

EVALUACIÓN DEL MÉTODO DE ANÁLOGOS PARA LA SIMULACIÓN DE LA PRECIPITACIÓN DIARIA EN UNA REGIÓN DE OROGRAFÍA COMPLEJA

Federico Gomez^{1,2}, María Laura Bettolli^{2,3,4}

¹Instituto Argentino de Nivología, Glaciología y Ciencias Ambientales, CONICET CCT Mendoza,
Argentina

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

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

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

(Manuscrito recibido el 17 de noviembre de 2023, en su versión final el 22 de febrero de 2024)

RESUMEN

Los Modelos Climáticos Globales (GCM) son la principal herramienta disponible para realizar predicciones sobre el clima en escenarios futuros, sin embargo, los mismos presentan un desempeño bajo para reproducir el clima local debido a su resolución espacial limitada. Esta característica se acentúa en regiones de orografía compleja. En el presente trabajo, se exploró la posibilidad de añadir valor agregado al modelado de la precipitación diaria a través de un método estadístico de reducción de escala (downscaling) en la región de los Andes Centrales. Se utilizó la precipitación diaria de 83 estaciones de la región durante el periodo 1981-2015 para calibrar el método de análogos utilizando el reanálisis ERA-Interim. Las series construidas a partir de los modelos de downscaling estadístico mostraron resultados más fidedignos en comparación con datos crudos del reanálisis, especialmente en el cálculo de valores medios y de estadísticos de escala diaria. En líneas generales, los modelos basados en la información de predictores atmosféricos locales obtuvieron un mejor desempeño que los constituidos utilizando la información de gran escala simplificada en base a un análisis de componentes principales. El desempeño de los modelos de downscaling a lo largo del dominio no fue uniforme, obteniéndose mejores resultados en las estaciones chilenas del sector sur. Esto posiblemente fue debido a que el forzante sinóptico dominante es bien capturado por los modelos de downscaling. Los distintos aspectos temporales de la variabilidad de la precipitación (intraanual, interanual y tendencias de largo plazo) fueron hábilmente reproducidos por los modelos estadísticos.

Palabras clave: Downscaling estadístico, ERA-Interim, Andes Centrales, Argentina, Chile.

EVALUATION OF THE ANALOG METHOD FOR DAILY PRECIPITATION SIMULATION IN A COMPLEX OROGRAPHY REGION

ABSTRACT

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

Keywords: Statistical downscaling, ERA-Interim, Central Andes, Argentina, Chile.

1. INTRODUCCIÓN

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

hidroeléctrica (Garreaud et al., 2017; Rivera et al., 2017).

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

(negativas) en las estaciones costeras de Chile durante episodios de El Niño (La Niña) (Montecinos et al., 2000).

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

Los Modelos Climáticos Globales (GCMs) son la principal herramienta disponible para realizar predicciones sobre el clima en escenarios futuros. Los GCMs están ideados para ser empleados en grandes escalas, de modo que presentan dificultades para recrear el ciclo hidrológico en zonas con orografía compleja (Chen y Dai, 2019). Los GCMs presentan dificultades al recrear climas locales por su resolución

espacial (Navarro-Racines et al., 2020). Estas limitaciones fueron encontradas sobre los AC por Zazulie et al. (2017), quienes analizaron el desempeño de 15 GCMs en reproducir las precipitaciones y temperaturas medias mensuales.

Las técnicas de reducción de escala (Downscaling, por su nombre en inglés) surgieron como una posibilidad para sortear las limitaciones de los GCMs. Estas técnicas se agrupan según los medios empleados para realizar este proceso, como técnicas estadísticas, dinámicas o una combinación de ambas. Las técnicas estadísticas (empleadas en este trabajo) se basan en relaciones empíricas entre predictores de gran escala y predictandos de escala local y/o regional (Wilby et al., 2002). En particular, desde el enfoque de perfect prognosis, estas relaciones empíricas se establecen en base a predictores de gran escala observados (usualmente representadas por los reanálisis) y predictandos de escala local (observaciones de precipitación) (Maraun et al. 2019). Una vez entrenados los modelos estadísticos en condiciones perfectas, se aplican a los predictores de gran escala simulados por los GCMs para obtener las simulaciones del clima local. Por ello, el entrenamiento y validación de los modelos estadísticos utilizando los reanálisis y las observaciones de las variables locales es un paso esencial para obtener simulaciones robustas.

A pesar de que estas técnicas han sido ampliamente utilizadas en otras regiones del mundo, su potencial no ha sido explorado en profundidad en Sudamérica y en particular, para simular la precipitación diaria y su variabilidad espacial y temporal en regiones de topografía compleja como los AC. En Chile, Araya-Osses et al. (2020) usaron datos de precipitación y temperatura diarias de 400 estaciones para entrenar una técnica de downscaling estadístico basada en el método de análogos. Los autores emplearon las relaciones empíricas halladas para realizar proyecciones de clima futuro. Bozkurt et al. (2018) aplicaron técnicas de

downscaling estadístico para corregir bias en los valores de precipitación diaria de 19 GCMs y proyectar escenarios hidroclimáticos futuros para el centro de Chile. Mutz et al. (2021) generaron modelos de downscaling estadístico en base a la técnica de regresión múltiple para simular la temperatura media mensual en 24 estaciones en los AC chilenos. En Argentina, Labraga (2010) utilizó métodos de downscaling basados en la regresión lineal múltiple para simular la precipitación mensual y logró reproducir las tendencias positivas encontradas en algunas estaciones de Cuyo en el periodo 1981-2001 y episodios extremos como el déficit pluvial registrado en dicha región en 1994 o las lluvias excepcionales de febrero de 1998. Balmaceda-Huarte y Bettolli (2022) evaluaron el desempeño de distintas técnicas de downscaling estadístico para simular las temperaturas máximas y mínimas diarias a lo largo de Argentina.

Dada la importancia de la variabilidad espacial y temporal de la precipitación en la región de los AC, surge la necesidad de contar con simulaciones climáticas con detalle regional para evaluar los cambios de la precipitación y su proyección futura en un contexto de cambio climático. Para ello, es necesario desarrollar técnicas estadísticas de downscaling y evaluar su potencial para reproducir las distintas características de la precipitación en una región de orografía compleja como la región de los AC. El objetivo de este trabajo fue evaluar la capacidad de una técnica estadística de downscaling para reproducir la precipitación diaria en la región cordillerana entre 28°S y 38°S, así como su variabilidad espacial y temporal.

2. DATOS Y METODOLOGÍA

2.1. Datos

Los predictandos empleados en este trabajo fueron los datos de precipitación diaria de 83 estaciones ubicadas entre los paralelos 28°S y 38°S y las longitudes 68°O y 73°O para el periodo

1981-2015 (Figura 1 y Tabla 1). Los datos de precipitación fueron provistos por el Servicio Meteorológico Nacional de Argentina (SMN), el Instituto Nacional de Tecnología Agropecuaria (INTA) y la Dirección de Recursos Hídricos de Argentina, y la Dirección General de Aguas y la Dirección Meteorológica de Chile.

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

Los campos medios diarios del reanálisis ERA-Interim (Dee et al., 2011) fueron utilizados como predictores en el dominio delimitado por 21°S-55°S y 55°O-90°O (Figura 1). ERA-Interim es un conjunto de reanálisis de observaciones producido por el European Center for Medium-Range Weather Forecasts (ECMWF) para numerosas variables atmosféricas que comprenden el periodo 1979-2019. El mismo posee 60 niveles verticales desde la superficie hasta 0,1hPa y una resolución horizontal de 0.75° x 0.75°. En el presente trabajo se utilizó el período entre 1981 y 2015 en una retícula de 2° x 2° con interpolación bilineal para reducir los costos computacionales. Las variables utilizadas fueron promedios diarios de altura geopotencial en 500 hPa (z500), viento (zonal y meridional) en 850 hPa (u850 y v850), temperatura del aire en 850 hPa y 700 hPa (t850 y t700), humedad específica en 850 hPa y 700 hPa (q850 y q700) y presión al nivel del mar (psl). Estas variables fueron seleccionadas en base a trabajos previos que estudiaron su influencia sobre la precipitación en los AC (Labraga, 2010; Viale y Núñez, 2011; Viale y

Tabla I: Datos de las estaciones utilizadas en el trabajo. En verde, las seleccionadas para mostrar resultados específicos.

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 Martín	-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

Tabla I continuación: Datos de las estaciones utilizadas en el trabajo. En verde, las seleccionadas para mostrar resultados específicos.

Número	Nombre	Longitud (°)	Latitud (°)	Altura (m)	Datos Faltantes (%)	Fuente
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	Potrerillos	-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

Garreaud, 2014). Asimismo, se consideraron también los acumulados diarios de precipitación en los puntos de enrejado más cercanos a las estaciones, con el fin de explorar el valor agregado de la reducción de escala (Tabla 2). Es importante destacar que la elección del reanálisis ERA-Interim para la calibración y

validación de los modelos estadísticos se basa en que es el reanálisis empleado por el programa Coordinated Regional Climate Downscaling Experiment (CORDEX) del World Climate Research Programme (Gutowski et al. 2016) para las simulaciones de evaluación de los modelos climáticos regionales y por lo tanto




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

facilita la evaluación comparativa de los modelos desarrollados para la representación del clima regional.

2.2. Metodología

El downscaling estadístico emplea relaciones conocidas entre la circulación de gran escala y la variable local de interés para construir modelos estadísticos que puedan traducir el impacto de las anomalías en los flujos de gran escala a variables locales (Zorita y von Storch, 1999). En este trabajo se utilizó el método de análogos para realizar las simulaciones, el cual fue utilizado en trabajos previos para reproducir la precipitación diaria (por ejemplo, Bettolli y Penalba, 2018; Maraun et al., 2019), y algunos trabajos recientes evaluaron su potencial como método de referencia en regiones

de orografía compleja (Horton y Brönnimann, 2018; Horton, 2021). El método de análogos se basa en la idea de que la repetición de ciertos patrones atmosféricos sobre una zona determinada dará como resultado condiciones meteorológicas similares (Bedia et al., 2019). La situación de gran escala del periodo histórico que más se asemeje a la que se quiere predecir será asignada como análogo a la misma.

La configuración de los predictores, es decir, la forma en que se incorporan al modelo, pueden tener influencia en los resultados. Por ello, se consideraron diferentes estrategias para incorporar la información. Por un lado, las influencias de las estructuras de gran escala en todo el dominio fueron sintetizadas a través del análisis de componentes principales (Wold et al., 1987) reteniendo el 90% de la

Tabla II: Variables del reanálisis utilizadas en el estudio.

Nombre	Variable	Altura	Unidades
z500	Altura geopotencial	500 hPa	$\text{m}^2 \text{s}^{-2}$
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

varianza. Los modelos que incorporaron los predictores de esta manera fueron indicados con la nomenclatura “pc” (Tabla 3). Por otro lado, se construyeron modelos considerando la influencia local de los predictores utilizando sólo $n=4$ o $n=16$ puntos de retícula más cercanos a cada estación meteorológica. Los modelos que incorporaron los predictores de esta manera fueron indicados con la nomenclatura “ls4” y “ls16” respectivamente (Tabla 3). Los modelos “ls4”, “ls16” y “pc” emplearon la información de las 8 variables seleccionadas como predictoras. El modelo “pc_c” es una versión simplificada de “pc”, empleando sólo las variables referidas a la circulación (“psl”, “z500”, “u850” y “v850”). El modelo “pf” se basa en los resultados hallados por Falvey y Garreaud (2007), quienes encontraron que el flujo zonal de humedad explica el 50 % de la varianza de la precipitación diaria en la zona central de Chile y hasta el 60 % de la varianza en este rubro en estaciones específicas. Teniendo en cuenta estos resultados, el modelo “pf” combina el análisis de componentes principales de las variables “u850” y “v850” más la variable “q700” utilizando la información de los 16 puntos de retícula más cercanos (Tabla 3).

Debido a la extensión temporal acotada de los datos observados, se eligió un proceso de cross-validation con k -folds (Singh y Lee, 2018) en lugar de periodos distintos de entrenamiento y validación. A efectos de este trabajo se eligieron 7 folds ($k=7$) de compuestos por 5 años de datos diarios cada uno, dispuestos de manera

Tabla III: Resumen de los modelos utilizados para realizar las simulaciones.

Modelo	ls16	ls4	pc	pc_c	pf
mssl	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		
X Predictores locales con $n=16$					
X Predictores locales con $n=4$					
X Análisis de componentes principales					

cronológica. La técnica de cross-validation consiste en tomar sucesivamente cada uno de los folds como el periodo a evaluar y emplear los restantes para calibrar el primero. Se ajusta un modelo para el periodo de calibración, se lo aplica al fold seleccionado y se evalúa su rendimiento. Este proceso se repite para todos los periodos que componen los datos del estudio.

Dado que el foco de este trabajo es el análisis de la representación de la variabilidad de la precipitación, los resultados de las simulaciones fueron sometidos a procesos de validación para diferentes escalas temporales: anual y estacional, interanual y diaria. En todos los casos se consideró como día con precipitación a aquel en el que se acumuló al menos 1 mm. Para sintetizar la información regional, se consideraron 8

estaciones representativas de distintas regiones climáticas incluidas en el dominio (indicadas en la Figura 1).

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

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

$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^n (\text{ppMod}_t - \text{ppObs}_t)^2}{n}} \quad (1)$$

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

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

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

donde index representa a R01 o P98Wet según corresponda.

Se evaluó la tasa de acierto de los modelos mediante el Critical Success Index (CSI) (Aniley et al., 2023). Este índice caracteriza el desempeño de las simulaciones a través

de un cociente entre la suma total de los aciertos (Hits, días con precipitación observada y modelada) y la suma de de los aciertos más los errores (Misses, días con precipitación observada no predicha por el modelo) y las falsas alarmas (False Alarms, días sin precipitación observada erróneamente calculados como día con precipitaciones por el modelo):

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

3. RESULTADOS

3.1. Caracterización climatológica de la precipitación en los Andes Centrales

En la Figura 2 se presentan los valores medios anuales observados de la precipitación e intensidad media en el período 1981-2015. Los valores se presentan en mm/día para facilitar su comparación entre ambos indicadores y entre regiones. Estos valores se obtuvieron realizando el cociente entre la precipitación total acumulada para el periodo en cada estación y la cantidad total de días (precipitación media diaria) o la cantidad de días con precipitaciones (intensidad media diaria). La precipitación media diaria presentó valores menores a 2 mm/día en casi toda la región excepto en las estaciones al sur de 35°S en Chile, donde se alcanzó un máximo de 5.75 mm/día (Figura 2 a). Sin embargo, la intensidad de las precipitaciones presentó una distribución espacial diferente con mayores valores en las estaciones chilenas (12-24 mm/día) que en las argentinas (6-11 mm/día) (Figura 2 b), enfatizando la influencia topográfica en la distribución espacial de la precipitación.

3.2. Validación de las simulaciones en escala anual y estacional

La precisión de los modelos para reproducir las precipitaciones medias anuales y estacionales se estudió mediante el bias relativo porcentual con respecto a los datos observados (Figura 3).




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

Los valores medios de los acumulados anuales de precipitación muestran un gradiente de crecimiento hacia el sur y el oeste (Figura 3 a). La región del dominio con mayor acumulado promedio es la Patagonia chilena (al sur de 35°S) con registros que alcanzan los 2098 mm. Hacia el norte, los acumulados promedios se reducen junto a la influencia de los storm tracks, con valores medios entre 300 y 600 mm en el centro de Chile y menores a 300 mm en el norte. En el lado argentino, se observan acumulados entre 100 y 400 mm en el centro y norte del dominio y entre 200 y 900 mm al sur. Esta distribución espacial de los acumulados anuales de precipitación se mantiene a lo largo de las estaciones de invierno y de transición (Figura 3 c, d y e), siendo el verano la estación que presenta los mayores acumulados en el centro y norte del sector argentino (con valores que alcanzan entre 80 y 140 mm, Figura 3 b). En el resto del dominio este periodo del año es el más seco con precipitaciones medias entre 40 y 100 mm al sur y despreciables en el centro y norte de Chile.

La evaluación del desempeño de ERA-Interim indica que el reanálisis presenta grandes sobreestimaciones de precipitaciones para casi toda la región y todas las épocas del año, excepto en la región del centro y sur de Chile

donde se observan subestimaciones moderadas.

Los modelos de downscaling presentan mejores rendimientos al reproducir los valores medios de precipitación anual y estacional en comparación con ERA-Interim. A nivel anual, los resultados de los modelos evidencian (salvo contadas excepciones) bias negativos con respecto a los datos observados. Estos errores son menores al 20 % en la mayoría de las estaciones y modelos, siendo el extremo norte de Chile la única región con subestimaciones más pronunciadas (entre -20 % y -40 %). Los modelos basados en predictores locales (“ls4” y “ls16”) muestran un mejor desempeño a nivel anual con respecto a los construidos a partir del análisis de componentes principales. El modelo “pf” tiene los bias más pronunciados.

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

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




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 de precipitación media de los modelos y los datos observados en %. (a) Anual (b) Verano (c) Otoño (d) Invierno (e) Primavera.

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

Los modelos de downscaling recrean correctamente la marcha anual en La Serena (Figura 4 a) aunque subestiman los acumulados para el otoño e invierno. Los modelos “ls4” y “ls16” simulan correctamente el máximo de precipitación en julio, mientras que los modelos basados en análisis de componentes principales (“pc”, “pc.c” y “pf”) calculan un máximo tardío en agosto. En las otras estaciones de Chile; Lago Peñuelas, Santiago y Diguillín (Figura 4 b, c y d), los modelos basados en predictores locales (“ls4” y “ls16”) logran replicar la marcha anual con mayor exactitud que los basados en análisis de componentes principales. Los datos observados indican que este grupo de estaciones tiene su máximo de precipitación en junio, lo cual es correctamente simulado por “ls4” y “ls16” mientras que los demás modelos calculan dicho máximo en julio. Los resultados crudos de ERA-Interim son los de menor precisión. Para la estación Santiago, los valores de ERA-Interim quedan fuera de escala, y en Lago Peñuelas combinan una subestimación de los acumulados promedios junto con una sobreestimación de la cantidad de días con precipitaciones. En Las Ramadas (1380 msnm), los modelos simulan correctamente la marcha anual de la precipitación pero calculan el máximo en julio en lugar de junio (Figura 4 e).

Los modelos muestran menor tasa de acierto y mayores discrepancias entre sí para las estaciones argentinas (Colorado, Trocoman y Mendoza Aero). Esta situación puede guardar relación con las condiciones áridas y menor

estacionalidad de las precipitaciones. Los resultados del reanálisis ERA-Interim quedan fuera de la escala.

3.3. Variabilidad Temporal

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

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




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 (izquierda) y de precipitación media mensual (derecha, en mm) para las 8 estaciones de referencia: (a) La Serena (b) Lago Peñuelas (c) Santiago (d) Diguillín (e) Las Ramadas (f) Mendoza Aero (g) Colorado (h) Trocoman. Se ofrecen imágenes de mayor resolución en el Anexo.




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

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

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

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

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

mayoría de las estaciones ubicadas en gran parte del sector argentino del dominio.

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

Los valores de correlación correspondientes al otoño son significativos estadísticamente para los modelos de downscaling basados en predictores locales “ls4” y “ls16”, y ERA-Interim en las estaciones chilenas (Figura 6 c), mientras que el resto de los modelos falla al recrear este aspecto para las estaciones en el sector norte del dominio. En el sector argentino, ERA-Interim y el modelo “ls16” son los que presentan el mejor desempeño con valores significativos de correlación en la mayoría de las estaciones. En la primavera (Figura 6 e), los modelos tienden a tener un desempeño similar al otoño.

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

A modo ilustrativo se muestran las series de acumulados anuales en las 8 estaciones de referencia obtenidas con los datos observados y modelados. En Chile, los modelos de downscaling y ERA-Interim logran recrear los extremos locales, principalmente en las estaciones del centro y sur (Santiago, Lago Peñuelas y Diguillín). Un ejemplo de esto son las situaciones de acumulado anual excepcionalmente altos para 1997 y bajos para 1996 y 1998. En las estaciones argentinas, los modelos tienen menos precisión que en Chile y valores más dispares entre sí. Se observan




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

casos puntuales donde tanto los modelos de downscaling como ERA-Interim no logran recrear periodos extremos de déficit y exceso de precipitación, como por ejemplo, los acumulados récord registrados en 1993 y 1994 en Trocoman (Figura 7 h) y en 1984 y 2001 en Mendoza (Figura 7 f). Es importante destacar que si bien ERA-Interim muestra las mayores correlaciones interanuales (Figura 6 a), presenta grandes sobreestimaciones y/o subestimaciones de los acumulados anuales en concordancia con lo observado en la Figura 3.

3.4. Validación de las simulaciones en escala diaria

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

Los principales contrastes en los resultados se observan al comparar los valores de ERA-Interim con los de los modelos de downscaling (Figura 8). En ese sentido a nivel anual (Figura 8 a), en Argentina al norte de 35°S, ERA-Interim obtiene valores de RMSE notablemente más altos que los obtenidos por los modelos con valores de hasta 30 mm. Esto puede guardar relación con la sobreestimación de las precipitaciones por parte del reanálisis en la región (Figura 3). El comportamiento inverso se halla en las estaciones argentinas al sur de 35°S, donde ERA-Interim tiene un mejor desempeño que los modelos de downscaling. Los valores de RMSE de las estaciones chilenas no observan diferencias entre el reanálisis y los modelos.

En verano (Figura 8 b), se destacan los errores calculados en Cuyo por el reanálisis (entre 15 y 44 mm) con respecto a los de los modelos (entre 8 y 20 mm). Para el invierno y el otoño, no se distinguen diferencias notables entre los

desempeños de ERA-Interim y los modelos de downscaling (Figura 8 c y d). Se destacan las excepciones puntuales de Pichi Neuquén, Llui-Llui Embalse y Lago Peñuelas que tienen valores de RMSE notablemente más altos. La primavera es la estación donde se hallan los menores valores de RMSE, siendo menores a 24 mm para todas las estaciones excepto Pichi Neuquén y Lago Peñuelas (Figura 8 e). Al igual que en el verano y otoño, ERA-Interim obtuvo valores de RMSE mayores que los modelos al norte de 35°S en Argentina.

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

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

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




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 (f) Mendoza Aero (g) Colorado (h) Trocoman. Se ofrecen imágenes de mayor resolución en el Anexo.




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




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.

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

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

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

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

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

El Critical Success Index (CSI) permite evaluar el desempeño de los modelos mediante su relación entre los días con precipitación predichos correctamente y la suma entre estos aciertos y días donde los modelos fallaron (Figura 11). A nivel anual (Figura 11 a) y estacional (Figura 11 b c d e), todos los modelos muestran valores de CSI mayores en las estaciones chilenas en comparación con las argentinas, y un aumento de los valores hacia el sur. Los modelos de downscaling obtienen mayores CSI para las estaciones chilenas en comparación con ERA-Interim, y a su vez los modelos basados en predictores locales muestran un mejor desempeño que los de análisis de componentes principales. En las estaciones argentinas, los resultados son pobres con valores menores a 0.25 salvo contadas excepciones. La estación con el peor desempeño es el verano (Figura 11 b) con valores por debajo de 0.2 para todos los modelos y estaciones, excepto para los modelos de downscaling al sur de 35°S en Chile; mientras que los mejores resultados se hallan en invierno (Figura 11 d), con valores que superaron 0.5 en la mayoría de las estaciones chilenas en consonancia con la estación húmeda de dicho país.

4. CONCLUSIONES

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




Figura 10: Índice P98Wet expresado como el ratio del valor del percentil 98 teniendo en cuenta solo los días con precipitación ≥ 1 mm con respecto a los datos observados. (a) Anual (b) Verano (c) Otoño (d) Invierno (e) Primavera.




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

el rendimiento de los modelos para reproducir los datos observados.

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

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

Los modelos evidencian una subestimación generalizada del índice R01 (Figura 8) y de la precipitación media anual (Figura 3) que está relacionada con la baja predictibilidad de

la precipitación diaria a nivel local empleando solo forzantes de gran escala. Con respecto a los extremos de precipitación, analizados a través del índice P98Wet (Figura 9), los modelos tienden a reproducirlo con habilidad excepto en la región árida del sector chileno donde la escasez de precipitaciones genera resultados con importantes diferencias entre estaciones cercanas en el cálculo del índice, ya que el contexto magnifica los errores de los modelos a la hora de cuantificarlos.

Los modelos muestran ciertas discrepancias en su desempeño entre sí, lo que representa una fuente de incertidumbre en las simulaciones. En este sentido, se encuentran resultados más fidedignos en las simulaciones que incluyen las 8 variables predictoras utilizadas en la reducción de escala en comparación con las que emplean sólo una parte de las mismas. Esto coincide con los resultados hallados por Horton y Brönnimann (2018), quienes encontraron que los modelos de downscaling que incluyeron múltiples variables tuvieron mejores desempeños a la hora de simular la precipitación diaria en una región de orografía compleja en comparación con los modelos que incluyeron una sola. Asimismo, se observan también mejores resultados por parte de los modelos basados en predictores locales (en especial "Is16") con respecto a los fundados en el análisis de componentes principales. Estos últimos consideran la influencia más generalizada de la estructura espacial de los predictores probablemente suavizando los aspectos más locales que influyen sobre la precipitación. Al respecto, Bettolli y Penalba (2018) y Olmo y Bettolli (2021) observaron este mismo comportamiento utilizando incluso otras técnicas estadísticas para la simulación de la precipitación diaria en la región Pampeana argentina y del sudeste de Sudamérica.

El desempeño de los modelos a lo largo del dominio no fue uniforme, sino que tanto ERA-Interim como los modelos de downscaling obtuvieron mejores resultados en las estaciones chilenas ubicadas al sur del dominio que en

el sector argentino. Esto está posiblemente asociado a que el forzante más relevante de la precipitación en el sector chileno es la actividad sinóptica, y estas estructuras son hábilmente capturadas por el método de análogos. Estos resultados son congruentes con lo encontrado por Bettolli y Penalba (2018) para la precipitación en la región pampeana durante el invierno y Timbal et al. (2004) para la región oeste de Francia. Consistentemente, las dificultades para simular la precipitación diaria en las estaciones argentinas se desprenden de la naturaleza mayormente convectiva de las precipitaciones estivales junto con la presencia de fenómenos locales, evidenciando la necesidad de incluir forzantes de menor escala a los modelos de downscaling. Sin embargo, Horton y Brönnimann (2018) emplearon el método de análogos para reproducir la precipitación diaria mediante modelos de downscaling y concluyeron que el valor agregado por resoluciones de los predictores atmosféricos mayores a 1° es despreciable.

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

Este trabajo sienta las bases de la evaluación de técnicas de downscaling para la precipitación diaria en regiones de topografía compleja. La técnica desarrollada aquí puede ser tomada como punto de referencia o benchmark para la comparación futura con métodos más complejos del estado del arte. En ese sentido, es relevante

explorar otras técnicas de downscaling como por ejemplo aquellas que incorporan machine learning en escenarios similares a los descritos en este trabajo.

ANEXO. Las Figuras A.1, A.2, A.3, A.4, A.5 y A.6 complementan la información de las Figuras 4 y 7.

REFERENCIAS

- Aniley, E.; Gashaw, T.; Abraham, T.; Demessie, S.F.; Bayabil, H.K.; Worqlul, A.W.; van Oel, P.R.; Dile, Y.T.; Chukalla, A.D.; Hailelassie A.; Wubaye, G.B.; 2023: Evaluating the performances of gridded satellite/reanalysis products in representing the rainfall climatology of Ethiopia, *Geocarto International*, 38:1, 2278329. <https://doi.org/10.1080/10106049.2023.2278329>
- Araneo, D. C., Compagnucci, R. H.; 2008: Atmospheric circulation features associated to Argentinean Andean rivers discharge variability, *Geophys. Res. Lett.*, 35, L01805 <https://doi.org/10.1029/2007GL032427>.
- Araneo, D.; Villalba, R.; 2014: Variability in the annual cycle of the Río Atuel streamflows and its relationship with tropospheric circulation, *Int. J. Climatol.* <https://doi.org/10.1002/joc.4185>
- Araya-Osses, D.; Casanueva, A.; Román-Figueroa, C.; Uribe, J.M.; Paneque, M.; 2020: Climate change projections of temperature and precipitation in Chile based on statistical downscaling, *Climate Dynamics* (2020) 54:4309–4330. <https://doi.org/10.1007/s00382-020-05231-4>
- 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. <http://doi.org/10.1002/joc.7142>
- Balmaceda-Huarte, R.; Bettolli, M.L.; 2022: Assessing statistical downscaling in Argentina: Daily maximum and minimum temperatures, *Int J Climatol.*




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




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




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




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




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




Figura A.6. Serie de acumulados totales anuales de precipitación para Las Ramadas, Mendoza, Colorado y Trocman según figura 7.

2022;42:8423–8445. <https://doi.org/10.1002/joc.7733>

Basist, A., Bell, G.D., Meentemeyer, V., 1994: Statistical Relationships between Topography and Precipitation Patterns, *Journal of Climate* 7:1305-1315. [https://doi.org/10.1175/1520-0442\(1994\)007\(1305:SRBTAP\)2.0.CO;2](https://doi.org/10.1175/1520-0442(1994)007(1305:SRBTAP)2.0.CO;2)

Bedía, J., Baño-Medina, J., Legasa, M.N., Iturbide, M., Manzanar, R., Herrera, S., Casanueva, A., San-Martín, D., Cofiño, A.S., Gutiérrez, J.M., 2019: Statistical downscaling with the downscaleR package: Contribution to the VALUE intercomparison experiment. <https://doi.org/10.5194/gmd-2019-224>
Bettoli, M.L. y Penalba, O.C., 2018: Statistical

- downscaling of daily precipitation and temperatures in southern La Plata Basin, *International Journal of Climatology* 2018:1-18. <https://doi.org/10.1002/joc.5531>
- Boisier, J.P.; Alvarez-Garreton, C.; Cordero, R.; Damiani, A.; Gallardo, L.; Garreaud, R.D.; Lambert, F.; Ramallo, C.; Rojas, M.; Rondanelli, R.; 2018: Anthropogenic drying in central-southern Chile evidenced by long-term observations and climate model simulations, *Elem Sci Anth*, 6: 74. <https://doi.org/10.1525/elementa.328>
- Bonelli, S.; Vicuña, S.; Meza, F.J.; Gironás, J.; Barton, J.; 2014: Incorporating climate change adaptation strategies in urban water supply planning: the case of central Chile, *Journal of Water and Climate Change* 05.3:357-376. <https://doi.org/10.2166/wcc.2014.037>
- Bozkurt, D.; Rojas, M.; Boisier, J.P.; Valdivieso, J.; 2018: Projected hydroclimate changes over Andean basins in central Chile from downscaled CMIP5 models under the low and high emission scenarios, *Climatic Change* (2018) 150:131–147. <https://doi.org/10.1007/s10584-018-2246-7>
- Bravo, C.; Loriaux, T.; Rivera, A.; Brock, B. W.; 2017: Assessing glacier melt contribution to streamflow at Universidad Glacier, central Andes of Chile, *Hydrol. Earth Syst. Sci.*, 21, 3249–3266. <https://doi.org/10.5194/hess-21-3249-2017>
- Chen, D. y Dai, A.; 2019: Precipitation Characteristics in the Community Atmosphere Model and Their Dependence on Model Physics and Resolution, *Journal of Advances in Modeling Earth Systems*, 11, 2352–2374. <https://doi.org/10.1029/2018MS001536>
- Dee, DP; Uppala, SM; Simmons, AJ; Berrisford, P; Poli, P; Kobayashi, S; Andrae, U; Balmaseda, MA; Balsamo, G; Bauer, P; Bechtold, P; Beljaars, ACM; van de Berg, L; Bidlot, J; Bormann, N; Delsol, C; Dragani, R; Fuentes, M; Geer, AJ; Haimberger, L; Healy, SB; Hersbach, H; Hólm, EV; Isaksen, L; Kállberg, P; Köhler, M; Matricardi, M; McNally, AP; Monge-Sanz, BM; Morcrette, JJ; Park, BK; Peubey, C; de Rosnay, P; Tavolato, C; Thépaut, JN; Vitart, F; 2011: The ERA-Interim reanalysis: configuration and performance of the data assimilation system. *Q J Roy Meteorol Soc* 137:553–597. <https://doi.org/10.1002/qj.828>
- Falvey, M., Garreaud, R., 2007: Wintertime Precipitation Episodes in Central Chile: Associated Meteorological Conditions and Orographic Influences, *Journal of Hydrometeorology* 8:171-193. <https://doi.org/10.1175/JHM562.1>
- Fuentealba, M.; Bahamóndez, C.; Sarricolea, P.; Meseguer-Ruiz, O.; Latorre, C.; 2021: The 2010–2020 'megadrought' drives reduction in lake surface area in the Andes of central Chile (32° - 36°S), *Journal of Hydrology: Regional Studies* 38. <https://doi.org/10.1016/j.ejrh.2021.100952>
- Garreaud R.D., 2009: The Andes climate and weather, *Advances in Geosciences* 7:1-9. <http://doi.org/10.5194/adgeo-22-3-2009>
- Garreaud, R.; Álvarez-Garreton, C.; Barichivich, J.; Boisier, J.P.; Christie, D.; Galleguillos, M.; LeQuesne, C.; McPhee, J.; Zambrano-Bigiarini, M.; 2017: The 2010–2015 megadrought in central Chile: impacts on regional hydroclimate and vegetation, *Hydrol. Earth Syst. Sci.*, 21, 6307–6327, 2017. <https://doi.org/10.5194/hess-21-6307-2017>
- Garreaud, R.D; Boisier, J.P.; Rondanelli, R.; Montecinos, A.; Sepúlveda, H.; Veloso-Aguila, D.; 2019: The Central Chile Mega Drought (2010–2018): A climate dynamics perspective, *Int J Climatol.* 2020;40:421–439. <https://doi.org/10.1002/joc.6219>
- Gutowski, J.W.; Giorgi, F.; Timbal, B.; Frigon, A.; Jacob, D.; Kang, H.S.; Raghavan, K.; Lee, B.; Lennard, C.; Nikulin, G.; O'Rourke, E.; Rixen, M.; Solman, S.; Stephenson, T.; Tangang, F.; 2016: WCRP COordinated Regional Downscaling EXperiment (CORDEX): a diagnostic MIP for CMIP6. *Geosci Model Dev* 9(11):4087–4095. <https://doi.org/10.5194/gmd-9-4087-2016>
- Horton, P.; Brönnimann, S.; 2018: Impact

- of global atmospheric reanalyses on statistical precipitation downscaling, *Climate Dynamics*. <https://doi.org/10.1007/s00382-018-4442-6>
- Horton, P.; 2021: Analogue methods and ERA5: Benefits and pitfalls, *Int J Climatol*. 2022;42:4078–4096. <https://doi.org/10.1002/joc.7484>.
- INDEC, 2022: Censo nacional de población, hogares y viviendas 2022: resultados provisionales / 1a ed, ISBN 978-950-896-633-9.
- Instituto Nacional de Estadísticas, 2018: Síntesis de Resultados Censo 2017 de Chile. https://www.inec.gob.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
- Labraga, J.C., 2010: Statistical downscaling estimation of recent rainfall trends, in the eastern slope of the Andes mountain range in Argentina, *Theoretical and Applied Climatology* 99,287–302. <https://doi.org/10.1007/s00704-009-0145-6>.
- Maraun, D.; Huth, R.; Gutiérrez, J.M.; San Martín, D.; Dubrovsky, M.; Fischer, A.; Hertig, E.; Soares, P.M.M.; Bartholy, J.; Pongrácz, R.; Widmann, M.; Casado, M.J.; Ramos, P.; Bedia, J.; 2019: The VALUE perfect predictor experiment: Evaluation of temporal variability, *Int. J. Climatol*. 2017;1–33. <https://doi.org/10.1002/joc.5222>.
- 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* 13:746-758. [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)
- Müller, G. y Lovino, M.; 2023: Variability and Changes in Temperature, Precipitation and Snow in the Desaguadero-Salado-Chadileuvú-Curacó Basin, Argentina, *Climate* 2023, 11, 135. <https://doi.org/10.3390/cli11070135>
- Mutz, S.; Scherrer, S.; Muceniece, I.; Ehlers, T.; 2021: Twenty-first century regional temperature response in Chile based on empirical-statistical downscaling, *Climate Dynamics* (2021) 56:2881–2894. <https://doi.org/10.1007/s00382-020-05620-9>
- Navarro-Racines, C.; Tarapues, J.; Thornton, P.; Jarvis, A.; Ramirez-Villegas, J.; 2020: High-resolution and bias-corrected CMIP5 projections for climate change impact assessments, *Scientific Data* (2020) 7:7. <https://doi.org/10.1038/s41597-019-0343-8>
- Olmo, M., Bettolli M.L., 2021: Statistical downscaling of daily precipitation over southeastern South America: assessing the performance in extreme events, *International Journal of Climatology* 42(2),1283–1302. <https://doi.org/10.1002/joc.7303>
- Penalba, O. y Vargas, W.; 2004: Interdecadal and Interannual Variations of Annual and Extreme Precipitation over Central-Northeastern Argentina, *Int. J. Climatol*. 24: 1565–1580 (2004). <https://doi.org/10.1002/joc.1069>
- Rivera, J.A.; Araneo, D.; Penalba, O.; 2017: Threshold level approach for streamflow drought analysis in the Central Andes of Argentina: a climatological assessment, *Hydrological Sciences Journal*, 62:12, 1949-1964. <https://doi.org/10.1080/02626667.2017.1367095>
- Singh, V.P., Lee, T., 2018: Statistical Downscaling for Hydrological and Environmental Applications, 181 págs. <https://doi.org/10.1201/9780429459580>
- Timbal, B., Dufour, A., McAvaney, B., 2004: An estimate of future climate change for western France using a statistical downscaling technique. *Climate Dynamics*, 20, 807–823. <http://dx.doi.org/10.1007/s00382-002-0298-9>
- Viale, M., Garreaud, R., 2014: Summer Precipitation Events over the Western Slope of the Subtropical Andes, *Monthly Weather Review* 142:1074-1092. <https://doi.org/10.1175/MWR-D-13-00259.1>
- Viale, M., Nuñez, M.N., 2011: Climatology of Winter Orographic Precipitation over the Subtropical Central Andes and Associated Synoptic and Regional Characteristics, *Journal of Hydrometeorology* 12:481-507.

<https://doi.org/10.1175/2010JHM1284.1>.

Wilby, R.L., Dawson, C.W., Barrow, E.M., 2002: SDSM — a decision support tool for the assessment of regional climate change impacts, *Environmental Modelling & Software* 17:147–159. [https://doi.org/10.1016/S1364-8152\(01\)00060-3](https://doi.org/10.1016/S1364-8152(01)00060-3)

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

Wold, S., Esbensen, K., Geladi, P., 1987: Principal Component Analysis, *Chemometrics and Intelligent Laboratory Systems* 2:37-52. [https://doi.org/10.1016/0169-7439\(87\)80084-9](https://doi.org/10.1016/0169-7439(87)80084-9)

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

Zorita, E., von Storch, H., 1999: The Analog Method as a Simple Statistical Downscaling Technique: Comparison with More Complicated Methods, *Journal of Climate* 12:2474-2489. [https://doi.org/10.1175/1520-0442\(1999\)012%3C2474:TAMAAS%3E2.0.CO;2](https://doi.org/10.1175/1520-0442(1999)012%3C2474:TAMAAS%3E2.0.CO;2)