023). El abastecimiento de agua
78 para los habitantes de la región de los AC depende del ciclo hidrológico de la región (Araneo
79 y Villalba, 2014; Bonelli et al., 2014) y es modulado por la acumulación de precipitaciones
80 sólidas en cotas altas y su posterior deshielo (Araneo y Compagnucci, 2008; Bravo et al.,
81 2017). La zona de influencia de los AC también se caracteriza por el desarrollo de actividades
82 subordinadas a los recursos hídricos cordilleranos, como la actividad agrícola y la producción
83 de energía hidroeléctrica (Garreaud et al., 2017; Rivera et al., 2017).

84 Los regímenes de precipitación en los AC varían de acuerdo a la latitud. En Chile, las
85 precipitaciones están concentradas en el invierno, promediando el 75% del acumulado anual
86 durante dichos meses (Basist et al., 1994). En el norte del dominio predominan condiciones
87 áridas sobre Chile y es el sector argentino el que recibe las mayores precipitaciones,
88 principalmente de origen convectivo durante los meses de verano (Labraga, 2010). La
89 posición del anticiclón semipermanente del Pacífico modula la marcha anual de
90 precipitaciones en el centro de Chile (Ruttland y Fuenzalida, 1991). Al sur de 35°S, es el
91 sector chileno el que recibe las mayores precipitaciones, originadas en el avance de sistemas
92 de presión desde el océano Pacífico hacia el este (Garreaud, 2009). Los cambios en la
93 circulación a gran escala también impactan sobre la distribución de precipitaciones de la
94 región en estudio. Un ejemplo de esto son las anomalías positivas (negativas) en las

Artículo en edición

95 estaciones costeras de Chile durante episodios de El Niño (La Niña) (Montecinos et al.,
96 2000).

97 La distribución y acumulados de las precipitaciones en la región de los AC presentó
98 en algunos casos tendencias que fueron estudiadas en trabajos previos. Boisier et al. (2018)
99 encontraron una tendencia promedio de -1.7% por década para las precipitaciones anuales en
100 Chile en 30°S-38°S a partir del estudio de series de datos pluviométricos observados para el
101 periodo 1960-2016. Las tendencias negativas se hicieron más intensas hacia mayores
102 latitudes. En el sector argentino de los AC, la escasez de estaciones meteorológicas limita las
103 posibilidades de cálculo de posibles tendencias de precipitación. Sin embargo, Muller y
104 Lovino (2023) encontraron que las estaciones San Juan, Mendoza Aero, San Martín,
105 Malargüe y San Rafael presentan una tendencia al alza de las precipitaciones medias hasta
106 1973 y una estabilización de dichos valores de ahí en adelante. Particularmente, desde el año
107 2010 se observa un fenómeno de sequía extendida de manera ininterrumpida en la región de
108 los AC. Garreaud et al. (2019) caracterizó esta situación mediante un índice regional de
109 precipitación (RPI) construido a partir de datos observados de 6 estaciones chilenas
110 representativas de la región ubicadas entre 32°S y 37°S mostrando que este déficit anómalo
111 de precipitaciones representa una amenaza al abastecimiento de recursos hídricos para la
112 región. Fuentealba et al. (2021) verificaron mediante imágenes satelitales una reducción
113 superficial de entre 7% y 25% para 12 lagos ubicados entre 32°S y 37°S en Chile.

114 Los Modelos Climáticos Globales (GCMs) son la principal herramienta disponible
115 para realizar predicciones sobre el clima en escenarios futuros. Los GCMs están ideados para
116 ser empleados en grandes escalas, de modo que presentan dificultades para recrear el ciclo
117 hidrológico en zonas con orografía compleja (Chen y Dai, 2019). Los GCMs presentan
118 dificultades al recrear climas locales por su resolución espacial (Navarro-Racines et al.,
119 2020). Estas limitaciones fueron encontradas sobre los AC por Zazulie et al. (2017), quienes
120 analizaron el desempeño de 15 GCMs en reproducir las precipitaciones y temperaturas
121 medias mensuales.

122 Las técnicas de reducción de escala (*Downscaling*, por su nombre en inglés) surgieron
123 como una posibilidad para sortear las limitaciones de los GCMs. Estas técnicas se agrupan
124 según los medios empleados para realizar este proceso, como técnicas estadísticas, dinámicas
125 o una combinación de ambas. Las técnicas estadísticas (empleadas en este trabajo) se basan
126 en relaciones empíricas entre predictores de gran escala y predictandos de escala local y/o

Artículo en edición

127 regional (Wilby et al., 2002). En particular, desde el enfoque de *perfect prognosis*, estas
 128 relaciones empíricas se establecen en base a predictores de gran escala observados
 129 (usualmente representadas por los reanálisis) y predictandos de escala local (observaciones de
 130 precipitación) (Maraun et al. 2019). Una vez entrenados los modelos estadísticos en
 131 condiciones perfectas, se aplican a los predictores de gran escala simulados por los GCMs
 132 para obtener las simulaciones del clima local. Por ello, el entrenamiento y validación de los
 133 modelos estadísticos utilizando los reanálisis y las observaciones de las variables locales es
 134 un paso esencial para obtener simulaciones robustas.

135 A pesar de que estas técnicas han sido ampliamente utilizadas en otras regiones del
 136 mundo, su potencial no ha sido explorado en profundidad en Sudamérica y en particular, para
 137 simular la precipitación diaria y su variabilidad espacial y temporal en regiones de topografía
 138 compleja como los AC. En Chile, Araya-Osses et al. (2020) usaron datos de precipitación y
 139 temperatura diarias de 400 estaciones para entrenar una técnica de *downscaling* estadístico
 140 basada en el método de análogos. Los autores emplearon las relaciones empíricas halladas
 141 para realizar proyecciones de clima futuro. Bozkurt et al. (2018) aplicaron técnicas de
 142 *downscaling* estadístico para corregir *bias* en los valores de precipitación diaria de 19 GCMs
 143 y proyectar escenarios hidroclimáticos futuros para el centro de Chile. Mutz et al. (2021)
 144 generaron modelos de *downscaling* estadístico en base a la técnica de regresión múltiple para
 145 simular la temperatura media mensual en 24 estaciones en los AC chilenos. En Argentina,
 146 Labraga (2010) utilizó métodos de *downscaling* basados en la regresión lineal múltiple para
 147 simular la precipitación mensual y logró reproducir las tendencias positivas encontradas en
 148 algunas estaciones de Cuyo en el periodo 1981-2001 y episodios extremos como el déficit
 149 pluvial registrado en dicha región en 1994 o las lluvias excepcionales de febrero de 1998.
 150 Balmaceda-Huarte y Bettolli (2022) evaluaron el desempeño de distintas técnicas de
 151 *downscaling* estadístico para simular las temperaturas máximas y mínimas diarias a lo largo
 152 de Argentina.

153 Dada la importancia de la variabilidad espacial y temporal de la precipitación en la
 154 región de los AC, surge la necesidad de contar con simulaciones climáticas con detalle
 155 regional para evaluar los cambios de la precipitación y su proyección futura en un contexto
 156 de cambio climático. Para ello, es necesario desarrollar técnicas estadísticas de *downscaling* y
 157 evaluar su potencial para reproducir las distintas características de la precipitación en una
 158 región de orografía compleja como la región de los AC.

Artículo en edición

159 El objetivo de este trabajo fue evaluar la capacidad de una técnica estadística de
160 *downscaling* para reproducir la precipitación diaria en la región cordillerana entre 28°S y
161 38°S, así como su variabilidad espacial y temporal.

162

163 **2. DATOS Y METODOLOGÍA**

164

165 *Datos*

166 Los predictandos empleados en este trabajo fueron los datos de precipitación diaria de
167 83 estaciones ubicadas entre los paralelos 28°S y 38°S y las longitudes 68°O y 73°O para el
168 periodo 1981-2015 (Figura 1 y Tabla 1). Los datos de precipitación fueron provistos por el
169 Servicio Meteorológico Nacional de Argentina (SMN), el Instituto Nacional de Tecnología
170 Agropecuaria (INTA) y la Dirección de Recursos Hídricos de Argentina, y la Dirección
171 General de Aguas y la Dirección Meteorológica de Chile.

172 Los datos utilizados en este trabajo fueron sometidos a un control de calidad según las
173 recomendaciones de Penalba y Vargas (2004). Las estaciones con más de 15% de datos
174 faltantes en el periodo en estudio fueron descartadas. Los 3 valores de precipitación diaria
175 más altos para cada estación fueron analizados de manera particular para descartar la posible
176 presencia de *outliers*, teniendo en cuenta la distribución de probabilidad típica en cada
177 estación, y además para las estaciones argentinas se incluyó una comparación con datos
178 históricos de máxima precipitación diaria del SMN.

179 Los campos medios diarios del reanálisis ERA-Interim (Dee et al., 2011) fueron
180 utilizados como predictores en el dominio delimitado por 21°S-55°S y 55°O-90°O (Figura 1).
181 ERA-Interim es un conjunto de reanálisis de observaciones producido por el European Center
182 for Medium-Range Weather Forecasts (ECMWF) para numerosas variables atmosféricas que
183 comprenden el periodo 1979-2019. El mismo posee 60 niveles verticales desde la superficie
184 hasta 0,1hPa y una resolución horizontal de 0.75° x 0.75°. En el presente trabajo se utilizó el
185 período entre 1981 y 2015 en una retícula de 2° x 2° con interpolación bilineal para reducir
186 los costos computacionales. Las variables utilizadas fueron promedios diarios de altura
187 geopotencial en 500 hPa (z500), viento (zonal y meridional) en 850 hPa (u850 y v850),
188 temperatura del aire en 850 hPa y 700 hPa (t850 y t700), humedad específica en 850 hPa y
189 700 hPa (q850 y q700) y presión al nivel del mar (psl). Estas variables fueron seleccionadas
190 en base a trabajos previos que estudiaron su influencia sobre la precipitación en los AC

Artículo en edición

191 (Labraga, 2010; Viale y Núñez, 2011; Viale y Garreaud, 2014). Asimismo, se consideraron
 192 también los acumulados diarios de precipitación en los puntos de enrejado más cercanos a las
 193 estaciones, con el fin de explorar el valor agregado de la reducción de escala (Tabla 2). Es
 194 importante destacar que la elección del reanálisis ERA-Interim para la calibración y
 195 validación de los modelos estadísticos se basa en que es el reanálisis empleado por el
 196 programa Coordinated Regional Climate Downscaling Experiment (CORDEX) del World
 197 Climate Research Programme (Gutowski et al. 2016) para las simulaciones de evaluación de
 198 los modelos climáticos regionales y por lo tanto facilita la evaluación comparativa de los
 199 modelos desarrollados para la representación del clima regional.

200

201 *Metodología*

202 El *downscaling* estadístico emplea relaciones conocidas entre la circulación de gran
 203 escala y la variable local de interés para construir modelos estadísticos que puedan traducir el
 204 impacto de las anomalías en los flujos de gran escala a variables locales (Zorita & von
 205 Storch, 1999). En este trabajo se utilizó el método de análogos para realizar las simulaciones,
 206 el cual fue utilizado en trabajos previos para reproducir la precipitación diaria (por ejemplo,
 207 Bettolli y Penalba, 2018; Maraun et al., 2019), y algunos trabajos recientes evaluaron su
 208 potencial como método de referencia en regiones de orografía compleja (Horton &
 209 Brönnimann, 2018; Horton, 2021). El método de análogos se basa en la idea de que la
 210 repetición de ciertos patrones atmosféricos sobre una zona determinada dará como resultado
 211 condiciones meteorológicas similares (Bedia et al., 2019). La situación de gran escala del
 212 periodo histórico que más se asemeje a la que se quiere predecir será asignada como análogo
 213 a la misma.

214 La configuración de los predictores, es decir, la forma en que se incorporan al modelo,
 215 pueden tener influencia en los resultados. Por ello, se consideraron diferentes estrategias para
 216 incorporar la información. Por un lado, las influencias de las estructuras de gran escala en
 217 todo el dominio fueron sintetizadas a través del análisis de componentes principales (Wold et
 218 al., 1987) reteniendo el 90% de la varianza. Los modelos que incorporaron los predictores de
 219 esta manera fueron indicados con la nomenclatura “pc” (Tabla 3). Por otro lado, se
 220 construyeron modelos considerando la influencia local de los predictores utilizando sólo $n=4$
 221 o $n=16$ puntos de retícula más cercanos a cada estación meteorológica. Los modelos que
 222 incorporaron los predictores de esta manera fueron indicados con la nomenclatura “ls4” y

Artículo en edición

223 “ls16” respectivamente (Tabla 3). Los modelos “ls4”, ls16” y “pc” emplearon la información
 224 de las 8 variables seleccionadas como predictoras. El modelo “pc_c” es una versión
 225 simplificada de “pc”, empleando sólo las variables referidas a la circulación (“psl”, “z500”,
 226 “u850” y “v850”). El modelo “pf” se basa en los resultados hallados por Falvey y Garreaud
 227 (2007), quienes encontraron que el flujo zonal de humedad explica el 50% de la varianza de
 228 la precipitación diaria en la zona central de Chile y hasta el 60% de la varianza en este rubro
 229 en estaciones específicas. Teniendo en cuenta estos resultados, el modelo “pf” combina el
 230 análisis de componentes principales de las variables “u850” y “v850” más la variable “q700”
 231 utilizando la información de los 16 puntos de retícula más cercanos (Tabla 3).

232 Debido a la extensión temporal acotada de los datos observados, se eligió un proceso
 233 de *cross-validation* con *k-folds* (Singh & Lee, 2018) en lugar de periodos distintos de
 234 entrenamiento y validación. A efectos de este trabajo se eligieron 7 *folds* (k=7) de
 235 compuestos por 5 años de datos diarios cada uno, dispuestos de manera cronológica. La
 236 técnica de *cross-validation* consiste en tomar sucesivamente cada uno de los *folds* como el
 237 periodo a evaluar y emplear los restantes para calibrar el primero. Se ajusta un modelo para el
 238 periodo de calibración, se lo aplica al *fold* seleccionado y se evalúa su rendimiento. Este
 239 proceso se repite para todos los periodos que componen los datos del estudio.

240 Dado que el foco de este trabajo es el análisis de la representación de la variabilidad
 241 de la precipitación, los resultados de las simulaciones fueron sometidos a procesos de
 242 validación para diferentes escalas temporales: anual y estacional, interanual y diaria. En todos
 243 los casos se consideró como día con precipitación a aquel en el que se acumuló al menos 1
 244 mm. Para sintetizar la información regional, se consideraron 8 estaciones representativas de
 245 distintas regiones climáticas incluidas en el dominio (indicadas en la Figura 1).

246 Con el fin de analizar si las simulaciones representan correctamente la
 247 correspondencia temporal interanual, se empleó el coeficiente de correlación de Pearson entre
 248 las series de acumulados de precipitación simuladas y observadas. Asimismo, la tendencia
 249 lineal se evaluó en base al testeo del valor de la pendiente de la recta de regresión lineal (en
 250 mm/año) utilizando el test t-Student con un nivel de confianza del 95% (Wilks, 1995).

251 Adicionalmente, se estudió la capacidad de los modelos estadísticos en reproducir
 252 distintas características de la precipitación. En primer lugar se estudió el error cuadrático
 253 medio (RMSE) según la fórmula 1:

$$RMSE = \sqrt{\frac{\sum_1^{t=n} (ppMod_t - ppObs_t)^2}{n}} \quad (1)$$

254
255 siendo ppMod la precipitación modelada, ppObs la precipitación observada, t el número de
256 día y n la cantidad de días en estudio.

257 Por otro lado también se consideraron, la frecuencia relativa de días con precipitación
258 (índice $R01 = \text{cantidad de días con lluvia} / \text{cantidad de días totales}$) y el índice P98Wet que
259 representa el valor del percentil 98 de precipitación diaria teniendo en cuenta solo los días
260 con precipitación (Olmo y Bettolli, 2021). La comparación de estos índices en las
261 simulaciones (Mod) y en las observaciones (Obs) se hizo mediante el cociente (ratio),
262 siguiendo la fórmula 2:

$$ratio = \frac{indexMod}{indexObs} \quad (2)$$

263
264 donde index representa a R01 o P98Wet según corresponda.

265 Se evaluó la tasa de acierto de los modelos mediante el Critical Success Index (CSI)
266 (Aniley et al., 2023). Este índice caracteriza el desempeño de las simulaciones a través de un
267 cociente entre la suma total de los aciertos (*Hits*, días con precipitación observada y
268 modelada) y la suma de de los aciertos más los errores (*Misses*, días con precipitación
269 observada no predicha por el modelo) y las falsas alarmas (*False Alarms*, días sin
270 precipitación observada erróneamente calculados como día con precipitaciones por el
271 modelo):

$$\frac{Hits}{Hits + Misses + False Alarms} \quad (3)$$

272
273

3. RESULTADOS

275

Caracterización climatológica de la precipitación en los Andes Centrales

276
277 En la Figura 2 se presentan los valores medios anuales observados de la precipitación
278 e intensidad media en el período 1981-2015. Los valores se presentan en mm/día para
279 facilitar su comparación entre ambos indicadores y entre regiones. Estos valores se
280 obtuvieron realizando el cociente entre la precipitación total acumulada para el periodo en
281 cada estación y la cantidad total de días (precipitación media diaria) o la cantidad de días con

Artículo en edición

282 precipitaciones (intensidad media diaria). La precipitación media diaria presentó valores
 283 menores a 2 mm/día en casi toda la región excepto en las estaciones al sur de 35°S en Chile,
 284 donde se alcanzó un máximo de 5.75 mm/día (Figura 2 a). Sin embargo, la intensidad de las
 285 precipitaciones presentó una distribución espacial diferente con mayores valores en las
 286 estaciones chilenas (12-24 mm/día) que en las argentinas (6-11 mm/día) (Figura 2 b),
 287 enfatizando la influencia topográfica en la distribución espacial de la precipitación.

288

289 *Validación de las simulaciones en escala anual y estacional*

290 La precisión de los modelos para reproducir las precipitaciones medias anuales y
 291 estacionales se estudió mediante el *bias* relativo porcentual con respecto a los datos
 292 observados (Figura 3). Los valores medios de los acumulados anuales de precipitación
 293 muestran un gradiente de crecimiento hacia el sur y el oeste (Figura 3 a). La región del
 294 dominio con mayor acumulado promedio es la Patagonia chilena (al sur de 35°S) con
 295 registros que alcanzan los 2098 mm. Hacia el norte, los acumulados promedios se reducen
 296 junto a la influencia de los *storm tracks*, con valores medios entre 300 y 600 mm en el centro
 297 de Chile y menores a 300 mm en el norte. En el lado argentino, se observan acumulados entre
 298 100 y 400 mm en el centro y norte del dominio y entre 200 y 900 mm al sur. Esta distribución
 299 espacial de los acumulados anuales de precipitación se mantiene a lo largo de las estaciones
 300 de invierno y de transición (Figura 3 c, d y e), siendo el verano la estación que presenta los
 301 mayores acumulados en el centro y norte del sector argentino (con valores que alcanzan entre
 302 80 y 140 mm, Figura 3 b). En el resto del dominio este periodo del año es el más seco con
 303 precipitaciones medias entre 40 y 100 mm al sur y despreciables en el centro y norte de Chile.

304 La evaluación del desempeño de ERA-Interim indica que el reanálisis presenta
 305 grandes sobreestimaciones de precipitaciones para casi toda la región y todas las épocas del
 306 año, excepto en la región del centro y sur de Chile donde se observan subestimaciones
 307 moderadas.

308 Los modelos de *downscaling* presentan mejores rendimientos al reproducir los valores
 309 medios de precipitación anual y estacional en comparación con ERA-Interim. A nivel anual,
 310 los resultados de los modelos evidencian (salvo contadas excepciones) *bias* negativos con
 311 respecto a los datos observados. Estos errores son menores al 20% en la mayoría de las
 312 estaciones y modelos, siendo el extremo norte de Chile la única región con subestimaciones
 313 más pronunciadas (entre -20% y -40%). Los modelos basados en predictores locales (“ls4” y

Artículo en edición

314 “ls16”) muestran un mejor desempeño a nivel anual con respecto a los construidos a partir del
315 análisis de componentes principales. El modelo “pf” tiene los *bias* más pronunciados.

316 Para el verano, los modelos muestran una distribución dispar de valores en el norte de
317 Chile, presentando estaciones con sobreestimaciones por encima de 80% y desvíos negativos
318 por encima del 40% (Figura 3 b). Esto puede guardar relación con la escasez estival de
319 precipitaciones en la región, con acumulados medios por debajo de los 10 mm (primera
320 columna en la Figura 3 b). Los modelos subestiman las precipitaciones en el resto del
321 dominio. El mejor desempeño se observa en el modelo “ls16”, mientras que el modelo “pc_c”
322 obtuvo mejores resultados que su versión más compleja (“pc”).

323 El desempeño de los modelos para el otoño e invierno es muy similar (Figura 3 c y d).
324 En general, los modelos muestran leves subestimaciones generalizadas, siendo el modelo
325 “pf” el que mayores sesgos presenta principalmente en el norte de Chile y en Argentina al sur
326 de 35°S. En la primavera, en cambio, los modelos tienden a sobreestimar levemente los
327 valores de precipitación media en algunas estaciones, con mayor intensidad en Chile al norte
328 de 33°S. Este periodo del año es el que presenta los desvíos más pequeños en términos
329 absolutos.

330 En la Figura 4 se presentan las marchas anuales de precipitación media y de cantidad
331 de días promedio con precipitación observadas y simuladas por cada modelo de *downscaling*
332 para las 8 estaciones seleccionadas (en verde) de la Tabla 1 y Figura 1, que representan las
333 distintas regiones geográficas y climáticas del dominio. En varios casos no fue posible incluir
334 la marcha generada a partir del reanálisis ERA-Interim, ya que los valores quedaron fuera de
335 la escala propuesta.

336 Los modelos de *downscaling* recrean correctamente la marcha anual en La Serena
337 (Figura 4 a) aunque subestiman los acumulados para el otoño e invierno. Los modelos “ls4” y
338 “ls16” simulan correctamente el máximo de precipitación en julio, mientras que los modelos
339 basados en análisis de componentes principales (“pc”, “pc_c” y “pf”) calculan un máximo
340 tardío en agosto. En las otras estaciones de Chile; Lago Peñuelas, Santiago y Diguillín
341 (Figura 4 b, c y d), los modelos basados en predictores locales (“ls4” y “ls16”) logran replicar
342 la marcha anual con mayor exactitud que los basados en análisis de componentes principales.
343 Los datos observados indican que este grupo de estaciones tiene su máximo de precipitación
344 en junio, lo cual es correctamente simulado por “ls4” y “ls16” mientras que los demás
345 modelos calculan dicho máximo en julio. Los resultados crudos de ERA-Interim son los de

Artículo en edición

346 menor precisión. Para la estación Santiago, los valores de ERA-Interim quedan fuera de
347 escala, y en Lago Peñuelas combinan una subestimación de los acumulados promedios junto
348 con una sobreestimación de la cantidad de días con precipitaciones. En Las Ramadas (1380
349 msnm), los modelos simulan correctamente la marcha anual de la precipitación pero calculan
350 el máximo en julio en lugar de junio (Figura 4 e).

351 Los modelos muestran menor tasa de acierto y mayores discrepancias entre sí para las
352 estaciones argentinas (Colorado, Trocoman y Mendoza Aero). Esta situación puede guardar
353 relación con las condiciones áridas y menor estacionalidad de las precipitaciones. Los
354 resultados del reanálisis ERA-Interim quedan fuera de la escala.

355

356 *Variabilidad Temporal*

357 Con el fin de evaluar el desempeño de los modelos para replicar las series temporales
358 de totales anuales y estacionales de precipitación para el periodo 1981-2015, inicialmente se
359 calcularon las tendencias lineales para las series construidas a partir de los datos observados,
360 los 5 modelos de *downscaling* y los datos de precipitación total de ERA-Interim en las 83
361 estaciones del dominio (Figura 5).

362 Las tendencias calculadas a nivel anual a partir de datos observados indican valores
363 negativos para casi todas las estaciones chilenas del dominio aunque sólo 4 de ellas son
364 significativas estadísticamente (Figura 5 a). Las tendencias negativas son más intensas en
365 mayores latitudes, con un mínimo de -12.3 mm/año. Los valores calculados a partir de ERA-
366 Interim evidencian que el reanálisis exagera las tendencias negativas en la precipitación para
367 Chile, mientras que los modelos de *downscaling* obtuvieron mejores resultados excepto “ls4”.
368 Las tendencias observadas para las estaciones argentinas no siguen un patrón geográfico
369 claro. Esto incluye contrastes como por ejemplo, las estaciones Auquinco y Pichi Neuquén,
370 localizadas al sur del lado Argentino, que tienen tendencias significativas (6.5 mm/año y -
371 14.2 mm/año respectivamente) con signos opuestos a pesar de estar situadas a menos de 200
372 km de distancia entre sí (Figura 5 a). Esta característica de estaciones con tendencias opuestas
373 se replica en varios casos para la región sur del dominio. Los modelos de *downscaling*
374 presentan una precisión mayor al replicar las tendencias observadas en las estaciones
375 argentinas en comparación con el reanálisis ERA-Interim, que sobreestima las tendencias. Sin
376 embargo, las simulaciones no logran reproducir la significancia estadística observada.

Artículo en edición

377 El verano presenta un patrón general de tendencias observadas positivas no
378 significativas (Figura 5 b). Los modelos de *downscaling* tienden a reproducir esta
379 característica, excepto el modelo “pc” que muestra tendencias negativas en el sector
380 Argentino. ERA-Interim sobreestima las tendencias positivas al este de la cordillera.

381 El otoño es la estación que presenta las tendencias negativas observadas más
382 pronunciadas en gran parte de la región, siendo significativas en la parte sur del dominio en
383 Chile (Figura 5 c) y algunas estaciones en el sector sur del dominio en Argentina. Los
384 modelos estadísticos logran replicar los patrones de distribución geográfica de las tendencias
385 y la significancia estadística observada en las estaciones del sur de Chile. En el sector
386 argentino, ERA-Interim no logra capturar el patrón regional de tendencias ni su significancia.

387 Para el invierno y la primavera, los datos observados indican tendencias mayormente
388 negativas aunque no significativas (Figura 5 d y e). Los modelos de *downscaling* tienden a
389 reproducir el patrón general de tendencias negativas no significativas, mientras que ERA-
390 Interim las sobreestima en valor absoluto y hasta las revierte en el sector argentino durante la
391 primavera.

392 Adicionalmente, se analizó el desempeño de los modelos en reproducir la variabilidad
393 interanual de los acumulados anuales y estacionales a partir del coeficiente de correlación de
394 Pearson (Figura 6). Los modelos reproducen correctamente la variabilidad interanual en la
395 totalidad de las estaciones de Chile con coeficientes de correlación positivos y significativos.
396 En las estaciones argentinas, los valores obtenidos son menores a los de Chile, en especial
397 hacia el norte, indicando que los modelos tienen más dificultad en reproducir la variabilidad
398 interanual en este sector. Los modelos basados en el análisis de componentes principales
399 (“pc”, “pc_c” y “pf”) no logran generar series con correlación significativa con los datos
400 observados en la mayoría de las estaciones ubicadas en gran parte del sector argentino del
401 dominio.

402 El verano es la estación del año donde se registran las correlaciones más bajas (Figura
403 6 b). En la mayoría de las estaciones, las correlaciones no son significativas excepto en el sur
404 de Chile, donde los modelos “ls16” y “pf”, y el reanálisis ERA-Interim presentan el mejor
405 desempeño.

406 Los valores de correlación correspondientes al otoño son significativos
407 estadísticamente para los modelos de *downscaling* basados en predictores locales “ls4” y
408 “ls16”, y ERA-Interim en las estaciones chilenas (Figura 6 c), mientras que el resto de los

Artículo en edición

409 modelos falla al recrear este aspecto para las estaciones en el sector norte del dominio. En el
410 sector argentino, ERA-Interim y el modelo “Is16” son los que presentan el mejor desempeño
411 con valores significativos de correlación en la mayoría de las estaciones. En la primavera
412 (Figura 6 e), los modelos tienden a tener un desempeño similar al otoño.

413 En invierno, los valores de correlación obtenidos son mayores que para las otras
414 estaciones del año en Chile y al sur en el sector argentino, indicando un mejor desempeño de
415 los modelos en esta estación del año (Figura 6 d). ERA-Interim y los modelos basados en
416 predictores locales nuevamente presentan el mejor desempeño.

417 A modo ilustrativo se muestran las series de acumulados anuales en las 8 estaciones
418 de referencia obtenidas con los datos observados y modelados. En Chile, los modelos de
419 *downscaling* y ERA-Interim logran recrear los extremos locales, principalmente en las
420 estaciones del centro y sur (Santiago, Lago Peñuelas y Diguillín). Un ejemplo de esto son las
421 situaciones de acumulado anual excepcionalmente altos para 1997 y bajos para 1996 y 1998.
422 En las estaciones argentinas, los modelos tienen menos precisión que en Chile y valores más
423 dispares entre sí. Se observan casos puntuales donde tanto los modelos de *downscaling* como
424 ERA-Interim no logran recrear periodos extremos de déficit y exceso de precipitación, como
425 por ejemplo, los acumulados récord registrados en 1993 y 1994 en Trocoman (Figura 7 h) y
426 en 1984 y 2001 en Mendoza (Figura 7 f). Es importante destacar que si bien ERA-Interim
427 muestra las mayores correlaciones interanuales (Figura 6 a), presenta grandes
428 sobreestimaciones y/o subestimaciones de los acumulados anuales en concordancia con lo
429 observado en la Figura 3.

430

431 *Validación de las simulaciones en escala diaria*

432 El error cuadrático medio (RMSE) entre los datos observados y los valores simulados
433 por los modelos más el reanálisis es empleado para evaluar el rendimiento de los mismos.
434 Solo se tuvieron en cuenta en el cálculo del estadístico los días en los que se observaron
435 precipitaciones en cada estación, con el objetivo de reducir la distorsión en los resultados
436 generados por periodos sin precipitaciones.

437 Los principales contrastes en los resultados se observan al comparar los valores de
438 ERA-Interim con los de los modelos de *downscaling* (Figura 8). En ese sentido a nivel anual
439 (Figura 8 a), en Argentina al norte de 35°S, ERA-Interim obtiene valores de RMSE
440 notablemente más altos que los obtenidos por los modelos con valores de hasta 30 mm. Esto

Artículo en edición

441 puede guardar relación con la sobreestimación de las precipitaciones por parte del reanálisis
 442 en la región (Figura 3). El comportamiento inverso se halla en las estaciones argentinas al sur
 443 de 35°S, donde ERA-Interim tiene un mejor desempeño que los modelos de *downscaling*.
 444 Los valores de RMSE de las estaciones chilenas no observan diferencias entre el reanálisis y
 445 los modelos.

446 En verano (Figura 8 b), se destacan los errores calculados en Cuyo por el reanálisis
 447 (entre 15 y 44 mm) con respecto a los de los modelos (entre 8 y 20 mm). Para el invierno y el
 448 otoño, no se distinguen diferencias notables entre los desempeños de ERA-Interim y los
 449 modelos de *downscaling* (Figura 8 c y d). Se destacan las excepciones puntuales de Pichi
 450 Neuquén, Llui-Llui Embalse y Lago Peñuelas que tienen valores de RMSE notablemente más
 451 altos. La primavera es la estación donde se hallan los menores valores de RMSE, siendo
 452 menores a 24 mm para todas las estaciones excepto Pichi Neuquén y Lago Peñuelas (Figura 8
 453 e). Al igual que en el verano y otoño, ERA-Interim obtuvo valores de RMSE mayores que los
 454 modelos al norte de 35°S en Argentina.

455 El índice R01 incluye la cantidad de días promedio con precipitaciones mayores o
 456 iguales a 1 mm a niveles anual y estacional. Los resultados se presentan como el cociente
 457 entre el valor modelado y el observado (*ratio*) (Figura 9). A nivel anual, los modelos tienden
 458 a subestimar la cantidad de días con precipitaciones. En Argentina y la mitad sur del dominio
 459 en Chile, se encuentran los mejores desempeños con *ratios* entre 0.8 y 1. En el centro y norte
 460 de Chile, se registran valores entre 0.7 y 0.9 excepto para el modelo “pf” que tiene déficits
 461 más pronunciados. ERA-Interim sobreestima la cantidad de días con precipitación en todo el
 462 dominio excepto en el sur de Chile, con valores mayores a 1.4 hasta un máximo de 9.85
 463 (fuera de escala en el sector argentino).

464 Las muy escasas precipitaciones estivales en el centro y norte del sector chileno
 465 afectan el rendimiento de los modelos de *downscaling*, sin un patrón geográfico claro (Figura
 466 9 b). En el resto del dominio, los desvíos con respecto a los datos observados son más ligeros
 467 con *ratios* entre 0.7 y 1.2.

468 En otoño e invierno, los modelos basados en predictores locales (“ls16” y “ls4”) son
 469 los que generan series más cercanas a los datos observados (Figura 9 c y d). En Chile, los
 470 modelos presentan déficits con respecto a las observaciones que se acentúan hacia el norte.
 471 En Argentina en el sector norte, predominan los *ratios* mayores a 1.

Artículo en edición

472 Para la primavera, no hay homogeneidad en los resultados de los modelos con *ratios*
473 entre 0.7 y 1.3 salvo excepciones puntuales (Figura 9 e). En ese sentido, el modelo “pc_c”
474 tiende a sobreestimar la cantidad de días con precipitaciones mientras que para los modelos
475 “ls16”, “pf” y “pc” se observan mayoría de *ratios* menores a 1.

476 ERA-Interim exagera la cantidad de días húmedos para todas las estaciones del año de
477 un modo similar a lo hallado a escala anual.

478 En la Figura 10 se presenta el desempeño de los modelos en reproducir la cola de la
479 distribución de la precipitación diaria en términos anuales y estacionales.

480 A nivel anual, los valores modelados se acercan a los datos observados con *ratios*
481 cercanos a 1, excepto estaciones puntuales. El modelo “pc” exagera los valores de P98Wet
482 para las estaciones del centro del sector chileno, con *ratios* mayores a 1.2. ERA-Interim
483 presenta valores que evidencian un desempeño más pobre que el de los modelos de
484 *downscaling* con grandes sobreestimaciones en el sector centro-norte de Argentina y
485 subestimaciones en el resto del dominio.

486 Los valores de P98Wet para verano están signados por las escasas precipitaciones
487 observadas en Chile (excepto en el sur). Los modelos de *downscaling* y ERA-Interim acusan
488 valores mayores a 1.4 y menores a 0.6 de manera alternada sin un patrón geográfico claro. En
489 el resto del dominio, el reanálisis muestra *ratios* mayores a 1.4 en gran parte de las estaciones
490 argentinas al norte del dominio y menores a 0.6 al sur. Los modelos de *downscaling* calculan
491 *ratios* más cercanos a los observados (entre 0.7 y 1.3) en la mayoría de las estaciones
492 argentinas pero sin una distribución geográfica distinguible. Los modelos “pc_c” y “ls16” son
493 los que presentan el mejor desempeño.

494 Los modelos de *downscaling* presentan el desempeño más pobre durante el verano sin
495 un patrón definido (Figura 10 b), seguido por la primavera donde predominan las
496 sobreestimaciones especialmente hacia el norte del dominio (Figura 10 e). Durante el otoño e
497 invierno, los modelos muestran un rendimiento relativamente superior. El desempeño de
498 ERA-Interim es muy bajo en todas las estaciones del año.

499 El Critical Success Index (CSI) permite evaluar el desempeño de los modelos
500 mediante su relación entre los días con precipitación predichos correctamente y la suma entre
501 estos aciertos y días donde los modelos fallaron (Figura 11). A nivel anual (Figura 11 a) y
502 estacional (Figura 11 b c d e), todos los modelos muestran valores de CSI mayores en las
503 estaciones chilenas en comparación con las argentinas, y un aumento de los valores hacia el

Artículo en edición

504 sur. Los modelos de *downscaling* obtienen mayores CSI para las estaciones chilenas en
 505 comparación con ERA-Interim, y a su vez los modelos basados en predictores locales
 506 muestran un mejor desempeño que los de análisis de componentes principales. En las
 507 estaciones argentinas, los resultados son pobres con valores menores a 0.25 salvo contadas
 508 excepciones. La estación con el peor desempeño es el verano ([Figura 11 b](#)) con valores por
 509 debajo de 0.2 para todos los modelos y estaciones, excepto para los modelos de *downscaling*
 510 al sur de 35°S en Chile; mientras que los mejores resultados se hallan en invierno ([Figura 11](#)
 511 [d](#)), con valores que superaron 0.5 en la mayoría de las estaciones chilenas en consonancia con
 512 la estación húmeda de dicho país.

513

514 **4. CONCLUSIONES**

515 En el presente trabajo se explora la posibilidad de añadir valor agregado al modelado
 516 de las precipitaciones diarias en una región con orografía compleja a través de técnicas
 517 estadísticas de reducción de escala. Se construyeron con ese fin modelos estadísticos
 518 considerando distintos conjuntos de predictores, constituidos por grupos de variables
 519 atmosféricas que pudieran guardar relación con procesos que generan precipitaciones sobre la
 520 zona de los AC. Se simularon series de precipitación diaria utilizando las variables del
 521 reanálisis ERA-Interim para las 83 estaciones del dominio en el periodo 1981-2015,
 522 siguiendo el método de análogos. A partir de las series obtenidas, se calcularon diversas
 523 métricas de validación de los modelos estadísticos a niveles anual, estacional y diario con el
 524 fin de evaluar el rendimiento de los modelos para reproducir los datos observados.

525 ERA-Interim presenta un desempeño pobre con respecto a los aspectos marginales de
 526 la distribución de la precipitación, como valores medios y extremos y frecuencia de días de
 527 lluvia. En este sentido, el reanálisis se presenta como un conjunto no apto para la
 528 representación de las precipitaciones en la región y se debe tener especial cuidado para
 529 considerarlo como conjunto de referencia en estudios de evaluación (Balmaceda-Huarte et al.
 530 2021). Estos resultados están en línea con lo encontrado por Zazulie et al. (2017) quienes
 531 señalaron las deficiencias de ERA-Interim en representar los acumulados de verano en la
 532 región. Sin embargo, al analizar distintos aspectos temporales de la variabilidad de la
 533 precipitación, ERA-Interim muestra un buen desempeño en la representación de la
 534 variabilidad intraanual, interanual y de largo plazo (tendencias).

Artículo en edición

535 Los modelos de *downscaling* en líneas generales agregan valor a ERA-Interim,
 536 particularmente en la representación de los valores medios y extremos y en la frecuencia de
 537 precipitación. Del mismo modo, muestran un buen desempeño en la representación de las
 538 distintas características regionales del ciclo anual de precipitación y en la variabilidad en las
 539 diferentes escalas temporales analizadas. Al respecto, los modelos son capaces de reproducir
 540 satisfactoriamente la variabilidad a largo plazo (tendencias) aún cuando fueron construidos en
 541 base diaria y siendo este un aspecto que deben heredar de los predictores (Maraun et al.
 542 2019). Las tendencias más pronunciadas, como por ejemplo las de la Patagonia chilena para
 543 el otoño (Figura 5 c), son satisfactoriamente capturadas y sus mayores errores se observan en
 544 estaciones puntuales posiblemente debido a que las tendencias están afectadas por fenómenos
 545 locales.

546 Los modelos evidencian una subestimación generalizada del índice R01 (Figura 8) y
 547 de la precipitación media anual (Figura 3) que está relacionada con la baja predictibilidad de
 548 la precipitación diaria a nivel local empleando solo forzantes de gran escala. Con respecto a
 549 los extremos de precipitación, analizados a través del índice P98Wet (Figura 9), los modelos
 550 tienden a reproducirlo con habilidad excepto en la región árida del sector chileno donde la
 551 escasez de precipitaciones genera resultados con importantes diferencias entre estaciones
 552 cercanas en el cálculo del índice, ya que el contexto magnifica los errores de los modelos a la
 553 hora de cuantificarlos.

554 Los modelos muestran ciertas discrepancias en su desempeño entre sí, lo que
 555 representa una fuente de incertidumbre en las simulaciones. En este sentido, se encuentran
 556 resultados más fidedignos en las simulaciones que incluyen las 8 variables predictoras
 557 utilizadas en la reducción de escala en comparación con las que emplean sólo una parte de las
 558 mismas. Esto coincide con los resultados hallados por Horton y Brönnimann (2018), quienes
 559 encontraron que los modelos de *downscaling* que incluyeron múltiples variables tuvieron
 560 mejores desempeños a la hora de simular la precipitación diaria en una región de orografía
 561 compleja en comparación con los modelos que incluyeron una sola. Asimismo, se observan
 562 también mejores resultados por parte de los modelos basados en predictores locales (en
 563 especial “ls16”) con respecto a los fundados en el análisis de componentes principales. Estos
 564 últimos consideran la influencia más generalizada de la estructura espacial de los predictores
 565 probablemente suavizando los aspectos más locales que influyen sobre la precipitación. Al
 566 respecto, Bettolli y Penalba (2018) y Olmo y Bettolli (2021) observaron este mismo

Artículo en edición

567 comportamiento utilizando incluso otras técnicas estadísticas para la simulación de la
568 precipitación diaria en la región Pampeana argentina y del sudeste de Sudamérica.

569 El desempeño de los modelos a lo largo del dominio no fue uniforme, sino que tanto
570 ERA-Interim como los modelos de *downscaling* obtuvieron mejores resultados en las
571 estaciones chilenas ubicadas al sur del dominio que en el sector argentino. Esto está
572 posiblemente asociado a que el forzante más relevante de la precipitación en el sector chileno
573 es la actividad sinóptica, y estas estructuras son hábilmente capturadas por el método de
574 análogos. Estos resultados son congruentes con lo encontrado por Bettolli y Penalba (2018)
575 para la precipitación en la región pampeana durante el invierno y Timbal et al. (2004) para la
576 región oeste de Francia. Consistentemente, las dificultades para simular la precipitación
577 diaria en las estaciones argentinas se desprenden de la naturaleza mayormente convectiva de
578 las precipitaciones estivales junto con la presencia de fenómenos locales, evidenciando la
579 necesidad de incluir forzantes de menor escala a los modelos de *downscaling*. Sin embargo,
580 Horton y Brönnimann (2018) emplearon el método de análogos para reproducir la
581 precipitación diaria mediante modelos de *downscaling* y concluyeron que el valor agregado
582 por resoluciones de los predictores atmosféricos mayores a 1° es despreciable.

583 El estudio del Critical Success Index (CSI, [Figura 11](#)) y el error cuadrático medio
584 (RMSE, [Figura 8](#)) caracterizan las dificultades y fortalezas de los modelos de *downscaling* al
585 reproducir la precipitación en la región de los AC. Los magros resultados de CSI en verano y
586 regiones áridas sugieren que los modelos son propensos a simular precipitaciones que no se
587 corroboraron, mientras que se desempeñan mejor en contextos con mayor cantidad de días
588 con precipitación, como lo son las estaciones del sur de Chile. Por su parte, los menores
589 valores de RMSE hallados en contextos áridos con respecto al resto del dominio sugieren una
590 fortaleza de los modelos de *downscaling* para cuantificar acumulados diarios en estos
591 contextos.

592 Este trabajo sienta las bases de la evaluación de técnicas de *downscaling* para la
593 precipitación diaria en regiones de topografía compleja. La técnica desarrollada aquí puede
594 ser tomada como punto de referencia o *benchmark* para la comparación futura con métodos
595 más complejos del estado del arte. En ese sentido, es relevante explorar otras técnicas de
596 *downscaling* como por ejemplo aquellas que incorporan *machine learning* en escenarios
597 similares a los descritos en este trabajo.

598

Artículo en edición

599 **REFERENCIAS**

600

601 Aniley, E.; Gashaw, T.; Abraham, T.; Demessie, S.F.; Bayabil, H.K.; Worqlul, A.W.;
602 van Oel, P.R.; Dile, Y.T.; Chukalla, A.D.; Hailelassie A.; Wubaye, G.B.; 2023: Evaluating
603 the performances of gridded satellite/reanalysis products in representing the rainfall
604 climatology of Ethiopia, *Geocarto International*, 38:1, 2278329, DOI:
605 10.1080/10106049.2023.2278329

606

607 Araneo, D. C., Compagnucci, R. H.; 2008: Atmospheric circulation features
608 associated to Argentinean Andean rivers discharge variability, *Geophys. Res. Lett.*, 35,
609 L01805 doi:10.1029/2007GL032427.

610

611 Araneo, D.; Villalba, R.; 2014: Variability in the annual cycle of the Río Atuel
612 streamflows and its relationship with tropospheric circulation, *Int. J. Climatol.*
613 doi:10.1002/joc.4185

614

615 Araya-Osses, D.; Casanueva, A.; Román-Figueroa, C.; Uribe, J.M.; Paneque, M.;
616 2020: Climate change projections of temperature and precipitation in Chile based on
617 statistical downscaling, *Climate Dynamics* (2020) 54:4309–4330.
618 <https://doi.org/10.1007/s00382-020-05231-4>

619

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

624

625 Balmaceda-Huarte, R.; Bettolli, M.L.; 2022: Assessing statistical downscaling in
626 Argentina: Daily maximum and minimum temperatures, *Int J Climatol.* 2022;42:8423–8445.
627 <https://doi.org/10.1002/joc.7733>

628

629 Basist, A., Bell, G.D., Meentemeyer, V., 1994: Statistical Relationships between
630 Topography and Precipitation Patterns, *Journal of Climate* 7:1305-1315.

Artículo en edición

631

632 Bedía, J., Baño-Medina, J., Legasa, M.N., Iturbide, M., Manzanos, R., Herrera, S.,
 633 Casanueva, A., San-Martín, D., Cofiño, A.S., Gutiérrez, J.M., 2019: Statistical downscaling
 634 with the downscaleR package: Contribution to the VALUE intercomparison experiment.
 635 <https://doi.org/10.5194/gmd-2019-224>.

636

637 Bettoli, M.L. y Penalba, O.C., 2018: Statistical downscaling of daily precipitation
 638 and temperatures in southern La Plata Basin, *International Journal of Climatology* 2018:1-18.
 639 [doi:10.1002/joc.5531](https://doi.org/10.1002/joc.5531).

640

641 Boisier, J.P.; Alvarez-Garreton, C.; Cordero, R.; Damiani, A.; Gallardo, L.; Garreaud,
 642 R.D.; Lambert, F.; Ramallo, C.; Rojas, M.; Rondanelli, R.; 2018: Anthropogenic drying in
 643 central-southern Chile evidenced by long-term observations and climate model simulations,
 644 *Elem Sci Anth*, 6: 74. <https://doi.org/10.1525/elementa.328>

645

646 Bonelli, S.; Vicuña, S.; Meza, F.J.; Gironás, J.; Barton, J.; 2014: Incorporating climate
 647 change adaptation strategies in urban water supply planning: the case of central Chile, *Journal*
 648 *of Water and Climate Change* 05.3:357-376. [doi:10.2166/wcc.2014.037](https://doi.org/10.2166/wcc.2014.037).

649

650 Bozkurt, D.; Rojas, M.; Boisier, J.P.; Valdivieso, J.; 2018: Projected hydroclimate
 651 changes over Andean basins in central Chile from downscaled CMIP5 models under the low
 652 and high emission scenarios, *Climatic Change* (2018) 150:131–147.
 653 <https://doi.org/10.1007/s10584-018-2246-7>

654

655 Bravo, C.; Loriaux, T.; Rivera, A.; Brock, B. W.; 2017: Assessing glacier melt
 656 contribution to streamflow at Universidad Glacier, central Andes of Chile, *Hydrol. Earth*
 657 *Syst. Sci.*, 21, 3249–3266. <https://doi.org/10.5194/hess-21-3249-2017>

658

659 Chen, D. y Dai, A.; 2019: Precipitation Characteristics in the Community Atmosphere
 660 Model and Their Dependence on Model Physics and Resolution, *Journal of Advances in*
 661 *Modeling Earth Systems*, 11, 2352–2374. <https://doi.org/10.1029/2018MS001536>

662

Artículo en edición

663 Dee, DP; Uppala, SM; Simmons, AJ; Berrisford, P; Poli, P; Kobayashi, S; Andrae, U;
664 Balmaseda, MA; Balsamo, G; Bauer, P; Bechtold, P; Beljaars, ACM; van de Berg, L; Bidlot,
665 J; Bormann, N; Delsol, C; Dragani, R; Fuentes, M; Geer, AJ; Haimberger, L; Healy, SB;
666 Hersbach, H; Hólm, EV; Isaksen, L; Kållberg, P; Köhler, M; Matricardi, M; McNally, AP;
667 Monge-Sanz, BM; Morcrette, JJ; Park, BK; Peubey, C; de Rosnay, P; Tavolato, C; Thépaut,
668 JN; Vitart, F; 2011: The ERA-Interim reanalysis: configuration and performance of the data
669 assimilation system. Q J Roy Meteorol Soc 137:553–597. <https://doi.org/10.1002/qj.828>

670

671 Falvey, M., Garreaud, R., 2007: Wintertime Precipitation Episodes in Central Chile:
672 Associated Meteorological Conditions and Orographic Influences, Journal of
673 Hydrometeorology 8:171-193. doi:10.1175/JHM562.1.

674

675 Fuentealba, M.; Bahamóndez, C.; Sarricolea, P.; Meseguer-Ruiz, O.; Latorre, C.;
676 2021: The 2010–2020 'megadrought' drives reduction in lake surface area in the Andes of
677 central Chile (32° - 36°S), Journal of Hydrology: Regional Studies 38.
678 <https://doi.org/10.1016/j.ejrh.2021.100952>

679

680 Garreaud R.D., 2009: The Andes climate and weather, Advances in Geosciences 7:1-
681 9.

682

683 Garreaud, R.; Álvarez-Garreton, C.; Barichivich, J.; Boisier, J.P.; Christie, D.;
684 Galleguillos, M.; LeQuesne, C.; McPhee, J.; Zambrano-Bigiarini, M.; 2017: The 2010–2015
685 megadrought in central Chile: impacts on regional hydroclimate and vegetation, Hydrol.
686 Earth Syst. Sci., 21, 6307–6327, 2017. <https://doi.org/10.5194/hess-21-6307-2017>

687

688 Garreaud, R.D; Boisier, J.P.; Rondanelli, R.; Montecinos, A.; Sepúlveda, H.; Veloso-
689 Aguila, D.; 2019: The Central Chile Mega Drought (2010–2018): A climate dynamics
690 perspective, Int J Climatol. 2020;40:421–439. doi:10.1002/joc.6219

691

692 Gutowski, J.W.; Giorgi, F.; Timbal, B.; Frigon, A.; Jacob, D.; Kang, H.S.; Raghavan,
693 K.; Lee, B.; Lennard, C.; Nikulin, G.; O'Rourke, E.; Rixen, M.; Solman, S.; Stephenson, T.;
694 Tangang, F.; 2016: WCRP COordinated Regional Downscaling EXperiment (CORDEX): a

Artículo en edición

695 diagnostic MIP for CMIP6. Geosci Model Dev 9(11):4087–4095.
696 <https://doi.org/10.5194/gmd-9-4087-2016>

697

698 Horton, P.; Brönnimann, S.; 2018: Impact of global atmospheric reanalyses on
699 statistical precipitation downscaling, *Climate Dynamics*. [https://doi.org/10.1007/s00382-018-](https://doi.org/10.1007/s00382-018-4442-6)
700 4442-6

701

702 Horton, P.; 2021: Analogue methods and ERA5: Benefits and pitfalls, *Int J Climatol*.
703 2022;42:4078–4096. doi:10.1002/joc.7484.

704

705 INDEC, 2022: Censo nacional de población, hogares y viviendas 2022: resultados
706 provisionales / 1a ed, ISBN 978-950-896-633-9.

707

708 Instituto Nacional de Estadísticas, 2018: Síntesis de Resultados Censo 2017 de Chile.
709 [https://www.ine.gov.cl/docs/default-source/censo-de-poblacion-y-vivienda/publicaciones-y-](https://www.ine.gov.cl/docs/default-source/censo-de-poblacion-y-vivienda/publicaciones-y-anuarios/2017/publicaci%C3%B3n-de-resultados/sintesis-de-resultados-censo2017.pdf?sfvrsn=1b2dfb06_6)
710 [anuarios/2017/publicaci%C3%B3n-de-resultados/sintesis-de-resultados-](https://www.ine.gov.cl/docs/default-source/censo-de-poblacion-y-vivienda/publicaciones-y-anuarios/2017/publicaci%C3%B3n-de-resultados/sintesis-de-resultados-censo2017.pdf?sfvrsn=1b2dfb06_6)
711 [censo2017.pdf?sfvrsn=1b2dfb06_6](https://www.ine.gov.cl/docs/default-source/censo-de-poblacion-y-vivienda/publicaciones-y-anuarios/2017/publicaci%C3%B3n-de-resultados/sintesis-de-resultados-censo2017.pdf?sfvrsn=1b2dfb06_6)

712

713 Labraga, J.C., 2010: Statistical downscaling estimation of recent rainfall trends, in the
714 eastern slope of the Andes mountain range in Argentina, *Theoretical and Applied*
715 *Climatology* 99,287–302. doi:10.1007/s00704-009-0145-6.

716

717 Maraun, D.; Huth, R.; Gutiérrez, J.M.; San Martín, D.; Dubrovsky, M.; Fischer, A.;
718 Hertig, E.; Soares, P.M.M.; Bartholy, J.; Pongrácz, R.; Widmann, M.; Casado, M.J.; Ramos,
719 P.; Bedia, J.; 2019: The VALUE perfect predictor experiment: Evaluation of temporal
720 variability, *Int. J. Climatol.* 2017;1–33. doi:10.1002/joc.5222.

721

722 Montecinos, A., Díaz, A., Aceituno, P., 2000: Seasonal Diagnostic and Predictability
723 of Rainfall in Subtropical South America Based on Tropical Pacific SST, *Journal of Climate*
724 13:746-758.

725

Artículo en edición

726 Müller, G. y Lovino, M.; 2023: Variability and Changes in Temperature, Precipitation
727 and Snow in the Desaguadero-Salado-Chadileuvú-Curacó Basin, Argentina, *Climate* 2023,
728 11, 135. <https://doi.org/10.3390/cli11070135>

729

730 Mutz, S.; Scherrer, S.; Muceniece, I.; Ehlers, T.; 2021: Twenty-first century regional
731 temperature response in Chile based on empirical-statistical downscaling, *Climate Dynamics*
732 (2021) 56:2881–2894. <https://doi.org/10.1007/s00382-020-05620-9>

733

734 Navarro-Racines, C.; Tarapues, J.; Thornton, P.; Jarvis, A.; Ramirez-Villegas, J.;
735 2020: High-resolution and bias-corrected CMIP5 projections for climate change impact
736 assessments, *Scientific Data* (2020) 7:7. <https://doi.org/10.1038/s41597-019-0343-8>

737

738 Olmo, M., Bettolli M.L., 2021: Statistical downscaling of daily precipitation over
739 southeastern South America: assessing the performance in extreme events, *International*
740 *Journal of Climatology* 42(2),1283–1302. doi:10.1002/joc.7303

741

742 Penalba, O. y Vargas, W.; 2004: Interdecadal and Interannual Variations of Annual
743 and Extreme Precipitation over Central-Northeastern Argentina, *Int. J. Climatol.* 24: 1565–
744 1580 (2004). doi:10.1002/joc.1069

745

746 Rivera, J.A.; Araneo, D.; Penalba, O.; 2017: Threshold level approach for streamflow
747 drought analysis in the Central Andes of Argentina: a climatological assessment,
748 *Hydrological Sciences Journal*, 62:12, 1949-1964. doi:10.1080/02626667.2017.1367095

749

750 Singh, V.P., Lee, T., 2018: Statistical Downscaling for Hydrological and
751 Environmental Applications, 181 págs.

752

753 Timbal, B., Dufour, A., McAvaney, B., 2004: An estimate of future climate change
754 for western France using a statistical downscaling technique. *Climate Dynamics*, 20, 807–
755 823.

756

Artículo en edición

757 Viale, M., Garreaud, R., 2014: Summer Precipitation Events over the Western Slope
758 of the Subtropical Andes, *Monthly Weather Review* 142:1074-1092. doi:10.1175/MWR-D-
759 13-00259.1.

760

761 Viale, M., Nuñez, M.N., 2011: Climatology of Winter Orographic Precipitation over
762 the Subtropical Central Andes and Associated Synoptic and Regional Characteristics, *Journal*
763 *of Hydrometeorology* 12:481-507. doi:10.1175/2010JHM1284.1.

764

765 Wilby, R.L., Dawson, C.W., Barrow, E.M., 2002: SDSM — a decision support tool
766 for the assessment of regional climate change impacts, *Environmental Modelling & Software*
767 17:147–159.

768

769 Wilks, D.S., 1995: *Statistical Methods in the Atmospheric Sciences*. Academic Press,
770 San Diego, 467 págs.

771

772 Wold, S., Esbensen, K., Geladi, P., 1987: Principal Component Analysis,
773 *Chemometrics and Intelligent Laboratory Systems* 2:37-52.

774

775 Zazulie, N.; Rusticucci, M.; Raga, G.; 2017: Regional climate of the subtropical
776 central Andes using high-resolution CMIP5 models—part I: past performance (1980–2005),
777 *Clim Dyn* (2017) 49:3937–3957. doi:10.1007/s00382-017-3560-x

778

779 Zorita, E., von Storch, H., 1999: The Analog Method as a Simple Statistical
780 Downscaling Technique: Comparison with More Complicated Methods, *Journal of Climate*
781 12:2474-2489.

782

783

784

785

786

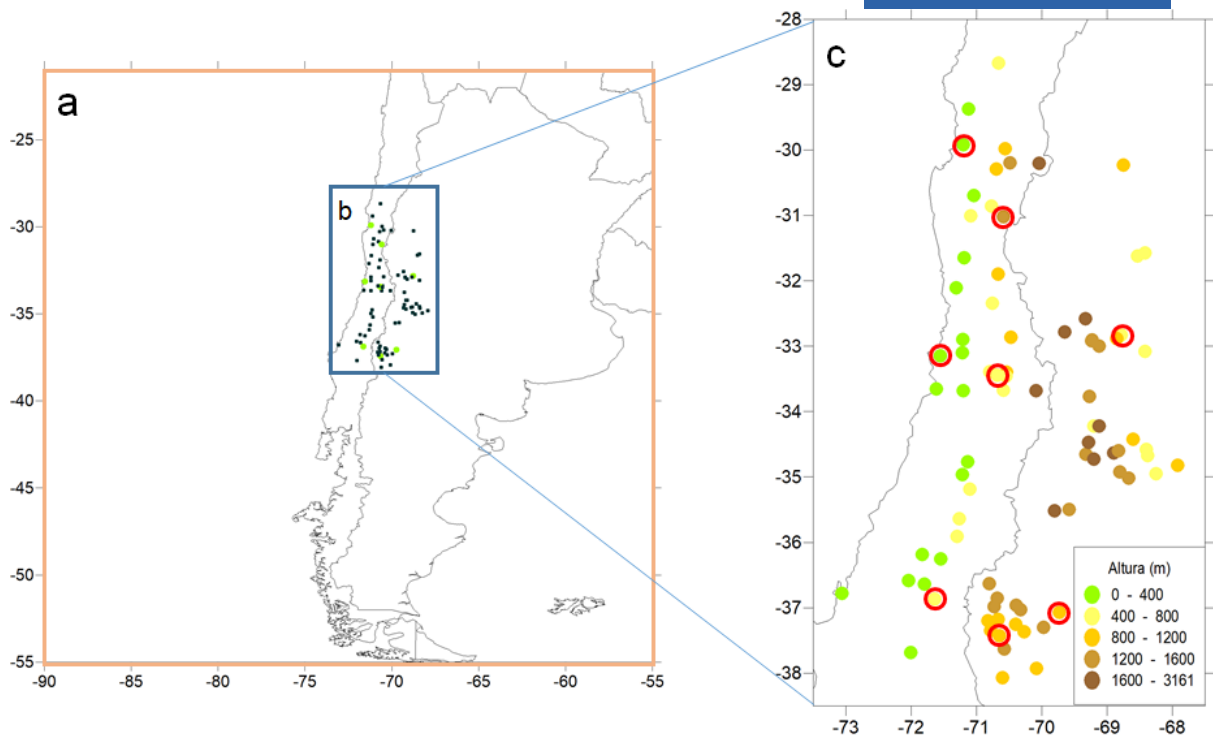
787

788

Artículo en edición

789
790
791
792
793
794
795
796
797
798
799
800
801
802
803
804
805
806
807
808
809
810

Figuras y tablas



811

812 *Figura 1 A la izquierda en naranja, el dominio en el que se empleó el reanálisis. En azul, la región*
813 *donde se ubican las estaciones utilizadas en el trabajo, las mismas están indicadas con puntos*
814 *negros y verdes (estaciones seleccionadas para mostrar resultados específicos). A la derecha, mapa*
815 *ampliado de las estaciones en estudio junto con su altura sobre el nivel del mar con las estaciones*
816 *seleccionadas destacadas en rojo.*

817

818

819

820

821

822

823

824

825

826

827

828

829

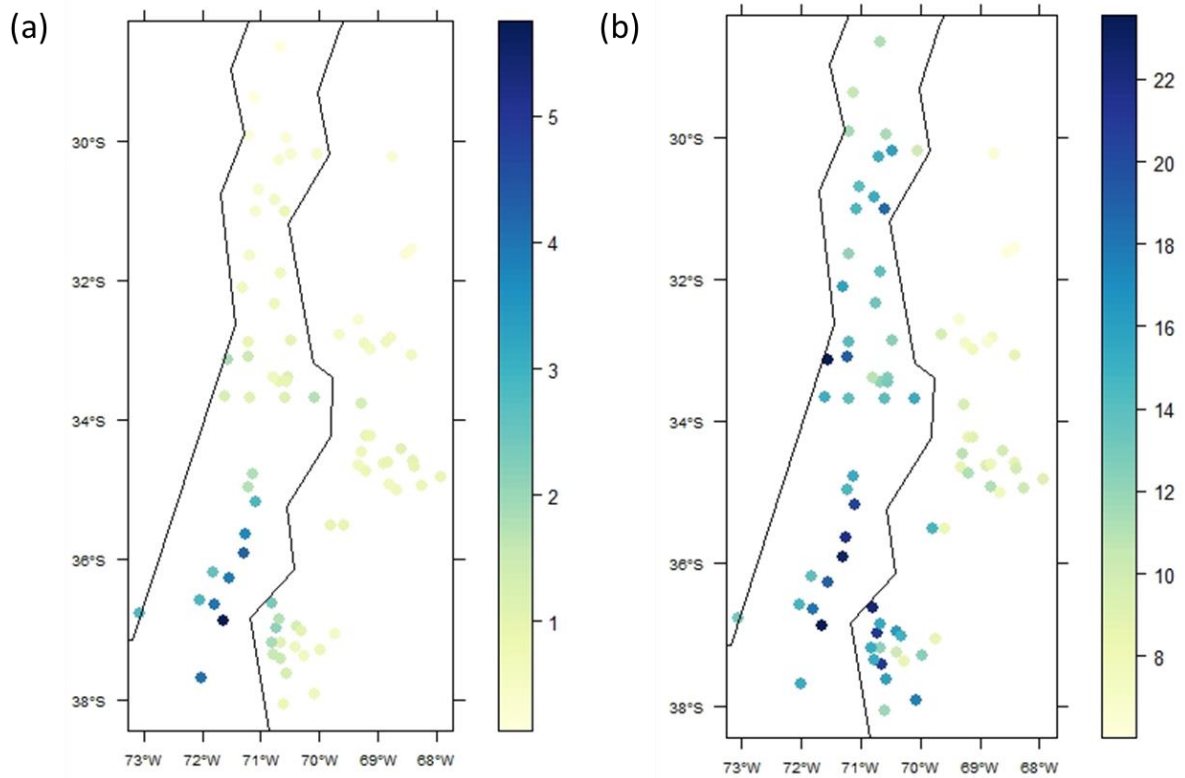
830

831

832

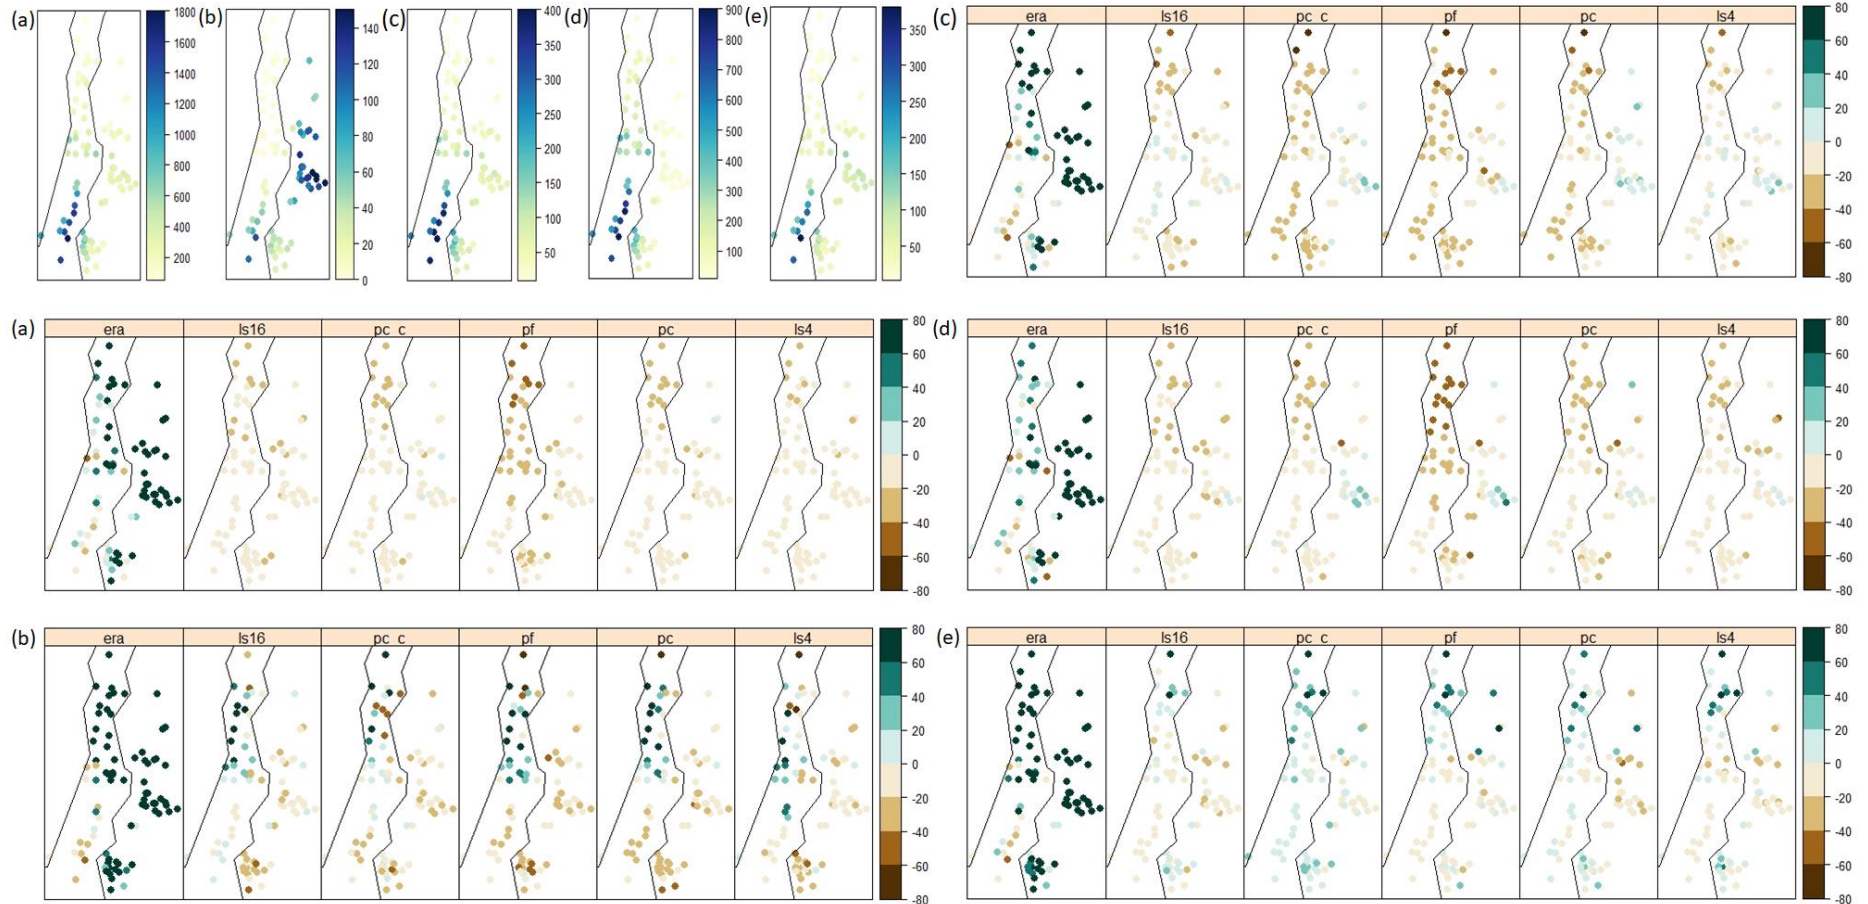
833

834
835
836



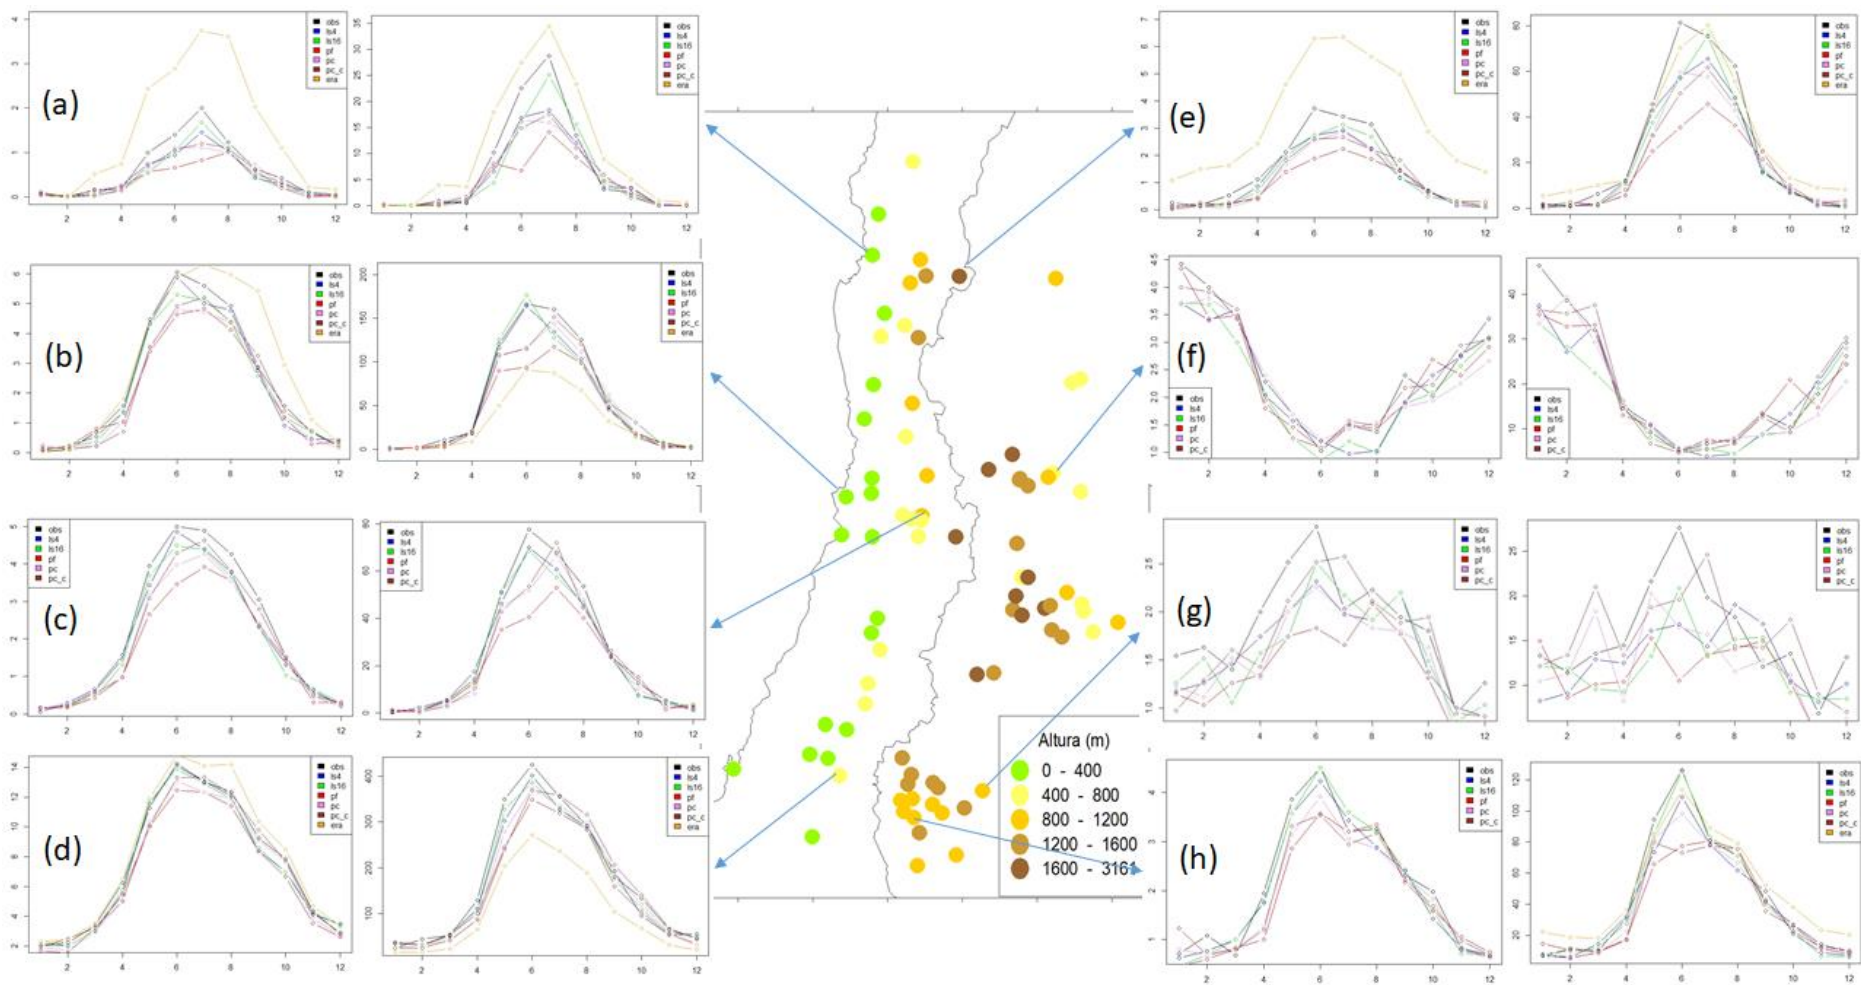
837
838 *Figura 2 a) Precipitación media diaria (mm/día) b) Intensidad media diaria de las precipitaciones*
839 *(mm/día) en términos anuales.*

840
841
842
843
844
845
846
847
848
849
850
851
852
853
854
855
856
857
858

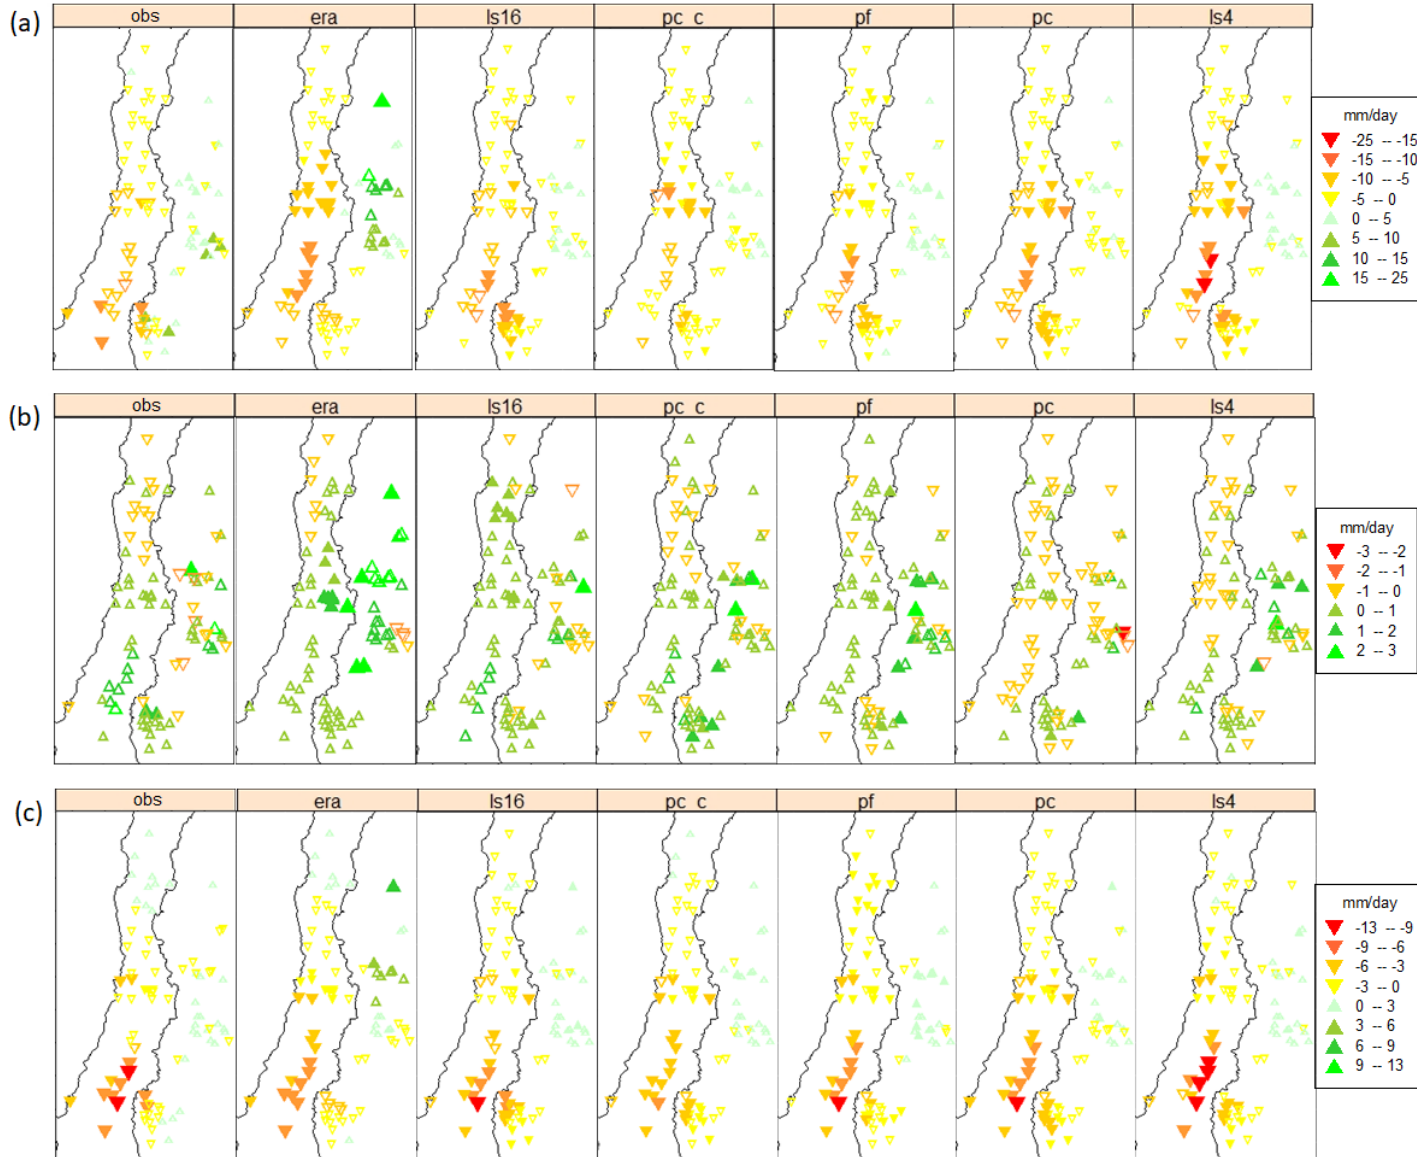


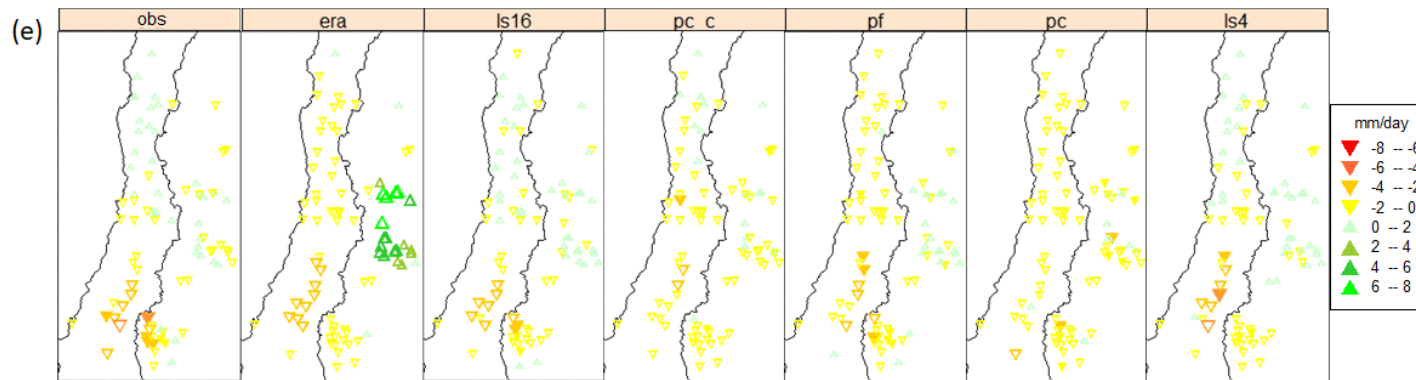
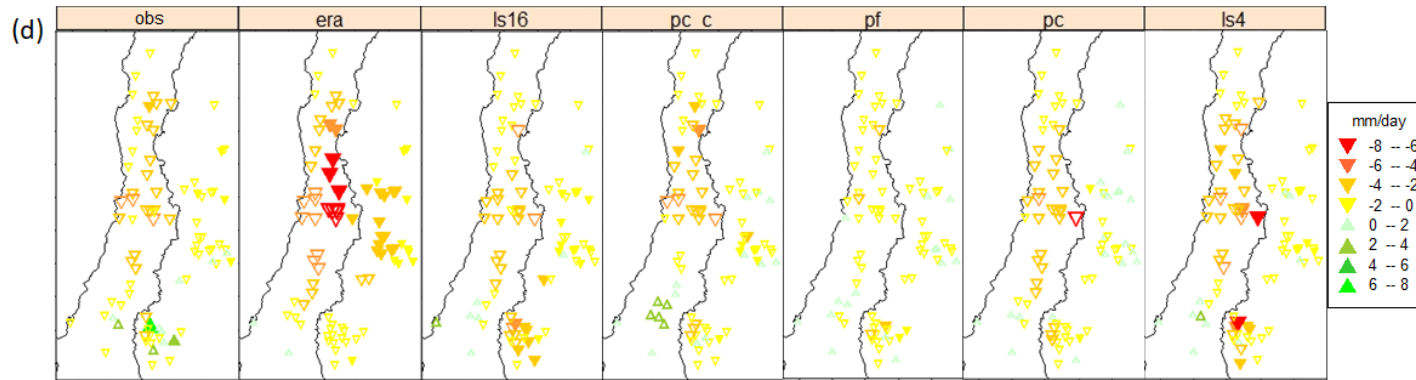
859
 860 *Figura 3 Arriba a la izquierda, precipitación media observada para el periodo 1981-2015 en milímetros. En el resto de la imagen, diferencia entre los valores*
 861 *de precipitación media de los modelos y los datos observados en %. (a) Anual (b) Verano (c) Otoño (d) Invierno (e) Primavera*

862
 863
 864
 865
 866
 867



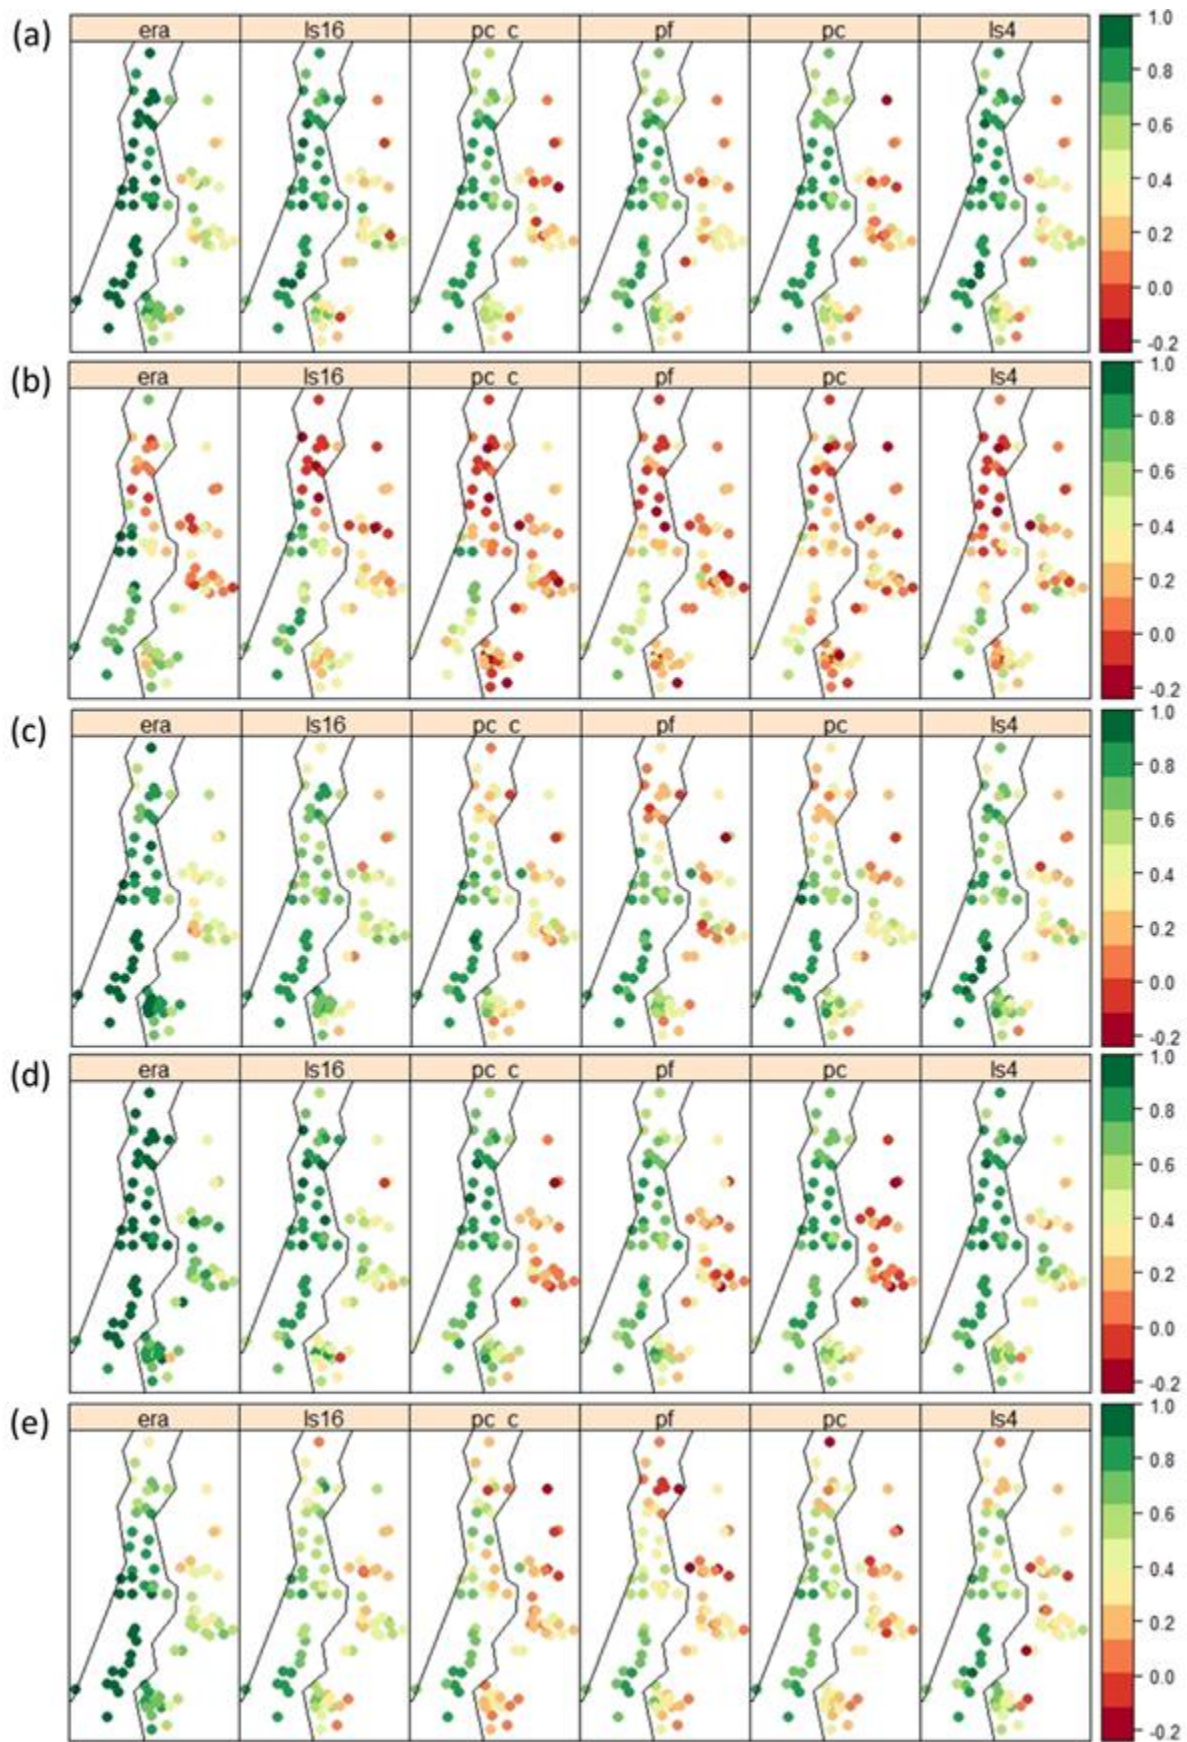
868
 869 *Figura 4 Mapa topográfico del dominio en estudio (centro) y pares de gráficos de marchas anuales de cantidad de días promedio con precipitación por mes*
 870 *(izquierda) y de precipitación media mensual (derecha, en mm) para las 8 estaciones de referencia: (a) La Serena (b) Lago Peñuelas (c) Santiago (d)*
 871 *Diguillín (e) Las Ramadas (f) Mendoza Aero (g) Colorado (h) Trocoman. Se ofrecen imágenes de mayor resolución en el Anexo.*
 872





874

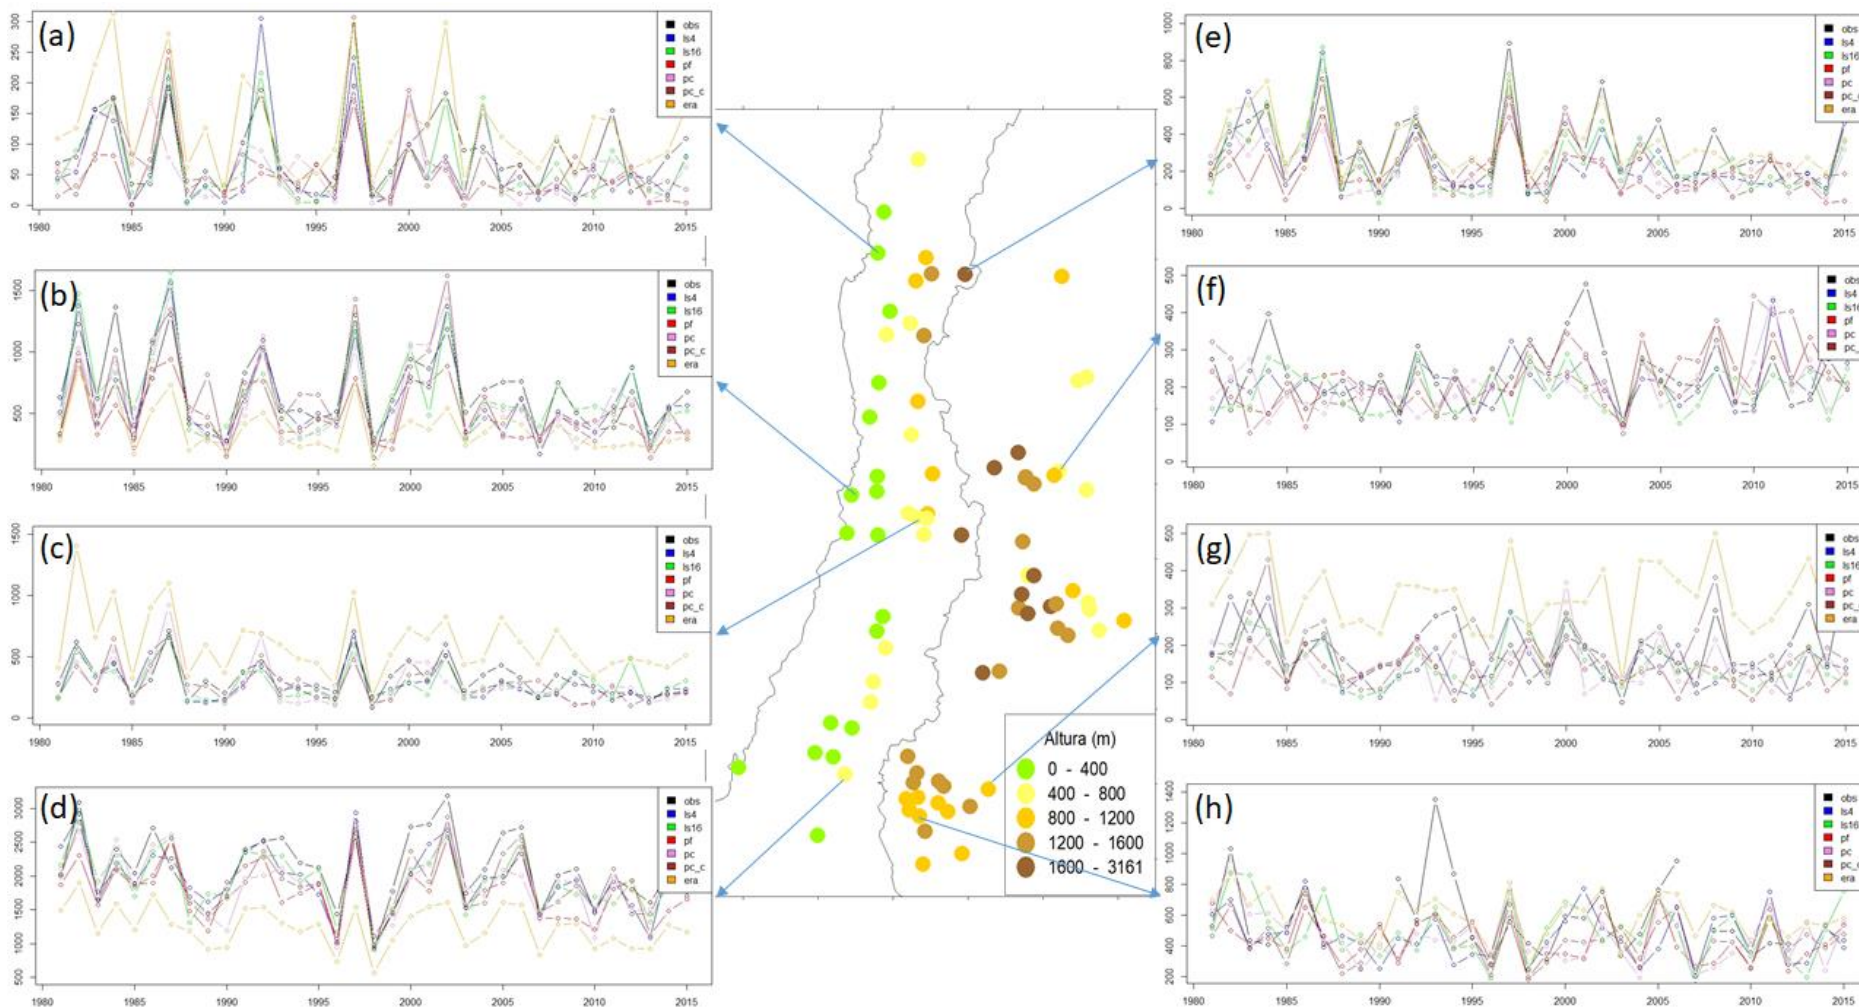
875 *Figura 5 Tendencia lineal de precipitación media para el periodo 1981-2015 en mm/año. Los triángulos llenos indican que dicho valor es estadísticamente*
 876 *significativo al 95%. (a) Anual (b) Verano (c) Otoño (d) Invierno (e) Primavera*



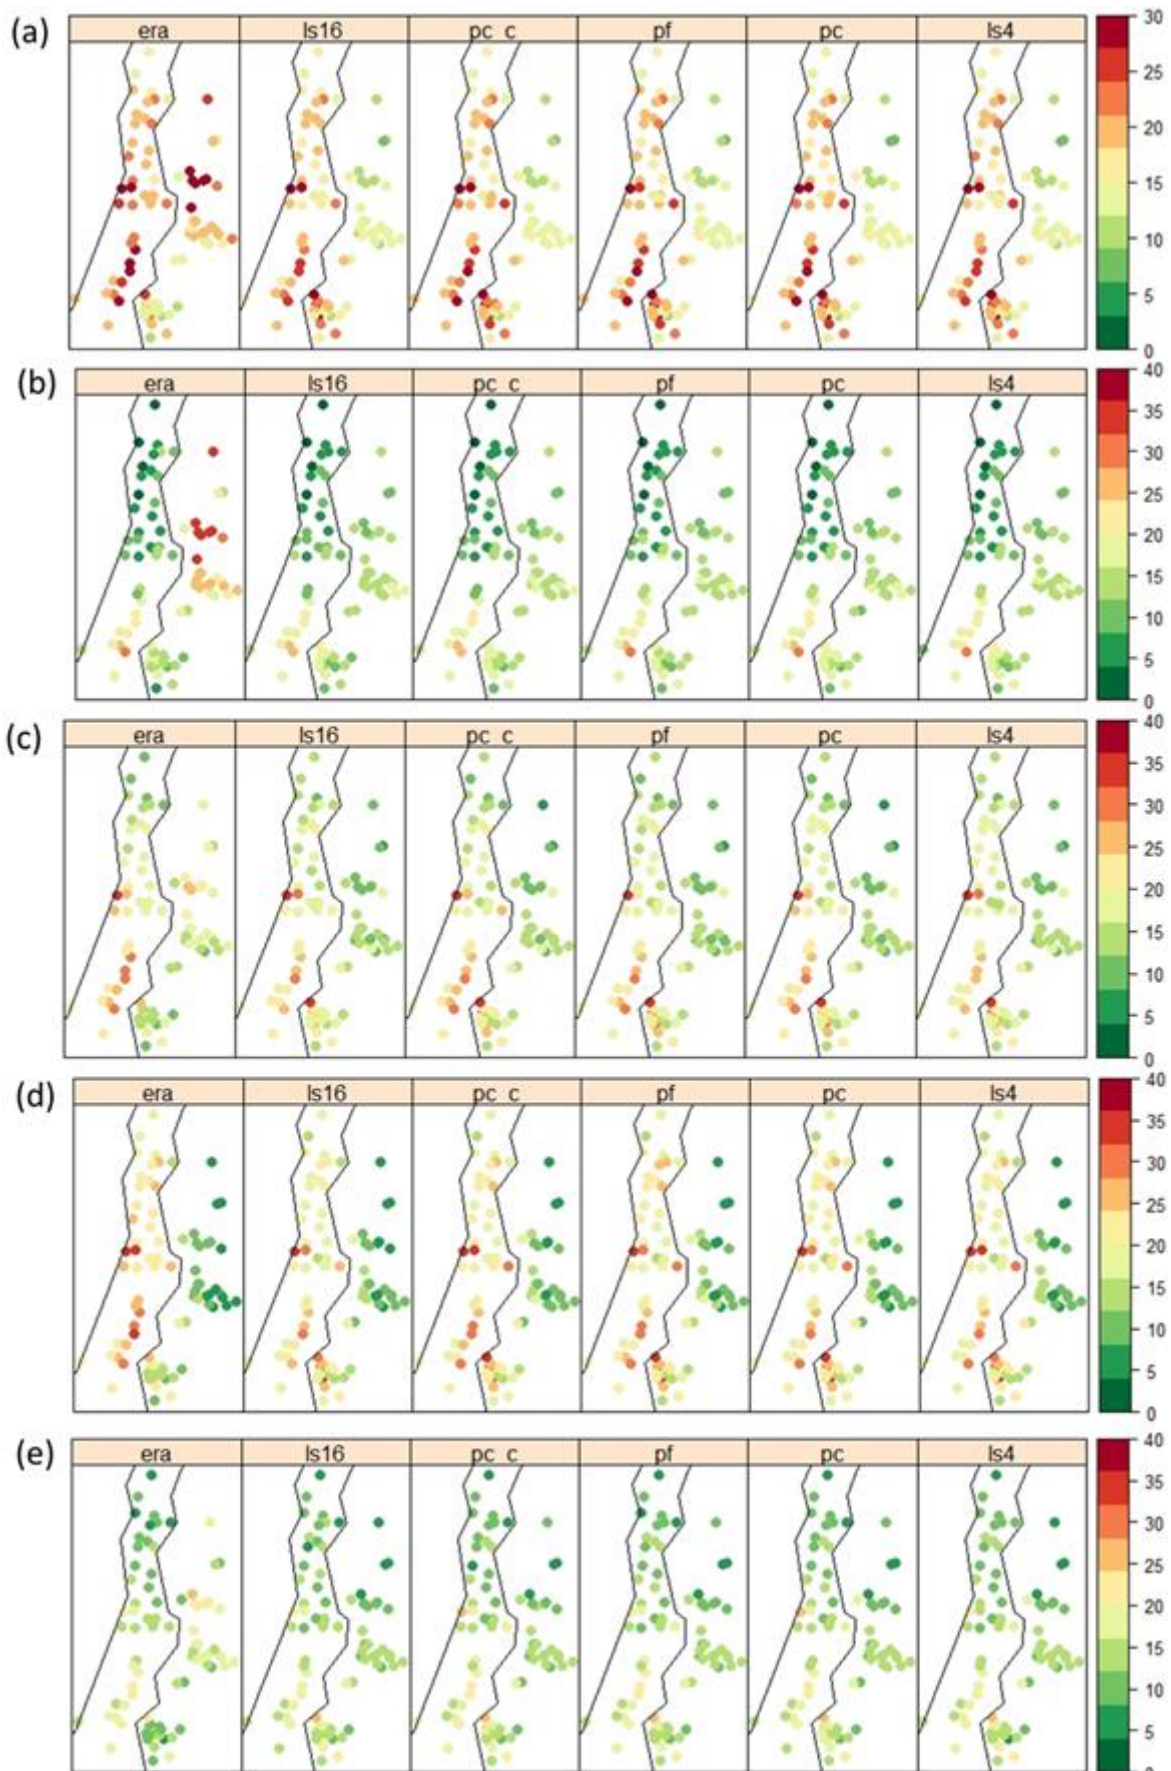
877
 878
 879
 880

881
882
883
884
885
886
887
888

889 *Figura 6 Correlación entre las series de precipitación acumulada observadas y simuladas a nivel*
890 *anual y estacional. Valores significativos estadísticamente al 95% (>0,38) en tonalidades verdes. (a)*
891 *Anual (b) Verano (c) Otoño (d) Invierno (e) Primavera*

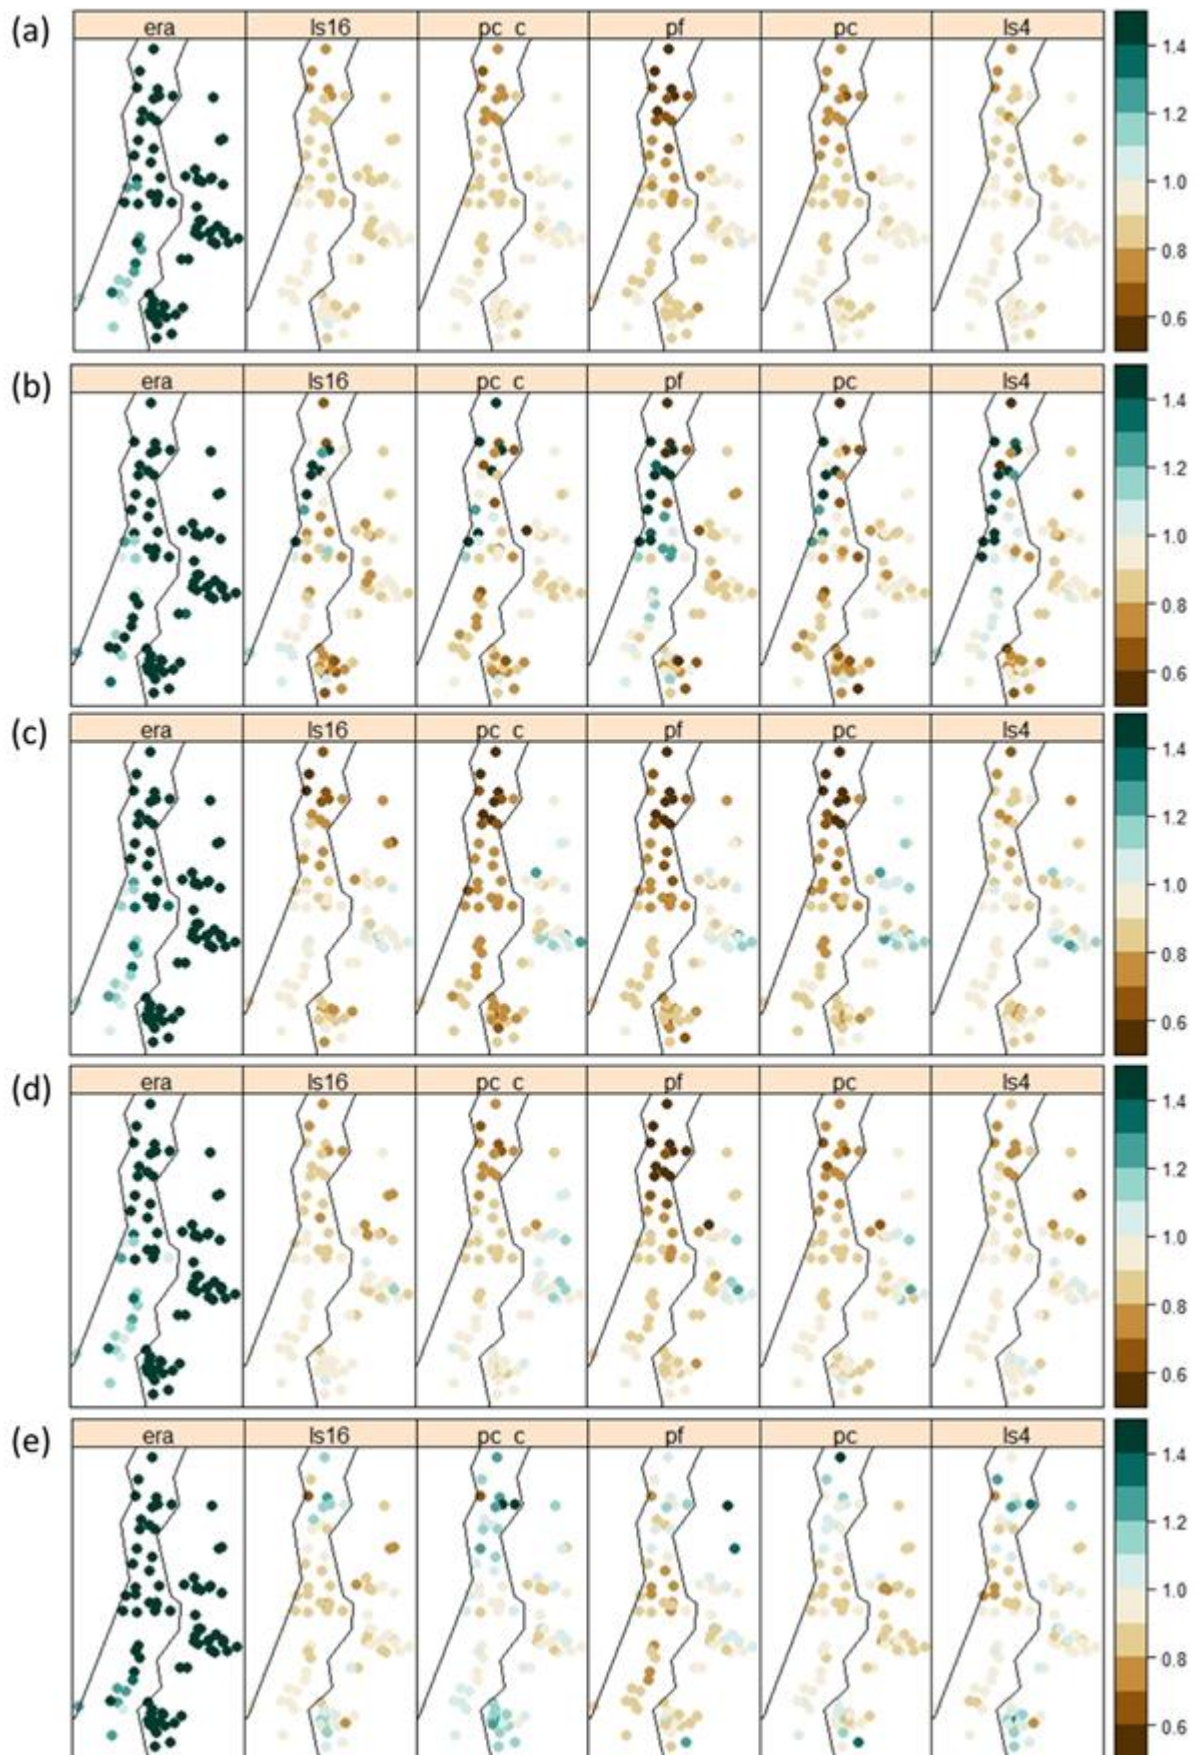


892
 893 *Figura 7 Precipitación anual acumulada para el periodo 1981-2015 en mm. (a) La Serena (b) Lago Peñuelas (c) Santiago (d) Diguillín (e) Las Ramadas*
 894 *(f) Mendoza Aero (g) Colorado (h) Trocoman. Se ofrecen imágenes de mayor resolución en el Anexo.*



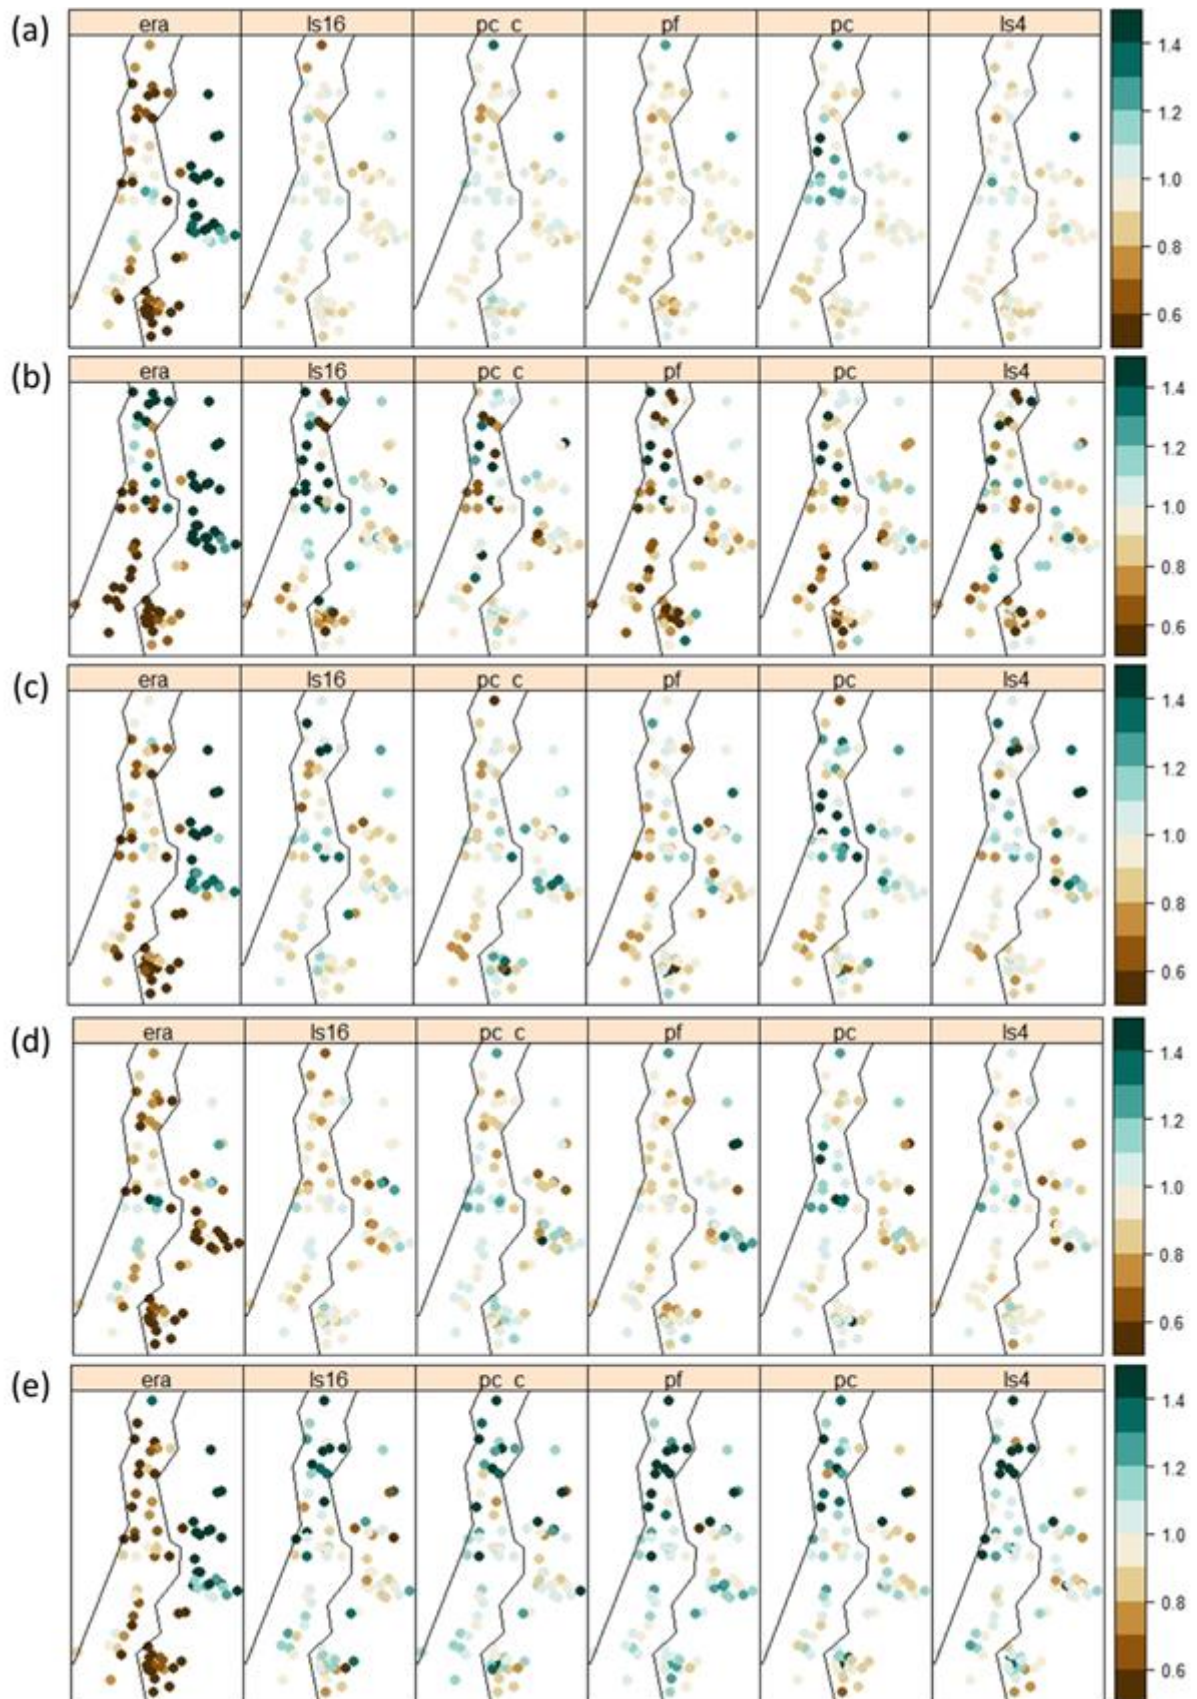
895
896
897

Figura 8. Raíz cuadrada del Error Cuadrático Medio en mm. (a) Anual (b) Verano (c) Otoño (d) Invierno (e) Primavera

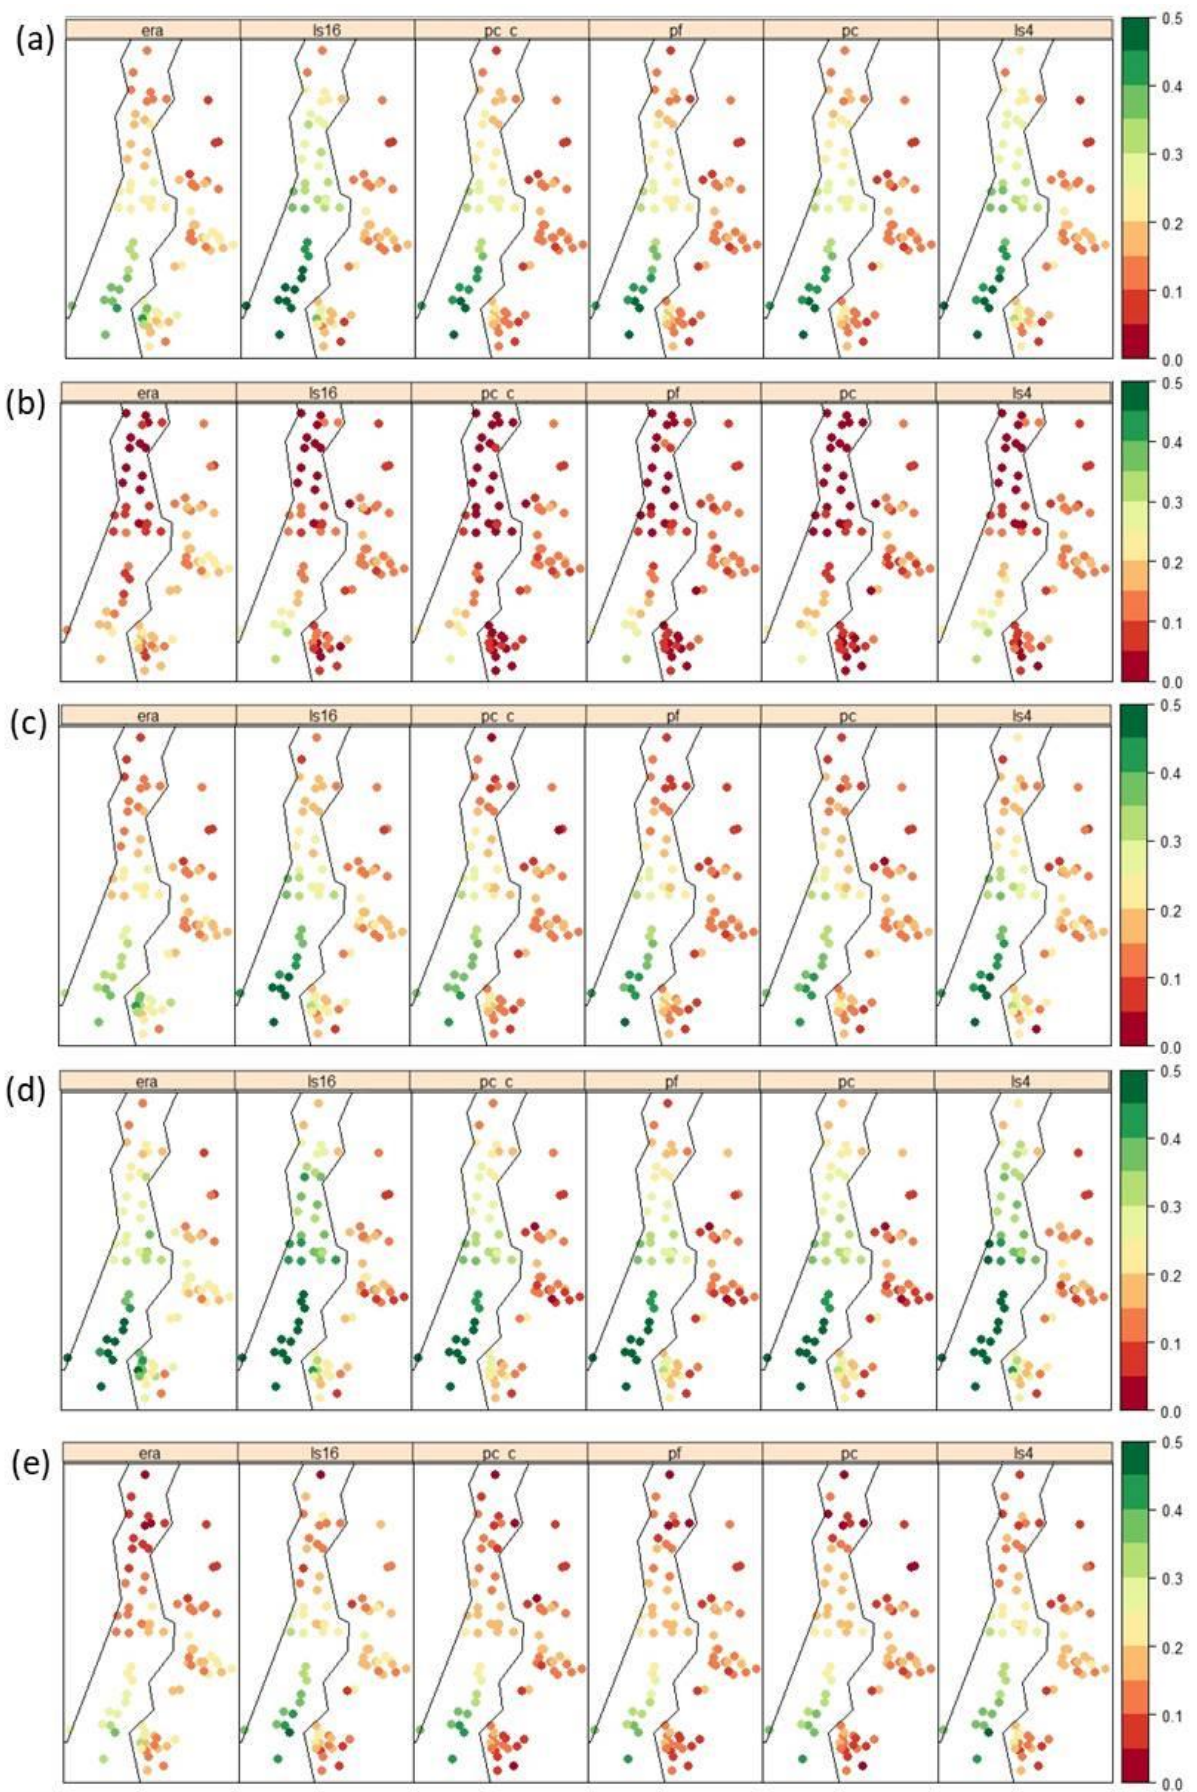


898
899
900

Figura 9 Índice R01 expresado como el ratio de cantidad de días con precipitaciones $\geq 1\text{mm}$ con respecto a los datos observados. (a) Anual (b) Verano (c) Otoño (d) Invierno (e) Primavera



901
 902 *Figura 10 Índice P98Wet expresado como el ratio del valor del percentil 98 teniendo en cuenta solo*
 903 *los días con precipitación $\geq 1\text{mm}$ con respecto a los datos observados. (a) Anual (b) Verano (c) Otoño*
 904 *(d) Invierno (e) Primavera*



905

906 *Figura 11 Índice Critical Success Index (CSI) (a) Anual (b) Verano (c) Otoño (d) Invierno (e) Primavera*

Número	Nombre	Longitud (°)	Latitud (°)	Altura (m)	Datos Faltantes (%)	Fuente
10086	Jáchal	-68.75	-30.23	1175	10.14	SMN
10179	Malargüe	-69.58	-35.50	1425	0.00	SMN
10131	Mendoza Aero	-68.78	-32.83	704	0.00	SMN
10132	Mendoza Observatorio	-68.85	-32.88	827	0.25	SMN
10495	San Juan	-68.42	-31.57	598	0.02	SMN
10370	San Martin	-68.42	-33.08	653	1.19	SMN
10325	San Rafael	-68.40	-34.58	748	0.02	SMN
10903	La Consulta INTA	-69.20	-34.22	740	1.71	INTA
10445	San Juan INTA	-68.53	-31.62	618	6.23	INTA
3820004	Santa Juana	-70.66	-28.67	560	0.27	DGA
4120001	El Trapiche	-71.12	-29.37	300	0.99	DGA
4308003	Rivadavia	-70.56	-29.98	820	0.01	DGA
4311005	La Ortiga	-70.48	-30.19	1560	0.29	DGA
4301005	La Laguna Embalse	-70.04	-30.20	3160	0.04	DGA
4502005	Hurtado	-70.70	-30.29	1100	3.44	DGA
4540006	Paloma Embalse	-71.04	-30.70	320	0.01	DGA
4513004	Caren	-70.77	-30.85	740	3.33	DGA
4535001	Cogoti Embalse	-71.09	-31.01	740	0.25	DGA
4511003	Las Ramadas	-70.59	-31.02	1380	0.02	DGA
4726003	Illapel Dga	-71.19	-31.65	290	0.23	DGA
4710001	La Tranquilla	-70.67	-31.90	1000	0.31	DGA
4902002	Los Condores	-71.31	-32.11	190	1.72	DGA
5200006	Alicahue	-70.75	-32.34	750	0.26	DGA
5410006	Vilcuya	-70.47	-32.86	1100	0.70	DGA
5426004	Quillota	-71.21	-32.90	130	0.92	DGA
5427006	Lliu-Lliu Embalse	-71.21	-33.10	260	0.51	DGA
5510002	Lago Peñuelas	-71.56	-33.15	360	0.50	DGA
5730012	Cerro Calan	-70.54	-33.40	848	0.00	DGA
5711003	Pirque	-70.59	-33.67	659	1.02	DGA
5703008	El Yeso Embalse	-70.09	-33.68	2475	0.08	DGA
5740005	Melipilla	-71.20	-33.68	168	1.31	DGA
6034003	Convento Viejo	-71.13	-34.77	239	0.01	DGA
7116005	Potrero Grande	-71.10	-35.18	445	0.03	DGA
7378003	Colorado	-71.26	-35.64	420	0.05	DGA
7355007	Ancoa Embalse	-71.30	-35.91	421	0.05	DGA
7345001	Parral	-71.83	-36.19	175	0.02	DGA
7331002	Digua Embalse	-71.55	-36.26	390	0.02	DGA
8113001	Coihueco Embalse	-71.80	-36.64	314	0.02	DGA
8130006	Diguillín	-71.64	-36.87	670	0.02	DGA
8318002	Quilaco	-72.01	-37.69	231	0.03	DGA
290004	La Florida La Serena Ad.	-71.20	-29.92	142	0.66	DMC
330020	Quinta Normal Santiago	-70.68	-33.45	527	0.00	DMC

340031	General Freire Curico Ad.	-71.22	-34.97	225	0.00	DMC
360011	Bernardo O'Higgins Chillan Ad.	-72.04	-36.59	151	0.00	DMC
360019	Carriel Sur Concepcion.	-73.06	-36.78	12	0.00	DMC
330021	Pudahuel Santiago	-70.79	-33.39	482	0.06	DMC
330019	Eulogio Sanchez Tobalaba Ad.	-70.55	-33.45	650	0.09	DMC
330030	Santo Domingo Ad.	-71.61	-33.66	75	0.06	DMC
11412	Cacheuta	-69.12	-33.00	1250	12.16	Hídricos
11413	Guido	-69.24	-32.92	1405	0.23	Hídricos
11419	Tunuyan Valle de Uco	-69.27	-33.77	1200	3.82	Hídricos
11423	Diamante La Jaula	-69.32	-34.65	1500	0.23	Hídricos
11426	Pincheira	-69.80	-35.52	1760	6.92	Hídricos
11431	Rama Caída	-68.38	-34.67	730	9.75	Hídricos
11437	El Nihuil	-68.67	-35.02	1200	3.34	Hídricos
11443	Villa Atuel	-67.92	-34.82	840	3.32	Hídricos
11450	Atuel Las Salinas	-68.80	-34.92	1325	13.34	Hídricos
11460	Las Vertientes	-68.60	-34.42	980	8.07	Hídricos
11461	Puesto Canales	-68.90	-34.63	1615	7.63	Hídricos
11464	Juncalito	-69.20	-34.73	1600	8.56	Hídricos
11466	Puesto Morales	-68.82	-34.60	1580	6.42	Hídricos
11467	Arroyo Hondo	-69.28	-34.47	1600	6.19	Hídricos
11469	Atuel Las Malvinas	-68.25	-34.95	600	0.24	Hídricos
11477	Polvaredas	-69.65	-32.78	2250	13.31	Hídricos
11478	Potrerrillos	-69.23	-32.90	1460	9.29	Hídricos
11487	Puesto Papagayos	-69.12	-34.22	1600	8.79	Hídricos
11491	Uspallata	-69.33	-32.58	1890	8.82	Hídricos
12002	Colorado Buta Tranquil	-69.73	-37.07	850	0.01	Hídricos
12011	Trocoman El Cholar	-70.65	-37.43	1080	4.98	Hídricos
12013	Chos Malal	-70.27	-37.37	900	2.63	Hídricos
12014	Loncopue	-70.60	-38.07	990	1.19	Hídricos
12036	Andacollo	-70.67	-37.18	1000	5.01	Hídricos
12071	Cajon Curileuvu	-70.39	-36.97	1374	4.31	Hídricos
12072	Curileivu El Alamito	-70.40	-37.25	900	4.42	Hídricos
12076	Nahueve Las ovejas	-70.73	-36.98	1500	2.88	Hídricos
12077	Varvarco	-70.68	-36.86	1212	0.97	Hídricos
12078	Agrío El Huecu	-70.57	-37.63	1450	1.68	Hídricos
12079	Curileuvu Triaco Malal	-70.32	-37.03	1350	0.26	Hídricos
12080	Lileo Los Miches	-70.82	-37.20	1000	0.73	Hídricos
12085	Reñileuvu Chochoy Mallin	-70.78	-37.35	1100	2.07	Hídricos
12089	Chorriaca	-70.08	-37.93	900	4.06	Hídricos
12091	Pichi Neuquén	-70.80	-36.63	1349	1.42	Hídricos
12092	Auquinco	-69.97	-37.30	1450	2.40	Hídricos

907 *Tabla 1 Datos de las estaciones utilizadas en el trabajo. En verde, las seleccionadas para mostrar*
908 *resultados específicos.*

909

910

Nombre	Variable	Altura	Unidades
z500	Altura geopotencial	500 hPa	m ² s ⁻²
u850	Viento zonal	850 hPa	m s ⁻¹
v850	Viento meridional	850 hPa	m s ⁻¹
t700	Temperatura del aire	700 hPa	K
t850	Temperatura del aire	850 hPa	K
q700	Humedad específica	700 hPa	kg/kg
q850	Humedad específica	850 hPa	kg/kg
psl	Presión sobre el nivel del mar	Nivel del mar	Pa
era	Precipitación total	Superficie	m

911 *Tabla 2 Variables del reanálisis utilizadas en el estudio.*

912
913
914
915
916
917
918
919
920

Modelo Variable	ls16	ls4	pc	pc_c	pf
msl	X	X	X	X	
z500	X	X	X	X	
u850	X	X	X	X	X
v850	X	X	X	X	X
q700	X	X	X		X
q850	X	X	X		
t700	X	X	X		
t850	X	X	X		


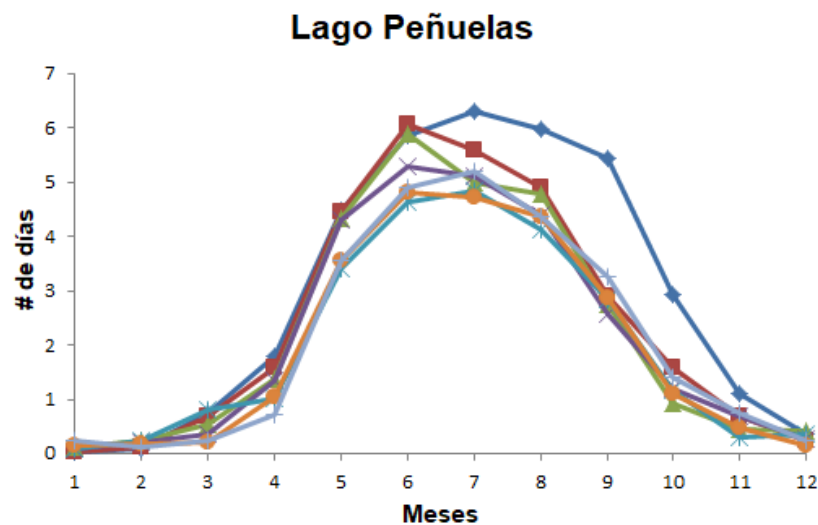
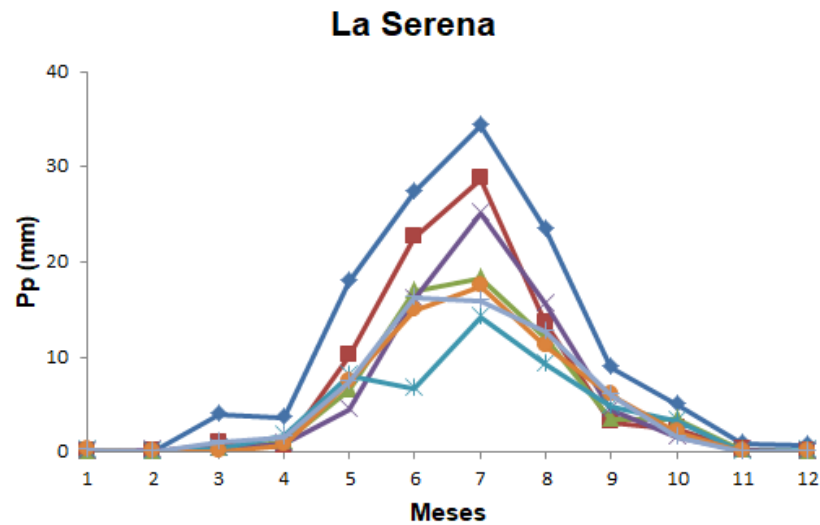
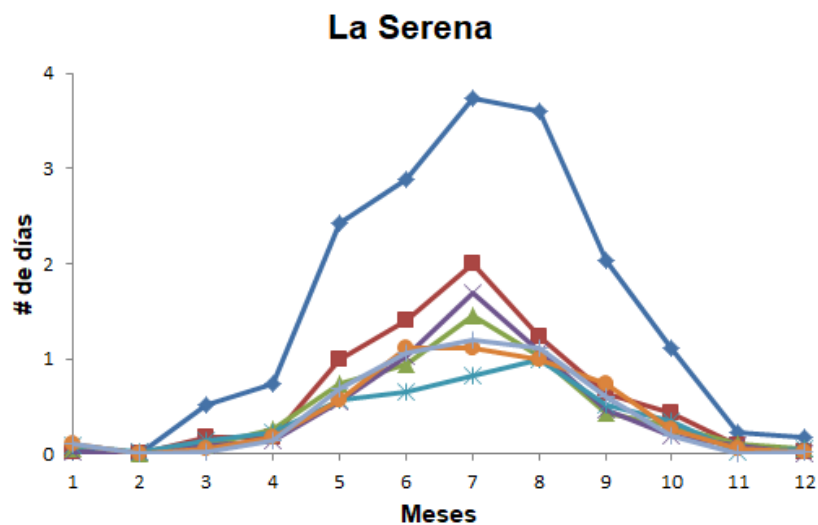
Referencias: X Predictores locales con n=16

X Predictores locales con n=4

X Análisis de componentes principales

921 *Tabla 3 Resumen de los modelos utilizados para realizar las simulaciones.*


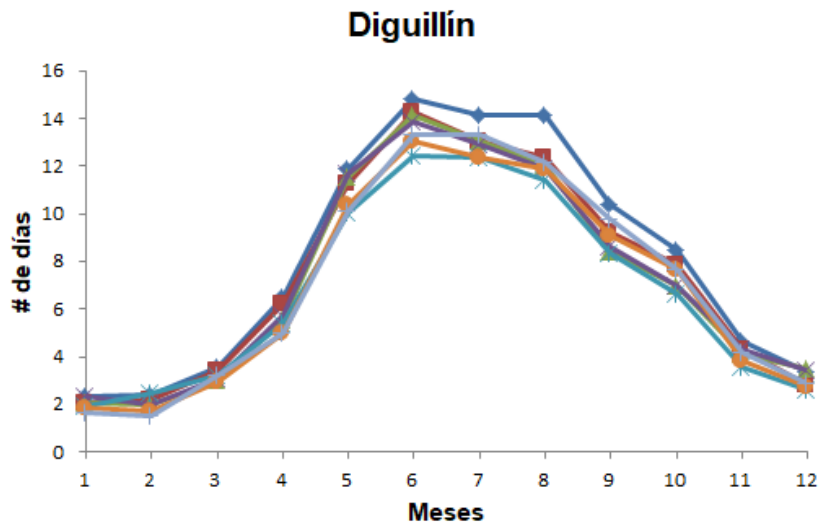
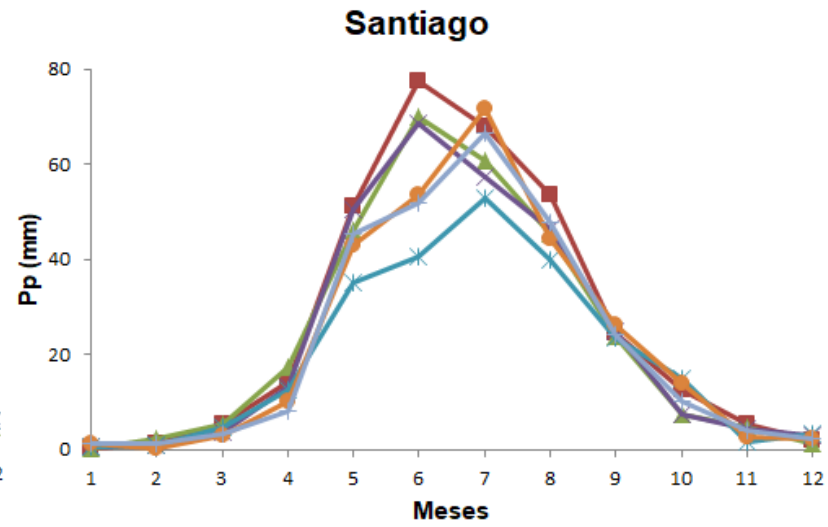
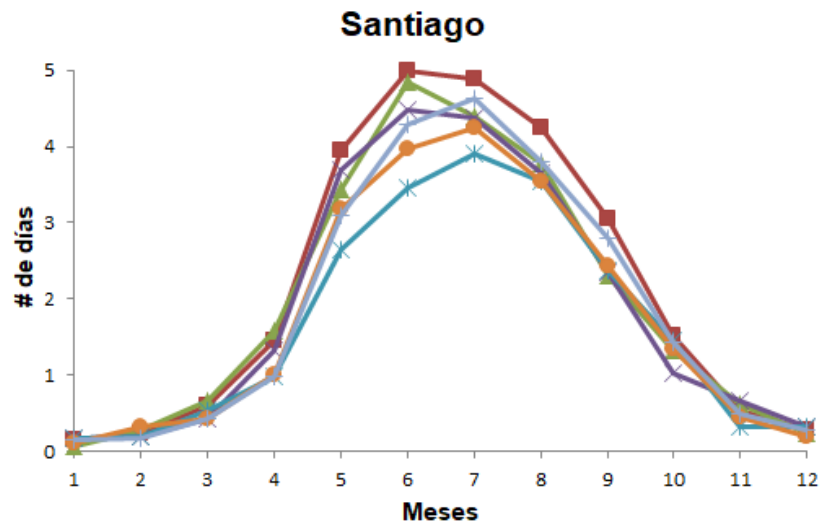
922
923
924
925
926
927
928
929
930
931



—era —obs —ls4 —ls16 —pf —pc —pc_c

932

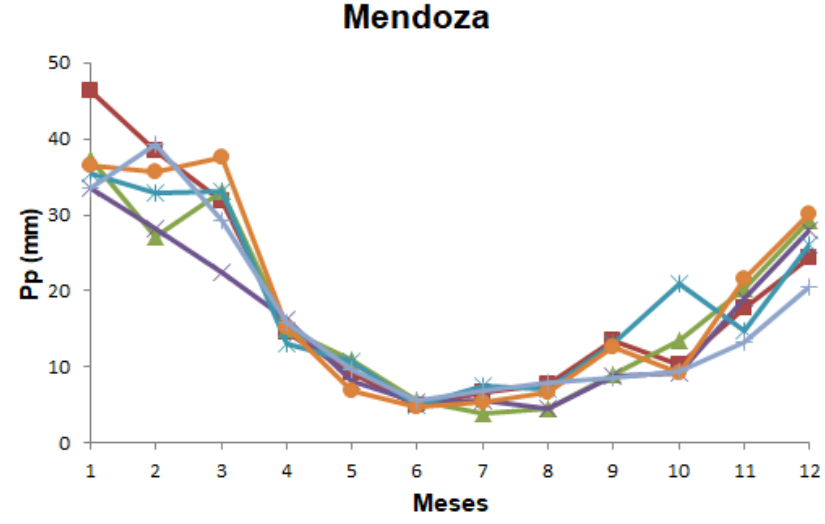

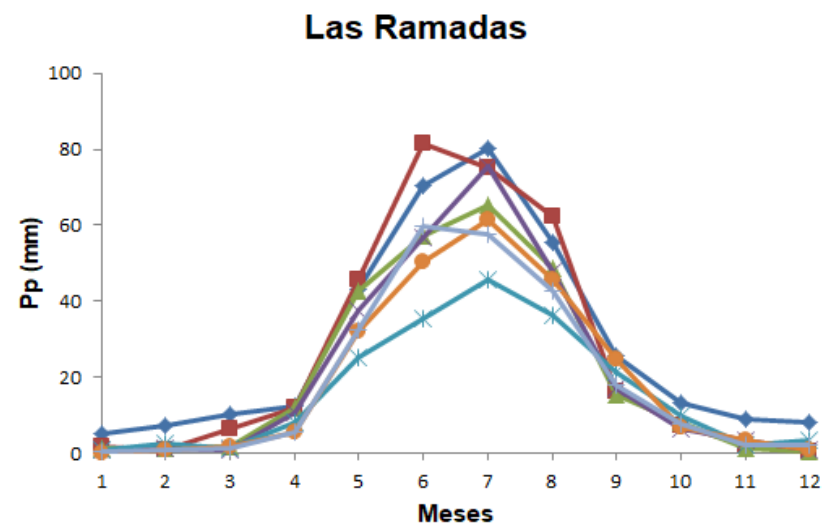
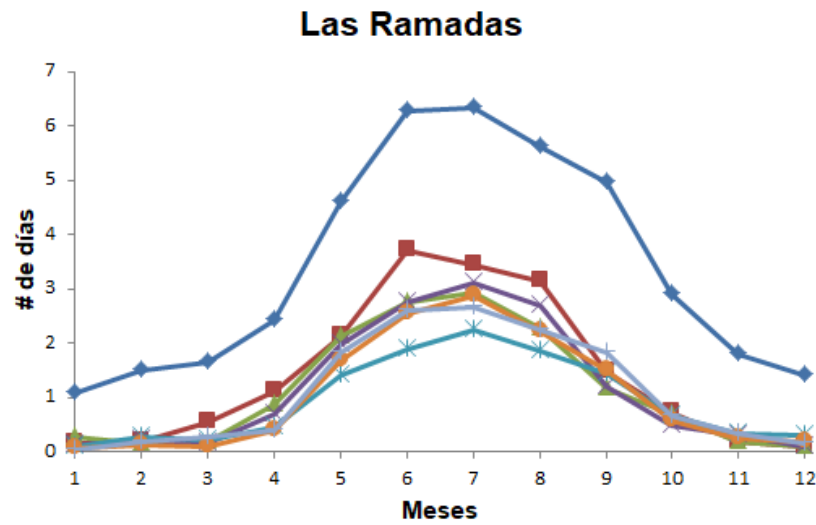
933 Anexo 1. Marcha anual de cantidad de días promedio con precipitaciones y precipitación media mensual para La Serena y Lago Peñuelas según figura 4.



era obs ls4 ls16 pf pc pc_c

934

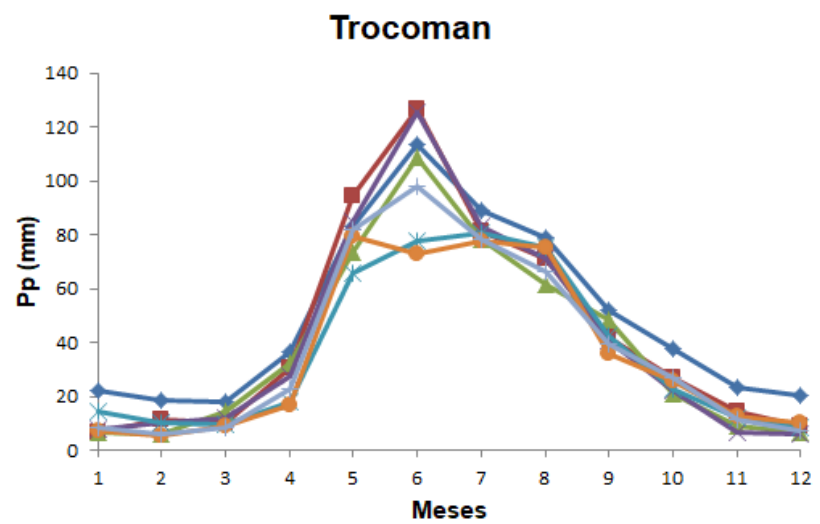
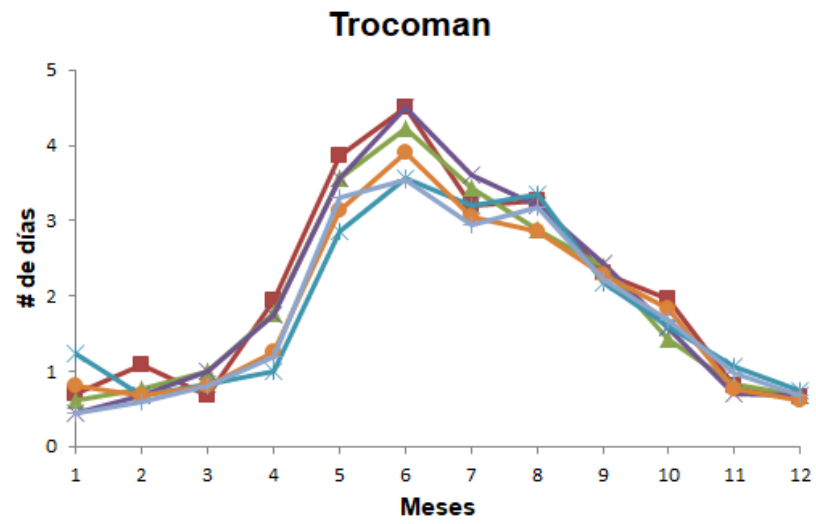
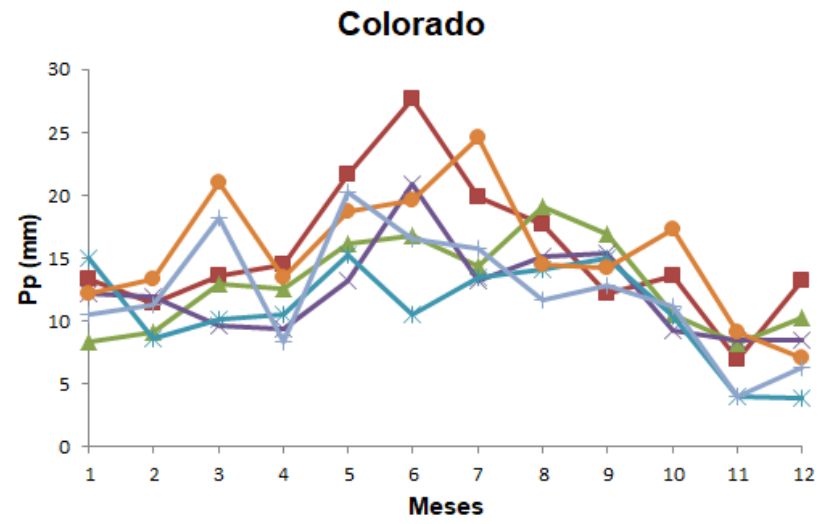
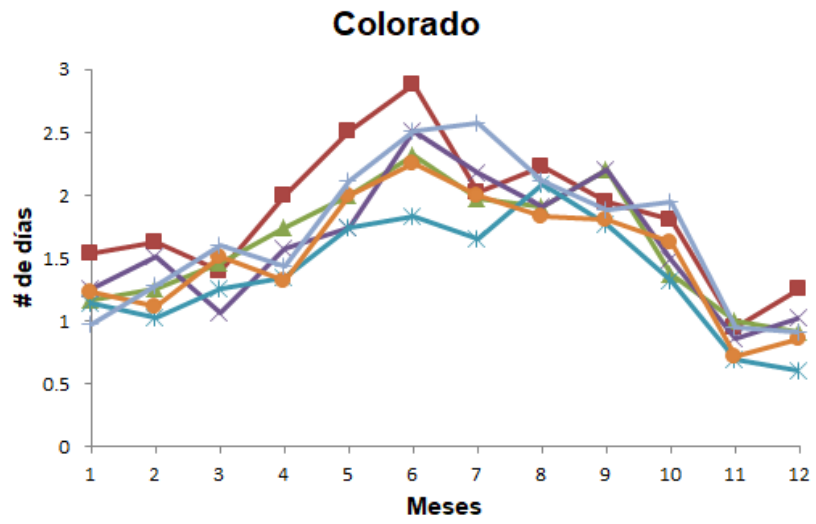
935 Anexo 2. Marcha anual de cantidad de días promedio con precipitaciones y precipitación media mensual para Santiago y Diguillín según figura 4.



era obs ls4 ls16 pf pc pc_c

936

937 Anexo 3. Marcha anual de cantidad de días promedio con precipitaciones y precipitación media mensual para Las Ramadas y Mendoza según figura 4.




—era —obs —ls4 —ls16 —pf —pc —pc_c


938

939 Anexo 4. Marcha anual de cantidad de días promedio con precipitaciones y precipitación media mensual para Colorado y Trocoman según figura 4.


La Serena




Lago Peñuelas



Santiago



Diguillín



—era —obs —ls4 —ls16 —pf —pc —pc_c

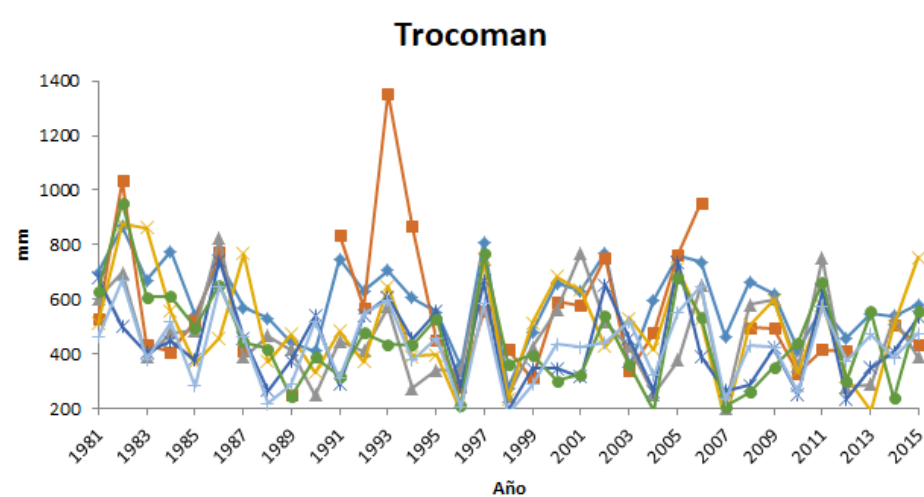
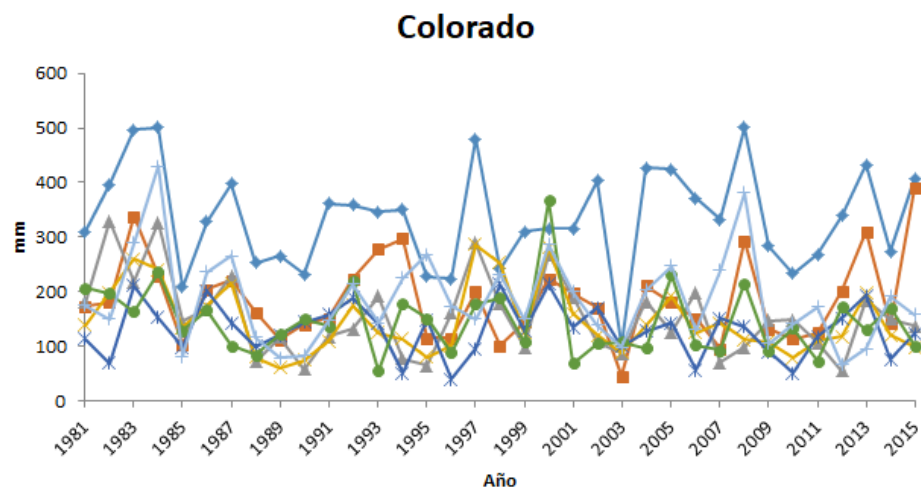


940

941 Anexo 5. Serie de acumulados totales anuales de precipitación para La Serena, Lago Peñuelas, Santiago y Diguillín según figura 7.

942

943

944



era obs ls4 ls16 pf pc pc_c

945

946 Anexo 6. Serie de acumulados totales anuales de precipitación para Las Ramadas, Mendoza, Colorado y Trocoman según figura 7.

947