



UNIVERSIDAD DE CONCEPCIÓN  
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS  
DEPARTAMENTO DE FÍSICA

---

# **Downscaling estadístico de variables hidroclimáticas en el centro-sur de Chile: desarrollo y análisis de campos temporales mensuales y diarios en alta resolución**

---

*Tesis presentada a la Facultad de Ciencias Físicas y Matemáticas para optar al grado de  
Doctor en Ciencias Físicas*

Francisco Javier Alvial Vásquez

Profesor Guía: Dr. Rodrigo Abarca del Río

Marzo de 2025

Concepción, Chile

© 2025, Francisco Javier Alvial Vásquez

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento.

*Tantas veces, lágrimas de sangre derramé  
en este camino. Y al llegar al final,  
la primavera se desvanece.*

*Inspirado de Saigyō Hōshi (1118 – 1190).*



## *Agradecimientos*

A la Agencia Nacional de Investigación y Desarrollo (ANID) por el financiamiento otorgado a través de la beca de Doctorado Nacional 2022, folio 21212281.



# Resumen

A pesar de la importancia de la precipitación en el ciclo hidrológico y en diversos sectores como la agricultura, la gestión de recursos hídricos y la adaptación al cambio climático, su variabilidad física, temporal y espacial sigue representando un desafío para su simulación y proyección a escala local (Pham et al., 2021). En Chile, la interacción entre su compleja orografía, la influencia del océano Pacífico, la continentalidad y los vientos predominantes del oeste en el sur configuran un sistema climático único, lo que incrementa el desafío en la representación de esta variable (Sarricolea et al., 2017; Araya-Osses et al., 2020a; Martínez-Retureta et al., 2021).

Datos meteorológicos espaciales coherentes con la información observacional son fundamentales para varios campos científicos (Parra et al., 2004; Hijmans et al., 2005; Abatzoglou, 2013; Cannon et al., 2015b; Liu XiaoMang et al., 2017; Sun et al., 2018). Sin embargo, a pesar de la existencia de numerosos conjuntos de datos de precipitación a nivel mundial, la representación de su variabilidad espacial sigue siendo una limitante, especialmente en regiones con topografía compleja. En este contexto, los productos de precipitación en alta resolución ( $<1 \text{ km}$ ) son preferidos, ya que permiten capturar con mayor precisión la variabilidad ambiental que puede perderse a menor resolución.

Este estudio propone el desarrollo de una metodología integral de downscaling estadístico para estimar y analizar la variabilidad espacio-temporal de la precipitación en la zona centro-sur de Chile, entre las regiones de O'Higgins y Los Ríos. La investigación se organiza en dos enfoques principales que corresponden a los productos generados: (a) Generación de un conjunto de datos de precipitación mensual en alta resolución ( $800 \text{ m}$ ) para el período 2000-2011. Este producto se construye mediante la integración de múltiples fuentes de información: modelos numéricos regionales, datos satelitales, productos de reanálisis y observaciones in situ. Las correcciones sistemáticas aplicadas permiten reflejar de manera coherente la variabilidad climática de la región a escala mensual. (b) Desarrollo de un campo diario en alta resolución denominado DA-SDM ( $800 \text{ m}$ ), una metodología avanzada de downscaling estadístico específicamente diseñada para la estimación de eventos extremos diarios. Este enfoque utiliza información multifuente

y considera factores orográficos y dinámicos para capturar adecuadamente estos eventos extremos, demostrando su capacidad para reproducirlos durante el período de mayo a agosto de 2006. Además, se destaca su potencial de aplicación en otras regiones con características similares.

Los resultados de esta tesis proporcionan dos productos complementarios: (1) un conjunto de datos de precipitación mensual en alta resolución que captura la variabilidad climática regional; y (2) un campo diario DA-SDM que permite la evaluación detallada de eventos extremos diarios. La integración de múltiples fuentes de información y la coherencia con la realidad observacional proporcionan una base sólida para estudios hidrológicos, modelación climática y planificación de recursos hídricos.

# Abstract

Despite the fundamental importance of precipitation in the hydrological cycle and various sectors such as agriculture, water resource management, and climate change adaptation, its physical, temporal, and spatial variability remains a major challenge for accurate simulation and projection at local scales (Pham et al., 2021). In Chile, the complex interplay between orography, the influence of the Pacific Ocean, continentality, and the prevailing westerly winds in the south creates a distinctive climatic system that complicates the accurate representation of precipitation (Sarricolea et al., 2017; Araya-Osses et al., 2020a; Martínez-Retureta et al., 2021).

High-quality meteorological datasets that are consistent with observational data are essential for a wide range of scientific applications (Parra et al., 2004; Hijmans et al., 2005; Abatzoglou, 2013; Cannon et al., 2015b; Liu XiaoMang et al., 2017; Sun et al., 2018). However, despite the availability of numerous global precipitation datasets, accurately capturing the spatial variability of precipitation remains a critical limitation, particularly in regions with complex topography. In this context, high-resolution precipitation products ( $<1\text{ km}$ ) are preferred, as they provide a finer representation of environmental variability that would otherwise be missed at coarser resolutions.

This study presents a comprehensive statistical downscaling framework aimed at estimating and analyzing the spatio-temporal variability of precipitation across the south-central region of Chile, spanning from the O'Higgins to Los Ríos regions. The research is structured around two main objectives, each corresponding to a specific product: (a) Development of a high-resolution monthly precipitation dataset ( $800\text{ m}$ ) for the period 2000–2011. This dataset is generated through the integration of multiple information sources, including regional numerical models, satellite observations, reanalysis products, and in situ measurements. Systematic correction procedures are applied to ensure that the dataset accurately reflects the climatic variability of the region at a monthly scale.

(b) Generation of a high-resolution daily field referred to as DA-SDM ( $800\text{ m}$ ). This advanced statistical downscaling methodology is specifically designed to estimate and analyze daily extreme

precipitation events. By combining multi-source information and incorporating orographic and dynamic factors, DA-SDM effectively captures extreme events and demonstrates robust performance in reproducing these events during the period from May to August 2006. Additionally, this methodology offers the flexibility to be applied to other regions with similar characteristics.

The outcomes of this thesis consist of two complementary products: (1) a high-resolution monthly precipitation dataset that accurately captures regional climatic variability, and (2) a specialized high-resolution daily field (DA-SDM) tailored for the detailed assessment of extreme precipitation events. The integration of diverse data sources and the consistency achieved with observational records provide a reliable foundation for hydrological studies, climate modeling, and water resource management.

# Índice general

<b>Agradecimientos</b>	<b>v</b>
<b>Resumen</b>	<b>vii</b>
<b>Tabla de contenidos</b>	<b>xiii</b>
<b>Tabla de figuras</b>	<b>xvi</b>
<b>Listado de tablas</b>	<b>xvii</b>
<b>1 Marco General</b>	<b>1</b>
1.1 Introducción . . . . .	1
1.2 Reducción de escala (downscaling) . . . . .	6
1.2.1 Downscaling Dinámico . . . . .	9
1.2.2 Downscaling estadístico . . . . .	13
Weather Generators (WG) . . . . .	14
Model Outputs Statistics (MOS) . . . . .	15
Perfect Prognosis (PP) . . . . .	15
Técnicas estadísticas; enfoque PP . . . . .	16
1.3 Motivación . . . . .	17
1.4 Objetivos de Investigación . . . . .	18
1.5 Estructura de tesis . . . . .	19
<b>2 Artículo 1</b>	<b>21</b>
2.1 Introducción . . . . .	21
2.2 Área de estudio . . . . .	23
2.3 Metodología . . . . .	25
2.3.1 Base de datos instrumental . . . . .	25
2.3.2 Modelo atmosférico . . . . .	26

2.3.3	Conjuntos de datos cuadriculados globales . . . . .	28
2.3.4	Modelo dinámico topo-climático . . . . .	30
2.3.5	Análisis estadístico . . . . .	33
2.4	Resultados . . . . .	35
2.4.1	Modelo atmosférico . . . . .	35
2.4.2	Conjuntos globales de precipitación . . . . .	40
2.4.3	Modelo dinámico topo-climático de precipitación . . . . .	41
	Análisis de dominios regionales . . . . .	41
	Análisis de zonal y de cuencas . . . . .	42
2.5	Discusión y conclusión . . . . .	46
<b>3</b>	<b>Artículo 2</b> . . . . .	<b>51</b>
3.1	Introducción . . . . .	51
3.2	Área de estudio . . . . .	53
3.3	Metodología . . . . .	55
3.3.1	Datos de observación . . . . .	55
3.3.2	Conjunto global de datos . . . . .	55
	ERA5 . . . . .	55
	ERA5-Land . . . . .	56
	Productos PERSIANN . . . . .	56
	CHIRPS-2.0 . . . . .	58
	MSWEP-2.2 . . . . .	58
3.3.3	Modelo de reducción de escala estadística . . . . .	59
3.3.4	Análisis estadístico . . . . .	60
3.4	Resultados . . . . .	61
3.4.1	Rendimiento de DA-SDM . . . . .	62
	Evaluación del diagrama de Taylor . . . . .	62
	Rendimiento del modelo DA-SDM en las distintas métricas de evaluación . . . . .	64
	Predictores Clave de Precipitación en el Modelo DA-SDM . . . . .	65
3.4.2	Evaluación comparativa del modelo DA-SDM con CMORPH y TRMM . . . . .	66
	Rendimiento general en las categorías de elevación . . . . .	67
	Eficiencia de Nash-Sutcliffe (NSE) en todos los modelos . . . . .	68
	Tendencias de desempeño de la eficiencia Kling-Gupta (KGE) . . . . .	68
	Evaluación del índice Willmott ( $W_d$ ) . . . . .	69
3.5	Discusión . . . . .	69

	xiii
3.5.1 Rendimiento y validación del modelo . . . . .	69
3.5.2 Análisis comparativo con CMORPH y TRMM . . . . .	70
3.5.3 Coherencia con estudios previos . . . . .	70
3.5.4 Fortalezas y limitaciones del enfoque DA-SDM . . . . .	71
3.5.5 Futuras orientaciones de la investigación e implicancias socioeconómicas . . . . .	71
3.6 Conclusión . . . . .	72
<b>4 Conclusión General</b>	<b>75</b>
<b>Bibliografía</b>	<b>79</b>
<b>A Apéndice A</b>	<b>109</b>



# Índice de figuras

1.1	Distribución de estaciones de la red chilena de precipitación; 1900-2019. . . . .	2
1.2	Distribución de estaciones de la red chilena de temperatura; 1900-2019. . . . .	3
1.3	Porcentaje histórico de datos disponibles a nivel mensual de la red chilena; 1900-2019. . . . .	4
1.3	Porcentaje histórico de datos disponibles a nivel mensual de la red chilena; 1900-2019. . . . .	5
1.4	Esquema de un GCM acoplado; atmósfera-océano. . . . .	10
1.5	Comparativa entre la baja y alta resolución. En ella, se puede observar cómo la reducción de escala puede proporcionar información más detallada a escalas locales de la temperatura a dos metros. . . . .	11
1.6	Esquemización del downscaling dinámico utilizando las condiciones de borde e iniciales del modelo climático global . . . . .	12
2.1	Área de estudio sobre el centro-sur de Chile; división regional y cuencas fluviales. . . . .	23
2.1	Área de estudio sobre el centro-sur de Chile; división regional y cuencas fluviales. . . . .	24
2.2	Número de estaciones de precipitación en Chile utilizadas por el conjunto de datos del Centro Global de Climatología de Precipitaciones. . . . .	25
2.3	Visualización de los dominios utilizados en el modelo atmosférico WRF. . . . .	26
2.4	Variables topográficas utilizadas en el modelo topo-climático. . . . .	31
2.5	Descripción esquemática del desarrollo del modelo topoclimático dinámico. . . . .	32
2.6	Diagramas de Taylor correspondientes al desempeño de los modelos de investigación y pronóstico del tiempo una vez ajustados. . . . .	37
2.7	Diagramas de cajas correspondientes al ajuste del modelo de investigación y predicción meteorológica (WRF), una vez ajustado sobre las cuencas hidrográficas de la zona de estudio. . . . .	38
2.8	Diagramas de Taylor correspondientes al desempeño de los conjuntos cuadrícula-dos, una vez ajustado. . . . .	39

2.9	Diagramas de caja correspondientes al comportamiento de los conjuntos cuadriculados una vez ajustado. . . . .	40
2.10	Diagramas de caja correspondientes al ajuste del modelo dinámico topoclimático sobre los dominios en ejecución. . . . .	43
2.11	Diagramas de Taylor correspondientes al desempeño del modelo dinámico topoclimático en las cuencas de los ríos. . . . .	44
2.12	Diagramas de caja correspondientes al ajuste del modelo dinámico topo-climático sobre los dominios en ejecución. . . . .	45
2.13	Precipitación acumulada anual del modelo topo-climática. . . . .	46
3.1	Área de estudio: centro-sur de Chile. . . . .	53
3.1	Área de estudio: centro-sur de Chile. . . . .	54
3.2	Características orográficas del área de estudio. . . . .	60
3.2	Características orográficas del área de estudio. . . . .	61
3.3	Selección de estaciones de medición para el ajuste por Quantile Mapping. . . . .	63
3.4	Diagramas de cajas correspondientes al comportamiento de DA-SDM. . . . .	63
3.4	Diagramas de cajas correspondientes al comportamiento de DA-SDM. . . . .	64
3.5	Diagramas de cajas correspondientes al comportamiento del DA-SDM. . . . .	66
3.6	Mapas de calor correspondientes al comportamiento de los conjuntos de datos DA-SDM, CMORPH y TRMM . . . . .	67

# Índice de tablas

1.1	Resumen de las fuentes de sesgo e incertidumbre en los modelos climáticos globales.	13
2.1	Configuración principal de los dominios aplicados sobre el modelo y esquemas de parametrización seleccionados para la ejecución del modelo WRF. . . . .	27
2.2	Descripción de las 8 (quasi) global (sub) conjuntos grillados de precipitación utilizados. . . . .	29
2.3	Resumen estadístico del tipo de modelo topo-climático elegido por el ámbito político de cada región. . . . .	42
3.1	Descripción de las 9 cuadrículas de (sub)precipitación (cuasi)globales utilizadas en este estudio. . . . .	57
3.2	Clasificación de los eventos de lluvia en función de su intensidad diaria $i$ . . . . .	59
3.3	Métricas de evaluación de precisión. . . . .	62



## Capítulo 1

# Marco General

### 1.1 Introducción

El sistema climático es impulsado por fuerzas dinámicas y determinado por procesos complejos como las interacciones entre la esfera terrestre en diferentes escalas espacio-temporales (Kreienkamp et al., 2020). En este sentido, los modelos Climáticos Globales (p. ej. Miyamoto et al. 2013; Klocke et al. 2017) y modelos regionales (p. ej. Prein et al. 2015; Kendon et al. 2017; Leutwyler et al. 2017; Fuhrer et al. 2018), constituyen la principal herramienta para analizar los cambios potenciales del sistema climático. No obstante, si bien sus salidas pueden lograr una resolución a escala kilométrica, hay una falta de datos de observación terrestre para verificar los resultados del modelo y estudiar el tiempo y el clima a esta resolución (Fuchsberger et al., 2021).

Si bien la cantidad de variables hidro-climáticas para la construcción de estudios de impacto son a menudo variadas. Existen dos variables hidro-climáticas fundamentales utilizadas como entradas en todos los modelos; la temperatura y la precipitación (Abdollahipour et al., 2022; Sigalla et al., 2023; Dorjsuren et al., 2024). En este sentido, y focalizandonos en la precipitación, esta juega un rol fundamental que va desde su papel en el ciclo hidrológico y los procesos ecosistémicos hasta su importancia como factor en la producción agrícola y el bienestar humano (Patz et al., 2005; Barrios et al., 2010; Skofronick-Jackson et al., 2018; Dlamini et al., 2024); razón fundamental para que esta variable hidro-climática se capture de manera confiable y esté disponible tanto espacial como temporalmente. Comúnmente, en Europa, las redes meteorológicas cubren distancias de 10 *km* o más (Wüest et al., 2010). Mientras, en escalas inferiores la mayoría de estaciones operan en un entorno tipo campaña; esto es, periodos de observación cortos o centrados en la escala subkilométrica (Moore et al., 2000; Jensen et al., 2005; Ciach et al., 2006; Fuchsberger

et al., 2021).

En Chile, la red meteorológica presenta una distribución desigual, con una mayor concentración de estaciones en la zona central y una cobertura significativamente menor en el norte y sur del país. Las Figuras (1.1) y (1.2) muestran la distribución longitudinal y latitudinal de las estaciones de precipitación y temperatura en relación con la altura (*hgt*). Esta distribución irregular genera vacíos de información en zonas clave, afectando la capacidad de monitorear adecuadamente la variabilidad climática. En particular, la escasez de estaciones en regiones extremas dificulta la detección de cambios en los patrones de precipitación y temperatura, la modelación climática de alta resolución y la evaluación de eventos extremos. Además, en áreas de gran altitud, la falta de observaciones limita el entendimiento de procesos atmosféricos fundamentales, como la acumulación de agua en cuencas y el impacto del cambio climático en ecosistemas de montaña.

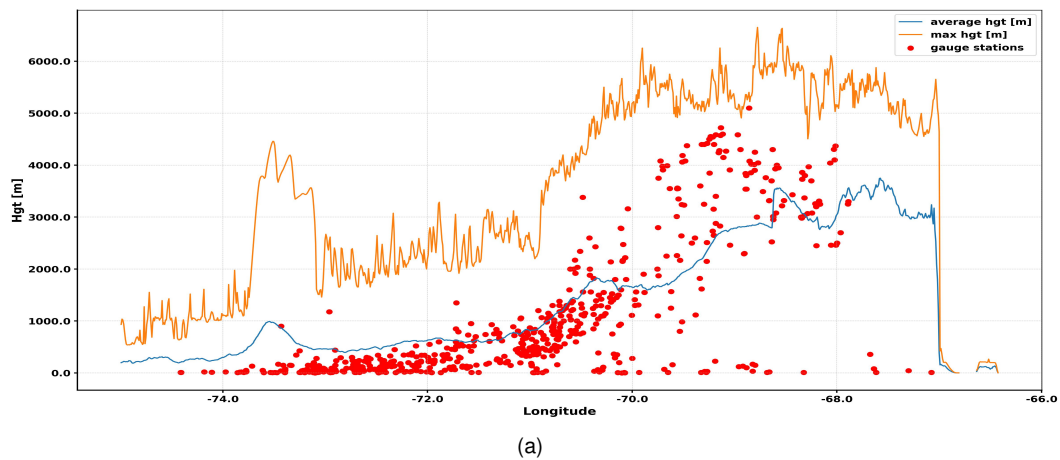
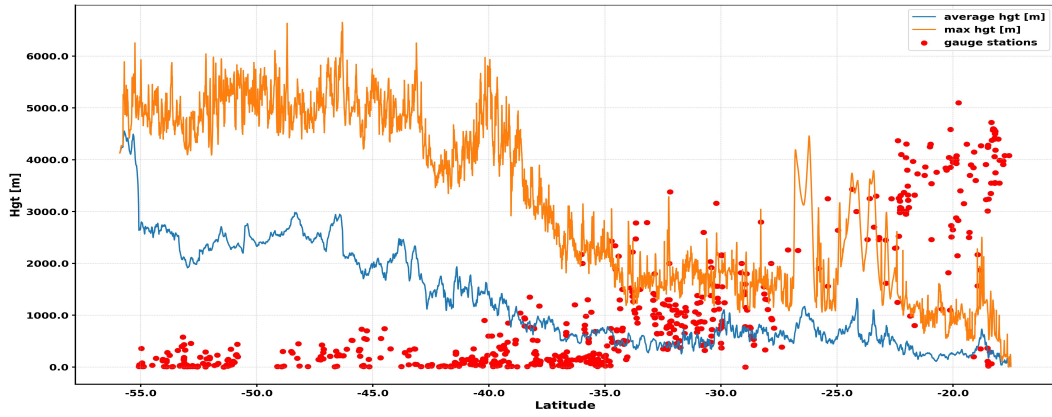
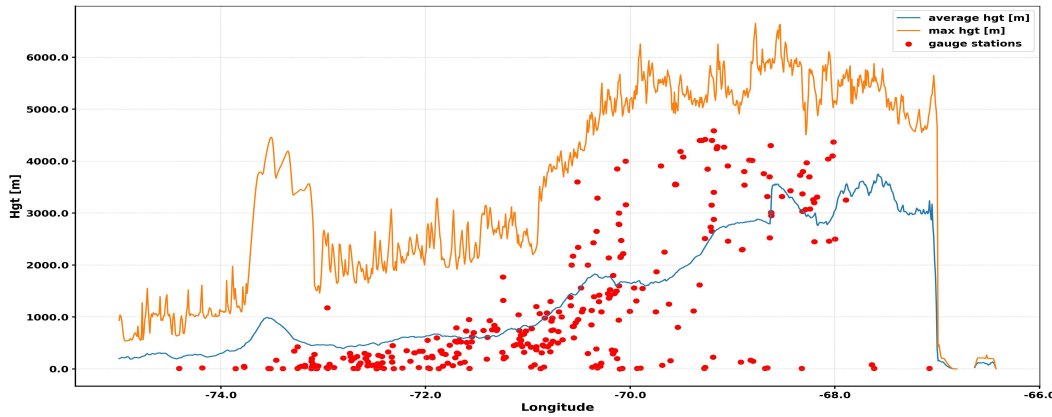


FIGURA 1.1: Distribución de estaciones de la red chilena de precipitación; 1900-2019. (a) longitud vs altura (*hgt*). Elaboración propia.




(a)

FIGURA 1.1 : (b) latitud vs altura (*hgt*). Elaboración propia.



(b)



(c)

FIGURA 1.2: Distribución de estaciones de la red chilena de temperatura; 1900-2019. (a) longitud vs altura (*hgt*), (b) latitud vs altura (*hgt*). Elaboración propia.

Esta problemática se ve agravada por la heterogeneidad en la continuidad temporal de los registros. Como se puede observar en la Figura (1.3), la red de estaciones de precipitación y temperatura por cada región presentan grandes discontinuidades, comprometiendo la homogeneidad de los datos recopilados. Incluso en la actualidad, la continuidad en los registros históricos de algunas estaciones es cuestionable, lo que introduce incertidumbre en los estudios de tendencias climáticas y en la calibración de modelos. Este problema es particularmente crítica en países en vías de desarrollo, donde la infraestructura meteorológica suele ser limitada y la recopilación de datos enfrenta desafíos persistentes (Dinku et al., 2014; Dinku, 2019).

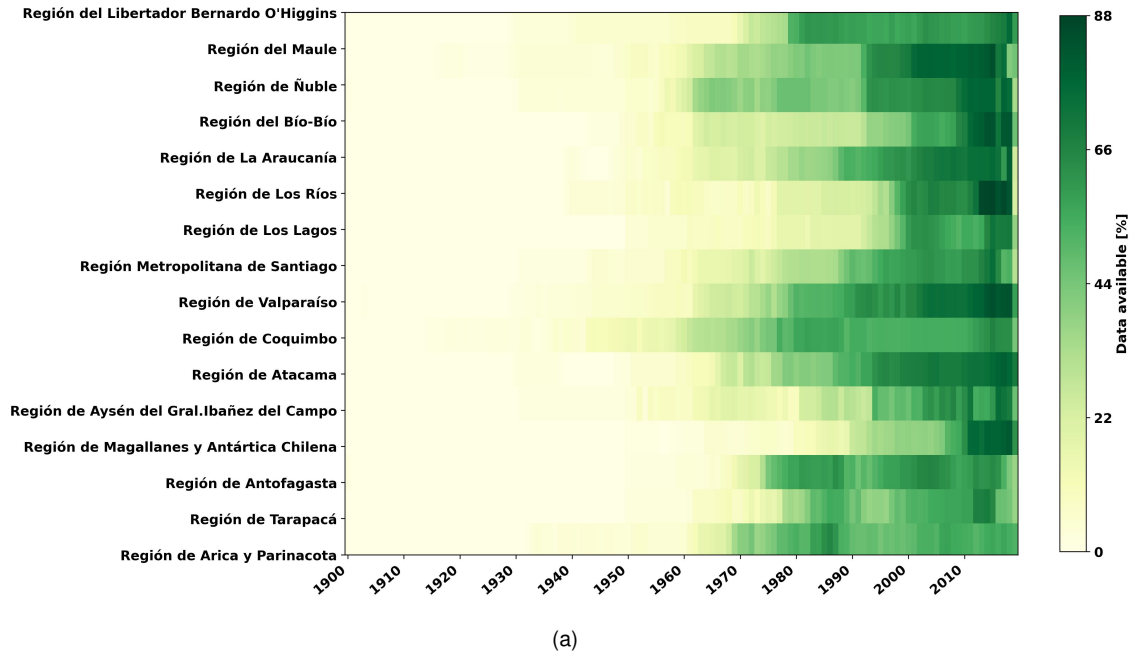


FIGURA 1.3: Porcentaje histórico de datos disponibles a nivel mensual de la red chilena; 1900-2019. (a) precipitación, (b) temperatura superficial. Fuente: elaboración propia.

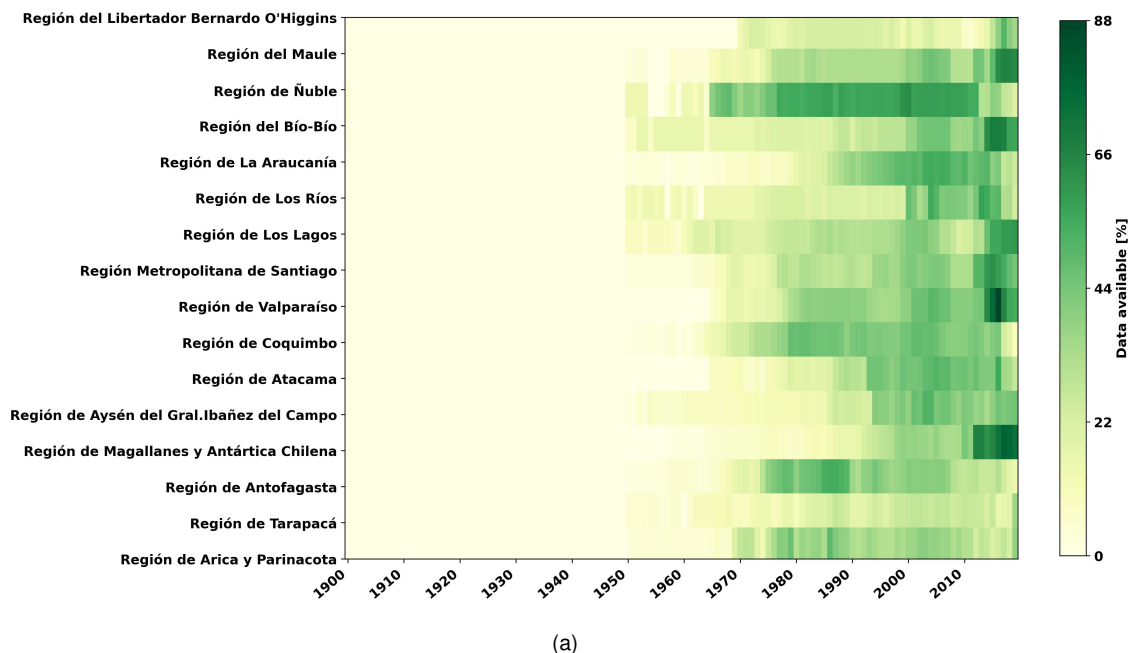


FIGURA 1.3: Porcentaje histórico de datos disponibles a nivel mensual de la red chilena; 1900-2019. (a) precipitación, (b) temperatura superficial. Fuente: elaboración propia.

A pesar de la disponibilidad de múltiples fuentes de datos hidro-climáticos sobre el territorio, persisten grandes incertidumbres en la manera en que estos representan la realidad, especialmente en zonas de montaña (p. ej. Zambrano et al. 2016; Zambrano-Bigiarini et al. 2017a; Zambrano et al. 2018; Schumacher et al. 2020a; Lagos-Zúñiga et al. 2024a). Entre los principales factores que contribuyen a estas incertidumbres, se encuentran la resolución espacial limitada de los modelos y productos de datos. Estos, a menudo no capturan adecuadamente la heterogeneidad del terreno y las características locales; las condiciones microclimáticas que prevalecen en estas regiones, influidas por fenómenos orográficos como la orientación de las pendientes y la altitud; así como las dificultades asociadas a la interpolación de datos obtenidos a partir de sensores remotos o estaciones meteorológicas dispersas. Además, la representación de procesos hidro-climáticos complejos, como la precipitación orográfica y la acumulación y derretimiento de nieve, sigue siendo un desafío importante para mejorar la precisión de las estimaciones en áreas montañosas. Con esto en mente, se ha abordado la construcción de datos hidro-climáticos en alta resolución espacial para la predicción del clima futuro (p. ej. Fuenzalida 2007; Souvignet et al. 2010; Garreaud et al. 2011; Fiebig-Wittmaack et al. 2012; Santibañez et al. 2014; Araya-Osses et al. 2020b). Sin embargo, aunque existen intentos en el desarrollo de campos de precipitación

en alta resolución como es lo propuesto por el Centro de Ciencia del Clima y la Resiliencia CR2 (CR2) (Boisier et al., 2018), estos no entregan detalles claros en su construcción.

## 1.2 Reducción de escala (downscaling)

Los modelos hidro-climáticos modernos, como los reanálisis globales, modelaciones regionales y satélites, proporcionan grillas consistentes y confiables para la representación de fenómenos climáticos a gran escala. Sin embargo, su resolución espacial es generalmente baja (típicamente de  $0.25^\circ$  a  $1^\circ$ ), lo cual dificulta su capacidad para capturar adecuadamente procesos locales y heterogeneidades topográficas propias de áreas montañosas (Giorgi et al., 2015; Cannon et al., 2015a). Esta limitación se debe, en gran parte, a la necesidad de equilibrar la cobertura espacial extensa con la viabilidad computacional y la disponibilidad de datos observacionales de alta calidad para la calibración y validación de modelos (Maraun et al., 2010). Además, procesos climáticos locales que afectan la precipitación pueden llevar a errores significativos en la estimación de variables hidro-climáticas fundamentales (Immerzeel et al., 2010; Sun et al., 2016).

Podemos reconocer que los primeros métodos de reducción de escala o downscaling como se denominará desde adelante, habían nacido ya a fines de la década de 1940 (Klein, 1948), aunque su uso fue descrito por primera vez por (Starr et al., 1942). En aquel entonces, los modelos numéricos del clima utilizados en la reducción de escala eran demasiado burdos para predecir el clima local y, además, no pronosticaban todas las variables de interés, sino sólo algunas, como la presión y la temperatura (Maraun et al., 2018). Los métodos de reducción de escala se hicieron operativos desde los primeros días del nacimiento de la predicción numérica. En este sentido, Shuman (1989) indica la existencia de publicaciones sobre el uso de una técnica de reducción de escala empírico-estadística (ESD), conocida como “método analógico”, en la predicción meteorológica desde 1951, y en la previsión estacional desde 1988 (Matulla et al., 2008). No obstante, probablemente el primer estudio estadístico de reducción de escala fue el análisis de Kim et al. (1984), el uso de la reducción de escala empírico-estadística en la investigación climática se generalizó a principios de los años 1990, en relación con la creciente preocupación por el calentamiento global y sus consecuencias para los recursos hídricos (Wilby et al., 1997a; Benestad, 2016).

Como tal, el término “downscaling” fue introducido por Von Storch et al. (1993), este refiere a un enfoque estadístico que relaciona estadísticas de gran escala con estadísticas de pequeña escala o impactos. Esto es, se basa en el supuesto de que el clima a gran escala genera una

fuerte influencia en el clima local; mientras, el clima local no genera un efecto sobre las escalas globales (Maraun et al., 2010). Esta relación, puede expresarse como:

$$S_t^C = F(L_t^C, \eta_t^s), \quad (1.1)$$

donde  $S_t^C$  son los estados climáticos en pequeña escala,  $L_t^C$  los estados climáticos en gran escala y  $\eta_t^s$  son los estados fisiográficos de pequeña escala; externos a la dinámica. El superíndice  $C$  se refiere al “clima” y  $F$  representa un modelo estadístico.  $F$  puede adoptar diversas formas, pero siempre es una especie de mapa interpolado, con  $L_t^C$  como coordenadas. El tiempo  $t$  ya no es una instancia temporal, sino que representa medias mensuales o anuales (Von Storch et al., 2019).

Con el nacimiento de la conciencia sobre la variabilidad climática, también aumentaron las preocupaciones sobre sus posibles impactos. Los encargados de la toma de decisiones estaban interesados en diversas cuestiones, como la seguridad alimentaria nacional o la evaluación de los riesgos asociados a los depósitos de residuos nucleares (Maraun et al., 2018). Esto, creó una demanda de estudios regionales sobre el cambio climático: ¿cómo responderían los climas regionales al cambio climático global?, ¿Cuáles serían los impactos de estos cambios?. En este sentido, y de acuerdo con Ambrizzi et al. (2019), Solman (2013) realizó una descripción general del desarrollo de las actividades de modelado climático regional en América del Sur desde su inicio en 2000 hasta 2013, el demostró que los primeros estudios sobre Sudamérica (SA) se realizaron para evaluar el desempeño de los Modelos Climáticos Regionales (RCM) en la captura de las principales características del clima observado. Así, el primer estudio que empleó el downscaling sobre SA fue realizado por Chou et al. (2000), donde se utilizó el Modelo Regional ETA de Predicción Numérica del Tiempo (ETA) de 80 km de los Centros Nacionales de Predicción Ambiental para realizar una simulación de un mes de duración para las estaciones seca y lluviosa en 1997 sobre todo el sur del continente americano.

A pesar del temprano desarrollo de métodos de downscaling, la mayor parte de la información ambiental a escala meso y micro, como las emisiones de  $CO_2$  de una aglomeración urbana o un condado, no es accesible (Wang et al., 2017). Por lo tanto, la escala de la información ambiental a la que tenemos acceso claramente no coincide necesariamente con la escala que necesitamos (Bierkens et al., 2000; Li et al., 2024). No obstante, el downscaling intenta mejorar la deficiente representación de modelos climáticos globales, los cuales suelen tener resoluciones espaciales entre 0.3°- 2° de resolución espacial. Por lo tanto, basándonos en el supuesto de que el clima a gran escala genera una fuerte influencia en el clima local (Maraun et al., 2010) y dado que los

procesos hidrológicos de interés típicamente ocurren sobre la escala fina (IPCC, 2007; Maraun et al., 2010), la reducción de escala se convierte en una herramienta que permite asistir a la comunidad científica y gubernamental a evaluar los posibles impactos de los procesos provenientes de la incertidumbre climática; más aún en lugares como Chile, que posee una gran cantidad de micro-climas influenciado por su características orográficas y físicas.

La diversidad de enfoques de reducción de escala refleja la diversidad de objetivos y recursos disponibles para cada evaluación (Pharasi et al., 2006; Trzaska et al., 2014). No existe un único enfoque de reducción de escala óptimo, y los métodos variarán en función de la resolución espacial y temporal deseada de los resultados y de las características del mayor impacto climático de interés (Trzaska et al., 2014; Kreienkamp et al., 2019; Keller et al., 2022). No obstante, es posible de reducir a una clasificación de dos categorías principales: downscaling dinámico (DD) y downscaling estadístico (SD).

El downscaling dinámico, desarrollado a partir de modelos Climáticos Globales aplicado a áreas limitadas, aunque relacionado con el downscaling estadístico (o empírico) presenta diferencias fundamentales en su configuración. En este sentido, el procedimiento no constituye, en sentido estricto, una verdadera “reducción de escala”, debido que la derivación de estimaciones a menor escala a partir de estados de mayor escala no era posible debido a la ausencia de un mecanismo explícito que modelara estos vínculos a nivel global. Entre los cuales se destacan:

- Condiciones iniciales y de frontera: Proveen la información de gran escala necesaria para iniciar y actualizar las simulaciones regionales, estableciendo la coherencia con el contexto climático global.
- Forzamientos superficiales: Factores como la temperatura del mar, albedo, uso del suelo y características del terreno, que afectan la interacción entre la atmósfera y la superficie terrestre o marina.
- Parámetros de subgrilla o física local: Representan procesos locales no resueltos explícitamente por el modelo, como la convección, la nubosidad o la precipitación orográfica.

Así, la incorporación de restricciones de gran escala resolvió este problema, permitiendo la adaptación global de este tipo de modelado (Von Storch et al., 2019). En otras palabras, la falta de una modelación específica de las interacciones entre escalas impedía la transferencia de información de manera realista, lo que hacía necesario incluir restricciones que representaran dichos vínculos

de manera coherente. Esto se puede expresar como:

$$S_t^w = M(L_t^w, \eta_t^s), \quad (1.2)$$

donde,  $L_t^w$ , es el estado meteorológico de gran escala,  $S_t^w$  es el estado meteorológico de pequeña escala y  $\eta_t^s$  son estados de pequeña escala que modulan la dinámica meteorológica regional, actuando como modificadores o condicionantes meteorológicos. Es decir, son un conjunto de condiciones externas a la dinámica atmosférica principal, que incluyen no solo características fisiográficas (elevación u orientación de pendientes) sino también otros factores locales relevantes como el uso del suelo y propiedades de este (p.ej. su humedad). Finalmente, aquí,  $M$  representa un modelo dinámico.

### 1.2.1 Downscaling Dinámico

Los modelos climáticos y del sistema terrestre con procesos biogeoquímicos complejos son las principales herramientas para proyectar el clima pasado, presente y futuro. Típicamente, los Modelos de Circulación Global (MCG) pueden ser modelos unidimensionales o modelos tridimensionales (Thiemeßl, 2011) con una resolución espacial habitual de 100 a 300 *km*. En lo que respecta a la representación de la atmósfera, los modelos tridimensionales, también conocidos como modelos climáticos globales (GCM), son la fuente principal para conocer la variabilidad atmosférica físicamente consistente (Figura 1.4). Sin embargo, los GCM no pueden resolver por completo la orografía, la cobertura terrestre y la dinámica de la atmósfera a escala fina, lo que dificulta su capacidad para simular fenómenos meteorológicos y climáticos extremos (Zongci et al., 2014; Xu et al., 2019a).




FIGURA 1.4: Esquema de un GCM acoplado; atmósfera-oceano. Referencia: <https://www.education.psu.edu/meteo469/node/140>.

Los GCM, resuelven numéricamente las ecuaciones diferenciales parciales que describen la dinámica de los diferentes componentes del sistema climático (atmósfera, océano, criósfera, etc.) y las interacciones que suceden entre ellos (Goosse, 2015; Legasa Ríos, 2023). Las ecuaciones que dominan estas componentes e interacciones se fundamentan en principios generales de la dinámica de fluidos y la termodinámica (p. ej. conservación de la masa, energía y momento). La complejidad para resolver estas ecuaciones (no cerradas) nos empuja a una solución por medio de métodos numéricos como las diferencias finitas (LeVeque, 2007; Solomon et al., 2007; Araya-Osses et al., 2020b) sobre un espacio cuatridimensional; latitud, longitud, niveles verticales y el tiempo.

Aunque la resolución espacial de los GCM ha mejorado sustancialmente en los últimos veinte años, aún existen limitaciones computacionales, lo cual aunado a simulaciones extensas, limita la resolución espacial que puedan alcanzar los GCM. En la Figura (1.5), se muestra un ejemplo de esta problemática para la temperatura a 2 metros del modelo Global Forecast System (GFS) a 1°, 0.5° y 0.25°; en ella claramente se aprecian patrones espaciales indistinguibles en baja resolución. Por lo tanto, los GCM fallan en proveer información climática realista en la sub-grilla o incluso en escala regional, así como en la escala diaria o sub-diaria.

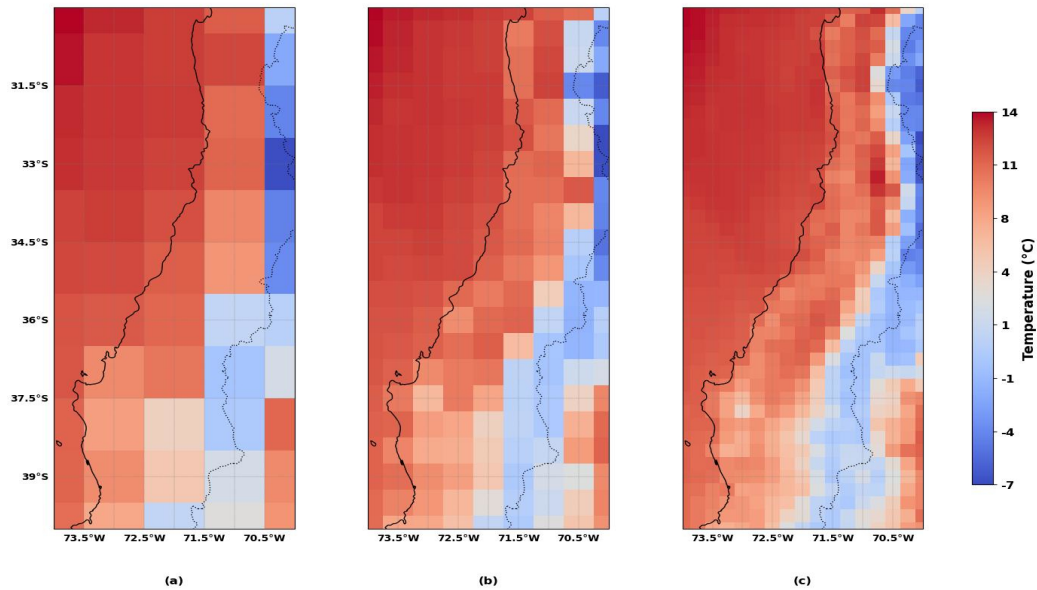


FIGURA 1.5: Comparativa entre la baja y alta resolución. En ella, se puede observar cómo la reducción de escala puede proporcionar información más detallada a escalas locales de la temperatura a dos metros. (a) GFS a 1°, (b) GFS a 0.5° y (c) GFS a 0.25° de resolución espacial. Fuente: elaboración propia.

Esta baja representación de los GCM en la escala local puede ser superado mediante el downscaling dinámico (Figura 1.6). El downscaling dinámico (DD), emplea un modelo climático regional (RCM) anidado dentro de un GCM para generar información climática de alta resolución. Similar al desarrollo de los GCM, los RCM se formulan sobre la base de principios físicos y de procesos biogeoquímicos. Así los RCM son modelos regionales del sistema terrestre que pueden simular las interacciones entre la atmósfera, la tierra, el agua, la economía social, etc (Adam et al., 2015a; Adam et al., 2015b). Por lo tanto, pueden interpretar fenómenos climáticos localizado y extremos que serían imposibles de apreciar mediante un GCM (Wilby et al., 2004; Caldwell et al., 2009; Ekström et al., 2015a; Holthuijzen, 2022; Xu et al., 2019a).

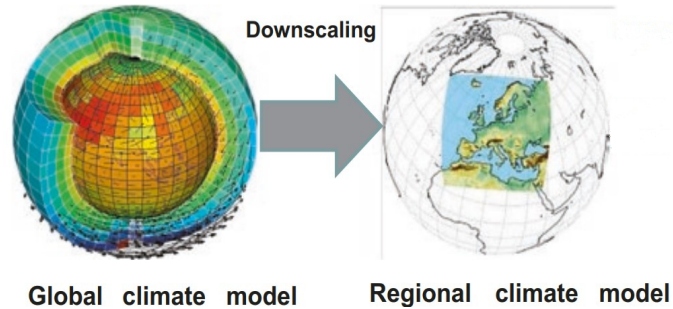


FIGURA 1.6: Esquematización del downscaling dinámico utilizando las condiciones de borde e iniciales del modelo climático global. Fuente: (Vautard, 2018).

A pesar de la sofisticación y la capacidad de los RCM para modelar el clima local, estos aún poseen varias deficiencias: (1) aunque requieren menos capacidad computacional que los GCM, estos aún son altamente costosos (Giorgi et al., 2009a; Feser et al., 2011a; Adachi et al., 2020a), (2) mantienen problemas como el tamaño y la ubicación del dominio, efectos provocados por la topografía compleja, la resolución horizontal y vertical, la calidad de los datos de forzamiento a gran escala y los procesos físicos (Jacob et al., 1997; Liang et al., 2004; Alexandru et al., 2007; Seager et al., 2010a; Caron et al., 2011a; White et al., 2013a; Xu et al., 2019a), (3) aunque resuelven numéricamente la atmósfera, para simplificar procesos estos utilizan parametrizaciones; en muchos casos estos no pueden dar cuenta de la variabilidad natural del área en análisis gracias a su construcción generalizada del sistema climático, (4) al hacer uso de estas parametrizaciones, estos subestiman o sobrestiman las retroalimentaciones atmosféricas complejas o fenómenos del área en estudio (Maraun et al., 2017).

Tales deficiencias generadas, provocan errores sistemáticos y considerables sesgos, en particular en variables superficiales como la precipitación (Schmidli et al., 2006; Tan et al., 2020; Legasa Ríos et al., 2023); un resumen de fuentes de errores e incertidumbre de los modelos globales se indica en la Tabla (1.1).

Fuente	Descripción
Representaciones simplificadas de procesos físicos y resolución espacial y temporal insuficiente	Los GCM utilizan una representación simplificada del sistema climático de la Tierra y parametrizaciones para procesos complejos que no se pueden simular debido a la resolución limitada.
Incertidumbres en las entradas y parametrizaciones del modelo	Los GCM requieren diversos insumos, como escenarios de emisiones, composición atmosférica y uso de la tierra, que están sujetos a incertidumbres y errores.
Perturbaciones computacionales y comportamiento caótico de la atmósfera	Los modelos de comportamiento global son, en esencia, sistemas de ecuaciones diferenciales parciales que se resuelven numéricamente. Las perturbaciones numéricas y las incertidumbres en las simulaciones se propagan y amplifican a través del tiempo y el espacio. La atmósfera en sí misma es un sistema caótico, lo que implica que pequeñas diferencias pueden producir enormes diferencias en su evolución.

TABLA 1.1: Resumen de las fuentes de sesgo e incertidumbre en los modelos climáticos globales.  
Fuente: Legasa Ríos et al. (2023)

### 1.2.2 Downscaling estadístico

Las técnicas de reducción de escala estadística o Statistical Downscaling (SD), se basan en relaciones estadísticas (a menudo denominadas funciones de transferencia) entre variables predictoras del clima a gran escala (p. ej. vorticidad, humedad) y predictores a escala local como la precipitación diaria (Pharasi et al., 2006; Maraun et al., 2010; Gutiérrez et al., 2013; Maraun et al., 2019). Si bien los términos “reducción de escala estadística” y “corrección del sesgo” algunas ocasiones se utilizan de manera intercambiable, esto debe tomarse con cuidado. Como indica (Maraun et al., 2018), estos dos términos caen en el tipo de enfoque para obtener una adecuada representación de la variable climática a analizar. Por ello, siguiendo la terminología propuesta por (Klein et al., 1974a) y popularizada por Maraun et al. (2010), podemos clasificar los métodos de downscaling estadístico de acuerdo a la naturaleza de sus datos en tres enfoques principales :

- Weather Generators (WG).
- Model outputs Statistics (MOS).
- Perfect prognosis (PP).

### Weather Generators (WG)

Se puede definir el enfoque WG, como un modelo estocástico de variables meteorológicas que modelan explícitamente su distribución marginal y dependencia temporal. Esto es, se construyen secuencias aleatorias del clima (estocásticas) pero que siguen patrones indicados por los datos observados; permitiendo el análisis en diferentes escenarios (Wilks, 1999; Zhang, 2005; Qian et al., 2010; Chen et al., 2012; Chen et al., 2021). Al menos tres características distinguen a los WG. Los WG se centran en escalas espaciales pequeñas (normalmente unos pocos sitios dentro de una región que se extiende a lo largo de unos pocos kilómetros), tienen que ser computacionalmente muy rápidos para proporcionar numerosas realizaciones aleatorias y esos resultados deben tener las mismas propiedades de distribución que las series temporales observadas, principalmente en las escalas diarias o subdiarias (Ailliot et al., 2015). Los generadores climáticos actuales, se pueden dividir en cuatro grupos: métodos de remuestreo (p. ej. Rajagopalan et al. 1999; Oriani et al. 2014; Yiou 2014), metodología de Box-Jenkins (p. ej. Box George et al. 1976), modelos de procesos puntuales (p. ej. Onof et al. 2000), modelos jerárquicos (p. ej. Pezzulli et al. 2006). Con esto en mente, los métodos WG pueden utilizarse básicamente en dos entornos diferentes para la reducción de escala:

- Factores de cambio: Este enfoque, modifica las estadísticas climáticas a largo plazo simuladas por los modelos climáticos utilizando factores de cambio. Estos factores, calculados a partir de los cambios proyectados por los modelos climáticos, se aplican para ajustar los parámetros del generador meteorológico; método similar al enfoque delta change, donde los cambios a largo plazo proyectados por los modelos son aplicados directamente a las series históricas.
- Series temporales: Este enfoque, utiliza las series temporales de predictores meteorológicos generadas por los modelos climáticos para ajustar los parámetros del generador meteorológico día a día. Ambas metodologías, tienen ciertas similitudes y diferencias con los métodos estándar MOS y PP.

En Chile, si bien no podemos encontrar un conjunto amplio de estudios que utilicen esta metodología, podemos destacar los trabajos de Souvignet et al. (2010), Meza et al. (2012), Chadwick et al. (2020); todos estos trabajos se focalizan en el norte del país y son a nivel de cuenca.

### Model Outputs Statistics (MOS)

Por otra parte, siguiendo la descripción de Von Storch et al. (1993), Widmann et al. (2003), Maraun et al. (2010), Themeßl (2011), Maraun et al. (2018), se define a cualquier método que establece una función de transferencia estadística entre el modelo y las observaciones históricas de la variable predictiva como un método MOS (Wong et al., 2014). Por lo tanto, este método esencialmente actúa como una corrección estadística de los GCM; reteniendo las tendencias climáticas predichas por los GCM (Eden et al., 2014; George et al., 2024). En el enfoque MOS, es necesario tener las siguientes consideraciones (Maraun et al., 2018):

- En el enfoque MOS, los predictores necesitan ser creíbles. Es decir, los valores que se generan para los predictores deben estar en concordancia con la realidad.
- Los predictores MOS deben ser representativos de la variable objetivo. Es decir, deben representar la misma escala espacial y ubicación.
- La función de transferencia debe tener una estructura adecuada, que sea aplicable en condiciones climáticas cambiantes.

Como podemos ver, este método se fundamenta esencialmente sobre el comportamiento entregado por las estaciones meteorológicas. En el contexto Chileno, sólo podemos destacar el trabajo de Mutz et al. 2021 utilizando esta metodología.

### Prefect Prognosis (PP)

En el enfoque pronostico perfecto (PP), se calibra un modelo estadístico que vincule los predictores de gran escala con los predictandos de escala local a los datos observados. por lo tanto, se requiere encontrar una función empírica que enlace los predictores y el predictando tal que:

$$y = \mu = f(X, g) + \eta, \quad (1.3)$$

donde  $y$  es la variable a estimar (predictado),  $X$  son las variables a gran escala (predictores),  $g$  son las características locales y  $\eta$  es un ruido a pequeña escala; debido que el clima local en general no está totalmente determinado por las condiciones a gran escala, surgen residuos  $\eta$  entre la media predicha  $\mu$  y el predictando  $y$  (Maraun et al., 2018). Luego, el modelo estadístico se aplica a los predictores simulados por los modelos climáticos (Maraun et al., 2018). Por lo tanto,

este enfoque se basa en la meteorología y la climatología sinóptica, que analizan la relación entre la escala sinóptica y el clima regional (Hewitson et al., 1996).

Se debe tener en cuenta, que este vínculo a encontrar (ec. 1.3) se puede establecer a diferentes escalas temporales. Además, generalmente nos podemos referir a este proceso de encontrar la función de vínculo  $f$ , independientemente de la metodología utilizada, como el entrenamiento/calibración de los métodos de desviación estándar, como se lo llama comúnmente en el aprendizaje automático (Legasa Ríos et al., 2023).

La construcción del enfoque PP, requiere de varias suposiciones para que estos funcionen correctamente. De acuerdo con Hewitson et al. (1996), Wilby et al. (2004), Cavazos et al. (2005) y Maraun et al. (2018) se debe considerar:

- Los predictores deben ser realistas y sin sesgos. Es decir, el modelo utilizado debe modelar correctamente el pasado, presente y futuro del clima.
- Se debe reconocer predictores que explique gran cantidad de la variabilidad local en todas las escalas temporales de interés.
- El modelo debe ser estructuralmente consistente. Es decir, la influencia de los predictores en el predictando debe ser adecuadamente incorporada.

### Técnicas estadísticas; enfoque PP

De acuerdo con Wilby et al. (1997b), Von Storch et al. (2000), Benestad et al. (2008) y Themeßl (2011), metodológicamente podemos clasificar las técnicas de escalamiento estadístico en tres grandes grupos: modelos de regresión, enfoques de tipificación y generadores meteorológicos; Aquí, sólo mostraremos la técnica de regresión.

### Modelos de regresión

- Modelos lineales: Es el caso más simple de modelos de regresión. Aquí, un conjunto de  $X$  series temporales de predictores se vinculan a una serie de predictados mediante la expresión.

$$E(Y_i) = \mu_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_M x_{iM}. \quad (1.4)$$

En este caso, se asume que presentan una distribución normal  $\eta_i \sim N(0, \sigma^2)$ , con media cero y varianza  $\sigma^2$ . Este ruido a menudo no se simula explícitamente, por lo que la mayoría

de las series de tiempo escaladas solo representan valores de escala local “típicos”; dichas series de tiempo son entonces demasiado suaves (Maraun et al., 2018). Esta característica, hace que algunos autores “inflen” la serie temporal producto del downscaling para que coincida con la varianza local observada (Karl et al., 1990; Maraun et al., 2018).

En general, la elección de la técnica de SD aplicada depende en gran medida de las características del predictando. Incluso para la misma técnica SD, Manzanos et al. (2020) demostraron que la elección de las variables predictoras consideradas también puede conducir a proyecciones de precipitación dramáticamente diferentes (Legasa et al., 2023). Por ejemplo, si el enfoque se centra en series temporales mensuales en estaciones de observación individuales, los modelos de regresión lineal en la mayoría de los casos funcionarán bien, ya que se espera que el predictando tenga una distribución normal, también para la cantidad de precipitación, y el modelo se puede aplicar estación por estación, sin tener en cuenta las correlaciones espaciales (Themeßl, 2011).

Sin embargo, si se requieren campos de precipitación diaria con una distribución no normal, pueden ser aconsejables métodos más sofisticados como procedimientos analógicos, generadores meteorológicos estocásticos o enfoques de escalamiento (Von Storch et al., 2000; Themeßl, 2005; Themeßl, 2011).

### 1.3 Motivación

El cambio climático y la variabilidad climática en la zona centro-sur de Chile plantean desafíos significativos para la gestión de recursos hídricos y la previsión de eventos extremos. Esta región, caracterizada por una topografía compleja y una diversidad climática considerable, es fundamental desarrollar modelos de variables hidroclimáticas de alta resolución que puedan capturar con precisión la variabilidad espacial y temporal.

Actualmente, en Chile, la necesidad de información hidrológica y de pronóstico atmosférico, así como de evaluaciones precisas para la gestión de desastres naturales, la agricultura y la generación de energía, ha cobrado una relevancia crítica, especialmente bajo el contexto de incertidumbre climática. Aunque existen modelos globales y datos satelitales con un amplio uso en la comprensión de patrones de circulación a gran escala, estos no logran capturar la compleja diversidad climática del país debido a sus limitaciones de resolución. Esta baja resolución espacial impide responder a las demandas específicas de información para aplicaciones a nivel regional y local, especialmente en contextos de variabilidad climática extrema.

Si bien los GCM permiten entender patrones generales de circulación atmosférica, la evaluación de impactos a escala local requiere información más detallada. La falta de coincidencia en la resolución espacial entre los GCM y datos satelitales versus las necesidades de modelos de impacto, limita su aplicación directa para evaluar el cambio climático a nivel de cuencas hidrográficas.

En si mismo, modelar variables como la precipitación, que presenta alta variabilidad a nivel subcuadrícula, representa un desafío particular. A diferencia de la temperatura, la precipitación es un fenómeno altamente errático, influenciado por múltiples factores externos y locales. Esta complejidad en su comportamiento la convierte en una variable desafiante, pero esencial para entender y gestionar los impactos del cambio climático en regiones de alta variabilidad climática como la centro-sur de Chile.

## 1.4 Objetivos de Investigación

La presente investigación tiene como objetivo principal comprender el comportamiento del downscaling estadístico aplicado a la estimación de precipitación en la zona centro-sur de Chile. De acuerdo a la irregularidad de información, complejidad topográfica y variabilidad climática de esta región, es crucial desarrollar metodologías que permitan obtener campos de precipitación en alta resolución espacial. Los objetivos específicos de este estudio son los siguientes:

- i) Analizar y comprender el comportamiento del downscaling estadístico para la estimación de campos precipitación en alta resolución en la zona centro-sur de Chile: Este objetivo busca examinar diferentes metodologías de downscaling estadístico en regiones de topografía compleja y características climáticas particulares, típicas de la zona centro-sur de Chile. Se evaluará el rendimiento de esta metodología en la captura de la variabilidad espacial y temporal de la precipitación, así como en la resolución de patrones asociados a fenómenos climáticos locales.
- ii) Desarrollar y validar una metodología robusta para generar campos de precipitación en alta resolución espacial ( $\leq 1 \text{ km}$ ): Se propone diseñar un enfoque metodológico que permita la obtención de datos de precipitación a una resolución espacial de un kilómetro. Este desarrollo implicará la selección de una metodología estadística de interpolación y ajuste del modelo.

- iii Implementar un modelo de downscaling estadístico (SD) mensual: Este objetivo busca combinar datos satelitales (p. ej. Chirps, CRU), modelación numérica regional (WRF) y observaciones en estaciones meteorológicas para la construcción de campos de precipitación. La integración de estas fuentes de datos permitirá analizar la influencia de condiciones macroclimáticas sobre áreas de menor escala, capturando patrones espaciales que los modelos globales o de baja resolución no logran identificar.
- iv) Implementar un modelo de downscaling estadístico diario centrado en la construcción de campos de precipitación sobre eventos extremos: Este punto, está orientado a capturar eventos de alta intensidad y su distribución espacial con precisión. Se diseñará un modelo diario que combine datos satelitales, modelos climáticos globales y observaciones locales, permitiendo una resolución detallada en el tiempo. Este enfoque permitirá una mejor evaluación del impacto potencial de eventos extremos, facilitando el estudio en la gestión de riesgos y la planificación ante desastres naturales en la región.

## 1.5 Estructura de tesis

**Marco General** : Este capítulo introduce el contexto de la investigación, proporcionando antecedentes locales y la respectiva justificación. Incluye la definición clara del problema y establece los objetivos principales de la investigación. Se enfoca en explicar la relevancia de la alta resolución espacial en los estudios de precipitación para mejorar la comprensión y gestión de los recursos hídricos en regiones de topografía compleja.

**Artículo 1** Este capítulo detalla el desarrollo y validación de un conjunto de datos grillado de precipitación mensual en alta resolución. Se describe en profundidad la metodología empleada, que incluye técnicas de interpolación, método de downscaling estadístico y el uso de datos satelitales y de observación local. También se abordan los desafíos metodológicos encontrados, como la variabilidad espacial de la precipitación en regiones de topografía compleja y las limitaciones de los datos de entrada.

**Artículo 2** Este capítulo se centra en la construcción de campos de precipitación diarios específicamente diseñados para el análisis de eventos extremos en el área de estudio. Utilizando nuevamente un enfoque de downscaling estadístico, se integran datos satelitales de alta resolución, observaciones meteorológicas locales y modelos climáticos globales. El objetivo es desarrollar un marco metodológico que permita capturar y predecir con precisión eventos de precipitación extrema, evaluando tanto su intensidad como su distribución espacial y temporal.

**Conclusión General** : Este capítulo ofrece una síntesis de los hallazgos de los capítulos anteriores, proporcionando una conclusión general del trabajo realizado. Además, se proponen recomendaciones para futuras investigaciones y aplicaciones, enfocadas en mejorar los modelos de precipitación y su aplicabilidad en estudios hidrológicos y climáticos, así como en la planificación de respuestas ante eventos extremos.

## Capítulo 2

### Conjunto de datos de precipitación cuadrículados en alta resolución sobre la zona centro-sur (34° S–41° S) de Chile

#### 2.1 Introducción

La información meteorológica espacial que sea consistente con la información de estaciones observacionales es crítica para varios campos científicos: ambiental, hidrología, agricultura, aplicación de energías renovables, biología, economía y sociología, entre otros (Parra et al., 2004; Hijmans et al., 2005; Abatzoglou, 2013; Cannon et al., 2015b; Liu XiaoMang et al., 2017; Sun et al., 2018). Dentro de las variables climáticas, la precipitación es el motor del ciclo hidrológico y el más difícil de estimar (Michaelides et al., 2009; Kidd et al., 2011a; Tapiador et al., 2012; Beck et al., 2017a). Por lo tanto, los conjuntos de precipitación proporcionan información para modelos hidrológicos como SWAT o TOPMODEL (Berezowski et al., 2016), o bien, para verificación ambiental (Ji et al., 2015; Berezowski et al., 2016; Brinckmann et al., 2016; Fick et al., 2017).

Los métodos de interpolación utilizan información de redes meteorológicas locales, productos de reanálisis atmosférico, radares meteorológicos, datos satelitales o una combinación de estos productos para construir conjuntos de datos de lluvia cuadrículados globales o locales; cada uno tiene particularidades. Por ejemplo, los conjuntos de datos basados únicamente en redes de observación instrumental dependen de la distribución espaciotemporal, la calidad y la longitud de los registros (Sun et al., 2014). Los datos de reanálisis atmosféricos, por otro lado, son de baja resolución y, a veces, parametrizan de manera inadecuada los procesos de subgrilla, lo que lleva a una tergiversación de la escala sinóptica y la dinámica convectiva (Roads, 2003a; Ebert et al., 2007a; Kidd et al., 2013a). Otro ejemplo es el radar meteorológico, estos proporcionan datos con alta resolución temporal y espacial, pero de cobertura espacial limitada (Koistinen, 1991; Kitchen et al., 1992; Chen et al., 2008; Beck et al., 2017c). Los datos satelitales permiten la cobertura directa de grandes áreas ( $\sim 0,25^\circ$ ) (Sorooshian et al., 2014; Ashouri et al., 2015), pero son en parte insensibles a lluvias ligeras o lloviznas, sensibles a errores sistemáticos y tampoco aptos

para nieve y superficies cubiertas de hielo en zonas montañosas (Sorooshian et al., 2014; Ashouri et al., 2015; Ferraro et al., 1998; Ebert et al., 2007a; Kidd et al., 2011a; Kidd et al., 2012; Laviola et al., 2013a; Beck et al., 2017c).

Algunas de estas fuentes de datos de precipitación grillada (satélite, reanálisis, modelización atmosférica o técnicas de reducción de escala estadística) pueden presentar problemas en áreas de topografía compleja donde la alta heterogeneidad espaciotemporal es difícil de estimar; por ejemplo Chile (Daly et al., 1994; Chen et al., 2014a; Herold et al., 2016; Beck et al., 2017c; Zambrano-Bigiarini et al., 2017a). Varios estudios han evaluado la insuficiencia de estos conjuntos de datos (p. ej., Nastos et al. 2016; Beck et al. 2017a; Camera et al. 2017; Liu XiaoMang et al. 2017; Hu ZengYun et al. 2018; Sun et al. 2018; Timmermans et al. 2019) incluyendo algunas zonas de Chile (Muñoz et al., 2011; Ward et al., 2011). Recientemente, este problema ha sido abordado sobre Chile continental (Zambrano et al., 2016; Zambrano-Bigiarini et al., 2017a).

Los conjuntos de datos de alta resolución que cubran adecuadamente a Chile son escasos. Esto es sorprendente, dado que el país se encuentra entre los más afectados por el cambio climático (Kreft et al., 2016). Sin embargo, su compleja topografía y diversidad climática representan un desafío para el desarrollo de estos conjuntos de datos. En consecuencia, la cobertura de estaciones de medición insitu es inadecuada y no homogénea, limitando los estudios sobre recursos hídricos (Hosseini-Moghari et al., 2018). Hasta la fecha, los conjuntos de datos están disponibles solo en regiones específicas por estaciones meteorológicas locales (Neira Román, 2010; Zambrano, 2011; Jacquín et al., 2013; I., 2013; Castro et al., 2014; Sijinaldo, 2015; Cifuentes, 2017) o de conjuntos de datos cuadrículados de baja resolución (Morales-Salinas et al., 2012).

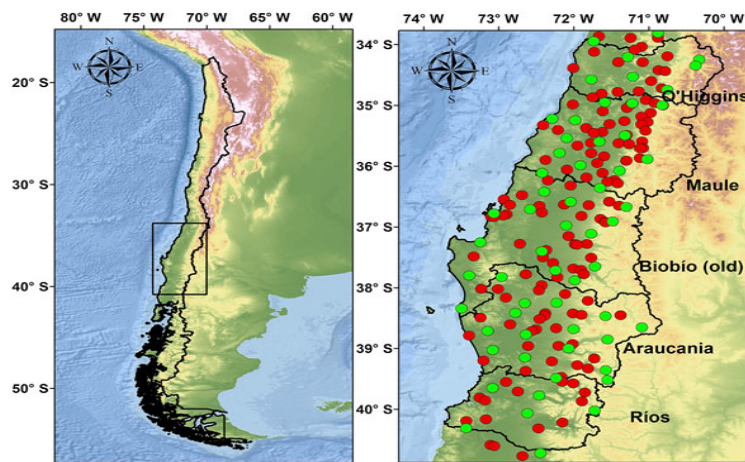
A pesar de estas dificultades, existen métodos conocidos que permiten construir bases de datos de alta resolución de forma eficiente. Entre las técnicas de reducción de escala estadística para la interpolación espacial, los métodos basados en regresión son computacionalmente baratos de ejecutar, fáciles de entender y estadísticamente eficientes y directos (Semenov et al., 1998; Dibike et al., 2005; Hashmi et al., 2011; Pahlavan et al., 2018). Así, los métodos de interpolación basados en funciones que describen cambios espaciales de la variable objetivo (Brinckmann et al., 2016) generan datos espaciales continuos (p. ej., Hay et al. 1998; Marquínez et al. 2003; Ceccherini et al. 2015; Beck et al. 2017a).

El objetivo principal de este capítulo es mejorar, cuantificar y ofrecer una nueva base de precipitación mensual promedio a alta resolución espacial ( $\sim 800$  m) utilizando un método estadístico

dinámico; cuantificando mejorar la data actualmente disponible. Centramos este análisis en la zona centro-sur de Chile (Figura 2.1) en el período 2000-2011.


## 2.2 Área de estudio

La variabilidad del anticiclón subtropical del Pacífico Sur y los centros de presión en latitudes altas dominan el clima sinóptico de Chile (Fuenzalida, 1982; Rojas, 2016). La estrecha anchura (180 km en promedio) entre la costa del Pacífico y los Andes (<https://www.gob.cl/nuestro-pais/>), junto con una extensión norte-sur de 4000 km, contribuye a una variedad de climas (Rojas, 2016). Chile tiene una característica climática distintiva de baja a alta humedad de norte a sur. Por el efecto orográfico, el patrón principal de precipitación muestra una acumulación anual que se desplaza hacia el sur y los Andes (Pizarro et al., 2012a; Quintana et al., 2012; Valdés-Pineda et al., 2016a; Valdés-Pineda et al., 2016a), con precipitaciones anuales en los 30°S norte de alrededor de 100 mm, que aumentan hasta 3000 mm en los 40°S sur (Pizarro et al., 2012a; Barrett et al., 2017a). Dado que la elevación aumenta desde el nivel del mar en el oeste hasta algunos miles de metros en unos pocos cientos de kilómetros hacia el este, las precipitaciones andinas pueden duplicar las precipitaciones costeras (Viale et al., 2015; Barrett et al., 2017a).



(a)

FIGURA 2.1: Área de estudio sobre el centro-sur de Chile; división regional y cuencas fluviales. (a) Área de estudio en el centro-sur de Chile y su división regional (O'Higgins–Los Ríos). (b) Cuencas fluviales utilizadas para el análisis de rendimiento espacial del modelo de pronóstico e investigación meteorológica, los conjuntos de precipitación cuadrículados (Tabla 2) y el modelo topo-climático. Los puntos rojos indican las 136 estaciones utilizadas como entrada para el modelo topo-climático y los 60 puntos verdes indican las estaciones utilizadas para el análisis de desempeño. Fuente: elaboración propia.



(a)

FIGURA 2.1: Área de estudio sobre el centro-sur de Chile; división regional y cuencas fluviales. (a) Área de estudio en el centro-sur de Chile y su división regional (O'Higgins–Los Ríos). (b) Cuencas fluviales utilizadas para el análisis de rendimiento espacial del modelo de pronóstico e investigación meteorológica, los conjuntos de precipitación cuadriculados (Tabla 2) y el modelo topo-climático. Los puntos rojos indican las 136 estaciones utilizadas como entrada para el modelo topo-climático y los 60 puntos verdes indican las estaciones utilizadas para el análisis de desempeño. Fuente: elaboración propia.

Nuestra área de estudio corresponde a la zona centro-sur de Chile entre las latitudes ( $34^{\circ}\text{S}$  –  $41^{\circ}\text{S}$ ), desde la región de O'Higgins hasta la de Los Ríos (Figura 2.1). Esta región presenta un ciclo anual bien definido, caracterizado por un pico de precipitación en el invierno austral y valores más bajos en el verano austral (Valdés-Pineda et al., 2016a; Valdés-Pineda et al., 2016). Además, esta es una de las zonas con mayor humedad del hemisferio sur (Miller, 1976) y una de las zonas extratropicales más afectadas por los eventos de El Niño y La Niña (Grimm et al., 2000; Waylen et al., 2002). Debido a su ubicación de transición entre temperaturas subtropicales y de latitudes altas, el clima de Chile se caracteriza por una importante variabilidad interanual de las precipitaciones (Aceituno, 1993; Quintana, 2004a; Le Quesne et al., 2009a). Esta variabilidad está influenciada por diferentes forzantes climáticos: en la zona norte, la Oscilación del Sur de El Niño (ENSO) regula los patrones de precipitación, generando años más húmedos durante eventos El Niño y sequías en períodos de La Niña. En contraste, en la zona sur, la Oscilación Decenal del Pacífico (PDO) afecta los regímenes hidrológicos, modulando la disponibilidad de agua (Arumí Ribera et al., 2006; Araya Ojeda et al., 2016). La zona centro-sur presenta precipitación acumulada anual entre 100 y 3000 mm de norte a sur (Quintana et al., 2012; Valdés-Pineda et al., 2016b). Esta, es una zona de recarga activa de aguas superficiales y subterráneas como resultado de procesos de infiltración y transporte en valles, canales y sistemas fracturados en las zonas altas y precordilleras (Arumí et al., 2012; Carling et al., 2012). A lo largo de los Andes, particularmente

hacia el sur, donde el papel de los frentes oceánicos es prominente, el efecto orográfico aumenta las precipitaciones.

## 2.3 Metodología

### 2.3.1 Base de datos instrumental

La Dirección General de Aguas y la Dirección Meteorológica de Chile (DMC) apoyan la red de estaciones meteorológicas de Chile. Aunque estos datos son confiables y cubren varias décadas, muchas estaciones son convencionales (informan solo acumulación diaria) y se encuentran en elevaciones bajas (Garreaud Salazar et al., 2016). Además, en la mayoría de los registros (Figura 2.2), las lagunas en los datos son comunes (Zambrano-Bigiarini et al., 2017a). Dentro de la zona de estudio, inicialmente consideramos 301 estaciones que reportaban observaciones diarias (Figura 2.1). Eliminamos estaciones con brechas de datos mensuales de más del 30 % entre 2000 y 2011 (105 estaciones). Del resto de estaciones (196), 136 corresponden a entrada para calibración del modelo y 60 para validación.




FIGURA 2.2: Número de estaciones de precipitación en Chile utilizadas por el conjunto de datos del Centro Global de Climatología de Precipitaciones (Schamm et al., 2016). Fuente: (Zambrano-Bigiarini et al., 2017a).

### 2.3.2 Modelo atmosférico

Se desarrolló una simulación numérica atmosférica utilizando el modelo Weather Research and Forecasting (WRF), versión 3,6 (Skamarock et al., 2008) para el período 2000 – 2011 para obtener un conjunto de datos de precipitación robusto de alta resolución. La simulación se inicializó en octubre de 1999 y se desarrolló hasta diciembre de 2014, descartándose los primeros 3 meses como puesta en marcha del modelo. Según lo recomendado por la DMC (DMC, 2015), este modelo debe considerar un dominio que abarque algunas partes del Océano Pacífico para capturar los fenómenos que se aproximan al continente (Yáñez-Morrón et al., 2018). Usamos tres dominios anidados para reducir la escala (Figura 2.3). El dominio más grande,  $D_1$ , con una resolución de 36 km, contenía dos dominios anidados,  $D_2$  y  $D_3$ , cada uno con una proporción de 1/3 en relación con su padre respectivo (Tabla 2.1).




FIGURA 2.3: Visualización de los dominios utilizados en el modelo atmosférico WRF.  $D_1$ : dominio principal con resolución de 36 km.  $D_2$ : primer anidamiento con resolución de 12 km (1/3 del tamaño del dominio principal).  $D_3$ : segundo anidamiento, con resolución de 4 km (1/9 del tamaño del dominio principal). Fuente: elaboración propia.

Las condiciones iniciales y de contorno para el dominio  $D_1$  corresponden al reanálisis global ERA-Interim, con una resolución de cuadrícula espacial de  $0,75^\circ \times 0,75^\circ$  latitud-longitud y 60 niveles híbridos verticales (Dee et al., 2011). La ingestión de los campos atmosféricos de ERA-Interim se realizó cada 6 horas. La simulación de doce años tomó alrededor de 22 meses computacionales reales en el clúster Troquil en el Centro de Excelencia de Modelado Científico y Computación

de la Universidad de La Frontera. En las simulaciones numéricas atmosféricas, las parametrizaciones influyen fuertemente en los patrones de precipitación simulada (Wang et al., 1997; Gallus, 1999; Jankov et al., 2005) y también afectan la respuesta del modelo a los cambios en el espaciado de las cuadrículas (Gallus, 1999) o humedad del suelo (Gallus, 1999; Gallus et al., 2000). En la Tabla (2.1) se muestra un resumen de las configuraciones utilizadas, seleccionadas siguiendo las recomendaciones del DMC (DMC, 2015).

Dominio	$\Delta x$	N° de puntos	Resolución topográfica
D1	36 km	69 × 48	5'
D2	12 km	126 × 84	2'
D3	4 km	234 × 189	30'
Física		Parametrización	Referencias
Microfísica		Esquema WSM3	(Hong et al., 2004)
Radiación de onda larga		Esquema RRTM	(Mlawer et al., 1997)
Radiación de onda corta		Dudhia	(Dudhia, 1989)
Física de la capa superficial		Esquema revisado MM5 Monin-Obukhov	(Zhang et al., 1982)
Física de la capa limite		Esquema de la Universidad de Yonsei (YSU)	(Hong et al., 2006)
Física del suelo		Esquema noah	(Chen, 2007)

TABLA 2.1: Configuración principal de los dominios aplicados sobre el modelo y esquemas de parametrización seleccionados para la ejecución del modelo WRF. Fuente: elaboración propia.

Implementamos un método para la corrección sistemática de errores (sesgo) aplicado a cada campo de precipitación generado por WRF dentro de cada dominio regional (Figura 2.1-a). Calculamos la relación entre la precipitación mensual promedio de una estación y su punto de cuadrícula más cercano del modelo WRF (una estación virtual). Para cada dominio regional, la ecuación (2.1) selección determinada de las estaciones virtuales del WRF. A continuación, obtuvimos y aplicamos un factor de ajuste  $\mu(P_o^s) / \mu(P_{wrf}^s)$  a cada punto de la cuadrícula en la región (ec. 2.1). Finalmente, cada punto de la cuadrícula ajustado fue reevaluado y descartado como entrada al modelo topo-climático dinámico si no cumplía con el requisito de la ecuación (2.1).

$$f(x) = \begin{cases} P_{wrf}, & \text{si } P_{min}^o - 0,05 \times P_{min}^o \leq P_{wrf} \leq P_{max}^o + 0,05 \times P_{min}^o \quad (a). \\ \frac{\mu(P_o^s)}{\mu(P_{wrf}^s)} P_{wrf}, & \text{si } P_{wrf} < P_{min}^o - 0,05 \times P_{min}^o \quad (b). \\ \frac{\mu(P_o^s)}{\mu(P_{wrf}^s)} P_{wrf}, & \text{si } P_{wrf} > P_{max}^o + 0,05 \times P_{max}^o \quad (c) \end{cases} \quad (2.1)$$

donde  $P_{min}^o$  y  $P_{max}^o$  son el mínimo y el máximo observados de precipitaciones respectivamente;

$\mu(P_o^s)$  es el promedio mensual observado de estaciones;  $\mu(P_{wrf}^s)$  es el promedio mensual de las estaciones virtuales más cercanas entregadas por el modelo WRF;  $P_{wrf}$  es el gridbox calculado; y  $P_{wrf}^{cs}$  es la precipitación con corrección del sesgo.

### 2.3.3 Conjuntos de datos cuadrículados globales

Nuestra compilación incluye ocho productos de precipitación de diversas fuentes (observación, reanálisis, satélite o combinación) y presentan diferentes resoluciones espaciales y temporales y cobertura (semiglobal o global, Tabla 2.2). No corregimos el sesgo de estos productos de precipitación, ya que lo realizaron los equipos que los construyeron. Por tanto, la dinámica de cada producto depende enteramente de su origen. Tres conjuntos de precipitación se basaron en datos satelitales (TRMM, CMOPRH y SM2RAIN), un conjunto se basó exclusivamente en datos observados (CRUv4.01) y cuatro conjuntos se construyeron con datos satelitales, reanálisis y observaciones (PGFv3, CHIRPSv2.0), PERSIANN-CDR y MSWEPv1.2).

Para minimizar la diferencia en el sesgo de estos productos de precipitación (Zhang et al., 2019; Yeh et al., 2020), cada producto de precipitación cuadrículado utilizado en este estudio se evaluó de acuerdo con la ecuación (2.2), donde se descartó cada punto cuando estaba por debajo o por encima del 5% de la precipitación mínima y máxima respectiva observada dentro del dominio regional respectivo (Figura 2.1-a). Este procedimiento intenta cubrir áreas donde se descartan las cuadrículas de precipitación del modelado atmosférico (ver 2.3.2). Así, una vez obtenido el mejor conjunto para cada dominio regional, no se buscó superposición de datos con el modelo WRF. De lo contrario, es decir, si se produce superposición, se selecciona el que tiene la menor diferencia en el sesgo de precipitación mínima y máxima de acuerdo con la ecuación (2.2). Nótese que si ni los datos atmosféricos ni los cuadrículados cumplieron con las condiciones de admisibilidad (ec.2.2), estos no son utilizados.

$$f(x) = \begin{cases} P_g, & \text{si } P_{min}^o - 0,05 \times P_{min}^o \leq P_{wrf} \leq P_{max}^o + 0,05 \times P_{min}^o \\ NaN, & \text{si } P_g < P_{min}^o - 0,05 \times P_{min}^o \\ NaN, & \text{si } P_g > P_{max}^o + 0,05 \times P_{max}^o \end{cases} \quad (2.2)$$

donde  $P_g$  es la precipitación de la cuadrícula de cada conjunto en la Tabla (2.2),  $P_g^s$  es la precipitación de la cuadrícula seleccionada del conjunto de precipitación global;  $P_{min}^o$  y  $P_{max}^o$  son la precipitación mínima y máxima de cada subregión, respectivamente. De lo contrario, eliminamos este gridbox.

Conjunto	Nombre y detalle	Fuente	Resolución espacial	Cobertura espacial	Resolución temporal	Cobertura temporal	Referencias
1	TRMM Multi-satellite Precipitation (TMPA) product 3B42 Version 7 <a href="https://mirador.gsfc.nasa.gov/">https://mirador.gsfc.nasa.gov/</a>	Analys S	0,25°	50°N-50°S	3 horas, diaria	1998-presente	(Huffman et al., 2007)
2	Climate Hazards group Infrared Precipitation (CHIRPS) V2.0 <a href="http://chg.ucsb.edu/data/chirps/">http://chg.ucsb.edu/data/chirps/</a>	S,R	0.05°	50°N-50°S	Diaria, Pentadal y mensual	1981-presente	(Funk et al., 2015b)
3	CPC MORPHing (CMORPH) <a href="https://rda.ucar.edu/datasets/ds502.0/">https://rda.ucar.edu/datasets/ds502.0/</a>	S	0.07°, 0.25°	60°N-60°S	3 horas, diarias	Dec presente	(Joyce et al., 2004; Commerce, 2011)
4	Climate Research Unit Time-series version 4.01 <a href="http://www.cru.uea.ac.uk/data">http://www.cru.uea.ac.uk/data</a>	I	0.5°	Global	Mensual	1901-2016	(Harris et al., 2014; Harris et al., 2017)
5	PERSIANN-CDR Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks (PERSIANN) Climate Data Record (CDR) <a href="http://chrs.web.uci.edu/">http://chrs.web.uci.edu/</a>	S,I	0.25°	60°N-60°	Diario	1983 - presente	(Sorooshian et al., 2014; Ashouri et al., 2015)
6	MSWEPv1.2 Multi-Source Weighted-Ensemble Precipitation (MSWEP) v1.2 <a href="http://www.gloh2o.org/">http://www.gloh2o.org/</a>	I,S,R	0.25°	90°N-90°S	Diario	1979-2014	(Beck et al., 2017c)
7	Princeton University Global Meteorological Forcing Version 3 <a href="http://hydrology.princeton.edu/home.php">http://hydrology.princeton.edu/home.php</a>	R,I	0.25°	Global	3 horas	1948-2012	(Sheffield et al., 2006; Peng et al., 2016)
8	SM2RAIN-CCI Rainfall Satellite Soil Moisture CCI <a href="http://hydrology.irpi.cnr.it/download-area/sm2rain-data-sets/">http://hydrology.irpi.cnr.it/download-area/sm2rain-data-sets/</a>	S	0.25°	Global	Diaria	1998-2015	(Brocca et al., 2013; Brocca et al., 2014)

TABLA 2.2: Descripción de las 8 (cuasi) global (sub) conjuntos grillados de precipitación utilizados. Las abreviaciones en la columna FUENTE, definidas como I, S, R son las abreviaciones de los productos derivados: in-situ, Satélite y reanálisis respectivamente. Fuente: elaboración propia.

### 2.3.4 Modelo dinámico topo-climático

Nuestro modelo es una regresión lineal múltiple entre la precipitación como variable dependiente (Swain et al., 2017; Navid et al., 2018; Devi et al., 2020) y las siguientes variables independientes: elevación, pendiente, exposición, continentalidad, latitud, y longitud (Zambrano, 2011; Camera et al., 2014; Cifuentes, 2017). El modelo ajusta los valores observados mediante un procedimiento de mínimos cuadrados entre los valores observados y predichos (Delbari et al., 2019a). La función de dependencia lineal viene dada por

$$P = \alpha + \beta_1 \cdot elev + \beta_2 \cdot exp + \beta_3 \cdot slp + \beta_4 \cdot cont + \beta_5 \cdot lat + \beta_6 \cdot lon \quad (2.3)$$

donde  $\alpha$  es la intercepción, y los valores  $\beta_i, i = 1, \dots, p$  se denominan coeficientes de regresión asociados a las variables elevación (*elev*), exposición (*exp*), pendiente (*slp*), continentalidad (*cont*), latitud (*lat*) y longitud (*lon*).

Para obtener el conjunto de datos cuadrado a 800 m, utilizamos el modelo de elevación digital Shuttle Radar Topography Mission (Farr et al., 2007) con una resolución espacial de 90 m. De este modelo de elevación digital se obtiene un nuevo modelo de elevación a una resolución de 800 m (Figura 2.4). Se debe tener en cuenta, que el dominio del modelo cubre cinco regiones administrativas: O'Higgins, El Maule, Biobío (dividido en Biobío y Ñuble desde 2017), La Araucanía y Los Ríos (Figura 2.1-a). Sin embargo, los dominios corresponden a límites regionales (Figura 2.1-a), junto con un aumento del 25% en la contribución de las regiones vecinas. Con esto aseguramos que se cubran cuencas compartidas entre diferentes regiones. Además, la cobertura mutua entre dominios garantiza una mayor coherencia y homogeneidad de la solución global. Por cada mes, los datos utilizados para la construcción del campo de precipitación cambia según los datos de entrada (Secciones 3.2 y 3.3).

Para cada dominio regional, resolvemos mensualmente el modelo topo-climático, probando diferentes configuraciones de las variables independientes descritas en la ecuación (2.3). Realizamos pruebas en las que se elimina una única variable topográfica o un conjunto de ellas. Así, cada mes se podrán realizar seis factorial, pruebas diferentes. La estructura se prueba mensualmente y, al final del período de 12 años (144 meses), se utiliza el modelo más eficaz como base para el cálculo del coeficiente mensual del modelo topo-climático. Debido a que juega un papel importante en un modelo topo-climático, la elevación es la única variable utilizada en todos los cálculos. De manera similar, las diferentes pruebas indicaron que las variables de elevación y exposición son necesarias para todos los dominios regionales. A continuación, sólo se muestran los

modelos más representativos.

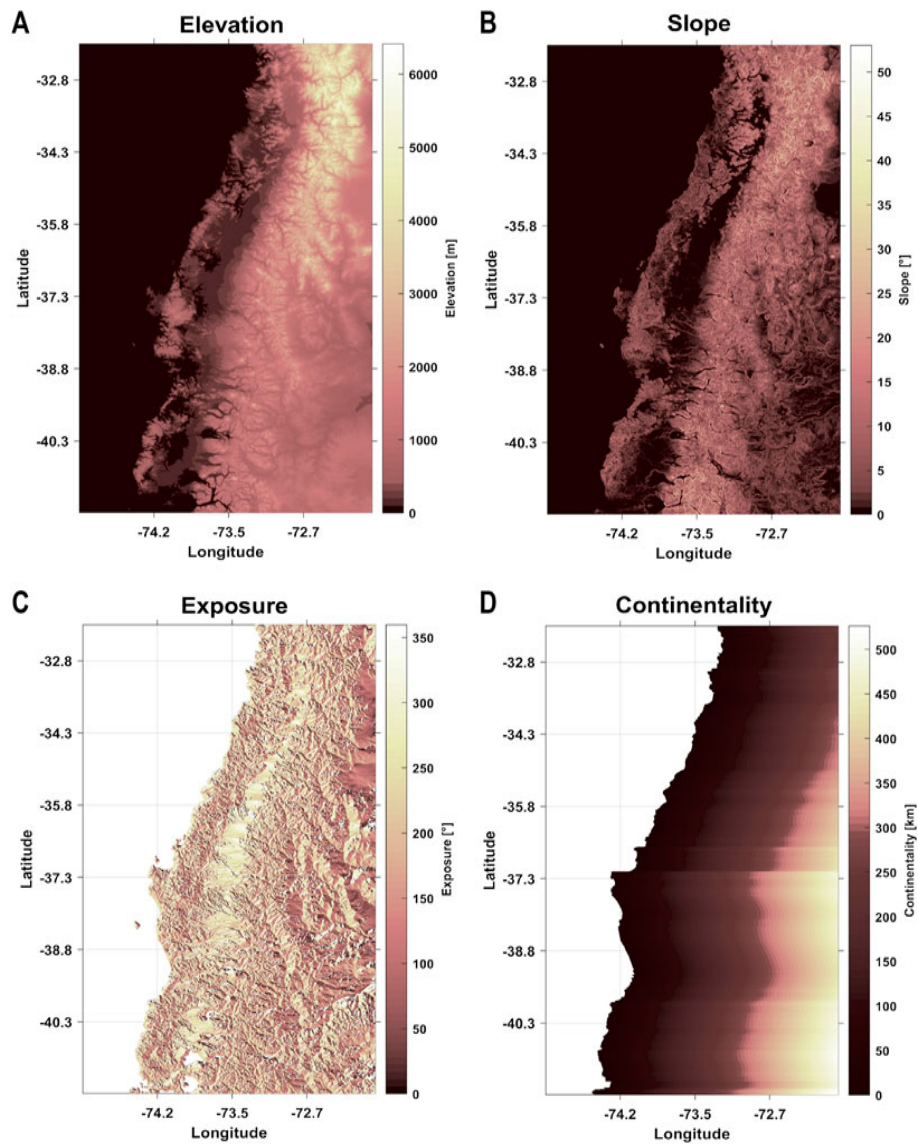


FIGURA 2.4: Variables topográficas utilizadas en el modelo topo-climático: (A) elevación, (B) pendiente, (C) exposición y (D) continentalidad. Fuente: elaboración propia.

Cada modelo desarrollado está etiquetado de acuerdo con las variables de la ecuación (2.3): (*all*), todas las variables; (*wexp*), sin exposición; (*wslp*), sin pendiente; (*wlat*), sin latitud; (*wlon*), sin longitud; y (*wcon*), sin variable de continentalidad. Posteriormente, cada modelo fue evaluado

mediante una prueba de análisis de varianza (ANOVA) y un análisis residual. Usamos diferentes estadísticas para determinar la estructura más apropiada para cada dominio regional, a saber, la desviación estándar estandarizada ( $\sigma_e$ , ec. 2.6), el error cuadrático medio estandarizado ( $nmrse$ , ec. 2.7), el porcentaje del error sistemático estandarizado ( $pbias$ , ec. 2.9), coeficiente de correlación ( $\rho_{xy}$ , ec. 2.8), coeficiente de Nash-Sutcliffe ( $nse$ , ec. 2.10) y coeficiente de Willmott modificado ( $d$ , ec. 2.11).

La Figura (2.5) muestra las tres fases realizadas para la construcción del modelo topoclimático dinámico. La primera fase ( $F_1$ ) determina el número de estaciones de precipitación locales y su posterior selección (Sección 2.3.1). La segunda fase ( $F_2$ ) corresponde al modelo climático que produce campos de precipitación, luego se corrigen su sesgo (Sección 2.3.2) utilizando los datos locales (Sección 2.3.1). La tercera fase ( $F_3$ ) (Sección 2.3.3) selecciona los conjuntos cuadriculados de precipitación global que se utilizan alternativamente para los campos modelados de precipitación ajustados localmente. Finalmente, dentro de la cuarta fase ( $F_4$ ) (Sección 2.3.4), en cada dominio geográfico, las pruebas permiten elegir los coeficientes de las variables (elevación, pendiente, exposición, continentalidad, latitud y longitud) para desarrollar los campos de alta resolución.

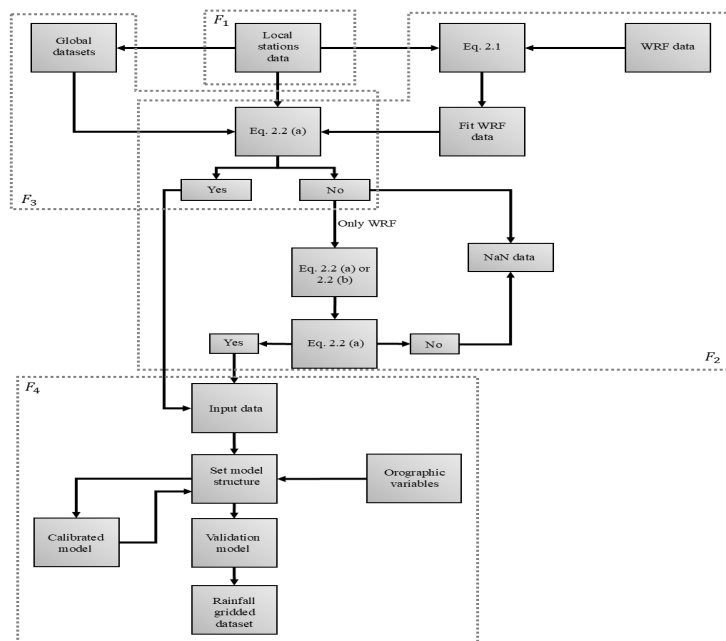


FIGURA 2.5: Descripción esquemática del desarrollo del modelo topoclimático dinámico. Fuente: elaboración propia.

### 2.3.5 Análisis estadístico

Esta sección presenta la estrategia de análisis estadístico necesaria para el proceso de corrección y ajuste del modelo atmosférico, la selección global del conjunto de datos cuadrículados, la calibración y validación del modelo topodinámico y la construcción final del producto cuadrículado de alta resolución.

Para cada dominio regional se analizan el ajuste espacial del modelo, la selección de campos mensuales del modelo WRF y la selección espacial de los mejores productos mensuales de precipitación de la red global (Figura 2.1-a): Los resultados de estos procesos se muestran para ocho cuencas hidrológicas (Figura 2.1-b). Nuestra estrategia utiliza una variedad de estadísticas siguiendo a Cardoso et al., 2013; Ji et al., 2015 y Akhter et al., 2019 : desviación estándar estandarizada ( $\sigma_e$ , ec. 2.6), error cuadrático medio estandarizado ( $nrmse$ , ec. 2.7), coeficiente de correlación ( $\rho_{xy}$ , ec. 2.8), porcentaje del error sistemático estandarizado ( $pbias$ , ec. 2.9), coeficiente de Nash-Sutcliffe ( $nse$ , ec. 2.10) y coeficiente de Willmott modificado ( $d$ , ec. 2.11). Utilizamos seis índices en la comparación de datos porque cada uno de ellos cuantifica sólo un aspecto del acuerdo o desacuerdo de los datos.

Una vez completada la selección de los mejores puntos de la grilla, se construye un modelo topoclimático mensual diferente sobre cada dominio regional. Para este proceso, a una fase de calibración le sigue una fase de validación. Como se indicó anteriormente, utilizamos el 70 % de los datos de lluvia locales (136 estaciones) para la calibración y el 30 % (60 estaciones) para la validación. En ambos procesos, debido a la distribución poco homogénea de las estaciones y a la notoria cobertura inadecuada en zonas montañosas, la distribución espacial de las estaciones locales elegidas intentó maximizar la cobertura homogénea de cada dominio regional.

La calibración del modelo dinámico-topoclimático incluye la aplicación de una prueba ANOVA y los parámetros de bondad de ajuste  $R^2$  (ec. 2.4) y  $R_j^2$  (ec. 2.5) con el respectivo análisis residual. Para la etapa de validación se utilizan los siguientes estadísticos: desviación estándar estandarizada ( $\sigma_e$ , ec. 2.6), error cuadrático medio estandarizado ( $nrmse$ , ec. 2.7), coeficiente de correlación ( $\rho_{xy}$ , ec. 2.8), porcentaje del error sistemático estandarizado ( $pbias$ , ec. 2.9), coeficiente de Nash-Sutcliffe ( $nse$ , ec. 2.10) y el coeficiente de Willmott modificado ( $d$ , ec. 2.11).

También analizamos los resultados utilizando diagramas de Taylor (Taylor, 2001), para visualizar el comportamiento del modelo en relación con las observaciones en términos de la estructura espacial generada por el coeficiente de correlación de Pearson ( $\rho_{xy}$ ), el error cuadrático medio estandarizado ( $nrmse$ ) y la desviación estándar estandarizada absoluta ( $|\sigma_e|$ ). Además, utilizamos diagramas de caja para visualizar las puntuaciones de desviación estándar ( $\sigma_e$ ), el porcentaje de error sistemático medio ( $pbias$ ), el coeficiente de Nash-Sutcliffe ( $nse$ ) y el coeficiente de Willmott modificado ( $d$ ). Estos procesos de calibración y validación se realizan mensualmente, generando así cada mes un modelo topoclimático diferente. Los resultados de calibración y validación aquí presentados corresponden al promedio de todos estos meses. Además, dado que todo el dominio incluye una zona de transición climática, los resultados de las ocho cuencas se resumen en tres subdivisiones: áreas norte, central y sur (Figura 2.1-b). Las estadísticas utilizadas se definen en las siguientes ecuaciones:

$$R^2 = \frac{\sum_{i=1}^n (Y_i - \bar{X})^2}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad (2.4)$$

$$R_j^2 = 1 - \frac{(n-1) \sum_{i=1}^n (X_i - Y_i)^2}{(n-k-1) \sum_{i=1}^n (X_i - \bar{X})^2} \quad (2.5)$$

$$\sigma_e = 1 - \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{\sum_{i=1}^n (X_i - \bar{X})^2}} \quad (2.6)$$

$$nrmse = \frac{\sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{n}}}{\sigma} \quad (2.7)$$

$$\rho_{xy} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (2.8)$$

$$pbias = \frac{\sum_{i=1}^n (X_i - Y_i)}{\sum_{i=1}^n X_i} \times 100 \quad (2.9)$$

$$nse = 1 - \frac{\sum_{i=1}^n (X_i - Y_i)^2}{\sum_{i=1}^n (X_i - \bar{Y}_i)^2} \quad (2.10)$$

$$d = 1 - \frac{\sum_{i=1}^n |Y_i - X_i|}{\sum_{i=1}^n (|Y_i - \bar{X}| + |X_i - \bar{X}|)} \quad (2.11)$$

donde  $X$  e  $Y$  son precipitación observada y simulada, respectivamente.

## 2.4 Resultados

En las Secciones 2.4.1 y 2.4.2, el comportamiento de la precipitación promedio del modelo atmosférico ajustado (ver Sección 2.3.2) y los productos cuadrículados globales seleccionados (ver Sección 2.3.3) se presenta en tres zonas (norte, centro y sur), que cubren ocho cuencas (Figura 2.1-b). Se utilizan todas las estaciones locales (196), y éstas se presentan utilizando diagramas de caja y de Taylor (consulte Sección 2.3.5).

La Sección 2.4.3 presenta los mejores resultados asociados al proceso de calibración del modelo topográfico-climático dinámico dentro de cada dominio regional (Sección 2.4.3) utilizando 132 estaciones de precipitación (Sección 2.3.1). La etapa de validación del modelo elegido utilizando 60 estaciones en la Sección 2.4.3 se presenta para las ocho cuencas (Figura 2.1-b). Esta parte del artículo finaliza mostrando la acumulación anual de la climatología mensual construida.

### 2.4.1 Modelo atmosférico

En la zona norte (Figuras 2.6A-C),  $\rho_{xy}$  muestra un promedio de 0,85, pero podemos apreciar casos atípicos con valores inferiores a 0,65. Mientras tanto,  $nmrse$  muestra acuerdos cercanos a 0,65, aunque todas las cuencas presentan casos superiores a 0,5. Para  $\sigma_e$  (Figura 2.7-A), la concordancia promedio es cercana a 0,1, y Rapel muestra algunos casos por encima de 0,3. Finalmente,  $pbias$  (Figura 2.7-B) da una concordancia promedio del 14 %, presentando Mataquito los valores más bajos ya que el 75 % de las estaciones analizadas se encuentran cercanas al 10 %.

Los resultados para la zona central (Figura 2.6D-E) indican un promedio para  $\rho_{xy}$  de 0,83 y 0,55 para  $nmrse$ , aunque con varios casos muy por encima de 0,65. Para  $\sigma_e$  (Figura 2.7-A), el promedio es 0,14, presentando la cuenca del Biobío valores superiores a 0,25. Para las  $pbias$  (Figura 2.7-B), el promedio del 17 % está marcado por ciertas cuencas que superan el 25 %.

Una buena estimación de  $\rho_{xy}$  caracteriza a la región sur (Figuras 2.6F-G), con un valor promedio de 0,87. Dentro de esta región, Valdivia presenta casos cercanos a 0,6.  $nmrse$  presenta un promedio de 0,56, aunque todas las cuencas tienen casos superiores a 0,7. A su vez,  $\sigma_e$  (Figura 2.7A) muestra un promedio de 0,15, con Imperial y Toltén por encima de 0,3. Finalmente, el  $pbias$  (Figura 2.7-B) muestra un promedio del 9 %. Toltén da la estimación promedio más baja con 7 %.

Mostramos los resultados de  $nse$  y el coeficiente de Willmott ( $d$ ) en todas las regiones (y cuencas) en la Figura 2.7-D. En todas las cuencas el valor promedio de  $nse$  es superior a 0,7;

sólo Rapel y Maule presentan valores menores a 0,6. El coeficiente de Willmott ( $d$ ) muestra valores cercanos a 0,8 en la zona norte (Rapel, Mataquito y Maule) y un valor de 0,75 para la zona central (Itata y Biobío), mientras que para la zona sur (Imperial, Toltén y Valdivia ); el 25 % de las estaciones presentan valores inferiores a 0,75 con una gran dispersión.

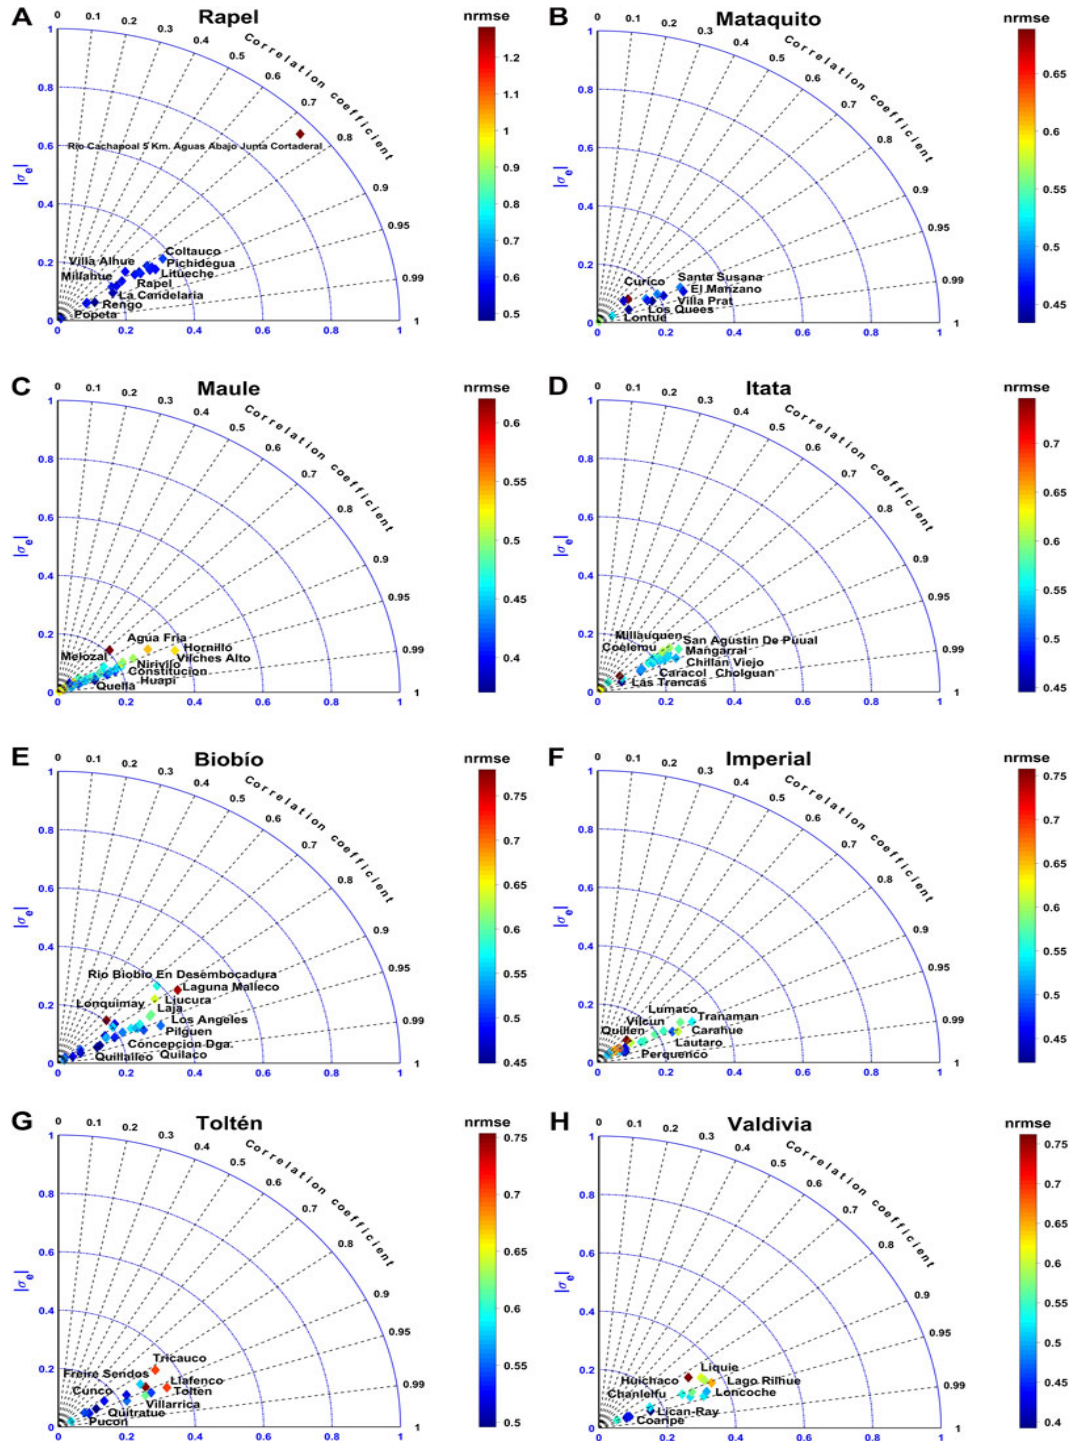


FIGURA 2.6: Diagramas de Taylor correspondientes al desempeño del modelo de investigación y predicción meteorológica (WRF) (Tabla 2.1) una vez ajustados (ec. 2.8) en las cuencas: (A) Rapel, (B) Mataquito, (C) Maule, (D) Itata, (E) Biobío, (F) Imperial, (G) Toltén y (H) Valdivia. Fuente: elaboración propia.

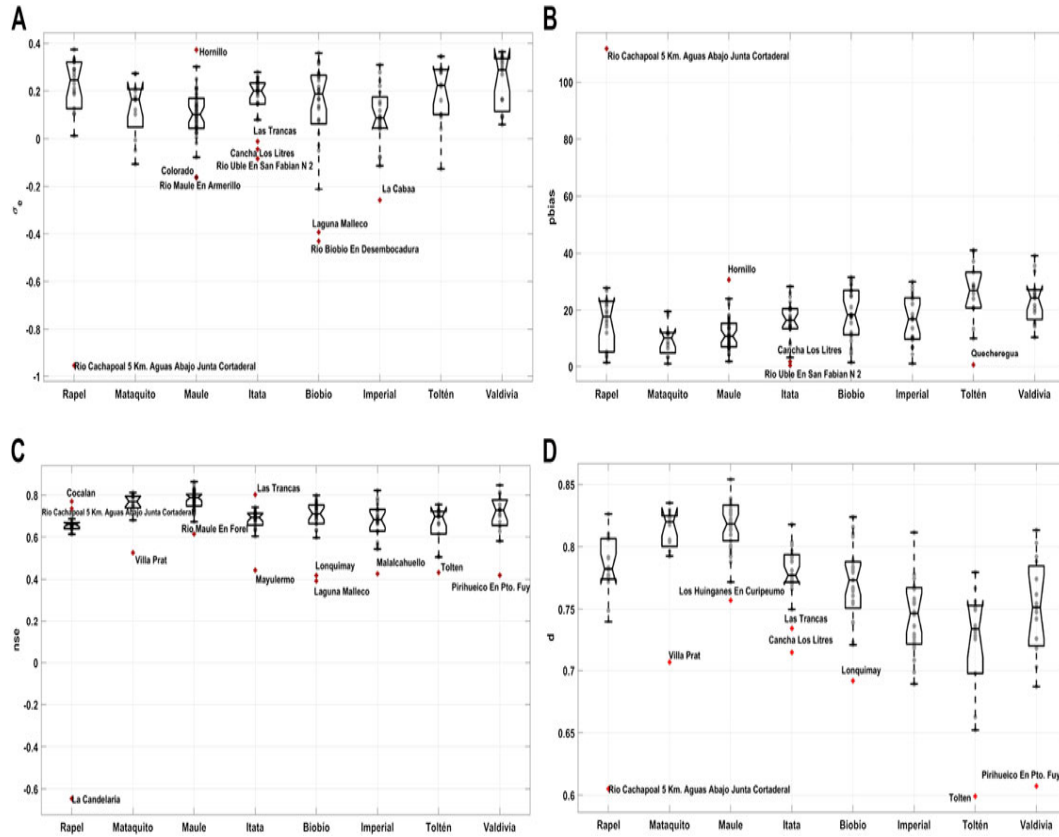


FIGURA 2.7: Diagramas de cajas correspondientes al ajuste del modelo de investigación y predicción meteorológica (WRF), una vez ajustado (ec. 2.1) sobre las cuencas hidrográficas de la zona de estudio (Figura 2.1-b). (A) Desviación estándar estandarizada ( $\sigma_e$ ), (B) porcentaje del error sistemático ( $pbias$ ), (C) coeficiente de Nash-Sutcliffe ( $mse$ ) y (D) coeficiente de Willmott ( $d$ ). Fuente: elaboración propia.

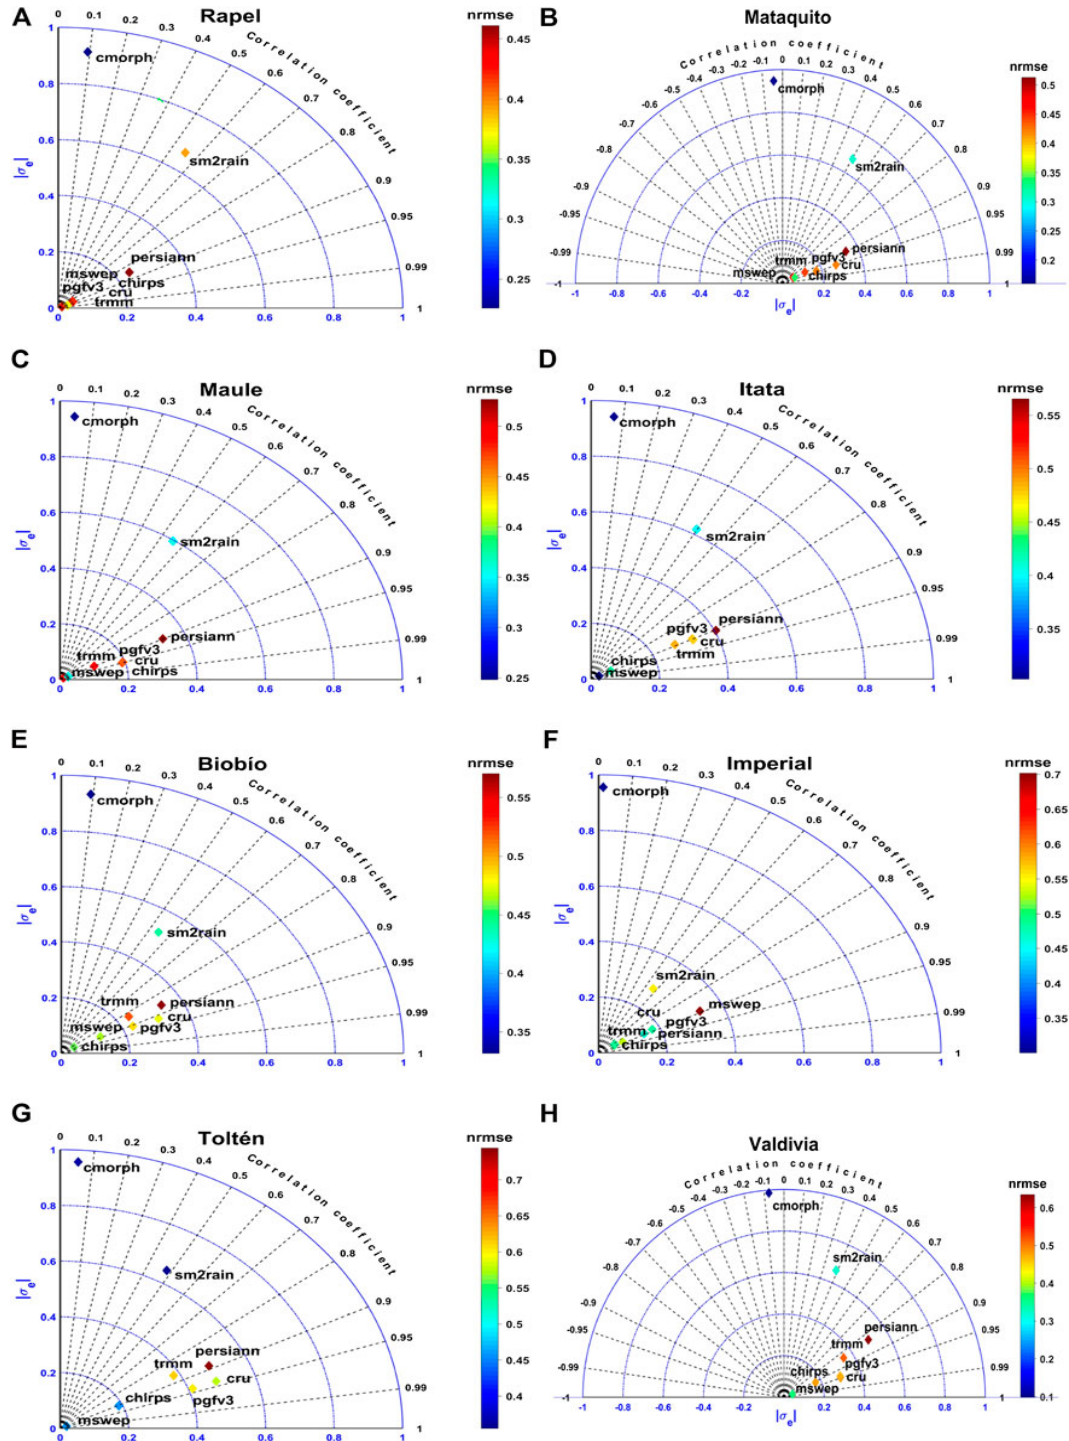


FIGURA 2.8: Diagramas de Taylor correspondientes al desempeño de los conjuntos cuadrículados (Tabla 2.2), una vez ajustado (ec. 2.2) en las cuencas de (A) Rapel, (B) Maule, (C) Itata, (D) Biobío, (E) Imperial, (F) Toltén, (G) Mataquito y (H) Valdivia. Fuente: elaboración propia.

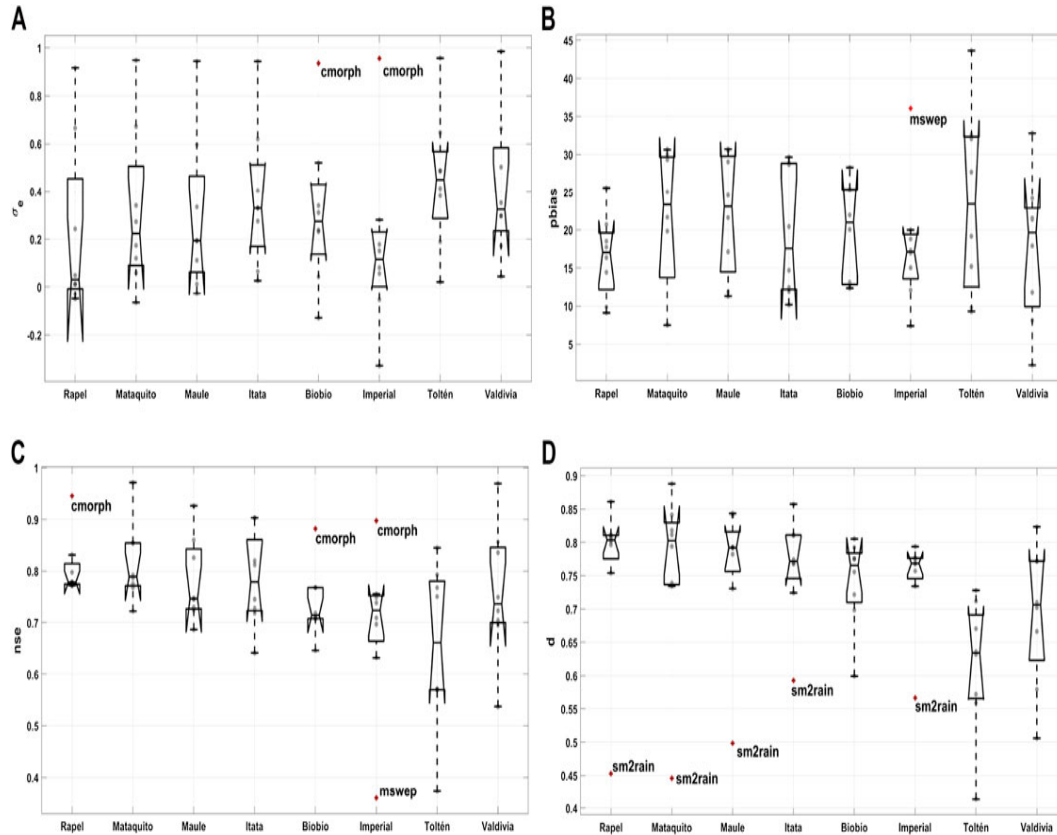


FIGURA 2.9: Diagramas de caja correspondientes al comportamiento de los conjuntos cuadriculados (Tabla 2.2), una vez ajustado (ec. 2.2) en las cuencas hidrográficas del área de estudio (Figura 2.1-b). (A) Desviación estándar estandarizada ( $\sigma_e$ ), (B) porcentaje del error sistemático ( $pbias$ ), (C) coeficiente de Nash-Sutcliffe ( $nse$ ) y (D) coeficiente de Willmott ( $d$ ). Fuente: elaboración propia.

## 2.4.2 Conjuntos globales de precipitación

En la zona norte (Figuras 2.8A-C),  $\rho_{xy}$  presenta un valor promedio de 0,74. Sin embargo, CMORPH y SM2RAIN muestran valores de  $\rho_{xy}$  inferiores a 0,6 en todas las zonas. Las variaciones en  $nrms$  muestran un promedio de 0,4, y Mataquito y Maule muestran 0,5 para el conjunto de datos PERSIAN. Para  $\sigma_e$  el promedio es 0,27, mientras que para CMORPH y SM2RAIN los valores son superiores a 0,6 para toda la zona (Figura 2.9-A). El  $pbias$  (Figura 2.9-B) muestra un promedio del 20 %, con estimaciones anómalas (más del 30 %) en Mataquito y Maule.

Sobre la zona central (Figuras 2.8D-E),  $\rho_{xy}$  presenta un promedio de 0,74. Nuevamente, CMORPH y SM2RAIN muestran los peores resultados para  $\rho_{xy}$ , con puntuaciones inferiores a 0,6. Mientras

tanto,  $nrsme$  da una media de 0,44, aunque toda la zona muestra valores superiores a 0,3. Siguiendo con  $\sigma_e$  (Figura 2.9-A), el promedio es 0,34. Como arriba, CMORPH y SM2RAIN dan estimaciones bastante diferentes en relación con el promedio, superiores a 0,5. Aquí, el  $pbias$  (Figura 2.9-B) muestra un error promedio del 20%, mientras que las estimaciones más altas están por debajo del 30% en las cuencas de Itata y Biobío.

Para la zona sur (Figuras 2.8: F-H),  $\rho_{xy}$  muestra un promedio de 0,73. De forma similar a lo descrito en el párrafo anterior, CMORPH y SM2RAIN muestran los peores resultados con estimaciones para  $\rho_{xy}$  inferiores a 0,6. Un  $nrmse$  alto en todas las cuencas arroja un promedio de 0,48. MSWEP y PERSIAN muestran el  $nrmse$  más alto con valores superiores a 0,6. El  $\sigma_e$  promedio es 0,34, con CMORPH y SM2RAIN por encima de 0,6 (Figura 2.9-A). Mientras tanto, el  $pbias$  (Figura 2.9-B), exhibe un promedio del 20%. En este caso, es importante resaltar que en todas las cuencas los diferentes conjuntos de datos presentan errores superiores al 30%.

Los coeficientes de Nash-Sutcliffe ( $nse$ ) y Willmott ( $d$ ) se muestran para todas las cuencas (Figuras 2.9: C-D). Aquí,  $nse$  muestra un ajuste medio de alrededor de 0,6 desde la cuenca Rapel hasta la cuenca Imperial. Existe un diferencial mayor para Toltén y Valdivia, con mínimos por debajo de 0,55. El coeficiente de Willmott ( $d$ ) muestra una distribución similar desde Rapel hasta Imperial, con casi el 90% de los conjuntos de datos por encima de 0,7. Nuevamente vemos mayor heterogeneidad en las cuencas de Toltén y Valdivia con valores inferiores a 0,5; SM2RAIN muestra el desempeño más débil para todas las cuencas.

### 2.4.3 Modelo dinámico topo-climático de precipitación

#### Análisis de dominios regionales

El ajuste promedio del modelo dinámico topoclimático para cada dominio regional se muestra en la Figura (2.10). El coeficiente de determinación ( $R^2$ ) (Figura 2.10: A) muestra un excelente desempeño del modelo en las regiones de O'Higgins y Biobío con valores superiores a 0,8. Mientras en la región de la Araucanía y de Los Ríos esta muestra valores inferiores a 0,77. El coeficiente de determinación ajustado ( $R_j^2$ ) (Figura 2.10: B), también muestra un buen ajuste (superior a 0,8) desde las regiones de O'Higgins hasta el Biobío; aunque la cuenca del Maule muestra la estimación más baja para  $R_j^2$ . Lo mismo ocurre en las regiones de la Araucanía y Los Ríos. El valor  $F_{value}$  del ANOVA muestra un ajuste excelente del modelo con un valor  $P_{value}$  inferior a 0,05 (Figura 2.10: C). A su vez, el rendimiento promedio del modelo para  $\rho_{xy}$  es superior a 0,9 en todos los dominios (Figura 2.10: H). También encontramos un  $pbias$  promedio inferior al 22%, con

O'Higgins y Biobío por debajo del 15 % (Figura 2.10: F). Los valores atípicos identificados para  $\sigma_e$  (Figura 2.10: G) muestran un error inferior a 0,22, lo que respalda que el modelo es hábil. Por su parte,  $nrmse$  (Figura 2.10: E) muestra valores promedio del modelo inferiores a 0,4; mientras que valores superiores a 0,48 se muestran en la Araucanía y Los Ríos. En estas regiones, un error alto confirma que el modelo es más incierto al estimar eventos de precipitación extrema. La Tabla (2.3) muestra los resultados de la configuración del modelo calibrado ( $R^2$ ,  $R_j^2$ ,  $F_{value}$  y  $P_{value}$ ) y la estimación del error ( $\sigma_e$ ,  $nrmse$ ,  $pbias$  y  $\rho_{xy}$ ) para cada dominio regional.

Región	Modelo	$R^2$	$R_j^2$	$F_{value}$	$P_{value}$	$\sigma_e$	$nrmse$	$pbias$	$\rho_{xy}$
O'Higgins	<i>wslp</i>	0,86	0,855	298,77	$1,10 \times 10^{-29}$	5	0,35	11,99	0,94
Maule	<i>wcon</i>	0,829	0,823	221,00	$1,40 \times 10^{-31}$	6	0,38	20,9	0,94
Biobío	<i>wcon</i>	0,848	0,843	218,93	$1,30 \times 10^{-22}$	10	0,39	13,96	0,93
Araucanía	<i>all</i>	0,747	0,736	121,35	$6,30 \times 10^{-26}$	9	0,48	19,84	0,92
Ríos	<i>wcon</i>	0,757	0,748	155,13	$4,10 \times 10^{-24}$	19	0,5	18,81	0,95

TABLA 2.3: Resumen estadístico del tipo de modelo topo-climático elegido por el ámbito político de cada región. (*wslp*), (*wcost*), (*all*), (*wcon*). O'Higgins se construye con un modelo sin pendiente (*wslp*), Maule y Biobío (antiguo) con un modelo sin continentalidad (*wcon*), Araucanía mediante un modelo con todas las variables descriptivas (*all*), y Los Ríos mediante un modelo con continentalidad (*wcon*). Fuente: elaboración propia.

### Análisis de zonal y de cuencas

La zona norte (Figuras 2.11: A-C) muestra un  $\rho_{xy}$  promedio de 0,88, aunque algunas estaciones de Rapel obtienen valores cercanos a 0,6. En tanto, la  $nrmse$  exhibe un promedio de 0,46, aunque en Rapel y Maule algunos casos están por encima de 0,55. Curiosamente,  $\sigma_e$  (Figura 2.12: A) muestra un ajuste promedio de 0,07, siendo el de Maule inferior a  $-0,4$ . La Figura 2.12: B, muestra un ajuste de  $pbias$  promedio de 18 %, pero Rapel y Maule muestran la diferencia más considerable con una estimación superior al 50 %.

La zona central (Figuras 2.11: D-E),  $\rho_{xy}$  muestra un promedio de 0,89 y Biobío exhibe valores inferiores a 0,8. El  $nrmse$  muestra un promedio de 0,52, mientras que Biobío muestra un valor irregular mayor a 1. El promedio para  $\sigma_e$  es 0,1 (Figura 2.13: A) estando solo Biobío por debajo de  $-0,5$ . Para los  $pbias$  (Figura 2.12: B) hay un error promedio del 24 % y Biobío muestra una estimación inferior al 100 %.

La zona sur (Figuras 2.11: F-H) exhibe un  $\rho_{xy}$  promedio superior a 0,9, mientras que las estimaciones más bajas están por encima de 0,85.  $nrmse$  muestra un promedio de 0,52, y todas las cuencas tienen algunos valores superiores a 0,66.

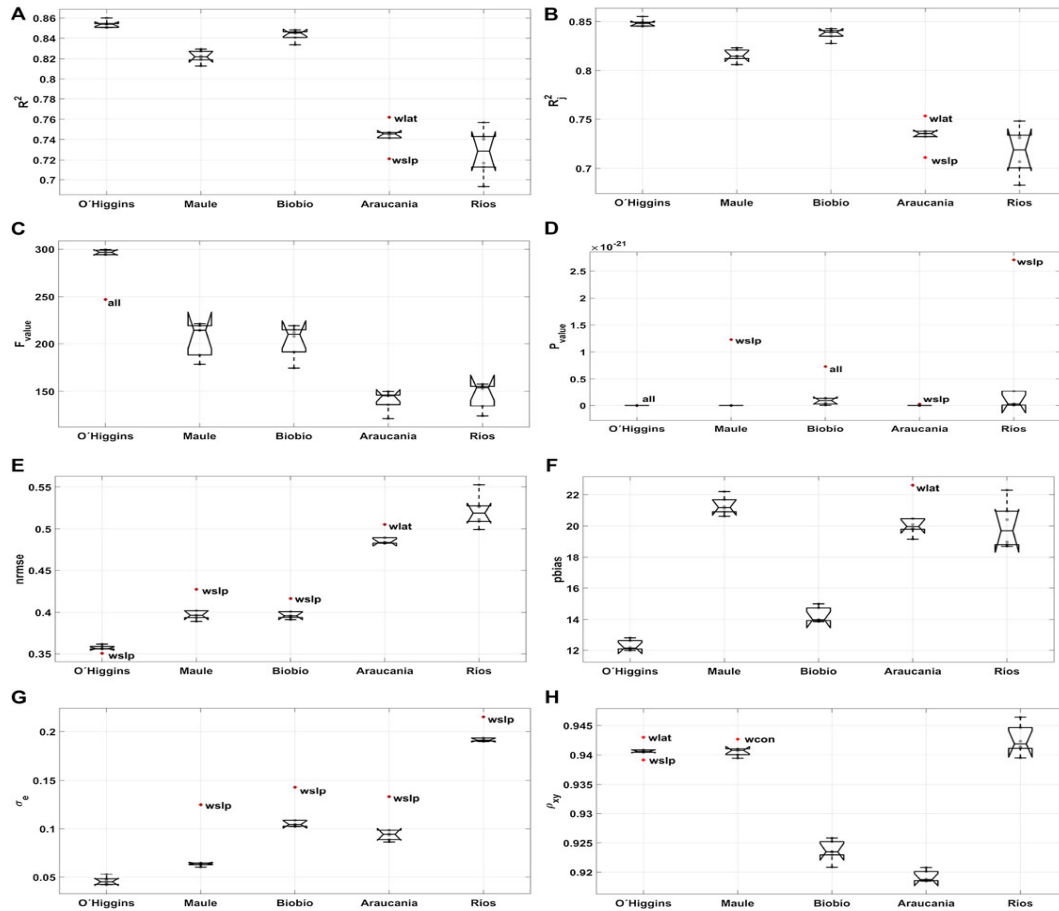


FIGURA 2.10: Diagramas de caja correspondientes al ajuste del modelo dinámico topo-climático sobre los dominios en ejecución. (A) Coeficiente de determinación múltiple ( $R^2$ ), (B) coeficiente de determinación múltiple ajustado  $R^2_a$ , (C) valor  $F$ , (D) valor  $P$ , (E) error cuadrático medio estandarizado ( $nrmse$ ), (F) porcentaje de error sistemático ( $pbias$ ), (G) desviación estándar estandarizada ( $\sigma_e$ ), (H) coeficiente de correlación de Pearson ( $\rho_{xy}$ ). Fuente: elaboración propia.

Por otro lado, mientras  $\sigma_e$  (Figura 2.12: A) muestra un promedio de 0,1, sólo la cuenca Imperial exhibe una estimación baja de  $-0,2$ . El  $pbias$  (Figura 2.12: B) muestra un promedio del 24%. El  $nse$  muestra un promedio superior a 0,7 en todas las cuencas (Figura 2.12: C); sólo se detectan dos casos atípicos en Maule y Biobío con valores de 0,5 y  $-1$ , respectivamente. Por otro lado,  $d$  (Figura 2.12: D) muestra un ajuste promedio de 0,75. Sólo Biobío presenta un valor atípico en la

estación Liucura con un valor inferior a 0,5.

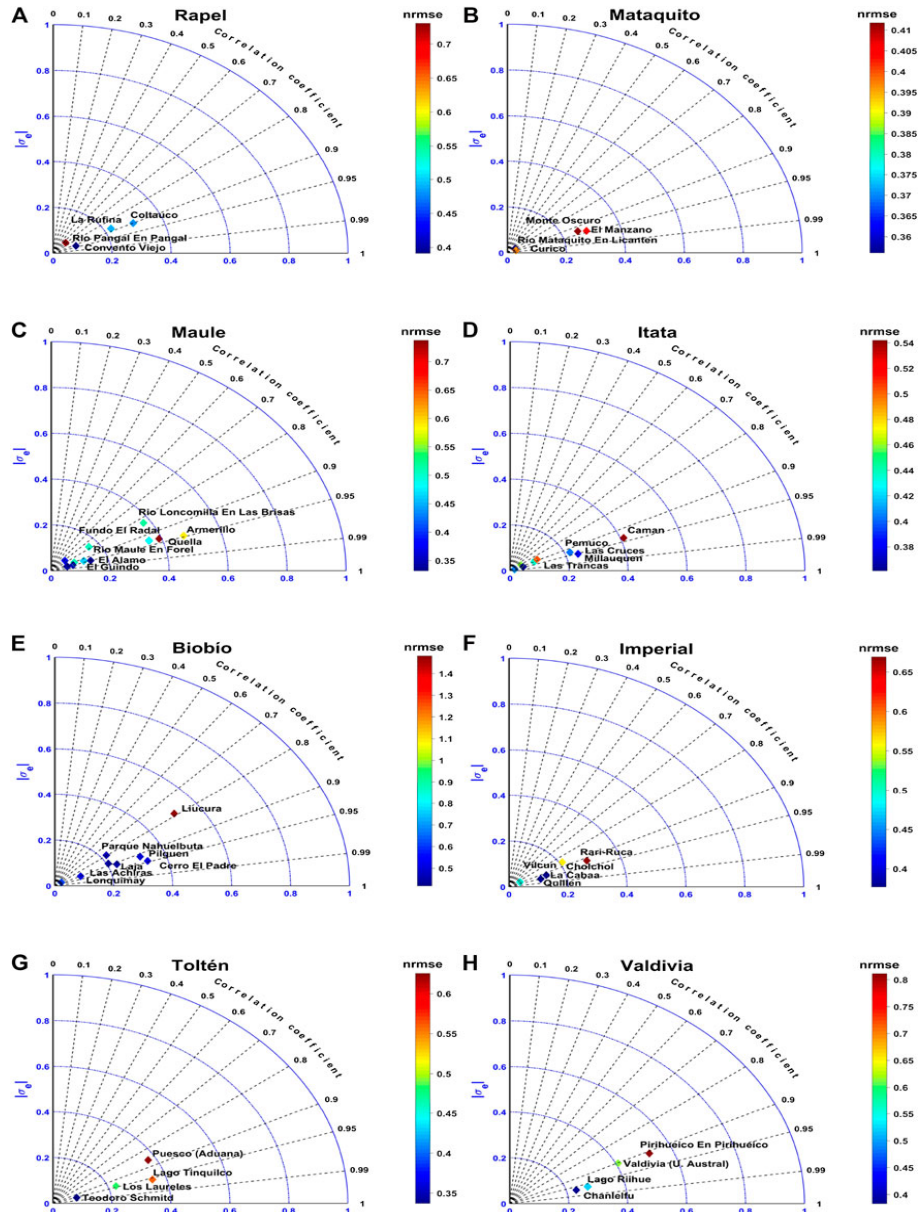


FIGURA 2.11: Diagramas de Taylor correspondientes al desempeño del modelo dinámico topoclimático en las cuencas de los ríos (Figura 1B): (A) Rapel, (B) Mataquito, (C) Maule, (D) Itata, (E) Biobío, (F) Imperial, (G) Toltén y (H) Valdivia. Fuente: elaboración propia.

En cada dominio regional, se ajusta un modelo mensual diferente a los datos de calibración y se verifica mediante puntos de validación. Esto nos permite construir una solución mensual para cada dominio regional, entregando un conjunto de datos de campos mensuales que cubren el período 2000 – 2011 que posteriormente se utilizan para producir climatologías mensuales de enero a diciembre. La Figura (2.13) muestra la precipitación anual acumulada observada y la obtenida por el modelo dinámico topoclimático sobre el área de estudio ( $34^{\circ}\text{S} - 41^{\circ}\text{S}$ ). La Figura (2.13-b) indica una distribución adecuada de la precipitación de norte a sur y del océano a los Andes. Hay un aumento progresivo de norte a sur y aumentos drásticos en las zonas montañosas, particularmente a lo largo de los Andes y la cordillera costera. Así, en sectores cercanos a la costa (a partir de  $38^{\circ}\text{S}$ ), se identifica una precipitación anual abundante, llegando en ocasiones a superar los 2000  $\text{mm}$ . En todas las zonas andinas, las precipitaciones anuales acumuladas pueden alcanzar y superar los 3000  $\text{mm}$  anuales. Finalmente, entre la costa y los Andes por debajo de  $36^{\circ}\text{S}$ , es posible identificar una disminución en la precipitación anual.

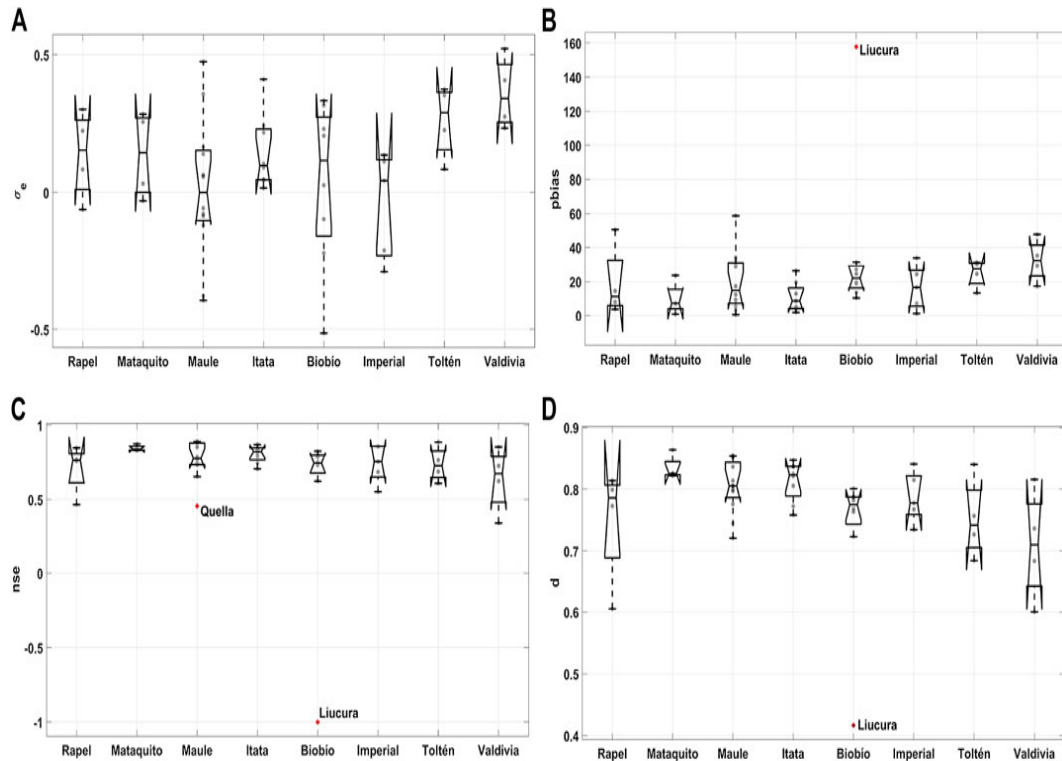


FIGURA 2.12: Diagramas de caja correspondientes al ajuste del modelo dinámico topo-climático sobre los dominios en ejecución. (A) Desviación estándar estandarizada ( $\sigma_e$ ), (B) porcentaje del error sistemático ( $pbias$ ), (C) coeficiente de Nash-Sutcliffe ( $nse$ ) y (D) coeficiente de Willmott ( $d$ ). Fuente: elaboración propia.

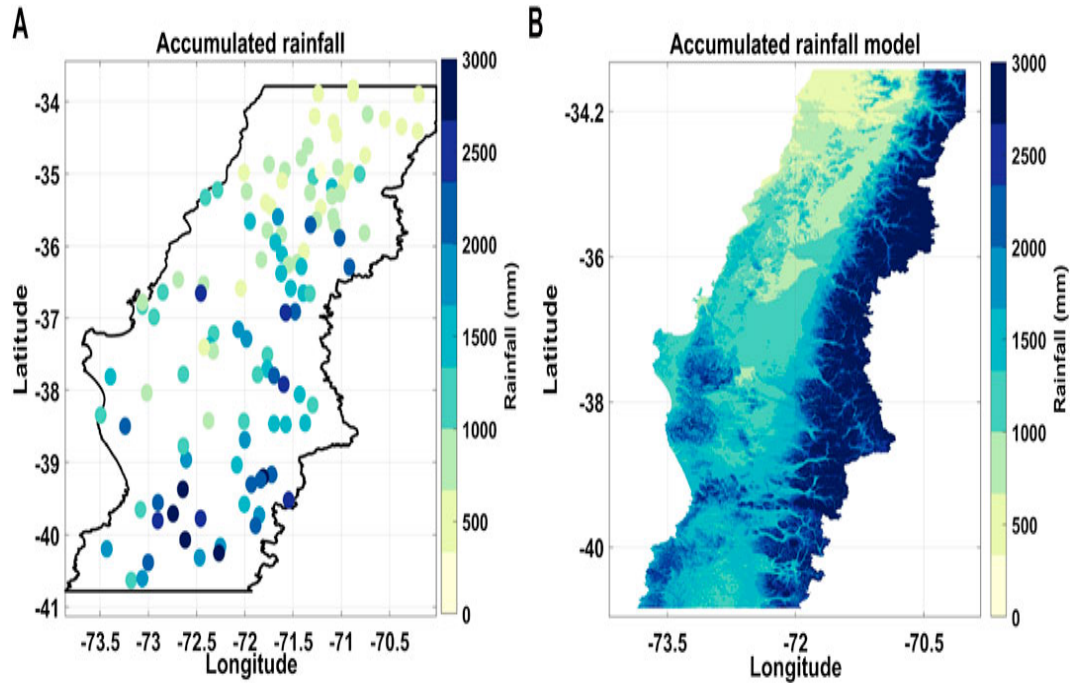


FIGURA 2.13: Precipitación acumulada anual del modelo topo-climática. (A) Precipitaciones observadas y (B) modelo dinámico topo-climático. Fuente: elaboración propia.

## 2.5 Discusión y conclusión

La variabilidad espacial de las precipitaciones de alta resolución es significativa en diferentes campos como la hidrología, el medio ambiente, la silvicultura y la agricultura. En Chile, varios autores trabajaron en conjuntos de datos de precipitación cuadrículados construidos únicamente con la información disponible de estaciones locales en algunas áreas del país (Neira Román, 2010; Jacquin et al., 2013; I., 2013; Castro et al., 2014; Sijinaldo, 2015). Además, en algunos casos, los conjuntos de datos se generaron a partir de datos observados y datos cuadrículados de baja resolución superior a 0,25 (Morales-Salinas et al., 2012) o incluso conjuntos de datos de peor calidad. Por lo tanto, estos conjuntos de datos de alta resolución son inadecuados para estudiar grandes áreas y/o todo el país. Además, la insuficiente distribución espacial de la red pluviométrica (Muñoz et al., 2018) impide un impacto hidroclimático real en las condiciones ambientales actuales.

Por lo tanto, afirmamos que el conjunto de datos será útil para diferentes comunidades en

Chile. Será de utilidad para la planificación agrícola, forestal y ganadera, por ejemplo, y para instituciones nacionales como la Dirección General de Aguas (DGA), el Instituto de Investigaciones Agropecuarias (INIA) y el Instituto Forestal de Chile (INFOR). entre otros. Este producto puede servir como base de comparación para estudios destinados a investigar futuros cambios climáticos o agrícolas (Muñoz et al., 2018), permitiendo investigar el papel de la Oscilación Antártica y muchos fenómenos climáticos en algunos aspectos locales relacionados con las precipitaciones (Fustos et al., 2020b), que está más allá del alcance de este estudio.

Para obtener un conjunto de datos mejorado y cuantificar la precipitación, construimos un producto de precipitación cuadrículado estadístico dinámico de alta resolución a aproximadamente 800 m. Su desarrollo involucró series temporales de precipitación local y diferentes conjuntos de cuadrículas de precipitación global (como se muestra en la Tabla 2.2). Para detectar la variabilidad espacio-temporal de la precipitación, realizamos modelos numéricos de la atmósfera en el área de estudio con una resolución espacial de 4 km para el período 2000-2011. Estos productos son una poderosa herramienta para la reducción de escala estadística (Widmann et al., 2003; Schmidli et al., 2006; González-Rojí et al., 2019). Además, dentro de cada región, según las ecs. (2.1) y (2.2) requisitos, realizamos una selección de datos mes a mes. También evaluamos series temporales de precipitación pertenecientes a ocho cuencas para estimar las respuestas de los mejores productos que ingresaron a nuestro modelo topoclimático dinámico (Figura 2.11).

Evaluamos algunas cuadrículas de precipitación y los resultados se presentan en la Tabla (2.2). Para clasificar las estimaciones óptimas de precipitación y reducir la incertidumbre, utilizamos un criterio de selección (ec. 2.2). Como muestran Zambrano et al., 2016 y Zambrano, 2011, el desempeño de muchos es insatisfactorio. Los productos CHIRPS, MSWEP y PGFv3 muestran las estimaciones más precisas ( $\rho_{xy} > 0,8$ ). Mientras tanto, CMORPH y SM2RAIN proporcionan el peor desempeño en toda el área de estudio ( $< 0,6$ ), y el promedio de  $\sigma_e$  muestra una distribución similar en todas las cuencas. Sin embargo, el conjunto CMORPH presenta los mayores desajustes, con estimaciones cercanas a 1 en Biobío e Imperial. El pbias muestra una distribución similar a lo largo de todas las cuencas entre 10 y 30 %. El coeficiente de Nash-Sutcliffe ( $nse$ ) muestra un rendimiento decreciente de Rapel a Itata ( $> 0,7$ ) junto con una dispersión creciente. Por ejemplo, en Biobío e Imperial el ajuste se centra en 0,7 con baja dispersión. Asimismo, Toltén y Valdivia tienen un promedio de 0,7, pero con alta dispersión. Por otro lado, Willmott ( $d$ ) no muestra una mejora en el rendimiento de los conjuntos de datos, aunque muestra un patrón similar a  $nse$  ( $> 0,7$ ). Para todas las cuencas, observamos que SM2RAIN muestra valores bajos. Sin embargo, los resultados del ajuste del modelo para algunos conjuntos de datos deben considerarse con

cautela, ya que eliminamos cualquier valor por encima o por debajo del 5 % de la precipitación máxima o mínima observada respectiva. Por tanto, los datos limpios mejoran las estimaciones de estos conjuntos.

Los modelos dinámicos atmosféricos, como el WRF, simulan la precipitación basada en procesos convectivos y de gran escala (como la precipitación de frentes de cumulonimbus o nubes), generando una mejor distribución de la precipitación así como de otros campos como la temperatura (Pope et al., 2002; Jung et al., 2006; Gent et al., 2010). Sin embargo, todavía existen errores atribuidos a procesos de retroalimentación, que no necesariamente se reducen al aumentar la resolución espacial del modelo. Como estos errores son pronunciados en terrenos accidentados, y más aún en zonas montañosas, para tener en cuenta esa posibilidad fue necesario añadir una corrección del 5 %. A pesar de esto, la densidad limitada de observación a lo largo de los Andes incorpora un alto grado de incertidumbre, lo que impide un ajuste homogéneo, lo que dificulta la construcción de un modelo correcto a gran altitud. Los diagramas de Taylor y boxplot muestran que el modelo presenta un desempeño notable en la zona norte (Figuras 2.6, 2.7). En lo que respecta a la zona central, nuevamente se obtiene un ajuste adecuado para  $\rho_{xy}$ ,  $nse$  y  $d$ .

Para construir nuestro modelo geoestadístico dinámico, utilizamos cuadrículas de precipitación global y un modelo atmosférico local (Tabla 2.2), además de dominios regionales (Figura 2.1: B). Este es un proceso no trivial, particularmente en regiones con una gran variedad de patrones espacio-temporales (Gent et al., 2010). Durante la fase de reconstrucción de la precipitación, verificamos los coeficientes de elevación relativos a cada dominio regional con información local disponible. Para las montañas, la poca información local disponible impide la corrección y ajuste adecuado del modelo WRF o de los datos cuadrículados. En consecuencia, en las zonas altas, las precipitaciones generalmente deben sobreestimarse. Cada mes, el ajuste proporciona diferentes coeficientes de elevación para cada dominio regional. Sin embargo, para todo el dominio, la solución que impuso un único coeficiente de elevación, considerando toda la información de norte a sur, resultó ser la mejor.

Los resultados del modelo elegido para cada región (Tabla 2.3) muestran una habilidad razonable en las cuencas evaluadas (Figuras 2.11, 2.12). Sin embargo, el modelo no puede representar satisfactoriamente los eventos de precipitación extrema, que aumentan gradualmente de norte a sur. Es fundamental señalar que la elección del modelo de regresión está condicionada por la selección de los datos de entrada y el dominio utilizado. Sólo la modelización numérica y

la información satelital son las que proporcionan una cobertura y persistencia espacial adecuada. A su vez, la reducción de escala estadística puede mejorar la precisión de las mediciones meteorológicas discretas (Diez et al., 2005; Fernández-Ferrero et al., 2009; Le Roux et al., 2018; González-Rojí et al., 2019). Hasta donde sabemos, este tipo de estudios es escaso en Chile, no sólo en la construcción de datos climáticos grillados sino también en el análisis y comparación de diferentes metodologías para un modelo estadístico óptimo de reducción de escala o el tipo de dominio necesario para llevarlo a cabo.

La base de datos presentada en este estudio es el resultado de un modelado atmosférico, corregido, ajustado y trasladado a una resolución más alta mediante un método topoclimático dinámico utilizando datos de estaciones meteorológicas locales y campos satelitales. Tenga en cuenta que para mejorar la precisión de la selección de la base de datos mediante diferentes metodologías estadísticas, inspeccionamos visualmente cada conjunto de datos en detalle y mes a mes. Sin embargo, todavía dependemos de la calidad de los modelos atmosféricos, que no son la realidad, y de la calidad de los campos satelitales y de los datos locales. Por ello, queremos señalar que si bien confiamos en que el método utilizado y la resolución permitirán una mejor comprensión de la variabilidad hidrológica local, esta base de datos no reemplaza la realidad. Es por eso que, a diferencia de varias bases de datos cuadrículadas globales, que no lo estipulan, recomendamos comparar dentro de cada cuenca los datos locales y corregir cualquier sesgo existente.

Por supuesto, todavía quedan muchas mejoras por hacer. Tenga en cuenta que siempre estaremos dependiendo de la distribución de la red meteorológica local, que es la única que permite el proceso de calibración y validación. Es fundamental mejorar la calidad de los registros *insitu* en muchas regiones es fundamental, especialmente en las laderas de la Cordillera de la Costa y de los Andes, donde la cobertura climática es casi inexistente. La distribución irregular de estaciones *insitu* en diferentes altitudes, utilizada para construir campos grillados de variables climáticas, puede no representar los diferentes procesos atmosféricos y climáticos que ocurren en ambas cordilleras, a veces separadas por menos de 100 *km*. Por tanto, se necesitan campañas de medición específicas para apoyar, por ejemplo, la calibración del modelo durante períodos breves y a escala local. Sin embargo, muchos fenómenos a lo largo de Chile se desarrollan con altas frecuencias, donde el valor mensual no permite una descripción correcta (Fustos et al., 2020a). Así, si bien es necesario ampliar la cobertura espacio-temporal, de norte a sur y hasta 2020, además de construir otras grillas de alta resolución de parámetros hidroclimáticos esenciales (como

la temperatura), también es imperativo centrarse en los productos de la grilla diaria.

## Capítulo 3

### Modelo estadístico de reducción de escala diaria adaptativo (DA-SDM) para eventos de precipitación extrema

#### 3.1 Introducción

En las últimas décadas, la frecuencia, magnitud y duración de los fenómenos meteorológicos extremos ha aumentado, aunque su ocurrencia no es uniforme en todo el mundo (Trenberth, 2011; Seneviratne et al., 2012; Vicuña et al., 2013; Donat et al., 2016; Fischer et al., 2016; Fowler et al., 2021; Lagos-Zúñiga et al., 2024b). Algunas regiones son particularmente sensibles a los cambios climáticos extremos (Stocker, 2014; Ali et al., 2019). Entre estos fenómenos, las precipitaciones extremas se destacan como un indicador altamente sensible de la variabilidad climática local y del cambio climático (O'Brien et al., 2008; Pal et al., 2009; Chiew et al., 2010; Im et al., 2010; Lavers et al., 2010; Pham et al., 2021). A pesar de su importancia, las características espaciales, temporales y físicas de la precipitación son sumamente complejas, lo que hace que su simulación y proyección sea un desafío persistente en el modelado climático (Pham et al., 2021). En particular, la precipitación diaria es notoriamente difícil de predecir debido a su pronunciada variabilidad espacial y temporal, caracterizada por distribuciones sesgadas y no gaussianas (Rashid et al., 2015; Liu et al., 2019; Pham et al., 2021; Wang et al., 2021; Şan et al., 2023).

Las características orográficas y climáticas únicas de Chile amplifican estos desafíos. Influenciado por el Océano Pacífico, la continentalidad, la proximidad a la Amazonia, los vientos del oeste en el sur y la Corriente de Humboldt impulsada por la Alta Presión Subtropical del Pacífico Sur, Chile experimenta un sistema climático complejo y altamente variable (Sarricolea et al., 2017; Araya-Osses et al., 2020a; Martínez-Retureta et al., 2021). Esta variabilidad se intensifica aún más por los gradientes de temperatura reducidos entre los polos y las latitudes medias, que disminuyen la disponibilidad de energía para los sistemas de baja presión a gran escala al tiempo que aumentan el potencial de precipitaciones convectivas extremas (Gertler et al., 2019; Eingrüber et al., 2022). Además, los modos climáticos tropicales como la Oscilación Madden-Julian, la

Oscilación Decadal del Pacífico y El Niño-Oscilación del Sur desempeñan un papel importante al influir en la variabilidad de las precipitaciones en la región (Garreaud, 2009; Barrett et al., 2012; Juliá et al., 2012; Rondanelli et al., 2019; Schumacher et al., 2020b; Aceituno et al., 2021a; Lagos-Zúñiga et al., 2024b).

La observación y proyección de datos de precipitación se basa en herramientas como los Modelos Climáticos Globales y Regionales (GCM y RCM), Reanálisis Atmosférico (RA), Radars Meteorológico (RM) y observaciones satelitales (SO). Si bien se utilizan ampliamente, estas herramientas tienen limitaciones notables en regiones con topografía compleja. Los GCM y RCM a menudo sufren parametrizaciones inadecuadas que perjudican su capacidad para representar dinámicas sinópticas y convectivas (Roads, 2003b; Ebert et al., 2007b; Kidd et al., 2013b; Alvial Vásquez et al., 2020). De manera similar, los sistemas RM enfrentan desafíos como el bloqueo topográfico y la canalización del haz (Young et al., 2000; Krajewski et al., 2002; Beck et al., 2017d; Chua et al., 2020; Germann et al., 2022), y los conjuntos de datos SO a menudo subestiman la precipitación en áreas montañosas o regiones con nieve y hielo (Dinku et al., 2007; Kidd et al., 2011b; Laviola et al., 2013b; Pipunic et al., 2015; Beck et al., 2017d; Chua et al., 2020).

Para abordar estas limitaciones se utilizan métodos de reducción de escala, clasificados en enfoques estadísticos (SD) y dinámicos (DD). (Sachindra et al., 2016; Kofidou et al., 2023). Si bien los RCM proporcionan simulaciones climáticas locales sólidas, son computacionalmente costosos y están limitados por la configuración del dominio, lo que obliga a la calidad de los datos y a su capacidad para resolver procesos a escala fina (Giorgi et al., 2009b; Seager et al., 2010b; Caron et al., 2011b; Feser et al., 2011b; White et al., 2013b; Xu et al., 2019b; Adachi et al., 2020b). Por el contrario, los métodos SD son más eficientes y se aplican ampliamente en estudios hidrológicos, generalmente clasificados en funciones de transferencia, generadores climáticos y patrones climáticos según los datos y la metodología empleada (Klein et al., 1974b; Fowler et al., 2007; Maraun et al., 2010; Chen et al., 2010; Tavakol-Davani et al., 2013; Chen et al., 2014b; Ekström et al., 2015b; Hou et al., 2017; Beck et al., 2017b).

Este estudio tiene como objetivo generar campos de precipitación de alta resolución ( $\sim 1 \text{ km}$ ) para eventos diarios extremos e identificar los impulsores geofísicos clave de estos episodios utilizando un método multivariado estadístico-adaptativo. Centrado en la región centro-sur de Chile (Figura 3.1-a) durante 2006, el artículo está organizado de la siguiente manera: la Sección 3.2 describe el clima y la topografía regional; la Sección 3.3 detalla el modelo dinámico-estadístico y la base de datos utilizados; la Sección 3.4 presenta los resultados; y la Sección 3.5 analiza la

solidez del modelo y extrae conclusiones.

## 3.2 Área de estudio

Este estudio se centra en el centro-sur de Chile, específicamente en las regiones entre el Maule y Los Ríos (Figura 3.1-a). Esta área alberga a más de 8 millones de habitantes, lo que representa casi la mitad de la población del país, e incluye actividades económicas clave y ciudades importantes. El clima de la región se caracteriza por una importante variabilidad interanual de las precipitaciones, impulsada por su posición de transición entre zonas de temperatura subtropicales y de alta latitud (Quintana, 2004b; Le Quesne et al., 2009b; Aceituno et al., 2021b; Garreaud et al., 2024).

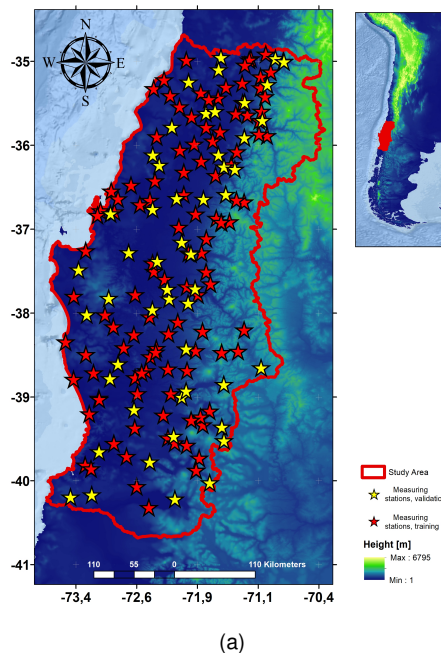


FIGURA 3.1: Área de estudio: centro-sur de Chile. (a) Zona de interpolación entre las regiones de O'Higgins y Los Ríos. Las estrellas amarillas y rojas representan las 171 estaciones utilizadas durante el período de mayo a agosto de 2006; (b) Distribución latitudinal y longitudinal de las estaciones de precipitación en Chile, incluyendo el período de mayo a agosto de 2006.

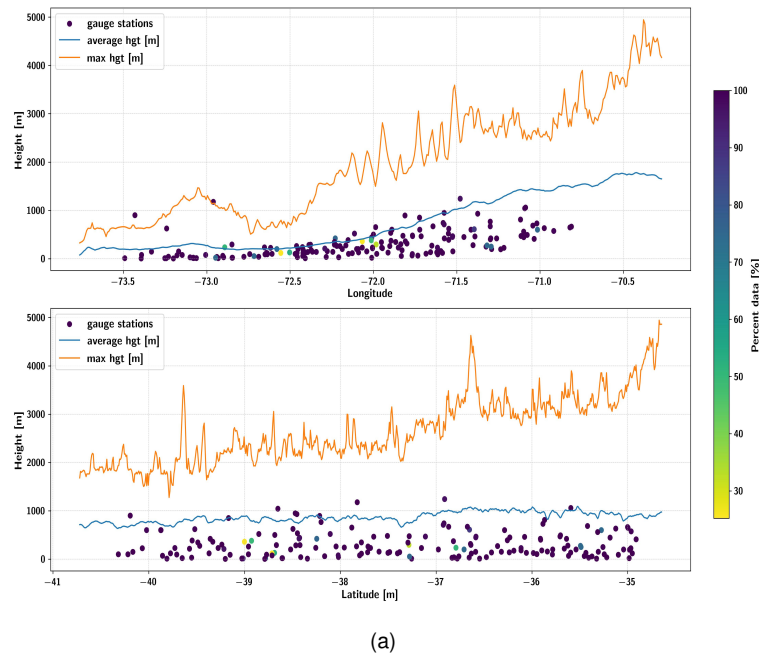


FIGURA 3.1: Área de estudio: centro-sur de Chile. (a) Zona de interpolación entre las regiones de O'Higgins y Los Ríos. Las estrellas amarillas y rojas representan las 171 estaciones utilizadas durante el período de mayo a agosto de 2006; (b) Distribución latitudinal y longitudinal de las estaciones de precipitación en Chile, incluyendo el período de mayo a agosto de 2006.

El territorio continental de Chile exhibe una amplia gama de condiciones hidroclimáticas, desde zonas extremadamente áridas en el norte hasta áreas extremadamente húmedas en el sur. La precipitación anual aumenta significativamente desde 100 mm en las áreas del norte cerca de los 30° S hasta 3000 mm en las regiones del sur cerca de los 40° S (Quintana et al., 2011; Pizarro et al., 2012b; Valdés-Pineda et al., 2014; Valdés-Pineda et al., 2016c; Barrett et al., 2017b). Esta variabilidad está influenciada en gran medida por efectos orográficos, con patrones de precipitación que se desplazan hacia el sur y se acumulan a lo largo de los Andes. En Chile central, la mayoría de los eventos de precipitación están asociados con perturbaciones baroclínicas de latitudes medias, a menudo acompañadas por ríos atmosféricos que tocan tierra. Estos sistemas producen docenas de eventos por temporada, lo que representa aproximadamente el 50 % de la precipitación anual (Garreaud et al., 2024) y hasta el 40 % de los eventos de precipitación extrema (Viale et al., 2018; Valenzuela et al., 2019; Aceituno et al., 2021b; Lagos-Zúñiga et al., 2024b). Si bien los eventos de precipitación extrema son característicos del invierno austral, también se observan peculiaridades en la precipitación de la estación cálida, impulsadas por las depresiones de corte, (Viale et al., 2014; Valenzuela et al., 2022). El realce orográfico a través de la elevación

forzada crea un máximo primario de precipitación sobre la cordillera de la costa, seguido por un débil efecto de sombra de lluvia sobre el Valle Central y luego un rápido aumento en las laderas occidentales de los Andes (Garreaud et al., 2024).

### 3.3 Metodología

La selección y organización de los datos de precipitación observados se presentan en la Sección 3.3.1. La recopilación de conjuntos de datos de precipitación en cuadrícula y su posterior selección se analizan en la Sección 3.3.2. La Sección 3.3.3 describe la estructura y el procedimiento para construir el modelo de reducción de escala estadística, incluida la estrategia de análisis estadístico necesaria para el proceso de calibración y validación, la selección de datos en cuadrícula globales y los datos topoclimáticos.

#### 3.3.1 Datos de observación

La red de estaciones meteorológicas de Chile cuenta con el apoyo de la Dirección General de Aguas (DGA) y la Dirección Meteorológica de Chile (DMC). El conjunto de datos de precipitación diaria utilizado en este estudio fue compilado por el Centro de Ciencia del Clima y la Resiliencia (CR2) y está disponible públicamente en <https://www.cr2.cl/datos-de-precipitacion/>. Aunque este conjunto de datos es confiable y abarca varias décadas, muchas estaciones son convencionales (solo informan valores de acumulación diaria) y están ubicadas a bajas elevaciones (Garreaud et al., 2016). Para este estudio se utilizaron 176 estaciones de precipitación diaria, que abarcan el período de mayo a agosto de 2006 en las regiones del Maule-Los Ríos (Figura 3.1-a). De ellas, sólo cuatro estaciones (2,2%) se ubican por encima de los 1000 metros. La distribución espacial del conjunto de datos se muestra en la Figura (3.1-a), lo que ilustra la heterogeneidad en la distribución latitudinal (Figura 3.1-b) pero una notable concentración entre  $-72^\circ$  y  $-73^\circ$  de longitud (Figura 3.1-b).

#### 3.3.2 Conjunto global de datos

##### ERA5

Este análisis utilizó nueve conjuntos de datos de precipitación construidos a partir de varias fuentes con diferente cobertura espacial y temporal (Tabla 3.1). Se seleccionó el conjunto de datos de reanálisis de quinta generación del Centro Europeo de Previsiones Meteorológicas a Plazo Medio (ECMWF), conocido como ERA5. ERA5 proporciona cobertura temporal desde 1950 hasta

el presente, con una resolución espacial de aproximadamente 30 *km* y variables atmosféricas a 139 niveles de presión (Hersbach et al., 2020; Jiang et al., 2021). Varios estudios indican que ERA5 funciona bien en comparación con las observaciones y otros conjuntos de datos de reanálisis (Olauson, 2018; Kalverla et al., 2019). Sin embargo, sus fortalezas son más evidentes en frecuencias temporales bajas (p. ej., datos mensuales) que en frecuencias temporales altas (p. ej., datos diarios) (Izadi et al., 2021; Malayeri et al., 2021; Perri et al., 2024). Específicamente, la precipitación superficial de ERA5 ha mostrado una tendencia a sobreestimar los totales mensuales (Liu et al., 2024). En Chile, ERA5 captura eficazmente los patrones de precipitación estacional pero exhibe sesgos, particularmente en la representación de eventos de lluvia ligera a moderada e intensidades de precipitación extremas. Además, tiende a sobreestimar el aumento de la precipitación orográfica en ciertas regiones (Torrez-Rodriguez et al., 2023). No obstante, el trabajo de Ferguglia et al. (2024) revela patrones consistentes en áreas montañosas en todo el mundo, más allá de la variabilidad geográfica de ERA5. Esto resalta la necesidad de análisis más exhaustivos utilizando datos observados.

#### **ERA5-Land**

ERA5-Land es un componente integral y operativo del Servicio de Cambio Climático de Copernicus (C3S) en el ECMWF (Muñoz Sabater, 2019). A diferencia de ERA-Interim/Land, que se produjo como un único conjunto de datos de investigación que abarca el período 1979-2010, ERA5-Land se genera en tres flujos o segmentos independientes: (1) Este enfoque de producción paralela acelera la generación de datos y la disponibilidad pública; (2) El forzamiento atmosférico necesario para ERA5-Land se deriva de ERA5, lo que significa que la producción depende de la finalización del segmento ERA5 correspondiente para el mismo período (Muñoz Sabater et al., 2021). ERA5-Land proporciona datos horarios en una cuadrícula regular de latitud/longitud de  $0,1^\circ \times 0,1^\circ$  y se puede acceder a ellos a través del catálogo Climate Data Store en (<https://cds.climate.copernicus.eu/>). Si bien se han realizado múltiples evaluaciones de ERA5-Land (p. ej., Gomis-Cebolla et al. (2023)), dichos estudios son limitados para Chile. Por ejemplo, Hurtado et al. (2024) evaluó el noreste de la Patagonia, donde ERA5-Land sobreestimó sistemáticamente las precipitaciones en toda el área. De manera similar, Valencia et al. (2023) informó que ERA5-Land sobreestima las precipitaciones mensuales en Colombia.

#### **Productos PERSIANN**

La familia de conjuntos de datos PERSIANN es uno de los conjuntos de datos basados en satélites más utilizados para simulaciones hidrológicas (Eini et al., 2022). PERSIANN emplea un

Conjunto	Nombre Detalle	Fuente	Resolución Espacial	Cobertura Espacial	Resolución Temporal	Cobertura Temporal	Referencias
ERA5-Land	ERA5-Land <a href="https://cds.climate.copernicus.eu">https://cds.climate.copernicus.eu</a>	R	0,1° × 0,1°	Global	Diaria	1950 - presente	(Muñoz Sabater, 2019)
ERA5	ERA5 <a href="https://cds.climate.copernicus.eu">https://cds.climate.copernicus.eu</a>	R	0,25° × 0,25°	Global	Diaria	1940 - presente	(Hersbach et al., 2023)
PERSIANN	Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks <a href="https://chrsdata.eng.uci.edu/">https://chrsdata.eng.uci.edu/</a>	S	0,25° × 0,25°	60°S – 60°N	Diaria	Marzo 2000 - presente	(Hsu et al., 1997; Hsu et al., 1999) (Hsu et al., 2000; Nguyen et al., 2019)
PERSIANN CSS	PERSIANN-Cloud Classification System <a href="https://chrsdata.eng.uci.edu/">https://chrsdata.eng.uci.edu/</a>	S	0,04° × 0,04°	60°S – 60°N	Diaria	Enero 2003 - presente	(Hsu et al., 1997; Hsu et al., 1999) (Hsu et al., 2000; Nguyen et al., 2019)
PERSIANN CDR	Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks - Climate Data Record <a href="https://chrsdata.eng.uci.edu/">https://chrsdata.eng.uci.edu/</a>	S	0,25° × 0,25°	60°S – 60°N	Diaria	Enero 1983 - presente	(Hsu et al., 1997; Hsu et al., 1999) (Hsu et al., 2000; Nguyen et al., 2019)
PERSIANN PDIR-Now	Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks Dynamic Infrared Rain Rate near real-time <a href="https://chrsdata.eng.uci.edu/">https://chrsdata.eng.uci.edu/</a>	S	0,04° × 0,04°	60°S – 60°N	Diaria	Marzo 2000 - presente	(Hsu et al., 1997; Hsu et al., 1999) (Hsu et al., 2000; Nguyen et al., 2019)
PERSIANN CCS-CDR	Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks-Cloud Classification System-Climate Data Record <a href="https://chrsdata.eng.uci.edu/">https://chrsdata.eng.uci.edu/</a>	S	0,04° × 0,04°	Global	Diaria	1940 - presente	(Hsu et al., 1997; Hsu et al., 1999) (Hsu et al., 2000; Nguyen et al., 2019)
CHIRPSv2.0	Climate Hazards Group Infrared Precipitation (CHIRPS) V2.0 <a href="http://chg.ucsb.edu/data/chirps/">http://chg.ucsb.edu/data/chirps/</a>	S, R	0,05° × 0,05°	50°S – 50°N	Diaria-Pentadal Mensual	1981 - presente	(Funk et al., 2015c)
MSWEPv2.2	Multi-Source Weighted-Ensemble Precipitation (MSWEP) v2.2 <a href="https://www.gloh2o.org/mswep/">https://www.gloh2o.org/mswep/</a>	I, S, R	0,1° × 0,1°	90°S – 90°N	3h	1979 - 2017	(Beck et al., 2019)

TABLA 3.1: Descripción de las 9 cuadrículas de (sub)precipitación (cuasi)globales utilizadas en este estudio. Las abreviaturas en la columna Fuente, definidas como I, S, R son las abreviaturas de los productos derivados: in situ, satélite y reanálisis, respectivamente.

modelo de red neuronal artificial (ANN) para estimar la precipitación mediante observaciones infrarrojas (IR). Su precisión se mejora mediante un ajuste adaptativo de los parámetros de la red mediante estimaciones de lluvia derivadas de sensores de microondas pasivos. A nivel de píxel, el algoritmo ajusta la media y la desviación estándar de la temperatura de brillo para un píxel determinado y la textura de los píxeles adyacentes para calcular la tasa de precipitación (Hsu et al., 1997; Zambrano-Bigiarini et al., 2017b). La familia PERSIANN incluye PERSIANN-CDR (Climate Data Record), PERSIANN-CCS (Cloud Classification System), PDIR-NOW (near-real-time dynamic IR rain rate) y PERSIANN-CCS-CDR (Cloud Classification System-Climate Data Record) (Nguyen et al., 2019; Nguyen et al., 2020a; Sadeghi et al., 2021). Tanto PERSIANN-CDR como PERSIANN-CCS utilizan el archivo de temperatura de brillo infrarrojo de GridSat-B1 como entrada para el algoritmo (Rossow et al., 2004; Knapp, 2008; Nguyen et al., 2019). PERSIANN-CDR corrige las estimaciones de precipitación utilizando el producto mensual Global Precipitation Climatology Project (GPCP), versión 2.3, con una resolución espacial de  $2,5^\circ \times 2,5^\circ$  (Sadeghi et al., 2019; Sadeghi et al., 2021). PERSIANN-CCS, por otro lado, extrae características locales y regionales de las nubes a partir de imágenes IR de satélites geoestacionarios ( $10,7 \mu m$ ) para estimar distribuciones de precipitación a escala más fina con una resolución de  $(0,04^\circ \times 0,04^\circ$  cada 30 minutos) (Hong et al., 2007; Sadeghi et al., 2021; Anjum et al., 2022). Para superar algunas de las limitaciones de precisión de PERSIANN-CCS y mejorar las estimaciones de precipitación extrema y orográfica, se desarrolló el algoritmo PDIR. Este algoritmo ajusta dinámicamente la curva de

tasa de precipitación-temperatura de la cima de las nubes ( $T_b - R$ ) utilizando datos de climatología de precipitación para refinar el posicionamiento de la curva (Nguyen et al., 2020b). Por último, PERSIANN-CCS-CDR integra los algoritmos utilizados en PERSIANN-CCS y PERSIANN-CDR, combinando la clasificación de nubes de PERSIANN-CCS con los ajustes climáticos de PERSIANN-CDR para producir un producto de alta resolución con una amplia cobertura temporal (Sadeghi et al., 2021).

#### **CHIRPS-2.0**

El conjunto de datos CHIRPS proporciona datos de precipitación derivados tanto de observaciones satelitales como de mediciones de pluviómetros, que abarcan desde 1981 hasta casi el presente, con resoluciones espaciales de  $0,25^\circ$  y  $0,05^\circ$  y resoluciones temporales que van desde diarias hasta anuales. CHIRPS combina campos de satélites geoestacionarios y de órbita polar de cinco productos diferentes. Utiliza indicadores topográficos y fisiográficos en un formato de cuadrícula para calcular regresiones locales de ventanas móviles e interpolación inversa ponderada por distancia (Funk et al., 2015c; Funk et al., 2015a). Varios estudios han evaluado CHIRPS en América del Sur (p. ej., Paredes Trejo et al. 2016; Rivera et al. 2018; Baez-Villanueva et al. 2018). En Chile, estudios como (Zambrano-Bigiarini et al., 2017b; Baez-Villanueva et al., 2018) han destacado su sólido desempeño en regiones húmedas y áreas de baja a media elevación (0-1000 m). Sin embargo, CHIRPS muestra una precisión menor para eventos de precipitación leve y es más confiable de diciembre a marzo, cuando se producen mayores precipitaciones en el norte de Chile (Medina et al., 2023).

#### **MSWEP-2.2**

MSWEP es un conjunto de datos de precipitación global con una resolución espacial de  $0,1^\circ$  y resoluciones temporales de tres horas, diarias y mensuales. Está disponible en <https://www.gloh2o.org/>. MSWEP integra estimaciones de precipitación a partir de observaciones satelitales IR y de microondas, pluviómetros y productos de reanálisis (Beck et al., 2017d; Prakash, 2019; Beck et al., 2019; Omondi et al., 2021). Incluye observaciones mensuales del GPCC y mediciones diarias compiladas a partir de múltiples fuentes (Beck et al., 2019; Satgé et al., 2020). En América del Sur, estudios como Moreira et al. (2019) indican que MSWEP supera a TRMM en términos de menor RMSE. Sin embargo, presenta incertidumbres significativas en el noreste y sur de Brasil. Olmo et al. (2022) muestra que MSWEP captura la variabilidad estacional y los patrones de precipitación, pero sobreestima la frecuencia e intensidad de la precipitación diaria en comparación con las estaciones meteorológicas. Baez-Villanueva et al. (2018) evaluó MSWEP en varias

cuencas sudamericanas y encontró que, a escala diaria, captura bien la dinámica temporal de la precipitación en Chile, pero funciona con menor eficacia en áreas con topografía compleja.

### 3.3.3 Modelo de reducción de escala estadística

El conjunto de datos obtenido del modelo de reducción de escala estadística adaptativa diaria (DA-SDM), donde la precipitación es la variable dependiente (predicha) y la elevación ( $hgt$ ), la pendiente ( $slp$ ), la orientación ( $asp$ ), el índice de rugosidad del terreno ( $tri$ ), la continentalidad ( $dcoast$ ) (ver Figura 3.2b-f) y los componentes del viento  $u$  y  $v$  a 10 metros son los predictores. El modelo se construye por región diariamente (Figura 3.2-a) ajustando los valores del conjunto de datos globales utilizando el procedimiento de mínimos cuadrados (Delbari et al., 2019b). La función de transferencia se expresa como:

$$\begin{aligned}
 P = & \alpha + \beta_1 \cdot hgt + \beta_2 \cdot slp + \beta_3 \cdot asp \\
 & + \beta_4 \cdot tri + \beta_5 \cdot dcoast + \beta_6 \cdot u10 \\
 & + \beta_7 \cdot v10,
 \end{aligned}
 \tag{3.1}$$

Donde  $\alpha$  es la intersección del plano generado y  $\beta_i, i = 1, \dots, p$  son los coeficientes de regresión asociados con las variables predictoras. Para cada dominio, se realizaron 128 pruebas con diferentes configuraciones de predictores. Se realizó un análisis de sensibilidad eliminando secuencialmente una variable para evaluar su influencia en el rendimiento del modelo. La calibración del modelo empleó el método de mapeo cuantil (QM), adaptado a cada categoría de evento de precipitación diaria según la clasificación de la Tabla (3.2). La calibración utilizó el 70 % de los datos disponibles, seleccionados aleatoriamente en cuantiles de elevación del 25 %, 50 % y 75 %. La validación utilizó el 30 % restante del conjunto de datos.

Eventos de Precipitación	Intensidad ( $i$ ), ( $mm/day$ )
No precipitación	[0 – 1)
Precipitación ligera	[1 – 5)
Precipitación moderada	[5 – 20)
Precipitación alta	[20 – 40)
Precipitación extrema	$\geq 40$

TABLA 3.2: Clasificación de los eventos de lluvia en función de su intensidad diaria  $i$ . Modificado para valores diarios de la Organización Meteorológica Mundial (2008). Adaptado de (Zambrano-Bigiarini et al., 2017b).

### 3.3.4 Análisis estadístico

La Tabla (3.3) resume los estadísticos considerados en el análisis. El coeficiente de correlación de Spearman ( $\rho_{sp}$ ) cubre un rango similar al coeficiente de correlación de Pearson. Sin embargo, a diferencia del coeficiente de Person, este estadístico no paramétrico no requiere que los datos se distribuyan normalmente (Gomis-Cebolla et al., 2023). Debido a su amplio uso, intuitividad y fácil interpretación, utilizamos *PBIAS* y *RMSE*. Aunque *RMSE* penaliza desproporcionadamente

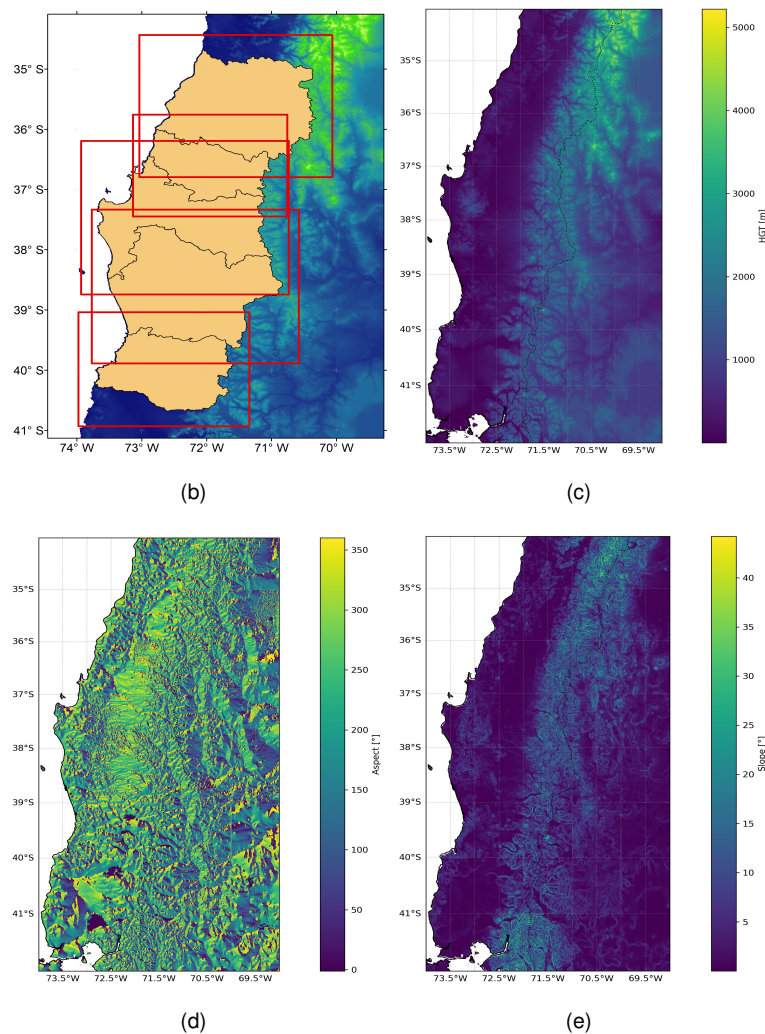


FIGURA 3.2: Características orográficas del área de estudio. (a) Mosaicos de selección de datos para cada región de Norte a Sur: Maule, Ñuble, Biobío, Araucanía, Los Ríos; (b) Elevación [m]; (c) Aspecto [°]; (d) Pendiente [°]; (e) Índice de Rugosidad del Terreno [m]; (f) Distancia a la costa [°].

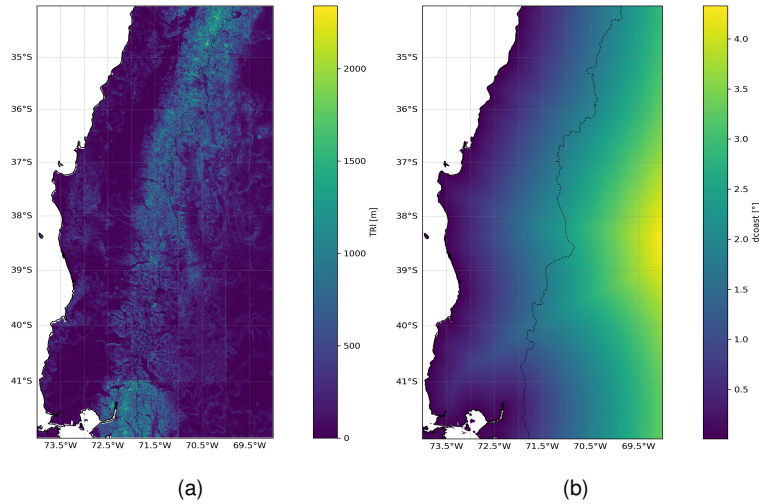


FIGURA 3.2: Características orográficas del área de estudio. (a) Mosaicos de selección de datos para cada región de Norte a Sur: Maule, Ñuble, Biobío, Araucanía, Los Ríos; (b) Elevación [m]; (c) Aspecto [°]; (d) Pendiente [°]; (e) Índice de Rugosidad del Terreno [m]; (f) Distancia a la costa [°].

los errores grandes, es útil para identificarlos espacialmente (Valencia et al., 2023); permitiendo una comparación directa en términos de precisión del modelo. Finalmente, para complementar el análisis, en el ajuste del modelo a los valores observados utilizamos el error medio o sesgo. La eficiencia de Kling-Gupta (KGE) proporciona una medida del rendimiento del modelo considerando la media ( $\beta$ ), la variabilidad ( $\gamma$ ) y la dinámica temporal ( $r$ ) (Gupta et al., 2009; Kling et al., 2012; Pool et al., 2018). Para complementar el análisis estadístico, utilizamos el coeficiente de Nash-Sutcliffe (NSE) y el coeficiente de Willmott modificado ( $W_d$ ) (Willmott et al., 2012; Deo et al., 2015).

### 3.4 Resultados

En la sección 3.4.1 se analiza el rendimiento del modelo generado en función de las estaciones de validación, evaluando su correlación, métricas de error e índices de evaluación estadística. En la sección 3.4.2, se compara este rendimiento con los conjuntos CMORPH y TRMM para evaluar la precisión relativa del modelo en diferentes categorías de elevación.

Métrica	Expresión	$[min, max]$ value	Unidad
Spearman Correlation Coefficient ( $\rho_{sp}$ )	$\rho_{sp} = 1 - \frac{6 \sum (y_i - \hat{y}_i)^2}{n(n^2 - 1)}$	1, $[-1, 1]$	-
Root mean square error (RMSE)	$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}$	0, $[0, \infty)$	mm
Systematic Bias Percent (PBIAS)	$PBIAS = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)}{\sum_{i=1}^n y_i} \times 100$	0, $(-\infty, \infty)$	%
Kling-Gupta efficiency (KGE)	$KGE = 1 - \sqrt{(r - 1)^2 + (\beta - 1)^2 + (\gamma - 1)^2}$	1, $(-\infty, 1]$	-
Nash-Sutcliffe coefficient (NSE)	$NSE = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}$	1, $(-\infty, 1]$	-
Willmott coefficient ( $W_d$ )	$W_d = 1 - \frac{\sum_{i=1}^n  \hat{y}_i - y_i }{\sum_{i=1}^n ( \hat{y}_i - \bar{y}_i  +  y_i - \bar{y}_i )}$	1, $(0, 1]$	-

TABLA 3.3: Métricas de evaluación de precisión.

### 3.4.1 Rendimiento de DA-SDM

Para evaluar el rendimiento del modelo DA-SDM, se seleccionaron aleatoriamente 52 estaciones de medición para garantizar una cobertura representativa en diferentes cuantiles de altitud (Figura 3.3).

#### Evaluación del diagrama de Taylor

En el primer cuartil (Figura 3.4-a), las estaciones de observación exhiben un coeficiente de correlación de Spearman promedio  $\rho_{sp}$  de 0,73, aunque algunas estaciones informan valores por debajo de 0,4. El error cuadrático medio (RMSE) tiene un promedio de 10,87 mm, y todas las estaciones con  $\rho_{sp} > 0,6$  registran valores RMSE por debajo de 15 mm. La desviación estándar normalizada (NSD) promedia 0,48, y la mayoría de los valores se agrupan alrededor de 0,5. Solo una estación presenta un NSD superior a 1, lo que indica una desviación sustancial de la media. En el segundo cuartil (Figura 3.4-b), el  $\rho_{sp}$  promedio aumenta a 0,8, superando la correlación observada en el primer cuartil. Sin embargo, algunas estaciones aún presentan valores por debajo de 0,4. El RMSE máximo sigue siendo comparable al del primer cuartil, con un promedio de 13,47 mm. A diferencia del primer cuartil, algunas estaciones con  $\rho_{sp} > 0,6$  registran valores de RMSE superiores a 20 mm. El NSD promedia 0,39, con la mayoría de los valores concentrados por debajo de 0,5.

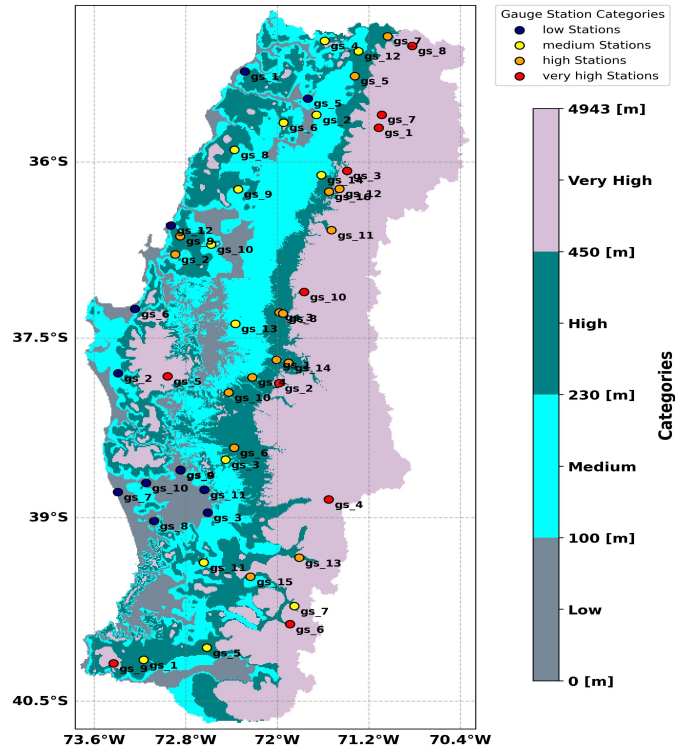


FIGURA 3.3: Selección de estaciones de medición para el ajuste de Quantile Mapping. Las categorías de elevación son: Baja (0-100 m); Media (100-230 m); Alta (230 - 450 m) y Muy Alta (450 - 4943 m).




FIGURA 3.4: Diagramas de cajas correspondientes al comportamiento de DA-SDM. (a) porcentaje de error sistemático ( $PBIAS$ ), (b) coeficiente de Nash-Sutcliffe ( $NSE$ ), (c) coeficiente de Kling-Gupta ( $KGE$ ), y (d) coeficiente de Willmott ( $W_d$ ).




FIGURA 3.4: Diagramas de cajas correspondientes al comportamiento de DA-SDM. (a) porcentaje de error sistemático ( $PBIAS$ ), (b) coeficiente de Nash-Sutcliffe ( $NSE$ ), (c) coeficiente de Kling-Gupta ( $KGE$ ), y (d) coeficiente de Willmott ( $W_d$ ).

En el tercer cuartil (Figura 3.4-c), el  $\rho_{sp}$  promedio se mantiene en 0,8, aunque algunas estaciones continúan reportando valores por debajo de 0,4. El RMSE alcanza un máximo de 22  $mm$ , con un promedio de 10.44  $mm$ , consistente con el cuartil anterior. Todas las estaciones con  $\rho_{sp}$  por encima de la media reportan valores de RMSE por debajo de 15  $mm$ . El NSD promedia 0.45, con la mayoría de los valores concentrados por debajo de 0.5, exhibiendo patrones consistentes con aquellos observados en los cuantiles inferiores.

En el cuarto cuartil (Figura 3.4-d), el  $\rho_{sp}$  promedio disminuye a 0.68, con algunas estaciones registrando valores por debajo de 0.4. Esta categoría exhibe un notable incremento en el RMSE máximo, el cual excede a los de los cuantiles anteriores en más de 10  $mm$ , alcanzando un promedio de 22.7  $mm$ . Este incremento se observa consistentemente en todas las estaciones evaluadas, independientemente de los niveles de  $\rho_{sp}$ . Cabe destacar que los valores RMSE más altos corresponden a estaciones con  $\rho_{sp}$  mayor que 0,9. El NSD promedia 0,25, con la mayoría de los valores por debajo de 0,5, aunque tres estaciones informan desviaciones más altas.

#### Rendimiento del modelo DA-SDM en las distintas métricas de evaluación

El rendimiento del modelo DA-SDM se evaluó utilizando el porcentaje de sesgo ( $PBIAS$ ), la eficiencia de Nash-Sutcliffe ( $NSE$ ), la eficiencia de Kling-Gupta ( $KGE$ ) y el índice de Willmott ( $W_d$ )

(Figura 3.5). En los cuatro cuantiles, el PBIAS muestra una tendencia decreciente. En la categoría baja (Figura 3.5-a), el PBIAS tiene un promedio del 45%, y la mayoría de las estimaciones superan el 50%. En la categoría media, el PBIAS promedio es del 44%, y dos valores atípicos muestran estimaciones negativas. En la categoría alta, el PBIAS tiene un promedio del 37,21%, aunque la mayoría de las estaciones aún informan valores superiores al 50%. Finalmente, en la categoría Muy Alta, el PBIAS se mantiene predominantemente por encima del 50%, con un promedio del 67%.

Se observa un patrón similar en NSE, KGE y  $W_d$  (Figura 3.5-b, 3.5-c, 3.5-d). En la categoría Baja, estas métricas exhiben valores promedio de 0.34, 0.13 y 0.71, respectivamente, con una alta dispersión, que va de -0.7 a 0.9. En la categoría Media, los valores promedio de NSE, KGE y  $W_d$  son 0.23, 0.00 y 0.69, respectivamente, mostrando una dispersión menor en comparación con la categoría anterior. En la categoría Alta, los valores se mantienen similares a los de la categoría Baja, con NSE, KGE y  $W_d$  alcanzando 0.36, 0.15 y 0.70, respectivamente. Sin embargo, KGE registra el desempeño más bajo entre las tres métricas en esta categoría. En la categoría Muy Alta, NSE, KGE y  $W_d$  alcanzan sus valores promedio más bajos de 0.00, -1.19 y 0.64, respectivamente. No obstante, algunas estaciones superan 0.6, lo que indica un desempeño satisfactorio en casos específicos.

#### **Predictores Clave de Precipitación en el Modelo DA-SDM**

El Apéndice (3.6) proporciona tablas que enumeran los nombres y las coordenadas geográficas de las estaciones utilizadas durante las etapas de calibración y validación. Además, la Figura (3.2) presenta las variables clave asociadas con diferentes tipos de eventos de precipitación. La frecuencia de cada predictor en el modelo DA-SDM se analiza para cada región. Los predictores más influyentes son los componentes del viento a 10 metros y la distancia a la costa. En contraste, la elevación y el índice de rugosidad del terreno contribuyen en menor medida en todos los tipos de precipitación. Además, la pendiente y la orientación no tienen una influencia significativa en el modelo.

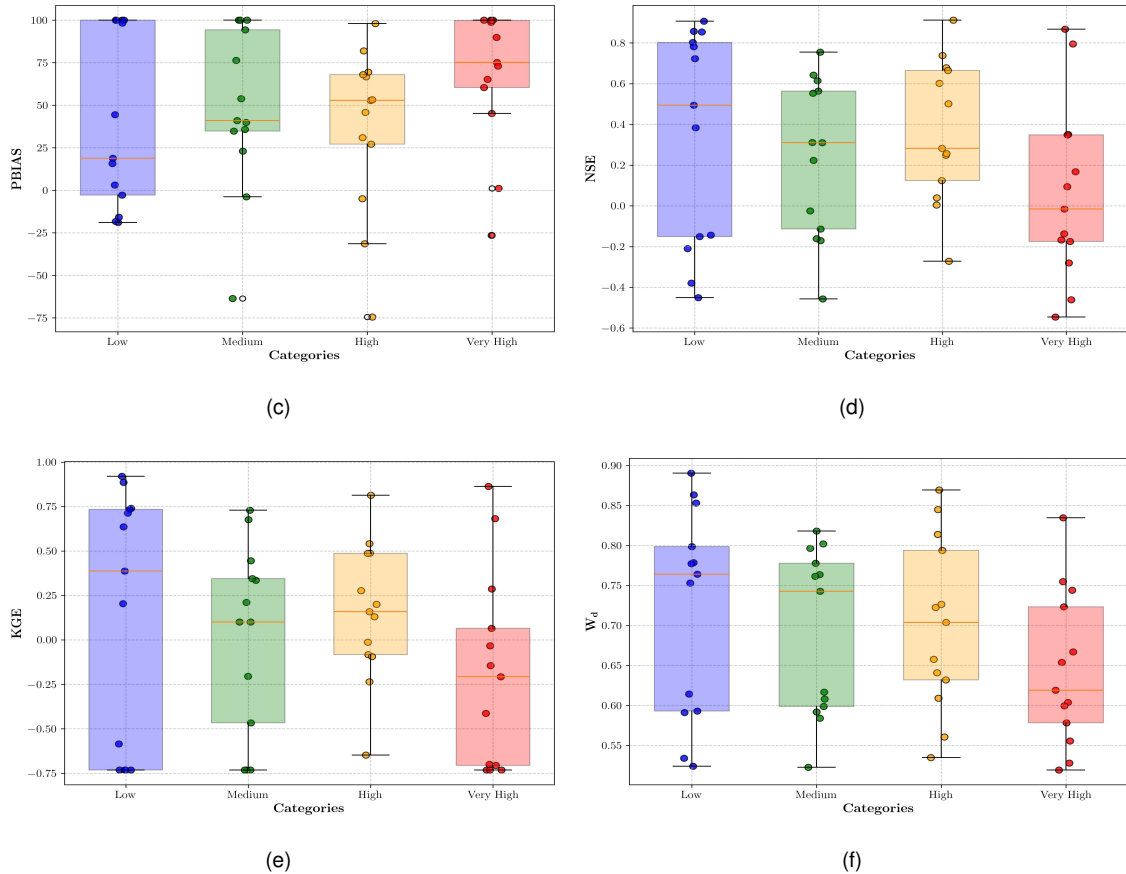


FIGURA 3.5: Diagramas de cajas correspondientes al comportamiento del DA-SDM. (a) porcentaje de error sistemático ( $PBIAS$ ), (b) coeficiente de Nash-Sutcliffe ( $NSE$ ), (c) coeficiente de Kling-Gupta ( $KGE$ ), y (d) coeficiente de Willmott ( $W_d$ ).

### 3.4.2 Evaluación comparativa del modelo DA-SDM con CMORPH y TRMM

La evaluación del modelo DA-SDM en la Sección 3.4.1 reveló fuertes correlaciones con las estaciones de validación, particularmente en los primeros tres cuantiles de altitud. Sin embargo, el aumento de los valores de RMSE y la correlación reducida en el cuantil más alto indican desafíos potenciales en condiciones de precipitación extrema. En esta sección, comparamos el desempeño de DA-SDM con CMORPH y TRMM en las mismas categorías de elevación para evaluar su precisión relativa.

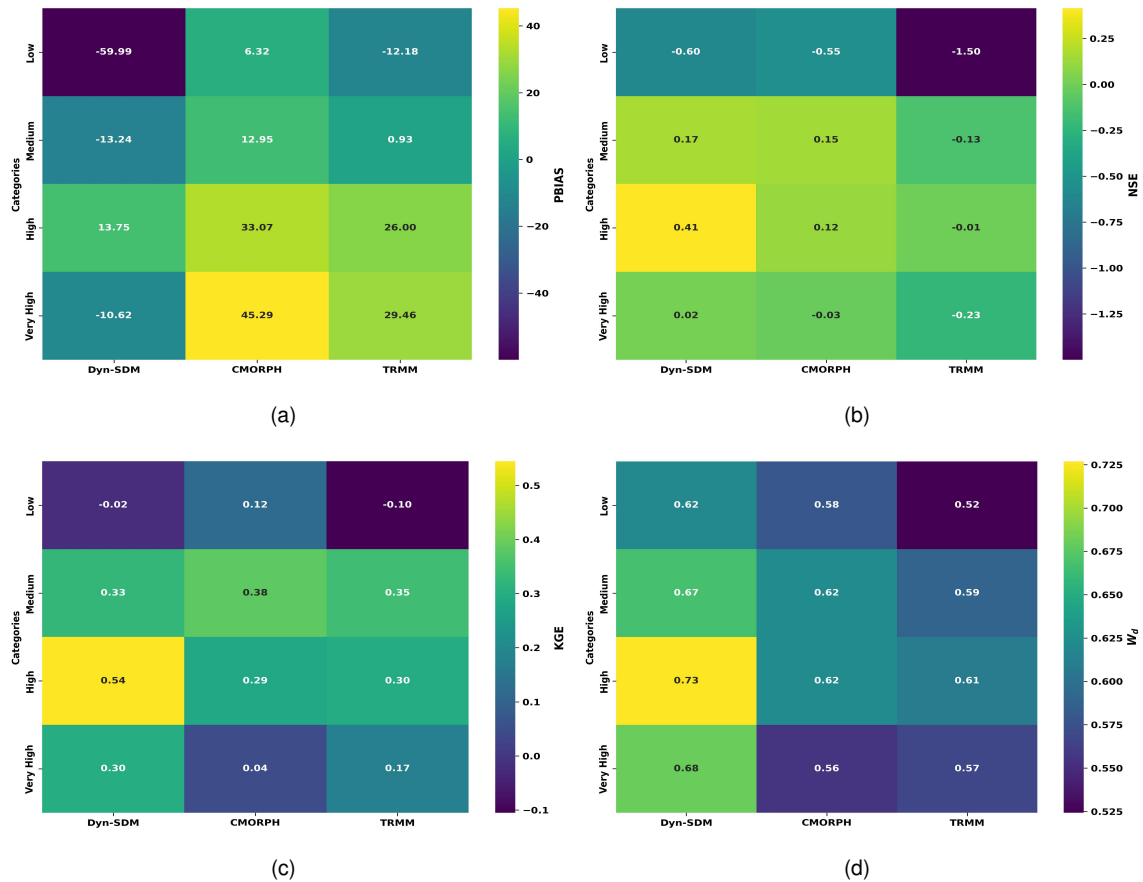


FIGURA 3.6: Mapas de calor correspondientes al comportamiento de los conjuntos de datos DA-SDM, CMORPH y TRMM. (a) porcentaje de error sistemático ( $PBIAS$ ), (b) coeficiente de Nash-Sutcliffe ( $NSE$ ), (c) coeficiente de Kling-Gupta ( $KGE$ ), y (d) coeficiente de Willmott ( $W_d$ ).

#### Rendimiento general en las categorías de elevación

El rendimiento medio del conjunto de modelos DA-SDM se comparó con los conjuntos de precipitación CMORPH y TRMM en las cuatro categorías de elevación definidas (Figura 3.3). La Figura (3.6) presenta la evaluación del rendimiento medio en función del porcentaje de sesgo ( $PBIAS$ ), la eficiencia de Nash-Sutcliffe ( $NSE$ ), la eficiencia de Kling-Gupta ( $KGE$ ) y el índice de Willmott ( $W_d$ ).

La Figura (3.6-a) ilustra la distribución del PBIAS. Tanto DA-SDM como TRMM indican una subestimación de la precipitación en la categoría baja. En la categoría media, DA-SDM continúa subestimando la precipitación, mientras que CMORPH y TRMM muestran una sobreestimación. En la categoría Alta, DA-SDM pasa a una sobreestimación, mientras que CMORPH y TRMM mantienen esta tendencia. Finalmente, en la categoría Muy Alta, DA-SDM vuelve a una subestimación, mientras que CMORPH y TRMM mantienen una sobreestimación con un margen de error mayor. A pesar de estas variaciones, DA-SDM muestra el ajuste más bajo en la categoría Baja, aunque la dispersión de PBIAS se mantiene por debajo del 15 % en las categorías posteriores. En cambio, CMORPH y TRMM muestran un aumento progresivo de PBIAS, lo que sugiere una mayor incertidumbre en las estimaciones de precipitación a altitudes crecientes.

#### **Eficiencia de Nash-Sutcliffe (NSE) en todos los modelos**

La Figura (3.6-b) presenta la evaluación de la NSE. En la categoría Baja, todos los conjuntos de datos tienen un rendimiento deficiente, y TRMM exhibe el peor rendimiento. En la categoría Media, los valores de NSE mejoran ligeramente, aunque el rendimiento sigue siendo subóptimo en todos los modelos. En la categoría Alta, DA-SDM demuestra una mejora notable, mientras que CMORPH y TRMM mantienen niveles de rendimiento comparables a la categoría Media. Sin embargo, en la categoría Muy Alta, los valores de NSE de DA-SDM disminuyen una vez más, mientras que CMORPH y TRMM mantienen valores bajos de manera constante. Estos resultados resaltan los desafíos que implica representar eventos de precipitación extrema a altitudes más altas, en particular para conjuntos basados en satélites.

#### **Tendencias de desempeño de la eficiencia Kling-Gupta (KGE)**

La Figura (3.6-c) presenta la evaluación de la KGE en las distintas categorías. En la categoría Baja, todos los modelos muestran un desempeño débil. En la categoría Media, se observa una mejora general, con estimaciones similares en todos los modelos. En la categoría Alta, DA-SDM muestra una mejora significativa, mientras que CMORPH y TRMM mantienen niveles de desempeño similares a los de la categoría Media. Sin embargo, en la categoría Muy Alta, DA-SDM experimenta una disminución en el desempeño, reduciéndose a valores comparables a los de la categoría Media. Por el contrario, CMORPH y TRMM sufren una disminución drástica, acercándose a valores cercanos a cero. Estos resultados enfatizan que la KGE es altamente sensible a condiciones extremas, lo que la convierte en una métrica valiosa para la diferenciación del desempeño del modelo.

**Evaluación del índice Willmott ( $W_d$ )**

La evaluación del índice Willmott ( $W_d$ ) (Figura 3.6-d) sugiere que, a diferencia de los otros índices, todos los modelos funcionan relativamente bien. En la categoría Baja, DA-SDM alcanza valores superiores a 0,6, mientras que CMORPH y TRMM exhiben valores similares. En la categoría Media, el rendimiento de los tres modelos es comparable, y DA-SDM muestra el mayor acuerdo con las observaciones. La categoría Alta muestra una mejora adicional, ya que todos los modelos superan 0,6 y DA-SDM supera 0,7. En la categoría Muy Alta, CMORPH y TRMM muestran una ligera disminución, aunque los valores se mantienen por encima de 0,5, mientras que DA-SDM mantiene valores superiores a 0,6. En general, DA-SDM supera de manera consistente a CMORPH y TRMM en la mayoría de las categorías, en particular en elevaciones más altas. Esta tendencia sugiere que el modelo DA-SDM proporciona una representación más confiable de la variabilidad de la precipitación en condiciones topográficas complejas.

## 3.5 Discusión

### 3.5.1 Rendimiento y validación del modelo

Este estudio analiza la precipitación extrema en el centro-sur de Chile utilizando un modelo de reducción de escala estadística adaptativa diaria (DA-SDM). La evaluación evalúa la capacidad de DA-SDM para representar eventos de precipitación extrema, seguido de un análisis comparativo con los conjuntos CMORPH y TRMM. El rendimiento del modelo se analizó utilizando múltiples métricas de evaluación (PBIAS, NSE, KGE,  $W_d$ ) y diagramas de Taylor, que proporcionan una representación gráfica de la correlación  $\rho_{sp}$ , el error cuadrático medio (RMSE) y la desviación estándar.

La Figura (3.4) confirma que DA-SDM logra un mejor ajuste en categorías de elevación intermedias, mostrando una correlación más alta y valores de RMSE por debajo de los 15 mm. En la categoría Baja, el modelo tiene dificultades para representar la variabilidad espacial de la precipitación, lo que da como resultado una baja correlación con las observaciones. Sin embargo, la correlación mejora en la categoría Alta, donde DA-SDM mantiene un RMSE cercano a 15 mm. En elevaciones Muy Altas, a pesar de un aumento en el RMSE, el modelo mantiene correlaciones aceptables superiores a 0,6. Estos hallazgos indican que, si bien DA-SDM exhibe algunas limitaciones en altitudes superiores a 450 m, la Figura (3.5) sugiere una precisión moderada, con valores de NSE, KGE e índice de Willmott superiores a 0,7 en todas las categorías de elevación. Sin embargo, la mayoría de los resultados exhiben estimaciones bajas y patrones de distribución

similares entre estos índices, como lo confirman además las tendencias de distribución de PBIAS.

### 3.5.2 Análisis comparativo con CMORPH y TRMM

Al evaluar DA-SDM frente a CMORPH y TRMM (Figura 3.6), las métricas de rendimiento indican que DA-SDM proporciona las mejores estimaciones, aunque sin un predominio sustancial en todas las categorías. El análisis PBIAS destaca errores pronunciados en estaciones por debajo de los 100 m, pero DA-SDM mantiene una baja dispersión en categorías de mayor elevación, mientras que CMORPH y TRMM muestran un aumento progresivo del sesgo.

Las evaluaciones NSE, KGE y  $W_d$  revelan resultados variados. TRMM exhibe el rendimiento NSE más débil, mientras que DA-SDM mejora significativamente en la categoría Alta pero vuelve a disminuir en elevaciones Muy Altas. La métrica KGE sigue una tendencia similar, con un bajo rendimiento en elevaciones Bajas, una mejora en elevaciones Medias y una precisión máxima en la categoría Alta. Sin embargo, en elevaciones muy altas, el rendimiento de DA-SDM se deteriora, mientras que los valores de CMORPH y TRMM se acercan a cero.

El índice de Willmott ( $W_d$ ) sugiere que todos los modelos muestran un rendimiento aceptable. DA-SDM supera 0,6 en todas las categorías, alcanzando un máximo en la categoría alta, mientras que CMORPH y TRMM muestran un rendimiento reducido en elevaciones muy altas, aunque no caen por debajo de 0,5.

### 3.5.3 Coherencia con estudios previos

Estos hallazgos coinciden con estudios previos (p. ej., Álvarez Rodríguez (2011), Zhou et al. (2019), Billios et al. (2024)), que enfatizan la influencia de la heterogeneidad espacial y la cobertura limitada de estaciones, particularmente en regiones de gran altitud. Los predictores geofísicos clave identificados en este estudio, como la elevación, los componentes del viento y la continentalidad, son consistentes con investigaciones anteriores sobre el papel de la topografía y la dinámica atmosférica en la conformación de los patrones de precipitación (p. ej., Roe (2005), Houze Jr (2012) y Junquas et al. (2018)).

La integración de múltiples conjuntos de datos globales (ERA5, ERA5-Land, CHIRPS-2.0, MSWEP-2.2 y PERSIANN-CCS-CDR) mejora la resolución espacial y temporal del modelo. Sin embargo, los sesgos específicos de los conjuntos de datos siguen siendo una preocupación. Por ejemplo, ERA5 tiende a sobrestimar la precipitación orográfica, mientras que CHIRPS subrepresenta los eventos de precipitación extrema. Estas limitaciones resaltan la necesidad de técnicas de

corrección de sesgo personalizadas y comparaciones entre conjuntos de datos para mejorar la confiabilidad del modelo.

### **3.5.4 Fortalezas y limitaciones del enfoque DA-SDM**

El marco DA-SDM proporciona una metodología transparente para comprender las relaciones físicas entre los predictores y la precipitación extrema. Una de sus principales ventajas es su capacidad para reducir los sesgos sistemáticos que se observan a menudo en los conjuntos de datos de precipitación basados en satélites y reanálisis. El modelo funciona bien en regiones de baja y media altitud, lo que sugiere un enfoque de reducción de escala bien calibrado que mejora las estimaciones de precipitación regional.

A pesar de estas ventajas, se deben reconocer varias limitaciones. En primer lugar, el conjunto limitado de predictores restringe la capacidad del modelo para representar la dinámica de la precipitación a escala fina, como la actividad convectiva y el transporte de humedad atmosférica. Ampliar el conjunto de predictores para incluir índices de estabilidad atmosférica y cizalladura vertical del viento podría mejorar la precisión del modelo. Además, la estructura lineal de DA-SDM simplifica la dinámica de la precipitación, lo que reduce potencialmente su capacidad para capturar interacciones atmosféricas complejas. Si bien la incorporación de técnicas de aprendizaje automático, como los bosques aleatorios, podría mejorar la precisión predictiva, esto se haría a expensas de la interpretabilidad, que sigue siendo un objetivo clave de este estudio. El proceso de calibración también presenta desafíos. El uso del mapeo de cuantiles en el modelo introduce sensibilidad a la estratificación y la selección de cuantiles, lo que podría influir en el rendimiento predictivo. Los métodos de calibración alternativos basados en conjuntos pueden proporcionar un enfoque más sólido para manejar la variabilidad en diferentes rangos de elevación. Por último, las limitaciones de resolución siguen siendo una preocupación. Si bien la alta resolución espacial del modelo ( $\sim 1 \text{ km}$ ) mejora la complejidad regional, la interpolación de conjuntos de datos gruesos a esta escala puede introducir imprecisiones. Estas limitaciones podrían mitigarse integrando mediciones de radar o lidar de alta resolución para mejorar la precisión de las estimaciones de precipitación en terrenos complejos.

### **3.5.5 Futuras orientaciones de la investigación e implicancias socioeconómicas**

El enfoque en un único evento de precipitación extrema (2006) limita la generalización de los hallazgos del estudio. Las investigaciones futuras deberían apuntar a analizar múltiples eventos extremos en diversas escalas temporales para comprender mejor la variabilidad en los procesos

de precipitación y mejorar la solidez del modelo. Además, los enfoques estadísticos alternativos, como los modelos lineales generalizados (GLM), podrían ayudar a explicar la heterocedasticidad, que puede ser significativa en regiones con una variabilidad sustancial de la precipitación.

Más allá de las mejoras del modelo, el estudio destaca importantes implicancias socioeconómicas. El evento de precipitación extrema de 2006 causó graves inundaciones, daños a la infraestructura y pérdidas agrícolas, lo que demuestra la vulnerabilidad del centro-sur de Chile a las condiciones climáticas extremas (Díaz Labbé et al., 2006; Rojas et al., 2014; Rojas Vilches et al., 2015; Henríquez et al., 2016). Las metodologías precisas de predicción de precipitaciones y de reducción de escala son fundamentales para la adaptación climática, la gestión de riesgos y la preparación para desastres.

Este estudio mejora la comprensión de los procesos de precipitación extrema en regiones topográficamente complejas y con escasez de datos al integrar un enfoque de reducción de escala estadística adaptativa diaria con modelos espaciales de alta resolución ( $\sim 1 \text{ km}$ ). La metodología combina datos de observación con conjuntos de datos globales para mejorar la resolución espacial, incorpora predictores geofísicos clave como componentes de elevación y viento, y aplica técnicas de calibración robustas para mejorar la precisión.

Al tiempo que equilibra la interpretabilidad con el rendimiento predictivo, el modelo DA-SDM proporciona un marco transparente para analizar las relaciones físicas entre la precipitación y sus impulsores. Estos hallazgos establecen una base para mejorar la previsión hidrológica, orientar las estrategias de adaptación climática y expandir las redes de observación para mejorar los marcos de modelado.

### 3.6 Conclusión

En este estudio, se construyó un modelo estadístico de reducción de escala adaptativo diario (DA-SDM) de alta resolución ( $\sim 1 \text{ km}$ ) para analizar los patrones de precipitación diaria extrema en el centro-sur de Chile durante un evento importante en 2006. El análisis identificó la elevación, los componentes del viento y la continentalidad como predictores geofísicos clave. El modelo demostró un rendimiento moderado, con valores de NSE, KGE y  $W_d$  superiores a 0,7 en todas las categorías de elevación. Sin embargo, la concentración de estimaciones por debajo de 0,4 destaca los desafíos de modelar la precipitación extrema en regiones con topografía compleja y redes de observación dispersas.

La integración de múltiples conjuntos de datos (ERA5, CHIRPS y otros) y la aplicación de la calibración de mapeo de cuantiles ayudaron a reducir los sesgos sistemáticos, aunque persisten

algunas limitaciones. A pesar de estas mejoras, persisten varios desafíos, en particular relacionados con los sesgos de los conjuntos de datos y los conjuntos de predictores limitados. Abordar estos problemas mediante conjuntos de datos personalizados, predictores adicionales (por ejemplo, índices de estabilidad atmosférica), técnicas de calibración alternativas o enfoques de aprendizaje automático físicamente interpretables podría mejorar aún más la precisión predictiva y, al mismo tiempo, mantener la interpretabilidad del modelo.

DA-SDM superó de manera consistente a los productos de precipitación basados en satélites (por ejemplo, CMORPH, TRMM), demostrando errores sistemáticos más bajos y una mejor concordancia con las observaciones in situ. Esto sugiere que DA-SDM es una herramienta valiosa para mejorar la reducción de escala de la precipitación, en particular en regiones con topografía compleja donde los modelos tradicionales enfrentan limitaciones significativas. Los eventos de precipitación extrema, como el caso de 2006, tienen graves impactos socioeconómicos, incluidas inundaciones y pérdidas agrícolas, lo que subraya la necesidad de mejores herramientas de pronóstico. Al abordar estas limitaciones, la investigación futura puede mejorar aún más la precisión predictiva, refinar el modelado de precipitaciones extremas y desarrollar herramientas de pronóstico para respaldar la preparación para desastres y la resiliencia climática.



## Capítulo 4

### Conclusión General

El presente trabajo ha desarrollado y evaluado una metodología de reducción de escala estadística para mejorar la representación espacio-temporal de la precipitación en la zona centro-sur de Chile. Para ello, se han implementado dos enfoques complementarios: (a) la generación de un conjunto de datos de precipitación mensual en alta resolución, utilizando como insumo principal un modelo numérico regional (WRF) con una resolución espacial de 4 km sobre el área de estudio, complementado con datos satelitales y observaciones in situ; (b) el desarrollo de un conjunto de datos de precipitación diaria enfocado en la caracterización de eventos extremos (DA-SDM). Ambos enfoques responden a la necesidad de contar con datos espaciales coherentes que representen la variabilidad climática de la región, caracterizada por una geografía compleja y una escasez de instrumentos de medición hidrometeorológica.

El primer enfoque, se centró en la construcción de un conjunto de datos de precipitación mensual de alta resolución ( $\sim 800 m$ ) para el período 2000-2011. Para ello, se combinó información de múltiples fuentes: un modelo numérico regional (WRF a 4 km de resolución), productos satelitales, reanálisis atmosféricos y observaciones in situ. La metodología incluyó un modelo topo-climático dinámico, en el cual se aplicaron técnicas de regresión multivariada para ajustar la distribución espacial de la precipitación en función de variables orográficas, tales como elevación, pendiente, exposición del terreno y distancia a la costa.

La evaluación de este primer producto generado, mostró una alta capacidad para representar la variabilidad espacio-temporal de la precipitación, con un coeficiente de determinación ( $R^2$ ) superior a 0.8 en las regiones de O'Higgins a Biobío, lo que indica una fuerte correspondencia entre las estimaciones modeladas y las observaciones in situ. Este alto grado de precisión se refleja también en las métricas estadísticas utilizadas, donde el coeficiente de correlación de Pearson ( $\rho_{xy}$ ) evidenció una adecuada correspondencia en la distribución espacial de la precipitación. Adicionalmente, el Nash-Sutcliffe Efficiency ( $NSE$ ) y el índice de Willmott ( $W_d$ ) indicaron

una buena capacidad del modelo para reproducir la variabilidad mensual, mientras que el PBIAS confirmó que el sesgo sistemático de las estimaciones se mantuvo dentro de rangos aceptables. Sin embargo, en las regiones más australes (Araucanía y Los Ríos), la calidad de la representación disminuyó, reflejando un aumento en la dispersión de los errores y una reducción en la correlación con los datos observados. Este deterioro en el desempeño se atribuye principalmente a tres factores clave: (1) la mayor complejidad orográfica, que introduce efectos locales difíciles de capturar; (2) la escasez de estaciones meteorológicas en zonas de altitud elevada, lo que limita la capacidad del modelo para ajustar correctamente los patrones de precipitación en estas áreas; y (3) la influencia diferencial de los predictores topoclimáticos, donde la elevación se identifica como la variable de mayor impacto en la estimación de la precipitación; consistente con estudios previos en regiones con topografía compleja, donde el levantamiento orográfico de masas de aire húmedas es el principal mecanismo modulador de la precipitación. Mientras, la distancia a la costa juega un nulo rol. Por lo tanto, a esta escala temporal los resultados sugieren que el forzamiento orográfico y las interacciones con la circulación atmosférica predominan sobre los efectos de continentalidad.

El segundo enfoque se centró en el desarrollo de un modelo estadístico adaptativo diario, denominado DA-SDM, diseñado específicamente para mejorar la representación de eventos extremos de precipitación a escala diaria. A diferencia del primer enfoque, DA-SDM no utiliza el modelo numérico WRF, sino que se basa exclusivamente en la combinación de datos satelitales, productos de reanálisis y observaciones in situ. Este modelo incorpora una selección optimizada de predictores geofísicos y dinámicos, incluyendo variables como la elevación, pendiente, orientación del terreno, índice de rugosidad topográfica (*TRI*) y distancia a la costa, además de factores meteorológicos clave como las componentes del viento a 10 metros ( $u_{10}$ ,  $v_{10}$ ), las cuales demostraron ser críticas para capturar la modulación orográfica de la precipitación en regiones de topografía compleja. Además, la incorporación de una corrección de sesgo basada en Quantile Mapping (QM) por cuantiles de elevación, permitió ajustar la distribución de los valores modelados. Esto, fue especialmente relevante en la calibración del modelo, asegurando una mayor coherencia con la climatología observada y mejorando su desempeño en la estimación de eventos de precipitación extrema.

El modelo DA-SDM demostró una mayor precisión en la representación de la precipitación extrema en regiones de altitud media (230-450 *m*), donde la correlación con las observaciones fue más alta y el error cuadrático medio (*RMSE*) se mantuvo por debajo de 15 *mm*. La evaluación del modelo con diferentes métricas estadísticas reveló una capacidad moderada a alta para

reproducir la variabilidad espacial de la precipitación extrema, con valores de Nash-Sutcliffe Eficiencia (NSE) superiores a 0.6 en altitudes intermedias, lo que indica una adecuada capacidad predictiva en estos sectores. Además, el índice de Willmott ( $W_d$ ) superó 0.7 en la mayoría de las categorías altitudinales, reflejando una buena concordancia entre las estimaciones del modelo y las observaciones in situ. Sin embargo, el desempeño del modelo se redujo en zonas de baja altitud ( $<100\ m$ ), donde se observó una subestimación de la variabilidad espacial, lo que se reflejó en valores de NSE, KGE y  $W_d$  inferiores a 0.5 y una mayor dispersión del error en una gran cantidad de estaciones evaluadas. Lo mismo refleja en altitudes elevadas ( $>450\ m$ ), DA-SDM tendió a infraestimar la precipitación en algunas estaciones, mostrando un deterioro en NSE, KGE y  $W_d$  y un aumento en el error sistemático. Este deterioro en la precisión del modelo en zonas de alta montaña se atribuye a la complejidad de los forzamientos topográficos y a la baja densidad de estaciones meteorológicas, lo que limita la capacidad del modelo para ajustar correctamente los valores extremos. Patrón confirmado por el análisis de PBIAS, donde se observó un mayor sesgo negativo en altitudes elevadas, indicando que la precipitación modelada fue consistentemente menor que la observada.

A pesar de estas limitaciones, DA-SDM mostró un desempeño superior en comparación con productos satelitales como CMORPH y TRMM, reduciendo los errores sistemáticos y mostrando una mejor concordancia con las observaciones in situ. En particular, mientras que los productos satelitales tendieron a sobreestimar la precipitación en altitudes elevadas, DA-SDM presentó un comportamiento más estable en la mayoría de las categorías altitudinales. No obstante, los resultados sugieren que, aunque la integración de múltiples conjuntos de datos mejoró la representación espacial de los eventos extremos, persisten sesgos asociados a efectos orográficos y a la limitada representación de eventos de precipitación extrema en los datos de entrenamiento.

Ambos enfoques presentan fortalezas y desafíos complementarios. Mientras que el modelo mensual de precipitación ofrece un producto robusto para estudios climatológicos y aplicaciones hidrológicas a largo plazo, DA-SDM proporciona una herramienta flexible para evaluar eventos extremos en resolución diaria. La comparación entre ambos enfoques evidencia que: (a) la integración de modelos numéricos regionales como WRF es útil para capturar patrones climáticos generales y son un input sustantivo en modelos de downscaling estadísticos, pero su resolución y/o parametrizaciones aún es limitada para eventos extremos; (b) la combinación de datos de satélite, reanálisis y observaciones permite mejorar la precisión de las estimaciones diarias, aunque presenta dificultades significativas en eventos de llovizna y representación en altura; (c) la incorporación de predictores dinámicos en DA-SDM como las componentes del viento ha sido

clave para mejorar la representación de eventos extremos, destacando la importancia de incluir variables adicionales en futuros modelos de reducción de escala; (d) en ambos productos, se aprecia la baja cantidad de estaciones de medición in-situ, generando un desafío en la calibración de productos de downscaling estadísticos..

Los productos generados en esta investigación representan un avance significativo en la estimación de la precipitación en regiones con alta variabilidad hidroclimática, con aplicaciones potenciales en la gestión de recursos hídricos, modelación climática y planificación territorial frente al cambio climático. Sin embargo, se identifican áreas clave para futuras mejoras: (a) la falta de datos en zonas de alta montaña sigue siendo una limitación, por lo que se recomienda fortalecer las redes de monitoreo en estas áreas críticas; (b) el uso de enfoques más sofisticados, como Bayesian Model Averaging o Machine Learning (en particular PINNS), podría reducir errores sistemáticos en regiones de alta montaña; (c) mantener la integración de técnicas estadísticas y dinámicas regionales podría mejorar la representación de eventos extremos.

Por lo tanto, esta investigación ha demostrado que un enfoque multivariado geo-estadístico de reducción de escala es una herramienta eficaz y robusta para mejorar la representación de la precipitación en Chile centro-sur. La aplicación de este enfoque a eventos de baja frecuencia, como la escala mensual, en combinación con un modelo numérico regional, permite una mejora significativa en la representación espacio-temporal de la precipitación, reduciendo errores sistemáticos y capturando con habilidad la variabilidad climática de la región. Por otra parte, al expandir este enfoque a eventos de alta frecuencia, como la precipitación diaria y, en particular, los eventos extremos, surgen desafíos adicionales. Si bien la incorporación de variables dinámicas, como las componentes del viento a 10 metros mejora la precisión del modelo, estas no son suficientes para capturar completamente la complejidad de los procesos físicos asociados a eventos extremos. En este contexto, el desarrollo de nuevas metodologías geo-estadísticas sigue siendo un área de investigación abierta, con un amplio potencial de mejora.

## Bibliografía

- [1] John T Abatzoglou. «Development of gridded surface meteorological data for ecological applications and modelling». En: *International journal of climatology* 33.1 (2013), págs. 121-131.
- [2] Arman Abdollahipour, Hassan Ahmadi y Babak Aminnejad. «A review of downscaling methods of satellite-based precipitation estimates». En: *Earth Science Informatics* 15.1 (2022), págs. 1-20.
- [3] P Aceituno. «Climate along the extratropical west coast of South America». En: *Earth system responses to global change: Contrasts between North and South America* (1993), págs. 61-69.
- [4] Patricio Aceituno et al. «Climate and weather in Chile». En: *Water resources of Chile* (2021), págs. 7-29.
- [5] Patricio Aceituno et al. «Climate and weather in Chile». En: *Water resources of Chile* (2021), págs. 7-29.
- [6] SA Adachi y H Tomita. «Methodology of the constraint condition in dynamical downscaling for regional climate evaluation: A review». En: *Journal of Geophysical Research: Atmospheres* 125.11 (2020), e2019JD032166.
- [7] SA Adachi y H Tomita. «Methodology of the constraint condition in dynamical downscaling for regional climate evaluation: A review». En: *Journal of Geophysical Research: Atmospheres* 125.11 (2020), e2019JD032166.
- [8] Jennifer C Adam et al. «BioEarth: Envisioning and developing a new regional earth system model to inform natural and agricultural resource management». En: *Climatic Change* 129 (2015), págs. 555-571.
- [9] Jennifer C Adam et al. «BioEarth: Envisioning and developing a new regional earth system model to inform natural and agricultural resource management». En: *Climatic Change* 129 (2015), págs. 555-571.
- [10] Pierre Ailliot et al. «Stochastic weather generators: an overview of weather type models». En: *Journal de la société française de statistique* 156.1 (2015), págs. 101-113.

- [11] Javed Akhter et al. «Evaluation of different large-scale predictor-based statistical downscaling models in simulating zone-wise monsoon precipitation over India». En: *Int. J. Climatol* 39.1 (2019), págs. 465-482.
- [12] Adelina Alexandru, Ramon de Elia y René Laprise. «Internal variability in regional climate downscaling at the seasonal scale». En: *Monthly Weather Review* 135.9 (2007), págs. 3221-3238.
- [13] Shaukat Ali et al. «Assessment of climate extremes in future projections downscaled by multiple statistical downscaling methods over Pakistan». En: *Atmospheric Research* 222 (2019), págs. 114-133.
- [14] Javier Álvarez Rodríguez. «Estimación de la distribución espacial de la precipitación en zonas montañosas mediante métodos geoestadísticos». Tesis doct. Caminos, 2011.
- [15] Francisco-J Alvial Vásquez, Rodrigo Abarca-del Río y Andrés I Ávila. «High-Resolution Precipitation Gridded Dataset on the South-Central Zone (34° S–41° S) of Chile». En: *Frontiers in Earth Science* 8 (2020), pág. 519975.
- [16] Tércio Ambrizzi et al. «The state of the art and fundamental aspects of regional climate modeling in South America». En: *Annals of the new york academy of sciences* 1436.1 (2019), págs. 98-120.
- [17] Muhammad Naveed Anjum et al. «Assessment of PERSIANN-CCS, PERSIANN-CDR, SM2RAIN-ASCAT, and CHIRPS-2.0 rainfall products over a semi-arid subtropical climatic region». En: *Water* 14.2 (2022), pág. 147.
- [18] Marcelo Araya Ojeda y Federico Ignacio Isla. «Variabilidad hidrológica en la región del Biobío: los eventos El Niño en zonas templadas de Chile». En: *Revista Universitaria de Geografía* 25.1 (2016), págs. 31-55.
- [19] Daniela Araya-Osses et al. «Climate change projections of temperature and precipitation in Chile based on statistical downscaling». En: *Climate Dynamics* 54 (2020), págs. 4309-4330.
- [20] Daniela Araya-Osses et al. «Climate change projections of temperature and precipitation in Chile based on statistical downscaling». En: *Climate Dynamics* 54.9-10 (2020), págs. 4309-4330. ISSN: 14320894. DOI: [10.1007/s00382-020-05231-4](https://doi.org/10.1007/s00382-020-05231-4).
- [21] José Luis Arumí et al. «Interacciones entre el agua superficial y subterránea en la región del Bío Bío de Chile». En: *Obras y proyectos* 12 (2012), págs. 4-13.
- [22] José L Arumí Ribera y RA Oyarzún Lucero. «Las aguas subterráneas en Chile». En: *Boletín Geológico y Minero* ÚMERO MONOGRÁFICO. HIDROGEOLOGÍA EN IBEROAMÉRICA (2006), págs. 37-45.

- [23] Hamed Ashouri et al. «PERSIANN-CDR: Daily precipitation climate data record from multisatellite observations for hydrological and climate studies». En: *Bulletin of the American Meteorological Society* 96.1 (2015), págs. 69-83.
- [24] Oscar Manuel Baez-Villanueva et al. «Temporal and spatial evaluation of satellite rainfall estimates over different regions in Latin-America». En: *Atmospheric Research* 213 (2018), págs. 34-50.
- [25] Bradford S Barrett, Jorge F Carrasco y Anthony P Testino. «Madden–Julian oscillation (MJO) modulation of atmospheric circulation and Chilean winter precipitation». En: *Journal of Climate* 25.5 (2012), págs. 1678-1688.
- [26] Bradford S Barrett y Sultan Hameed. «Seasonal variability in precipitation in central and southern Chile: Modulation by the South Pacific high». En: *Journal of Climate* 30.1 (2017), págs. 55-69.
- [27] Bradford S Barrett y Sultan Hameed. «Seasonal variability in precipitation in central and southern Chile: Modulation by the South Pacific high». En: *Journal of Climate* 30.1 (2017), págs. 55-69.
- [28] Salvador Barrios, Luisito Bertinelli y Eric Strobl. «Trends in rainfall and economic growth in Africa: A neglected cause of the African growth tragedy». En: *The Review of Economics and Statistics* 92.2 (2010), págs. 350-366.
- [29] Hylke E Beck et al. «Global-scale evaluation of 22 precipitation datasets using gauge observations and hydrological modeling». En: *Hydrology and Earth System Sciences* 21.12 (2017), págs. 6201-6217.
- [30] Hylke E Beck et al. «Global-scale evaluation of 22 precipitation datasets using gauge observations and hydrological modeling». En: *Hydrology and Earth System Sciences* 21.12 (2017), págs. 6201-6217.
- [31] Hylke E Beck et al. «MSWEP: 3-hourly 0.25 global gridded precipitation (1979–2015) by merging gauge, satellite, and reanalysis data». En: *Hydrology and Earth System Sciences* 21.1 (2017), págs. 589-615.
- [32] Hylke E Beck et al. «MSWEP: 3-hourly 0.25 global gridded precipitation (1979–2015) by merging gauge, satellite, and reanalysis data». En: *Hydrology and Earth System Sciences* 21.1 (2017), págs. 589-615.
- [33] Hylke E Beck et al. «MSWEP V2 global 3-hourly 0.1 precipitation: methodology and quantitative assessment». En: *Bulletin of the American Meteorological Society* 100.3 (2019), págs. 473-500.

- [34] Rasmus Benestad. «Downscaling climate information». En: *Oxford research encyclopedia of climate science*. 2016.
- [35] Rasmus E Benestad, Deliang Chen e Inger Hanssen-Bauer. *Empirical-statistical downscaling*. World Scientific Publishing Company, 2008.
- [36] T. Berezowski et al. «CPLFD-GDPT5: High-resolution gridded daily precipitation and temperature data set for two largest Polish river basins». En: *Earth System Science Data* 8.1 (2016), págs. 127-139. DOI: [10.5194/essd-8-127-2016](https://doi.org/10.5194/essd-8-127-2016). URL: <https://essd.copernicus.org/articles/8/127/2016/>.
- [37] M Bierkens, Peter Finke y Peter De Willigen. *Upscaling and downscaling methods for environmental research*. Kluwer Academic, 2000.
- [38] Marios Billios y Lampros Vasiliades. «A Network-Based Clustering Method to Ensure Homogeneity in Regional Frequency Analysis of Extreme Rainfall». En: *Water* 17.1 (2024), pág. 38.
- [39] Juan Pablo Boisier et al. «CR2MET: A high-resolution precipitation and temperature dataset for hydroclimatic research in Chile». En: *EGU general assembly conference abstracts*. 2018, pág. 19739.
- [40] EP Box George et al. «Time series analysis: forecasting and control». En: *San Francisco: Holden Bay* (1976).
- [41] S. Brinckmann, S. Krähenmann y P. Bissolli. «High-resolution daily gridded data sets of air temperature and wind speed for Europe». En: *Earth System Science Data* 8.2 (2016), págs. 491-516. DOI: [10.5194/essd-8-491-2016](https://doi.org/10.5194/essd-8-491-2016). URL: <https://essd.copernicus.org/articles/8/491/2016/>.
- [42] Luca Brocca et al. «A new method for rainfall estimation through soil moisture observations». En: *Geophysical Research Letters* 40.5 (2013), págs. 853-858.
- [43] Luca Brocca et al. «Soil as a natural rain gauge: Estimating global rainfall from satellite soil moisture data». En: *Journal of Geophysical Research: Atmospheres* 119.9 (2014), págs. 5128-5141.
- [44] Peter Caldwell et al. «Evaluation of a WRF dynamical downscaling simulation over California». En: *Climatic change* 95 (2009), págs. 499-521.
- [45] Corrado Camera et al. «Evaluation of a spatial rainfall generator for generating high resolution precipitation projections over orographically complex terrain». En: *Stochastic Environmental Research and Risk Assessment* 31 (2017), págs. 757-773.

- [46] Corrado Camera et al. «Evaluation of interpolation techniques for the creation of gridded daily precipitation ( $1 \times 1 \text{ km}^2$ ); Cyprus, 1980–2010». En: *Journal of Geophysical Research: Atmospheres* 119.2 (2014), págs. 693-712.
- [47] Alex J Cannon, Stephen R Sobie y Trevor Q Murdock. «Bias correction of GCM precipitation by quantile mapping: how well do methods preserve changes in quantiles and extremes?» En: *Journal of Climate* 28.17 (2015), págs. 6938-6959.
- [48] Dirk J Cannon et al. «Using reanalysis data to quantify extreme wind power generation statistics: A 33 year case study in Great Britain». En: *Renewable Energy* 75 (2015), págs. 767-778.
- [49] RM Cardoso et al. «WRF high resolution simulation of Iberian mean and extreme precipitation climate». En: *Int. J. Climatol* 33.11 (2013), págs. 2591-2608.
- [50] Greg T Carling et al. «Mechanisms, timing, and rates of arid region mountain front recharge». En: *Journal of Hydrology* 428 (2012), págs. 15-31.
- [51] Louis-Philippe Caron, Colin G Jones y Katja Winger. «Impact of resolution and downscaling technique in simulating recent Atlantic tropical cyclone activity». En: *Climate dynamics* 37 (2011), págs. 869-892.
- [52] Louis-Philippe Caron, Colin G Jones y Katja Winger. «Impact of resolution and downscaling technique in simulating recent Atlantic tropical cyclone activity». En: *Climate dynamics* 37 (2011), págs. 869-892.
- [53] Lina Mabel Castro, Jorge Gironás y Bonifacio Fernández. «Spatial estimation of daily precipitation in regions with complex relief and scarce data using terrain orientation». En: *Journal of Hydrology* 517 (2014), págs. 481-492.
- [54] Tereza Cavazos y Bruce C Hewitson. «Performance of NCEP–NCAR reanalysis variables in statistical downscaling of daily precipitation». En: *Climate Research* 28.2 (2005), págs. 95-107.
- [55] Guido Ceccherini et al. «High-resolution precipitation datasets in South America and West Africa based on satellite-derived rainfall, enhanced vegetation index and digital elevation model». En: *Remote Sensing* 7.5 (2015), págs. 6454-6488.
- [56] Cristian Chadwick et al. «Assessing reservoir performance under climate change. When is it going to be too late if current water management is not changed?» En: *Water* 13.1 (2020), pág. 64.
- [57] Fei Chen. «The Noah land surface model in WRF: a short tutorial». En: *LSM group meeting*. 2007.

- [58] Fengrui Chen et al. «Spatial downscaling of TRMM 3B43 precipitation considering spatial heterogeneity». En: *International Journal of Remote Sensing* 35.9 (2014), págs. 3074-3093.
- [59] Jie Chen, François P Brissette y Robert Leconte. «Assessing regression-based statistical approaches for downscaling precipitation over North America». En: *Hydrological processes* 28.9 (2014), págs. 3482-3504.
- [60] Jie Chen, François P Brissette y Robert Leconte. «Downscaling of weather generator parameters to quantify hydrological impacts of climate change». En: *Climate Research* 51.3 (2012), págs. 185-200.
- [61] Jie Chen y Xunchang John Zhang. «Challenges and potential solutions in statistical downscaling of precipitation». En: *Climatic Change* 165.3 (2021), pág. 63.
- [62] Mingyue Chen et al. «Assessing objective techniques for gauge-based analyses of global daily precipitation». En: *Journal of Geophysical Research: Atmospheres* 113.D4 (2008).
- [63] Shien-Tsung Chen, Pao-Shan Yu y Yi-Hsuan Tang. «Statistical downscaling of daily precipitation using support vector machines and multivariate analysis». En: *Journal of hydrology* 385.1-4 (2010), págs. 13-22.
- [64] FHS Chiew et al. «Comparison of runoff modelled using rainfall from different downscaling methods for historical and future climates». En: *Journal of Hydrology* 387.1-2 (2010), págs. 10-23.
- [65] Sin Chan Chou, Ana Maria Bueno Nunes e Iracema FA Cavalcanti. «Extended range forecasts over South America using the regional eta model». En: *Journal of Geophysical Research: Atmospheres* 105.D8 (2000), págs. 10147-10160.
- [66] Zhi-Weng Chua, Yuriy Kuleshov y Andrew Watkins. «Evaluation of satellite precipitation estimates over Australia». En: *Remote Sensing* 12.4 (2020), pág. 678.
- [67] Grzegorz J Ciach y Witold F Krajewski. «Analysis and modeling of spatial correlation structure in small-scale rainfall in Central Oklahoma». En: *Advances in water resources* 29.10 (2006), págs. 1450-1463.
- [68] Juan Carlos Gutiérrez Cifuentes. «Modelación atmosférica de la cuenca del río Baker mediante el modelo WRF, e implicaciones de la temperatura en superficie en un modelo de regresión lineal». Tesis doct. Universidad de Concepción, 2017.
- [69] Climate Prediction Center National Centers for Environmental Prediction National Weather Service NOAA US Department of Commerce. «NOAA CPC Morphing Technique (CMORPH) Global Precipitation Analyses». En: *Research Data Archive at the Center for Atmospheric Research, Computational*. (2011).

- [70] Christopher Daly, Ronald P. Neilson y Donald L. Phillips. «A Statistical-Topographic Model for Mapping Climatological Precipitation over Mountainous Terrain». En: *Journal of Applied Meteorology and Climatology* 33.2 (1994), págs. 140 -158. DOI: [10.1175/1520-0450\(1994\)033<0140:ASTMFM>2.0.CO;2](https://doi.org/10.1175/1520-0450(1994)033<0140:ASTMFM>2.0.CO;2). URL: [https://journals.ametsoc.org/view/journals/apme/33/2/1520-0450\\_1994\\_033\\_0140\\_astmfm\\_2\\_0\\_co\\_2.xml](https://journals.ametsoc.org/view/journals/apme/33/2/1520-0450_1994_033_0140_astmfm_2_0_co_2.xml).
- [71] Dick P Dee et al. «The ERA-Interim reanalysis: Configuration and performance of the data assimilation system». En: *Quarterly Journal of the royal meteorological society* 137.656 (2011), págs. 553-597.
- [72] Masoomeh Delbari, Salman Sharifazari y Ehsan Mohammadi. «Modeling daily soil temperature over diverse climate conditions in Iran—a comparison of multiple linear regression and support vector regression techniques». En: *Theoretical and Applied Climatology* 135 (2019), págs. 991-1001.
- [73] Masoomeh Delbari, Salman Sharifazari y Ehsan Mohammadi. «Modeling daily soil temperature over diverse climate conditions in Iran—a comparison of multiple linear regression and support vector regression techniques». En: *Theoretical and Applied Climatology* 135 (2019), págs. 991-1001.
- [74] Ravinesh C Deo y Mehmet Şahin. «Application of the artificial neural network model for prediction of monthly standardized precipitation and evapotranspiration index using hydro-meteorological parameters and climate indices in eastern Australia». En: *Atmospheric research* 161 (2015), págs. 65-81.
- [75] Usha Devi et al. «Statistical method of forecasting of seasonal precipitation over the North-west Himalayas: North Atlantic Oscillation as precursor». En: *Pure and Applied Geophysics* 177.7 (2020), págs. 3501-3511.
- [76] Fernando Díaz Labbé et al. «Informe sistema frontal 10 al 13 de julio 2006». En: (2006).
- [77] Yonas B Dibike y Paulin Coulibaly. «Hydrologic impact of climate change in the Saguenay watershed: comparison of downscaling methods and hydrologic models». En: *Journal of hydrology* 307.1-4 (2005), págs. 145-163.
- [78] E Diez et al. «Statistical and dynamical downscaling of precipitation over Spain from DEMETER seasonal forecasts». En: *Tellus A: Dynamic Meteorology and Oceanography* 57.3 (2005), págs. 409-423.
- [79] T Dinku et al. «Validation of satellite rainfall products over East Africa's complex topography». En: *International Journal of Remote Sensing* 28.7 (2007), págs. 1503-1526.

- [80] Tufa Dinku. «Challenges with availability and quality of climate data in Africa». En: *Extreme hydrology and climate variability*. Elsevier, 2019, págs. 71-80.
- [81] Tufa Dinku et al. «Bridging critical gaps in climate services and applications in Africa». En: *Earth Perspectives* 1 (2014), págs. 1-13.
- [82] Wisdom MD Dlamini y Samkele S Tfwala. «The performance of a high-resolution satellite-derived precipitation product over the topographically complex landscape of Eswatini». En: *Geoscience Data Journal* (2024).
- [83] DMC. *Análisis de los resultados convenio alta dirección pública, director, dirección meteorológica de Chile, objetivo n3*. 2015.
- [84] Markus G Donat et al. «More extreme precipitation in the world's dry and wet regions». En: *Nature Climate Change* 6.5 (2016), págs. 508-513.
- [85] Batsuren Dorjsuren et al. «Trend analysis of hydro-climatic variables in the Great Lakes Depression region of Mongolia». En: *Journal of Water and Climate Change* 15.3 (2024), págs. 940-957.
- [86] Jimmy Dudhia. «Numerical study of convection observed during the winter monsoon experiment using a mesoscale two-dimensional model». En: *Journal of Atmospheric Sciences* 46.20 (1989), págs. 3077-3107.
- [87] Elizabeth E Ebert, John E Janowiak y Chris Kidd. «Comparison of near-real-time precipitation estimates from satellite observations and numerical models». En: *Bulletin of the American Meteorological Society* 88.1 (2007), págs. 47-64.
- [88] Elizabeth E Ebert, John E Janowiak y Chris Kidd. «Comparison of near-real-time precipitation estimates from satellite observations and numerical models». En: *Bulletin of the American Meteorological Society* 88.1 (2007), págs. 47-64.
- [89] Jonathan M Eden y Martin Widmann. «Downscaling of GCM-simulated precipitation using model output statistics». En: *Journal of Climate* 27.1 (2014), págs. 312-324.
- [90] Nils Eingrüber y Wolfgang Korres. «Climate change simulation and trend analysis of extreme precipitation and floods in the mesoscale Rur catchment in western Germany until 2099 using Statistical Downscaling Model (SDSM) and the Soil & Water Assessment Tool (SWAT model)». En: *Science of The Total Environment* 838 (2022), pág. 155775.
- [91] Mohammad Reza Eini, Akbar Rahmati y Mikołaj Piniewski. «Hydrological application and accuracy evaluation of PERSIANN satellite-based precipitation estimates over a humid continental climate catchment». En: *Journal of Hydrology: Regional Studies* 41 (2022), pág. 101109.

- [92] Marie Ekström, Michael R Grose y Penny H Whetton. «An appraisal of downscaling methods used in climate change research». En: *Wiley Interdisciplinary Reviews: Climate Change* 6.3 (2015), págs. 301-319.
- [93] Marie Ekström, Michael R Grose y Penny H Whetton. «An appraisal of downscaling methods used in climate change research». En: *Wiley Interdisciplinary Reviews: Climate Change* 6.3 (2015), págs. 301-319.
- [94] Tom G Farr et al. «The shuttle radar topography mission». En: *Reviews of geophysics* 45.2 (2007).
- [95] Olivia Ferguglia, Elisa Palazzi y Enrico Arnone. «Elevation dependent change in ERA5 precipitation and its extremes». En: *Climate Dynamics* 62.8 (2024), págs. 8137-8153.
- [96] Alejandro Fernández-Ferrero et al. «Evaluation of statistical downscaling in short range precipitation forecasting». En: *Atmospheric Research* 94.3 (2009), págs. 448-461.
- [97] Ralph R Ferraro et al. «A screening methodology for passive microwave precipitation retrieval algorithms». En: *Journal of the Atmospheric Sciences* 55.9 (1998), págs. 1583-1600.
- [98] Frauke Feser et al. «Regional climate models add value to global model data: a review and selected examples». En: *Bulletin of the American Meteorological Society* 92.9 (2011), págs. 1181-1192.
- [99] Frauke Feser et al. «Regional climate models add value to global model data: a review and selected examples». En: *Bulletin of the American Meteorological Society* 92.9 (2011), págs. 1181-1192.
- [100] Stephen E Fick y Robert J Hijmans. «WorldClim 2: new 1-km spatial resolution climate surfaces for global land areas». En: *International journal of climatology* 37.12 (2017), págs. 4302-4315.
- [101] Melitta Fiebig-Wittmaack et al. «Climatic trends and impact of climate change on agriculture in an arid Andean valley». En: *Climatic change* 111 (2012), págs. 819-833.
- [102] Erich M Fischer y Reto Knutti. «Observed heavy precipitation increase confirms theory and early models». En: *Nature Climate Change* 6.11 (2016), págs. 986-991.
- [103] Hayley J Fowler, Stephen Blenkinsop y Claudia Tebaldi. «Linking climate change modelling to impacts studies». En: (2007).
- [104] Hayley J Fowler et al. «Anthropogenic intensification of short-duration rainfall extremes». En: *Nature Reviews Earth & Environment* 2.2 (2021), págs. 107-122.

- [105] Jürgen Fuchsberger, Gottfried Kirchengast y Thomas Kabas. «WegenerNet high-resolution weather and climate data from 2007 to 2020». En: *Earth System Science Data* 13.3 (2021), págs. 1307-1334.
- [106] H Fuenzalida. «Clima de Chile para fines del siglo XXI: Simulaciones con Modelo PRECIS bajo escenarios A2 y B2 del IPCC». En: *Revista Ambiente y Desarrollo* 23.2 (2007), págs. 9-14.
- [107] H Fuenzalida. «Un país de extremos climáticos». En: *Chile, Esencia y Evolución. Universidad de Chile, Santiago* (1982), págs. 27-35.
- [108] Oliver Fuhrer et al. «Near-global climate simulation at 1 km resolution: establishing a performance baseline on 4888 GPUs with COSMO 5.0». En: *Geoscientific Model Development* 11.4 (2018), págs. 1665-1681.
- [109] C Funk et al. «A global satellite-assisted precipitation climatology». En: *Earth System Science Data* 7.2 (2015), págs. 275-287.
- [110] Chris Funk et al. «The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes». En: *Scientific data* 2.1 (2015), págs. 1-21.
- [111] Chris Funk et al. «The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes». En: *Scientific data* 2.1 (2015), págs. 1-21.
- [112] I Fustos et al. «Rainfall-induced landslide identification using numerical modelling: A southern Chile case». En: *Journal of South American Earth Sciences* 101 (2020), pág. 102587.
- [113] I Fustos et al. «Rainfall-Induced Landslides forecast using local precipitation and global climate indexes». En: *Natural Hazards* 102 (2020), págs. 115-131.
- [114] William A Gallus. «Eta simulations of three extreme precipitation events: Sensitivity to resolution and convective parameterization». En: *Weather and forecasting* 14.3 (1999), págs. 405-426.
- [115] William A Gallus y Moti Segal. «Sensitivity of forecast rainfall in a Texas convective system to soil moisture and convective parameterization». En: *Weather and forecasting* 15.5 (2000), págs. 509-525.
- [116] R Garreaud, M Falvey y A Montecinos. «Orographic precipitation in coastal southern Chile: Mean distribution, temporal variability, and linear contribution». En: *Journal of Hydrometeorology* 17.4 (2016), págs. 1185-1202.
- [117] René Garreaud et al. «Cambio climático: bases físicas e impactos en Chile.» En: (2011).
- [118] René D Garreaud. «The Andes climate and weather». En: *Advances in geosciences* 22 (2009), págs. 3-11.

- [119] René D Garreaud et al. «Atmospheric Rivers in South-Central Chile: Zonal and Tilted Events». En: *Atmosphere* 15.4 (2024), pág. 406.
- [120] René Garreaud Salazar, M Falvey y A Montecinos. «Orographic Precipitation in Coastal Southern Chile: Mean Distribution, Temporal Variability, and Linear Contribution». En: (2016).
- [121] Peter R Gent et al. «Improvements in a half degree atmosphere/land version of the CCSM». En: *Climate Dynamics* 34 (2010), págs. 819-833.
- [122] Jose George y P Athira. «A model output statistic-based probabilistic approach for statistical downscaling of temperature». En: *Theoretical and Applied Climatology* (2024), págs. 1-20.
- [123] Urs Germann et al. «Weather radar in complex orography». En: *Remote Sensing* 14.3 (2022), pág. 503.
- [124] Charles G Gertler y Paul A O’Gorman. «Changing available energy for extratropical cyclones and associated convection in Northern Hemisphere summer». En: *Proceedings of the National Academy of Sciences* 116.10 (2019), págs. 4105-4110.
- [125] Filippo Giorgi y William J Gutowski Jr. «Regional dynamical downscaling and the CORDEX initiative». En: *Annual review of environment and resources* 40.1 (2015), págs. 467-490.
- [126] Filippo Giorgi, Colin Jones, Ghassem R Asrar et al. «Addressing climate information needs at the regional level: the CORDEX framework». En: *World Meteorological Organization (WMO) Bulletin* 58.3 (2009), pág. 175.
- [127] Filippo Giorgi, Colin Jones, Ghassem R Asrar et al. «Addressing climate information needs at the regional level: the CORDEX framework». En: *World Meteorological Organization (WMO) Bulletin* 58.3 (2009), pág. 175.
- [128] José Gomis-Cebolla et al. «Evaluation of ERA5 and ERA5-Land reanalysis precipitation datasets over Spain (1951–2020)». En: *Atmospheric Research* 284 (2023), pág. 106606.
- [129] Santos J González-Rojí et al. «Harmonized evaluation of daily precipitation downscaled using SDSM and WRF+ WRFDA models over the Iberian Peninsula». En: *Climate dynamics* 53.3 (2019), págs. 1413-1433.
- [130] Hugues. Goosse. «Climate system dynamics and modelling». En: (2015), pág. 358. URL: [https://books.google.com/books/about/Climate\\_System\\_Dynamics\\_and\\_Modeling.html?hl=es&id=aCFTCgAAQBAJ](https://books.google.com/books/about/Climate_System_Dynamics_and_Modeling.html?hl=es&id=aCFTCgAAQBAJ).
- [131] Alice M Grimm, Vicente R Barros y Moira E Doyle. «Climate variability in southern South America associated with El Niño and La Niña events». En: *Journal of climate* 13.1 (2000), págs. 35-58.

- [132] Hoshin V. Gupta et al. «Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling». En: *Journal of Hydrology* 377.1 (2009), págs. 80-91. ISSN: 0022-1694. DOI: <https://doi.org/10.1016/j.jhydrol.2009.08.003>. URL: <https://www.sciencedirect.com/science/article/pii/S0022169409004843>.
- [133] JM Gutiérrez et al. «Review of the different statistical downscaling methods for s2d prediction». En: *Technical Report. SPECS Deliverable 52* (2013), pág. 1.
- [134] IC Harris, PD Jones, T Osborn et al. «CRU TS4. 01: Climatic Research Unit (CRU) Time-Series (TS) version 4.01 of high-resolution gridded data of month-by-month variation in climate (Jan. 1901–Dec. 2016)». En: *Centre for Environmental Data Analysis* 25 (2017).
- [135] IPDJ Harris et al. «Updated high-resolution grids of monthly climatic observations-the CRU TS3. 10 Dataset». En: *International journal of climatology* 34 (2014), págs. 623-642.
- [136] Muhammad Zia Hashmi, Asaad Y Shamseldin y Bruce W Melville. «Comparison of SDSM and LARS-WG for simulation and downscaling of extreme precipitation events in a watershed». En: *Stochastic Environmental Research and Risk Assessment* 25 (2011), págs. 475-484.
- [137] Lauren Hay, Roland Viger y GREGORY McCABE. «Precipitation interpolation in mountainous regions using multiple linear regression». En: *IAHS Publications-Series of Proceedings and Reports-Intern Assoc Hydrological Sciences* 248 (1998), págs. 33-38.
- [138] Cristián Henríquez, Nicolle Aspee y Jorge Quense. «Zonas de catástrofe por eventos hidrometeorológicos en Chile y aportes para un índice de riesgo climático». En: *Revista de Geografía Norte Grande* 63 (2016), págs. 27-44.
- [139] N Herold et al. «How much does it rain over land?». En: *Geophysical Research Letters* 43.1 (2016), págs. 341-348.
- [140] H Hersbach et al. *Datos horarios de ERA5 sobre niveles únicos desde 1940 hasta la actualidad. Servicio de cambio climático de Copernicus (C3S) Climate Data Store (CDS)*. 2023. URL: <https://cds.climate.copernicus.eu/datasets/reanalysis-era5-single-levels?tab=overview>.
- [141] Hans Hersbach et al. «The ERA5 global reanalysis». En: *Quarterly Journal of the Royal Meteorological Society* 146.730 (2020), págs. 1999-2049.
- [142] Bruce C Hewitson y Robert George Crane. «Climate downscaling: techniques and application». En: *Climate Research* 7.2 (1996), págs. 85-95.

- [143] Robert J Hijmans et al. «Very high resolution interpolated climate surfaces for global land areas». En: *International Journal of Climatology: A Journal of the Royal Meteorological Society* 25.15 (2005), págs. 1965-1978.
- [144] Maïke Holthuijzen. *High-resolution downscaling and bias-correction of temperature and precipitation: advances in statistical methods*. The University of Vermont y State Agricultural College, 2022.
- [145] Song-You Hong, Jimy Dudhia y Shu-Hua Chen. «A revised approach to ice microphysical processes for the bulk parameterization of clouds and precipitation». En: *Monthly weather review* 132.1 (2004), págs. 103-120.
- [146] Song-You Hong, Yign Noh y Jimy Dudhia. «A new vertical diffusion package with an explicit treatment of entrainment processes». En: *Monthly weather review* 134.9 (2006), págs. 2318-2341.
- [147] Yang Hong et al. «Evaluation of PERSIANN-CCS rainfall measurement using the NAME event rain gauge network». En: *Journal of Hydrometeorology* 8.3 (2007), págs. 469-482.
- [148] Seyed-Mohammad Hosseini-Moghari, Shahab Araghinejad y Kumars Ebrahimi. «Spatio-temporal evaluation of global gridded precipitation datasets across Iran». En: *Hydrological Sciences Journal* 63.11 (2018), págs. 1669-1688.
- [149] Yu-Kun Hou et al. «Coupling a Markov chain and support vector machine for at-site downscaling of daily precipitation». En: *Journal of Hydrometeorology* 18.9 (2017), págs. 2385-2406.
- [150] Robert A Houze Jr. «Orographic effects on precipitating clouds». En: *Reviews of Geophysics* 50.1 (2012).
- [151] K-L Hsu et al. «Rainfall estimation from satellite imagery». En: *artificial neural networks in hydrology* (2000), págs. 209-234.
- [152] Kou-lin Hsu et al. «Precipitation estimation from remotely sensed information using artificial neural networks». En: *Journal of Applied Meteorology and Climatology* 36.9 (1997), págs. 1176-1190.
- [153] Kuo-lin Hsu et al. «Estimation of physical variables from multichannel remotely sensed imagery using a neural network: Application to rainfall estimation». En: *Water Resources Research* 35.5 (1999), págs. 1605-1618.
- [154] Hu ZengYun Hu ZengYun et al. «Evaluation of three global gridded precipitation data sets in central Asia based on rain gauge observations.» En: (2018).

- [155] George J Huffman et al. «The TRMM multisatellite precipitation analysis (TMPA): Quasi-global, multiyear, combined-sensor precipitation estimates at fine scales». En: *Journal of hydrometeorology* 8.1 (2007), págs. 38-55.
- [156] Santiago I Hurtado et al. «Monthly gridded precipitation databases performance evaluation in North Patagonia, Argentina». En: *Theoretical and Applied Climatology* 155.9 (2024), págs. 8771-8783.
- [157] Reyes M. I. «Análisis y aplicación del método geoestadístico kriging ordinario, en estaciones pluviográficas de la región metropolitana, maule y bíobío». En: (2013).
- [158] Eun-Soon Im et al. «Hydroclimatological response to dynamically downscaled climate change simulations for Korean basins». En: *Climatic Change* 100 (2010), págs. 485-508.
- [159] Walter W Immerzeel, Ludovicus PH Van Beek y Marc FP Bierkens. «Climate change will affect the Asian water towers». En: *science* 328.5984 (2010), págs. 1382-1385.
- [160] IPCC. «Climate change 2007: impacts, adaptation and vulnerability». En: 2300 (2007).
- [161] Naser Izadi et al. «Evaluation of ERA5 precipitation accuracy based on various time scales over Iran during 2000–2018». En: *Water* 13.18 (2021), pág. 2538.
- [162] Daniela Jacob y Ralf Podzun. «Sensitivity studies with the regional climate model REMO». En: *Meteorology and atmospheric physics* 63 (1997), págs. 119-129.
- [163] Alexandra P Jacquin y Jaime C Soto-Sandoval. «Interpolation of monthly precipitation amounts in mountainous catchments with sparse precipitation networks». En: *Chilean journal of agricultural research* 73.4 (2013), págs. 406-413.
- [164] Isidora Jankov et al. «The impact of different WRF model physical parameterizations and their interactions on warm season MCS rainfall». En: *Weather and forecasting* 20.6 (2005), págs. 1048-1060.
- [165] NE Jensen y Lisbeth Pedersen. «Spatial variability of rainfall: Variations within a single radar pixel». En: *Atmospheric Research* 77.1-4 (2005), págs. 269-277.
- [166] Lei Ji, Gabriel B. Senay y James P. Verdin. «Evaluation of the Global Land Data Assimilation System (GLDAS) Air Temperature Data Products». En: *Journal of Hydrometeorology* 16.6 (2015), págs. 2463 -2480. DOI: [10.1175/JHM-D-14-0230.1](https://doi.org/10.1175/JHM-D-14-0230.1). URL: [https://journals.ametsoc.org/view/journals/hydr/16/6/jhm-d-14-0230\\_1.xml](https://journals.ametsoc.org/view/journals/hydr/16/6/jhm-d-14-0230_1.xml).
- [167] Qin Jiang et al. «Evaluation of the ERA5 reanalysis precipitation dataset over Chinese Mainland». En: *Journal of hydrology* 595 (2021), pág. 125660.

- [168] Robert J Joyce et al. «CMORPH: A method that produces global precipitation estimates from passive microwave and infrared data at high spatial and temporal resolution». En: *Journal of hydrometeorology* 5.3 (2004), págs. 487-503.
- [169] Cristóbal Juliá, David A Rahn y José A Rutllant. «Assessing the influence of the MJO on strong precipitation events in subtropical, semi-arid north-central Chile (30 S)». En: *Journal of Climate* 25.20 (2012), págs. 7003-7013.
- [170] Thomas Jung et al. «Sensitivity of extratropical cyclone characteristics to horizontal resolution in the ECMWF model». En: *Quarterly Journal of the Royal Meteorological Society: A journal of the atmospheric sciences, applied meteorology and physical oceanography* 132.619 (2006), págs. 1839-1857.
- [171] Clémentine Junquas et al. «Understanding the influence of orography on the precipitation diurnal cycle and the associated atmospheric processes in the central Andes». En: *Climate dynamics* 50 (2018), págs. 3995-4017.
- [172] Peter C Kalverla et al. «Low-level jets over the North Sea based on ERA5 and observations: together they do better». En: *Wind Energy Science* 4.2 (2019), págs. 193-209.
- [173] Thomas R Karl et al. «A method of relating general circulation model simulated climate to the observed local climate. Part I: Seasonal statistics». En: *Journal of Climate* 3.10 (1990), págs. 1053-1079.
- [174] Arturo A Keller et al. «Downscaling approaches of climate change projections for watershed modeling: Review of theoretical and practical considerations». En: *PLoS Water* 1.9 (2022), e0000046.
- [175] Elizabeth J Kendon et al. «Do convection-permitting regional climate models improve projections of future precipitation change?» En: *Bulletin of the American Meteorological Society* 98.1 (2017), págs. 79-93.
- [176] C Kidd et al. «Intercomparison of high-resolution precipitation products over northwest Europe». En: *Journal of Hydrometeorology* 13.1 (2012), págs. 67-83.
- [177] Chris Kidd, Erin Dawkins y George Huffman. «Comparison of precipitation derived from the ECMWF operational forecast model and satellite precipitation datasets». En: *Journal of Hydrometeorology* 14.5 (2013), págs. 1463-1482.
- [178] Chris Kidd, Erin Dawkins y George Huffman. «Comparison of precipitation derived from the ECMWF operational forecast model and satellite precipitation datasets». En: *Journal of Hydrometeorology* 14.5 (2013), págs. 1463-1482.

- [179] Chris Kidd y V Levizzani. «Status of satellite precipitation retrievals». En: *Hydrology and Earth System Sciences* 15.4 (2011), págs. 1109-1116.
- [180] Chris Kidd y V Levizzani. «Status of satellite precipitation retrievals». En: *Hydrology and Earth System Sciences* 15.4 (2011), págs. 1109-1116.
- [181] JW Kim et al. «The statistical problem of climate inversion: Determination of the relationship between local and large-scale climate». En: *Monthly weather review* 112.10 (1984), págs. 2069-2077.
- [182] M Kitchen y RM Blackall. «Representativeness errors in comparisons between radar and gauge measurements of rainfall». En: *Journal of Hydrology* 134.1-4 (1992), págs. 13-33.
- [183] William H Klein. «Winter precipitation as related to the 700–mb circulation». En: *Bulletin of the American Meteorological Society* 29.9 (1948), págs. 439-453.
- [184] William H Klein y Harry R Glahn. «Forecasting local weather by means of model output statistics». En: *Bulletin of the American Meteorological Society* 55.10 (1974), págs. 1217-1227.
- [185] William H Klein y Harry R Glahn. «Forecasting local weather by means of model output statistics». En: *Bulletin of the American Meteorological Society* 55.10 (1974), págs. 1217-1227.
- [186] Harald Kling, Martin Fuchs y Maria Paulin. «Runoff conditions in the upper Danube basin under an ensemble of climate change scenarios». En: *Journal of hydrology* 424 (2012), págs. 264-277.
- [187] Daniel Klocke et al. «Rediscovery of the doldrums in storm-resolving simulations over the tropical Atlantic». En: *Nature Geoscience* 10.12 (2017), págs. 891-896.
- [188] Kenneth R Knapp. «Scientific data stewardship of International Satellite Cloud Climatology Project B1 global geostationary observations». En: *Journal of Applied Remote Sensing* 2.1 (2008), pág. 023548.
- [189] Maria Kofidou, Stavros Stathopoulos y Alexandra Gemitzi. «Review on spatial downscaling of satellite derived precipitation estimates». En: *Environmental Earth Sciences* 82.18 (2023), pág. 424.
- [190] J Koistinen. «Operational Correction of Radar Rainfall Errors due to the Vertical Reflectivity Profile. 25th Int Radar Meteor Conf». En: AMS. 1991.
- [191] WF Krajewski y James A Smith. «Radar hydrology: Rainfall estimation». En: *Advances in water resources* 25.8-12 (2002), págs. 1387-1394.
- [192] Sönke Kreft, David Eckstein, Inga Melchior et al. «Global climate risk index 2017. Who suffers most from extreme weather events? Weather-related loss events in 2015 and 1996 to 2015». En: (2016).

- [193] Frank Kreienkamp, Philip Lorenz y Tobias Geiger. «Statistically downscaled CMIP6 projections show stronger warming for Germany». En: *Atmosphere* 11.11 (2020), pág. 1245.
- [194] Frank Kreienkamp et al. «Evaluation of the empirical–statistical downscaling method EPI-SODES». En: *Climate dynamics* 52 (2019), págs. 991-1026.
- [195] Miguel Lagos-Zúñiga et al. «Trends in seasonal precipitation extremes and associated temperatures along continental Chile». En: *Climate Dynamics* (2024), págs. 1-18.
- [196] Miguel Lagos-Zúñiga et al. «Trends in seasonal precipitation extremes and associated temperatures along continental Chile». En: *Climate Dynamics* (2024), págs. 1-18.
- [197] David Lavers, Christel Prudhomme y David M Hannah. «Large-scale climate, precipitation and British river flows: Identifying hydroclimatological connections and dynamics». En: *Journal of Hydrology* 395.3-4 (2010), págs. 242-255.
- [198] Sante Laviola et al. «The 183-WSL fast rain rate retrieval algorithm. Part II: Validation using ground radar measurements». En: *Atmospheric research* 134 (2013), págs. 77-86.
- [199] Sante Laviola et al. «The 183-WSL fast rain rate retrieval algorithm. Part II: Validation using ground radar measurements». En: *Atmospheric research* 134 (2013), págs. 77-86.
- [200] Carlos Le Quesne et al. «Long-term glacier variations in the Central Andes of Argentina and Chile, inferred from historical records and tree-ring reconstructed precipitation». En: *Palaeogeography, Palaeoclimatology, Palaeoecology* 281.3-4 (2009), págs. 334-344.
- [201] Carlos Le Quesne et al. «Long-term glacier variations in the Central Andes of Argentina and Chile, inferred from historical records and tree-ring reconstructed precipitation». En: *Palaeogeography, Palaeoclimatology, Palaeoecology* 281.3-4 (2009), págs. 334-344.
- [202] Renan Le Roux et al. «Comparison of statistical and dynamical downscaling results from the WRF model». En: *Environmental modelling & software* 100 (2018), págs. 67-73.
- [203] MN Legasa et al. «Assessing three perfect prognosis methods for statistical downscaling of climate change precipitation scenarios». En: *Geophysical Research Letters* 50.9 (2023), e2022GL102525.
- [204] Mikel Néstor Legasa Ríos. «Advances for statistical downscaling of climate change precipitation scenarios based on machine learning techniques». En: (2023). URL: <https://repositorio.unican.es/xmlui/handle/10902/29679>.
- [205] Mikel Néstor Legasa Ríos et al. «Advances for statistical downscaling of climate change precipitation scenarios based on machine learning techniques». En: (2023).

- [206] David Leutwyler et al. «Evaluation of the convection-resolving climate modeling approach on continental scales». En: *Journal of Geophysical Research: Atmospheres* 122.10 (2017), págs. 5237-5258.
- [207] Randall J. LeVeque. «Finite Difference Methods for Ordinary and Partial Differential Equations». En: *Finite Difference Methods for Ordinary and Partial Differential Equations* (2007). DOI: [10.1137/1.9780898717839](https://doi.org/10.1137/1.9780898717839).
- [208] Shiting Li et al. «Downscaling of environmental indicators: A review». En: *Science of The Total Environment* (2024), pág. 170251.
- [209] Xin-Zhong Liang et al. «Regional climate model simulation of US precipitation during 1982–2002. Part I: Annual cycle». En: *Journal of Climate* 17.18 (2004), págs. 3510-3529.
- [210] Ronghua Liu et al. «Global-scale ERA5 product precipitation and temperature evaluation». En: *Ecological Indicators* 166 (2024), pág. 112481.
- [211] Yonghe Liu et al. «Identify optimal predictors of statistical downscaling of summer daily precipitation in China from three-dimensional large-scale variables». En: *Atmospheric research* 224 (2019), págs. 99-113.
- [212] Liu XiaoMang Liu XiaoMang et al. «Evaluating the streamflow simulation capability of PERSIANN-CDR daily rainfall products in two river basins on the Tibetan Plateau.» En: (2017).
- [213] Arman Kavyani Malayeri, Bahram Saghafian y Tayeb Raziei. «Performance evaluation of ERA5 precipitation estimates across Iran». En: *Arabian Journal of Geosciences* 14 (2021), págs. 1-18.
- [214] Rodrigo Manzananas et al. «Statistical downscaling or bias adjustment? A case study involving implausible climate change projections of precipitation in Malawi». En: *Climatic Change* 162 (2020), págs. 1437-1453.
- [215] D. Maraun et al. «Precipitation downscaling under climate change: Recent developments to bridge the gap between dynamical models and the end user». En: *Reviews of Geophysics* 48.3 (2010). ISSN: 1944-9208. DOI: [10.1029/2009RG000314](https://doi.org/10.1029/2009RG000314). URL: <https://onlinelibrary.wiley.com/doi/full/10.1029/2009RG000314><https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2009RG000314>
- [216] Douglas Maraun y Martin Widmann. *Statistical downscaling and bias correction for climate research*. Cambridge University Press, 2018.

- [217] Douglas Maraun, Martin Widmann y José M Gutiérrez. «Statistical downscaling skill under present climate conditions: A synthesis of the VALUE perfect predictor experiment». En: (2019).
- [218] Douglas Maraun et al. «Towards process-informed bias correction of climate change simulations». En: *Nature Climate Change* 7.11 (2017), págs. 764-773.
- [219] Jorge Marquínez, Javier Lastra y Pilar García. «Estimation models for precipitation in mountainous regions: the use of GIS and multivariate analysis». En: *Journal of hydrology* 270.1-2 (2003), págs. 1-11.
- [220] Rebeca Martínez-Retureta et al. «Estimation of the climate change impact on the hydrological balance in basins of south-central Chile». En: *Water* 13.6 (2021), pág. 794.
- [221] C Matulla et al. «Influence of similarity measures on the performance of the analog method for downscaling daily precipitation». En: *Climate Dynamics* 30 (2008), págs. 133-144.
- [222] Franco D Medina et al. «Performance of CHIRPS dataset for monthly and annual rainfall indices in Northern Argentina». En: *Atmospheric Research* 283 (2023), pág. 106545.
- [223] Francisco J Meza et al. «Impacts of climate change on irrigated agriculture in the Maipo Basin, Chile: reliability of water rights and changes in the demand for irrigation». En: *Journal of water resources planning and management* 138.5 (2012), págs. 421-430.
- [224] Silas Michaelides et al. «Precipitation: Measurement, remote sensing, climatology and modeling». En: *Atmospheric Research* 94.4 (2009), págs. 512-533.
- [225] A Miller. *The climate of Chile*. In "World survey of climatology. Climates of Central and South America." (W. Schwerdtfeger, Ed.) 1976.
- [226] Yoshiaki Miyamoto et al. «Deep moist atmospheric convection in a subkilometer global simulation». En: *Geophysical Research Letters* 40.18 (2013), págs. 4922-4926.
- [227] Eli J Mlawer et al. «Radiative transfer for inhomogeneous atmospheres: RRTM, a validated correlated-k model for the longwave». En: *Journal of Geophysical Research: Atmospheres* 102.D14 (1997), págs. 16663-16682.
- [228] RJ Moore et al. «Design of the HYREX raingauge network». En: *Hydrology and Earth System Sciences* 4.4 (2000), págs. 521-530.
- [229] L Morales-Salinas et al. «Simple linear algorithm to estimate the space-time variability of precipitable water in the Araucanía Region, Chile». En: *Journal of soil science and plant nutrition* 12.2 (2012), págs. 295-302.
- [230] Adriana Aparecida Moreira et al. «Assessment of terrestrial water balance using remote sensing data in South America». En: *Journal of Hydrology* 575 (2019), págs. 131-147.

- [231] Enrique Muñoz et al. «Comparison of gridded and measured rainfall data for basin-scale hydrological studies». En: *Chilean Journal of Agricultural Research* 71 (2011), Nr. 3 71.3 (2011), págs. 459-468.
- [232] Enrique Muñoz et al. «Correction of precipitation records through inverse modeling in watersheds of south-central Chile». En: *Water* 10.8 (2018), pág. 1092.
- [233] Joaquín Muñoz-Sabater et al. «ERA5-Land: A state-of-the-art global reanalysis dataset for land applications». En: *Earth system science data* 13.9 (2021), págs. 4349-4383.
- [234] Sebastian G Mutz et al. «Twenty-first century regional temperature response in Chile based on empirical-statistical downscaling». En: *Climate Dynamics* 56 (2021), págs. 2881-2894.
- [235] J. Muñoz Sabater. *ERA5-Land hourly data from 1950 to present. Copernicus Climate Change Service (C3S) Climate Data Store (CDS)*. 2019. URL: <https://cds.climate.copernicus.eu/datasets/reanalysis-era5-land?tab=overview>.
- [236] PT Nastos, J Kapsomenakis y KM Philandras. «Evaluation of the TRMM 3B43 gridded precipitation estimates over Greece». En: *Atmospheric Research* 169 (2016), págs. 497-514.
- [237] MAI Navid y NH Niloy. «Multiple linear regressions for predicting rainfall for Bangladesh». En: *Communications* 6.1 (2018), págs. 1-4.
- [238] Fernando Andrés Neira Román. «Elaboración de la cartografía climática de temperaturas y precipitación mediante redes neuronales artificiales: caso de estudio en la Región del Libertador Bernardo O'Higgins». En: (2010).
- [239] Phu Nguyen et al. «Persiann dynamic infrared–rain rate (PDIR-now): A near-real-time, quasi-global satellite precipitation dataset». En: *Journal of hydrometeorology* 21.12 (2020), págs. 2893-2906.
- [240] Phu Nguyen et al. «Persiann dynamic infrared–rain rate (PDIR-now): A near-real-time, quasi-global satellite precipitation dataset». En: *Journal of hydrometeorology* 21.12 (2020), págs. 2893-2906.
- [241] Phu Nguyen et al. «The CHRS Data Portal, an easily accessible public repository for PERSIANN global satellite precipitation data». En: *Scientific data* 6.1 (2019), págs. 1-10.
- [242] Jon Olason. «ERA5: The new champion of wind power modelling?» En: *Renewable energy* 126 (2018), págs. 322-331.
- [243] Matías Ezequiel Olmo y María Laura Bettolli. «Statistical downscaling of daily precipitation over southeastern South America: Assessing the performance in extreme events». En: *International Journal of Climatology* 42.2 (2022), págs. 1283-1302.

- [244] Calisto Kennedy Omondi et al. «Satellite rainfall bias assessment for crop growth simulation—A case study of maize growth in Kenya». En: *Agricultural Water Management* 258 (2021), pág. 107204.
- [245] Christian Onof et al. «Rainfall modelling using Poisson-cluster processes: a review of developments». En: *Stochastic Environmental Research and Risk Assessment* 14 (2000), págs. 384-411.
- [246] Fabio Oriani et al. «Simulation of rainfall time series from different climatic regions using the direct sampling technique». En: *Hydrology and Earth System Sciences* 18.8 (2014), págs. 3015-3031.
- [247] Karen L O'Brien et al. «Disaster Risk Reduction, Climate Change Adaptation and Human Security: A Commissioned Report for the Norwegian Ministry of Foreign Affairs by the Global Environmental Change and Human Security (GECHS) Project». En: (2008).
- [248] HA Pahlavan et al. «Improvement of multiple linear regression method for statistical downscaling of monthly precipitation». En: *International journal of environmental science and technology* 15 (2018), págs. 1897-1912.
- [249] Indrani Pal y Abir Al-Tabbaa. «Trends in seasonal precipitation extremes—An indicator of 'climate change' in Kerala, India». En: *Journal of Hydrology* 367.1-2 (2009), págs. 62-69.
- [250] Franklin Javier Paredes Trejo et al. «Intercomparison of improved satellite rainfall estimation with CHIRPS gridded product and rain gauge data over Venezuela». En: *Atmósfera* 29.4 (2016), págs. 323-342.
- [251] Juan L Parra, Catherine C Graham y Juan F Freile. «Evaluating alternative data sets for ecological niche models of birds in the Andes». En: *Ecography* 27.3 (2004), págs. 350-360.
- [252] Jonathan A Patz et al. «Impact of regional climate change on human health». En: *Nature* 438.7066 (2005), págs. 310-317.
- [253] Liqing Peng, Justin Sheffield y Koen MJ Verbist. «Merging station observations with large-scale gridded data to improve hydrological predictions over Chile». En: *AGU Fall Meeting Abstracts*. Vol. 2016. 2016, H33H-1666.
- [254] Daiana V Perri et al. «Optimal automatic enhanced ERA5 daily precipitation data for environmental and agricultural monitoring tools in scarce data regions». En: *Theoretical and Applied Climatology* 155.3 (2024), págs. 1847-1856.
- [255] Sergio Pezzulli et al. «The seasonal forecast of electricity demand: A hierarchical Bayesian model with climatological weather generator». En: *Applied Stochastic Models in Business and Industry* 22.2 (2006), págs. 113-125.

- [256] Hoa X Pham, Asaad Y Shamseldin y Bruce W Melville. «Projection of future extreme precipitation: a robust assessment of downscaled daily precipitation». En: *Natural Hazards* 107 (2021), págs. 311-329.
- [257] Sid. Pharasi y Sid. Pharasi. *Development of statistical downscaling methods for the daily precipitation process at a local site*. 2006. URL: <https://escholarship.mcgill.ca/concern/theses/q237hs18x?locale=en>.
- [258] Robert C Pipunic et al. «An evaluation and regional error modeling methodology for near-real-time satellite rainfall data over Australia». En: *Journal of Geophysical Research: Atmospheres* 120.20 (2015), págs. 10-767.
- [259] Roberto Pizarro et al. «Latitudinal analysis of rainfall intensity and mean annual precipitation in Chile». En: *Chilean Journal of Agricultural Research* 72.2 (2012), págs. 252-261.
- [260] Roberto Pizarro et al. «Latitudinal analysis of rainfall intensity and mean annual precipitation in Chile». En: *Chilean Journal of Agricultural Research* 72.2 (2012), págs. 252-261.
- [261] Sandra Pool, Marc Vis y Jan Seibert. «Evaluating model performance: towards a non-parametric variant of the Kling-Gupta efficiency». En: *Hydrological Sciences Journal* 63.13-14 (2018), págs. 1941-1953.
- [262] V Pope y R Stratton. «The processes governing horizontal resolution sensitivity in a climate model». En: *Climate Dynamics* 19 (2002), págs. 211-236.
- [263] Satya Prakash. «Performance assessment of CHIRPS, MSWEP, SM2RAIN-CCI, and TMPA precipitation products across India». En: *Journal of hydrology* 571 (2019), págs. 50-59.
- [264] Andreas F Prein et al. «A review on regional convection-permitting climate modeling: Demonstrations, prospects, and challenges». En: *Reviews of geophysics* 53.2 (2015), págs. 323-361.
- [265] Budong Qian et al. «Comparing scenarios of Canadian daily climate extremes derived using a weather generator». En: *Climate Research* 41.2 (2010), págs. 131-149.
- [266] J Quintana. «Estudio de los factores que explican la variabilidad de la precipitación en Chile en escalas de tiempo interdecadal». Tesis doct. MSc thesis, Universidad de Chile, 2004.
- [267] J Quintana. «Estudio de los factores que explican la variabilidad de la precipitación en Chile en escalas de tiempo interdecadal». Tesis doct. MSc thesis, Universidad de Chile, 2004.
- [268] J Quintana y Patricio Aceituno. «Changes in the rainfall regime along the extratropical west coast of South America (Chile) during the 20th Century». En: *J. Clim., submitted* (2011).

- [269] JM Quintana y Patricio Aceituno. «Changes in the rainfall regime along the extratropical west coast of South America (Chile): 30-43° S». En: *Atmósfera* 25.1 (2012), págs. 1-22.
- [270] Balaji Rajagopalan y Upmanu Lall. «A k-nearest-neighbor simulator for daily precipitation and other weather variables». En: *Water resources research* 35.10 (1999), págs. 3089-3101.
- [271] Md Mamunur Rashid, Simon Beecham y Rezaul K Chowdhury. «Statistical downscaling of CMIP5 outputs for projecting future changes in rainfall in the Onkaparinga catchment». En: *Science of the Total Environment* 530 (2015), págs. 171-182.
- [272] Juan A Rivera, Georgina Marianetti y Sofía Hinrichs. «Validation of CHIRPS precipitation dataset along the Central Andes of Argentina». En: *Atmospheric Research* 213 (2018), págs. 437-449.
- [273] John Roads. «The NCEP–NCAR, NCEP–DOE, and TRMM tropical atmosphere hydrologic cycles». En: *Journal of Hydrometeorology* 4.5 (2003), págs. 826-840.
- [274] John Roads. «The NCEP–NCAR, NCEP–DOE, and TRMM tropical atmosphere hydrologic cycles». En: *Journal of Hydrometeorology* 4.5 (2003), págs. 826-840.
- [275] Gerard H Roe. «Orographic precipitation». En: *Annu. Rev. Earth Planet. Sci.* 33.1 (2005), págs. 645-671.
- [276] Octavio Rojas et al. «Una revisión de inundaciones fluviales en Chile, período 1574-2012: causas, recurrencia y efectos geográficos». En: *Revista de Geografía Norte Grande* 57 (2014), págs. 177-192.
- [277] Y Rojas. *Eventos extremos de precipitación diaria en Chile central*. 2016.
- [278] Octavio Enrique Rojas Vilches et al. «Cambios ambientales y dinámica de inundaciones fluviales en una cuenca costera del centro sur de Chile.» En: (2015).
- [279] R Rondanelli et al. «Strongest MJO on record triggers extreme Atacama rainfall and warmth in Antarctica». En: *Geophysical Research Letters* 46.6 (2019), págs. 3482-3491.
- [280] WB Rossow y EN Duenas. «The international satellite cloud climatology project (ISCCP) web site: An online resource for research». En: *Bulletin of the American Meteorological Society* 85.2 (2004), págs. 167-172.
- [281] DA Sachindra y BJC Perera. «Statistical downscaling of general circulation model outputs to precipitation accounting for non-stationarities in predictor-predictand relationships». En: *PloS one* 11.12 (2016), e0168701.
- [282] Mojtaba Sadeghi et al. «Evaluation of PERSIANN-CDR constructed using GPCP V2. 2 and V2. 3 and a comparison with TRMM 3B42 V7 and CPC unified gauge-based analysis in global scale». En: *Remote Sensing* 11.23 (2019), pág. 2755.

- [283] Mojtaba Sadeghi et al. «PERSIANN-CCS-CDR, a 3-hourly 0.04 global precipitation climate data record for heavy precipitation studies». En: *Scientific Data* 8.1 (2021), pág. 157.
- [284] Murat Şan et al. «Daily precipitation performances of regression-based statistical downscaling models in a basin with mountain and semi-arid climates». En: *Stochastic Environmental Research and Risk Assessment* 37.4 (2023), págs. 1431-1455.
- [285] F Santibañez et al. «Atlas de cambio climático de la zona semiárida de Chile». En: *Fondo de Protección Ambiental del Ministerio de Medioambiente*. p 145 (2014).
- [286] Pablo Sarricolea, Mariajosé Herrera-Ossandon y Óliver Meseguer-Ruiz. «Climatic regionalisation of continental Chile». En: *Journal of Maps* 13.2 (2017), págs. 66-73.
- [287] Frédéric Satgé et al. «Evaluation of 23 gridded precipitation datasets across West Africa». En: *Journal of Hydrology* 581 (2020), pág. 124412.
- [288] Kirstin Schamm et al. «GPCC full data daily version 1.0: daily land-surface precipitation from rain gauges built on GTS based and historic data». En: (2016).
- [289] Jürg Schmidli, Christoph Frei y Pier Luigi Vidale. «Downscaling from GCM precipitation: a benchmark for dynamical and statistical downscaling methods». En: *International Journal of Climatology: A Journal of the Royal Meteorological Society* 26.5 (2006), págs. 679-689.
- [290] Vanúcia Schumacher et al. «Comparison between observations and gridded data sets over complex terrain in the Chilean Andes: Precipitation and temperature». En: (2020).
- [291] Vanúcia Schumacher et al. «Comparison between observations and gridded data sets over complex terrain in the Chilean Andes: Precipitation and temperature». En: (2020).
- [292] Richard Seager y Gabriel A Vecchi. «Greenhouse warming and the 21st century hydroclimate of southwestern North America». En: *Proceedings of the National Academy of Sciences* 107.50 (2010), págs. 21277-21282.
- [293] Richard Seager y Gabriel A Vecchi. «Greenhouse warming and the 21st century hydroclimate of southwestern North America». En: *Proceedings of the National Academy of Sciences* 107.50 (2010), págs. 21277-21282.
- [294] Mikhail A Semenov et al. «Comparison of the WGEN and LARS-WG stochastic weather generators for diverse climates». En: *Climate research* 10.2 (1998), págs. 95-107.
- [295] Sonia Seneviratne et al. «Changes in climate extremes and their impacts on the natural physical environment». En: (2012).
- [296] Justin Sheffield, Gopi Goteti y Eric F Wood. «Development of a 50-year high-resolution global dataset of meteorological forcings for land surface modeling». En: *Journal of climate* 19.13 (2006), págs. 3088-3111.

- [297] Frederick G Shuman. «History of numerical weather prediction at the National Meteorological Center». En: *Weather and forecasting* 4.3 (1989), págs. 286-296.
- [298] Onesmo Zakaria Sigalla et al. «Analysis of spatial and temporal trend of hydro-climatic parameters in the Kilombero River Catchment, Tanzania». En: *Scientific Reports* 13.1 (2023), pág. 7864.
- [299] TJ Sijinaldo. «Análisis geoestadístico para la confección de mapas de precipitaciones máximas para la Región del Libertador General Bernardo O'Higgins». Tesis doct. PhD thesis.. Chile: Universidad Católica de la Santísima Concepción, 2015.
- [300] WC Skamarock et al. *A Description of the Advanced Research WRF Version 3, University Corporation for Atmospheric Research, (No. NCAR/TN-475+ STR)*. 2008.
- [301] Gail Skofronick-Jackson et al. «The Global Precipitation Measurement (GPM) mission's scientific achievements and societal contributions: Reviewing four years of advanced rain and snow observations». En: *Quarterly Journal of the Royal Meteorological Society* 144 (2018), págs. 27-48.
- [302] Silvina A Solman. «Regional climate modeling over South America: a review». En: *Advances in Meteorology* 2013.1 (2013), pág. 504357.
- [303] Susan Solomon et al. «Fourth assessment report of the Intergovernmental Panel on Climate Change: Important observations and conclusions». En: *Current Science* 92.8 (2007), pág. 1034. ISSN: 00113891.
- [304] Soroosh Sorooshian et al. «NOAA climate data record (CDR) of precipitation estimation from remotely sensed information using artificial neural networks (PERSIANN-CDR), Version 1, Revision 1». En: *Available at gis.ncdc.noaa.gov/geoportal/catalog/search/resource/details.page* (2014).
- [305] Maxime Souvignet et al. «Statistical downscaling of precipitation and temperature in north-central Chile: an assessment of possible climate change impacts in an arid Andean watershed». En: *Hydrological Sciences Journal—Journal des Sciences Hydrologiques* 55.1 (2010), págs. 41-57.
- [306] Victor P Starr et al. «Basic principles of weather forecasting». En: (1942).
- [307] Thomas Stocker. *Climate change 2013: the physical science basis: Working Group I contribution to the Fifth assessment report of the Intergovernmental Panel on Climate Change*. Cambridge university press, 2014.

- [308] Qiaohong Sun, Chiyuan Miao y Qingyun Duan. «Extreme climate events and agricultural climate indices in China: CMIP5 model evaluation and projections.» En: *International Journal of Climatology* 36.1 (2016).
- [309] Qiaohong Sun et al. «A review of global precipitation data sets: Data sources, estimation, and intercomparisons». En: *Reviews of Geophysics* 56.1 (2018), págs. 79-107.
- [310] Qiaohong Sun et al. «Would the 'real' observed dataset stand up? A critical examination of eight observed gridded climate datasets for China». En: *Environmental Research Letters* 9.1 (2014), pág. 015001.
- [311] S. Swain, P. Patel y S. Nandi. «A multiple linear regression model for precipitation forecasting over Cuttack district, Odisha, India». En: *2017 2nd International Conference for Convergence in Technology (I2CT)*. 2017, págs. 355-357. DOI: [10.1109/I2CT.2017.8226150](https://doi.org/10.1109/I2CT.2017.8226150).
- [312] Yaogeng Tan et al. «Selection of effective GCM bias correction methods and evaluation of hydrological response under future climate scenarios». En: *Climate* 8.10 (2020), pág. 108.
- [313] Francisco J Tapiador et al. «Global precipitation measurement: Methods, datasets and applications». En: *Atmospheric Research* 104 (2012), págs. 70-97.
- [314] H Tavakol-Davani, M Nasserli y B Zahraie. «Improved statistical downscaling of daily precipitation using SDSM platform and data-mining methods.» En: *International Journal of Climatology* 33.11 (2013).
- [315] Karl E Taylor. «Summarizing multiple aspects of model performance in a single diagram». En: *Journal of geophysical research: atmospheres* 106.D7 (2001), págs. 7183-7192.
- [316] Jakob Matthias Themeßl. «Empirical-statistical downscaling and error correction of temperature , precipitation , and derived extremes in Europe». En: *Thesis* 45 (2011), págs. 1-147.
- [317] Matthias Themeßl. *Downscaling of temperature and precipitation in the Alpine Region Hohe Tauern*. na, 2005.
- [318] Ben Timmermans et al. «An evaluation of the consistency of extremes in gridded precipitation data sets». En: *Climate dynamics* 52 (2019), págs. 6651-6670.
- [319] Limbert Torrez-Rodriguez et al. «Evaluation of temperature and precipitation from CORDEX-CORE South America and Eta-RCM regional climate simulations over the complex terrain of Subtropical Chile». En: *Climate Dynamics* 61.7 (2023), págs. 3195-3221.
- [320] Kevin E Trenberth. «Changes in precipitation with climate change». En: *Climate research* 47.1-2 (2011), págs. 123-138.

- [321] Sylwia Trzaska, Emilie Schnarr et al. «A review of downscaling methods for climate change projections». En: *United States Agency for International Development by Tetra Tech ARD 2014* (2014), págs. 1-42.
- [322] Rodrigo Valdés-Pineda et al. «Analysis of spatio-temporal changes in annual and seasonal precipitation variability in South America-Chile and related ocean–atmosphere circulation patterns». En: *International Journal of Climatology* 8 (2016), págs. 2979-3001.
- [323] Rodrigo Valdés-Pineda et al. «Analysis of spatio-temporal changes in annual and seasonal precipitation variability in South America-Chile and related ocean–atmosphere circulation patterns». En: *International Journal of Climatology* 36.8 (2016), págs. 2979-3001.
- [324] Rodrigo Valdés-Pineda et al. «Analysis of spatio-temporal changes in annual and seasonal precipitation variability in South America-Chile and related ocean–atmosphere circulation patterns». En: *International Journal of Climatology* 36.8 (2016), págs. 2979-3001.
- [325] Rodrigo Valdes-Pineda et al. «Spatio-temporal trends of precipitation, its aggressiveness and concentration, along the Pacific coast of South America (36–49 S)». En: *Hydrological Sciences Journal* 61.11 (2016), págs. 2110-2132.
- [326] Rodrigo Valdés-Pineda et al. «Water governance in Chile: Availability, management and climate change». En: *Journal of Hydrology* 519 (2014), págs. 2538-2567.
- [327] Santiago Valencia et al. «Spatio-temporal assessment of Gridded precipitation products across topographic and climatic gradients in Colombia». En: *Atmospheric Research* 285 (2023), pág. 106643.
- [328] Raúl Valenzuela et al. «An extraordinary dry season precipitation event in the subtropical Andes: Drivers, impacts and predictability». En: *Weather and Climate Extremes* 37 (2022), pág. 100472.
- [329] Raúl A Valenzuela y René D Garreaud. «Extreme daily rainfall in central-southern Chile and its relationship with low-level horizontal water vapor fluxes». En: *Journal of Hydrometeorology* 20.9 (2019), págs. 1829-1850.
- [330] Robert Vautard. «Regional climate projections». En: *Weather & Climate Services for the Energy Industry* (2018), págs. 139-149.
- [331] Maximiliano Viale y René Garreaud. «Orographic effects of the subtropical and extratropical Andes on upwind precipitating clouds». En: *Journal of Geophysical Research: Atmospheres* 120.10 (2015), págs. 4962-4974.
- [332] Maximiliano Viale y René Garreaud. «Summer precipitation events over the western slope of the subtropical Andes». En: *Monthly Weather Review* 142.3 (2014), págs. 1074-1092.

- [333] Maximiliano Viale et al. «Impacts of atmospheric rivers on precipitation in southern South America». En: *Journal of Hydrometeorology* 19.10 (2018), págs. 1671-1687.
- [334] Sebastian Vicuña et al. «Exploring possible connections between hydrological extreme events and climate change in central south Chile». En: *Hydrological sciences journal* 58.8 (2013), págs. 1598-1619.
- [335] Hans Von Storch, Bruce Hewitson y Linda Mearns. «Review of empirical downscaling techniques». En: *Regional climate development under global warming. General Technical Report 4* (ene. de 2000).
- [336] Hans Von Storch y Eduardo Zorita. «The history of ideas of downscaling—from synoptic dynamics and spatial interpolation». En: *Frontiers in Environmental Science* 7 (2019), pág. 21.
- [337] Hans Von Storch, Eduardo Zorita y Ulrich Cubasch. «Downscaling of global climate change estimates to regional scales: an application to Iberian rainfall in wintertime». En: *Journal of Climate* 6.6 (1993), págs. 1161-1171.
- [338] Fang Wang et al. «Deep learning for daily precipitation and temperature downscaling». En: *Water Resources Research* 57.4 (2021), e2020WR029308.
- [339] Shaojian Wang y Xiaoping Liu. «China's city-level energy-related CO2 emissions: Spatio-temporal patterns and driving forces». En: *Applied energy* 200 (2017), págs. 204-214.
- [340] Wei Wang y Nelson L Seaman. «A comparison study of convective parameterization schemes in a mesoscale model». En: *Monthly Weather Review* 125.2 (1997), págs. 252-278.
- [341] E Ward et al. «Evaluation of precipitation products over complex mountainous terrain: A water resources perspective». En: *Advances in water resources* 34.10 (2011), págs. 1222-1231.
- [342] Peter Waylen y Germán Poveda. «El Niño–Southern Oscillation and aspects of western South American hydro-climatology». En: *Hydrological Processes* 16.6 (2002), págs. 1247-1260.
- [343] RH White y R Toumi. «The limitations of bias correcting regional climate model inputs». En: *Geophysical Research Letters* 40.12 (2013), págs. 2907-2912.
- [344] RH White y R Toumi. «The limitations of bias correcting regional climate model inputs». En: *Geophysical Research Letters* 40.12 (2013), págs. 2907-2912.
- [345] Martin Widmann, Christopher S Bretherton y Eric P Salathé. «Statistical precipitation downscaling over the northwestern United States using numerically simulated precipitation as a predictor». En: *Journal of Climate* 16.5 (2003), págs. 799-816.

- [346] Robert L Wilby y Thomas ML Wigley. «Downscaling general circulation model output: a review of methods and limitations». En: *Progress in physical geography* 21.4 (1997), págs. 530-548.
- [347] Robert L Wilby y Thomas ML Wigley. «Downscaling general circulation model output: a review of methods and limitations». En: *Progress in physical geography* 21.4 (1997), págs. 530-548.
- [348] Robert L Wilby et al. «Guidelines for use of climate scenarios developed from statistical downscaling methods». En: *Supporting material of the Intergovernmental Panel on Climate Change, available from the DDC of IPCC TGCIA 27* (2004).
- [349] Daniel S Wilks. «Interannual variability and extreme-value characteristics of several stochastic daily precipitation models». En: *Agricultural and forest meteorology* 93.3 (1999), págs. 153-169.
- [350] Cort J Willmott, Scott M Robeson y Kenji Matsuura. «A refined index of model performance». En: *International Journal of climatology* 32.13 (2012), págs. 2088-2094.
- [351] Geraldine Wong et al. «Stochastic model output statistics for bias correcting and downscaling precipitation including extremes». En: *Journal of Climate* 27.18 (2014), págs. 6940-6959.
- [352] Marc Wüest et al. «A gridded hourly precipitation dataset for Switzerland using rain-gauge analysis and radar-based disaggregation». En: *International Journal of Climatology* 30 (2010), págs. 1764-1775.
- [353] Zhongfeng Xu, Ying Han y Zongliang Yang. «Dynamical downscaling of regional climate: A review of methods and limitations». En: *Science China Earth Sciences* 62 (2019), págs. 365-375.
- [354] Zhongfeng Xu, Ying Han y Zongliang Yang. «Dynamical downscaling of regional climate: A review of methods and limitations». En: *Science China Earth Sciences* 62 (2019), págs. 365-375.
- [355] Gonzalo Yáñez-Morrón et al. «Using the Weather Research and Forecasting (WRF) model for precipitation forecasting in an Andean region with complex topography». En: *Atmosphere* 9.8 (2018), pág. 304.
- [356] Nan-Ching Yeh et al. «Bias adjustment of satellite precipitation estimation using ground-based observation: Mei-Yu front case studies in Taiwan». En: *Asia-Pacific Journal of Atmospheric Sciences* 56.3 (2020), págs. 485-492.
- [357] Pascal Yiou. «AnaWEGE: a weather generator based on analogues of atmospheric circulation». En: *Geoscientific Model Development* 7.2 (2014), págs. 531-543.

- [358] C Bryan Young et al. «Evaluating NEXRAD multisensor precipitation estimates for operational hydrologic forecasting». En: *Journal of Hydrometeorology* 1.3 (2000), págs. 241-254.
- [359] Francisco Zambrano, Brian Wardlow y Tsegaye Tadesse. «Evaluating satellite-derived long-term historical precipitation datasets for drought monitoring in Chile». En: *Remote Sensing for Agriculture, Ecosystems, and Hydrology XVIII*. Vol. 9998. SPIE. 2016, págs. 654-677.
- [360] Francisco Zambrano et al. «Prediction of drought-induced reduction of agricultural productivity in Chile from MODIS, rainfall estimates, and climate oscillation indices». En: *Remote Sensing of Environment* 219 (2018), págs. 15-30.
- [361] Mariso G. Zambrano. «Balance Hídrico del Lago General Carrera y su variabilidad climática asociada». Tesis doct. Universidad de Concepción, 2011.
- [362] Mauricio Zambrano-Bigiarini et al. «Temporal and spatial evaluation of satellite-based rainfall estimates across the complex topographical and climatic gradients of Chile». En: *Hydrology and Earth System Sciences* 21.2 (2017), págs. 1295-1320.
- [363] Mauricio Zambrano-Bigiarini et al. «Temporal and spatial evaluation of satellite-based rainfall estimates across the complex topographical and climatic gradients of Chile». En: *Hydrology and Earth System Sciences* 21.2 (2017), págs. 1295-1320.
- [364] Dalin Zhang y Richard A Anthes. «A high-resolution model of the planetary boundary layer—Sensitivity tests and comparisons with SESAME-79 data». En: *Journal of Applied Meteorology and Climatology* 21.11 (1982), págs. 1594-1609.
- [365] X-C Zhang. «Spatial downscaling of global climate model output for site-specific assessment of crop production and soil erosion». En: *Agricultural and Forest Meteorology* 135.1-4 (2005), págs. 215-229.
- [366] Yiran Zhang et al. «Error adjustment of TMPA satellite precipitation estimates and assessment of their hydrological utility in the middle and upper Yangtze River Basin, China». En: *Atmospheric research* 216 (2019), págs. 52-64.
- [367] Zhengzheng Zhou et al. «Storm catalog-based analysis of rainfall heterogeneity and frequency in a complex terrain». En: *Water Resources Research* 55.3 (2019), págs. 1871-1889.
- [368] Zhao Zongci, Luo Yong y Huang Jianbin. «Are extreme weather and climate events affected by global warming?» En: *Advances in Climate Change Research* 10.5 (2014), pág. 388.

## Apéndice A

### Resultados derivados de esta tesis

Durante el desarrollo de esta tesis se generaron los siguientes trabajos derivados y colaboraciones:

- **Francisco-J. Alvia Vázquez**, Rodrigo Abarca-del-Río and Andrés I. Ávila. High-Resolution Precipitation Gridded Dataset on the South-Central Zone (34° S–41° S) of Chile (2020) doi: [10.3389/feart.2020.519975](https://doi.org/10.3389/feart.2020.519975).
- I. Fustos , R. Abarca-del-Río b , O. Artal, **F. Alvia**, H.H. Sepúlveda. Impact on discharge modelling using different spatial and temporal resolution scenarios in South of Chile. (2022) <https://doi.org/10.1016/j.jsames.2022.103727> .
- **Francisco-J. Alvia Vázquez**, Rodrigo Abarca-del-Río. A Daily-Adaptive Statistical Downscaling Model (DA-SDM) for Extreme Precipitation Events (enviada).