



Universidad de Buenos Aires

Facultad de Ciencias Exactas y Naturales

Departamento de Ciencias de la Atmósfera y los Océanos

Pronóstico estadístico de la precipitación en el semestre cálido en la Cuenca del río Bermejo

Tesis presentada para optar por el título de Doctor de la Universidad de Buenos Aires en el Área Ciencias de la Atmósfera y los Océanos

Lic. Sabrina Noemí Ayala

Directora de tesis: Dra. Marcela Hebe González

Consejera de Estudios: Dra. Matilde Rusticucci

Lugar de trabajo: Centro de Investigaciones del Mar y la Atmósfera (CONICET-UBA)

Buenos Aires, 2025

Resumen

La Cuenca del Río Bermejo se ubica en el norte argentino en una zona de transición de ecosistemas que se refleja en los regímenes pluviométricos de la cuenca. En particular, la variabilidad interanual de la precipitación en la temporada cálida austral afecta significativamente el aspecto ambiental y socio-económico de la cuenca. Por este motivo, el objetivo de este estudio es diseñar modelos de pronóstico de la precipitación mensual en el semestre cálido (octubre-marzo) en la Cuenca del Río Bermejo mediante el uso de técnicas estadísticas. Para ello, se dividió a la región de estudio en dos zonas climáticamente homogéneas y, a partir del uso de indicadores tomados en el mes previo, se exploraron posibles fuentes de predictibilidad de la precipitación mensual en estas áreas. Entre los forzantes más destacados se encuentran El Niño-Oscilación del Sur, la circulación regional dada por la variabilidad del anticiclón del océano Atlántico, y el desarrollo convectivo en Sudamérica tropical. Se encontró que la señal de cada forzante es variable a lo largo del semestre de estudio, así como varía la influencia de cada forzante sobre las áreas climáticamente homogéneas. Con los indicadores obtenidos se definieron predictores de la precipitación mensual, y se elaboraron esquemas de predicción estadística empleando las técnicas de Regresión Lineal Múltiple (RLM), Modelos Aditivos Generalizados (GAM), Regresión de Vectores de Soporte (SVR), y Redes Neuronales Artificiales Multicapa (ANN). Desde el enfoque determinístico, los modelos ANN fueron los que mejor desempeño exhibieron. En cuanto al enfoque probabilístico por categorías, el mejor rendimiento se observó para los pronósticos mensuales en la primera mitad del semestre cálido, particularmente para los eventos de precipitación subnormal y sobrenormal en el área ubicada en el centro-oeste de la cuenca.

Palabras clave: precipitación, cuenca, Bermejo, aprendizaje automático, modelado estadístico, pronóstico probabilístico.

Abstract

The Bermejo River Basin is located in the Argentinean north in a zone with ecosystem transition that reflects in the precipitation regimes of the basin. In particular, interannual variability of precipitation in the austral warm season significantly affects the environmental and socio-economic aspects of the basin. Given these reasons, the objective of this thesis is to design forecast models of monthly precipitation in the warm semester (October-March) in the Bermejo River Basin using statistical techniques. In order to achieve this, the study region was divided into two climatic homogeneous areas and, through the use of indicators measured on the previous month, different possible sources of predictability of monthly precipitation in these areas were explored. Amongst the most relevant forcings are the El Niño-Southern Oscillation, regional circulation features given by the variability of the semipermanent Atlantic High, and the development of convection in tropical South America. The signal of each forcing varies throughout the semester of study, as does the influence that each forcing has on the two distinct climatic areas. These indicators were used to define predictors of monthly precipitation, and statistical prediction schemes were constructed by Multiple Linear Regression (MLR), Generalized Additive Models (GAM), Support Vector Regression (SVR), and Multi-layer Artificial Neural Networks (ANN). From the deterministic standpoint, ANN models were the ones that showed the best performance. As for the categorical probabilistic forecast, the highest efficiency was obtained for monthly forecasts during the first half of the warm semester, particularly for events with below normal and above normal precipitation in the area located in the centre-west portion of the basin.

Key words: precipitation, basin, Bermejo, machine learning, statistical modeling, probabilistic forecast.

Para Aída

*“Cuando mires al cielo, por la noche, como yo habitaré en una [estrella],
como yo reiré en una [estrella],
será para ti como si rieran todas las estrellas,
¡tú tendrás estrellas que saben reír!”*

El Principito

Antoine de Saint-Exupéry

Agradecimientos

A los miembros del jurado, por aceptar leer esta tesis doctoral, y por sus valiosos comentarios.

A la educación pública, gratuita, y de calidad, que me acompañó en tantísimos años de formación académica, profesional, y personal.

A la Universidad de Buenos Aires, particularmente al Departamento de Ciencias de la Atmósfera y los Océanos de la Facultad de Ciencias Exactas y Naturales, por haberme otorgado las herramientas para mi crecimiento profesional.

Al Consejo Nacional de Investigaciones Científicas y Técnicas, por haberme confiado una beca doctoral que posibilitó mi formación de posgrado. Al Centro de Investigaciones del Mar y la Atmósfera, por haberme brindado un espacio para hacer realidad este camino.

A Marcela, mi directora en esta aventura, por su guía, sus enseñanzas, su paciencia y, por sobre todas las cosas, su apoyo incondicional. Me considero infinitamente afortunada de haberme cruzado en su camino, hoy y siempre.

Al grupo de Perspectiva Climática, por generar un ambiente positivo y de crecimiento. A Alfredo, por su infinita paciencia y por inspirarnos a mejorar. A Paula y a Laura W., quienes me acompañaron con mucho amor en este último tramo.

A los integrantes fijos y migratorios de la oficina 2306, con quienes compartí risas, preocupaciones, consejos, matecitos (¡hasta decoración de interiores!). El camino es arduo, pero ellos lo hicieron divertido.

A los amigos que me dio la facultad, siempre al pie del cañón, siempre amorosos.

A los amigos que me dio la escritura creativa, que me han demostrado que la distancia y los husos horarios son poco relevantes cuando crece una amistad sincera.

A Laura R. y Noelia, amigas, hermanas.

A mi familia, la original y la extendida, que me protegió y me alentó a avanzar siempre, incluso cuando los obstáculos me parecían infranqueables.

A Pabli, por su amor, su protección, sus ocurrencias, y por su convicción en demostrar que juntos, la vida es más divertida. ¡Y cuánta razón tiene!

Acrónimos

AA – anticiclón del Atlántico sur

AAINT – indicador general de intensidad del AA

AALAT – indicador general de posición latitudinal del AA

AALON – indicador general de posición longitudinal del AA

AD – test de Anderson-Darling

ANN – Redes Neuronales Artificiales

AP – anticiclón del Pacífico sur

APINT – indicador general de intensidad del AP

APLAT – indicador general de posición latitudinal del AP

APLON – indicador general de posición longitudinal del AP

AIC – criterio de Información de Akaike

APA – Administración Provincial del Agua (Chaco)

AUC – área bajo la curva ROC

BMI – subcuenca Bermejo Medio Inferior

BRT – test de Rango de Buishand

BS – subcuenca Bermejo Superior

BSco – Brier Score

BSS – Brier Skill Score

C3S – Copernicus Climate Change Service

CHFP – Climate Historial Forecast Project

COREBE – Comisión Regional del Río Bermejo

CRB – sector argentino de la cuenca del Río Bermejo

CV - validación cruzada

DOI – Dipolo del Océano Índico / indicador general representativo del Dipolo del Océano Índico

DT – diagrama de tendencia

DWD - Deutscher Wetterdienst

ECCC – Environment and Climate Change Canada

ECMWF – European Centre for Medium-Range Weather Forecasts

EFM – trimestre de verano definido en este estudio (enero a marzo)

ENSO – El Niño-Oscilación del Sur

ERA5 - ECMWF Reanalysis v5

ERSSTv5 – Extended Reconstructed Sea Surface Temperature v5

GAM – Modelos Aditivos Generalizados

hgt – altura geopotencial

HHP – Heidke Hit Proportion

HSS – Heidke Skill Score

InfInt – índice de Intensidad de Influencia

IOBW – Calentamiento Generalizado de la Cuenca del Índico / indicador general representativo del Calentamiento Generalizado de la Cuenca del Índico

IPE – Índice de Precipitación Estandarizado

IPEE – Índice de Precipitación-Evapotranspiración Estandarizado

ITCZ – Zona de Convergencia Intertropical

LASSO –Least Absolute Shrinkage and Selection Operator

LLJ – corriente en chorro en capas bajas de Sudamérica

LOOCV – validación cruzada de un elemento

MCG – modelo climático global

MCR – modelo climático regional

MF – Météo-France

MJO – Oscilación de Madden-Julian

NMME – North American Multi-Model Ensemble

OLR – flujo de radiación de onda larga saliente

OMM – Organización Meteorológica Mundial

OND – trimestre de primavera definido en este estudio (octubre a diciembre)

PAM – algoritmo Partitioning Around Medoids para la aplicación de k-medoides

PCR – regresión por componentes principales

PDO – Oscilación Decadal del Pacífico / indicador general representativo de la Oscilación Decadal del Pacífico

PLS – regresión de mínimos cuadrados parciales

PSA – patrón Pacífico-Sudamérica

ReLU – función Unidad Lineal Rectificada

RLM – Regresión Lineal Múltiple

RMSD – raíz de la diferencia cuadrática media

ROC – Relative Operating Characteristic

RPS – Ranked Probability Score

RPSS – Ranked Probability Skill Score

RSS – suma de los cuadrados de la regresión

SACZ – Zona de Convergencia del Atlántico Sur

SAM – Modo Anular del Sur / indicador general representativo del Modo Anular del Sur

SAMS – Sistema Monzónico Sudamericano

SF – subcuenca San Francisco

SNHI – Sistema Nacional de Información Hídrica

SNHT – test de Homogeneidad Normal Estándar

SMN – Servicio Meteorológico Nacional

S-R – señal-ruido

SST – temperatura superficial del mar

SVM – Máquina de Vectores de Soporte

SVR – Regresión de Vectores de Soporte

SW – test de Shapiro-Wilk

tcwv – agua precipitable

u – viento zonal

v – viento meridional

VCE – Variable Climática Esencial

Índice general

Resumen	I
Abstract	II
Acrónimos	V
1. Introducción -----	1
1.1. Pronóstico a mediano plazo: generalidades.....	2
1.2. Pronóstico a mediano plazo mediante metodologías empíricas en Argentina	6
1.3. Objetivos y aporte científico	8
2. Cuenca del Río Bermejo -----	10
2.1. Caracterización general de la Cuenca del Río Bermejo.....	10
2.2. Caracterización hidroclimatológica de la CRB	14
2.2.1. Datos empleados y control de calidad.....	14
2.2.1.1. Precipitación	14
2.2.1.2. Caudal	23
2.2.2. Caracterización hidrometeorológica.....	24
2.2.2.1. Comportamiento medio.....	24
2.2.2.2. Relación precipitación-caudal.....	30
2.2.2.3. Semestre estival	34
2.2.2.4. Variabilidad de largo plazo	36
2.3. Clusterización mediante <i>k</i> -medoides	43
2.4. Síntesis	47
3. Hacia la generación de esquemas de predicción: factores de influencia de la precipitación -----	48
3.1. Búsqueda de predictores	48
3.1.1. Definición de indicadores generales	51

3.1.1.1. Indicadores de temperatura superficial del mar y de circulación hemisférica	55
3.1.1.2. Indicadores de circulación regional	61
3.1.1.3. Indicadores de convección en Sudamérica tropical ...	65
3.1.2. Construcción del Índice de Precipitación Estandarizado	69
3.1.3. Relación entre los indicadores generales y el IPE	74
3.1.3.1. Indicadores de temperatura superficial del mar y de circulación hemisférica	75
3.1.3.2. Indicadores de circulación regional	81
3.1.3.3. Indicadores de convección en Sudamérica tropical ...	85
3.1.4. Indicadores generales como predictores de la precipitación mensual.....	91
3.1.5. Construcción de indicadores particulares	94
3.2. Selección de predictores: aplicación de la técnica Least Absolute Shrinkage and Selection Operator (LASSO)	97
3.3. Esquemas conceptuales de influencia de la precipitación	105
3.4. Síntesis	122
4. Hacia la generación de esquemas de predicción: modelado estadístico	124
4.1. Modelado estadístico.....	124
4.1.1. Regresión Lineal Múltiple	127
4.1.2. Modelos Aditivos Generalizados	129
4.1.3. Regresión de Vectores de Soporte	130
4.1.4. Redes Neuronales Artificiales	132
4.2. Generación de modelos: estrategia de validación cruzada	135
4.3. Modelado estadístico: evaluación determinística	140
4.3.1. Umbral de aceptación de modelos.....	141
4.3.2. Evaluación de precisión	146
4.3.3. Diagramas de Taylor.....	151
4.4. Síntesis	157
5. Pronóstico probabilístico -----	158
5.1. La búsqueda del “buen” pronóstico	158

5.2. Estrategias de evaluación de los pronósticos probabilísticos.....	163
5.2.1. Diagrama de tendencia	165
5.2.2. Tasa de aciertos	166
5.2.3. Diagrama de confiabilidad	167
5.2.4. Diagrama Relative Operating Characteristic	170
5.2.5. Otras métricas para atributos múltiples	173
5.2.6. Síntesis de las herramientas de evaluación	175
5.3. Resultados de la evaluación de los pronósticos probabilísticos.....	177
5.4. Comparación con pronósticos dinámicos emitidos por centros operativos	193
5.4.1. Sistemas de pronóstico empleados y estrategia de comparación	194
5.4.2. Resultados de la comparación de desempeño.....	200
5.5. Síntesis	206
 6. Conclusiones -----	 208
 Referencias -----	 213
Anexo -----	239

Capítulo 1

Introducción

La precipitación es una variable de gran relevancia dentro del sistema climático, considerada como una Variable Climática Esencial (VCE) dentro del Sistema de Observación Climática Global, programa cofundado por la Organización Meteorológica Mundial (OMM) (Bojinski et al., 2014). La precipitación es uno de los factores que modula el balance hídrico de un ecosistema, influyendo en las componentes de evapotranspiración, escurrimiento superficial, y drenaje profundo (Jóbbagy et al., 2008). A su vez, la precipitación es una de las variables más destacables en el análisis de las condiciones de sequía en distintas escalas temporales, y es utilizada como variable de entrada en el cálculo de índices para el monitoreo de su evolución (Vicente-Serrano et al., 2010; Zargar et al., 2011; Beguería et al., 2013). Asimismo, el conocimiento sobre la precipitación no se enfoca solamente en la variable acumulada en un cierto período de tiempo, sino que también existen estudios abocados a los extremos pluviométricos. Los mismos son entendidos como eventos puntuales o persistentes en el tiempo, que son pocos frecuentes para la región y época del año. Esta área de estudio cobra particular relevancia en el contexto de cambio climático global (IPCC, 2021), en el cual se proyectan cambios en la frecuencia, intensidad y duración de los extremos pluviométricos, reconociendo además la naturaleza compleja y espacialmente heterogénea de la precipitación (Skansi et al., 2013; Asadieh y Krakauer, 2015; Lovino et al., 2018; Seneviratne et al., 2021). Por otro lado, la precipitación es una variable típicamente considerada en el análisis de eventos compuestos, definidos como la ocurrencia de dos o más eventos extremos que ocurren simultáneamente o muy cercanamente en el tiempo, amplificando así su impacto severamente (Tencer et al., 2016; Raymond et al., 2020; Seneviratne et al., 2021; Olmo et al., 2022b).

1.1. Pronóstico a mediano plazo: generalidades

La naturaleza caótica del tiempo meteorológico complejiza el pronóstico de sus condiciones instantáneas más allá de un par de semanas hacia adelante. Sin embargo, existen algunas componentes dentro del sistema climático que varían lentamente en comparación a los eventos individuales de tiempo, lo que hace posible el pronóstico de ciertas cantidades estadísticas (por ejemplo, variables medias) a mediano plazo y largo plazo (Zwiers y von Storch, 2004; Palmer et al., 2005). Dentro de las componentes del sistema climático que aportan predictibilidad, se reconocen tres grandes grupos de procesos que operan en una variedad de escalas temporales (National Research Council, 2010). En el primer grupo se encuentran las variables que aportan inercia al sistema, es decir cuyas anomalías tardan entre días y años en decaer, como por ejemplo ocurre con el contenido de calor en el océano. En segundo lugar, se ubican los modos de variabilidad de gran escala que representan diferentes procesos de acople en el sistema climático, como es el caso de El Niño-Oscilación del Sur (ENSO). Finalmente, el tercer grupo conjuga a los forzantes externos a la dinámica propia del sistema climático, como por ejemplo la actividad volcánica, la emisión de gases de efecto invernadero y de aerosoles antropogénicos, los cambios en la actividad solar, etc. En particular, el pronóstico de la precipitación acumulada mensual, que es la escala temporal objetivo de esta tesis, se ubica como límite inferior del rango temporal de pronóstico correspondiente a las perspectivas estacionales (White et al., 2017).

En este contexto, la información climática se vuelve esencial para las actividades que son sensibles a la variabilidad del sistema climático. En particular, algunos sectores que pueden verse beneficiados por los avances en las predicciones de la precipitación acumulada a mediano plazo (~ 1-3 meses) se vinculan a (OMM, 2020):

- **Agricultura y seguridad alimentaria:** la variabilidad climática puede afectar la disponibilidad, el acceso, la estabilidad, y la utilización de los alimentos. Los pronósticos a mediano plazo pueden ser utilizados en apoyo a actividades de planificación y toma de decisión en sistemas agrícolas, reduciendo así la incerteza y las pérdidas vinculadas a la variabilidad climática, y optimizando las ganancias que puedan surgir de ella.

- **Gestión de recursos hídricos:** la disponibilidad de recursos hídricos depende de la abundancia de la precipitación líquida y sólida, así como de su almacenamiento. La variabilidad climática puede inducir cambios en la precipitación acumulada, así como su intensidad, momento de ocurrencia, y forma. La variabilidad climática también puede propiciar cambios en los momentos donde ocurre el aporte hidrológico por derretimiento níveo, y puede suscitar cambios en la evapotranspiración. Los pronósticos a mediano plazo juegan un rol importante en el proceso de toma de decisión respecto a la gestión de estos recursos.
- **Gestión de riesgo de desastre:** el pronóstico a mediano plazo asiste en la toma de decisiones proactiva respecto de las estrategias y políticas enmarcadas en la gestión de riesgo de desastre, con el propósito de lidiar con el impacto asociado a la variabilidad climática.
- **Salud pública:** el pronóstico a mediano plazo puede integrarse interdisciplinariamente con el estudio de riesgos epidémicos. Esto permitiría brindar una advertencia temprana de la probabilidad de que se generen condiciones que propicien la aparición de enfermedades.
- **Energía:** la variabilidad climática impacta fuertemente en las formas de producción de la energía (como, por ejemplo, la energía hidroeléctrica), así como también incide en los niveles de consumo energético. Los pronósticos a mediano plazo pueden anticipar las chances de que exista un máximo en la demanda energética, con el objetivo de ajustar la producción.

Existen dos tipos de métodos de predicción para las perspectivas a mediano plazo: los de enfoque dinámico y los de enfoque estadístico. Estos métodos pueden utilizarse además en forma híbrida, y son complementarios entre sí. Ambos enfoques precisan fuertemente de observaciones para su buen desempeño, pues proveen información sobre el “estado inicial” del sistema climático a partir del cual se generan las predicciones, y también son usadas para verificar pronósticos y perfeccionar los modelos a partir de un mejor entendimiento de los procesos climáticos subyacentes (National Research Council, 2010; Doblas-Reyes et al., 2013). Por otro lado, para el pronóstico a mediano plazo en escala local, las estimaciones derivadas de modelos dinámicos tienden a ser ajustadas mediante una reducción de escala de origen dinámico o estadístico (Doblas-Reyes et al., 2013).

En el caso del enfoque dinámico, los sistemas de pronóstico están basados en modelos numéricos que representan procesos dinámicos en la atmósfera, y en las superficies oceánicas y continentales, incluyendo además la interacción no lineal entre ellos. Este tipo de modelos son muy complejos y demandan un gran costo computacional. Asimismo, en algunas regiones y para algunas épocas del año, este tipo de modelos pueden exhibir sesgos que limitan su habilidad de pronóstico. Algunos de estos errores se vinculan a las condiciones de inicialización de los modelos numéricos acoplados, como también a la representación de procesos físicos de escala pequeña, y a problemáticas asociadas a la formulación numérica de los procesos dinámicos (Eden et al., 2015; Osman et al., 2023). Particularmente en Sudamérica, Alves y Marengo (2010) evaluaron la predictibilidad estacional de la temperatura, la precipitación, y la circulación en distintos niveles verticales a través del modelo climático regional (MCR) HadRM3P, de 40 km de resolución horizontal, para el periodo 1961-1990. Los autores encontraron que el MCR logra capturar exitosamente los patrones espaciales de las variables, aunque tiende a subestimar la precipitación en la cuenca amazónica, y a sobreestimar la precipitación en los Andes. Los errores podrían vincularse a la física del modelo y a los sesgos heredados del modelo climático global (MCG) que provee las condiciones de borde. Por su parte, Osman y Vera (2017) y Andrian et al. (2023) analizaron el desempeño de los ensambles multi-modelo de pronóstico estacional derivados del Climate Historical Forecast Project (CHFP) y del North American Multi-Model Ensemble (NMME), respectivamente. En estos estudios hallaron que la predictibilidad de la temperatura es mayor que la de precipitación, y que el sudeste de Sudamérica y la Patagonia tienen potencial predictivo en latitudes extratropicales. Además, Osman y Vera (2017) hallaron que la predictibilidad mejora en los años que presentan fase no neutra de ENSO.

En el caso del enfoque estadístico o empírico, los modelos de previsión se basan en encontrar relaciones estadísticas entre la variable a pronosticar y variables de escala global, hemisférica, o regional observadas con antelación a la variable objetivo del pronóstico. Las variables que sirven de indicadores de la situación futura se denominan *predictoras*. Estas relaciones empíricas se obtienen a través de técnicas de aprendizaje estadístico, donde un algoritmo de determinadas características “aprende” de la relación entre las variables observada en el pasado. Las predicciones se basan en la suposición de que la relación históricamente observada continúa siendo válida en el futuro, lo que implica que son necesarias observaciones de calidad, y que se precisa encontrar

asociaciones que no sean espurias. Además, esta suposición puede ser una limitación ante la existencia de modos de variabilidad multidecadal y en el contexto de cambio climático antropogénico, que favorecen que las variables y su interacción no se mantengan estacionarias (Mason y Baddour, 2008; National Research Council, 2010; Renom et al., 2011; Doblas-Reyes et al., 2013; entre otros). Por otro lado, los modelos estadísticos requieren de bajo costo computacional para su diseño y su puesta en operaciones.

A nivel global, existen múltiples estudios que se han abocado a investigar la predictibilidad de distintas variables climáticas mediante metodologías empíricas. Las técnicas lineales fueron aplicadas para el pronóstico estacional de un gran abanico de variables (Gissila et al., 2004; Schöngart y Junk, 2007; Folland et al., 2011; Brands et al., 2012; Martínez et al., 2022; entre otros), aunque también han surgido investigaciones que emplean técnicas de aprendizaje no lineal. Li et al. (2010) compararon el desempeño de modelos de regresión lineal múltiple contra modelos derivados de la técnica no lineal denominada Máquina de Vectores de Soporte, encontrando que ésta última presentaba mejores resultados para el pronóstico del caudal en una región de Taiwán. Singhrattna et al. (2012) analizaron el desempeño del pronóstico de la precipitación acumulada trimestral en la cuenca del río Chao Phraya de Tailandia, desarrollado mediante la metodología de k -vecinos más cercanos. Mendoza et al. (2014) emplearon regresiones polinómicas locales para el pronóstico del caudal de primavera y verano en distintos sitios de la región central de Chile, encontrando particular habilidad en el pronóstico estacional de condiciones secas. Moura y Hastenrath (2004) se enfocaron en el pronóstico de la precipitación entre mayo y junio en la región noreste de Brasil, y contrastaron el rendimiento de pronósticos de regresión lineal múltiple y de redes neuronales artificiales contra el modelo de circulación general ECHAM4.5. Los autores hallaron que las dos primeras técnicas mejoran los errores, el sesgo, y la correlación entre los valores pronosticados y observados, respecto al modelo numérico. Además, encontraron que las redes neuronales explican un mayor porcentaje de varianza de la precipitación que los modelos lineales.

1.2. Pronóstico a mediano plazo mediante metodologías empíricas en Argentina

Existen distintas variables que son foco de atención para estudios de predictibilidad en la región, que emplean tanto metodologías lineales como no lineales. A continuación, se mencionan brevemente algunos ejemplos.

Tanco y Kruse (2001) elaboraron un pronóstico estacional de la precipitación en un sector en el este de la provincia de La Pampa y del noroeste de la provincia de Buenos Aires, partiendo de información sobre la temperatura superficial del mar en el océano Pacífico y empleando un algoritmo lineal. Con este pronóstico, derivaron finalmente una estimación futura del nivel de la napa freática en la región, clave para la mitigación de impactos de eventos tales como inundaciones. Almeira y Scian (2006) elaboraron modelos de regresión lineal para la predicción del Índice de Precipitación Estandarizado trimestral en el litoral argentino, concluyendo que para la región es posible encontrar un modelo univariado o multivariado adecuado para cada época del año. González y Cariaga (2010) estimaron la precipitación de invierno y primavera para el Comahue, una región de gran potencial de generación de energía hidroeléctrica en el noroeste patagónico, a partir de la técnica de correlación canónica. En la misma región, González y Domínguez (2012) elaboraron un pronóstico de ocurrencia de períodos húmedos y secos, partiendo del Índice de Precipitación Estandarizado de 6 meses y aplicando una regresión lineal múltiple. Más recientemente, González et al. (2023) desarrollaron esquemas estadísticos de predicción probabilística de la precipitación acumulada trimestral en la región del Comahue. Los autores emplearon un conjunto de técnicas lineales y no lineales en su trabajo, y encontraron que la habilidad de los pronósticos en situaciones no normales mejora el conocimiento dado por la climatología particularmente en invierno, cuando típicamente los valores acumulados son máximos. Teverovsky Korsic et al. (2023) emplearon la técnica de Regresión de Vectores de Soporte para el pronóstico con un mes de antelación del caudal medio mensual en la cuenca del río Tupungato, en los Andes centrales, empleando como variables de entrada a datos meteorológicos y a la cobertura nívica estimada satelitalmente. Las predicciones fueron comparadas con las derivadas de otras técnicas (Árboles de Decisión y Modelos Autoregresivos), pero se encontró comparativamente un mejor desempeño a partir de la Regresión de Vectores de Soporte. A su vez, también existen estudios enfocados en la perspectiva estacional de valores extremos. En este sentido, Collazo et al. (2022) se enfocaron en el análisis de extremos

térmicos al norte de 40°S. Las autoras diseñaron modelos para la previsión probabilística de índices vinculados a la frecuencia de ocurrencia de temperaturas mínimas y máximas que exceden umbrales dados por percentiles. En dicho estudio, se utilizó un importante conjunto de técnicas de aprendizaje estadístico y de selección de variables de entrada, y hallaron que el desempeño varía según la región, el momento del año, y el índice térmico pronosticado.

Actualmente, el Servicio Meteorológico Nacional (SMN) de Argentina organiza mensualmente las Reuniones de Tendencia Climática Trimestral en un espacio de coproducción del conocimiento entre distintas instituciones, que obran de productoras y usuarias de las herramientas de monitoreo y predicción climática que se presentan (Carabajal, 2020). En estas reuniones, se discute la perspectiva estacional de la temperatura media y la precipitación acumulada en el trimestre siguiente para distintos sectores del territorio argentino. Dicha perspectiva se basa en el consenso consolidado a partir de modelos dinámicos, estadísticos, e híbridos, así como de las condiciones prevalentes en los océanos y la atmósfera (Herrera, 2022). En particular, empleando los pronósticos trimestrales emitidos en el período desde 2018 a 2021, los pronósticos dados por el consenso muestran un mejor porcentaje de aciertos que los modelos individuales, tanto en precipitación como en temperatura. Por otro lado, la máxima eficiencia para discriminar la ocurrencia de eventos normales y no normales de las variables corresponde a los modelos estadístico e híbrido (Poggi et al., 2021).

Una de las bondades del modelado empírico es que permite realizar estudios locales, siempre dependiendo de la disponibilidad de datos para entrenar y validar los modelos de predicción. En particular, en el norte argentino se ubica la cuenca del Río Bermejo, emplazada en el sector centro-oeste del país. Por su ubicación geográfica en latitudes subtropicales y al este de la Cordillera de los Andes, esta región presenta cierta variabilidad espacial de sus características climáticas. A diferencia de lo que se observa en los Andes tropicales y patagónicos, la contribución a la descarga hidrológica en esta cuenca proviene fundamentalmente de la precipitación (Castino et al., 2017). Además, es una zona relevante en términos de la producción agropecuaria bajo condiciones de secano de sorgo, soja, algodón, maíz, y porotos (Arrieta y Pastor, 1998; Subsecretaría de Agricultura, 2022).

En esta región se han llevado a cabo algunos desarrollos en términos de la previsión estadística. A partir de observaciones tomadas en el período 1960-2010 en la llanura chaqueña, González et al. (2012) hallaron asociaciones simultáneas entre la precipitación trimestral e indicadores vinculados a la circulación en niveles bajos sobre el océano Atlántico, y a la temperatura superficial del mar en el Pacífico tropical central y en la costa oriental de Sudamérica. González y Murgida (2012) derivaron un pronóstico para la región de la cuenca del Río Bermejo empleando la técnica de regresión lineal múltiple sobre la precipitación acumulada trimestral entre enero y marzo, encontrando mayor eficiencia predictiva en el caso de veranos muy lluviosos. Más recientemente, Ayala (2019) y Ayala et al. (2021) se enfocaron en la previsión de la precipitación acumulada entre septiembre y noviembre mediante la técnica de regresión lineal múltiple. Los resultados hallados muestran la existencia de cierto grado de predictibilidad de la precipitación estacional de primavera en la cuenca. Estos trabajos alentaron a expandir el estudio a toda la época precipitante de la región, así como considerar la utilización de metodologías no lineales de modelado y evaluar la posibilidad de generar predicciones de la precipitación acumulada a nivel mensual. Además, estos trabajos estuvieron enfocados en la generación de pronósticos de carácter determinístico, es decir que no consideraron la inclusión de la incertidumbre dentro del resultado de los pronósticos emitidos. En este sentido, esta tesis doctoral apunta a profundizar la visión probabilística de los pronósticos a mediano plazo en la región.

1.3. Objetivos y aporte científico

Considerando la importancia del pronóstico a mediano plazo, el objetivo general de esta tesis es diseñar un conjunto de modelos de pronóstico de la precipitación mensual en la cuenca del Río Bermejo mediante el uso de metodologías de aprendizaje estadístico, en particular empleando técnicas lineales y no lineales. Esto permitirá elaborar pronósticos determinísticos y probabilísticos de la precipitación mensual en la temporada más lluviosa, es decir, es el semestre cálido austral (octubre-marzo).

En función de lo detallado, se abordarán los siguientes objetivos específicos:

- Elaborar una base de datos pluviométricos para el norte argentino, y analizar las diferencias en el régimen de precipitación en la extensión de la cuenca del Río Bermejo.
- Estudiar la relación entre las características meteorológicas e hidrológicas en la cuenca del Río Bermejo.
- Estudiar la relación existente entre la variabilidad interanual de la precipitación y diferentes forzantes climáticos de gran escala y escala regional, evaluando su potencialidad como predictores de la precipitación mensual en el semestre cálido.
- Elaborar esquemas de predicción mediante metodologías estadísticas, explorando distintas alternativas de aprendizaje estadístico. Evaluar la potencialidad predictiva a escala mensual analizando la eficiencia de estos modelos.

La presente tesis doctoral se estructura de la siguiente forma. En el Capítulo 2 se presentarán los datos de precipitación empleados en el estudio, y se abordará la caracterización hidroclimatológica de la cuenca del Río Bermejo. En el Capítulo 3 se realizará la exploración de los indicadores a ser considerados como potenciales predictores para los modelos de pronóstico de la precipitación mensual. En el Capítulo 4 se detallará la generación de dichos modelos mediante distintas técnicas de aprendizaje estadístico. Además, se incluirá una verificación del pronóstico determinístico dado por los modelos. En el Capítulo 5 se describirá la construcción y la verificación de los pronósticos probabilísticos, siguiendo un conjunto de métricas de desempeño. Finalmente, en el Capítulo 6 se presentarán las principales conclusiones.

Capítulo 2

Cuenca del Río Bermejo

El objetivo de este capítulo es realizar una descripción geográfica e hidroclimatológica de la región de la Cuenca del Río Bermejo, con el propósito de entender la relevancia de generar una previsión a mediano plazo de la precipitación en el período estival. En particular, se realiza una breve descripción de las principales características físicas de la cuenca. Luego, se detallan los datos in situ de precipitación y de caudal empleados para todo el estudio, así como el control de calidad de los mismos. Finalmente, se analiza la relación entre las variables hídricas y se detalla la regionalización del área de estudio a emplear en este trabajo.

2.1. Caracterización general de la Cuenca del Río Bermejo

La Cuenca del Río Bermejo forma parte de la Cuenca del Plata y se ubica en latitudes subtropicales de Sudamérica. Diversos autores han explorado los regímenes de circulación hemisférica y regional que influyen sobre la variabilidad climática en la región de la cuenca del Plata, particularmente en el sector sudeste de Sudamérica (González y Barros, 1998; Silvestri y Vera, 2003; Carvalho et al., 2004; Chan et al., 2008; Montini et al., 2019, Cai et al., 2020; entre otros). En particular, la Cuenca del Río Bermejo es una cuenca binacional compartida entre Argentina y Bolivia; cuenta con un área aproximada de 123000 km², 90% de la cual se concentra en territorio argentino mientras que el área restante se localiza dentro del Departamento de Tarija en el sudeste del país vecino (Figura 2-1a). El sector argentino de la Cuenca del Río Bermejo (simplemente denominado CRB a partir de ahora) se localiza ocupando parte de las provincias de Jujuy, Salta, Chaco y Formosa (Figura 2-1b). La cuenca se ubica al este de

la Cordillera de los Andes en un área conocida como el Gran Chaco, y ocupa una importante distancia longitudinal con una marcada disposición noroeste-sudeste de forma que atraviesa diferentes ecorregiones: el Chaco húmedo hacia el este, el Chaco semiárido en la región central, y los sectores Subandinos y Oriental de la Cordillera ubicados en el extremo oeste (Morello et al., 2012; Beck et al., 2018).




Figura 2-1. Cuenca del río Bermejo. **a)** Delimitación y elevación de la cuenca binacional del Bermejo, compartida por Argentina y Bolivia. En el recuadro superior derecho se indica la posición relativa de la cuenca en el continente sudamericano y se incluye la localización de Balapuca (circulo amarillo) y El Colorado (triángulo naranja). **b)** Red de drenaje del sector argentino de la cuenca (CRB) y delimitación por subcuencas (sombreado). Se indica con recuadros los nombres de las provincias argentinas en las cuales se asienta la CRB. Se señala también la ubicación de la Junta de San Antonio y la Junta de San Francisco.

La CRB se encuentra dividida en tres subcuencas distintivas: Bermejo Superior (BS), porción en comunicación directa con el sector boliviano de la cuenca ubicado en la naciente de Tarija; San Francisco (SF), localizada al sur del Bermejo Superior; y finalmente, el Bermejo Medio Inferior (BMI) que ocupa la sección centro-este de la cuenca (Figura 2-1b). El río Bermejo nace como confluencia de los cursos Orosas y

Condado, y representa el límite internacional entre Bolivia y Argentina en su recorrido en dirección noroeste-sudeste. Luego de aproximadamente 80 km de curso, confluye con el río Grande de Tarija en el punto conocido como Junta de San Antonio (Figura 2-1b). A partir de esa confluencia, el río Bermejo continúa circulando en dirección noroeste-sudeste recibiendo numerosos afluentes a través de su margen derecha. Entre ellos, se encuentran cursos con nacientes en altura (por ejemplo, el río Pescado nace a 4000 msnm) y cursos que aportan una gran carga de sedimentos, especialmente en el sector oeste de la cuenca. Por otro lado, el río San Francisco surge de la unión de los ríos Grande de Jujuy y Lavayén, y circula con rumbo nor-noreste recibiendo aportes por su margen izquierda hasta confluir con el río Bermejo en la Junta de San Francisco. A partir de este punto, el río Bermejo continúa su recorrido en el BMI sin recibir mayores aportes y primordialmente circulando en la llanura chaqueña, en una zona con muy poca pendiente lo que genera que el cauce del río no tenga límites precisos. En esta zona se destacan las pérdidas por evaporación e infiltración, pero también pueden ocurrir desbordes ante eventos de crecida, que suelen dirigirse hacia la margen derecha (COBINABE, 2010). Finalmente, el río Bermejo desemboca en el curso del río Paraguay, que eventualmente deposita sus aguas en el río Paraná. En particular, en el sector de planicie los eventos de inundación extraordinaria también podrían generar cambios en el curso del río, como en el evento identificado en la década de 1870. En esa ocasión, el curso se bifurcó, y la mayor parte del volumen de agua se trasladó a su posición actual y comenzó a fluir decenas de km al norte de su posición previa, dejando al curso anterior como un brazo secundario del río (Prieto y Rojas, 2015).

En la Figura 2-1a se incluye información sobre la elevación en los distintos puntos del área de la cuenca binacional, derivada de datos topográficos con resolución horizontal de ~ 90 m, obtenidos a través de la Shuttle Radar Topography Mission (SRTM) y disponibles en <https://www.earthdata.nasa.gov/data/instruments/srtm> (acceso en febrero de 2020). Se puede observar que existe un fuerte gradiente en la inclinación del terreno, especialmente en el sector occidental de la cuenca. Las subcuencas BS y SF presentan un área total de aproximadamente 38000 km² con una altura media de ~1800 msnm y máximos cercanos a 5000 msnm, mientras que el BMI tiene un área cercana a 70000 km² y una altura media de 220 msnm. Esta diferencia de alturas en los distintos sectores de la CRB implica también un cambio en el comportamiento de la red de drenaje, que presenta características típicas de montaña en el extremo noroeste y comportamiento de llanura en la región este.

En la Figura 2-2 se muestra el perfil longitudinal del cauce derivado de los datos de elevación de SRTM, siguiendo el curso del río Bermejo partiendo de la estación Balapuca en dirección corriente abajo hasta su desembocadura en el río Paraguay. Este perfil muestra claramente cómo disminuye la inclinación del cauce principal a partir de la Junta de San Francisco, pasando de una pendiente aproximada de 300 m en 100 km de recorrido sobre el cauce principal, a una pendiente de 300 m en 700 km aguas abajo de la Junta de San Francisco. Es importante destacar que, al seguir el curso principal, este perfil no considera el cambio de elevación de terreno dentro del área que contiene a los afluentes tributarios al cauce. La pendiente del terreno en la región de los tributarios al río Bermejo es significativa, particularmente en las subcuencas BS y SF (Figura 2-1).




Figura 2-2. Perfil longitudinal del cauce del río Bermejo entre la estación Balapuca y su desembocadura en el río Paraguay, aguas debajo de la estación El Colorado. En sombreado rojo se indica la porción del curso principal entre Balapuca y la Junta de San Antonio, y en sombreado azul se indica la porción del río Bermejo entre la Junta de San Antonio y la Junta de San Francisco. En sombreado gris se indica el sector del curso correspondiente al BMI. Tanto Balapuca como El Colorado se encuentran localizadas en la Figura 2-1a.

El río Bermejo es considerado altamente activo, con tasas elevadas de migración lateral del canal (20 a 30 m año⁻¹) particularmente en el sector oriental de planicie (Ferrero et al., 2015; Sambrook Smith et al., 2016). Castino et al. (2017) encontraron que el régimen de caudal está altamente influenciado por la precipitación, con un máximo en los meses de verano. Además, la carga sedimentológica en la CRB es una de las más altas del mundo; Amsler y Drago (2009) hallaron que el río Bermejo contribuye con aproximadamente 90% de la carga de sedimentos observada en el río Paraná, uno de los tributarios del Río de La Plata. Esto impacta en el material particulado en suspensión del Río de La Plata, cuya variabilidad está altamente asociada a la descarga del río Bermejo, y que presenta su máxima concentración de material particulado en el otoño austral, aproximadamente un mes después del pico medio anual de caudal del río Bermejo (Dogliotti et al., 2016; Camiolo et al., 2018).

2.2. Caracterización hidroclimatológica de la CRB

2.2.1. Datos empleados y control de calidad

Como se mencionó anteriormente, la CRB se emplaza atravesando regiones de ecosistemas diversos y las características del terreno también presentan variaciones a lo largo del recorrido del río homónimo. Esto se ve reflejado directamente en las particularidades hidroclimatológicas de la CRB, especialmente en variables como la precipitación y el caudal. Para poder analizar este comportamiento y, más adelante para poder generar un pronóstico a mediano plazo de precipitación areal, se emplearon datos in situ tomados en distintos puntos localizados en el norte argentino, tanto dentro de los límites geográficos de la cuenca como en zonas adyacentes.

2.2.1.1. Precipitación

La precipitación es una variable meteorológica que presenta enormes desafíos al momento de ser estudiada dada su naturaleza discontinua en el tiempo y en el espacio. Esto es particularmente relevante al trabajar en regiones acotadas de topografía compleja,

donde una red densa y confiable de puntos de medición in situ se vuelve necesaria, pero no siempre se encuentra disponible (OMM, 2018a). En muchas ocasiones, esta dificultad deriva en la necesidad de aplicar procedimientos complejos de interpolación espacial, combinando información satelital regional con herramientas estadísticas y técnicas de aprendizaje automático (por ejemplo, Di Piazza et al., 2011; Wagner et al., 2012), o en la necesidad de utilizar bases de datos de precipitación en puntos de retícula, derivadas de modelos numéricos. La elección del producto a utilizar para el análisis de la precipitación no es trivial, debiendo ser evaluado en la región objetivo y considerando que el producto utilizado impacta en las herramientas que de él se deriven (Tuo et al., 2016). En el sur de Sudamérica, Balmaceda Huarte et al. (2021) evaluaron la habilidad de un conjunto de reanálisis en representar apropiadamente diversos índices asociados a temperatura y precipitación, y encontraron que algunos productos tienen dificultades en representar apropiadamente los extremos de precipitación particularmente en cercanías a la Cordillera de los Andes y en la diagonal árida argentina. Birkel et al. (2022) realizaron una comparación similar en la región de los Andes centrales, en la cual uno de los reanálisis considerados exhibía errores considerablemente menores en su representación de la precipitación al contener una corrección basada en observaciones pluviométricas. Hurtado et al. (2024) evaluaron la precipitación del norte patagónico representada por un conjunto de reanálisis globales y cuatro bases de datos construidas a partir de técnicas de interpolación; una de éstas últimas mostró el mejor rendimiento en términos de variabilidad temporal, pero uno de los productos de reanálisis, en conjunto con un factor de corrección, presentó menores errores al sur de 40°S.

Debido a la dificultad vinculada a la representación de la precipitación en regiones de topografía compleja, en este trabajo de investigación se priorizó el valor de la observación tomada in situ en estaciones de medición. En Argentina, el Servicio Meteorológico Nacional cuenta con una red oficial de estaciones meteorológicas convencionales en el territorio argentino que portan pluviómetros y proveen datos de gran calidad siguiendo las directrices de la OMM. Sin embargo, el entramado de información generado no siempre es suficiente para estudiar procesos de escala regional (Skansi et al., 2013; Hurtado et al., 2021). Considerando el objetivo final del trabajo, esto es generar un pronóstico a mediano plazo de la precipitación areal a escala de cuenca en la CRB, se tomó información de las siguientes instituciones que cubren la región de estudio:

- Servicio Meteorológico Nacional (SMN)

- Sistema Nacional de Información Hídrica (SNHI)
- Administración Provincial del Agua (APA) de la provincia de Chaco

Los datos de precipitación obtenidos son de escala mensual en el sector argentino encuadrado en [66° O-58°O; 22°S-28°S] (región representada en la Figura 2-1b). En el sector de interés, el SNHI aporta información de pluviómetros correspondientes a la Red Hidrológica Nacional y a la Comisión Regional del Río Bermejo (COREBE). Por otro lado, APA incorpora datos de precipitación mensual en la provincia de Chaco, provenientes tanto de instrumentos electrónicos como de pluviómetros tipo “B” convencionales. Mediante la incorporación de los datos del SNHI y de la APA a la red pluviométrica del SMN, se generó una base de datos preliminar del sector de interés lo más densa posible. En este proceso fue importante considerar solamente estaciones de medición activas cuyas mediciones estuviesen disponibles con un registro suficientemente largo de datos, de forma que las herramientas de pronóstico de precipitación que se construyeran fueran no solamente operativizables, sino también verificables a futuro. Los datos del SNHI se encuentran actualmente disponibles en la web <https://www.argentina.gob.ar/obras-publicas/hidricas/base-de-datos-hidrologica-integrada>, mientras que los datos de la APA se pueden encontrar en <http://apachaco.gob.ar/site/> (acceso septiembre 2024). Para este estudio, se tomaron estaciones ubicadas dentro de los límites de la CRB y estaciones localizadas en los alrededores; esta última adición se realizó principalmente con el objetivo de mapear en forma más regionalmente coherente a los forzantes de la precipitación estival, como se detallará en el Capítulo 3.

Como se mencionó anteriormente, un factor de importancia es emplear estaciones que continuaran su actividad de registro hasta la actualidad, dado que un pronóstico operativo eficiente requiere de una tarea constante de verificación, y esto se logra solamente si existen datos reales contra los cuales contrastar a los pronósticos. Otra problemática a resolver fue la de determinar cuál sería el período de estudio y, por lo tanto, la muestra disponible para entrenar y verificar los pronósticos a mediano plazo. En este punto se plantea una disyuntiva: disponer de un registro de mediciones más extenso temporalmente, con la desventaja de tener menor cobertura espacial de los datos; o bien, acortar levemente el período de análisis, pero obteniendo una mayor cantidad de puntos de medición disponibles.

La Figura 2-3 muestra la cantidad de estaciones que se encuentran disponibles en el sector seleccionado para dos períodos específicos: 1981-2020 y 1984-2020. Se puede observar que retrasar el inicio del período de análisis ayuda a incrementar la cantidad total de estaciones disponibles, con una particular mejora en la cobertura dentro de la cuenca (21 a 35 estaciones, en forma preliminar). Dado que la CRB se trata de un área de estudio muy acotada territorialmente, donde la variabilidad espacial de la precipitación es relevante, se priorizó tener una mayor cobertura espacial a expensas de la longitud del registro. Por este motivo se continuó el análisis empleando a 1984-2020 como período de estudio, en el cual se cuenta con 62 estaciones en total para el sector (Tabla 2-1). Una vez determinado el período de estudio, se evaluó la calidad de los datos en los puntos de medición disponibles. Para ello, se realizó una búsqueda de errores indiscutibles (por ejemplo, valores de precipitación mensual negativos) y de outliers a remover. Adicionalmente, se evaluó la homogeneidad de las estaciones, así como el porcentaje de datos faltantes de las mismas.




Figura 2-3. Cantidad de estaciones pluviométricas dentro y fuera de los límites de la CRB que presentan mediciones en 1981-2020 y en 1984-2020. Los números dentro de las barras indican la cantidad de estaciones asociada a cada barra.

Lon (°O)	Lat (°S)	Institución	Provincia	Nombre	En CRB	Subcuenca
64.32	23.14	SMN	Salta	ORAN	x	BS
63.82	22.65	SMN	Salta	TARTAGAL		
62.88	24.18	SMN	Salta	RIVADAVIA	x	BMI
64.27	27.78	SMN	Sgo. del Estero	SGO DEL ESTERO		
58.99	27.45	SMN	Chaco	RESISTENCIA		
60.58	24.70	SMN	Formosa	LAS LOMITAS	x	BMI
60.45	26.78	SMN	Chaco	PRES RSPENIA		
58.18	26.18	SMN	Formosa	FORMOSA		
65.22	26.82	SMN	Tucuman	TUCUMAN		
65.40	27.05	SMN	Tucuman	FAMAILLA		
61.07	27.05	APA	Chaco	LAS BREÑAS		
65.96	27.40	SNHI	Tucuman	POTRERO DEL CLAVILLO		
65.22	27.10	SNHI	Tucuman	ruta PROV N307		
65.41	26.85	SNHI	Tucuman	POTRERO DE LAS TABLAS		
64.35	22.71	SNHI	Salta	AGUAS BLANCAS	x	BS
62.51	22.36	SNHI	Salta	LA PAZ		
59.35	26.33	SNHI	Formosa	EL COLORADO	x	BMI
61.20	27.80	APA	Chaco	SANTA SYLVINA		
60.70	27.30	APA	Chaco	SAN BERNARDO		
60.70	27.60	APA	Chaco	VILLA ANGELA		
60.80	26.80	APA	Chaco	CAMPO LARGO*		
59.60	27.60	APA	Chaco	CHARADAI		
60.43	26.35	APA	Chaco	TRES ISLETAS		
59.90	27.00	APA	Chaco	PRES PLAZA		
60.60	25.90	APA	Chaco	JJ CASTELLI		
58.70	27.30	APA	Chaco	CNIA BENITEZ*	x	BMI
59.70	26.50	APA	Chaco	LAGUNA LIMPIA*	x	BMI
58.50	26.90	APA	Chaco	PUERTO BERMEJO	x	BMI
59.30	26.50	APA	Chaco	GRAL SAN MARTIN	x	BMI

Lon (°O)	Lat (°S)	Institución	Provincia	Nombre	En CRB	Subcuenca
61.80	25.10	APA	Chaco	FUERTE ESPERANZA		
63.27	25.61	APA	Chaco	TACO POZO		
64.43	22.52	SNHI	Salta	BALAPUCA	x	BS
64.48	22.80	SNHI	Salta	CUATRO CEDROS	x	BS
64.10	22.37	SNHI	Salta	ASTILLERO	x	BS
64.72	22.90	SNHI	Salta	SAN JOSE	x	BS
65.22	22.79	SNHI	Salta	IRUYA	x	BS
65.10	22.75	SNHI	Salta	LAS HIGUERAS	x	BS
64.97	22.82	SNHI	Salta	SAN ANTONIO	x	BS
65.24	22.76	SNHI	Salta	SAN ISIDRO*	x	BS
65.10	22.51	SNHI	Salta	NAZARENO*	x	BS
65.09	22.41	SNHI	Salta	PALTORCO	x	BS
64.97	22.25	SNHI	Salta	SANTA VICTORIA OESTE	x	BS
65.26	22.42	SNHI	Salta	TUC TUCA	x	BS
65.08	22.46	SNHI	Salta	POSCAYA	x	BS
65.04	22.38	SNHI	Salta	TRIGO HUAICO	x	BS
65.29	22.53	SNHI	Salta	EL PABELLON	x	BS
64.20	23.22	SNHI	Salta	POZO SARMIENTO	x	BS
64.36	23.73	SNHI	Jujuy	CAIMANCITO	x	SF
65.60	22.11	SMN	Jujuy	LA QUIACA		
65.30	24.19	SMN	Jujuy	JUJUY AERO	x	SF
65.41	24.79	SMN	Salta	SALTA AERO		
59.93	26.03	APA	Chaco	PAMPA DEL INDIO	x	BMI
58.65	26.93	APA	Chaco	GRAL VEDIA*	x	BMI
61.48	24.91	APA	Chaco	NUEVA POMPEYA	x	BMI
61.18	26.50	APA	Chaco	PAMPA DEL INFIERNO		
65.15	22.60	SNHI	Salta	EL MOLINO	x	BS
59.23	28.03	SNHI	Santa Fe	FLORENCIA		

Lon (°O)	Lat (°S)	Institución	Provincia	Nombre	En CRB	Subcuenca
62.24	24.56	APA	Chaco	COMANDANCIA FRIAS	x	BMI
61.68	24.42	APA	Chaco	EL SAUZALITO	x	BMI
59.60	26.14	APA	Chaco	PRESIDENCIA ROCA	x	BMI
59.63	26.58	APA	Chaco	CIERVO PETISO	x	BMI
59.07	26.84	APA	Chaco	LA EDUVIGIS	x	BMI

Tabla 2-1. Listado preliminar de estaciones pluviométricas del norte argentino. Se incluye su posición geográfica, así como institución, provincia, y subcuenca de la CRB (marcado con una cruz, si corresponde) de pertenencia. Los nombres que se encuentran seguidos de un asterisco corresponden a estaciones que no atravesaron el control de calidad.

Ninguna de las estaciones consideradas presentó errores de naturaleza indiscutible. Paralelamente, para el análisis de outliers se decidió estudiar individualmente aquellos casos en los cuales la precipitación se alejó de la mediana al menos cinco veces el intervalo intercuartil del mes correspondiente, tomando como referencia climatológica al período 1985-2018. Este análisis individual por caso consistió en comparar la medición sospechosa contra la medición del mismo momento observada en estaciones cercanas, lo cual arrojó como resultado la ausencia de outliers a remover.

A partir de este punto, se analizó la homogeneidad de las estaciones. Esta evaluación cobra particular importancia por el uso de redes pluviométricas externas al SMN, dado que podrían potencialmente existir cambios de instrumental, relocalización de los puntos de medición, y otras fuentes desconocidas de saltos de origen no climático y/o puntos de quiebre espurios en las series temporales de las estaciones de medición. Para el análisis de homogeneidad se emplearon dos metodologías: el test de Homogeneidad Normal Estándar (Alexandersson, 1986) y test de Rango de Buishand (Buishand, 1982). Estas técnicas exploran si existe un punto de quiebre en la serie de precipitación mensual en el período observado que pueda indicar que hubo un cambio en las características estadísticas de la serie con el tiempo. El test de Homogeneidad Normal Estándar (SNHT) es una prueba paramétrica de quiebre que compara las sumas acumuladas entre segmentos de una serie temporal antes y después de un salto, mientras que el test de Rango de

Buishand (BRT) es una prueba no paramétrica realizada mediante simulaciones de Monte Carlo, que compara sumas acumuladas de las diferencias entre las observaciones y su media. Ambas metodologías se aplicaron con un 90% de confianza bajo la hipótesis nula de que no existe un quiebre en la variabilidad de la precipitación mensual de cada estación.

En la Figura 2-4 se marcan los años en los cuales el SNHT y el BRT detectan un punto de quiebre con 90% de confianza para cada una de las 62 estaciones originalmente consideradas. En este caso, se descartaron las estaciones en las cuales existe un quiebre en el mismo año o años muy cercanos según ambas metodologías, con un 10% de significancia. Por esta razón, se removieron a las estaciones Campo Largo (quiebre en 2003), Colonia Benítez (quiebre en 1998), Laguna Limpia (quiebre en 2002), San Isidro (quiebre en 1993), Nazareno (quiebre en 1991 según SNHT y en 1993 según BRT), y General Vedia (quiebre en 1998 según SNHT y en 1999 según BRT).




Figura 2-4. Resultados de los tests de homogeneidad aplicados sobre la precipitación mensual de cada una de las 62 estaciones meteorológicas preliminares. Los círculos (cruces) indican el año en el cual el SNHT (BRT) detecta un punto de quiebre con 90% de confianza para cada uno de los puntos de medición.

Finalmente, se evaluó la cantidad de faltantes en las series de precipitación mensual en 1984-2020, tomando como umbral máximo aceptable un 10% de faltantes en el registro total, considerando además que al menos un 90% de los registros de cada mes se encuentren completos para evitar que los faltantes del registro total se concentren en un mes en particular. Con esto, se obtuvieron 56 puntos de medición, 31 de los cuales se ubican dentro de los límites de la CRB. La máxima cantidad de faltantes es de 7% en el registro completo de precipitación. En todos los casos, los faltantes fueron completados con la media mensual en el periodo 1985-2018. La distribución espacial de las estaciones que atravesaron el control de calidad se muestra en la Figura 2-5, en la cual se detalla también el aporte de información por parte del SNHI y de la APA.




Figura 2-5. Distribución espacial de las 56 estaciones que atravesaron el control de calidad. Se indica con distintos marcadores la institución de pertenencia. En sombreado se marca el área de cada subcuenca de la CRB.

2.2.1.2. Caudal

Para la caracterización hidrometeorológica de la CRB se tomaron datos de caudal medio diario en distintas estaciones hidrométricas ubicadas dentro de los límites de la CRB (Figura 2-6) para el período 1985-2018. El caudal fue seleccionado como variable de análisis hidrológico dado que la información relativa a la altura hidrométrica puede presentar inconsistencias en algunos puntos de medición atribuibles a cambios no documentados en la posición de la escala hidrométrica de referencia (COBINABE, 2010). Se consideraron aquellas estaciones hidrométricas que presentaran al menos 90% de registro de datos diarios completo, se calcularon los promedios mensuales, y aquellos valores mensuales faltantes fueron completados con la media mensual del mes correspondiente. A lo largo del control de calidad no se detectaron errores indiscutibles ni presencia de outliers. Todos los datos de caudal fueron obtenidos de la SNHI.




Figura 2-6. Distribución de estaciones de medición consideradas para el análisis de la relación precipitación-caudal. Se incluyen las estaciones puramente hidrométricas (círculos azules), las estaciones puramente meteorológicas (triángulos verdes) y las estaciones hidrometeorológicas (rombos amarillos). Los nombres de las estaciones se encuentran detallados en la esquina superior derecha.

2.2.2. Caracterización hidrometeorológica

En esta sección, se presenta el análisis climatológico de la precipitación y el caudal en la región de estudio. Debido a que el caudal presenta un registro ligeramente más acotado que el de la precipitación, el análisis del comportamiento medio, de las tendencias, y de la relación entre las variables se realizó en base al período coincidente (1985-2018).

2.2.2.1. Comportamiento medio

La Figura 2-7 exhibe los ciclos medios de precipitación de las estaciones pluviométricas dentro de los confines de la CRB para el periodo 1985-2018, disgregados por subcuenca de pertenencia (ver Tabla 2-1 y Figura 2-5 para más detalle de las ubicaciones). Se puede observar que a lo largo de toda la extensión de la CRB existe una marcada estacionalidad de la precipitación mensual, aunque el comportamiento de las ondas anuales y las diferencias intra-subcuencas difieren según el sector que se analice. En todas las estaciones el invierno austral presenta los menores acumulados, incluso registrándose ausencia de precipitación en las estaciones ubicadas en el extremo oeste de la CRB. Las estaciones localizadas en el BS muestran grandes variaciones en el rango anual de la onda, definido como la diferencia entre los valores máximo y mínimo del ciclo medio. En esta subcuenca los máximos se observan primordialmente entre diciembre y febrero, con una marcada temporada seca entre mayo y septiembre. Los máximos del ciclo medio se observan típicamente en enero, y pueden variar entre acumulados mensuales menores a 100 mm en el borde oeste del BS hasta valores que superan los 300 mm por mes en el sector centro-este del BS. Esto implica que existe una diferencia superior a los 200 mm entre estaciones del BS, la subcuenca de área más pequeña dentro de la CRB, lo cual podría estar muy vinculado a las variaciones en la elevación del terreno. La subcuenca SF sólo contiene dos estaciones pluviométricas, que presentan un comportamiento similar en cuanto a su estacionalidad y a los meses del año que presentan los mayores acumulados, aunque con menor variación intra-subcuenca respecto a los rangos de la onda anual en comparación al BS. Por otro lado, el BMI muestra un comportamiento pluviométrico de doble máximo, concentrados primordialmente en los meses de transición estacional (abril y octubre). Los únicos apartamientos de este comportamiento se observan en las estaciones Rivadavia y Comandancia Frías, que siguen mostrando una onda anual de único máximo en los meses estivales; ambas estaciones se localizan precisamente en el

extremo oeste del BMI, de forma que su comportamiento actúa como transición entre las subcuencas del sector oeste y la región este de la CRB. Los rangos anuales de las estaciones del BMI no son tan marcados como en el caso del sector superior de la CRB (BS+SF), y en el invierno austral los acumulados son menores que en el resto del año, pero no alcanza a observarse la presencia de una estación propiamente seca. Estas diferencias en el comportamiento pluviométrico a lo largo de la extensión de la CRB es una de las causas de la variabilidad en ecosistemas presentes en la cuenca.




Figura 2-7. Ciclos medios anuales de precipitación en 1985-2018 para las estaciones pluviométricas consideradas dentro de los límites de la CRB. En la leyenda las estaciones se ordenan según su posición longitudinal en orden oeste-este. Los ciclos se encuentran separados por subcuenca de pertenencia.




Figura 2-8. Hidrograma medio (1985-2018) para las estaciones hidrométricas mostradas en la Figura 2-6. Los hidrogramas se encuentran separados por subcuenca de pertenencia.

El caudal medio mensual también presenta un comportamiento estacional pronunciado, según se detalla en la Figura 2-8. Así como ocurre con la precipitación, el caudal medio mensual presenta fuertes variaciones en su magnitud según el punto de aforo que se considere (ver Figura 2-6). Las estaciones San José y Cuatro Cedros son de referencia para dos de los tributarios al Río Bermejo en el BS, los ríos Iruya y Pescado respectivamente. En ambas locaciones el caudal presenta sus máximos hacia el final del período estival en el mes de febrero, con valores menores a los $200 \text{ m}^3 \text{ s}^{-1}$. En Aguas Blancas, ubicada aguas arriba de la Junta de San Antonio, se observa una evolución similar, aunque con un máximo en febrero que supera levemente los $250 \text{ m}^3 \text{ s}^{-1}$, similar al comportamiento del Río San Francisco a la altura de la estación Caimancito. Aguas abajo de la Junta de San Antonio, y previo a recibir los aportes del río San Francisco en la Junta de San Francisco, la estación Pozo Sarmiento muestra un incremento sustancial de los máximos observados, con un caudal mensual máximo que supera en más de cuatro veces el caudal pico de Aguas Blancas. Esto se debe a la confluencia del río Bermejo con el río Grande de Tarija en la Junta de San Antonio y los posteriores aportes de los numerosos afluentes del BS. Finalmente en El Colorado, ubicado en el extremo este del BMI, el caudal muestra un comportamiento muy similar al observado en Pozo Sarmiento,

lo que sugiere que posiblemente los aportes del BS sean los que en gran parte expliquen la evolución anual del caudal en el BMI. Los meses de estiaje, correspondientes al momento en el que se da el mínimo caudal mensual y que dan inicio al año hidrológico, se ubican en torno a septiembre-octubre, de forma que el aumento estacional del caudal responde al ciclo pluviométrico, especialmente del sector oeste de la cuenca. En la Tabla 2-2 se detallan algunas características del comportamiento del caudal para cada punto de aforo. El año hidrológico, que comienza en el mes de estiaje, inicia entre septiembre y octubre para todas las estaciones hidrométricas de la cuenca. Se puede observar que El Colorado maximiza su caudal en marzo, es decir que presenta un desfase de un mes respecto a los puntos ubicados aguas arriba. En la Tabla 2-2 también se incluye el coeficiente de variación anual, que cuantifica la variabilidad interanual del caudal a través del cociente entre el desvío estándar y el valor medio del caudal medio anual en el año hidrológico para el período de referencia 1985-2018. En este caso se puede observar que el mínimo coeficiente de variación se asocia a Aguas Blancas, mientras que la mayor variabilidad interanual del caudal se observa en San José (aforo ubicado sobre un tributario del BS) y Caimancito (aforo ubicado sobre el río San Francisco en el SF). Esta variabilidad interanual es levemente menos marcada hacia El Colorado, sobre el final del curso de Bermejo.

Estación	Subcuenca	Mes de estiaje	Mes de pico	Coef. de variación
Aguas Blancas	BS	9	2	0.19
Cuatro Cedros	BS	9	2	0.22
San José	BS	9	2	0.28
Caimancito	SF	10	2	0.28
Pozo Sarmiento	BS	9	2	0.23
El Colorado	BMI	10	3	0.23

Tabla 2-2. Métricas del comportamiento del caudal en las estaciones hidrométricas de la CRB.

Se indica mes de inicio del año hidrológico (estiaje), mes del máximo caudal mensual observado, y coeficiente de variación del caudal medio anual según el año hidrológico.

En la Figura 2-9 se muestra la correlación cruzada del caudal diario (1985-2018) a lo largo de todo el año entre las series temporales de Pozo Sarmiento-El Colorado, Caimancito-El Colorado, y Entrante-El Colorado. Siguiendo a COBINABE (2010), se entiende por Entrante al caudal que ingresa al BMI y que resulta de la suma de los aportes de caudal de Pozo Sarmiento y Caimancito. El coeficiente de correlación cruzada máximo (0.76) y significativo al 95% de confianza se observa en el desfase de 8 días entre el caudal Entrante y El Colorado, lo cual refleja la relación entre la estación de aforo del BMI y las estaciones individuales ubicadas aguas arriba. Esto indica que a lo largo del año existe un retraso de aproximadamente una semana en la onda de crecida de caudal diario entre la Junta de San Francisco y El Colorado. Conocer el tiempo de retraso es particularmente relevante para poder activar tareas de gestión de riesgo ante potenciales eventos de crecida que puedan impactar negativamente al BMI. En particular, según COBINABLE (2010) un caudal entrante al BMI mayor a $2000 \text{ m}^3 \text{ s}^{-1}$ puede causar desbordes en el tramo inferior de la CRB.




Figura 2-9. Correlación cruzada entre el caudal medio diario de: Pozo Sarmiento y El Colorado (azul), Caimancito y El Colorado (rojo), Entrante y El Colorado (verde) para 1985-2018. En todos los casos la serie temporal de El Colorado se desfasa hacia adelante en el tiempo comparada a las demás series. Todos los valores de correlación mostrados en la Figura son significativos al 95% de confianza usando test T-Student a dos colas.

Es de interés analizar si existe algún momento del año hidrológico en el cual la relación entre los caudales de las subcuencas superiores y el BMI en escala mensual es más intensa. Al tomar caudales mensuales se filtran los eventos de crecidas individuales del orden de los pocos días, pero permite inferir si una situación sostenida en el tiempo de caudales anómalamente altos en la parte superior de la CRB puede predecir una situación similar en el tramo inferior. La Figura 2-10 muestra la correlación cruzada entre el caudal Entrante y El Colorado para cada uno de los meses entre octubre (estiaje de El Colorado) y marzo (mes a partir del cual el hidrograma medio muestra una caída del caudal en el BMI, como se observó en la Figura 2-8). Existe una correlación alta y significativa al 95% de confianza particularmente en los desfases de 0 y 1 mes en gran parte del semestre, indicando que un mayor caudal mensual Entrante se asocia a un aumento simultáneo en el caudal de El Colorado, así como en el mes posterior. Sólo hacia el final del semestre se tiene que el caudal Entrante está estadísticamente asociado al caudal de El Colorado con hasta 3 meses de retraso.




Figura 2-10. Correlación cruzada de caudal mensual entre Entrante y El Colorado para 1985-2018. El título de cada panel hace referencia al mes en el que se observa el caudal Entrante, y en todos los casos la serie temporal de El Colorado se desfasa hacia adelante en el tiempo comparada al caudal Entrante. Se indican bandas de significancia de los coeficientes de correlación lineal siguiendo un test T-Student a dos colas con 95% de confianza.

Por otro lado, contar con un caudal de base más alto podría potencialmente ser una situación de riesgo ante crecidas repentinas. La Figura 2-11 muestra la correlación cruzada calculada bajo el período 1985-2018 entre el caudal medio mensual observado entre octubre y marzo en Pozo Sarmiento y el caudal máximo diario observado posteriormente en El Colorado. Los valores de correlación alcanzados son significativos y máximos con desfases de 0 y 1 mes, indicando que mayores caudales diarios pueden suceder en el tramo inferior hasta un mes después de la presencia de anomalías positivas en el caudal medio mensual del sector superior.




Figura 2-11. Correlación cruzada entre el caudal mensual de Pozo Sarmiento y el caudal diario máximo del mes en El Colorado en el período de octubre a marzo para 1985-2018. La serie temporal de caudal diario máximo de El Colorado se desfasa hacia adelante en el tiempo comparada a la serie de Pozo Sarmiento. Se indican bandas de significancia de los coeficientes de correlación lineal siguiendo un test T-Student a dos colas con 95% de confianza.

2.2.2.2. Relación precipitación-caudal

Para analizar la relación entre ambas variables hidrológicas, en cada una de las subcuencas se consideraron algunas estaciones de referencia, que se muestran en la Figura 2-6. En el BS se tomaron a las estaciones pluviométricas Orán Aero (357 msnm) e Iruya (2741 msnm) como representativas de las regiones centro-este y extremo oeste de la

subcuenca, respectivamente. Esta doble elección se debió a la variación de altura del terreno en la dirección transversal al curso principal. Además, si bien la precipitación mensual de octubre a abril (por fuera del período seco) muestra un coeficiente de correlación lineal significativo (r) entre Orán Aero e Iruya ($r = 0.52$), no existe una asociación lineal estadísticamente relevante entre ambas estaciones para la precipitación acumulada anual ($r = -0.04$). En el caso del SF, se tomaron los datos pluviométricos de la estación Jujuy Aero, que está correlacionada significativamente con la estación Caimancito a escala mensual entre octubre y abril, así como a escala anual (coeficientes de correlación lineal iguales a 0.66 y 0.43, respectivamente). Todas las pruebas de significancia se realizaron con un test T-Student a dos colas, bajo un 95% de confianza. En el caso del BMI, se consideraron los datos pluviométricos de El Colorado. Por otro lado, se tomaron los datos de caudal en las estaciones Pozo Sarmiento y Caimancito (aguas arriba de la Junta de San Francisco sobre los ríos Bermejo y San Francisco, respectivamente) y en El Colorado, localizado previo a la desembocadura del Río Bermejo en el Río Paraguay.

Como se destacó anteriormente, las estaciones Pozo Sarmiento y Caimancito, cercanas a los puntos de cierre de las subcuencas BS y SF respectivamente, presentan el pico de caudal medio mensual (1985-2018) en el mes de febrero (Tabla 2-2). Esto implica que existe un desfase de un mes entre el hidrograma medio mensual de las estaciones de aforo y sus respectivas estaciones pluviométricas de referencia aguas arriba (Iruya y Orán Aero para BS; Jujuy Aero para SF). Para poder inferir si existe una relación entre la precipitación observada en las distintas estaciones meteorológicas y el caudal en las estaciones de aforo, se calculó la correlación cruzada entre cada punto de medición pluviométrica y el caudal mensual (Figura 2-12a), así como el caudal diario máximo del mes (Figura 2-12b) en El Colorado. Para lograrlo, se tomaron los meses de octubre a marzo en 1985-2018, comprendiendo el período entre el estiaje y el máximo de caudal medio mensual en el tramo inferior de la CRB. En la Figura 2-12 se puede observar que el comportamiento del caudal en El Colorado no responde realmente a los valores acumulados de precipitación en el mismo punto, sino a lo que esté precipitando corriente arriba en la CRB. En particular, tanto el BS como el SF presentan una máxima asociación significativa al 95% de confianza con el tramo inferior en forma simultánea y con un desfase de un mes. Esto implica que las anomalías de precipitación en cualquiera de las estaciones pluviométricas del sector superior de la CRB en un determinado mes del

período octubre-marzo se vinculan linealmente tanto con el caudal medio mensual como con el máximo caudal diario en el tramo inferior, en el mismo mes y en el mes siguiente. El coeficiente de correlación en el desfase de un mes es máximo para Orán Aero (sector centro-este del BS) y para Jujuy Aero (SF), y decae rápidamente ante mayores desfases. Esto implica que tener una estimación de cómo se comportará la precipitación a mediano plazo, particularmente en el sector superior de la cuenca, es relevante para poder tener una perspectiva de cómo será el comportamiento medio del caudal en simultáneo y posteriormente, así como para evaluar la posibilidad de que se originen picos diarios en el caudal que puedan generar un impacto local en el tramo superior o, en forma retrasada, en el tramo inferior de la CRB. Adicionalmente, los picos de crecidas son altamente dependientes de la situación del caudal base que puede verse directamente influido por las anomalías de la precipitación; mayor precipitación podría producir un aumento simultáneo del caudal base en la red de drenaje, de forma que la chance de desborde se incrementa un mes posterior incluso aunque la precipitación revierta a una situación normal. Esto se vio previamente en la Figura 2-11, en la cual se encontró una relación estadística entre el valor del caudal medio de un mes en el BS y la magnitud del caudal pico diario alcanzado ese mismo mes y el mes siguiente en El Colorado, indicando que existe una inercia en el comportamiento hidrológico de la CRB a la que muy probablemente contribuye la baja pendiente en el tramo inferior. Por estas razones, el pronóstico de precipitación a mediano plazo en esta región es una herramienta útil en la gestión del recurso hídrico.




Figura 2-12. Correlación cruzada de precipitación mensual de octubre a marzo entre Iruya (Orán Aero/Jujuy Aero/El Colorado) y **a)** el caudal medio mensual en El Colorado; **b)** el caudal diario máximo del mes en El Colorado para 1985-2018. En todos los casos la serie temporal de caudal de El Colorado se desfasa hacia adelante en el tiempo comparada a las series de precipitación. Se indican bandas de significancia de los coeficientes de correlación lineal siguiendo un test T-Student a dos colas con 95% de confianza.

2.2.2.3. Semestre estival

Como se observó anteriormente en los ciclos medios anuales de precipitación mensual (Figura 2-7), las estaciones de la CRB muestran claramente que la precipitación se concentra en la temporada estival austral; incluso en algunas estaciones del sector superior (BS+SF) se observa la presencia de una estación seca en los meses del invierno austral. Dado que esta es una variable de interés para la evolución del caudal, el objetivo de este estudio es lograr un pronóstico mensual de precipitación centrado en la estación cálida y lluviosa.

Para ello, a partir de la base de datos de precipitación de las estaciones que atravesaron el control de calidad (Figura 2-13a), se realizó una selección subjetiva de los puntos de medición que permitiera tener una cobertura lo más uniforme posible en el sector norte del país (estaciones dentro y fuera de los límites de la CRB), evitando siempre que fuera posible tener aglomeración de puntos en sitios específicos. De esta forma, se llegó a la base final de precipitación mensual, cuya distribución espacial se muestra en la Figura 2-13b. Esta base cuenta con 45 puntos de medición, de los cuales 22 se encuentran dentro de los límites de la CRB. De aquí en adelante, este grupo de estaciones conformará la base de datos de precipitación final.




Figura 2-13. a) Distribución espacial preliminar de estaciones en el sector norte argentino, seleccionadas luego del control de calidad. **b)** Distribución espacial final de estaciones en el sector argentino.

El panel izquierdo de la Figura 2-14 muestra cuál es el semestre en el que se detectan a nivel climatológico los valores de precipitación acumulada más altos para cada estación de la CRB. Se puede observar que la precipitación se concentra en octubre-marzo y noviembre-abril, siendo las estaciones ubicadas más al oeste donde mayor es el porcentaje de aporte de estos semestres al acumulado anual climatológico (hasta 96% del total anual). Por otro lado, las estaciones en el extremo este de la cuenca presentan en comparación una evolución más uniforme de la precipitación a lo largo del año (cómo se destacó previamente en la Figura 2-7), y por lo tanto existe un aporte más sustancial al acumulado anual por fuera del semestre más precipitante. En la Figura 2-14 se destaca que todas las estaciones ubicadas al oeste de Las Lomitas concentran más del 80% de los acumulados anuales en el período octubre-abril, mientras que hacia el este de Las Lomitas este período concentra aproximadamente un 66% a 80% de la precipitación anual.




Figura 2-14. Izquierda: Semestre más precipitante para cada estación pluviométrica seleccionada (barra horizontal) y porcentaje de aporte de la precipitación semestral a la precipitación anual media (1985-2018). **Derecha:** diferencia en la contribución a la precipitación anual media de los semestres noviembre-abril y octubre-marzo. Las estaciones en el eje-y se encuentran ordenadas longitudinalmente de oeste a este.

La diferencia entre considerar a octubre-marzo o a noviembre-abril como semestre de estudio uniforme para toda la extensión de la cuenca radica esencialmente en los aportes de los meses de octubre y abril en cada punto de medición. La diferencia entre estos semestres en términos de contribución a la precipitación anual se muestra en el panel

derecho de la Figura 2-14. Si bien en la mayor parte de las estaciones el semestre más precipitante es noviembre-abril, las diferencias en el aporte al acumulado anual presentan una mediana del 2.1% y se mantienen menores al 6.2%. Considerando estas pequeñas diferencias, se decidió definir al semestre estival de estudio como aquel comprendido entre octubre y marzo, ocupando la primera porción del año hidrológico en la cuenca y acercando el inicio del semestre más hacia lo que típicamente se considera la primavera meteorológica austral (septiembre-noviembre), en la cual es esperable tener más señal de los forzantes de gran escala sobre la precipitación (Cai et al., 2020). A partir de este momento, el semestre estival será entonces definido como el período comprendido en octubre-marzo, y se considerará que la primavera estará compuesta por los meses octubre a diciembre (OND) mientras que el verano estará conformado por los meses enero a marzo (EFM).

2.2.2.4. Variabilidad de largo plazo

Dentro del estudio general de la variabilidad climática de una región se encuentra el análisis de las tendencias a largo plazo, especialmente en el contexto global de cambio climático en el cual se han observado cambios en el ciclo hidrológico desde mediados del siglo XX (Arias et al., 2021). En particular, la precipitación ha demostrado presentar una gran variabilidad espacial en los cambios de largo plazo observados en las últimas décadas, así como también se espera que los cambios proyectados a futuro no se desarrollen de manera uniforme en todo el globo (Liebmann et al., 2004b; Gemmer et al., 2004; Longobardi y Villardi, 2010; de Luis et al., 2014; entre otros). En particular, una tendencia hacia condiciones más húmedas ha sido detectada en el sudeste de Sudamérica desde mediados del siglo XX. Barros et al. (2000) documentaron en el período 1956-1991 principalmente tendencias positivas de precipitación anual en Argentina subtropical al este de la Cordillera de los Andes, que relacionaron con cambios en la posición latitudinal de los sistemas de circulación de gran escala. De forma similar, Haylock et al. (2006) hallaron incrementos en la precipitación anual y extrema en el sur de Brasil, Paraguay, Uruguay y noreste de Argentina hacia finales del siglo XX, que parcialmente explicaron a través de una migración hacia condiciones Niño más dominantes mediante análisis de correlación canónica. La CRB está localizada en una zona que atravesó la expansión hacia el oeste de la frontera agrícola en la segunda mitad del siglo XX, parcialmente como consecuencia del incremento en las precipitaciones anuales en el sudeste de Sudamérica

(Murgida et al., 2014; Barros y Camilloni, 2016). Esto derivó a su vez en deforestación y cambios en el uso del suelo que favorecieron el desarrollo de actividades de agricultura. A continuación, se analizará la presencia de tendencias observadas de la precipitación y el caudal en el sector norte argentino, con especial énfasis en la CRB. Para ello, se utilizarán dos metodologías.

En primer lugar, se utilizó la metodología de regresión lineal. Dicha técnica es ampliamente empleada para la caracterización y la cuantificación de cambios graduales en variables hidrometeorológicas (ver por ejemplo Gemmer et al., 2004; Doyle et al., 2012; de Luis et al., 2014). La pendiente obtenida mediante regresión lineal expresa la cantidad de cambio de una variable por unidad de tiempo, que luego puede ser testada por significancia utilizando un test T-Student. El estadístico t se obtiene como el cociente entre la estimación de la pendiente lineal, calculada con ajuste por cuadrados mínimos, y el error estándar de la estimación de la pendiente. En un test T-Student a dos colas para una serie temporal compuesta de n observaciones y considerando un nivel de significancia α de 5%, la pendiente lineal se considera estadísticamente significativa si el valor absoluto de t supera el umbral que acumula el 97.5% de probabilidad en la función de distribución T-Student con $n-2$ grados de libertad.

Por otro lado, se aplicó la metodología de Mann-Kendall para detección de tendencia en series hidrometeorológicas (Hannaford y Buys, 2012; Chen et al., 2014; Ay y Kisi, 2015). A diferencia de la regresión lineal, Mann-Kendall es un test no paramétrico que no requiere suposiciones sobre la distribución de los datos y que puede emplearse en variables de naturaleza asimétrica donde la presencia de valores extremos que puedan afectar la estimación de la pendiente por cuadrados mínimos es posible. El test de Mann-Kendall permite la detección de un comportamiento creciente/decreciente monótono en una variable a lo largo del tiempo, que no necesariamente implica un cambio lineal. Si la serie temporal consta de n observaciones, el parámetro S cuenta la cantidad de veces que un cierto valor x_i observado en el instante i es superado en un tiempo subsiguiente j ($j > i$) por x_j :

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{signo}(x_j - x_i) \quad (2.1)$$

La varianza de S es computada como

$$Var(S) = \frac{n(n-1)(2n+5) - \sum_{k=1}^p t_k(t_k-1)(2t_k+5)}{18} \quad (2.2)$$

donde p denota la cantidad de grupos con observaciones repetidas y t_k es la cantidad de valores repetidos dentro del k -ésimo grupo. Este término suele ser obviado en ausencia de observaciones repetidas en la serie temporal. Combinando las ecuaciones (2.1) y (2.2) se obtiene el estadístico Z de Mann-Kendall como

$$Z = \begin{cases} \frac{S-1}{\sqrt{Var(S)}}, & \text{si } S > 0 \\ 0, & \text{si } S = 0 \\ \frac{S+1}{\sqrt{Var(S)}}, & \text{si } S < 0 \end{cases} \quad (2.3)$$

El estadístico Z sigue una distribución gaussiana y toma valores positivos (negativos) si hay un incremento (reducción) de la variable en el tiempo. En un test a dos colas considerando un nivel de significancia α de 5% se dice que existe una tendencia estadísticamente significativa si el valor absoluto de Z excede al umbral que acumula el 97.5% de probabilidad en la función de distribución gaussiana.

Como en el caso de la regresión lineal, el test de Mann-Kendall fue diseñado para detectar tendencias en series temporales con independencia serial; caso contrario, puede aumentar el error tipo I del test. Para sortear esta problemática, algunos autores propusieron distintas alternativas (von Storch, 1995; Yue et al., 2002). Para este análisis de tendencias, se utilizó la variante propuesta por Öñöz y Bayazit (2012) denominada block-bootstrap Mann-Kendall en los casos en los que se observa una autocorrelación en el primer desfase significativa al 95% de confianza mediante test de Anderson (Anderson, 1942), lo que sería indicativo de dependencia serial. La variante de Mann-Kendall de Öñöz y Bayazit (2012) implica utilizar remuestro de bootstrap en bloques de datos. En este caso se consideraron 2000 simulaciones y se empleó un bloque de longitud 5; para cada simulación (muestra) se obtiene un estadístico Z' de Mann-Kendall. En estos casos particulares, se dice que existe una tendencia positiva (negativa) significativa al 5% de

significancia si el estadístico Z de la serie temporal original supera al cuantil 97.5% (es menor al cuantil 2.5%) dado por el histograma de los Z' surgidos de los remuestreos.

En este caso particular, las técnicas se aplicaron sobre la precipitación acumulada anual y la precipitación acumulada en el semestre estival. Los resultados de aplicar las técnicas de detección de tendencias se observan en las Figuras 2-15 y 2-16 para la precipitación anual (1985-2018) y semestral en octubre-marzo (1984/1985-2017/2018), respectivamente. En ellas se indican el valor de la tasa de cambio de la precipitación según la pendiente por cuadrados mínimos, el cociente de regresión lineal que cuantifica la tasa de cambio por década normalizada por la precipitación anual o semestral (según corresponda), y el p-valor del test de Mann-Kendall.

La Figura 2-15 muestra que en el período de análisis la precipitación anual presenta predominantemente tendencias al decrecimiento según la regresión lineal, que son máximas en magnitud en la provincia de Chaco y que oscilan entre $-10.8 \text{ mm año}^{-1}$ y $-17.3 \text{ mm año}^{-1}$. Esto implica un decrecimiento relativo a los valores climatológicos anuales del orden de los 10% década⁻¹, según el cociente de regresión lineal. Al oeste de 62°O la variabilidad en el signo de la tendencia aumenta, aunque en SF y BS las estaciones que presentan los cambios más relevantes en términos del cociente de regresión presentan pendientes negativas. En el noroeste de la provincia de Salta, en el sector oeste del BS, hay una reducción significativa de cerca de -4.7 mm año^{-1} , lo que representa una caída del 10% por década en la precipitación anual relativa a valores climatológicos. El estadístico Z de Mann-Kendall muestra un patrón espacial de cambios similar a la técnica de regresión lineal, y ambas metodologías coinciden en que los cambios sólo son estadísticamente significativos al 95% de confianza en puntos muy localizados.




Figura 2-15. Campos de cambio de la precipitación anual en 1985-2018. **Fila superior (izquierda):** pendiente lineal por cuadrados mínimos. Los marcadores opacos indican significancia de la pendiente según un test T-Student al 95% de confianza. **Fila superior (derecha):** cociente de regresión lineal, definido como el porcentaje de cambio de la precipitación anual por década relativo a la precipitación anual media (1985-2018). **Fila inferior:** p-valor del estadístico de Z de Mann-Kendall. Se indica también los límites de la CRB (contorno rojo)




Figura 2-16. Campos de cambio de la precipitación semestral estival en 1984/1985-2017/2018.

Fila superior (izquierda): pendiente lineal por cuadrados mínimos. Los marcadores opacos indican significancia de la pendiente según un test T-Student al 95% de confianza. **Fila superior (derecha):** cociente de regresión lineal, definido como el porcentaje de cambio de la precipitación semestral por década relativo a la precipitación semestral media (1984/1985-2017/2018). **Fila inferior:** p-valor del estadístico de Z de Mann-Kendall. Se indica también los límites de la CRB.

Es de interés verificar si en el semestre lluvioso se observan cambios significativos en la precipitación, dado que es el momento del año de mayor aporte hídrico a la CRB. La Figura 2-16 muestra que la distribución espacial del signo de las tendencias es muy similar al caso anual, aunque con magnitudes más débiles en el sur de Chaco. Nuevamente, predominan las reducciones en la cantidad de precipitación acumulada, pero estos cambios son significativos al 95% de confianza en zonas muy localizadas según el test T-Student sobre la pendiente lineal, así como según el test de Mann-Kendall. En particular, las localidades que presentan tendencias negativas significativas de la

precipitación semestral, también muestran la presencia de una variabilidad de baja frecuencia con tendencia al decrecimiento, observable al aplicar un promedio móvil con una ventana de 11 años (Figura A-2-1 en Anexo). Si bien se han documentado cambios hacia condiciones más húmedas en el norte argentino a lo largo del siglo XX, algunos autores han notado una reversión en el signo de las tendencias en las últimas décadas (González et al., 2012; Barros y Camilloni, 2016; Castino et al., 2017; Lovino et al., 2022). Esta modificación en las tendencias podría deberse a patrones de variabilidad multidecadal (Barros y Camilloni, 2016; Zhang et al., 2016) y a la modificación local en el uso del suelo, con su consecuente alteración del albedo superficial y de los flujos superficiales de calor sensible y latente (Lee y Berbery, 2011).

La Figura 2-17 muestra los resultados de las técnicas de detección de tendencia aplicadas al caudal medio anual y al caudal mensual pico en año hidrológico para el período 1984/1985-2017/2018 en las estaciones de aforo de Aguas Blancas, Caimancito, Pozo Sarmiento, y El Colorado. A pesar del predominio de las tendencias negativas en la precipitación anual de la región, tanto la técnica de regresión lineal como el estadístico de Mann-Kendall acuerdan en un crecimiento del caudal medio anual en las estaciones del sector superior de la cuenca (máximo en Pozo Sarmiento, con una pendiente lineal de $+10.2 \text{ m}^3 \text{ s}^{-1} \text{ década}^{-1}$), mientras que lo opuesto es detectado en El Colorado. Sin embargo, estos aumentos son débiles al normalizarlos por el caudal medio anual climatológico: en Pozo Sarmiento, la estación con el mayor aumento absoluto, el cambio sólo implica un incremento del 2.4% por década. Una situación similar se evidencia en El Colorado, ubicado en la zona de mayores decrecimientos observados de la precipitación: si bien el caudal decrece $24.5 \text{ m}^3 \text{ s}^{-1} \text{ década}^{-1}$, este cambio representa un 5.4% de reducción comparado con el caudal medio anual climatológico. Ninguna de estas estaciones de aforo presenta cambios estadísticamente significativos según el test T-Student y el test de Mann-Kendall al 95% de confianza. En el caso del caudal mensual pico, se observa un patrón espacial de signo en el cambio muy similar al caso anual: nuevamente Pozo Sarmiento y El Colorado presentan comportamiento opuestos, pero son las estaciones de aforo con las mayores tendencias observadas a nivel absoluto ($+114.5 \text{ m}^3 \text{ s}^{-1} \text{ década}^{-1}$ y $-62.7 \text{ m}^3 \text{ s}^{-1} \text{ década}^{-1}$, respectivamente) y a nivel porcentual ($+7.6 \% \text{ década}^{-1}$ y $-5.0 \% \text{ década}^{-1}$, respectivamente). Sin embargo, en ninguno de estos casos los cambios observados son significativos bajo los tests T-Student y Mann-Kendall considerando un nivel de significancia del 5%.




Figura 2-17. Campos de tendencia en año hidrológico (1984/1985-2017/2018) en la CRB. **Izquierda:** caudal medio anual. **Derecha:** caudal mensual máximo del año hidrológico. Los triángulos negros (grises) indican un valor positivo (negativo) del estadístico Z de Mann-Kendall. Las etiquetas indican la tasa de cambio según la pendiente lineal en $\text{m}^3\text{s}^{-1}\text{década}^{-1}$. Se indica también los límites de la CRB (contorno rojo).

2.3. Clusterización mediante k-medoides

El objetivo final de este estudio es poder generar una herramienta de pronóstico probabilístico a mediano plazo de la precipitación areal mensual, es decir poder estimar con cierto nivel de incertidumbre si la precipitación mensual en un año particular se alejará de la normalidad para un área determinada de la CRB. Es por esto que uno de los interrogantes a responder es qué se entiende por *área de pronóstico*, lo cual va a repercutir en el análisis de los forzantes de la variable y en el desarrollo de la herramienta de pronóstico.

Una de las posibilidades es desarrollar un conjunto de modelos de pronóstico areal de la precipitación considerando las subcuencas ya definidas, es decir, promediando

arealmente los valores acumulados de las estaciones contenidas en BS, en SF, y en BMI respectivamente. Sin embargo, ya notamos que existe una diferencia de área sustancial entre las subcuencas del sector superior y el BMI, lo cual podría dificultar el análisis de las áreas de influencia de los forzantes de gran escala. Además, como se destacó previamente en los ciclos medios anuales de la precipitación a lo largo de la extensión de la CRB (Figura 2-7), existen ciertas estaciones ubicadas en el tramo medio de la cuenca que pertenecen formalmente al BMI pero que presentan un régimen de único máximo más similar a lo esperando para el extremo noroeste argentino.

Con la motivación de encontrar el mejor agrupamiento posible de estaciones pluviométricas en función de su variabilidad climática se aplicó la metodología de *k-medoides* (Reynolds et al., 2006) sobre las series de precipitación del semestre estival en el período 1984/1985-2019/2020 (36 temporadas estivales). *K-medoides* es una variante más robusta de *k-means* (MacQueen, 1967). Ambas son metodologías de agrupamiento no jerárquico y no supervisado en las cuales una serie de objetos es separada en *k* conjuntos o clusters, procurando que los objetos dentro de cada cluster sean relativamente similares y que los objetos pertenecientes a distintos clusters sean lo más diferentes posibles entre sí. En particular, *k-means* opera separando a los objetos en *k* grupos iniciales (por ejemplo, de manera aleatoria) y, en función de alguna medida de similitud como la distancia Euclídea, mide la distancia de cada objeto al centroide del cluster (media de todos los objetos que lo componen) y reasigna cada objeto al cluster cuyo centroide se encuentre más cercano. Esto se repite de manera iterativa de forma que, paso a paso, se reduce la varianza intra-cluster hasta alcanzar un óptimo local. En el caso de *k-medoides*, el centroide del cluster no es la media de los objetos del cluster, sino que el mismo está representado por el elemento presente en el cluster cuya distancia a los demás objetos es mínima (medoide). El algoritmo que se utiliza para la aplicación de *k-medoides* es conocido como Partitioning Around Medoids (PAM).

Para la clusterización de la región, se obtuvieron las anomalías estandarizadas de la precipitación en el semestre estival para cada una de las 45 estaciones pluviométricas seleccionadas (Figura 2-13b). Estas anomalías fueron calculadas sustrayendo la media climatológica y normalizando por el desvío de la precipitación estival en 1984/1985-2019/2020. Sobre las series temporales obtenidas se buscó la cantidad óptima de clusters a través del algoritmo PAM, empleando como métricas de optimización a la Suma Total de Cuadrados Intra-Cluster y al Ancho Promedio de Silueta. En el primer caso, minimizar

la Suma Total de Cuadrados Intra-Cluster implica que los objetos que pertenecen a un mismo cluster son similares entre sí en términos de la distancia Euclídea, disminuyendo así la varianza intra-cluster. El Ancho Promedio de Silueta cuantifica en promedio para todos los elementos a clusterizar cuál es la diferencia entre la distancia máxima de un objeto a un cluster vecino en relación a la distancia del objeto a los demás individuos del cluster al que fue asignado (Reynolds et al., 2006). En consecuencia, la cantidad ideal de clusters es aquella que minimiza la Suma Total de Cuadrados Intra-Cluster (o en su defecto, que no mejora el valor de esta métrica al aumentar la cantidad de agrupamientos) y que maximiza el Ancho de Silueta. En la Figura 2-18 se muestran ambas métricas para una variedad de valores k , donde se puede notar que la cantidad óptima de clusters para las anomalías estandarizadas de precipitación estival corresponde a $k = 2$. Esta cantidad genera un quiebre en la curva de la Suma Total de Cuadrados Intra-Cluster (Figura 2-18a) y un máximo local en el Ancho Promedio de Silueta (Figura 2-18b). Al considerar las anomalías estandarizadas de primavera (octubre-noviembre-diciembre, OND) y verano (enero-febrero-marzo, EFM) se obtuvo la misma cantidad óptima de agrupamientos (Figura A-2-2 en Anexo).




Figura 2-18. a) Suma Total de Cuadrados Intra-Cluster y **b)** Ancho Promedio de Silueta para distintos valores de cantidad de clusters k de las anomalías estandarizadas de precipitación estival en el norte argentino.

Considerando un total de dos clusters, a partir de k -medoides se encontró el agrupamiento mostrado en la Figura 2-19a. La metodología separó eficientemente las estaciones

ubicadas en el sector noroeste del dominio de aquellas localizadas en el sector sudeste. Sin embargo, en la zona de transición entre ambos clusters existe algo de heterogeneidad espacial en la asignación a cada cluster. En particular, las estaciones Comandancia Frías (1), Nueva Pompeya (2), y Santiago del Estero (3) fueron asignadas al cluster 2, aunque se encuentran espacialmente cercanas a estaciones del cluster 1. Considerando que la motivación para regionalizar el sector de estudio es generar un pronóstico a nivel areal de la precipitación, no sería conveniente tener una zona acotada espacialmente donde se combinen estaciones de distintos clusters. por lo cual se decidió reasignar estas tres estaciones al cluster 1. Esta corrección genera una separación clara entre ambas áreas, de forma que el cluster 1 nuclea a las estaciones del centro-oeste del norte argentino (incluyendo a las estaciones del BS+SF y algunas del tramo superior del BMI), mientras que el cluster 2 concentra a las estaciones del sector este del norte argentino entre las que se incluyen los puntos de medición en el extremo oriental del BMI pertenecientes al Chaco húmedo (Figura 2-19b).




Figura 2-19. a) Clusterización mediante *k-medoides* de las anomalías de precipitación estandarizadas en el semestre estival. **b)** Clusterización final luego de re-asignar las estaciones 1, 2, y 3 al cluster 1.

2.4. Síntesis

En este capítulo se realizó una descripción geográfica e hidroclimatológica de la región de la CRB, ubicada en el norte argentino. En particular, se creó una base de datos de precipitación a partir de observaciones tomadas in situ a nivel mensual en el período 1984-2020. Además, se regionalizó al área de estudio en dos zonas climáticamente homogéneas mediante la metodología de k -medoides: el cluster 1, correspondiente al sector centro-oeste del sector de análisis, y el cluster 2 en el extremo este. En la CRB se destaca un régimen pluvial con máximos acumulados en la estación cálida austral y máximos anuales en el caudal hacia los meses de febrero y marzo, lo cual motivó a definir como semestre objetivo de los modelos de pronóstico de precipitación al período comprendido entre octubre y marzo.

Entre el tramo superior y el tramo inferior de la CRB se exhibe un desfase del caudal diario del orden de una semana. Adicionalmente, se encontró que el caudal medio mensual y el caudal diario máximo en el extremo este de la CRB responden principalmente a la evolución de la precipitación en el sector superior de la cuenca, resaltando la relevancia de desarrollar un pronóstico de precipitación a mediano plazo en este sector. Finalmente, se evaluaron las tendencias a largo plazo de la precipitación y del caudal. Si bien se encontraron predominantemente tendencias al decrecimiento de la precipitación anual y semestral, los cambios no resultaron estadísticamente significativos en la mayor parte de las estaciones de la región.

Capítulo 3

Hacia la generación de esquemas de predicción: factores de influencia de la precipitación

En este capítulo se exploran los potenciales forzantes de la precipitación en el semestre estival, algunos de los cuales resultarán ser predictores de la precipitación mensual en la CRB. A continuación, se presentan los indicadores seleccionados para representar distintas fuentes de variabilidad, y su asociación con la precipitación dentro del período de estudio. Luego, se estudia la posibilidad de diseñar indicadores específicos para la generación de los esquemas de predicción de cada cluster de la CRB. Finalmente, se presentan los esquemas conceptuales de influencia remota y regional sobre la precipitación, y se especifican los predictores a considerar en los modelos estadísticos.

3.1. Búsqueda de predictores

Para la construcción de esquemas de predicción empírica a mediano plazo de una determinada variable es necesario estudiar previamente cuáles son los indicadores que se considerarán predictores de la evolución futura de dicha variable. En este estudio, la variable objetivo de pronóstico es la precipitación acumulada mensual en la CRB para los meses que componen al semestre estival. Por otro lado, un predictor es una variable en sí misma, cuya evolución tiene un impacto cuantificable sobre la variable que se desea pronosticar. El conocimiento del estado de cada predictor de interés en un caso particular es, por lo tanto, relevante para evaluar si en dicha situación existe una mayor probabilidad de que la variable objetivo se aleje de su valor medio climatológico.

La búsqueda de predictores adecuados y suficientes para representar a la variable objetivo es una tarea esencial en el modelado empírico, donde la eficiencia de los esquemas

estadísticos de predicción se ve limitada por los predictores empleados, además de depender de la técnica de modelado seleccionada y de la predictibilidad del sistema climático en la escala temporal de interés (Mason y Baddour, 2008; González et al., 2023). En particular, una de las fuentes de predictibilidad más reconocidas dentro de la predicción subestacional y estacional se relaciona con patrones o modos de variabilidad que reflejan la interacción y retroalimentación entre variables de sistemas acoplados. Estos modos de variabilidad reflejan mecanismos dinámicos típicamente oscilantes originados a partir de una anomalía en la interacción superficie (océano/suelo)-atmósfera, que pueden a su vez actuar sobre características del sistema climático a distancias geográficamente extensas respecto a la ubicación de la perturbación original. Este tipo de interacción se denomina *teleconexión*, y refleja cómo la predictibilidad de dos locaciones que se encuentran alejadas entre sí puede verse vinculada (National Research Council, 2010). Entre los patrones climáticos más destacados para el pronóstico a mediano plazo se encuentra la variabilidad de la temperatura superficial del mar (SST) en el Pacífico ecuatorial representada por El Niño-Oscilación del Sur (ENSO). Este modo de variabilidad es ampliamente considerado como forzante de relevancia en la previsión estacional de variables atmosféricas a nivel global. Particularmente, Osman y Vera (2017) verificaron mediante el uso de modelos acoplados de circulación global que la predictibilidad estacional de la precipitación se ve incrementada en años no neutros de ENSO para las latitudes extratropicales de Sudamérica, especialmente en el trimestre diciembre-enero-febrero en el sector sur del sudeste de Sudamérica y los Andes extratropicales, y en el trimestre junio-julio-agosto para los Andes al sur de 40°S.

A pesar de la relevancia del patrón de variabilidad de la SST del Pacífico ecuatorial en términos de predictibilidad, otros modos oscilantes han sido considerados con la intención de realizar un pronóstico estadístico a mediano plazo de variables hidrológicas y atmosféricas. Como ejemplo, Gissila et al. (2004) añadieron predictores basados en la SST del océano Índico tropical a los predictores vinculados al ENSO para la predicción de lluvias en el verano etíope; Lamb et al. (2011) consideraron indicadores basados en patrones de SST del océano Pacífico, así como indicadores asociados a modos de variabilidad oceánicos y atmosféricos en la región del Atlántico norte con el objetivo de pronosticar el caudal en la cuenca del Río Colorado en Estados Unidos. Paralelamente, otras fuentes de predictibilidad en el sistema climático se vinculan al almacenamiento de calor y humedad en el océano y en el suelo, así como al acople de los océanos y la

atmósfera con componentes de la criósfera (National Research Council, 2010). Estos forzantes generan respuestas en el sistema climático en distintas escalas temporales, y reflejan la importancia de considerar indicadores relacionados con la circulación regional. En este sentido, Leyba et al. (2023) emplearon un modelo bidimensional semi-lagrangiano para estimar el transporte de vapor estacional en el continente sudamericano y en el océano Atlántico adyacente, de forma de poder evaluar los aportes de humedad a la precipitación en Sudamérica. En este trabajo, los autores resaltan la importancia del reciclado local de vapor y del aporte de humedad desde la región del Amazonas para las precipitaciones que se desarrollan en el verano austral en la Cuenca del Plata. En Argentina, Garbarini et al. (2019) y Garbarini et al. (2021) definieron distintos índices asociados a la variabilidad en la posición e intensidad de los anticiclones semipermanentes del Atlántico y Pacífico sur. Dichos indicadores aportan cierto nivel de predictibilidad para la previsión estacional de la precipitación, particularmente de primavera, en algunas regiones del territorio argentino. Oliveri y González (2020) hallaron que la SST del invierno austral en el borde oeste de la cuenca del océano Atlántico sur podría ser empleada como variable predictora de la temperatura media de primavera en el centro y norte de Argentina. A su vez, Collazo et al. (2022) emplearon una variedad de predictores vinculados a patrones de circulación regional y condiciones de humedad del suelo para sus esquemas de predicción estadística de la frecuencia estacional de temperaturas extremas diarias en el centro-norte de Argentina. Por otro lado, a escala local Ayala et al. (2021) elaboraron esquemas de predicción determinísticos de la precipitación acumulada en el trimestre septiembre-octubre-noviembre para la subcuenca BS del CRB mediante la técnica de regresión lineal múltiple. Los modelos hallados emplearon predictores vinculados a la dinámica del ENSO, así como indicadores definidos a partir de la circulación regional en Sudamérica en niveles bajos de la atmósfera.

La bibliografía existente sobre el modelado empírico de variables del sistema climático resalta que, incluso en un análisis de escala regional, no necesariamente un forzante o potencial predictor genera una influencia espacialmente homogénea sobre la variable objetivo (Sharda et al., 2012; Shi et al., 2017; Collazo et al., 2019; entre otros). De igual forma, la incidencia que un forzante pueda tener sobre la variable no necesariamente es constante a lo largo del tiempo, sino que puede presentar períodos de diferente intensidad, o incluso períodos en los cuales no se observa un impacto cuantificable sobre la región

de estudio (Grimm y Saboia, 2015; Garbarini et al., 2019; Cai et al., 2020). Esto complejiza la búsqueda de mecanismos explicativos de la variabilidad interanual de la precipitación, y abre la posibilidad de explorar distintos forzantes para ambos clusters de la CRB y para distintos subperiodos dentro del semestre estival.

3.1.1. Definición de indicadores generales

En primera instancia, se abordaron forzantes caracterizados a través de indicadores denominados *generales*. Estos indicadores son índices preestablecidos que representan la variabilidad de un mecanismo físico de acción que potencialmente podría tener repercusiones en la precipitación estival. En principio, se analizó la asociación simultánea entre estos indicadores y la precipitación estacional a nivel regional en el norte argentino, para posteriormente evaluar su potencialidad como predictores de la precipitación mensual areal. Es importante destacar que en la búsqueda de forzantes se incluyen las estaciones dentro de los límites geográficos de la CRB, así como estaciones adyacentes que fueron asignadas a un cluster determinado (Figura 2-19b) con el fin de aumentar la coherencia espacial de los forzantes, que podrían tener una señal en un área que exceda a la CRB.

Los indicadores generales empleados en este estudio se detallan en cuanto a su definición y construcción en la Tabla 3-1. Los mismos fueron obtenidos en la página web de la National Oceanic and Atmospheric Administration (NOAA) (<https://psl.noaa.gov/>), o derivados a partir de datos en puntos de retícula del European Centre for Medium-Range Weather Forecasts (ECMWF) Reanalysis v5 (ERA5, con resolución horizontal de 2.5°; Hersbach et al., 2023) y del Extended Reconstructed Sea Surface Temperature v5 (ERSSTv5, con resolución horizontal de 2°; Huang et al., 2017). Los indicadores generales representan a modos de variabilidad asociados a la temperatura superficial del mar y la circulación hemisférica y regional, así como al comportamiento de la convección en Sudamérica tropical. Para el propósito de este estudio, los indicadores están representados por series temporales mensuales. A continuación, se describe el origen de los indicadores generales seleccionados.

Indicador general	Descripción	Fuente
PDO	Indicador de la Oscilación Decadal del Pacífico. Construido a partir de primera Función Ortogonal Empírica de anomalías mensuales de SST en el océano Pacífico al norte de 20°N.	Obtenido de https://psl.noaa.gov/pdo/
EN3.4	Indicador de ENSO en la región central del Pacífico tropical. Construido a partir de anomalías mensuales de SST promediadas arealmente en la región Niño 3.4 [170° O-120°O; 5°N-5°S].	Obtenido de https://psl.noaa.gov/data/correlation/nina34.anom.data
DOI	Indicador del Dipolo del Océano Índico. Construido a partir de la diferencia de anomalías mensuales de SST entre el Índico tropical occidental [50°E-70°E; 10°N-10°S] y el Índico tropical sudeste [90°E-110°E; 0°-10°S].	Derivado de base de SST de ERSSTv5
IOBW	Indicador del Modo Generalizado del Océano Índico. Construido a partir de las anomalías mensuales de SST promediadas arealmente en el Índico tropical [40°E-100°E; 20°N-20°S].	Derivado de base de SST de ERSSTv5

Indicador general	Descripción	Fuente
SAM	Indicador del Modo Anular del Sur. Construido como la diferencia entre el promedio zonal de presión al nivel del mar en 40°S y en 60°S, habiendo estandarizado previamente cada promedio zonal utilizando la media y el desvío estándar correspondiente.	Derivado de datos de presión al nivel del mar de reanálisis ERA5
AAINT	Indicador de la intensidad del Anticiclón del Atlántico Sur. Definido como la máxima altura geopotencial en 1000 hPa en [40°O-10°E; 0°-40°S].	Derivado de datos de altura geopotencial en 1000 hPa de reanálisis ERA5
AALAT	Indicador de la posición latitudinal del Anticiclón del Atlántico Sur. Definido como la latitud a la que se posiciona la máxima altura geopotencial en 1000 hPa en [40°O-10°E; 0°-40°S].	Derivado de datos de altura geopotencial en 1000 hPa de reanálisis ERA5
AALON	Indicador de la posición longitudinal del Anticiclón del Atlántico Sur. Definido como la longitud a la que se posiciona la máxima altura geopotencial en 1000 hPa en [40°O-10°E; 0°-40°S].	Derivado de datos de altura geopotencial en 1000 hPa de reanálisis ERA5
APINT	Indicador de la intensidad del Anticiclón del Pacífico Sur. Definido como la máxima altura geopotencial en 1000 hPa en [150°O-75°O; 0°-50°S].	Derivado de datos de altura geopotencial en 1000 hPa de reanálisis ERA5

Indicador general	Descripción	Fuente
APLAT	Indicador de la posición latitudinal del Anticiclón del Pacífico Sur. Definido como la latitud a la que se posiciona la máxima altura geopotencial en 1000 hPa en [150°O-75°O; 0°-50°S].	Derivado de datos de altura geopotencial en 1000 hPa de reanálisis ERA5
APLON	Indicador de la posición longitudinal del Anticiclón del Pacífico Sur. Definido como la longitud a la que se posiciona la máxima altura geopotencial en 1000 hPa en [150°O-75°O; 0°-50°S].	Derivado de datos de altura geopotencial en 1000 hPa de reanálisis ERA5
OLRN	Indicador de la convección en Sudamérica tropical. Construido como promedio areal de la OLR en [75°O-45°O; 0°-12°S], excluyendo sección al oeste de 60°O y al norte de 5°S.	Derivado de datos de OLR de reanálisis ERA5
OLRC	Indicador de la convección en Sudamérica tropical. Construido como promedio areal de la OLR en [60°O-50°O; 12°S-18°S]	Derivado de datos de OLR de reanálisis ERA5
OLRSE	Indicador de la convección en Sudamérica tropical. Construido como promedio areal de la OLR en [50°O-35°O; 15°S-28°S]	Derivado de datos de OLR de reanálisis ERA5

Indicador general	Descripción	Fuente
posOLRSE	Indicador de la convección en Sudamérica tropical. Definido como la posición latitudinal del mínimo OLR sobre la costa oriental de Sudamérica en la caja correspondiente al indicador OLRSE	Derivado de datos de OLR de reanálisis ERA5

Tabla 3-1. Listado de los indicadores generales empleados. Se detalla el nombre del indicador, descripción de su construcción, y fuente del indicador y/o de los datos utilizados para su construcción.

3.1.1.1. Indicadores de temperatura superficial del mar y de circulación hemisférica

Como se mencionó anteriormente, existen patrones climáticos que reflejan la dinámica de acople entre las superficies oceánicas y la atmósfera. Entre ellos, el ENSO es uno de los mecanismos más estudiados por la intensidad de su señal interanual y sus impactos a escala global (Davey et al., 2014). Asimismo, en los últimos años se desarrolló un gran progreso en términos de la predictibilidad estacional de este fenómeno, pudiéndose actualmente encontrar predicciones eficientes de las fases del ENSO con hasta 12 meses de antelación, lo cual redundo en beneficios para las actividades de mitigación y adaptación en relación a eventos climáticos propiciados por el ENSO (Tang et al., 2018).

El ENSO es un modo de variabilidad con una cuasi-periodicidad de entre 2 y 7 años, caracterizado por la presencia de una fase cálida (El Niño) y una fase fría (La Niña) vinculadas a anomalías de SST y de presión al nivel del mar en el océano Pacífico ecuatorial. La influencia del ENSO sobre Sudamérica típicamente se explica a través de mecanismos directos y remotos (Cai et al., 2020). En el primer caso existe un forzamiento local en la costa occidental de Sudamérica tropical, mediante el cual las aguas anómalamente cálidas en el océano adyacente incrementan la transferencia de energía hacia la atmósfera durante eventos El Niño, activando la convección atmosférica profunda y abundantes precipitaciones en las costas de Perú y Ecuador, principalmente entre febrero y abril. Asimismo, este calentamiento anómalo durante la fase cálida

también se vincula a un debilitamiento en el transporte de humedad hacia Colombia, favoreciendo condiciones más secas en esa región (Poveda y Mesa, 1999). Por otro lado, los impactos remotos del ENSO se reflejan tanto en latitudes tropicales como extratropicales. Las anomalías de SST activadas durante el ENSO generan cambios en la circulación zonal de la celda de Walker y derivan en la modificación de las zonas típicas de ascenso y subsidencia atmosférica de latitudes bajas. En consecuencia, durante la fase El Niño se promueven movimientos de descenso anómalo sobre Sudamérica ecuatorial oriental y el sector occidental del Atlántico ecuatorial, principalmente entre septiembre y febrero. Paralelamente, la convección anómala generada por las anomalías de SST en el Pacífico tropical induce la generación de ondas de Rossby estacionarias, representadas mediante anomalías de presión alternantes en distintos niveles verticales de la atmósfera. Estas ondas se extienden hacia latitudes medias y hacia el este, para luego virar hacia la cuenca Atlántica. En el hemisferio sur, el patrón dado por estas ondas de Rossby se denomina patrón Pacífico-Sudamérica (PSA) (Mo, 2000). Este comportamiento es más pronunciado durante septiembre-octubre-noviembre debido a la intensidad de las anomalías vinculadas al ENSO y al gradiente meridional de temperatura ecuador-polo. En particular, este patrón refuerza la advección de aire cálido y húmedo hacia el sudeste sudamericano y puede promover en consecuencia precipitaciones abundantes en el norte de Argentina, sur de Brasil, y Uruguay (Zhou y Lau, 2001; Grimm 2003; Ropelewski y Bell, 2008; entre otros). La fase La Niña es opuesta a la fase cálida en líneas generales, aunque presenta ciertas asimetrías en términos de distribución espacial de las anomalías e intensidad respecto a los eventos El Niño. De manera análoga, los eventos de fase cálida presentan cierto grado de diversidad en cuanto al posicionamiento de las anomalías máximas, su evolución temporal y las áreas de impacto (Ashok et al., 2007; Tedeschi et al., 2014; Capotondi y Sardeshmukh, 2015; Capotondi et al., 2015).

Actualmente, existen diversos índices que intentan representar la variabilidad en la evolución del ENSO. Algunos de estos índices se basan en el comportamiento de la SST, así como también se emplea la salinidad superficial y la temperatura oceánica subsuperficial en distintas regiones del océano Pacífico ecuatorial (Capotondi et al., 2015). Sin embargo, como se trata de un patrón acoplado océano-atmósfera, también existen índices que incorporan la componente atmosférica a través de la presión al nivel mar (por ejemplo, el *Índice de Oscilación del Sur*) o en combinación multivariada con la SST, el flujo de radiación de onda larga saliente (OLR), y el viento en superficie (por

ejemplo, el *Índice Multivariado del ENSO*). En particular para el presente estudio, se decidió representar al ENSO mediante el índice **EN3.4**, basado en las anomalías de SST en la región Niño 3.4 ubicada en el Pacífico ecuatorial central (Tabla 3-1). Valores positivos (negativos) del indicador implican anomalías positivas (negativas) de SST, típicamente observables en eventos El Niño (La Niña).

Otro modo de variabilidad originado en el océano Pacífico es la Oscilación Decadal del Pacífico (PDO). Este patrón climático fue descrito por Mantua et al. (1997) como el primer modo de variabilidad obtenido al aplicar la metodología de Funciones Ortogonales Empíricas a las anomalías mensuales de SST en el océano Pacífico norte (20°N-70°N) durante el siglo XX. En forma similar al ENSO, la PDO induce anomalías de SST, presión al nivel del mar, y viento, pero, a diferencia del ENSO, la estructura espacial de las anomalías de SST asociadas no se encuentra confinada a latitudes bajas, sino que se extiende hacia latitudes extratropicales del Pacífico. Además, la PDO destaca como un modo de variabilidad interdecádica (Mantua et al., 1997; Zhang et al., 1998). La PDO presenta una fase positiva vinculada a aguas anómalamente cálidas en la costa occidental de América del norte y en el centro-este del Pacífico tropical mientras que anomalías negativas de SST se desarrollan en el oeste y centro de la cuenca del Pacífico norte; durante la fase negativa estas características se revierten (Andreoli y Kayano, 2005).

Debido a la diferencia en la frecuencia típica de acción de la PDO y del ENSO, diversos estudios se han enfocado en evaluar cómo la primera podría modular las variaciones de las anomalías asociadas al ENSO. En principio, estos forzantes podrían actuar constructivamente, es decir induciendo en el sistema océano-atmósfera un patrón de anomalías intensas y bien definidas, o destructivamente propiciando anomalías dispersas y débiles. En particular para Sudamérica, Andreoli y Kayano (2005) analizaron durante un período de 50 años las composiciones de patrones de circulación, movimientos verticales, y precipitación mensual de eventos El Niño en combinación con eventos no neutros de la PDO. En este trabajo hallaron que la señal de la fase cálida del ENSO deja una señal más clara sobre el continente cuando se sucede en conjunto con una fase positiva de la PDO, con anomalías positivas de precipitación en el sudeste de Sudamérica particularmente marcadas durante la primavera, y anomalías negativas en el norte del continente destacables especialmente en el verano siguiente a la fase cálida del ENSO. Da Silva et al. (2011) encontraron resultados similares al analizar el trimestre diciembre-enero-febrero y encontraron que los trenes de onda originados en el Pacífico son más

intensos cuando ambos modos actúan constructivamente, propiciando la intensificación de la convergencia del flujo de humedad en el sudeste de Sudamérica. Más recientemente, Newman et al. (2016) advirtieron que la PDO no es un fenómeno individual sino una combinación de procesos físicos de origen tropical y extratropical que incluyen cambios en los flujos de calor superficiales y en el transporte de Ekman asociado a la variabilidad de la baja de las Aleutianas en escala sinóptica a decadal, la inercia térmica del océano, y cambios del orden decadal en el sistema de corrientes Kuroshio-Oyashio. Por lo tanto, la atribución de una respuesta remota a la influencia de la PDO debe ser analizada con cuidado, pues tanto la respuesta como la PDO pueden estar siendo forzadas a su vez por un proceso común, como por el ejemplo el ENSO. En particular para el presente estudio, la PDO fue considerada como indicador general y representada mediante el índice homónimo **PDO**, basado en la primera EOF de las anomalías de SST en el Pacífico norte, siguiendo la definición de Mantua et al. (1997) (Tabla 3-1). Valores positivos (negativos) del indicador implican anomalías positivas (negativas) de SST en el Pacífico norte oriental y anomalías negativas (positivas) de SST en el sector centro-oeste del Pacífico norte.

El océano Índico tropical también es fuente de procesos acoplados océano-atmósfera que generan un impacto remoto relevante en Sudamérica. Los dos patrones climáticos predominantes, en orden decreciente de varianza explicada, corresponden a una señal uniforme en la extensión de la cuenca oceánica, y a una señal con estructura dipolar (Chambers et al., 1999; Saji et al., 1999). Estos patrones son conocidos en la bibliografía como Comportamiento Generalizado de la Cuenca del Índico (IOBW por sus siglas en inglés) y el Dipolo del Océano Índico (DOI).

El IOBW es el patrón climático dominante en la región del Índico, y explica cerca de un 25% de la variabilidad de la SST mensual del Índico tropical (Taschetto y Ambrizzi, 2012). Este modo se caracteriza por fases de calentamiento (enfriamiento) generalizado de la SST en la región, y cuenta con una periodicidad de aproximadamente 4 años. Tiene un vínculo dinámico con el ENSO, pues cuando la fase El Niño se encuentra madura hacia noviembre-diciembre se observa paralelamente una rama subsidente sobre el Índico oriental. Este movimiento vertical es inducido por las anomalías en la celda de circulación de Walker, inhibiendo en consecuencia la formación de nubosidad e incrementando el flujo neto de calor hacia el océano. Este cambio en el transporte vertical de energía favorece el calentamiento rápido del Índico oriental que, en combinación con una

anomalía anticiclónica en niveles bajos, favorece la formación de ondas de Rossby en el océano que se propagan hacia el oeste y provocan el calentamiento uniforme de la cuenca. A raíz de este mecanismo, el IOBW presenta su máxima actividad luego de la madurez de El Niño, pudiendo mantener las condiciones anómalamente cálidas hasta el siguiente invierno austral (Schott et al., 2009). Taschetto y Ambrizzi (2012) realizaron experimentos numéricos para evaluar la conexión entre la variabilidad del IOBW y las condiciones climáticas en Sudamérica. En este trabajo encontraron que un evento de IOBW derivado de una fase El Niño puede reforzar la circulación generada por el mismo a través de la generación de un tren de ondas de latitudes medias, favoreciendo los acumulados de precipitación en la Cuenca del Plata entre marzo y mayo. Asimismo, el IOBW puede favorecer condiciones más secas en el noreste de Sudamérica durante el otoño austral a través de las anomalías que se generan en la celda de circulación de Walker por la presencia de aguas cálidas en el Índico. En particular para el presente estudio, el IOBW fue considerado como indicador general y fue representado mediante el índice homónimo **IOBW**, basado en las anomalías de SST promediadas arealmente en el Índico tropical (Tabla 3-1). Valores positivos (negativos) del indicador implican anomalías positivas (negativas) de SST en la cuenca del Índico tropical.

El segundo modo dominante de variabilidad corresponde al DOI. Éste explica cerca de un 12% de varianza de la SST en la cuenca del océano Índico, y puede ser representado mediante la diferencia en las anomalías de SST entre los sectores occidental y suroriental del Índico tropical (Saji et al., 1999), con la fase positiva caracterizada por un calentamiento (enfriamiento) anómalo del sector occidental (suroriental). Saji et al. (2005) encontraron que el DOI alcanza su máxima actividad entre septiembre y noviembre. Si bien este modo de variabilidad tiende a ocurrir simultáneamente en combinación con el ENSO, existe evidencia observacional y derivada de modelos que sugiere que el DOI es un modo de variabilidad que puede surgir como consecuencia de la evolución del ENSO, o también puede autogenerarse a partir de variaciones en la profundidad de la termoclina oceánica en el noreste de la cuenca del Índico (Schott et al., 2009).

Saji et al. (2005) encontraron que las latitudes subtropicales pueden ser impactadas de manera remota por el DOI a través de la propagación de ondas de Rossby estacionarias. En particular, Chan et al. (2008) evaluaron las anomalías de precipitación observadas en Sudamérica entre septiembre y noviembre bajo eventos no neutros de DOI. Este forzante

se manifiesta como un dipolo de precipitación, con incrementos en los valores acumulados en latitudes subtropicales de la Cuenca del Plata y menores precipitaciones en el centro de Brasil. Este patrón obedece a una anomalía anticiclónica en niveles bajos adyacente a la costa de Brasil, que refuerza los alisios y fortalece el flujo de aire cálido hacia el sur, a través de la corriente en chorro de capas bajas (LLJ, por sus siglas en inglés) ubicada al este de los Andes, incrementando a su vez el transporte de humedad y las precipitaciones en Uruguay y el norte de Argentina. En particular para el presente estudio, el DOI fue considerado como indicador general y fue representado mediante el índice homónimo **DOI**, basado en la diferencia de anomalías de SST entre los polos de acción, definidos según Saji et al. (1999) (Tabla 3-1). Valores positivos (negativos) del indicador implican anomalías positivas (negativas) de SST en el sector occidental y negativas (positivas) en el sector suroriental.

El modo de variabilidad dominante en latitudes extratropicales del hemisferio sur es el Modo Anular del Sur (SAM) (Thompson y Wallace, 2000). Este patrón climático se caracteriza por una estructura zonalmente simétrica de anomalías de presión o altura geopotencial entre las latitudes medias del hemisferio sur y las latitudes altas, considerándose que la fase positiva (negativa) del SAM se desarrolla cuando se observan anomalías positivas (negativas) de presión en latitudes medias y negativas (positivas) en latitudes altas. Esta variación en el gradiente meridional de presión se vincula con un desplazamiento meridional de la corriente en chorro subpolar de niveles altos. Dado que esta corriente está ligada a la presencia de baroclinicidad, necesaria para el desarrollo de sistemas transientes extratropicales, el SAM está asociado a corrimientos en la dirección norte-sur de los *storm tracks*. En frecuencias relativamente bajas (un mes a un trimestre aproximadamente) las variaciones del SAM pueden ser promovidas por variaciones en la SST tropical, como por ejemplo el ENSO. Esto se debe a que el ENSO puede inducir cambios en la intensidad y extensión latitudinal de la celda de Hadley, afectando a la corriente en chorro subtropical y alterando la distribución latitudinal de la baroclinicidad. Esto favorece que el SAM adquiera una fase negativa durante eventos El Niño. Esta interacción es más proclive a suceder en el verano austral, cuando se combinan la madurez de las anomalías de SST del ENSO, una mayor simetría zonal en la circulación del hemisferio sur, y los jets subtropical y subpolar se “acoplan” (Gong et al., 2010; Lim et al., 2013). Fogt et al. (2011) acuerdan con la vinculación entre el ENSO y el SAM durante

el verano, y agregan que la combinación de fase positiva del ENSO y negativa del SAM (y viceversa) tienden a interactuar colaborativamente.

Silvestri y Vera (2003) hallaron que la señal del SAM sobre la precipitación en el sudeste de Sudamérica es particularmente intensa en invierno y el final de la primavera austral, aunque con signos opuestos. En particular, bajo una fase positiva del SAM en primavera se encontró que la presencia de una anomalía anticiclónica en niveles altos debilita la convergencia de humedad y disminuye los acumulados de precipitación sobre el sudeste de Sudamérica. Reboita et al. (2009) agrega que durante la fase negativa del SAM las trayectorias de los ciclones extratropicales se desplazan más hacia el norte respecto a la fase positiva, dejando anomalías positivas de precipitación en el sur de Sudamérica en el otoño, y en el sur de Brasil y norte de Argentina en el verano. Más recientemente, Iacovone et al. (2024) correlacionaron significativamente y en forma indirecta (directa) al SAM con la precipitación acumulada entre octubre y diciembre en la región del sudeste de Sudamérica (norte de Sudamérica), y vincularon esta asociación a la fortaleza de la señal en el mes de noviembre. En particular para el presente estudio, el SAM fue considerado como indicador general y fue representado mediante el índice homónimo **SAM**, basado en el gradiente meridional de presión al nivel del mar en latitudes extratropicales (Tabla 3-1). Valores positivos (negativos) del indicador implican una intensificación (debilitamiento) de los sistemas de latitudes altas y medias.

3.1.1.2. Indicadores de circulación regional

Dentro de las fuentes de variabilidad climática vinculadas a la circulación regional se encuentran los anticiclones semipermanentes del Atlántico sur (AA) y del Pacífico sur (AP) en niveles bajos, caracterizados por su persistencia a lo largo del año, contrariamente a lo que se observa en los anticiclones migratorios (Reboita et al., 2019). Los anticiclones semipermanentes se localizan en latitudes subtropicales y se destacan por la presencia de subsidencia y alta presión en niveles bajos, así como movimientos horizontales mayormente divergentes (He et al., 2017). Si bien se conoce su ubicación promedio sobre la cuenca sur de los océanos Atlántico y Pacífico, existe variabilidad estacional e interanual vinculado a su posición, extensión, e intensidad. En principio, los anticiclones semipermanentes se vinculan a la rama de descenso de la celda de Hadley, particularmente en el invierno cuando la circulación de la celda se intensifica. En segundo

lugar, en verano predominan las aguas cálidas y los movimientos de ascenso convectivo en el borde oeste de las cuencas oceánicas, mientras que lo opuesto sucede en el borde este. Este contraste zonal favorece que los anticiclones se desplacen desde el oeste en invierno hacia el centro y este de las cuencas en primavera y verano (Seager et al., 2003). Miyasaka y Nakamura (2010) añaden que estos contrastes también favorecen la aparición de ondas planetarias que contribuyen a la persistencia de los anticiclones mediante procesos de retroalimentación. En tercer lugar, existe evidencia de que la liberación de calor latente vinculada a los sistemas monzónicos durante el verano propicia una rama de descenso que refuerza los movimientos subsidentes en las regiones anticiclónicas adyacentes (Rodwell y Hoskins, 2001).

A partir de datos de altura geopotencial de 850 hPa en 1979-2015, Sun et al. (2017) hallaron que el AA presenta máxima intensidad y máxima extensión espacial durante dos momentos del año: en el invierno, cuando se posiciona hacia el norte y el oeste de su posición media, y en el verano, cuando se localiza hacia el sur de su posición media. A su vez, los autores encontraron que el AA se posiciona más al sur (norte) de su posición media ante casos de SAM positiva (negativa) durante el verano austral. Paralelamente, dado que la SST en latitudes tropicales puede actuar como forzante del SAM en el verano (Gong et al., 2010; Fogt et al., 2011), Sun et al. (2017) también destacaron que los eventos La Niña (El Niño) se vinculan a un AA desplazado más al sur (norte) de su posición meridional media, siendo consistente con la correlación indirecta entre el SAM y el ENSO.

La variabilidad en la posición, extensión, e intensidad del AA genera impactos en el clima sudamericano. La precipitación en el invierno austral en el sudeste brasileiro se ve inhibida por el acercamiento del AA al continente sudamericano, mientras que hacia la costa noreste los valores acumulados de precipitación se incrementan por el aumento en la intensidad de los alisios y en la convergencia de humedad, siguiendo el desplazamiento del AA hacia el norte. En cambio, en el verano el AA contribuye a incrementar el transporte de humedad desde el Atlántico hacia el continente, favoreciendo la precipitación en el sudeste brasileiro (Reboita et al., 2010). Degola (2013) observó una intensificación de los alisios a través del noreste de Brasil durante la primavera y el verano en los cuales el AA se ubica más hacia el oeste de su posición climatológica, acompañado por enfriamiento (calentamiento) de la costa noreste (sudeste) de Brasil en consonancia con la advección de temperatura por el AA. Garbarini et al. (2019) elaboraron índices de

caracterización de intensidad y posición longitudinal y latitudinal del AA. Los autores hallaron que existe cierta predictibilidad de la precipitación estacional en Argentina a través de la variabilidad del AA en el mes previo al comienzo de la estación, especialmente para la primavera; en verano, la señal de la predictibilidad disminuye notablemente.

En particular para el presente estudio, el AA fue considerado como indicador general y fue representado por los índices de intensidad (**AAINT**), de posición longitudinal (**AALON**), y de posición latitudinal (**AALAT**) (Tabla 3-1). Estos índices fueron contruidos siguiendo a Garbarini et al. (2019) y tomando como referencia al sector del océano Atlántico sur indicado en la Figura 3-1. Valores positivos (negativos) de AALAT implican un desplazamiento del AA hacia el ecuador (polo). Asimismo, valores positivos (negativos) de AALON reflejan que el AA se ubica más al este (oeste) de su posición media. Finalmente, valores positivos (negativos) de AAINTE representan una intensificación (debilitamiento) del AA.




Figura 3-1. Zonas sobre las cuales se realiza la búsqueda de la máxima altura geopotencial en 1000 hPa para definir los indicadores generales AAINTE, AALAT, y AALON (Océano Atlántico Sur) y los indicadores generales APINT, APLAT, y APLON (Océano Pacífico Sur).

De forma análoga, el AP presenta variabilidad estacional, interanual, e interdecadal en términos de su posición e intensidad. El AP es el forzante dominante del giro subtropical del océano Pacífico sur. El mismo favorece la surgencia de aguas profundas a lo largo de la costa de Perú, especialmente en invierno, gracias al transporte de Ekman hacia el centro de la cuenca favorecido por la circulación del anticiclón; este proceso es reforzado cuando el AP se intensifica (Croquette et al., 2007). En verano, la intensidad del AP aumenta y el mismo se desplaza hacia el sur y hacia el oeste de su posición media anual (Strub et al., 1998; Ancapichún y Garcés-Vargas, 2015). A escala interanual, el ENSO es una de las fuentes más preponderantes de variabilidad del AP, y se manifiesta a través de un debilitamiento (intensificación) del AP ante eventos El Niño (La Niña) (Rutllant 2004; Ancapichún y Garcés-Vargas, 2015; Garbarini et al., 2021). Por otro lado, la PDO y el SAM se identifican como fuentes de variabilidad decadal del AP, aunque Ancapichún y Garcés-Vargas (2015) identifican que la variabilidad del SAM antecede aproximadamente 6 años al AP. La fase cálida (fría) de la PDO se asocia una disminución (incremento) en la intensidad del AP (Garreaud and Battisti 1999, Pezza et al. 2007), lo cual es coherente considerando la vinculación entre la PDO y el ENSO (Da Silva et al., 2011; Newman et al., 2016). Además, Ancapichún y Garcés-Vargas (2015) hallaron que el AP se desplaza hacia el noreste (suroeste) desde su posición media ante la ocurrencia de PDO en fase cálida (fría), particularmente en febrero-marzo y septiembre-octubre.

Garbarini et al. (2021) definieron índices para describir la posición e intensidad del AP, análogos a los propuestos en Garbarini et al. (2019) para el AA. Los autores evaluaron la asociación simultánea entre estos índices y la precipitación a nivel estacional en Argentina, así como su potencial predictivo. En primavera, los autores observan una correlación negativa entre la intensidad del AP y la precipitación acumulada en gran parte del territorio, especialmente en el norte argentino y los Andes centrales. A su vez, encuentran que un desplazamiento hacia el norte (sur) favorece a la precipitación de primavera en el noroeste (noreste) del país. A diferencia de lo que ocurre en primavera, los autores encuentran que la precipitación de verano en el noreste argentino se correlaciona positivamente con la intensidad del AP. Al adelantar a los indicadores del AP un mes respecto a la precipitación, observan que el noroeste argentino pierde predictibilidad en todas las estaciones del año. Por el contrario, en el noreste argentino la intensidad (posición latitudinal) del AP sirve como predictor de la precipitación de primavera (verano) con un mes de antelación.

En particular para el presente estudio, el AP fue considerado como indicador general y fue descrito por los índices de intensidad (**APINT**), de posición longitudinal (**APLON**), y de posición latitudinal (**APLAT**) (Tabla 3-1). Estos índices fueron construidos siguiendo a Garbarini et al. (2021) y tomando como referencia al sector del océano Pacífico sur indicado en la Figura 3-1.

3.1.1.3. Indicadores de convección en Sudamérica tropical

En Sudamérica existe abundante evidencia de la existencia de un régimen monzónico denominado Sistema Monzónico Sudamericano (SAMS) (Horel et al., 1989; Zhou y Lau, 1998; Gan et al., 2004; Vera et al., 2006; Marengo et al., 2010; entre otros). El SAMS se desarrolla por la combinación de múltiples factores, como ser la evolución anual de la temperatura, la distribución continente-océanos, la presencia de la Cordillera de los Andes, y los procesos de interacción suelo-atmósfera. El SAMS se caracteriza por la presencia de sistemas de circulación distintivos en niveles altos y bajos durante el verano austral. En niveles altos (200-300 hPa), el sistema anticiclónico conocido como la Alta Boliviana se produce como respuesta dinámica al calentamiento diabático originado por la convección profunda en la región amazónica (centrada aproximadamente en 15°S-65°O). Sobre la costa del noreste brasileiro se conforma además una vaguada de niveles altos. Por otro lado, en niveles bajos de la tropósfera sobre el norte argentino, Bolivia y Paraguay, se destaca la presencia de un sistema de baja presión de origen térmico denominado Baja del Chaco. Además, se observa la presencia del LLJ al este de los Andes, favorecido por el gradiente horizontal de presión originado entre la Baja del Chaco y el AA. El LLJ tiene principalmente dirección noroeste-sudeste: el aire que ingresa al continente proveniente del AA, encuentra la barrera montañosa de Los Andes y canaliza el flujo hacia el sur, proveyendo un importante aporte de humedad desde la cuenca del Amazonas y el océano Atlántico hacia el sudeste de Sudamérica. El SAMS también se caracteriza por la presencia de la Zona de Convergencia del Atlántico Sur (SACZ), una banda de nubosidad y actividad convectiva con dirección noroeste-sudeste localizada en el sudeste de Sudamérica y extendiéndose hacia el océano Atlántico adyacente (Marengo et al., 2010; Espinoza et al., 2020). Este último patrón está presente específicamente en verano, y tiene una periodicidad menor al mes (variabilidad subestacional), con épocas de mayor y menor actividad, así como gran variabilidad en su posición. Existen trabajos

que encontraron una estructura dipolar en latitudes bajas de Sudamérica, con una intensificación de la SACZ acompañada de convección inhibida hacia el sur en latitudes subtropicales, y viceversa. Cuando se observa debilitamiento de la SACZ, se evidencia además el fortalecimiento del LLJ y un incremento en el transporte de humedad desde el Amazonas hacia latitudes subtropicales (Doyle y Barros, 2002; Silva y Berbery, 2006; Grimm y Zilli, 2009; Carvalho et al., 2011). Liebmann et al. (2004a) investigaron las anomalías de precipitación en el verano austral en la región de la SACZ y áreas adyacentes. Los autores encontraron que según la fase de un tren de ondas de Rossby originado en el océano Pacífico y dirigido hacia Sudamérica se podría inferir si la precipitación se ve favorecida corriente abajo del LLJ o en la zona de la SACZ, propiciando el dipolo de precipitación hallado en otros trabajos. Además, vincularon la frecuencia de eventos de precipitación extrema en el centro-este de Argentina, sudeste de Paraguay, norte de Uruguay y sur de Brasil con casos de LLJ intenso. Solman y Orlanski (2010) enfocaron su estudio en la variabilidad intraestacional de la precipitación entre octubre y diciembre, y encontraron un tren de ondas con estructura barotrópica equivalente muy similar al hallado por Liebmann et al. (2004a). En la Cuenca del Plata observaron anomalías positivas de precipitación en conjunto con anomalías anticiclónicas sobre el océano Atlántico subtropical y anomalías ciclónicas sobre el centro de Sudamérica, mientras que el patrón de circulación opuesto se observó en casos de SACZ intensificada. Asimismo, Solman y Orlanski (2010) identificaron una anomalía anticiclónica (ciclónica) en niveles medios sobre el sudeste del océano Pacífico como parte del tren de ondas que favorece la precipitación la Cuenca del Plata (SACZ). Dicha anomalía presenta períodos distintivos de 16, 23, y 50 días, y está fuertemente vinculada a la variabilidad intraestacional en el dipolo de la precipitación de Sudamérica. Los autores asignan posibles orígenes a este patrón de circulación intraestacional, como ser los modos PSA disparados por la convección tropical (Mo y Higgins 1998; Mo, 2000) y por la variabilidad del océano Índico (Chan et al., 2008). Paralelamente, la variabilidad intraestacional de los patrones convectivos en Sudamérica está relacionada a la Oscilación de Madden-Julian (MJO) (Madden y Julian, 1994; Kiladis y Mo, 1998; Vera et al., 2017; Grimm, 2019). Este modo de variabilidad tropical se caracteriza por la presencia de una rama convectiva generada sobre el océano Índico que se propaga hacia el este, y presenta una señal intraestacional del orden de los 30-70 días. Su impacto sobre Sudamérica obedece a los cambios en la circulación tropical debido a la propagación

zonal hacia el este de las anomalías de calentamiento diabático, así como a la generación de ondas de Rossby extratropicales que vinculan a la región con las latitudes bajas de los océanos Pacífico e Índico (Mo y Higgins, 1998). Liebmann et al. (2004a) emplearon un indicador de la convección sobre el Continente Marítimo para evaluar la incidencia de la MJO sobre el dipolo de precipitación de verano en latitudes subtropicales. En este trabajo encontraron que eventos de precipitación intensa sobre el centro-norte de Argentina tienden a ocurrir 2 días luego de la máxima convección en el Continente Marítimo, mientras que lo mismo ocurre en la SACZ 26 días más tarde. Resultados similares fueron hallados por Carvalho et al. (2004), que relacionaron un incremento en el percentil 95 de la precipitación diaria de verano en el sur (este y sudeste) de Brasil con convección favorecida (suprimida) en Indonesia y suprimida (favorecida) sobre el océano Pacífico central. Más recientemente, Álvarez et al. (2016) analizaron la probabilidad de superar el segundo tercil de precipitación acumulada semanal según distintas fases de la MJO para cada estación del año, donde el seguimiento de la MJO se realizó empleando el índice multivariado de Wheeler-Hendon. En primavera, la precipitación en la región de la SACZ se ve incrementada durante las fases 7 y 8, mientras que en verano la precipitación en la SACZ (sudeste de Sudamérica) se ve favorecida bajo las fases 8 y 1 (3 y 4). Estas fases se asocian a ramas de ascenso convectivo cuya localización coincide con los resultados hallados en trabajos previos enfocados únicamente en el verano.

Además de los sistemas de circulación ya mencionados, el desplazamiento meridional de la Zona de Convergencia Intertropical (ITCZ) también constituye uno de los factores vinculados a la evolución del SAMS. A medida que avanza la primavera austral, el movimiento de la ITCZ favorece el avance de la convección profunda en dirección noroeste-sudeste a lo largo de las latitudes bajas de Sudamérica. Esto implica que las fechas típicas de inicio del SAMS ocurren en el noroeste de la región amazónica en primer lugar a mediados de septiembre, y en el sudeste de dicha región hacia octubre (Kousky 1988; Marengo et al., 2001). González y Barros (2002) evaluaron los factores precursores de la variabilidad interanual del inicio y el final de la temporada convectiva en el Amazonas, identificados a través de la OLR. Esta variable permite identificar la presencia de convección y de convección profunda en función de que su valor sea inferior a 240 W m^{-2} y 220 W m^{-2} , respectivamente. Los autores vincularon la existencia de anomalías positivas de SST en el océano Atlántico norte tropical y el Mar Caribe durante agosto con fechas retrasadas de inicio y final del SAMS, posiblemente asociado a que el

desplazamiento de la ITCZ hacia el hemisferio sur con la declinación solar se ve demorado por existir una fuente de calor oceánica reforzada ante casos de SST anómalamente cálida. Además, la variabilidad interanual de la fecha de activación del SAMS pueden impactar en la precipitación acumulada en latitudes subtropicales de Argentina, favoreciendo las anomalías positivas (negativas) de precipitación en septiembre cuando el inicio del SAMS se ve adelantado (demorado) (González y Barros, 1998).

En particular para el presente estudio, la influencia de la convección en Sudamérica tropical fue identificada a través de cuatro indicadores construidos a partir de la OLR: **OLRN**, **OLRC**, **OLRSE**, y **posOLRSE** (Tabla 3-1). Los primeros tres indicadores están basados en el promedio areal de la OLR en las regiones de avance de la ITCZ durante la primavera y el verano australes (Figura 3-2). OLRN abarca la cuenca amazónica y representa a la zona de desplazamiento más rápido de la convección sobre Sudamérica al inicio y al final del SAMS (Kousky 1988; González y Barros, 2002). OLRC identifica al centro-oeste de Brasil, donde el inicio del monzón típicamente ocurre a fines de septiembre y que presenta un aumento importante de la precipitación hacia fines de octubre (Gan et al., 2004; González et al., 2007). OLRSE contiene a la posición media de la SACZ en la intersección con la costa de Sudamérica (Camilloni y Barros, 2000; Doyle y Barros, 2002). Al tratarse de latitudes tropicales, valores positivos (negativos) de OLRN, OLRC, y OLRSE implican que la convección en dichas áreas se ve inhibida (reforzada). Finalmente, el indicador posOLRSE representa a la latitud de mayor convección (mínimo de OLR) en la intersección con la costa sudamericana dentro del área de OLRSE; esto implica que posOLRSE pretende reflejar los movimientos meridionales de la SACZ. Valores positivos (negativos) de este indicador representan un desplazamiento hacia el norte (sur) de la máxima convección en el sudeste de Brasil.




Figura 3-2. Zonas sobre las cuales se realiza un promedio areal de la OLR para definir los indicadores generales OLRN, OLRC, OLRSE, y posOLRSE.

3.1.2. Construcción del Índice de Precipitación Estandarizado

Los indicadores generales son series temporales que representan la evolución de diversos forzantes y que pueden ser empleados para evaluar la incidencia regional de un determinado patrón climático sobre una variable de interés. En particular, como se describió anteriormente, la CRB atraviesa distintas ecorregiones en su extensión territorial y la precipitación estival presenta diferencias en cuanto a su régimen típico según la región de la cuenca que se analice (Figura 2-7). Por esta razón, para evaluar la incidencia regional de los indicadores generales se optó por considerar al Índice de Precipitación Estandarizado en cada una de las estaciones pluviométricas disponibles.

El Índice de Precipitación Estandarizado (IPE) es, como lo indica su nombre, un índice estandarizado basado en la precipitación que puede calcularse para distintas escalas temporales de interés y que es utilizado ampliamente para monitorear las condiciones de sequía/humedad en una región (McKee et al., 1993). Una de las ventajas de este índice es que es de fácil construcción y que sólo utiliza observaciones de precipitación para su cálculo, a diferencia de otras métricas de monitoreo similares como el Índice de Severidad de Sequía de Palmer (Palmer, 1965) o el Índice de Precipitación Evapotranspiración Estandarizado (Vicente-Serrano et al., 2010; Beguería et al., 2013).

Para su cálculo, se debe realizar una transformación equiprobable. En primer lugar, la precipitación es acumulada en la escala temporal deseada (por ejemplo, 3 meses) y luego es ajustada a una función de distribución de probabilidades paramétrica. Finalmente, esas probabilidades son transformadas a una distribución Normal estándar, de forma que el índice obtenido es adimensional y discrimina a los eventos húmedos ($IPE > 1$), eventos normales ($-1 < IPE \leq 1$), y eventos secos ($IPE \leq -1$), con una escala que permite variar la intensidad de los eventos. Debido a la naturaleza estandarizada propia del IPE, es posible emplearlo como métrica de las condiciones de sequía/humedad comparable entre regiones que presentan un régimen climático distinto, como es el caso de la CRB. De esta forma, el IPE sirve como medida de la influencia de distintos forzantes sobre la situación hídrica de las distintas estaciones pluviométricas del norte argentino.

Al momento de obtener el IPE se deben determinar la escala temporal de construcción del índice y la función de distribución paramétrica que ajustará a los datos de precipitación. En cuanto a lo primero, se decidió calcular el IPE de 3 meses finalizado en diciembre (IPE3-Dic) y finalizado en marzo (IPE3-Mar). El IPE3-Dic se obtiene a partir de la precipitación acumulada de OND mientras que el IPE3-Mar se construye en base a la precipitación acumulada de EFM, con lo cual sirven para analizar la incidencia de los indicadores generales sobre la situación hídrica de primavera y de verano, respectivamente. En cuanto a la segunda problemática, Sienz et al. (2012) plantean que la elección de una función de distribución apropiada es muy relevante para no generar sesgos en los valores del IPE, exagerando o minimizando así la severidad de un evento no normal. Stagge et al. (2015) analizaron esta problemática para una base de datos reticulada en Europa y propusieron realizar una validación de un conjunto de funciones de distribución, considerando distintas escalas temporales de acumulación de la precipitación.

En este estudio se consideraron cinco posibles funciones de distribución para el ajuste de la precipitación acumulada trimestral: Gamma, Normal, Log-normal, Weibull, y Gumbel. Todas estas distribuciones son paramétricas basadas en dos parámetros. Para cada una de las 45 estaciones pluviométricas del norte argentino (Figura 2-19b), se ajustó la precipitación de OND y de EFM a cada función de distribución candidata y luego se realizó la transformación final a una Normal estándar para obtener el IPE3. Adicionalmente, se realizó una corrección de ceros para evitar sesgos en el IPE que

enmascaren la ocurrencia de eventos secos, siguiendo la metodología propuesta por Stagge et al. (2015).

Para probar la eficiencia de cada función de distribución considerada se emplearon tres criterios:

- **Test de Anderson-Darling** (Anderson y Darling, 1954): se trata de un test no paramétrico de bondad de ajuste de una determinada muestra a una función de distribución específica, considerado una mejora respecto al test de Kolmogorov-Smirnov (Massey, 1951) especialmente en las colas de la distribución. El test de Anderson-Darling (AD) sirve para evaluar el ajuste de la precipitación trimestral a cada función candidata. El test AD se aplica con una significancia del 5%.
- **Criterio de Información de Akaike** (Akaike, 1974): en el caso particular de este análisis, es una métrica que sirve para evaluar la bondad de ajuste de la precipitación trimestral a las funciones de distribución candidatas. El Criterio de Información de Akaike (AIC) tiene en cuenta la cantidad de parámetros y el máximo valor de la función de verosimilitud para cada distribución. Si bien no es un test estadístico, permite evaluar la calidad relativa de cada ajuste, donde el mejor ajuste es aquel que minimice al AIC.
- **Test de Shapiro-Wilk** (Shapiro y Wilk, 1965): se trata de un test no paramétrico de bondad de ajuste de una determinada muestra a una distribución Normal estándar. El test de Shapiro-Wilk (SW) sirve para evaluar si el IPE hallado sigue una distribución con media nula y desvío unitario. El test SW se aplica con una significancia del 5%.

La Figura 3-3 muestra si la hipótesis nula de los tests AD y SW fue rechazada con 95% de confianza para cada estación pluviométrica considerada y para cada distribución candidata. Idealmente, la función de distribución óptima es la que ajusta con mayor eficiencia y para la mayor proporción posible de estaciones, es decir es la función que no presenta una gran tasa de rechazo de ambos tests. En general, se encuentra que en los casos donde existe rechazo hay coincidencia entre AD y SW, o bien el IPE3 obtenido no sigue una distribución Normal Estándar luego de la transformación equiprobable según el test SW a pesar del resultado favorable de AD. Para el caso de la primavera, se observa que tanto Gumbel como Gamma son las funciones que mejor ajustan a los datos estacionales de precipitación, mientras que Normal y Log-Normal son las que peor

rendimiento tienen, particularmente en las estaciones ubicadas en el extremo este para la función Log-Normal. En el verano Gumbel y Gamma continúan siendo las funciones de distribución que llevan a un IPE3 más representativo.




Figura 3-3. Resultados de los tests Anderson-Darling (AD) y Shapiro-Wilk (SW) para el ajuste de las cinco funciones de distribución candidatas en la construcción del IP3-Dic y el IPE3-Mar en cada estación del norte argentino. En sombreado (cruces) se detalla cuando se rechaza la hipótesis nula del test AD (SW) con 95% de confianza, y por lo tanto el ajuste no es favorable.

Las estaciones se encuentran ordenadas longitudinalmente de este a oeste.




Figura 3-4. Fila superior: Frecuencia de rechazo del test AD, **fila intermedia:** de obtención de mínimo AIC, y **fila inferior:** de rechazo del test SW para cada una de las cinco distribuciones candidatas. La frecuencia está calculada sobre la cantidad total de estaciones del norte argentino (45), y considerando todos los ajustes de IP3 (**primera columna**), sólo los ajustes de IP3-Dic (**segunda columna**), y sólo los ajustes de IPE3-Mar (**tercera columna**).

En la Figura 3-4 se muestra la frecuencia total de rechazos de los tests de AD y SW en la región, así como la frecuencia total de casos en los cuales cada distribución candidata presentó el mínimo AIC. Idealmente, un IPE3 representativo debería presentar bajas tasas de rechazo de los tests y altas tasas de AIC mínimo. En esta Figura se destaca que, si bien Gumbel se muestra como buena opción en términos de los tests AD y SW para el IPE3 de cada trimestre individualmente y en general para la suma de todos los casos, Gamma es el ajuste más exitoso porque adicionalmente es el que consistentemente muestra altas tasas de frecuencia de AIC mínimo, con más del 30% de las estaciones pluviométricas presentando resultados favorables según esta métrica. Contrariamente, la distribución Normal presenta los peores ajustes. Considerando los tres criterios, se optó por realizar

un ajuste Gamma de dos parámetros como paso inicial para el cálculo del IPE3-Dic e IPE3-Mar a cada una de las estaciones pluviométricas del norte argentino, empleando la precipitación acumulada en el trimestre OND (EFM) en el período 1984-2019 (1985-2020).

3.1.3. Relación entre los indicadores generales y el IPE

Se procedió a analizar la asociación simultánea entre los indicadores generales y el IPE en la CRB y zonas adyacentes durante el semestre estival. Para ello, se empleó el índice de Intensidad de Influencia (*InfInt*) definido por Kim et al. (2006) que permite examinar la variabilidad espacial en la influencia de un determinado patrón climático sobre la situación hídrica reflejada por el IPE3. El *InfInt* se define como

$$InfInt(C) = \frac{1}{N_c} \sum_{i=1}^{N_c} IPE3_c(i) \quad (3.1)$$

donde *InfInt(C)* es el índice *InfInt* bajo una fase climática determinada del indicador general (positiva, neutra, o negativa), N_c representa a la cantidad de eventos de la fase climática del indicador e $IPE3_c(i)$ representa al IPE3 en el i -ésimo evento de la fase climática. Contar con valores positivos (negativos) de *InfInt* implica que para la fase climática de interés se observa un promedio de valores positivos (negativos) de IPE3, es decir que dicha fase del patrón climático se asocia a condiciones más húmedas (secas) a escala estacional.

Cada indicador general empleado fue promediado trimestralmente en OND y EFM, y se definió a la fase climática positiva (negativa) como aquellos trimestres en los cuales el indicador general estacional resultó mayor (menor) que el segundo tercil (primer tercil) en el período 1984/1985-2019/2020. Esta definición fue utilizada para el cálculo del *InfInt* en fase positiva y negativa, tanto en primavera y en verano, para cada indicador seleccionado. Adicionalmente, para evaluar si un indicador se asocia a una diferencia relevante entre fases climáticas opuestas, se obtuvo una medida de la señal-ruido (S-R) definida de la siguiente manera:

$$S - R = \frac{InfInt(+) - InfInt(-)}{\sqrt{\frac{s_{(+)}^2}{n_{(+)}} + \frac{s_{(-)}^2}{n_{(-)}}}} \quad (3.2)$$

donde $InfInt(+)$ e $InfInt(-)$ refieren al $InfInt$ de las fases positiva y negativa del indicador respectivamente; $s(+)$ y $s(-)$ representan al desvío estándar muestral del $InfInt$ bajo cada fase del indicador; $n(+)$ y $n(-)$ es la cantidad de eventos de cada fase del indicador. La expresión de S-R en (3.2) esencialmente es un estadístico para test de diferencias de medias con varianzas diferentes. Por lo tanto, considerando a los grados de libertad acordes para este tipo de test (Eq. 26 en Welch, 1947), se puede inferir si existe una influencia significativa de un determinado forzante sobre la situación hídrica.

3.1.3.1. Indicadores de temperatura superficial del mar y de circulación hemisférica

La Figura 3-5 muestra mediante boxplots cómo se distribuyen los valores de $InfInt$ en primavera y en verano para las estaciones pluviométricas incluidas en ambos clusters, considerando las fases positiva y negativa de cada indicador general dentro del período 1984/1985-2019/2020. Durante la primavera se puede observar que los valores más intensos de $InfInt$ se asocian a EN3.4, particularmente en el cluster 2. Esto refiere a que una fase positiva (negativa) del indicador EN3.4 en OND, vinculada a anomalías cálidas (frías) de SST en el Pacífico ecuatorial central, se asocia con valores positivos (negativos) del IPE3-Dic, indicando condiciones más húmedas (secas) en la región este de estudio. Un resultado similar, aunque con mayor dispersión, se observa para el cluster 1 localizado en el sector centro-oeste de la región de estudio. El indicador PDO muestra un impacto similar al EN3.4 para el cluster 2, mientras que menor señal se observa para el cluster 1 al comparar las fases opuestas entre sí. Por otro lado, los indicadores del océano Índico muestran una señal más leve en general que su contraparte del océano Pacífico a juzgar por el acercamiento de los boxplots a valores poco intensos de $InfInt$. Aun así, valores positivos (negativos) de los indicadores DOI e IOBW se asocian a condiciones más húmedas (secas) en el cluster 2 y, se observa un resultado análogo para el cluster 1 al analizar el indicador DOI, pero con una señal más débil.

En verano, la señal del EN3.4 y la PDO sobre el *InfInt* disminuye notoriamente para el cluster 2, mientras que para el cluster 1 el indicador del Pacífico ecuatorial revierte la dirección de influencia de forma que valores negativos (positivos) de EN3.4 se vinculan a veranos más húmedos (secos) para las estaciones del sector centro-oeste. Por otro lado, las condiciones de humedad en verano vinculadas al DOI e IOBW son similares que para la primavera en el cluster 2, a diferencia del cluster 1 donde la relación no es tan clara.




Figura 3-5. Boxplots del índice *InfInt* para las fases positiva (+) y negativa (-) de los indicadores generales PDO, EN3.4, DOI, e IOBW. Los boxplots se encuentran discriminados por cluster de pertenencia. En la fila superior (inferior) el índice *InfInt* se calcula en base al IPE3-Dic (IPE3-Mar).

La Figura 3-6 muestra la distribución espacial del *InfInt* bajo las fases positiva y negativa de los indicadores asociados a la SST para la primavera, así como la S-R asociada a la diferencia entre ambas fases. Es importante notar que dado el tamaño de la muestra total (36 temporadas) la cantidad de observaciones en fase positiva y negativa es pequeña ($n(+)$, $n(-) < 30$) pero se destacan los puntos donde la S-R es estadísticamente significativa al 90% de confianza para brindar una medida de importancia relativa de la influencia de cada indicador. Los campos refuerzan el hecho de que las estaciones del cluster 2 presentan la mayor señal para EN3.4 particularmente, con un gran contraste en las condiciones de humedad al comparar las fases positiva y negativa; esto en menor medida también se observa para la PDO. Por el contrario, para los indicadores del océano Índico la variabilidad espacial del signo de *InfInt* es mayor y la proporción de estaciones con S-R significativa es menor, resultado acorde a la mayor dispersión de los boxplots de la Figura 3-5 para estos indicadores. En particular, el contraste entre ambas fases previamente detallado en las distribuciones es estadísticamente significativo solamente en puntos muy localizados de la región, con valores leves de S-R.




Figura 3-6. Campos espacial de *InfInt* de primavera para fases positiva (**primera fila**) y negativa (**segunda fila**) de la PDO, EN3.4, DOI, e IOBW respectivamente. Se incluye la S-R calculada en base a (3.2) (**tercera fila**). Los círculos rellenos en los paneles de S-R indican que la misma es significativa al 90% de confianza. En contorno rojo se destaca la CRB.




Figura 3-7. Análogo a Fig. 3-6 para el verano.

En verano (Figura 3-7), se refuerza el debilitamiento de la señal de EN3.4 y la PDO sobre la región. En particular, el vínculo entre condiciones más húmedas y EN3.4 en fase negativa se presenta particularmente para las estaciones del BS. Estas estaciones también muestran una S-R significativa para el IOBW, indicando que un enfriamiento generalizado de la cuenca del océano Índico se relaciona con condiciones más húmedas en verano.

La mayor influencia del ENSO sobre las condiciones hídricas en la primavera comparado con el verano, y su vinculación a condiciones más húmedas ante anomalías positivas de SST en el Pacífico ecuatorial central coincide con resultados obtenidos en trabajos previos de otros autores (Garreaud et al., 2009; Cai et al., 2020, entre otros). Es destacable que en el sector noroeste de la región de estudio esta influencia se revierte para el verano. En este sentido, Garreaud y Aceituno (2001) analizaron la variabilidad interanual de la precipitación en el trimestre diciembre-marzo en el Altiplano sudamericano, ubicado en los Andes centrales (15-21°S). Los autores hallaron que condiciones más húmedas (secas) se asocian a una anomalía del este (oeste) en niveles altos sobre los Andes centrales, vinculada a una anomalía anticiclónica (cyclónica) en altura sobre Sudamérica

subtropical. En particular, la intensificación del jet subtropical observada durante eventos El Niño (Kiladis, 1998), podría propiciar anomalías del oeste sobre los Andes Centrales que debiliten la circulación de la Alta Boliviana en el verano y que inhiben la convección sobre el Altiplano sudamericano. Además, Garreaud y Aceituno (2001) encontraron que la supresión de la convección de verano vinculada a las anomalías ciclónicas de altura se extiende espacialmente sobre el noroeste de Argentina, con lo cual condiciones más húmedas de *InfInt* de verano ante eventos de EN3.4 en fase negativa podrían asociarse a este comportamiento. Paralelamente, dada la respuesta del IOBW a la evolución del ENSO (Schott et al., 2009), es consistente encontrar que el IOBW en fase negativa también favorezca las condiciones húmedas en verano en el noroeste argentino (Figura 3-7).




Figura 3-8. Boxplots del índice *InfInt* para las fases positiva (+) y negativa (-) del indicador general SAM. Los boxplots se encuentran discriminados por cluster de pertenencia. En la **fila superior (inferior)** el índice *InfInt* se calcula en base al IPE3-Dic (IPE3-Mar).

La Figura 3-8 muestra cómo varían las funciones de distribución del *InfInt* según las fases del SAM. Se destaca una mayor influencia sobre el cluster 2 particularmente en primavera, dado que valores negativos del indicador se vinculan a condiciones más húmedas en el sector este mientras que lo opuesto se observa cuando el SAM se encuentra en fase positiva. Esto es esperable dado que el SAM en fase negativa posibilita el avance hacia el norte de sistemas migratorios (Reboita et al., 2009). En el verano, esta señal parece debilitarse en el cluster 2. Por otro lado, la influencia simultánea del SAM sobre las condiciones hídricas del cluster 1 muestra menor señal en ambos trimestres. La asociación entre el SAM y el IPE3 en las estaciones del cluster 2, así como la pérdida de señal en el verano, se ven también reflejados al analizar la variabilidad espacial del *InfInt* en las Figuras 3-9 y 3-10. En la primavera, la mayor proporción de estaciones con S-R significativa se localiza al este de 62°O, región donde las condiciones húmedas se ven favorecidas ante casos de SAM en fase negativa (Figura 3-9); en cambio la señal disminuye drásticamente en el verano (Figura 3-10).




Figura 3-9. Campos espacial de *InfInt* de primavera para fases positiva (**primera columna**) y negativa (**segunda columna**) del SAM. Se incluye la S-R calculada en base a (3.2) (**tercera columna**). Los círculos rellenos en los paneles de S-R indican que la misma es significativa al 90% de confianza. En contorno rojo se destaca la CRB.




Figura 3-10. Análogo a Fig. 3-9 para el verano.

3.1.3.2. Indicadores de circulación regional

La Figura 3-11 muestra los boxplots asociados a cada fase de los indicadores de intensidad y posición de los anticiclones semipermanentes de los océanos Atlántico y Pacífico sur. En primavera existe una clara señal asociada a la posición latitudinal del anticiclón del Atlántico (AA) de forma que condiciones más húmedas (secas) en el cluster 2 (y en menor medida en el cluster 1) se vinculan a un AA ubicado más hacia el norte (sur) que lo normal. Esto podría relacionarse con que la llegada de los sistemas ciclónicos migratorios desde el sur se vea favorecido en concordancia con lo analizado en la Figura 3-8. Con menor grado de influencia, un AA más intenso (débil) se relaciona con valores de *InflInt* más bajos (altos) en el cluster 2, y un AA ubicado más al este (fase positiva de AALON) podría acompañar a situaciones más secas (húmedas) en el cluster 1 durante la primavera. Por otro lado, el anticiclón del Pacífico (AP) muestra una influencia similar al AA en cuanto al índice de intensidad (APINT), con condiciones más húmedas asociadas al AP más débil particularmente en el cluster 2, y en cuanto al índice de posición longitudinal sobre ambos clusters. La posición latitudinal del AP no genera una influencia tan relevante como su contraparte del Atlántico.




Figura 3-11. Boxplots del índice *InfInt* para las fases positiva (+) y negativa (-) de los indicadores generales AAIN, AALAT, AALON, APINT, APLAT, y APLON. Los boxplots se encuentran discriminados por cluster de pertenencia. En la **fila superior (inferior)** el índice *InfInt* se calcula en base al IPE3-Dic (IPE3-Mar).

En el verano, disminuye notablemente la señal simultánea de AALAT sobre las condiciones de humedad, pero cobran relevancia la posición latitudinal del AP (un corrimiento hacia el sur implica condiciones más húmedas en cluster 2, y viceversa) y la intensidad del AP (un aumento en el máximo de altura geopotencial en 1000 hPa se relaciona a condiciones más húmedas en el cluster 2). Para el cluster 1 predomina la señal de AALON (AA ubicado más al oeste implica condiciones más húmedas y viceversa) y de AALNT (AA menos intenso implica condiciones más húmedas) aunque la variabilidad que presentan los valores de *InfInt* para el verano en las estaciones del centro-oeste dificulta la búsqueda de una señal clara.

La Figura 3-12 muestra los campos espaciales de *InfInt* para los indicadores de circulación regional en OND. Se destaca que el indicador con más señal en cuanto a cobertura y homogeneidad espacial es el AALAT, particularmente para las estaciones del cluster 2. Para este sector, el desplazamiento hacia el norte del AA se asocia a valores más altos del índice *InfInt*, lo cual podría guardar relación con la dinámica del ENSO (Sun et al., 2017). En menor medida, APINT y APLON muestran tener cierto grado de influencia relevante en la región, particularmente en el extremo oriental. En el verano (Figura 3-13) la S-R significativa predomina al sur de la CRB para el indicador APINT, que sugiere que en esa zona existe una señal significativa del favorecimiento de las condiciones húmedas (secas) ante una intensificación (debilitamiento) del AP. El cambio en el signo de *InfInt* vinculado al APINT entre la primavera y el verano sobre el extremo este de la región de estudio fue también notado por Garbarini et al. (2021) al analizar la distribución de precipitación en relación a los casos de APINT superior al segundo tercil e inferior al primer tercil en septiembre-octubre-noviembre y diciembre-enero-febrero. En la zona centro-oeste del norte argentino, correspondiente al cluster 1, la S-R no es estadísticamente relevante a excepción de un área muy localizada en el sector occidental del BS para el indicador APLON.




Figura 3-12. Campos espacial de *InfInt* de primavera para fases positiva (**primera fila**) y negativa (**segunda fila**) de la AAIN, AALAT, AALON, APINT, APLAT, y APLON respectivamente. Se incluye la S-R calculada en base a (3.2) (**tercera fila**). Los círculos rellenos en los paneles de S-R indican que la misma es significativa al 90% de confianza. En contorno rojo se destaca la CRB.




Figura 3-13. Análogo a Fig. 3-12 para el verano.

3.1.3.3. Indicadores de convección en Sudamérica tropical

Los indicadores de OLR funcionan como proxy de la convección húmeda en latitudes bajas de Sudamérica. En particular, como se mencionó anteriormente, estos indicadores hacen referencia a distintas regiones de desarrollo del sistema monzónico sudamericano. La Figura 3-14 muestra la distribución de valores de *InflInt* para cada uno de los indicadores convectivos en primavera. En particular, la OLRC presenta cierta influencia en el sentido de que un mayor desarrollo convectivo (OLRC en fase negativa) se vincula a condiciones más húmedas en ambos clusters, aunque no es tan claro que lo opuesto suceda para casos de OLRC en fase positiva. El comportamiento contrario se observa según el indicador OLRN particularmente para el cluster 2. Por otro lado, en el cluster 2 los valores más altos de *InflInt* se asocian a un menor desarrollo convectivo en OLRSE y a un corrimiento hacia el sur del núcleo convectivo en el sudeste de Sudamérica (posOLRSE en fase negativa). Para el cluster 1 la influencia del OLRSE y posOLRSE en primavera presenta más incertidumbre. En cambio, en el verano se refuerza el contraste en la influencia del posOLRSE sobre las condiciones hídricas del cluster 1 y el cluster 2; un corrimiento hacia el norte (sur) de la máxima convección en la costa oriental sudamericana genera condiciones más húmedas (secas) en el cluster 1 y más secas (húmedas) en el cluster 2. Además, el OLRSE sugiere que la presencia de convección más desarrollada en el sudeste de Brasil (OLRSE en fase negativa) genera valores de *InflInt* más bajos en el cluster 2, y lo opuesto en el cluster 1. Por otro lado, menor desarrollo convectivo en la zona central del Brasil (OLRC fase positiva) se vincula a condiciones más secas en el cluster 1, mientras que menor desarrollo convectivo en el norte de Brasil (OLRN) se vincula a condiciones más húmedas en el cluster 2.




Figura 3-14. Boxplots del índice *InfInt* para las fases positiva (+) y negativa (-) de los indicadores generales OLRN, OLRC, OLRSE, y posOLRSE. Los boxplots se encuentran discriminados por cluster de pertenencia. En la **fila superior (inferior)** el índice *InfInt* se calcula en base al IPE3-Dic (IPE3-Mar).

La Figura 3-15 muestra el campo espacial de valores de *InfInt* para la primavera. Se puede observar que la influencia de OLRC es homogénea espacialmente sobre la región con condiciones húmedas vinculadas a un mayor desarrollo convectivo en la región central de Brasil, mientras que OLRN presenta mayor heterogeneidad espacial en la señal, particularmente en el cluster 1. Por otro lado, la intensidad y posición del desarrollo convectivo en el sudeste de Sudamérica presenta una S-R significativa más dispersa

espacialmente. Esto resalta que en la primera mitad del semestre estival priman los efectos de la OLR en latitudes tropicales, siguiendo el avance del desarrollo convectivo profundo en dirección noroeste-sudeste. Contrariamente, en verano (Figura 3-16) la influencia de posOLRSE sobre la situación hídrica se evidencia más organizada y estadísticamente significativa, con un dipolo de acción en el cual valores en fase negativa del indicador se asocian a situaciones más húmedas (secas) en las estaciones del cluster 2 (cluster 1), resaltando la importancia que cobra la convección en el sudeste de Sudamérica una vez que el SAMS se encuentra maduro. Debido a la estación considerada, este dipolo de acción podría responder a la variabilidad intraestacional en la intensidad y la posición latitudinal de la SACZ (Doyle y Barros, 2002; Carvalho et al., 2010). Los eventos en los cuales la SACZ se evidencia más intensa tienden a ser acompañados por un LLJ debilitado que se desvía hacia la SACZ, en conjunto con anomalías negativas de precipitación en el sur de Brasil, noreste de Argentina y Uruguay por efectos de subsidencia compensatoria, y anomalías positivas de precipitación en el noroeste y centro de Argentina; además, la SACZ tiende a localizarse más hacia el norte en estos eventos. Por otro lado, ante casos de SACZ debilitada y desplazada hacia el sur de su posición climatológica, el LLJ se ve fortalecido y aporta gran contenido de humedad al sector al sur de la SACZ, revirtiendo así los centros de anomalías positivas y negativas de precipitación en latitudes subtropicales. Este comportamiento se ve reflejado particularmente mediante el indicador posOLRSE.




Figura 3-15. Campos espacial de *InfInt* de primavera para fases positiva (**primera fila**) y negativa (**segunda fila**) de la OLRN, OLRC, OLRSE, y posOLRSE respectivamente. Se incluye la S-R calculada en base a (3.2) (**tercera fila**). Los círculos rellenos en los paneles de S-R indican que la misma es significativa al 90% de confianza. En contorno rojo se destaca la CRB.




Figura 3-16. Análogo a Fig. 3-15 para el verano.

A modo de síntesis, se detalla en la Tabla 3-2 la influencia simultánea predominante de cada indicador general sobre cada cluster para OND y EFM, respectivamente. Sobre las estaciones del cluster 2 se destaca en forma generalizada la presencia de condiciones más húmedas en primavera ante fases positivas de EN3.4 y AALAT (desplazamiento hacia el norte del AA). Hacia el verano la señal disminuye, y predominan las condiciones más húmedas ante un desplazamiento hacia el sur de la máxima convección en el este de Brasil. Por otro lado, en el cluster 1 las señales de los distintos indicadores generales son más heterogéneas espacialmente que en el cluster 2. Se destaca el cambio en la influencia de EN3.4, pasando de favorecer condiciones más húmedas ante casos de fase positiva en OND a casos de fase negativa en EFM. Asimismo, el comportamiento en el cluster 1 ante corrimientos de la convección en la zona de la SACZ es opuesta al cluster 2 en el verano.

Indicador general	OND		EFM	
	Cluster 1	Cluster 2	Cluster 1	Cluster 2
PDO	○	▲	○	○
EN3.4	▲	▲	▼	○
DOI	○	○	○	▲
IOBW	○	▲	▼	▲
SAM	○	▼	○	○
AAINT	○	○	○	○
AALAT	○	▲	○	○
AALON	▼	○	○	○
APINT	▼	▼	○	○
APLAT	○	○	○	▼
APLON	○	▼	○	○
OLRN	○	▲	○	▲
OLRC	▼	▼	▼	○
OLRSE	○	○	○	○
posOLRSE	○	○	▲	▼

Tabla 3-2. Síntesis de la influencia regional de los indicadores generales sobre las condiciones hídricas en OND y EFM cada cluster. Triángulos verdes (naranjas) indican que una fase positiva del indicador se vincula en forma simultánea con condiciones más húmedas (secas) en la región. El tamaño de los triángulos es proporcional a la cantidad de estaciones que muestran una S-R significativa. Los indicadores blancos señalan que menos del 15% de las estaciones del cluster presentan una S-R significativa al 95% de confianza

3.1.4. Indicadores generales como predictores de la precipitación mensual

Hasta este punto, se ha explorado si los indicadores generales presentan alguna asociación simultánea con la situación hídrica del norte argentino considerando al índice *InfInt* construido a partir del IPE3-Dic e IPE3-Mar. Se encontró que algunos de estos indicadores presentan una señal simultánea significativa con distintas zonas del norte argentino al evaluar la fase positiva y negativa de dichos índices. La asociación entre los indicadores y la precipitación estacional no es homogénea espacialmente en la mayor parte de los casos, como tampoco presenta la misma respuesta en primavera y verano.

Para poder avanzar en la exploración de predictores de la precipitación areal es necesario analizar si efectivamente existe una relación estadística entre los indicadores generales y la precipitación mensual con cierto desfase temporal, que señale que anomalías del indicador previo al mes objetivo de pronóstico se vinculan a anomalías significativas en la precipitación areal. Con este fin, se utilizó el coeficiente de correlación de Pearson (Wilks, 2011) para caracterizar la importancia estadística de cada forzante como potencial predictor. Este coeficiente cuantifica el grado de asociación lineal entre dos variables, en este caso representadas por cada indicador en forma individual (variable independiente) y la precipitación desfasada temporalmente (variable dependiente). Si bien existen otras alternativas de naturaleza no lineal para evaluar asociación entre variables, la correlación de Pearson se destaca por la simpleza de su cálculo y por la facilidad en la interpretación del impacto cuantificable sobre la variable dependiente ante un cambio específico en la variable independiente. El coeficiente de correlación de Pearson se encuentra acotado numéricamente entre -1 y 1, con valores positivos (negativos) representativos de una relación directa (indirecta) entre las variables de interés.

Para el cálculo del coeficiente de correlación, se consideró a la precipitación acumulada mensual, así como la precipitación acumulada estacional en OND y EFM. En todos los casos, la serie temporal de precipitación empleada para el cálculo es areal y se obtuvo mediante un promedio aritmético entre todas las estaciones pluviométricas que conforman el cluster 1 y el cluster 2. Por otro lado, los indicadores se tomaron a paso mensual y anteceden a la precipitación con un mes de antelación. A modo de ejemplo, para la precipitación mensual de octubre se consideraron indicadores observados en el mes de septiembre previo; en cambio, para la precipitación de EFM se tomaron indicadores del mes de diciembre que antecede al inicio del trimestre. En este análisis se

consideró a la precipitación correspondiente a los semestres estivales de 1984/1985-2019/2020, y los coeficientes fueron testeados empleando un test T-Student a dos colas con niveles de significancia de 5% y 10%. En todos los casos las tendencias lineales fueron filtradas previo al cálculo de las correlaciones.

La decisión de emplear indicadores observados en el mes previo al objetivo del pronóstico radicó en posibilitar que la mayor cantidad de indicadores posibles resultaran en potenciales predictores por la inmediatez de su influencia sobre la precipitación. Sin embargo, este análisis se repitió considerando un desfase de dos meses entre los indicadores y el objetivo de pronóstico, pero no se hallaron diferencias relevantes respecto a la cantidad de indicadores significativos al tomar un mes de desfase (Figura A-3-1 en Anexo).



Figura 3-17. Coeficiente de correlación de Pearson entre la precipitación areal de cada cluster (a nivel mensual en el semestre estival, y a nivel estacional en OND y EFM) y los indicadores generales observados en el mes previo. En el caso de la precipitación estacional, los indicadores están monitoreados en el mes anterior al inicio del trimestre. En letra azul cursiva (negra) se destacan las correlaciones significativas al 90% (95%) de confianza mediante un test T-Student. Las celdas de tonalidad violeta (verde) representan correlaciones positivas (negativas), las más oscuras con mayor magnitud.

La Figura 3-17 muestra los coeficientes de correlación de Pearson entre la precipitación areal de cada cluster en el semestre estival y los indicadores generales observados en el mes previo. Dentro del conjunto de indicadores se añadió a la precipitación areal del cluster observada en el mes previo, como una medida de persistencia climática que podría reflejar si la situación hídrica detectada en un determinado mes tiene algún grado de memoria y se extiende al mes o trimestre siguiente. Para la muestra considerada, los coeficientes cuyo valor absoluto supera a 0.33 (0.28) son estadísticamente significativos al 95% (90%) de confianza.

En la Figura 3-17 se destaca que a nivel estacional la predictibilidad es mayor en OND que en EFM en ambos clusters, dado que se observa una mayor cantidad de relaciones lineales significativas entre los indicadores y la precipitación areal. Esta señal disminuye fuertemente en el verano, cuando solamente el DOI muestra una relación significativa al 95% de confianza con la precipitación (con influencia opuesta entre ambos clusters). En la primavera las señales estadísticamente significativas se concentran en los indicadores regionales asociados al AP, en los indicadores de convección en Sudamérica y en el indicador de la SST del Pacífico ecuatorial (EN3.4). A pesar de haber encontrado una mayor proporción de correlaciones significativas en OND, es evidente que existe variabilidad intraestacional de forma que no todos los meses que componen al trimestre presentan señales significativas o el mismo tipo de influencia, como es el caso del indicador OLRN que genera impactos opuestos sobre la precipitación entre el inicio y el final de la primavera en el cluster 2. En particular, las correlaciones a nivel mensual más relevantes para los indicadores generales están asociadas al comienzo de la primavera en ambos clusters. En ningún caso se observa que exista persistencia en la precipitación areal, reflejado a través de la falta de significancia de la correlación lineal de Pearson vinculada a la precipitación desfasada en un mes.

Este resultado sugiere que a nivel intraestacional no es suficiente con considerar solamente indicadores preestablecidos como potenciales predictores en la construcción de los modelos de pronóstico, sino que es necesario definir nuevos indicadores específicamente diseñados para la región de estudio. Si bien una determinada fuente de predictibilidad puede activar un mecanismo dinámico de asociación con la precipitación que sea físicamente coherente, como por ejemplo el ENSO al disparar trenes de onda de

Rossby que vinculan al Pacífico ecuatorial con latitudes subtropicales de Sudamérica (Mo, 2000), es posible que el indicador general utilizado y predefinido no sea el más adecuado para representar cómo ese forzamiento impacta en la variabilidad interanual de la precipitación mensual. Esto no implica que el patrón climático no tenga incidencia en la región de estudio, sino que simplemente el indicador seleccionado para su representación no es el más adecuado para ser utilizado como predictor de modelos estadísticos. En este sentido, Grimm y Saboia (2015) plantean que distintos indicadores referidos al mismo fenómeno climático podrían llevar a diferentes resultados al correlacionarlos con otra variable; además, la definición de un índice vinculado a un modo de variabilidad no necesariamente refleja las características responsables de la teleconexión y posterior impacto sobre la variable de interés. A raíz de los resultados encontrados para los indicadores generales, se exploraron y definieron nuevos indicadores denominados *particulares* para cada mes del semestre estival y para cada cluster de la región de análisis. Los indicadores generales que se relacionaron significativamente con la precipitación con un mes de antelación bajo un 5% de significancia fueron conservados como potenciales predictores.

3.1.5. Construcción de indicadores particulares

Los indicadores particulares refieren a índices definidos exclusivamente para el mes y la región de interés. Los mismos fueron contruidos a partir de variables promediadas mensualmente derivadas del reanálisis ERA5. Este reanálisis es la quinta generación de reanálisis del ECMWF y actúa como reemplazo de su predecesor ERA-Interim (Dee et al., 2011). Presenta una resolución horizontal global de $\sim 0.25^\circ$, con información en 37 niveles verticales de presión (Hersbach et al., 2023). El reanálisis ERA5 contiene avances en términos de la representación de la temperatura, el viento, y la humedad troposférica gracias a las mejoras en la física de los modelos involucrados, la representación dinámica de los procesos y las técnicas de asimilación de datos (Hersbach et al., 2020). Actualmente, las variables incluidas en la base de datos de ERA5 se encuentran disponibles con cobertura temporal desde 1940. Además de contar con una resolución espacial fina, la base de datos de ERA5 fue seleccionada para el diseño de los indicadores particulares porque los datos diarios que posteriormente derivan en los indicadores mensuales son fácilmente accesibles con una latencia temporal de aproximadamente 5

días. Esto es un aspecto muy relevante a considerar con el fin último de elaborar una herramienta operativa, para la cual sea posible obtener de manera sencilla y rápida los datos actualizados de las variables predictoras, y poder así generar una estimación de la precipitación para el mes próximo en tiempo real.

Los datos mensuales de ERA5 empleados para la definición de los indicadores particulares correspondieron a los campos espaciales de las siguientes variables geofísicas:

- Altura geopotencial (hgt) en 1000, 500, y 200 hPa (hgt1000, hgt500, y hgt200, respectivamente), al sur de 20°N en todos los niveles verticales.
- Viento zonal (u) en 850 y 200 hPa (u850 y u200, respectivamente), en continente sudamericano y océanos adyacentes [80°O-25°O; 20°N-45°S] para niveles bajos, y al sur de 20°N para niveles altos.
- Viento meridional (v) en 850 hPa (v850) en continente sudamericano y océanos adyacentes [80°O-25°O; 20°N-45°S].
- SST entre 60°N y 60°S.
- Agua precipitable (tcwv), en continente sudamericano y océanos adyacentes [80°O-25°O; 20°N-45°S].

Así como en el caso de los indicadores generales, estas variables fueron seleccionadas en el mes anterior al mes objetivo de pronóstico. El propósito es hallar indicadores específicos que representen potenciales fuentes de predictibilidad para cada mes del semestre estival y para ambos clusters. Los indicadores específicos reflejan la variabilidad de sistemas de circulación en superficie y en altura, del contenido de humedad en latitudes bajas de Sudamérica, y de las condiciones térmicas superficiales en regiones oceánicas cercanas a Sudamérica que puedan derivar en anomalías en el transporte vertical de calor sensible y latente. Para cada mes comprendido entre octubre y marzo se construyeron campos espaciales de correlación de Pearson entre la serie temporal de precipitación areal, y cada variable geofísica seleccionada en el mes previo a la precipitación. Este cálculo se repitió para ambos clusters, tomando información comprendida en el período 1984/1985-2019/2020. Finalmente, se utilizó un test T-Student para evaluar la significancia de la correlación al 95% de confianza.

A partir de los campos de correlación, se delimitaron las zonas que presentaron una asociación significativa entre la precipitación areal y la variable geofísica que la antecede.

Se evitó trazar áreas pequeñas de correlación significativa que refirieran a potenciales fuente de variabilidad extremadamente localizadas; esto se logró tomando como criterio que los polígonos que delimitan las zonas significativas estuviesen conformados por al menos 250 puntos de retícula. Los indicadores particulares están definidos como las series temporales de las variables geofísicas que resultan de promediar los puntos de retícula contenidos en los polígonos trazados previamente.

Para la detección de las áreas relevantes en términos de predictibilidad, se tuvieron en cuenta algunos criterios adicionales a la significancia. En primer lugar, se seleccionaron regiones que pudiesen tener una conexión físicamente plausible con la precipitación en el norte argentino, en función de la información provista en trabajos previos. En segundo lugar, se evitó definir indicadores en regiones de topografía compleja para las variables de niveles bajos de la atmósfera (hgt1000, u850, y v850); para ello, se enmascararon las superficies ubicadas a una altura mayor a 1000 msnm siguiendo la información de orografía dada por la base de datos ERA5-Land (Muñoz-Sabater et al., 2021). Para justificar físicamente la relación entre indicadores y precipitación, se elaboraron campos de composición de circulación y humedad bajo eventos positivos y negativos de cada indicador particular, tomando como meses de fase positiva (negativa) a los meses en los cuales el valor del indicador se ubica por encima (debajo) del segundo tercil (primer tercil). Estos campos asisten en la explicación física de los indicadores particulares hallados, y pretenden reflejar cuáles son los patrones climáticos típicos bajo ciertas condiciones del indicador que pudiesen explicar el impacto esperado en la precipitación areal posterior. Para los campos de composición se emplearon nuevamente las mismas variables geofísicas que dieron origen a los indicadores particulares, y se consideraron además datos de OLR y de humedad específica en 850 hPa. Los datos de humedad específica fueron empleados junto al viento en niveles bajos para el cálculo del transporte de humedad en el nivel de 850 hPa.

En la Figura 3-18 se presenta a modo de ejemplo uno de los campos de correlación obtenidos, donde se muestra la correlación entre la precipitación areal del cluster 2 en noviembre y la SST observada en el mes previo (octubre). En la Figura se incluye el polígono que delimita al área de uno de los indicadores particulares, referido a la SST en la región del Pacífico tropical. Este polígono encierra valores estadísticamente significativos del coeficiente de correlación, y el signo de la correlación es positivo indicando que valores más altos (bajos) de SST en esta zona preceden a condiciones más

húmedas (secas) en el cluster 2 en noviembre. Este indicador está claramente vinculado al fenómeno ENSO, y sugiere que condiciones anómalamente cálidas (frías) típicamente ligadas a la fase El Niño (La Niña) se vinculan a precipitaciones más abundantes (escasas) el mes posterior en el extremo este de la región de estudio. El promedio aritmético de la SST de octubre en los puntos de retícula que conforman la zona del polígono tropical, define la serie temporal del indicador particular ligado a la variabilidad del ENSO para la predicción de la precipitación areal de noviembre en el cluster 2. De forma análoga, se trabajó con las demás variables geofísicas consideradas.




Figura 3-18. Campo de correlación de Pearson entre la SST de octubre y la precipitación areal del cluster 2 en noviembre (desfasaje de un mes). El polígono negro en la región del Pacífico tropical encierra valores del coeficiente estadísticamente significativos mediante un test *T-Student* (5% significancia) y representa al área que da origen a un indicador particular vinculado a la SST.

3.2. Selección de predictores: aplicación de la técnica Least Absolute Shrinkage and Selection Operator (LASSO)

La búsqueda de fuentes de predictibilidad a partir de los campos de correlación desfasada llevó a definir una gran cantidad de indicadores particulares para cada uno de los meses del semestre estival y para cada cluster. La Figura 3-19 muestra la cantidad total de indicadores generales y particulares que fueron seleccionados como potenciales predictores de la precipitación mensual, discriminados por trimestre de pertenencia. Como se mencionó anteriormente, los indicadores generales considerados fueron

solamente aquellos que presentaran una correlación desfasada con la precipitación areal significativa al 95% de confianza mediante un test T-Student (Figura 3-17). Se puede observar en la Figura 3-19 que la mayor cantidad de indicadores hallados corresponde a la primavera para ambos clusters, mientras que para el verano se encontró aproximadamente un 30% menos de potenciales predictores (111 indicadores en OND versus 76 indicadores en EFM). El cluster 1 presenta ligeramente más indicadores que el cluster 2, aunque las diferencias son leves en ambos trimestres.




Figura 3-19. Cantidad de indicadores generales y particulares definidos para cada cluster, agrupados según si anteceden a la precipitación areal de OND o de EFM. Las etiquetas numéricas indican la cantidad exacta de indicadores por cluster y trimestre.

En particular, para cada mes del semestre estival y asociado a cada cluster se obtuvo un conjunto total de entre 10 y 29 indicadores. Esta cantidad de potenciales predictores puede suponer un problema metodológico al momento de construir los modelos de predicción. Como se detallará en el Capítulo 4, los modelos estadísticos se entrenarán considerando una muestra de entrenamiento compuesta por 35 temporadas estivales. Esto implica que

la cantidad de variables independientes dentro de los esquemas de predicción puede acercarse fuertemente al tamaño de la muestra de entrenamiento, lo que supone un problema de *sobreajuste* (Wilks, 2011). Este fenómeno ocurre cuando el cociente entre la cantidad de variables explicativas del modelo y el tamaño de la muestra del predictando es alto, de modo que se incrementa la varianza de las estimaciones de los parámetros del modelo. El sobreajuste también lleva al modelo a tener mayores chances de demostrar un pobre desempeño en una muestra independiente, lo cual es un resultado indeseable para un modelo de pronóstico operativo (James et al., 2013).

En segundo lugar, muchos de los indicadores seleccionados pueden estar relacionados dinámica y estadísticamente entre sí. A modo de ejemplo, la variabilidad del Pacífico ecuatorial central representada mediante el indicador general EN3.4 está altamente correlacionada con el indicador particular definido a través del campo de correlación de la Figura 3-18, obtenido al correlacionar linealmente a la SST de octubre y la precipitación del cluster 2 en noviembre ($r = 0.97$). Esto sucede porque ambos indicadores reflejan la variabilidad climática asociada al ENSO; de hecho, el indicador particular incluye al área sobre la cual se calcula EN3.4 en su polígono de definición. Esto implica que dentro del conjunto de potenciales predictores de un mes específico puede existir información redundante y presencia de *colinealidad*. La colinealidad es la existencia de asociación entre dos o más predictores, lo cual dificulta la separación de los efectos individuales de cada variable colineal sobre la variable objetivo, introduciendo a cambio un alto grado de incertidumbre en las estimaciones de los coeficientes de los modelos de pronóstico (James et al., 2013).

Existen diferentes alternativas para resolver la problemática de la selección eficiente de indicadores predictivos. A continuación, se listan algunas de estas metodologías:

- **Técnicas de selección de variables:** basadas en conservar variables explicativas potencialmente útiles en términos de la reducción del error predictivo de los modelos. Entre estas técnicas se encuentran los métodos de selección de variables *forward stepwise* y *backward stepwise* (Wilks, 2011). El primero consta en la inclusión sucesiva de predictores al esquema de predicción hasta llegar a un punto en el que las métricas de eficiencia predictiva del modelo no pueden ser mejoradas; en el segundo caso, la lógica es inversa y los predictores son sucesivamente removidos del modelo. Además, dentro de este grupo de técnicas

se encuentra la variante de *mejor subset*, donde se identifican subconjuntos de variables explicativas linealmente independientes entre sí y se evalúa cuál subconjunto se asocia a un modelo con mejor eficiencia predictiva. Algunos ejemplos de aplicación de estas técnicas se pueden encontrar en González y Cariaga (2009), Hidalgo-Muñoz et al. (2015), y Ayala et al. (2021).

- **Técnicas de reducción de la dimensión:** basadas en realizar una transformación de las variables explicativas originales, de forma que las variables transformadas son las que luego servirán como variables independientes en los esquemas predictivos. En este enfoque las p variables originales son proyectadas a un subespacio de dimensión M ($M < p$), es decir que se obtienen M combinaciones lineales independientes de las variables originales (Stone y Brooks, 1990; James et al., 2013). La utilización de estas combinaciones lineales como predictores de la variable objetivo se conoce como *regresión por componentes principales* (PCR). Es importante destacar que esta transformación se hace sin considerar la vinculación de las variables explicativas con la variable de respuesta. En consecuencia, existe también una variante de la regresión por componentes principales denominada *regresión de mínimos cuadrados parciales* (PLS) que transforma las variables originales a un espacio multidimensional que además está altamente correlacionado con la variable de respuesta. Algunos ejemplos de aplicación de PCR y PLS se encuentran en Abudu et al. (2010) y Sinha y Sankarasubramanian (2013).
- **Técnicas de regularización:** basadas en la restricción o regularización de las estimaciones de los coeficientes de un ajuste lineal, “reduciendo” dichas estimaciones a cero. Dentro de este grupo de técnicas se encuentran la regresión Ridge y la metodología Least Absolute Shrinkage and Selection Operator (LASSO), que fue aplicada en este estudio para la selección de potenciales predictores de la precipitación mensual en la CRB.

La metodología LASSO fue originalmente propuesta por Tibshirani (1996) como una técnica de regresión lineal que a su vez es de utilidad para la selección de variables. LASSO forma parte del conjunto de técnicas que se denominan de *regularización* y operan ajustando un modelo de p predictores por cuadrados mínimos, restringiendo las estimaciones de sus coeficientes hacia cero. Esto disminuye la varianza de las estimaciones, así como la complejidad del modelo (James et al., 2013). De esta manera,

LASSO se emplea como herramienta para seleccionar a las fuentes de predictibilidad en base al aprendizaje de un modelo lineal, lo que permite reducir la probabilidad de sobreajuste de los esquemas predictivos de la precipitación mensual areal.

Al aplicar LASSO, se realiza una modificación a un ajuste lineal clásico por cuadrados mínimos sobre las variables explicativas. Su objetivo es minimizar la cantidad:

$$RSS + \lambda \sum_{j=1}^p |\beta_j| \quad (3.3)$$

donde RSS representa a la suma de los cuadrados de una regresión lineal clásica, mientras el segundo término es un factor de penalización. Dentro de ese término, se toma a λ como el parámetro de penalización de LASSO y β_j es el j -ésimo coeficiente a ajustar en el ajuste lineal. Si λ es alto, el impacto de la penalización aumenta y por lo tanto una mayor cantidad de coeficientes deberán anularse para minimizar la ecuación (3.3). Por lo tanto, al aplicar esta técnica sobre un set p de predictores, sólo un subconjunto de los mismos sobrevivirá; los demás predictores son removidos en el proceso de selección pues su coeficiente acompañante es reducido a cero al minimizar la ecuación (3.3).

La regresión Ridge actúa de manera similar a LASSO en términos del encogimiento de los coeficientes que acompañan a las variables explicativas. Sin embargo, al aplicar Ridge el argumento de la sumatoria en la ecuación (3.3) reemplaza a $|\beta_j|$ por el cuadrado de los j -ésimos coeficientes. Esto hace que algunos coeficientes adquieran un peso relativo bajo en comparación a los parámetros de predictores más relevantes, pero aun así Ridge retiene a todas las variables explicativas al finalizar el proceso de regularización. En cambio, bajo un λ adecuado, en el caso de LASSO las estimaciones de algunos coeficientes se reducen exactamente a cero, pudiendo así remover a los predictores asociados a los coeficientes anulados. Eso por esto que LASSO presenta ventajas sobre Ridge en términos de la eficacia en la selección de predictores.

La elección del hiperparámetro λ no es trivial, pues su magnitud dicta cuál es la intensidad de la regularización. Para poder decidir qué valor del hiperparámetro λ es más recomendable utilizar, se aplicó la metodología de validación cruzada (CV) de m -folds. Esta técnica divide a la muestra en m conjuntos (folds) de igual cantidad de observaciones elegidas aleatoriamente. Fijando al i -ésimo fold, la técnica CV entrena un modelo lineal

intentando minimizar la ecuación (3.3) con los $m-1$ folds restantes y empleando los coeficientes obtenidos para predecir al i -ésimo fold no utilizado en el entrenamiento. En este caso, la búsqueda del λ óptimo para cada mes y para cada cluster se realizó sobre la muestra de semestres estivales en 1984/1985-2019/2020 usando CV de 9-folds. Previamente, los valores de la precipitación areal mensual y los valores de los indicadores fueron centrados y estandarizados para poder ajustar el modelo lineal de LASSO e intercomparar la magnitud de los coeficientes entre sí. El λ óptimo es aquel que minimiza el error cuadrático medio en el proceso de CV. Una vez seleccionado el λ óptimo para cada mes y cada cluster, se descartaron aquellos indicadores que no aportaron a minimizar la expresión (3.3) y que, por lo tanto, adquieren un coeficiente nulo en el ajuste lineal de regularización. En este sentido, LASSO optimiza el uso de los indicadores, descartando aquellos que no aportan información relevante en términos de la minimización del error de un ajuste lineal.

La Figura 3-20 muestra los resultados de LASSO para los indicadores de la precipitación de noviembre en el cluster 2. En este caso particular, el λ óptimo de penalización que minimiza el error cuadrático medio de las estimaciones, equivale a 0.043 (Figura 3-20). Del total de indicadores ingresados a la técnica se destaca que no todos sobreviven al alcanzar el valor óptimo del hiperparámetro; aquellos indicadores cuyo coeficiente es nulo al alcanzar el valor $\lambda = 0.043$ deben ser descartados (Figura 3-20). Adicionalmente, se verifica que los indicadores seleccionados por LASSO no presenten colinealidad. Esto se logró calculando los coeficientes de correlación de Pearson entre cada par de indicadores, y removiendo aquellos indicadores que se encuentran correlacionados significativamente con algún otro indicador del set que, a su vez, esté mejor relacionado con la precipitación en términos del coeficiente de Pearson. Para verificar la significancia en la colinealidad se utilizó un test T-Student con 5% de significancia.

Los indicadores que atravesaron el proceso de regularización por LASSO y fueron efectivamente seleccionados conforman los sets de predictores independientes entre sí para la construcción de los modelos estadísticos. La aplicación de LASSO y la remoción de colinealidad redujo notablemente la cantidad de predictores por mes y por cluster. El listado final se detalla en la Tabla 3-3. Los nombres de los predictores hacen referencia a la variable a partir de la cual se definen, el cluster y mes de precipitación al cual anteceden, y el esquema al cual pertenecen. Por ejemplo, el predictor `u850_octC1_e4`

corresponde a un indicador basado en el viento zonal de 850 hPa (u850) para la predicción de la precipitación de octubre del cluster 1 (octC1), y se agrupa bajo el Esquema 4 (e4) que se describirá a continuación.

Noviembre - Cluster 2




Figura 3-20. Resultado de LASSO para los indicadores de la precipitación areal de noviembre en el cluster 2. **Fila superior:** Error cuadrático medio surgido de aplicar CV de 9-folds para la búsqueda del λ óptimo. El eje-x inferior expresa el logaritmo de λ , el eje-x superior muestra la cantidad de predictores que se seleccionan para cada valor del logaritmo de λ . En sombreado se indica la dispersión del error cuadrático medio. **Fila inferior:** Selección de los predictores mediante LASSO. Las curvas indican la variación en el valor de los coeficientes de LASSO para cada indicador ingresado a la metodología a medida que varía el valor de λ . En rojo (azul) se indican los predictores que conservan un coeficiente negativo (positivo) al alcanzar el λ óptimo. En gris se indican los coeficientes que no son seleccionados por la metodología pues sus coeficientes se anulan para el valor de λ elegido.

Mes	Cluster 1	Cluster 2
Octubre	u850_octC1_e4 (-0.48) u200_octC1_e4 (-0.48) u200_octC1_e2 (-0.45)	hgt1000_octC2_e1 (-0.53) v850_octC2_e4 (0.50) posOLRSE_octC2_e4 (0.46)
Noviembre	u200_novC1_e1 (0.63) hgt1000_novC1_e2 (0.41) sst_novC1_e1 (-0.48)	sst_novC2_e1 (0.51) hgt200_novC2_e2 (-0.47)
Diciembre	u850_dicC1_e3 (-0.59) sst_dicC1_e1 (0.44) hgt500_dicC1_e2 (-0.37)	hgt1000_dicC2_e1 (-0.58) tcwv_dicC2_e4 (-0.46)
Enero	hgt200_eneC1_e1 (-0.56) sst_eneC1_e2 (0.44) hgt1000_eneC1_e2 (0.43)	u200_eneC2_e2 (-0.46) sst_eneC2_e1 (0.44) hgt1000_eneC2_e3 (0.43) hgt200_eneC2_e2 (0.41)
Febrero	sst_febC1_e3 (0.59) u200_febC1_e2-1 (-0.51) u200_febC1_e2-2 (0.44) sst_febC1_e1 (-0.43) u850_febC1_e3 (0.41)	sst_febC2_e3 (0.54) u200_febC2_e2-1 (0.48) hgt500_febC2_e2 (-0.45) u200_febC2_e2-2 (-0.40) hgt1000_febC2_e2 (0.37)
Marzo	sst_marC1_e1 (0.55) u200_marC1_e2 (-0.46) hgt1000_marC1_e2 (0.43)	u200_marC2_e2-1 (-0.50) u200_marC2_e2-2 (0.46)

Tabla 3-3. Listado de los indicadores generales y particulares seleccionados para conformar los sets de predictores de cada mes y cada cluster en el proceso de conformación de los modelos estadísticos de predicción. La nomenclatura de los predictores incluye la variable a partir de la cual se definen, el cluster y mes de precipitación al cual anteceden, y el esquema al cual pertenecen. Todos los predictores están estadísticamente correlacionados con la precipitación al 95% de confianza ($|r| > 0.33$).

3.3. Esquemas conceptuales de influencia de la precipitación

A continuación, se describen algunos esquemas conceptuales que vinculan a la precipitación areal mensual de cada cluster con los predictores observados en el mes previo y seleccionados para la construcción de los modelos estadísticos (Tabla 3-3). Estos esquemas agrupan predictores y resumen posibles procesos físicos explicativos de la variabilidad interanual de la precipitación en la CRB, pero no representan mecanismos dinámicos exclusivos de generación de condiciones más húmedas o secas en la región de estudio. Asimismo, los cuatro esquemas que se describen no incluyen necesariamente mecanismos independientes entre sí, sino que agrupan a los predictores en función del mecanismo físico que, al menos en parte, lo explica y de este modo se asegura que la correlación significativa no es casual, sino que responde a una causa física. Todos los predictores que se mencionan a continuación presentan una correlación estadísticamente significativa desfasada en un mes con la precipitación (95% de confianza según un test T-Student).

- **Esquema 1 - Variabilidad en latitudes bajas de los océanos Pacífico e Índico**

Se incluyen los predictores vinculados directamente (basados en la SST tropical) o indirectamente (basados en la SST, altura geopotencial, o viento zonal de latitudes extratropicales) a la dinámica del ENSO, la PDO, el IOBW y el DOI (Figura 3-21, Tabla 3-4). Estos predictores reflejan características típicamente vinculadas a los modos de variabilidad de latitudes bajas en los océanos Pacífico e Índico: la estructura espacial de las SST en dichas cuencas oceánicas, la variabilidad en la intensidad del AP, la generación de un tren de ondas de latitudes medias en niveles altos, y la intensificación/debilitamiento del jet subtropical sobre el océano Pacífico (Zhou y Lau, 2001; Taschetto y Ambrizzi, 2012; Sena y Magnusdottir, 2021; entre otros). La Tabla 3-4 muestra que este conjunto de predictores deja una señal sobre la precipitación del cluster 1 entre noviembre y marzo, mientras que en el cluster 2 dicha influencia predomina entre octubre y enero. Sobre el cluster 2, la precipitación se ve favorecida (inhibida) en el mes siguiente a la ocurrencia de anomalías cálidas (frías) de SST en las cuencas oceánicas, en concordancia con lo hallado en trabajos previos para el sudeste de Sudamérica (Grimm,

2003; Vera et al., 2004; Barreiro, 2010; Cai et al., 2020; Reboita et al., 2021; entre otros). En particular, los predictores vinculados al ENSO predominan en primavera. En el cluster 1 se evidencian algunas diferencias respecto al sector anterior. En primer lugar, existe cierta señal del Pacífico sobre la precipitación hacia fines del verano, pero en este caso es el enfriamiento anómalo en el Pacífico tropical quien favorece mayores acumulados de precipitación. En segundo lugar, el predictor *sst_novC1_e1* referido a la SST en el Índico tropical sugiere que el enfriamiento anómalo en esta región precede a anomalías positivas de precipitación de noviembre en el cluster 1. Si bien la influencia del IOBW como respuesta a la evolución del ENSO se observa más hacia fines de verano y en el otoño austral (Taschetto y Ambrizzi, 2012), la relación entre el predictor *sst_novC1_e1* en octubre y la precipitación en noviembre ($r = -0.48$) mejora al remover la influencia del ENSO mediante el cálculo de una correlación parcial ($r_{parcial} = -0.61$), lo que sugiere que este predictor podría aportar predictibilidad sobre la precipitación de noviembre en el cluster 1 ante casos de ENSO neutral.




Figura 3-21. Predictores del Esquema 1 (Variabilidad en latitudes bajas de los océanos Pacífico e Índico). En contorno llenos violeta (contornos intermitentes verde) se muestra la ubicación aproximada de los predictores que presentan una correlación estadísticamente significativa positiva (negativa) con la precipitación en el mes posterior para el **a)** cluster 1 y **b)** cluster 2.


Mes	Cluster 1	Cluster 2
Octubre		hgt1000_octC2_el
Noviembre	u200_novC1_el sst_novC1_el	sst_novC2_el
Diciembre	sst_dicC1_el	hgt1000_dicC2_el
Enero	hgt200_eneC1_el	sst_eneC2_el
Febrero	sst_febC1_el	
Marzo	sst_marC1_el	

Tabla 3-4. Listado de los predictores vinculados al Esquema 1, discriminados por mes de influencia (es decir, mes donde se observa un efecto sobre la precipitación) y cluster. En letra imprenta (cursiva) se indica cuando el predictor se asocia fundamentalmente a la variabilidad de la SST en el océano Pacífico (Índico). En rojo (azul) se indica si condiciones más húmedas (secas) en la región de estudio se asocian a la fase de calentamiento en latitudes bajas del Índico o Pacífico.

- **Esquema 2 - Trenes de onda extratropicales – Circulación hemisférica**

Se incluyen los predictores que reflejan la acción de un tren de ondas en el hemisferio sur (Figura 3-22). Estos predictores refieren a la posición de anomalías de altura geopotencial en distintos niveles verticales de la atmósfera, así como del viento zonal en niveles altos (200 hPa). Si bien la influencia de los modos de variabilidad del Esquema 1 sobre la precipitación en Sudamérica subtropical se explica mayormente por trenes de onda de Rossby, los predictores que forman parte de este grupo no están estadísticamente relacionados con los indicadores generales EN3.4, PDO, IOBW, DOI. Esto puede deberse a que la activación de los trenes de onda se da en ubicaciones que no están siendo completamente representadas por estos indicadores generales, o bien porque los predictores hallados responden a modos de variabilidad de otras escalas temporales, como la MJO.

a)



b)




Figura 3-22. Análogo a Figura 3-21 para los predictores del Esquema 2 (Trenes de onda extratropicales – Circulación hemisférica).

A modo de ejemplo, las Figuras 3-23 y 3-24 muestran la estructura de las anomalías observadas en distintas variables de gran escala ante los casos en los que el predictor hgt500_dicC1_e2 se encuentra en fase positiva (superior al segundo tercil) y negativa (inferior al primer tercil), así como su diferencia. Debido a que el predictor hgt500_dicC1_e2 se correlaciona negativamente con la precipitación, la fase negativa (positiva) del predictor en noviembre tendería a preceder a anomalías positivas (negativas) de precipitación en diciembre en el cluster 1. La Figura 3-23 muestra la composición de anomalías de altura geopotencial en niveles altos que se observa en forma simultánea a la ocurrencia del predictor hgt500_dicC1_e2 en fases negativa (primera fila) y positiva (segunda fila). Se destaca la presencia de un tren de ondas de latitudes medias en niveles altos que ingresa desde el sudoeste a Sudamérica, y cuyo desfase varía según si el predictor se encuentra en fase negativa (Figura 3-23, fila superior) o positiva (Figura 3-23, fila intermedia). Esto implica que el predictor hgt500_dicC1_e2 funciona como indicador de la presencia de un tren de ondas que antecede a la ocurrencia de la precipitación. En líneas generales, los predictores que forman parte del Esquema 2 se asocian a la estructura de un tren de ondas sobre el océano Pacífico que ingresa a Sudamérica en latitudes medias, como se muestra para el ejemplo del predictor hgt500_dicC1_e2 (Figura 3-23).

Además, en la Figura 3-24 se muestra la estructura espacial de las anomalías de viento en niveles altos (Figura 3-24a) y de transporte de humedad y agua precipitable (Figura 3-24b) observadas en simultáneo a la precipitación, bajo los casos de hgt500_dicC1_e2 en fase negativa (primera columna), fase positiva (segunda columna) y su diferencia. Nuevamente, debido a que el predictor hgt500_dicC1_e2 se correlaciona negativamente con la precipitación, la fase negativa (positiva) del mismo se vincula a anomalías positivas (negativas) de precipitación en diciembre en el cluster 1. En el caso de los meses donde se favorece la precipitación (Figura 3-24a, primera columna), el predictor hgt500_dicC1_e2 se vincula a la presencia de un giro anticiclónico del viento de niveles altos sobre latitudes subtropicales de Sudamérica y el océano Atlántico, en conjunto con un giro ciclónico del viento en latitudes medias, y sobre el este de Brasil y el océano Atlántico tropical; lo opuesto se observa en los meses en los cuales se inhibe la precipitación (Figura 3-24a, segunda columna). Por otro lado, en la Figura 3-24b se destaca cómo es la estructura del transporte y el contenido de humedad, en simultáneo a la precipitación. En los casos en los cuales el predictor favorece la precipitación (Figura

3-24b, primera columna), se observa un fortalecimiento del transporte de humedad desde el noroeste en capas bajas hacia el norte argentino, con anomalías positivas de agua precipitable en el este de Bolivia, Paraguay, y norte argentino; lo opuesto ocurre en los casos en los cuales el predictor `hgt500_dicC1_e2` inhibe la precipitación (Figura 3-24b, segunda columna). La estructura de las anomalías del viento en niveles altos, y del transporte y contenido de humedad vinculados al predictor `hgt500_dicC1_e2` (Figura 3-24) también se observa en los demás predictores agrupados bajo este Esquema.

Anom hgt 200 hPa (mvp) - Noviembre





Figura 3-23. Campos de composición de anomalía de altura geopotencial en 200 hPa en noviembre (sombreado), en simultáneo a los casos del predictor `hgt500_dicC1_e2` en noviembre con fase negativa (**primera fila**), positiva (**segunda fila**) y diferencia (**tercera fila**). La **primera (segunda) fila** corresponde a situaciones en las cuales se favorece (inhibe) la precipitación en el cluster 1 en diciembre.

a)

Anom Viento 200 hPa (vect, m s^{-1}) - Diciembre



b)

Anom qViento 850 hPa (vect, $\text{g kg}^{-1} \text{ m s}^{-1}$) Diciembre




Figura 3-24. Campos de composición de anomalía de **a)** viento en 200 hPa en diciembre, **b)** anomalía de transporte de humedad en 850 hPa (vectores) y anomalía de agua precipitable (sombreado) en diciembre, sucediendo a los casos del predictor `hgt500_dicC1_e2` en noviembre con fase negativa (**primera columna**), positiva (**segunda columna**) y diferencia (**tercera columna**). La **primera (segunda)** columna corresponde a situaciones donde la precipitación del cluster 1 en diciembre se vería favorecida (inhibida).

La disposición espacial de las anomalías de altura geopotencial en niveles altos sobre Sudamérica (Figura 3-23) fue identificada en trabajos previos en relación a los modos PSA como disparadora del dipolo de precipitación entre la Cuenca del Plata y la SACZ durante la temporada cálida a nivel intraestacional (Carvalho et al., 2004; Liebmann et al., 2004a; Solman y Orlanski, 2010; Carvalho et al., 2011). Asimismo, el SAM puede actuar en conjunto con la acción de la estructura de ondas tipo PSA para reforzar anomalías de precipitación en ciertos sectores de Sudamérica durante el verano austral. En particular, una fase negativa del SAM se vincula a un desplazamiento hacia el norte más marcado de los sistemas ciclónicos, y tiende a favorecer el flujo de humedad hacia el norte argentino en detrimento de las anomalías de precipitación en la zona de la SACZ (Vasconcellos y Cavalcanti, 2010; Andrade y Cavalcanti, 2018; Reboita et al., 2021). En este sentido, el Esquema 2 también incluye a predictores que preceden a la generación de un patrón espacial de anomalías de altura geopotencial tipo SAM en la región de Sudamérica y océanos adyacentes. Es importante destacar que, si bien el patrón de ondas que favorece condiciones más húmedas en latitudes subtropicales al este de los Andes fue hallado en la literatura a partir del estudio de campos diarios de circulación y precipitación, existe la posibilidad de que dicha señal se vea asociada a los predictores mensuales si se presentó con particular intensidad o frecuencia durante el mes.

- **Esquema 3 - Anticiclón semipermanente del océano Atlántico**

Se incluyen los predictores que reflejan la variabilidad en la influencia del AA (Figura 3-25). En la Cuenca del Plata, a la cual pertenece la CRB, cerca de un 17% de la precipitación entre diciembre y febrero se debe a la contribución de humedad por parte del océano Atlántico sur, especialmente de latitudes tropicales y subtropicales. Por otro lado, aproximadamente un 60% de la precipitación proviene de latitudes bajas del continente, con un 28% de dicha contribución debida al reciclado local de vapor (Leyba et al., 2023). El AA funciona como parte del mecanismo de transporte de la humedad hacia el norte argentino, por lo que su variabilidad puede inducir cambios en la precipitación de la región de estudio.




Figura 3-25. Análogo a Figura 3-21 para los predictores del Esquema 3 (Anticiclón semipermanente del océano Atlántico).

Previamente, se encontró que un corrimiento hacia el norte del AA se asocia a primaveras más húmedas que lo normal, particularmente en el cluster 2 (Figura 3-12). Sin embargo, esta influencia decae en OND al considerar al indicador general AALAT como predictor desfasado de la precipitación (Figura 3-17). En cambio, se destaca que valores más bajos de AALAT (AA desplazada hacia el sur) podría anteceder a valores más altos de precipitación en febrero, particularmente en el cluster 1. En este sentido, los predictores sst_febC1_e3, u850_febC1_e3, y sst_febC2_e3 reflejan dicho comportamiento en relación a la precipitación de febrero (Figura 3-25). La Figura 3-26 muestra la estructura de las anomalías de altura geopotencial en 1000 hPa durante enero (mes previo a la precipitación), así como las anomalías en el transporte de humedad en 850 hPa y en el agua precipitable para febrero en relación al predictor sst_febC1_e3 en fase positiva (mayor al segundo tercil), negativa (menor al primer tercil) y su diferencia. Este predictor presenta una correlación desfasada positiva con la precipitación, lo que indica que anomalías cálidas (frías) de SST en el Atlántico de latitudes medias preceden a mayores (menores) acumulados de precipitación en el cluster 1. Cuando el predictor se encuentra en fase positiva en enero, es decir favoreciendo la precipitación en el mes posterior, se observan anomalías positivas de altura geopotencial en niveles bajos en latitudes medias


del océano Atlántico sur, consistente con un corrimiento hacia el sur del AA (Figura 3-26a, primera columna). A su vez, estos casos se asocian a un incremento en el transporte de humedad al este de los Andes dirigido hacia el norte argentino, así como un aumento en el agua precipitable en febrero. Además del aporte de humedad a través del flujo del noroeste, se observa una contribución del transporte desde el Atlántico subtropical, que refuerza la convergencia de humedad en el norte argentino (Figura 3-26b, primera columna). La situación se revierte para los casos de predictor en fase negativa, es decir, en los casos en los cuales la precipitación de febrero se ve desfavorecida (Figura 3-26, segunda columna). Esta estructura de anomalías es análoga para el predictor *sst_febC2_e3*. Por otro lado, el predictor *u850_febC1_e3* referido al viento zonal en latitudes bajas de Sudamérica se encuentra relacionado en forma directa con la precipitación de febrero del cluster 1, y además está significativamente correlacionado con el indicador AALAT de manera indirecta ($r = -0.62$). Esto sugiere que el predictor *u850_febC1_e3* es otro posible indicador de la influencia de los desplazamientos meridionales del AA sobre la variabilidad interanual de la precipitación de febrero.

Los predictores *u850_dicC1_e3* y *hgt1000_eneC2_e3* refieren al viento zonal y la altura geopotencial en capas bajas en Sudamérica tropical (Figura 3-25), y se asocian a cambios en la precipitación de diciembre y de enero respectivamente, cuando el SAMS ya se encuentra activo en el continente. Estos predictores reflejan principalmente la variabilidad en la circulación sobre el sector noroeste del AA: tanto anomalías de viento zonal del este (oeste) en 850 hPa como anomalías anticiclónicas (ciclónicas) en 1000 hPa sobre latitudes bajas de Sudamérica centro-este precede a meses con mayor (menor) precipitación acumulada. A modo de ejemplo, la Figura 3-27 muestra la estructura de las anomalías en el transporte de humedad en 850 hPa y en el agua precipitable para enero en relación al predictor *hgt1000_eneC2_e3* en fase positiva (mayor al segundo tercil), negativa (menor al primer tercil) y su diferencia. Este predictor está directamente correlacionado con la precipitación de enero del cluster 2. Puede observarse que ante la presencia de anomalías anticiclónicas en latitudes bajas del continente en diciembre, es decir cuando el predictor favorece la precipitación en el enero siguiente, existe un incremento en el transporte de humedad por los alisios y por el flujo del noroeste, coincidente con anomalías positivas en el agua precipitable en el este de Bolivia, Paraguay, sur de Brasil y centro-este de Argentina subtropical; lo opuesto ocurre bajo la fase negativa del predictor, en la cual además se destaca el dipolo en el contenido de

humedad entre la región de la SACZ y el norte argentino. El predictor $u850_dicC1_e3$ muestra un comportamiento similar en la región para la precipitación de diciembre, aunque con anomalías de agua precipitable más acotadas al sector argentino subtropical (Figura no mostrada).

a)

Anom hgt 1000 hPa (m) - Enero



b)

Anom qV_{850} hPa (vect, $g\ kg^{-1}\ m\ s^{-1}$) y Anom tcwv (somb, $kg\ m^{-2}$) - Febrero




Figura 3-26. Campos de composición de anomalía de **a)** altura geopotencial en 1000 hPa en enero, **b)** anomalía de transporte de humedad en 850 hPa (vectores) y anomalía agua precipitable (sombreado) en febrero, sucediendo a los casos del predictor sst_febC1_e3 en enero con fase positiva (primera columna), negativa (segunda columna) y diferencia (tercera columna). La primera (segunda) columna corresponde a situaciones donde la precipitación del cluster 1 en febrero se vería favorecida (inhibida).




Figura 3-27. Campos de composición de anomalía de transporte de humedad en 850 hPa (vectores) y agua precipitable (sombreado) en enero, sucediendo a los casos del predictor *hgt1000_eneC2_e3* en diciembre con fase positiva (**primera columna**), negativa (**segunda columna**) y diferencia (**tercera columna**). La **primera (segunda)** columna corresponde a situaciones donde la precipitación del cluster 2 en enero se vería favorecida (inhibida).

• Esquema 4 – SAMS

Se incluyen los predictores vinculados a la evolución de la convección en Sudamérica (*u850_octC1_e4*, *u200_octC1_e4*, *v850_octC2_e4* y *posOLRSE_octC2_e4* para la precipitación de octubre) y la distribución de humedad (*tcwv_dicC2_e4* para la precipitación de diciembre) (Figura 3-28).

En el primer caso, los predictores son observados en el mes de septiembre, cuando el avance de la ITCZ en dirección noroeste-sudeste sobre latitudes bajas de Sudamérica se está desarrollando previo a la activación del SAMS. La fecha de inicio u *onset* del SAMS depende de la variable usada para su definición y el sector de Sudamérica que se analice, y presenta variabilidad interanual (Silva y Kousky, 2012; Gan et al., 2004; Gan et al., 2005; Carvalho y Cavalcanti, 2016). Marengo et al. (2001) emplearon un criterio basado en la tasa de precipitación diaria y encontraron que la fecha de onset ocurre alrededor de la péntada centrada el 25 de septiembre en el Amazonas central, favorecida por alisios del este intensos y un giro anticiclónico del viento en latitudes tropicales del continente. Gan et al. (2005) construyeron cuatro indicadores basados en la evolución de las componentes

zonal y meridional del viento en distintos niveles, y encontraron que la fecha de onset se ubica entre mediados de octubre y principios de noviembre para el centro-oeste de Brasil (10°S-20°S; 50°O-60°O), donde el incremento en el transporte de vapor es necesario para la activación del SAMS. Da Silva y Carvalho (2007) aplicaron la técnica de Funciones Ortogonales Empíricas Combinadas sobre la precipitación, temperatura, humedad específica, y componentes del viento en 850 hPa para obtener el índice denominado *Large-scale Index for South American Monsoon* (LISAM), representativo de la dinámica del SAMS en Sudamérica tropical y subtropical oriental. Mediante el LISAM identificaron el onset promedio del SAMS en la péntada centrada el 30 de octubre. González y Barros (2002) plantearon que la aparición prematura de la convección en la región en la que posteriormente se desarrollará la SACZ se vincula a una activación temprana del SAMS.




Figura 3-28. Análogo a Figura 3-21 para los predictores del Esquema 4 (SAMS).




Figura 3-29. Campos de composición de anomalía de OLR (sombreado) en septiembre, en simultáneo a los casos del `u850_octC1_e4` en septiembre con fase negativa (**primera columna**), positiva (**segunda columna**) y diferencia (**tercera columna**). La **primera (segunda) columna** corresponde a situaciones donde la precipitación del cluster 1 en octubre se vería favorecida (inhibida).

En este caso, el predictor `u850_octC1_e4` (Figura 3-28) hace referencia a que anomalías de viento zonal del este (oeste) en niveles bajos sobre la región tropical del Atlántico norte en septiembre precede a octubres más (menos) precipitantes en el cluster 1. Por otro lado, un debilitamiento (incremento) del viento del oeste en niveles altos en la región el predictor `u200_octC1_e4` sobre el Pacífico subtropical oriental y norte de Chile y Argentina (Figura 3-28) antecede a mayores (menores) acumulados en octubre. A modo de ejemplo, la Figura 3-29 muestra la composición de anomalías de OLR observadas en septiembre al mismo tiempo que el predictor `u850_octC1_e4` se encuentra en fase negativa (es decir, asociada a condiciones más precipitantes en octubre en el cluster 1), positiva (inhibidora de la precipitación posterior), y su diferencia. Se puede observar que cuando el predictor se encuentra en fase negativa, las anomalías de OLR en la región central de Sudamérica son negativas, es decir indicativas de convección favorecida (debilitada). En particular, presenta una relación estadísticamente significativa al 95% de confianza con los indicadores generales OLRN y OLRC ($r = 0.48$ y $r = 0.54$, respectivamente), sugiriendo que podría existir una activación temprana (tardía) del SAMS cuando el predictor presenta anomalías negativas (positivas). Resultados similares se hallaron para el predictor `u200_octC1_e4`.

Por otro lado, los indicadores `v850_octC2_e4` y `posOLRSE_octC2_e4` para la precipitación de octubre en el cluster 2 refieren al viento meridional en capas bajas y a la posición latitudinal de la máxima convección sobre la costa este de Brasil, respectivamente (Figura 3-28). Ambos predictores se asocian directamente con la precipitación observada en el mes posterior, con lo cual anomalías del sur (norte) en 850 hPa sobre el sur de Brasil y este de Paraguay y Bolivia en septiembre se vinculan a anomalías positivas (negativas) de precipitación en el mes siguiente. Análogamente, si la convección se desplaza más al norte (sur) de su posición media sobre la costa este de Brasil, la precipitación posterior se ve favorecida (inhibida). Estos predictores podrían ser indicativos de un desarrollo temprano de la convección monzónica. A modo de ejemplo, siguiendo el caso del predictor `v850_octC2_e4`, la Figura 3-30 muestra la estructura espacial de las anomalías de altura geopotencial en niveles altos en septiembre, es decir, en simultáneo a la ocurrencia del predictor. El patrón de anomalías de altura geopotencial observado en simultáneo a la ocurrencia de fase positiva (favorecedora de precipitación) y negativa (inhibidora de precipitación) de `v850_octC2_e4` es opuesto a la estructura observada anteriormente en el caso de un tren de ondas sobre el continente (Esquema 2, Figura 3-23). Si bien hacia septiembre todavía no se observa desarrollada la estructura de la SACZ, esto podría sugerir que anomalías positivas (negativas) de `v850_octC2_e4` se asocian a una dinámica en niveles altos que favorece la convección en el este de Brasil y que, por lo tanto, fomenta la activación temprana del SAMS. Este predictor está correlacionado significativamente e indirectamente con los indicadores generales OLRN y OLRC en forma simultánea ($r = -0.49$ y $r = -0.36$, respectivamente), es decir que valores de `v850_octC2_e4` que favorecen la precipitación de octubre en el cluster 2 (valores positivos del predictor) también se asocian a un mayor desarrollo convectivo en el norte y centro de Brasil durante septiembre (valores negativos de OLRN y OLRC). Análogamente, el predictor `posOLRSE_octC2_e4` se vincula indirectamente con los indicadores OLRC y OLRSE ($r = -0.48$ y $r = -0.45$, respectivamente) es decir que un corrimiento hacia el norte (sur) de la convección en la costa brasilera se asocia a su vez a un fortalecimiento (debilitamiento) de la convección en el centro y este de Brasil.

Anom AltGeo 200 hPa (mvp) - Septiembre




Figura 3-30. Campos de composición de anomalía de altura geopotencial en 200 hPa (sombreado) en septiembre, en simultáneo a los casos del predictor v850_octC2_e4 en septiembre con fase positiva (primera columna), negativa (segunda columna) y diferencia (tercera columna). La primera (segunda) columna corresponde a situaciones donde la precipitación del cluster 2 en octubre se vería favorecida (inhibida).

Finalmente, el predictor tcwv_dicC2_e4 se localiza en latitudes ecuatoriales de Sudamérica oriental (Figura 3-28), y refiere a la distribución de agua precipitable una vez activado el SAMS para la predicción de la precipitación en diciembre en el cluster 2. Este predictor presenta una correlación desfasada negativa con la precipitación. La Figura 3-31 muestra la estructura espacial de las anomalías de agua precipitable en noviembre, donde se puede observar que cuando tcwv_dicC2_e4 se encuentra en fase negativa (favorecedora de la precipitación en el mes siguiente) se evidencia un dipolo meridional en el contenido de humedad en Sudamérica, con anomalías positivas de agua precipitable en el este de Bolivia, sur de Brasil, y centro-este de Argentina subtropical; el comportamiento opuesto se destaca cuando tcwv_dicC2_e4 se encuentra en fase positiva. Por lo tanto, este predictor indica si existe un apartamiento en el contenido de humedad disponible localmente previo al mes objetivo de la precipitación.




Figura 3-31. Campos de composición de anomalía de agua precipitable (sombreado) en noviembre, en simultáneo a los casos del predictor tcwv_dicC2_e4 en noviembre con fase positiva (primera columna), negativa (segunda columna) y diferencia (tercera columna). La primera (segunda) columna corresponde a situaciones donde la precipitación del cluster 2 en diciembre se vería favorecida (inhibida).

3.3. Síntesis

En este capítulo se estudió la relación, tanto simultánea como desfasada un mes, entre la precipitación estival en el norte argentino y distintas fuentes de variabilidad regionales y remotas. Para ello, se emplearon una serie de indicadores preestablecidos (denominados *generales*), así como indicadores diseñados específicamente para incrementar las fuentes de predictibilidad de la precipitación en cada mes y para cada cluster (denominados *particulares*). Los indicadores fueron seleccionados en base al método de regularización LASSO, evitando la multicolinealidad, y evaluando potenciales causas físicas. En particular, se destacaron cuatro grandes grupos de predictores.

En primer lugar, se identificaron predictores vinculados a los modos de variabilidad de SST en los océanos Pacífico e Índico. Se destaca que la presencia del ENSO en fase cálida se vincula a condiciones más húmedas en forma simultánea y desfasada en la primavera para toda la región, pero particularmente en el cluster 2. En el cluster 1 la situación se

revierte en el verano, cuando condiciones más húmedas se observan ante un enfriamiento anómalo del Pacífico tropical central. En segundo lugar, se identificaron predictores que señalan la presencia de un tren de ondas de latitudes medias. Estos predictores predominan en el verano, particularmente favoreciendo un dipolo de precipitación entre el norte argentino y la región de la SACZ. En tercer lugar, se identificaron predictores asociados a la variabilidad en la circulación dada por el AA, especialmente en términos de desplazamiento meridional durante el verano (condiciones más húmedas vinculadas a previo desplazamiento hacia el sur), y de cambios de intensidad en el sector noroeste del AA a fines de primavera e inicios de verano que modifican el transporte de humedad desde el noroeste hacia la región de estudio. Finalmente, se identificaron predictores que sugieren que una activación temprana del SAMS podría posteriormente favorecer condiciones más húmedas en el norte argentino.

Si bien existen diferencias en la zona de definición de los predictores y en las variables empleadas según el cluster que se analice, en líneas generales se sugieren mecanismos precipitantes similares en ambos casos. La mayor diferencia entre clusters se observa en términos de la influencia del Pacífico tropical en el verano, que genera distintos impactos según la fase. Asimismo, en forma simultánea existe una influencia opuesta de la posición de la máxima convección en el este de Brasil sobre las condiciones hídricas de ambos clusters. Sin embargo, en términos de predictibilidad a mediano plazo de la precipitación mensual, esta influencia no se destacó y se observó que ambos clusters responden con mayor precipitación cuando la convección en la región promedio de la SACZ se ve inhibida.

Capítulo 4

Hacia la generación de esquemas de predicción: modelado estadístico

A partir de los predictores hallados en el Capítulo 3, en el presente Capítulo se detallará la confección de los modelos estadísticos para la previsión de la precipitación mensual areal durante el semestre estival en la CRB. En primer lugar, se presenta una síntesis de las metodologías de modelado empleadas en este estudio. Luego, se detalla para los datos con los que se cuenta cómo se aplicaron estas metodologías, incluyendo el uso de la validación cruzada de un elemento. Finalmente, se realiza una evaluación de métricas de desempeño determinísticas.

4.1. Modelado estadístico

Dentro del área de la previsión del tiempo y del clima, la estadística ha jugado un rol muy relevante. Además de proveer conceptos necesarios para el desarrollo de métricas de evaluación de pronósticos, las técnicas estadísticas se emplean en el proceso de inicialización de modelos de pronóstico dinámicos (McLaughlin, 2002; Denby et al., 2008; entre otros), en combinación con modelado dinámico para incrementar su habilidad y remover potenciales sesgos (Widmann et al., 2003; Haerter et al., 2011; Cionni et al., 2022; Olmo et al., 2022; Balmaceda-Huarte et al., 2024; entre otros), y para realizar pronósticos de condiciones futuras independientemente de otras herramientas de modelado dinámico (Zwiers y von Storch, 2004; Ayala et al., 2021; Collazo et al., 2022; González et al., 2023; entre otros). En particular, el modelado estadístico o empírico para la previsión de condiciones medias de variables climáticas en escala estacional es utilizado ampliamente junto a esquemas dinámicos en procesos de toma decisión por su buena habilidad de previsión a la vez que su bajo costo computacional (Osman et al.,

2023). Sin embargo, en escala subestacional (entre dos semanas a una temporada) existe una brecha en los productos de pronóstico desarrollados, debido en parte a la dificultad en la predictibilidad de esa escala temporal (Mariotti et al., 2018).

El modelado empírico se basa en el *aprendizaje estadístico* de patrones con el objetivo de comprender procesos o, como es el propósito de este estudio, pronosticar una variable objetivo. Las herramientas de aprendizaje estadístico pueden dividirse en dos grandes grupos: aprendizaje *supervisado* y *no supervisado*. En el primer grupo se concentran las técnicas enfocadas en construir esquemas estadísticos que permitan estimar o pronosticar una variable predictando o *output* partiendo de un conjunto de variables explicativas o *input*. En este caso, las tareas de verificación de desempeño consisten en evaluar la habilidad de los modelos obtenidos en representar la evolución de la variable conocida de interés. Por otro lado, las técnicas de aprendizaje no supervisado cuentan con variables input, pero no existe una variable objetivo a la cual representar. Su objetivo es lograr encontrar estructuras y relaciones subyacentes en los datos, como por ejemplo sucede para la técnica de clusterización de *k*-means (McQueen, 1967).

El modelado estadístico para la previsión a mediano plazo de variables climáticas forma parte de las técnicas de aprendizaje supervisado. En este caso, partiendo de las variables predictoras $X = (X_1, X_2, \dots, X_p)$ y con una variable objetivo Y , se puede decir que existe una relación del tipo:

$$Y = f(X) + \epsilon \quad (4.1)$$

La ecuación (4.1) muestra que existe un vínculo entre las p variables predictoras y la variable output Y , representado por una función denominada f , a priori desconocida. El término ϵ representa al error, que es independiente de los predictores y cuyo promedio es nulo. En particular, el objetivo es poder estimar la expresión de la función f para poder inferir de la manera más fiel posible el valor que tomará la variable de respuesta. Esto implica que, si la estimación de f es $\hat{f}$, se puede aproximar el valor de la variable de respuesta Y conociendo los valores de las p predictoras de la forma:

$$\hat{Y} = \hat{f}(X) \sim Y \quad (4.2)$$

La estimación $\hat{Y}$ no es idénticamente igual a Y , sino que la precisión al representar al output depende de un error reducible, ligado a la elección de la técnica estadística que genera a $\hat{f}$, y un error irreducible. Éste último depende fuertemente del error ϵ que, al ser independiente de X , no puede ser mejorado incluso aunque se tenga una estimación perfecta de f (James et al., 2013).

Adicionalmente, la búsqueda de un modelo predictivo eficiente trae aparejada la problemática del compromiso sesgo-varianza. El error de un esquema predictivo sobre una muestra independiente (error de testeo) puede ser disgregado en tres componentes aditivas: la varianza del modelo, el sesgo del modelo (elevado al cuadrado), y la varianza del error irreducible. Las dos primeras componentes son las que pueden variar según la elección y construcción del método predictivo: para minimizar el error de testeo se debe trabajar con una técnica de aprendizaje estadístico que tenga bajo sesgo y baja varianza. El sesgo aumenta cuando se intenta aproximar un problema complejo con un modelo excesivamente simple. Por otro lado, la varianza aumenta cuando pequeños cambios en los datos usados para entrenar a los modelos provocan grandes cambios en el esquema predictivo, lo cual típicamente se condice con modelos de alta complejidad (James et al., 2013). El error de testeo también es conocido como *error de generalización* en la teoría del aprendizaje estadístico, pues refleja el desempeño de los modelos en datos no empleados para su construcción. Típicamente, el sesgo disminuye a medida que aumenta la complejidad del modelo, y lo opuesto ocurre con la varianza. Por esta razón, para reducir el error de generalización se debe seleccionar un esquema que tenga un nivel de complejidad intermedio que permita balancear ambas fuentes de error, de forma de disminuir el sesgo sin aumentar sensiblemente la varianza, y viceversa. Sin embargo, con el advenimiento de técnicas poderosas de aprendizaje automático, este compromiso sesgo-varianza está siendo reevaluado. Esto se debe a que para modelos altamente sobreparametrizados, es decir altamente complejos, se ha encontrado que el error de testeo disminuye en lugar de aumentar (Belkin et al., 2019; Dar et al., 2021). Independientemente de los avances en la teoría del error, queda manifiesto que hallar la complejidad adecuada, y por lo tanto el modelo adecuado, no es una tarea trivial en la búsqueda de un buen pronóstico.

En este estudio, se pretende generar un conjunto de modelos estadísticos para la predicción a mediano plazo de la precipitación mensual en ambos clusters de la CRB. Las variables input que participan en la generación de los modelos corresponden a los

conjuntos de predictores que fueron seleccionados en el Capítulo 3. Dado que estos predictores fueron definidos en base a variables observadas anteriormente al mes objetivo de pronóstico, existe un desfase temporal entre los inputs y el output que añade el carácter de *predicción* (Mason y Baddour, 2008). A modo de ejemplo, conociendo el valor promedio de los predictores *sst_novC2_e1* y *hgt200_novC2_e2* durante el mes de octubre en el año de interés, se podría brindar una estimación cuantitativa de la precipitación mensual en el cluster 2 de la CRB para el mes de noviembre siguiente. Para poder llegar a una predicción a través del aprendizaje estadístico, se debe estimar la forma de la función f que vincula a predictores y predictando. Para ello, se emplea un conjunto de datos denominado *muestra de entrenamiento*. A continuación, se describen las metodologías de modelado estadístico que han sido seleccionadas en este estudio para ese propósito.

4.1.1. Regresión Lineal Múltiple

La Regresión Lineal Múltiple (RLM) es una de las metodologías más ampliamente usadas para derivar esquemas de predicción de variables climáticas a escala estacional (Mason y Baddour, 2008). El objetivo es estimar cuantitativamente el predictando como una respuesta lineal al valor que toman los predictores. En este sentido, la expresión matemática de dicha relación es:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_p X_p + \epsilon \quad (4.3)$$

donde X_j representa al j -ésimo predictor y β_j cuantifica al vínculo entre el j -ésimo predictor y el predictando. El vínculo dado por el parámetro β_j puede interpretarse como el efecto promedio que tiene un incremento unitario del predictor X_j sobre el predictando si las demás variables predictoras se mantienen fijas. Es por esto que los valores de los parámetros β_j que se obtienen al derivar una única ecuación de RLM para un grupo de inputs, como es el caso de la ecuación (4.3), no son idénticamente iguales a los valores que se obtendrían si se derivaran ecuaciones individuales de relación predictor-predictando para cada input. Los $j+1$ parámetros de la ecuación (4.3) se estiman mediante álgebra matricial minimizando la suma de los cuadrados de los residuos, definidos como

la diferencia entre la predicción $\hat{Y}$ y el valor verdadero Y (Wilks, 2011). Este procedimiento se denomina *búsqueda por cuadrados mínimos*. Al realizar el ajuste es importante considerar si es necesario aplicar un procedimiento para reducir la cantidad de inputs y no incurrir en redundancia de información y potencial sobreajuste. En el Capítulo 3, se aplicó la técnica de regularización LASSO y se removió la colinealidad para sortear esta problemática.

Algunos de los potenciales problemas vinculados al uso de la RLM son (James et al., 2013):

- **Correlación entre los errores y heterocedasticidad:** dentro de las suposiciones que se realizan en la aplicación de la regresión lineal simple ($p = 1$) y múltiple ($p > 1$) están la independencia de los términos de error que acompañan al ajuste, y la homocedasticidad. La correlación entre términos de error puede ocurrir en series temporales que presentan persistencia temporal. Por otro lado, la homocedasticidad refiere a que los errores presentan una varianza constante; de no ocurrir esto, es decir cuando cambia la dispersión de los residuos según el valor de la variable de respuesta, se produce la heterocedasticidad.
- **Outliers:** refiere a las instancias en las que el valor del predictando se aleja atípicamente del conjunto de observaciones restante, de forma que la estimación del output queda alejada del valor verdadero. Este problema suele tener origen en la etapa de recolección de los datos, y puede afectar no solamente a la expresión del modelo de RLM sino también a las métricas de bondad de ajuste.
- **Puntos de gran influencia:** refiere a las instancias en las que el valor del predictor se aleja atípicamente del conjunto de observaciones restante, lo cual puede tener un impacto aún más sustancial en la expresión del ajuste lineal que el punto anterior.
- **Colinealidad:** refiere a la situación en la cual dos o más predictores se relacionan fuertemente entre sí. En el Capítulo 3, este problema fue tratado mediante la remoción de predictores que presentaran una asociación lineal con otro input del conjunto mediante un test T-Student (5% significancia) y la aplicación de la técnica LASSO.

- **No linealidad entre el predictor y la respuesta:** la RLM supone que existe una relación lineal entre los predictores y la respuesta. De no ser así, la precisión en la predicción del predictando puede verse reducida significativamente. En particular, existe evidencia de que en el sistema climático la relación causa-efecto pueden ser no lineal (Taschetto y Ambrizzi, 2012; Frauen et al., 2014; Takahashi y Dewitte, 2016; entre otros). Es por esta razón, que en este estudio se exploraron además alternativas no lineales de aprendizaje estadístico.

4.1.2. Modelos Aditivos Generalizados

Los Modelos Aditivos Generalizados (GAM) fueron introducidos por Hastie y Tibshirani (1986) como una generalización y una extensión de los modelos lineales clásicos. Los modelos GAM admiten la presencia de funciones no lineales, pero mantienen el carácter aditivo de la respuesta que se observa en la RLM. Para permitir la presencia de no linealidad entre los inputs y el output, se reemplaza a los términos lineales $\beta_j X_j$ ($j \neq 0$) de la ecuación (4.3) por una función suave no lineal del tipo $f_j(X_j)$, de forma que la expresión matemática del modelo es:

$$Y = \beta_0 + f_1(X_1) + f_2(X_2) + \dots + f_p(X_p) + \epsilon \quad (4.4)$$

Las funciones f_j , que típicamente se usan en los modelos GAM, son regresiones locales, regresiones polinómicas, o *splines*. Los *splines* son curvas suaves y diferenciables que son ajustadas mediante el algoritmo *backfitting*, enfocado en actualizaciones iterativas del ajuste para cada predictor, a la vez que deja a los demás fijos. Para poder aplicar el ajuste mediante splines es necesario indicar los grados de libertad que se desean para cada función f , lo cual controla a su vez el nivel de suavizado de los splines y la complejidad del modelo.

Como se mencionó anteriormente, los modelos GAM permiten introducir no linealidad en la relación predictores-predictando, evitando tener que considerar aplicar transformaciones de las variables para ampliar el horizonte lineal. Al conservar la característica de aditividad, los modelos que se pueden obtener mediante GAM permiten, al igual que con RLM, evaluar el impacto del cambio en un input sobre la variable

respuesta manteniendo las demás variables fijas. Esto también implica una desventaja, pues no se consideran posibles interacciones entre predictores dado que los efectos son aditivos. Para incorporar estas interacciones es necesario transformar las variables predictoras o incorporar técnicas de ajuste más complejas (James et al., 2013).

Algunos ejemplos de uso de GAM se mencionan a continuación. Yin y Wang (2017) emplearon modelos basados en GAM para la predicción de la cantidad de días con ocurrencia de bruma en el norte de China. Los predictores considerados se basaron en la variación interanual de la SST de otoño en el golfo de Alaska y el área de hielo marino en el mar de Beaufort, así como la cantidad de días con bruma del año previo. Dantas et al. (2020) usaron una variante de GAM para generar predicciones estacionales de precipitación en el estado de Paraíba, localizado en el noreste de Brasil. Encontraron cierta capacidad predictiva de estos modelos al emplear indicadores vinculados a la SST de los océanos Atlántico y Pacífico tropical. Mathivha et al. (2020) generaron modelos para la predicción de condiciones de sequía en el noreste de Sudáfrica, identificadas a través del Índice de Precipitación-Evapotranspiración Estandarizado (IPEE) en distintas escalas temporales. Dentro de los modelos considerados se encontraban el GAM clásico y una variante de GAM que considera la autocorrelación de los errores. Los autores encontraron que los modelos de tipo GAM presentaban mejores errores de testeo comparados a otros modelos, particularmente para el IPEE en escala temporal de 12 meses.

4.1.3. Regresión de Vectores de Soporte

La Regresión de Vectores de Soporte (SVR) es una extensión hacia problemas de regresión de una técnica de clasificación denominada Máquina de Vectores de Soporte (SVM) (Cortes y Vapnik, 1995). En su variante de clasificación, SVM es un algoritmo supervisado que construye el hiperplano óptimo que opera como frontera de clasificación de observaciones. Este hiperplano es el que más alejado se encuentra respecto a las observaciones de entrenamiento, separado de las mismas por una distancia denominada *margen*. Los vectores de soporte son las observaciones que determinan cuál es el hiperplano óptimo, es decir el *hiperplano de margen máximo*. Existen distintas condiciones matemáticas que se pueden establecer para hallar los parámetros que caracterizan al hiperplano óptimo. El detalle de las mismas puede hallarse en Cortes y

Vapnik (1995). En particular, existen flexibilizaciones del algoritmo que permiten la separación imperfecta de las observaciones en favor de una mayor robustez del método. En estos casos donde las clases no son perfectamente separables linealmente, se introduce un umbral de tolerancia de observaciones mal clasificadas a considerar en el ajuste de los parámetros del hiperplano óptimo (Mammone et al., 2009).

La técnica SVR es la variante de SVM empleada como herramienta para los problemas de regresión. En forma análoga a SVM, SVR pretende encontrar los parámetros que describen a la función predictiva óptima. Al igual que en la variante de clasificación, se introduce una región fronteriza alrededor de la función óptima, de forma que la misma presenta una desviación ε respecto al valor observado del predictando en la muestra de entrenamiento. Para ello, se considera al hiperparámetro de costo $C > 0$, que cuantifica la tolerancia que se tendrá durante el ajuste a que ocurran apartamientos de los valores observados más allá del umbral dado por ε . En el caso de aplicar SVR para una función lineal, la expresión del modelo es similar a la de un modelo por RLM clásico (ecuación 4.3), pero en el proceso de búsqueda de los vectores de soporte (es decir, durante el ajuste de los parámetros del modelo de SVR) se considera un término de penalización asociado al umbral de tolerancia impuesto (Smola y Schölkopf, 2004; James et al., 2013).

Además, SVR permite abordar problemas de regresión no lineales. Para ello, se utiliza un operador denominado *kernel*, que transforma las observaciones del espacio original a un nuevo espacio en el que sí es posible aplicar una función lineal. Existen algunos ejemplos de operadores kernel que se pueden emplear, como ser un kernel lineal, polinómico, sigmoidal, radial, entre otros (James et al., 2013). Para poder generar un modelo SVR no lineal, se deben seleccionar el tipo de kernel, el valor de costo C y el valor de umbral dado por ε .

Li et al. (2010) aplicaron una modificación al esquema de SVM para predecir el caudal entrante al reservorio de Shihmen en Taiwán, durante diciembre y enero. Para ello, mediante una correlación lineal, identificaron predictores basados en SST, presión al nivel del mar, y OLR en meses previos. Los autores hallaron que tanto el SVM modificado como el SVM clásico mejoran el desempeño en el pronóstico del caudal respecto a la RLM. Gizaw y Gan (2016) estimaron los cuantiles de inundación regionales en distintos sectores de Canadá basándose en la técnica de SVR, empleando predictores climáticos y fisiográficos. Los autores compararon el desempeño del modelo basado en SVR contra un modelo basado en redes neuronales artificiales, y hallaron que el primero presenta

mejores métricas y capacidad de generalización que el segundo ante una limitada cantidad de datos de entrenamiento. González et al. (2023) emplearon una variedad de técnicas de aprendizaje estadístico para la previsión estacional de la precipitación en la región del Comahue, y hallaron que SVR es la técnica que mayor cantidad de modelos provee con al menos 50% de la varianza de la precipitación explicada.

4.1.4. Redes Neuronales Artificiales

Las Redes Neuronales Artificiales corresponden a un conjunto de técnicas de aprendizaje automático en el campo de la Inteligencia Artificial, ampliamente utilizadas en diferentes áreas del conocimiento en los últimos años (Wu y Feng, 2018). En líneas generales, las redes buscan construir modelos que repliquen las conexiones neuronales del cerebro humano en términos del procesamiento de la información. Las redes pueden procesar distinto tipo de información y, en particular, se emplean en problemas de regresión.

Las redes se componen de un conjunto de *nodos* o *neuronas* interconectadas entre sí siguiendo una arquitectura determinada. Las neuronas se acomodan en capas, y cada neurona recibe señales, las procesa, y las transmite. Esencialmente, las redes pueden dividirse en dos grandes grupos (Wang, 2003; Zhang et al., 2018):

- **Redes multicapa *feedforward*:** consiste de neuronas organizadas en capas, donde cada neurona en una determinada capa está conectada a todas las neuronas de la capa anterior. La relevancia de cada conexión depende del *peso* que se le asigne. La arquitectura de estas redes se caracteriza por una capa de inputs que contiene a todas las variables explicativas o predictoras, una o más *capas ocultas*, y una capa de outputs que contiene tantas neuronas como variables de salida o predictandos existan. La información en este tipo de redes se dirige desde la capa de inputs hacia la capa de outputs, atravesando las capas ocultas en su recorrido.
- **Redes recurrentes:** se distinguen del tipo anterior de redes porque contienen al menos un ciclo de retroalimentación. Para ello, se incorporan *unidades recurrentes*, que contienen información sobre inputs previos en una secuencia con el propósito de reingresarla a la red para el entrenamiento. De esta forma, la red recurrente captura las dependencias temporales, por lo que se dice que este tipo de redes tienen “memoria”.




Figura 4-1. Esquema representativo de una ANN. Se indican la capa de inputs con tres predictores genéricos, dos capas ocultas con distinta cantidad de neuronas, y la capa de salida de la cual se obtiene la predicción sobre el predictando.

En este estudio, se emplearon las redes de tipo multicapa feedforward (de ahora en más, simplemente referidas como ANN). Un ejemplo esquemático de una ANN se muestra en la Figura 4-1, en la que se observa la capa de inputs donde ingresan los predictores, dos capas ocultas compuestas de neuronas (donde las capas no necesariamente presentan la misma cantidad de nodos), y una capa de salida donde se expresa el output. La dimensión de la capa de salida depende de la cantidad de predictandos que tenga el problema. Una vez que se determina la arquitectura deseada, se debe hallar los pesos entre las conexiones. Estos pesos son los parámetros a ajustar en el modelo dado por la ANN, y reflejan el aprendizaje de los patrones subyacentes en la muestra de entrenamiento. La salida z_m de la m -ésima neurona en la primera capa oculta se puede expresar como:

$$z_m = h \left(w_0^{(1)} + \sum_{d=1}^D w_{d,m}^{(1)} x_d \right) \quad (4.5)$$

En la ecuación (4.5) se observa que z_m resulta de aplicar la función h a una combinación lineal de elementos. Dicha función se denomina *función de activación* y su propósito es introducir la no linealidad a la red. El argumento de h contiene a la combinación lineal de los D predictores, notados como x_d , y los pesos $w_{d,m}^{(1)}$ que corresponden a la conexión entre el d -ésimo predictor y la m -ésima neurona en la primera capa oculta. También se incluye en la ecuación (4.5) un término independiente dentro del argumento de h . Esta expresión muestra que la información dada por los inputs se relativiza según determinados pesos y se transforma en la primera capa oculta a través de una función de activación. Dicha información resultante es transmitida para operar como input de las neuronas de la siguiente capa oculta (que puede contener una cantidad distinta de neuronas y otra función de activación), y así sucesivamente hasta llegar al output de la ANN.

El entrenamiento de la ANN tiene el propósito de encontrar los pesos de las conexiones. Esto se realiza mediante un proceso de optimización iterativo, en el cual los pesos se inicializan de forma aleatoria y se van corrigiendo con el objetivo de minimizar una función de pérdida, como por ejemplo el error cuadrático medio de predicción. Esta metodología se denomina *gradiente descendente*. En cada iteración, los pesos son actualizados a una velocidad dada por la *tasa de aprendizaje* (Günther y Fritsch, 2010). Otros hiperparámetros que se deben definir para entrenar a la ANN son la cantidad de *épocas* y los tamaños de *batch*. El primero es la cantidad de veces que la muestra de entrenamiento completa es empleada en el algoritmo de optimización. Por otro lado, un batch es una submuestra de la muestra de entrenamiento que es recorrida por el algoritmo y, al final de la cual, los pesos de la ANN se actualizan. Si el tamaño de batch es igual al tamaño de la muestra de entrenamiento, los pesos son actualizados al finalizar el primer paneo completo de los datos (es decir, al finalizar la primera época). A modo de ejemplo, si se selecciona un tamaño de batch igual a 10 para una muestra de entrenamiento de 500 observaciones, la muestra será dividida en 50 grupos de 10 observaciones cada uno. Al finalizar el algoritmo de gradiente descendente sobre el primer batch, los pesos de la red se actualizarán, y así sucesivamente a medida que se recorren todos los batches y a lo largo de todas las épocas (Brownlee, 2018).

En los últimos años, el avance en la aplicación de redes neuronales para tareas de modelado y pronóstico ha sido muy importante. Aquí sólo se mencionan algunos ejemplos de aplicación de ANN. Mouatadid et al. (2018) evaluaron la habilidad de

modelos basados en la lógica de las redes neuronales para la predicción del IPEE en escalas de 3 y 12 meses en diferentes regiones del este de Australia. Encontraron que el desempeño de este tipo de técnicas supera al de las variantes de RLM y SVR aplicadas por los autores. Todas las técnicas demostraron mejor precisión en el caso del IPEE de 12 meses en comparación al IPEE de 3 meses, lo que asociaron a la alta variabilidad de corto plazo de los procesos hidrológicos vinculados con el IPEE, que pueden resultar desafiantes de representar por las técnicas de aprendizaje automático. Anochi et al. (2021) desarrollaron un sistema de pronóstico basado en Inteligencia Artificial que combina ANN con redes de aprendizaje profundo para la previsión estacional de precipitación en Sudamérica. Los autores utilizaron datos medios mensuales del viento en niveles bajos y medios de la atmósfera, y la temperatura del aire y la humedad específica en niveles bajos como input para el entrenamiento de los esquemas predictivos. Encontraron que los modelos logran reproducir los patrones de precipitación observados, con mayores errores en el verano probablemente debido a la relevancia de procesos locales que las redes no logran aprender eficientemente. Los autores también encontraron mejorías con estas técnicas al compararlas contra el modelo de circulación Brazilian Global Atmospheric Model (BAM) operado por el Instituto Nacional de Pesquisas Espaciais (INPE) de Brasil. Recientemente, Giuliani et al. (2024) desarrollaron una metodología de aprendizaje automático que emplea ANN para la predicción de la precipitación mensual en un área de Países Bajos a partir de variables globales y locales, encontrando resultados prometedores.

4.2. Generación de modelos: estrategia de validación cruzada

Los modelos de naturaleza estadística aprenden los patrones de covariabilidad subyacentes entre predictores y predictando a través de registros pasados. Es por esto que la determinación del período de entrenamiento de los modelos no es trivial. Como se mencionó en el Capítulo 2, en el caso de este estudio se decidió tomar como período de análisis a las temporadas estivales en 1984/1985-2019/2020 para poder tener una óptima cobertura espacial de la CRB mediante estaciones pluviométricas. Por lo tanto, se tiene una muestra de 36 observaciones por mes objetivo dentro del semestre estival. A partir de

esta etapa, considerando que el objetivo final es realizar un pronóstico de la precipitación areal específicamente dentro la CRB, los modelos estadísticos fueron entrenados considerando la serie temporal de precipitación media areal tomando solamente a las estaciones que se encontraran dentro de los límites geográficos de la CRB.

Idealmente, el modelado estadístico depende de la existencia de tres muestras distintivas (Mason y Baddour, 2008; James et al., 2013):

- *muestra de entrenamiento*, la cual sirve de aprendizaje de los modelos y estimación de los coeficientes o parámetros que los modelos requieran.
- *muestra de validación*, sobre la cual se basa el cálculo de los hiperparámetros necesarios para los modelos.
- *muestra de testeo*, independiente de las dos muestras anteriores y sobre la cual se realizan las tareas de evaluación de desempeño de los modelos.

Debido a la acotada longitud del registro con el que se cuenta en la CRB, la problemática de cómo entrenar y verificar los modelos de pronóstico no es menor. Incluso aunque no se tome una muestra de validación y se trabaje con hiperparámetros preasignados, dividir en observaciones de entrenamiento y testeo a la totalidad de los datos implica evaluar los tamaños relativos de ambas muestras, pues aumentar el tamaño de una de ellas necesariamente implica disminuir el tamaño de la otra. Esto resulta en que, o bien el entrenamiento se realiza sobre pocos datos, acotando el aprendizaje de los modelos a un menor cúmulo de situaciones posibles y restringiendo los patrones que los modelos pueden prever, o el testeo se realiza sobre pocas observaciones, posiblemente sesgando el resultado de la verificación y perdiendo robustez estadística en su análisis.

Para resolver esta problemática, se optó por utilizar la validación cruzada de un elemento (*leave-one-out crossvalidation*, LOOCV). Esta metodología es una variante de la CV de *m*-folds, en la cual una muestra completa de *n* elementos es separada en *m* subgrupos o *folds* (Efron y Gong, 1983; Elsner y Schmertmann, 1994). En el caso de la LOOCV, cada fold está compuesto de una única observación ($m = n$). Esta metodología sigue un procedimiento iterativo que permite entrenar a los modelos de cada mes y cada cluster usando la mayor cantidad de observaciones posibles, a la vez que conserva observaciones independientes para realizar la tarea de verificación de desempeño.




Figura 4-2. Esquema de entrenamiento de los modelos estadísticos con LOOCV. Se ejemplifica el caso de los modelos de pronóstico de la precipitación de noviembre en el cluster 2. El cuadro superior indica los predictores que son considerados para la confección de los modelos. En cada paso, las celdas naranjas señalan los años que son usados para el entrenamiento de los modelos; la predicción independiente se realiza sobre el año indicado con la celda verde.

La Figura 4-2 muestra a modo de ejemplo una síntesis del procedimiento para el caso de los modelos de pronóstico de la precipitación areal de noviembre en el cluster 2. La muestra total es de tamaño $n = 36$, pues se cuenta con la serie temporal de la precipitación acumulada mensual en cada noviembre del período 1984-2019, y con las series temporales de los dos predictores seleccionados para este mes y cluster (ambos observados el mes previo a la precipitación). En primera instancia, se entrenan los modelos para predecir la situación de noviembre de 1984. Para ello, se remueven el predictando y los predictores de este año de la muestra, y las 35 observaciones restantes (1985-2019) son empleadas en la búsqueda de los parámetros de los modelos. Una vez entrenados los modelos, los mismos son utilizados para realizar pronósticos de la precipitación en noviembre de 1984 conociendo cómo se comportaron los predictores en octubre de ese mismo año. En segunda instancia, se desea entrenar los modelos para prever la situación de noviembre de 1985, con lo cual el predictando y los predictores de dicho año son extraídos de la muestra total y el entrenamiento se realiza en base a la

información del año 1984 y del período 1986-2019. En forma sucesiva, se ajustan los modelos para predecir cada mes de noviembre del período 1984-2019, en todo momento procurando apartar el año objetivo para el entrenamiento. Este procedimiento es análogo para los modelos del cluster 1 y para los demás meses del semestre estival.

Es importante aclarar que los modelos que se construyan para un año específico no serán idénticos a los de otros años, pues el ajuste se realiza con muestras ligeramente diferentes. Sin embargo, mediante el proceso de LOOCV se logra maximizar el tamaño de la muestra de entrenamiento, y el error cuadrático entre la precipitación y su estimación provee una aproximación razonablemente insesgada del error de testeo (James et al., 2013). Si se deseara operativizar este procedimiento y entrenar un modelo para un año posterior al 2019 (simbolizado como paso 36 en la Figura 4-2), este procedimiento se convertiría en una “actualización” de los parámetros, pues se emplearían todos los años hasta el año objetivo para entrenar y, posteriormente, se evaluaría la eficiencia del modelo en el año independiente. Si bien los predictores continuarían definiéndose de la misma forma, la relación predictores-predictando se adaptaría a medida que se incorporaran nuevos años a la muestra. En este sentido, González et al. (2023) entrenaron modelos estadísticos de precipitación estacional en la cuenca del Comahue, reajustando sucesivamente los modelos hasta el año anterior al año objetivo de pronóstico. Al año siguiente incorporan una nueva observación para el entrenamiento y repiten este procedimiento, siendo una adaptación de la LOOCV donde la observación que se “remueve” al entrenar es la más reciente, correspondiente al año objetivo.

A continuación, se indican algunos detalles respecto al entrenamiento de los cuatro métodos de aprendizaje estadístico utilizados. En todos los casos el entrenamiento se realizó en el período 1984-2019 (1985-2020) para los meses de primavera (verano) usando LOOCV. Todos los predictores que se muestran en la Tabla 3-4 y que fueron analizados en el Capítulo 3, fueron ingresados para el entrenamiento de los modelos. La búsqueda de los parámetros de los modelos para todas las técnicas se llevó a cabo en el aplicativo R (R Core Team, 2021):

- **RLM:** los modelos fueron ajustados siguiendo el procedimiento de ajuste por cuadrados mínimos. Los predictores ingresados no presentan colinealidad.

- **GAM:** se consideraron splines como funciones no lineales que acompañan a cada predictor en el ajuste, tomando 3 grados de libertad como cota superior de cada función.
- **SVR:** se empleó un kernel radial, y se determinaron los valores de C y ε evaluando el error cuadrático medio promedio al realizar validación cruzada 10-fold sobre la muestra de entrenamiento que corresponda según la LOOCV.
- **ANN:** se consideraron cuatro arquitecturas con dos capas ocultas (además de la capa de entrada y la capa de salida), que se detallan en la Tabla 4-1. En todos los casos la función de activación utilizada en las capas ocultas y la capa de salida fue la *Unidad Lineal Rectificada* (ReLU). Esta función retorna el valor de entrada si el mismo es positivo, y cero en el caso contrario. Además, se aplica una capa de *dropout* entre la primera y segunda capa oculta. Esta capa se encarga de desactivar algunas neuronas de la primera capa durante la optimización iterativa. La probabilidad de dropout cuantifica las chances de que un nodo sea desactivado durante el proceso. Esta técnica se suele emplear para evitar el sobreajuste de los modelos en problemas de aprendizaje supervisado (Srivastava et al., 2014). Las arquitecturas empleadas siguen ejemplos de modelado utilizados para la precipitación mensual en el Gran Chaco (González y Rolla, 2022) y para la precipitación estacional en la región del Comahue (González et al., 2023). En todos los casos se utilizaron 1000 épocas con un tamaño de batch equivalente a 5, y una tasa de aprendizaje de 0.001 para el entrenamiento de las ANN.

Arquitectura	Cantidad neuronas		Probabilidad de dropout	Cantidad de épocas	Tamaño de batch	Tasa de aprendizaje
	Capa oculta 1	Capa oculta 2				
1	16	32	0.2	1000	5	0.001
2	32	32	0.2			
3	16	32	0.1			
4	32	32	0.1			

Tabla 4-1. Detalle de las arquitecturas de ANN empleadas.

La Figura 4-3 muestra la cantidad de predictores que fueron seleccionados en el Capítulo 3 para cada mes de pronóstico de la precipitación y para cada cluster. Los meses que contengan mayor cantidad de indicadores (febrero para ambos clusters, y enero para el cluster 2) se asociarán a una mayor cantidad de modelos de RLM, GAM, y SVR debido a que estas metodologías generan combinatorias de los predictores en el proceso de desarrollo de los modelos. Por el contrario, en todos los meses se cuenta con cuatro modelos de ANN independientemente del tamaño del set de predictores ingresado, debido a que se consideraron cuatro arquitecturas que toman la totalidad de los predictores que correspondan al mes y al cluster.




Figura 4-3. Cantidad de predictores seleccionados por cluster y por mes.

4.3. Modelado estadístico: evaluación determinística

En esta sección, se evalúa el rendimiento de los modelos encontrados mediante los métodos de aprendizaje propuestos. Antes de proseguir, es necesario hacer la distinción entre dos enfoques de pronóstico: el *determinístico* y el *probabilístico*. El primer enfoque

radica en emitir un pronóstico cuantitativo o cualitativo específico, sin brindar una medida de la incertidumbre vinculada a esa previsión. Por el contrario, el enfoque probabilístico no propone un valor o una categoría específica de previsión, sino que brinda probabilidades de ocurrencia de fenómenos futuros posibles (Stephenson, 2008). A continuación, se presentarán los resultados vinculados al desempeño de los modelos desde un punto de vista determinista y cuantitativo.

4.3.1. Umbral de aceptación de modelos

Como se mencionó en la sección previa, la estrategia de entrenamiento por LOOCV permite ajustar los modelos con la mayor cantidad de información posible. Para cada mes y cluster, cada una de las 36 observaciones del período 1984/1985-2019/2020 puede ser individualmente pronosticada mediante los esquemas entrenados a partir de las 35 observaciones restantes. Es por esto que en todos los meses se cuenta, a priori, con una muestra de valores pronosticados cuyo tamaño es 36 veces la cantidad de modelos que puedan obtenerse mediante la combinatoria de predictores. Esto implica una gran cantidad de pronósticos sobre los cuales realizar las tareas de verificación de desempeño de los modelos entrenados.

Sin embargo, no todas las metodologías logran entrenar esquemas predictivos que tengan un desempeño lo suficientemente bueno sobre la muestra de entrenamiento como para ser considerados en un pronóstico operativo para un año determinado. Para comprender este punto, se plantea el siguiente ejemplo: se desea pronosticar la precipitación de noviembre en el año 2019 para el cluster 2, considerando un modelo de RLM y un modelo de GAM (ambos partiendo del mismo set de predictores). Para ello, ambos modelos son entrenados en base al período 1984-2018. Sin embargo, sobre la muestra de entrenamiento el modelo de RLM presenta métricas de verificación de desempeño sensiblemente peores que el modelo de GAM. Si bien las métricas de evaluación calculadas sobre el entrenamiento tienden a subestimar el error sobre una muestra independiente, es esperable que el modelo de GAM pueda acercarse más al valor verdadero de precipitación que efectivamente ocurre en noviembre de 2019. Es por esta razón que se debe realizar una selección de los modelos obtenidos planteando un criterio de aceptación en base a alguna métrica de verificación de desempeño sobre la muestra de entrenamiento. En consecuencia, puede

sucedan que algunos modelos deban ser descartados para la predicción en años específicos dado que no cumplen con el umbral de tolerancia fijado.

La selección de los modelos a considerar para cada año fue realizada mediante una métrica derivada del coeficiente de correlación de Pearson. Este coeficiente es típicamente empleado para evaluar la correspondencia entre las series temporales de valores pronosticados y de valores observados. Idealmente, la correlación debería ser cercana a uno para concluir que los modelos reproducen la evolución de los valores observados. A su vez, el cuadrado de este coeficiente, denominado *coeficiente de determinación*, indica la proporción de la varianza de los valores observados que es representada por el pronóstico. Existe una variante conocida como el *coeficiente de determinación ajustado* que penaliza al grado de asociación lineal en función de la cantidad de predictores que ingresan al modelo. Esto es porque añadir una mayor cantidad de variables independientes tiende a incrementar el valor del coeficiente de determinación usual, incluso aunque dichas variables aporten información irrelevante y se tienda al sobreajuste. La expresión del coeficiente de determinación ajustado $AdjR^2$ es (James et al., 2013):

$$AdjR^2 = 1 - (1 - R^2) \frac{n - 1}{n - p - 1} \quad (4.6)$$

donde R^2 es el coeficiente de determinación usual, n es la cantidad de observaciones, y p es la cantidad de predictores asociados al esquema predictivo. Este coeficiente puede expresarse en términos adimensionales (ecuación 4.6) o en términos porcentuales si es multiplicado por 100. El valor de $AdjR^2$ calculado en base a la muestra de entrenamiento permite seleccionar modelos para su evaluación posterior en base a su rendimiento en el pronóstico de años conocidos.

La distribución de los valores de $AdjR^2$ para cada tipo de metodología, por mes, y por cluster se muestra en la Figura 4-4. Esta Figura exhibe cuál es la correspondencia existente entre los valores observados de precipitación mensual y los valores pronosticados por cada modelo sobre la muestra de entrenamiento en el período 1984/1985-2019/2020. Los valores más altos del coeficiente de determinación son alcanzados por los modelos de ANN, particularmente en el cluster 1 donde una gran proporción de los modelos presenta un coeficiente de determinación mayor a 0.8. Los

boxplots de los esquemas de RLM, GAM, y SVR muestran una mediana más favorable en el cluster 1 especialmente en noviembre y diciembre, aunque manteniéndose por debajo del rendimiento de las ANN. Sin embargo, la dispersión observada en el desempeño de estos meses es ligeramente menor en el cluster 2. Si bien la distribución del $AdjR^2$ de los esquemas de SVR tiende a estar desplazada hacia valores más altos respecto a RLM y GAM, esta metodología es la que mayor dispersión presenta en su desempeño en la mayor parte de los meses y en ambos clusters. Por otro lado, no se detectan diferencias relevantes entre el $AdjR^2$ de RLM y de GAM.




Figura 4-4. Boxplots de coeficientes de determinación ajustados en base a la muestra de entrenamiento para cada mes y por tipo de modelo, para el cluster 1 (**primera columna**) y el cluster 2 (**segunda columna**). La caja indica los valores del primer cuartil (borde inferior), mediana (línea horizontal) y tercer cuartil (borde superior). El coeficiente $AdjR^2$ está expresado de forma adimensional.

Existe una gran variación entre modelos en términos del coeficiente de determinación ajustado, con esquemas que explican menos de un 20% de la variabilidad de la precipitación mensual observada en contraste al desempeño de los modelos de ANN. Si se fijara un umbral de selección de modelos excesivamente alto ($AdjR^2 > 0.6$) es posible que algunas técnicas queden totalmente descartadas. Es por esto que, para facilitar la incorporación de la mayor variedad de modelos posibles, en cada mes se seleccionaron aquellos modelos que explicaran al menos un 40% de la variabilidad de la precipitación observada según el coeficiente de determinación ajustado. La Figura 4-5 muestra la proporción de modelos de cada tipo que cumplen la condición impuesta sobre el $AdjR^2$,

separados por trimestre de pertenencia. Es destacable que existen más modelos disponibles durante los meses de verano en ambos clusters, aunque esto también puede deberse a que en febrero hay una mayor cantidad de predictores que ingresan a los esquemas. En el cluster 1 la cantidad de modelos seleccionados por tipo de técnica es más equitativa que en el cluster 2 en ambos trimestres, mientras que en el cluster 2 predominan las alternativas no lineales (ANN y SVR en primavera, a los que se suma GAM en el verano). Si se incrementara el umbral de tolerancia a $AdjR^2 \geq 0.5$, los modelos de RLM serían descartados prácticamente en su totalidad, especialmente en el cluster 2 (Figura A-4-1 en Anexo), lo que muestra que predomina el rendimiento de las alternativas no lineales.




Figura 4-5. Proporción de modelos de precipitación mensual que cumplen la condición de $AdjR^2 \geq 0.4$ por cada tipo de técnica en 1984/1985-2019/2020 para el cluster 1 (**primera fila**) y el cluster 2 (**segunda fila**), discriminando los modelos según trimestre de pertenencia: OND (**primera columna**) y EFM (**segunda columna**). En la esquina superior izquierda de cada panel se indica la cantidad total de modelos que cumple la condición sobre el $AdjR^2$.

Para poder realizar un análisis de desempeño robusto, se descartaron adicionalmente las técnicas de modelado que presentaran pocos casos por encima del umbral de tolerancia de $AdjR^2$. En otras palabras, si para un determinado mes y cluster sucede que una técnica no logra entrenar modelos con $AdjR^2 \geq 0.4$ para una gran proporción de años, esa técnica no es incorporada en el posterior análisis. Se consideraron aquellas técnicas que lograron emitir un pronóstico en base a modelos que cumplan el umbral de aceptación en al menos 28 años del período 1984/1985-2019/2020. El detalle de las técnicas que se preservaron por mes y por cluster se incluye en la Tabla 4-2, donde se destaca que el mayor inconveniente en términos de disponibilidad de los modelos se encuentra en el cluster 2.

CLUSTER 1						
	Oct	Nov	Dic	Ene	Feb	Mar
RLM	✓	✓	✓	✗	✓	✓
GAM	✓	✓	✓	✗	✓	✓
SVR	✓	✓	✓	✓	✓	✓
ANN	✓	✓	✓	✓	✓	✓
CLUSTER 2						
	Oct	Nov	Dic	Ene	Feb	Mar
RLM	✓	✗	✗	✗	✓	✗
GAM	✓	✗	✗	✗	✓	✗
SVR	✓	✗	✓	✓	✓	✗
ANN	✓	✓	✓	✓	✓	✓

Tabla 4-2. Detalle de las técnicas que fueron incluidas (tildes) y descartadas (cruces) para cada mes y cluster en el proceso de evaluación de desempeño.

Luego de haber seleccionado los modelos, el análisis continuó en base al pronóstico sobre las observaciones independientes. En particular, para cada mes del semestre estival en el período 1984/1985-2019/2020 se calculó el *ensamble multimodelo*, definido como el promedio aritmético de las estimaciones brindadas individualmente por cada modelo disponible. Esta técnica es típicamente usada en el modelado dinámico para compensar las diferencias entre los miembros que lo conforman y generar una mejor aproximación a la señal climática en comparación a los miembros individuales (Mason, 2008). En el

aprendizaje estadístico también se aplican los métodos de ensamble con el objetivo de reducir la varianza de las estimaciones, mejorar el rendimiento del pronóstico y brindar robustez sobre observaciones independientes (Budgaga et al., 2016). Asimismo, debido a que los modelos difieren año a año por la naturaleza de la LOOCV, se caracterizó el rendimiento de cada técnica a partir de un ensamble por técnica. A modo de ejemplo, si para un año y mes específico existen 5 modelos de RLM, se tomó el promedio aritmético de los mismos para cuantificar la estimación por RLM en esa situación particular.

4.3.2. Evaluación de precisión

La precisión refiere a la correspondencia entre pronósticos individuales y los eventos que intentan predecir (Wilks, 2011). En la Figura 4-6 se brindan boxplots que exhiben visualmente una medida de la precisión. En el panel superior, los boxplots muestran la distribución del cociente entre cada pronóstico emitido por el ensamble por técnica en el período 1984/1985-2019/2020 y la precipitación observada en ese mismo mes. Idealmente, una técnica con buen rendimiento debería tener una distribución de la precisión centrada alrededor del 100%.

En la Figura 4-6 se puede observar que, en líneas generales, todas las técnicas presentan una mediana centrada alrededor del 100%. El mayor desplazamiento de la mediana se encuentra en los modelos de marzo en el cluster 2, vinculado al desempeño de los modelos de ANN que fueron los únicos seleccionados para este mes. Los modelos tienden a ser más propensos a sobreestimar que a subestimar la precipitación. En el cluster 2 las sobreestimaciones numéricas tienden a ser más frecuentes e intensas que en el cluster 1, particularmente en el verano, con casos en los que la precipitación estimada es del orden de 7 veces mayor que la precipitación efectivamente observada. Por el contrario, la mayor dispersión en el cluster 1 se observa particularmente en octubre. Esto puede deberse a que la estación lluviosa está iniciando en esta región, de forma que los valores observados tienden a ser más pequeños que en el resto del semestre, propiciando que errores en el pronóstico pesen más al relativizarlos en función del valor observado. Por otro lado, el panel inferior de la Figura 4-6 muestra los boxplots considerando el ensamble multimodelo para cada cluster. El ensamble mejora la frecuencia e intensidad de las sobreestimaciones, aunque continúa destacándose la menor precisión del cluster 2 en comparación al cluster 1 sostenidamente en todos los meses.




Figura 4-6. Fila superior: Boxplots del cociente porcentual entre la precipitación estimada por el ensamble por técnica y la precipitación observada en cada mes para el cluster 1 (columna izquierda) y cluster 2 (columna derecha). **Fila inferior:** análogo a la fila superior, pero considerando el ensamble total de todos los modelos.

Las Figuras 4-7 y 4-8 muestran diagramas de dispersión de los valores pronosticados por cada técnica y por el ensamble, versus la precipitación mensual efectivamente observada en el cluster 1 (Figura 4-7) y el cluster 2 (Figura 4-8). Es deseable que un esquema predictivo con buen desempeño presente una buena correspondencia con los valores observados, de forma que la nube de puntos en el diagrama de dispersión se concentre alrededor de la recta de identidad, cuya pendiente es unitaria. En líneas generales, en ambos clusters y para todos los meses se observa que los modelos tienden a subestimar la precipitación en eventos con acumulados importantes, mientras que lo opuesto ocurre en eventos donde se observaron acumulados menores. A su vez, en el cluster 2 (Figura 4-8) el ensamble de los meses de noviembre y marzo sólo se calcula en base a las ANN, con lo cual los errores que se reproduzcan en el ensamble son los errores provenientes de la aplicación del método ANN.




Figura 4-7. Gráficos de dispersión de la precipitación estimada por cada tipo de técnica y por el ensamble (Ens)(eje-y) versus la precipitación observada (eje-x) para cada tipo de modelo (marcadores) y para cada mes en el cluster 1. La línea punteada indica la recta identidad.




Figura 4-8. Análogo a la Figura 7 para el cluster 2.

Para poder sintetizar el comportamiento de las nubes de puntos de las Figuras 4-7 y 4-8, se obtuvieron las pendientes asociadas a cada técnica de modelado mediante un ajuste por cuadrados mínimos, tomando como variable independiente a las series temporales de valores observados (Figura 4-9). La pendiente no permite realizar una comparación directa de la precisión en eventos individuales, pero brinda una visión general respecto a la correspondencia entre valores pronosticados y observados. En la Figura 4-9 se destaca que la pendiente es menor a la unidad en todos los casos, lo que se condice con lo que se detectó visualmente respecto a la subestimación (sobreestimación) de acumulados altos (bajos) de precipitación. A excepción de los meses de octubre y febrero, cuando la pendiente del ensamble multimodelo presenta valores similares en ambos clusters, se observa que las pendientes en el cluster 1 son más cercanas a la unidad que en el cluster 2. Esto implica que las nubes de puntos tienden a reproducir más fielmente que estimaciones altas (bajas) corresponden a años con acumulados altos (bajos) en el cluster 1. Por otro lado, en el cluster 1 los modelos de SVR tienden a presentar los peores ajustes lineales en términos de la pendiente, mientras que las técnicas de RLM y GAM presentan pendientes similares a las de ANN en la mayoría de los meses. El ensamble se vincula a pendientes aproximadamente promedio entre las técnicas que lo conforman, y son generalmente menores a las pendientes dadas por ANN.




Figura 4-9. Pendientes asociadas a las nubes de puntos de las Figuras 4-7 para el cluster 1 (panel superior) y 4-8 para el cluster 2 (panel inferior), discriminando por mes de la precipitación (eje-x). En marcadores se indica el tipo de modelo.

4.3.3. Diagramas de Taylor

Otras métricas de desempeño de pronósticos determinísticos se pueden expresar gráficamente en un diagrama de Taylor. Las Figuras 4-10 y 4-11 muestran los diagramas asociados a la predicción de la precipitación mensual para ambos clusters. El diagrama de Taylor resume gráficamente algunas métricas de representación de campos espaciales o series temporales respecto a un patrón de referencia (Taylor, 2001). En este caso, se compara la correspondencia estadística entre la serie temporal pronosticada por cada técnica y la serie temporal de precipitación mensual observada en el cluster correspondiente. El espacio del diagrama se basa en tres ejes (horizontal, vertical, y azimutal) y contiene información sobre tres cantidades estadísticas. Los ejes horizontal y vertical indican el desvío estándar de las estimaciones normalizado por el desvío estándar observado, de forma que la distancia radial al origen indica la similitud en la dispersión de ambas series temporales. El eje azimutal indica el grado de asociación lineal entre los pronósticos y las observaciones, cuantificado a través del coeficiente de correlación de Pearson. El diagrama de Taylor incluye el patrón de referencia, que en este caso corresponde a la serie temporal de precipitación observada. La misma se posiciona en la región del diagrama con desvío estándar normalizado unitario y coeficiente de correlación de Pearson unitario. Los arcos concéntricos alrededor del patrón de referencia indican el valor de la raíz de la diferencia cuadrática media (RMSD, por sus siglas en inglés), normalizada por el desvío estándar de las observaciones. La RMSD se define como:

$$RMSD = \left\{ \frac{1}{n} \sum_{i=1}^n [(y_i - \bar{y}_i) - (\hat{y}_i - \bar{\hat{y}}_i)]^2 \right\}^{\frac{1}{2}} \quad (4.7)$$

donde n es la longitud de las series temporales, $(y_i - \bar{y}_i)$ es la anomalía de precipitación observada en el i -ésimo año, y $(\hat{y}_i - \bar{\hat{y}}_i)$ es la anomalía de precipitación estimada por cada tipo de modelo en ese mismo año. La RMSD es similar a la raíz del error cuadrático medio, solo que la primera centra los valores en función del promedio de las observaciones y los modelos ($\bar{y}_i$ y $\bar{\hat{y}}_i$, respectivamente). Al encontrarse normalizada por el desvío estándar, la RMSD indicada en el diagrama de Taylor es adimensional. Idealmente, los modelos que mejor reproduzcan el comportamiento observado son

aquellos que más cerca se encuentren en el diagrama al patrón de referencia, con un desvío normalizado y un coeficiente de correlación cercanos a la unidad, y con la RMSD normalizada cercana a cero.

La Figura 4-10 muestra el desempeño de los modelos para el cluster 1. Se puede observar que todos los modelos presentan un desvío normalizado menor a uno, es decir que tienden a subestimar la variabilidad observada. Esto es consistente con los valores de pendiente lineal encontrados anteriormente (Figura 4-9), que sugerían que podría haber una subestimación de la precipitación ante eventos de mayores acumulados y lo opuesto en casos de meses más secos. El tipo de técnica que mejor reproduce la amplitud de la serie observada en forma consistente a lo largo de los meses es ANN, que incluso se aproxima al desvío normalizado unitario en diciembre y enero. Por el contrario, las subestimaciones de la amplitud más importantes y persistentes en el semestre se observan para los modelos de SVR. Las técnicas de RLM y GAM presentan un desempeño intermedio según esta métrica, mostrando un desvío similar a las ANN en octubre, noviembre, y marzo. El ensamble muestra un desvío normalizado intermedio entre todas las técnicas, lo cual se deriva de la propia construcción del ensamble como promedio de los modelos individuales. Por otro lado, la correlación entre las predicciones y las observaciones presenta ciertas variaciones a lo largo de los meses. En todos los casos el coeficiente de correlación es positivo, lo cual es deseable de modelos que deberían reproducir la realidad. La correlación es máxima en noviembre y en febrero, cuando la mayor parte de las técnicas muestran coeficientes entre 0.7 y 0.8. En cambio, enero es el mes con peor desempeño pues sólo se cuenta con dos técnicas (SVR y ANN), y ambas presentan coeficientes entre 0.3 y 0.5. En líneas generales, el ensamble tiende a mostrar una correlación similar a la mejor correlación disponible por parte de las técnicas individuales. Si se combinaran todas las métricas que muestra el diagrama, los meses con mejor rendimiento son noviembre y febrero pues muestran un mayor acercamiento al patrón de referencia, particularmente por una RMSD relativamente baja y un coeficiente de correlación relativamente alto.




Figura 4-10. Diagramas de Taylor del rendimiento de cada tipo de modelo (marcadores) para cada mes en el cluster 1. En cada panel los ejes horizontal y vertical, en conjunto con las curvas azules, indican el desvío estándar del tipo de modelo, normalizado por el desvío estándar observado. El eje azimutal indica el coeficiente de correlación de Pearson entre la serie temporal de valores observados y de valores pronosticados por cada tipo de modelo. Las curvas rojas indican el RMSD normalizado por las observaciones. El punto negro en la región inferior de cada panel simboliza a la serie temporal de valores observados.




Figura 4-11. Análogo a la Figura 4-10 para el cluster 2.

La Figura 4-11 muestra el desempeño de los modelos para el cluster 2. En primera instancia, queda manifiesta la menor disponibilidad de técnicas puesto que hay menor cantidad de modelos seleccionados según el criterio de $AdjR^2$ (particularmente de RLM y GAM). En segunda instancia, al evaluar la distancia relativa de los modelos al patrón de referencia, se destaca que los esquemas predictivos del cluster 2 tienden a un peor desempeño que en el cluster 1, especialmente en noviembre, diciembre, y enero. En particular, los modelos de SVR suelen vincularse a una correlación más alta que los modelos de ANN, aunque éstos reproducen la amplitud de las series temporales observadas con mayor fidelidad que los modelos de SVR. Según el ensamble multimodelo, en diciembre es cuando el desvío estimado se asemeja más al observado, pero la variabilidad es pobremente reproducida en términos de la correlación. Los meses de octubre y febrero son los que mejor rendimiento presentan para el ensamble en términos del acercamiento al patrón de referencia, aunque en ambos meses se subestima la magnitud de los extremos según el desvío normalizado.

Para sintetizar el rendimiento de los modelos, se realizaron diagramas de Taylor comparativos de ambos clusters (Figura 4-12). Estos diagramas se construyeron en base a los ensambles multimodelo, combinando las series pronosticadas de los meses individuales según si corresponden a la primavera (OND) o al verano (EFM). Se destaca que el cluster 1 tiene un desempeño superior al cluster 2, particularmente en la primavera. El ensamble vinculado al pronóstico de los meses de octubre a diciembre presenta una correlación superior a 0.8, con un desvío normalizado cercano a la unidad y una RMSD normalizada menor que en el cluster 2. Estas métricas empeoran hacia el verano, aunque el cluster 1 sigue mostrando un rendimiento ligeramente más favorable que el cluster 2. Por su parte, el ensamble del cluster 2 muestra una mejora hacia al verano, especialmente en términos de la RMSD normalizada y del coeficiente de correlación. Sin embargo, el cambio en el desempeño observado de la primavera al verano no es tan marcado como lo es para el cluster 1.




Figura 4-12. Diagrama de Taylor del rendimiento de los ensambles de modelos para el cluster 1 (cuadrado violeta) y cluster 2 (círculo verde) en los meses de la primavera (**fila superior**) y del verano (**fila inferior**). En este diagrama se combinan las series temporales de las predicciones de precipitación de octubre, noviembre, y diciembre para OND, y de enero, febrero y marzo para EFM. Los detalles gráficos son análogos a los de la Figura 4-10.

4.4. Síntesis

En este Capítulo se generaron los modelos de predicción estadística de la precipitación mensual areal sobre los dos clusters que conforman la CRB. Para este propósito, se emplearon las técnicas de RLM, GAM, SVR, y ANN. Los modelos fueron entrenados empleando como input a los predictores hallados en el Capítulo 3, definidos en el mes inmediatamente anterior al mes objetivo de pronóstico. La estrategia de entrenamiento utilizada fue la LOOCV, con el objetivo de lograr una muestra de evaluación lo suficientemente grande que permitiera obtener en forma más robusta ciertas métricas de desempeño. Desde el enfoque determinístico, se encontró que los modelos del cluster 1 presentan una mayor habilidad en el pronóstico de la precipitación acumulada mensual que los modelos del cluster 2, especialmente en los meses de primavera. Dentro del conjunto de técnicas consideradas, las ANN son las que presentan un mejor desempeño. Sin embargo, existe una cierta variabilidad intraestacional en el rendimiento de las técnicas individuales y del ensamble multimodelo. Adicionalmente, los modelos tienen dificultades para representar la amplitud de los valores observados, tendiendo a subestimar (sobreestimar) valores altos (bajos) de precipitación mensual. Debido a la naturaleza compleja de la previsión numérica a una escala temporal mayor a dos semanas (Mariotti et al., 2018), es esperable que los esquemas predictivos tengan grandes dificultades en representar los valores observados en forma precisa. Es por esta razón que en el Capítulo 5 se abordará la previsión por cuantiles de la variable. Además, se explorará la generación de un pronóstico probabilístico de precipitación que permita expresar la incertidumbre aparejada a la previsión climática.

Capítulo 5

Pronóstico probabilístico

A lo largo de los Capítulos anteriores, se realizó una exploración de potenciales predictores de la precipitación estival en la Cuenca del Río Bermejo. Los mismos sirvieron de materia prima para la generación de modelos estadísticos de predicción a plazo mensual, contruidos a partir de las técnicas de Regresión Lineal Múltiple, Modelos Aditivos Generalizados, Regresión de Vectores de Soporte, y Redes Neuronales Artificiales multicapa. En el presente Capítulo, se evaluará el desempeño de dichos modelos desde el enfoque probabilístico por categorías. Finalmente, se comparará su rendimiento con sistemas de pronóstico a mediano plazo elaborados por centros meteorológicos internacionales, que se encuentran actualmente operativos.

5.1. La búsqueda del “buen” pronóstico

La evaluación del desempeño de los pronósticos es una tarea esencial dentro del proceso de generación de los sistemas de pronóstico, una realidad a la que no escapan los pronósticos estaciones o subestacionales. Dentro la complejidad de la evaluación, cabe preguntarse no solamente si los pronósticos son “buenos” o “malos” en forma binaria, sino si tienen mayores tasas de fallo bajo ciertas condiciones - pero alta frecuencia de aciertos bajo otras, si mejoran o no de forma relativa las previsiones de sistemas de pronósticos ya establecidos, si tienen particulares dificultades para prever la situación futura en regiones particulares, etc. Este tipo de verificación no solamente lleva a un análisis de parámetros de habilidad actual de los modelos de pronóstico, sino también a dilucidar cómo puede ser mejorado el sistema de pronóstico, o cómo puede ser utilizado de manera más eficiente a partir del conocimiento de sus fortalezas y debilidades.

En este sentido, Murphy (1993) asocia a los “buenos” pronósticos con tres cualidades distintivas: consistencia, calidad, y valor. La primera de estas características refiere a que haya un alto grado de coincidencia entre el mejor juicio del pronosticador y el pronóstico emitido. En el caso de un pronóstico que presenta probabilidades de ocurrencia de eventos, se dice que existe consistencia si el grado de incertidumbre que tiene el pronosticador está bien representado por las probabilidades brindadas por el pronóstico. En segundo lugar, la calidad se vincula a cuánta correspondencia existe entre los pronósticos y las observaciones, caracterizando así la habilidad que tiene el sistema de pronóstico en modelar a la realidad. Finalmente, el valor o utilidad refiere a cómo los usuarios pudieron beneficiarse en términos de planificación y toma de decisión gracias al pronóstico emitido.

Como se mencionó en el Capítulo 4, los pronósticos pueden ser generados y evaluados en el marco del enfoque determinístico y/o del enfoque probabilístico. El primero radica en pronosticar un valor o categoría específico para la variable objetivo. El desempeño de este tipo de pronóstico para la región de interés fue evaluado en el Capítulo anterior al contrastar los valores estimados por cada tipo de esquema predictivo contra los valores efectivamente observados en cada cluster. Por otra parte, en el enfoque probabilístico los esquemas predictivos cuantifican la incertidumbre ligada al pronóstico al proveer las probabilidades de ocurrencia de una variedad de posibles resultados futuros.

Stephenson (2008) menciona alguna de las ventajas de emitir un pronóstico probabilístico en lugar de uno determinístico. Por un lado, la complejidad del sistema climático y de su evolución futura hacen imposible la predicción con absoluta certeza. En cambio, brindar un abanico de posibilidades, donde cada una se vincula a determinadas chances de ocurrencia, permite a los usuarios del pronóstico poder tomar decisiones óptimas en función de las estimaciones disponibles. Además, los pronósticos probabilísticos son esenciales para poder realizar una evaluación cuantitativa del riesgo. Sin embargo, Stephenson (2008) menciona que este tipo de pronósticos también trae aparejadas ciertas dificultades. La percepción y comprensión de la probabilidad y del riesgo varían según el usuario, y esto hace que la comunicación de lo que implica el pronóstico probabilístico sea más compleja y menos concisa que para un pronóstico determinístico. Además, las probabilidades de los potenciales eventos futuros son difíciles de cuantificar confiablemente cuando la fuente de la incertidumbre es desconocida y su incerteza se propaga a lo largo de todo el proceso de generación del sistema de pronóstico. Las

incertezas típicamente pueden clasificarse en aleatorias o epistémicas, entre las que se reconocen:

- **Incerteza observacional:** vinculada a errores en la toma del dato, a sesgos y errores sistemáticos instrumentales, y a la elección del período de análisis y su longitud temporal en el contexto de un sistema físico cuya variabilidad ocurre en distintas escalas temporales.
- **Incerteza de los modelos de predicción:** vinculada al proceso de generación de los sistemas predictivos. Incluye incertezas basadas en el desconocimiento de los parámetros de los modelos (por ejemplo, por la dificultad de resolución numérica de ciertos procesos físicos dentro del sistema climático) e incertezas basadas en la longitud de las simulaciones numéricas. También depende de la cantidad y tipo de ensamble utilizado, la resolución espacial y temporal, y de la existencia de fallas en la identificación completa de los procesos actuantes en el sistema climático.

La naturaleza del pronóstico probabilístico implica que la evaluación del desempeño también deba realizarse empleando métricas que consideren la presencia de incertidumbre en la estimación. Si bien algunas cantidades determinísticas, como ser el coeficiente de correlación entre el pronóstico y las observaciones, aportan información sobre la eficiencia del esquema predictivo, no son suficientes para una verificación de desempeño probabilístico (National Research Council, 2010). A modo de ejemplo, ante dos situaciones hipotéticas en las que el valor o categoría pronosticada con mayor probabilidad sea la misma, el proceso de toma de decisión que realicen los usuarios se modificará si la incertidumbre asociada al resultado varía según la situación. Sin embargo, una métrica determinística no evaluará esa incertidumbre, sino que simplemente contrastará al valor más probable contra la realidad para verificar el desempeño, obviando que el nivel de certeza de ese evento es distinto según la situación. Es por esta razón que las métricas de evaluación que se emplean para los pronósticos probabilísticos son típicamente diferentes a las de los pronósticos determinísticos.

Asimismo, existen diferentes maneras de construir un pronóstico probabilístico, que dependen de cuál es la variable objetivo de interés para el usuario. Algunos ejemplos pueden ser estimar la probabilidad de que la variable objetivo tome valores dentro de un intervalo determinado, pronosticar la probabilidad de que un evento específicamente

definido ocurra con una frecuencia determinada, estimar la probabilidad de superar un determinado cuantil, etc. En este estudio, se optó por realizar un pronóstico probabilístico categórico, donde las categorías están limitadas por los terciles de la función de distribución de precipitación mensual observada en cada cluster. Los terciles son cuantiles que dividen a los datos en tres partes iguales, de forma que se puede pronosticar la ocurrencia de precipitación *subnormal* (es decir, que toma un valor por debajo del primer tercil), *normal* (entre el primer y segundo tercil), y *sobrenormal* (por encima del segundo tercil). Al tratarse de categorías equiprobables, climatológicamente cada una de estas categorías presenta una probabilidad de ocurrencia de 33.3%. Sin embargo, para situaciones particulares que se deseen pronosticar, las probabilidades de estas categorías pueden diferir entre sí y alejarse de las chances climatológicas de ocurrencia. En este sentido, el propósito de los esquemas predictivos es el de detectar si existen forzantes de gran escala y escala regional (representados por los predictores) que inclinen la probabilidad de ocurrencia hacia un intervalo particular, favoreciendo así una categoría por encima de las demás.

Para la generación del pronóstico probabilístico en la región de la CRB, se empleó la técnica de *pronóstico de ensamble* (Toth et al., 2003). La misma consta en tomar todos los pronósticos determinísticos obtenidos para un mes y cluster en particular, donde se incluyen todas las estimaciones de los esquemas predictivos que hayan superado el umbral de tolerancia de $AdjR^2 \geq 0.4$ sobre la muestra de entrenamiento. Luego, la probabilidad de ocurrencia de un evento subnormal, normal, o sobrenormal se cuantifica como la fracción de pronósticos cuyo valor estimado corresponde a la categoría del evento, respecto al conjunto total de pronósticos emitidos.

Los terciles de la función de distribución de la variable objetivo son típicamente definidos en base a una climatología de referencia. En este caso, los terciles fueron calculados para cada mes y cluster en base a la muestra de entrenamiento. Dado que la estrategia de ajuste de los modelos se basó en la LOOCV, la muestra de entrenamiento varía en función del año objetivo a pronosticar. Por lo tanto, es posible que también puedan variar los terciles de la distribución. La Figura 5-1 exhibe los terciles que corresponden a cada mes del semestre estival y cada cluster de la CRB, calculados en base a las muestras de 35 datos de entrenamiento que corresponden a cada año en el período 1984/1985-2019/2020, siguiendo la estrategia de LOOCV. Si bien hay una leve dispersión en los valores de los terciles, la magnitud de los mismos no varía fuertemente entre las diferentes muestras de

entrenamiento consideradas. En el cluster 1 se observa un incremento importante en el valor de estos cuantiles a medida que avanza el semestre, pasando de ~40-60 mm en octubre a ~120-170 mm en marzo. Este comportamiento ya se vio reflejado previamente en el Capítulo 2 al evaluar el rango que presenta la onda anual en el sector centro-oeste de la cuenca (Figura 2-7). Por el contrario, los terciles en el cluster 2 oscilan alrededor de ~90mm (~140mm) para el primer (segundo) tercil a lo largo de toda la temporada estival.




Figura 5-1. Terciles climatológicos de cada cluster para la clasificación en categorías de la precipitación mensual. En sombreado se indica el rango (máximo – mínimo) del valor de los terciles para cada mes, calculado mediante la técnica LOOCV. En líneas se indica el promedio de los terciles en el periodo 1984/1985-2019/2020 para cada mes.

Los terciles obtenidos siguiendo la estrategia de LOOCV fueron utilizados para clasificar los eventos de cada año particular. A modo de ejemplo, si se quisiese clasificar la precipitación pronosticada u observada en el mes de noviembre del año 1984 en el cluster 2, se tomarían los terciles de noviembre correspondientes al entrenamiento en el período

1985-2019 como límites cuantitativos para las categorías subnormal/normal/sobrenormal. Siguiendo esta lógica, para ambos clusters se clasificó cada evento observado y cada valor estimado por predicciones individuales según los terciles correspondientes. Finalmente, se cuantificó la probabilidad de ocurrencia de cada evento contabilizando la proporción de predicciones que corresponden a cada categoría.

5.2. Estrategias de evaluación de los pronósticos probabilísticos

La generación de los pronósticos probabilísticos va aparejada de un análisis de eficiencia que considere la existencia de incertidumbre. En este sentido, la OMM (2018b) plantea que los siguientes atributos son deseables para los “buenos” pronósticos probabilísticos:

- **Resolución:** refiere a la intensidad con la cual la ocurrencia del evento está condicionada por el pronóstico. Si la ocurrencia de un evento es independiente de lo pronosticado, el pronóstico no aporta un valor agregado y, por lo tanto, no es útil. A modo de ejemplo, se quiere evaluar el desempeño de un pronóstico en prever situaciones de precipitación sobrenormal. Si se tratase de un pronóstico de buena resolución, sería esperable encontrar una mayor ocurrencia de eventos sobrenormales cuando el pronóstico asignó probabilidades más altas a la sobrenormalidad y, al mismo tiempo, observar pocos eventos sobrenormales cuando el pronóstico asignó probabilidades bajas a la sobrenormalidad. Sin embargo, se debe considerar que la resolución no es el único atributo deseable de un pronóstico, pues no habla de cuando acertado éste pueda ser. Siguiendo el ejemplo anterior, si existe mayor ocurrencia de eventos sobrenormales cuando el pronóstico asignó menor probabilidad a la sobrenormalidad y, al mismo tiempo, se observa menor ocurrencia de eventos sobrenormales cuando el pronóstico asignó mayor probabilidad, entonces la ocurrencia del evento sí está condicionada por el pronóstico y, por lo tanto, existe resolución. Sin embargo, el pronóstico falla en prever la situación que efectivamente es observada, pues bajas probabilidades de ocurrencia del evento se condicen con una alta frecuencia de ocurrencia efectiva, y viceversa.

- **Discriminación:** así como sucede con la resolución, la discriminación distingue entre pronósticos que son potencialmente útiles de aquellos que no lo son, sin considerar si ese pronóstico es acertado o no. Mientras que la resolución evalúa si la ocurrencia del evento cambia según el pronóstico emitido, la discriminación considera si el pronóstico cambia según el tipo de evento observado. Nuevamente consideremos el ejemplo de querer evaluar el desempeño de un pronóstico en prever situaciones de precipitación sobrenormal. Si se tratase de un sistema de pronóstico con capacidad de discriminación, sería esperable que se emitan probabilidades más altas de ocurrencia de sobrenormalidad cuando efectivamente la precipitación observada es sobrenormal.
- **Confiabilidad:** vincula la probabilidad de pronóstico de un evento con la frecuencia de ocurrencia observada del mismo. Por ejemplo, en las ocasiones en las cuales un pronóstico probabilístico habla de un 20% de probabilidad de ocurrencia de precipitación sobrenormal, es esperable que la sobrenormalidad efectivamente ocurra un 20% de las veces si el pronóstico fuera confiable. Así como ocurre con los demás atributos, la confiabilidad por sí sola no es una medida suficiente para evaluar cuán “bueno” es un sistema de pronóstico probabilístico. Por ejemplo, emitir una probabilidad de ocurrencia del 33.3% para las tres categorías de precipitación por terciles constituye un sistema de pronóstico confiable, pues las observaciones climatológicas muestran precisamente esa probabilidad de ocurrencia para las categorías subnormal, normal, y sobrenormal. Sin embargo, ese sistema de pronóstico no aporta ninguna información relevante en términos de si puede prever cuando en una situación particular una determinada categoría se verá favorecida por sobre las demás.
- **Agudeza:** es un atributo que cuantifica la variabilidad de las funciones de distribución de los pronósticos alrededor de la función de distribución climatológica. Como se mencionó anteriormente, un sistema de pronóstico que sistemáticamente prevé probabilidades climatológicas de ocurrencia es confiable pero no aporta información de valor. En cambio, un sistema de pronóstico que presenta agudeza tiende a asignar probabilidades alejadas de la climatología (ya sean altas o bajas) con lo cual hay gran certeza en que un determinado evento podrá o no desarrollarse. La agudeza sólo se basa en las probabilidades pronosticadas, y no considera la correspondencia entre los pronósticos y las observaciones.

- **Habilidad:** también comúnmente referida por su nombre en inglés (*skill*), refiere a un conjunto de métricas o *scores* que cuantifica, sintetiza y, primordialmente, compara cuán buenos son dos o más conjuntos de pronósticos en representar la realidad, considerando los atributos anteriormente mencionados. Las métricas de *skill* también permiten reconocer rápidamente si el pronóstico de alguna de las categorías de la variable objetivo presenta un mejor desempeño que otras. Es importante resaltar que no existe una única métrica que sirva para cuantificar la habilidad de un sistema de pronóstico, sino que se suelen tomar un conjunto de *scores* que evalúen los pronósticos en términos de resolución, discriminación, confiabilidad, y agudeza.

A continuación, se detallan las herramientas que se utilizaron en este estudio para evaluar el desempeño de los pronósticos probabilísticos. Es importante resaltar que la mayor parte de las herramientas mencionadas pueden combinar más de un atributo en su definición.

5.2.1. Diagrama de tendencia

Al analizar el rendimiento de un pronóstico, debe considerarse la posibilidad de que existan sesgos no condicionados (Wilks, 2011), que refieren a la existencia de diferencias sistemáticas entre los pronósticos y los eventos efectivamente observados. El sesgo no condicionado refiere al grado de correspondencia entre el pronóstico promedio y las observaciones promedio en un sentido distinto a la precisión, pues no compara pares de predicción-observación, sino correspondencias promedio entre ambos.

Una de las formas en las que se puede evaluar la presencia de sesgos no condicionados en un esquema de pronóstico probabilístico es a partir del *diagrama de tendencia*. Este diagrama es utilizado para la verificación del pronóstico estacional (Coelho, 2013; OMM, 2018b; Collazo et al., 2022), aunque también es aplicable en el caso de este estudio a escala mensual por la naturaleza categórica del pronóstico probabilístico. En este diagrama se compara la probabilidad promedio con la que cada tipo de evento fue pronosticado versus la frecuencia climatológica de dicho evento. Esto permite evaluar si en el período de análisis el sistema de pronóstico tiende a sesgarse hacia la ocurrencia de una categoría en particular, o si muestra probabilidades de cada evento similares a las climatológicas.

5.2.2. Tasa de aciertos

El diagrama de tendencia provee una indicación visual sobre la relación entre la probabilidad media del pronóstico categórico y la frecuencia climatológica de observación. Sin embargo, no especifica cómo es la correspondencia individual entre pronósticos y ocurrencia de eventos. Por esta razón, se debe evaluar la tasa de aciertos del pronóstico probabilístico.

Un acierto se entiende como un evento en el cual efectivamente se observó la categoría asociada a la mayor probabilidad de ocurrencia. En particular, el Heidke Hit Proportion (HHP) es una métrica que cuantifica la tasa de aciertos de un esquema predictivo. La misma se puede definir como:

$$HHP = \frac{\text{cantidad de aciertos}}{\text{cantidad de pronósticos emitidos}} \quad (5.1)$$

Existen algunas salvedades en cuanto a cómo aportan los aciertos a la ecuación (5.1) en un pronóstico probabilístico de triple categoría (OMM, 2018b). Si el acierto corresponde a una situación donde la categoría más probable presenta la máxima probabilidad pronosticada, el acierto suma 1 al numerador de la ecuación (5.1). Por el contrario, si existe un empate de máxima probabilidad entre dos categorías, el acierto aporta 0.5 al numerador pues sólo se trata de un éxito parcial. Si las tres categorías presentan la misma probabilidad (33.3%), el acierto sólo suma un tercio al numerador de la ecuación (5.1). En cualquier otro caso, no se contabiliza un acierto para el cálculo del HHP.

De la forma en la que se encuentra definido el HHP en la ecuación (5.1), éste toma valores entre 0 y 1. Si bien es intuitivo que valores más altos del HHP indican mayor eficiencia del sistema de pronóstico, la magnitud en sí misma del HHP no aporta información respecto a si existe una mejora del esquema predictivo respecto a un modelo de referencia. En este sentido, se define al Heidke Skill Score (HSS) como una variante del HHP (OMM, 2018b):

$$HSS = \frac{\text{cantidad de aciertos} - \text{cantidad esperada de aciertos}}{\text{cantidad de pronósticos emitidos} - \text{cantidad esperada de aciertos}} \quad (5.2)$$

donde la “cantidad esperada de aciertos” refiere a la cantidad de ocasiones en las cuales un sistema de pronóstico de referencia emitió un mayor porcentaje de probabilidades a la categoría efectivamente observada. La referencia puede ser la climatología, que por definición emite pronósticos certeros un 33.3% de las veces, u otro sistema de pronóstico de comparación. A diferencia del HHP, el HSS puede tomar valores positivos o negativos según si la cantidad de aciertos del pronóstico probabilístico supera a la cantidad de aciertos de la referencia ($HSS > 0$) o no ($HSS < 0$); a su vez, un esquema predictivo perfecto presentaría $HSS = 1$. El HSS además brinda cierta información de la resolución del pronóstico probabilístico, si la referencia es la climatología. Cuando el HSS es nulo, la cantidad de aciertos del esquema predictivo coincide con los de la climatología, la cual es considerada un sistema de pronóstico sin resolución pues es equiprobable a través de todas las categorías.

5.2.3. Diagrama de confiabilidad

El diagrama de confiabilidad contiene información sobre múltiples aspectos de la verificación. Puede ser construido combinando todos los tipos de eventos, o bien de manera individual para cada categoría del pronóstico, como se aplicó en este análisis. En síntesis, el diagrama de confiabilidad indica si el evento efectivamente ocurrió con la frecuencia con la que fue pronosticado (OMM, 2018b).

La lógica detrás de su construcción se sintetiza en la Figura 5-2 con un ejemplo basado en el pronóstico probabilístico de eventos sobrenormales. En principio, todos los pronósticos emitidos son clasificados según la magnitud de la probabilidad de ocurrencia de sobrenormalidad. En este estudio, las probabilidades pronosticadas entre 0 y 1 fueron discretizadas en intervalos de ancho 0.2. Para cada intervalo de probabilidad, se tiene una cierta cantidad de casos que pronosticaron el evento con esa probabilidad, y sólo en un subconjunto de ellos se habrá verificado realmente la ocurrencia de sobrenormalidad. Es por esto que para cada intervalo de probabilidades pronosticadas se cuantifica cuál es la proporción de ocasiones en las cuales el evento efectivamente ocurrió. En otras palabras, el diagrama de confiabilidad compara distintos intervalos de probabilidad pronosticada (eje-x) contra la frecuencia observada condicionada por la probabilidad de pronóstico (eje-y). La correspondencia entre la probabilidad pronosticada y la frecuencia de ocurrencia condicionada representan a la confiabilidad del esquema predictivo.

Idealmente, la curva de confiabilidad resultante debería acercarse a la recta de identidad pues implicaría que hay una buena correspondencia entre las chances de ocurrencia del evento y la frecuencia de observación del mismo. Asimismo, este tipo de diagrama incorpora el atributo de resolución, pues evalúa cómo fue la realidad habiendo condicionado la probabilidad pronosticada de ocurrencia (Santos Burguete y Pastor Saavedra, 2018). Si la curva de confiabilidad tiende a ubicarse de forma horizontal, se tiene que la frecuencia observada es constante (cerca a 0.33) independientemente de la probabilidad pronosticada. Por lo tanto, el esquema predictivo no puede resolver más allá de la frecuencia climatológica de observación y, en consecuencia, carece de resolución.




Figura 5-2. Esquema conceptual para la realización de un diagrama de confiabilidad. Para un determinado tipo de evento, el total de pronósticos emitidos es clasificado en intervalos de probabilidad pronosticada (1). Luego, para estos intervalos se contabiliza la frecuencia efectivamente observada del evento (2). En el diagrama, la curva de confiabilidad (línea llena rosa) expresa el resultado de la contabilización. La línea punteada rosa indica el ajuste lineal pesado de la curva de confiabilidad, y la línea punteada negra indica la recta de identidad.

La curva de confiabilidad puede en ocasiones ser difícil de interpretar, pues no incluye información sobre cuál es la proporción de pronósticos que se asocian a cada intervalo de probabilidades. Cuando la muestra es pequeña para algunos intervalos, la curva puede volverse ruidosa. Por esta razón, es recomendable realizar un ajuste lineal pesado a la curva de confiabilidad (Figura 5-2), donde los pesos están dados por la frecuencia de pronósticos emitidos en cada intervalo de probabilidad (OMM, 2018b). Los parámetros de la regresión lineal pesada son la pendiente β_1 y la ordenada al origen β_0 , definidos como (Wilks y Murphy, 1998):

$$\beta_1 = \frac{\sum_{k=1}^d (p_k - \bar{p})(y_k - \bar{y})}{\sum_{k=1}^d n_k (p_k - \bar{p})^2} \quad (5.3)$$

$$\beta_0 = \bar{y} - \beta_1 \bar{x} \quad (5.4)$$

Las ecuaciones (5.3) y (5.4) consideran d intervalos discretos de probabilidad, de forma tal que n_k pronósticos corresponden al k -ésimo intervalo, p_k indica el k -ésimo valor de probabilidad, $\bar{p}$ es la probabilidad promedio de todos los pronósticos emitidos, y_k es la frecuencia observada correspondiente al k -ésimo intervalo, $\bar{x}$ es el promedio de los intervalos de probabilidad considerados, e $\bar{y}$ es la frecuencia observada en todo el período de verificación. La pendiente de esta curva es una medida de la resolución del pronóstico probabilístico, e idealmente debería ser unitaria si se tiene un esquema perfectamente resolutivo.

Adicionalmente, el diagrama de confiabilidad suele acompañarse de un histograma de probabilidades pronosticadas. Este histograma muestra visualmente una medida de la agudeza del pronóstico probabilístico. Como se mencionó anteriormente, un esquema predictivo agudo no emite probabilidades climatológicas frecuentemente, sino que se decanta por emitir pronósticos con alta certeza de ocurrencia ($\sim 100\%$ de probabilidad) y de no ocurrencia ($\sim 0\%$ de probabilidad). Por lo tanto, es deseable que el histograma de probabilidades pronosticadas presente forma de “U” (OMM, 2018b).

5.2.4. Diagrama Relative Operating Characteristic

El diagrama Relative Operating Characteristic (ROC), también conocido como diagrama Receiver Operating Characteristic, permite evaluar la capacidad que tienen los pronósticos de distinguir la ocurrencia de la no ocurrencia de un evento. Este atributo es el que previamente se definió como discriminación, y puede considerarse en la verificación de pronósticos determinísticos y probabilísticos. En el segundo caso, el diagrama ROC permite visualizar la capacidad de discriminación de un esquema predictivo a partir de distintos niveles de confianza probabilística (National Research Council, 2010). En este contexto, cada pronóstico emitido es pensado como un resultado binario con probabilidad de “sí evento” y “no evento”, donde “sí evento” responde a la ocurrencia de una de las tres categorías por terciles, y “no evento” se entiende como la ocurrencia de cualquiera de las otras dos categorías. Por esta razón, se dice que el diagrama ROC permite evaluar la eficiencia que tiene el pronóstico como clasificador binario de eventos (Toth et al., 2003; OMM, 2018b).

El diagrama ROC se construye en forma individual para cada una de las categorías de pronóstico. Para comprender mejor la información que el diagrama provee, se plantea nuevamente como ejemplo el análisis de la eficiencia predictiva para los eventos de precipitación sobrenormal (Figura 5-3). Como se mencionó anteriormente, para la evaluación de la capacidad de discriminación de un pronóstico probabilístico se trabaja con niveles de confianza, cuantificados a través de la magnitud de la probabilidad asignada a la ocurrencia de los eventos. Por esta razón, del conjunto total de pronósticos emitidos se distinguen los “sí eventos” (precipitación sobrenormal efectivamente observada) y los “no eventos” (precipitación subnormal o normal efectivamente observada) asociados a distintos rangos de probabilidad pronosticada, como se muestra en la tabla de la Figura 5-3. Si el pronóstico tuviese buena capacidad de discriminación, los “sí eventos” deberían concentrarse particularmente en los intervalos con mayor magnitud de probabilidad pronosticada (base de la tabla en la Figura 5-3), pues es en estos casos donde hay más acuerdo entre los modelos en que el evento sí ocurrirá y, por lo tanto, habría más certeza en la ocurrencia del fenómeno; por el contrario, los “no eventos” deberían asociarse principalmente a valores bajos de probabilidad de ocurrencia (tope de la tabla en la Figura 5-3). El comportamiento opuesto se observaría si el pronóstico tuviese mala capacidad de discriminación. En cambio, si el pronóstico no fuera de

utilidad, los “sí eventos” y los “no eventos” se distribuirían aleatoriamente a lo largo de todos los intervalos de probabilidad.




Figura 5-3. Esquema conceptual para la realización de un diagrama ROC. Para un determinado tipo de evento se obtiene la tasa de aciertos y la tasa de falsa alarma, dependientes del umbral de detección t_i . Estos valores se plasman en un diagrama ROC a través de una curva (rosa). En sombreado se indica el AUC bajo la curva ROC, y la línea punteada negra indica la recta de identidad.

Para cuantificar la capacidad de discriminación de los pronósticos, se utilizan distintos umbrales de probabilidad a modo de regla de detección del evento. Para un dado umbral t_i , se considera que el esquema predictivo emite un pronóstico afirmativo del evento en todas las situaciones que presenten probabilidad $\hat{p}$ de ocurrencia del evento tal que $\hat{p} \geq t_i$; por el contrario, en las situaciones en las que $\hat{p} < t_i$ se asigna un pronóstico de “no evento”. A partir de un t_i fijo, se calculan las tasas de acierto y falsa alarmas, definidas como (Mason y Stephenson, 2008):

$$\text{Tasa de aciertos}(t_i) = \text{Probabilidad}(\hat{p} \geq t_i \mid \text{"sí evento" observado}) \quad (5.5)$$

$$\text{Tasa de falsa alarma}(t_i) = \text{Probabilidad}(\hat{p} \geq t_i \mid \text{"no evento" observado}) \quad (5.6)$$

La tasa de aciertos (ecuación 5.5) cuantifica la frecuencia con la que se pronosticó al evento que fue efectivamente observado, considerando a t_i como el umbral de detección. Por otro lado, la tasa de falsa alarma (ecuación 5.6) expresa la frecuencia con la que el esquema predictivo emitió un pronóstico de ocurrencia del evento, pero el evento finalmente no sucedió. En la Figura 5-3 se señala cuáles son los casos que corresponden a un acierto o a una falsa alarma para el umbral de detección t_i , a modo de ejemplo.

El diagrama ROC se elabora graficando la tasa de aciertos versus la tasa de falsa alarma para distintos umbrales t_i (Figura 5-3). En un pronóstico útil, a medida que aumenta el valor del umbral de detección se observa que disminuye la tasa de aciertos, pues se exige mayor nivel de certeza para la detección del evento, y eso sólo lo cumplirá un subconjunto de los pronósticos emitidos. Sin embargo, también disminuye la tasa de falsa alarma pues los pronósticos erróneos se vinculan mayoritariamente a valores más bajos de probabilidad de ocurrencia, y no son captados por el umbral de detección impuesto. Adicionalmente, un pronóstico útil presenta una mayor tasa de aciertos que de falsas alarmas para los distintos valores de t_i , con lo cual la curva ROC resultante se ubica por encima de la diagonal a 45°. Dicha diagonal representa a un esquema que no tiene capacidad de discriminación, es decir que no presenta una correspondencia entre los valores de probabilidad pronosticada y la observación de los “sí eventos” y “no eventos”, propiciando que la tasa de aciertos coincida con la tasa de falsas alarmas. Cuanto más apartada de la diagonal hacia la esquina superior izquierda del diagrama se encuentre la curva ROC, mejor será la habilidad del pronóstico probabilístico para detectar la ocurrencia del tipo de evento de interés. Por esta razón, el área que queda encerrada bajo la curva ROC también es usada como métrica de verificación de desempeño. Dicha región, denominada *área bajo la curva* (AUC, por sus siglas en inglés), se incrementa a medida que aumenta la potencia de discriminación del pronóstico y la curva se acerca a la esquina superior izquierda del diagrama. Dado que las tasas de aciertos y de falsas alarmas toman valores entre 0 y 1, la diagonal de carencia de discriminación presenta un $AUC = 0.5$, mientras que un esquema predictivo útil presenta un $AUC > 0.5$.

5.2.5. Otras métricas para atributos múltiples

El Ranked Probability Score (RPS) es una métrica útil para la evaluación integral de los pronósticos probabilísticos, pues combina el desempeño de las K categorías en una única cantidad. Esta métrica integra información sobre los atributos de confiabilidad y resolución.

Para un conjunto de n pronósticos emitidos, el RPS se define como (Weigel et al., 2007):

$$RPS = \frac{1}{n} \sum_{j=1}^n \sum_{k=1}^K (P_{acum_{kj}} - O_{kj})^2 \quad (5.7)$$

donde $P_{acum_{kj}} = \sum_{i=1}^k P_{ij}$, siendo P_{ij} la probabilidad de ocurrencia pronosticada de la i -ésima categoría para la j -ésima situación. Por su parte, O_{kj} representa a la “probabilidad” de la realidad, y se define como $O_{kj} = \sum_{i=1}^k o_{ij}$ donde $o_{ij} = 1$ si se observó la i -ésima categoría en la j -ésima situación, y $o_{ij} = 0$ en el caso contrario. De esta manera, el RPS cuantifica la diferencia cuadrática entre las probabilidades pronosticadas y el evento efectivamente observado en esa situación particular, y equivale a cero en el caso de que el pronóstico haya asignado 100% de probabilidad de ocurrencia a la categoría efectivamente observada (pronóstico ideal).

Al igual que como sucede con el HHP, la magnitud del RPS brinda cierta información sobre la habilidad del esquema predictivo para detectar la ocurrencia de las distintas categorías, pero más útil aún es poder contrastarlo contra un pronóstico de referencia. Es así como se define al Ranked Probability Skill Score (RPSS) (Weigel et al., 2007):

$$RPSS = 1 - \frac{RPS}{RPS_{ref}} \quad (5.8)$$

donde RPS_{ref} indica al RPS del pronóstico de referencia. La ecuación (5.8) toma valores positivos cuando la habilidad del esquema predictivo de interés es superior a la habilidad del pronóstico de referencia, cuantificando así la ventaja vinculada al uso del esquema predictivo por sobre la utilización del pronóstico de referencia.

Tanto el RPS como el RPSS brindan una visión sintetizada sobre la habilidad del pronóstico probabilístico en detectar satisfactoriamente todas las posibles categorías. Sin embargo, podría suceder que el esquema predictivo tenga un mejor desempeño para reconocer la ocurrencia de algún tipo de evento en particular. En este sentido, el Brier Score (BSco) trabaja en forma individual sobre cada categoría de pronóstico mediante la evaluación de la calidad de los pronósticos probabilísticos binarios, es decir, de los pronósticos de tipo “sí evento” y “no evento” (Mason y Stephenson, 2008). El BSco de la i -ésima categoría para un conjunto de n pronósticos probabilísticos emitidos se define como:

$$BSco = \frac{1}{n} \sum_{j=1}^n (P_{ij} - o_{ij})^2 \quad (5.9)$$

En forma similar a las cantidades definidas para el RPS, en la ecuación (5.9) P_{ij} corresponde a la probabilidad pronosticada para la i -ésima categoría en la j -ésima situación, mientras que o_{ij} vale 1 si la i -ésima categoría fue efectivamente observada en la j -ésima situación (“sí evento”) y vale 0 si ocurre otra categoría (“no evento”). Idealmente, si el pronóstico probabilístico fuese perfecto al momento de detectar la ocurrencia de la i -ésima categoría, BSco sería nulo.

Adicionalmente, el BSco puede descomponerse en tres partes distintivas (Toth et al., 2003):

$$BSco = BSco_{conf} + BSco_{res} + BSco_{incert} \quad (5.10)$$

El término $BSco_{conf}$ es una medida de la confiabilidad del esquema predictivo, pues cuantifica la distancia cuadrática de la curva de confiabilidad a la diagonal del diagrama de confiabilidad (Figura 5-2). En segundo lugar, el término $BSco_{res}$ es una medida de la resolución del pronóstico probabilístico, es decir que evalúa si el mismo puede identificar a priori las situaciones que llevan a la ocurrencia o no ocurrencia de un evento en el futuro. Tanto $BSco_{conf}$ como $BSco_{res}$ se anulan en el caso de un sistema de pronóstico perfectamente confiable y resolutivo, respectivamente. Por último, el término $BSco_{incert}$ se lo conoce como *incerteza* y es la parte del BSco que no puede ser reducida mediante

una mejora de los modelos de predicción. La ecuación (5.10) muestra que el BSc_o permite sintetizar a los atributos de confiabilidad y resolución en una única métrica.

En forma análoga al RPSS, se define el Brier Skill Score (BSS) como una métrica que contrasta la capacidad de detección de las distintas categorías entre un esquema predictivo específico y un pronóstico de referencia (Mason y Stephenson, 2008):

$$BSS = 1 - \frac{BSc_o}{BSc_{o_{ref}}} \quad (5.11)$$

donde BSc_{o_{ref}} indica el BSc_o del pronóstico de referencia. La ecuación (5.11) toma valores positivos si el esquema predictivo a evaluar mejora la capacidad de detección del pronóstico de referencia, y valores negativos en el caso contrario.

5.2.6. Síntesis de las herramientas de evaluación

En la Tabla 5-1 se indica un resumen de las herramientas que fueron descritas en la sección 5.2. Las mismas fueron utilizadas para analizar la eficiencia predictiva del pronóstico probabilístico en ambos clusters de la CRB, siempre considerando que la predicción para el j -ésimo año en un mes y cluster específico se realiza mediante los modelos entrenados a partir de los $j-1$ años restantes.

Herramienta	Característica/Atributo	Problemática a responder	Esquema predictivo deseable
Diagrama de tendencia	Sesgo no condicionado	¿Existen sesgos sistemáticos en las probabilidades pronosticadas de cada categoría?	La frecuencia promedio de pronóstico de cada categoría se asemeja a la frecuencia climatológica
HSS	Proporción de aciertos Resolución (empleando a la climatología como pronóstico de referencia)	El pronóstico, ¿mejora la tasa de aciertos respecto a la referencia?	$HSS > 0$, $HSS = 1$ (idealmente)
Diagrama de confiabilidad	Resolución Confiabilidad	¿Se observan distintos eventos si fueron dados distintos pronósticos? La frecuencia de ocurrencia de un evento, ¿depende de la probabilidad con la que es pronosticado?	La curva de confiabilidad se posiciona sobre la recta de pendiente unitaria
Histograma de frecuencia pronosticada	Agudeza	¿Con qué frecuencia se emiten distintas probabilidades de un evento?	Histograma con forma de “U”: altas frecuencia de pronósticos con probabilidad cercana a 0% y a 100%; baja frecuencia de pronósticos con probabilidades climatológicas
RPSS BSS	Confiabilidad Resolución	Los pronósticos, ¿asocian la ocurrencia de los eventos a mayores probabilidades de ocurrencia?	$RPSS > 0$, $RPSS = 1$ (idealmente) $BSS > 0$, $BSS = 1$ (idealmente)
Diagrama ROC AUC	Discriminación	Los pronósticos, ¿distinguen un “sí evento” de un “no evento”?	Curva ROC convexa hacia la esquina superior izquierda del diagrama. $AUC > 0.5$, $AUC = 1$ (idealmente)

Tabla 5-1. Síntesis de las herramientas de análisis de eficiencia predictiva utilizadas para los pronósticos probabilísticos de la CRB.

5.3. Resultados de la evaluación de los pronósticos probabilísticos

En esta sección, se presentan los resultados de aplicar las herramientas incluidas en la Tabla 5-1 sobre los pronósticos probabilísticos de la precipitación mensual en ambos clusters. Debido a que se optó por un sistema de pronóstico de triple categoría, gran parte de las herramientas se orientan a evaluar la capacidad de los pronósticos en detectar las situaciones de precipitación subnormales, normales, y sobrenormales.

La Figura 5-4 muestra los diagramas de tendencia de cada categoría a lo largo del semestre estival, con el propósito de evaluar si los pronósticos sesgan sus estimaciones hacia un tipo de evento en particular. Se puede observar que la frecuencia climatológica varía levemente alrededor del valor esperado de 33%. Esto es porque las muestras de entrenamiento se modifican según el año objetivo, con lo cual puede suceder que cada categoría no ocurra exactamente un tercio de las veces para todos los meses en el período 1984/1985-2019/2020. Idealmente, en un esquema predictivo no sesgado debería observarse en cada mes que la probabilidad promedio de pronóstico y la frecuencia observada del evento son similares. En la Figura 5-4 puede notarse rápidamente que los pronósticos tienden a sobreestimar la frecuencia de ocurrencia de eventos normales, especialmente en el cluster 2. Anteriormente en el Capítulo 4, al estudiar el desempeño desde el enfoque determinístico, se observó que los modelos tienden a subestimar la variabilidad de las series temporales de precipitación mensual (ver por ejemplo la Figura 4-12). Esto puede traducirse en que muchas de las estimaciones tiendan hacia la categoría intermedia de pronóstico, esto es la categoría normal, en detrimento de la previsión probabilísticas de las categorías más extremas. De hecho, en líneas generales no se observa una mayor frecuencia de previsión de las categorías subnormal o sobrenormal comparado a lo esperado; sólo en febrero se observa una leve sobreestimación en la previsión de la categoría sobrenormal (subnormal) en el cluster 1 (cluster 2), pero con frecuencias muy similares a las observadas.




Figura 5-4. Diagramas de tendencia del pronóstico probabilístico categórico para el cluster 1 (fila superior) y cluster 2 (fila inferior). Las categorías consideradas son de precipitación subnormal (“sub”, primera columna), normal (“nor”, segunda columna), y sobrenormal (“sobre”, tercera columna). Los paneles comparan la probabilidad promedio pronosticada (naranja) y la frecuencia observada (gris) de cada tipo de evento a lo largo del semestre estival (eje-y).

Las mayores diferencias entre el pronóstico y las observaciones se presentan en el cluster 2, especialmente para los eventos subnormales en diciembre y marzo. En particular, la categoría sobrenormal tiende a ser mejor representada en este cluster durante la primavera. En los meses de verano, la subestimación de los eventos sobrenormales se profundiza, mientras que la representación de los eventos subnormales es más variable a lo largo de estos meses. Por otro lado, en el cluster 1 las diferencias entre la frecuencia

observada y pronosticada para la categoría sobrenormal es menor comparada a la categoría subnormal a lo largo de todo el semestre, a excepción del mes de noviembre.

El diagrama de tendencia muestra en forma sencilla si los pronósticos tienden a sesgarse en promedio hacia alguna categoría específica. Sin embargo, no ahondan en la correspondencia individual entre el evento con más chances de ocurrencia y el evento efectivamente observado. Es por esta razón que se presenta en la Figura 5-5, cuál es la frecuencia de pronósticos eficientes, subestimaciones, y sobreestimaciones para cada mes y cluster. En este contexto, se entiende por pronóstico eficiente a la coincidencia entre la categoría con mayor probabilidad pronosticada y el evento efectivamente observado. Por otro lado, las subestimaciones de una categoría (notadas como “Sub1” en la Figura 5-5) corresponden a situaciones en las cuales se estimó con mayor chance de ocurrencia a una categoría por debajo de la realmente observada (por ejemplo, se pronosticó normalidad, pero aconteció un evento de precipitación sobrenormal). Las subestimaciones de dos categorías (“Sub2” en la Figura 5-5) refieren a situaciones en las cuales un pronóstico de categoría subnormal fue sucedido por un evento sobrenormal. Las sobreestimaciones de una y dos categorías (“Sobre1” y “Sobre2” en la Figura 5-5, respectivamente) se definen en forma análoga. La Figura 5-5 exhibe en su panel superior cuál es la frecuencia neta de cada tipo de estimación, mientras que en el panel inferior se destaca la diferencia entre el cluster 1 y el cluster 2. Las diferencias positivas indican una mayor preponderancia de casos en el cluster 1 que en el cluster 2, y viceversa para las diferencias negativas.

La Figura 5-5 muestra que en toda la región hay una mayor frecuencia de pronósticos eficientes que de otro tipo de estimaciones, principalmente en octubre, noviembre, y febrero. Asimismo, los pronósticos eficientes tienden a ser más frecuentes en el cluster 1 que en el cluster 2 en la mayoría de los meses. La mayor eficiencia se alcanza en noviembre en el cluster 1, con una frecuencia de coincidencia de categorías mayor al 60%. En líneas generales, las subestimaciones y sobreestimaciones de una categoría son más frecuentes que en dos categorías en ambos clusters, es decir que los pronósticos son más propensos a confundir un evento normal con un evento extremo, y menos propensos a confundir dos categorías extremas entre sí. El cluster 2 tiende a cometer subestimaciones de una categoría más frecuentemente que el cluster 1 en verano, aunque los contrastes más evidentes entre clusters para los errores de una categoría se observan en el trimestre de primavera. En este sentido, el cluster 1 presenta mayor frecuencia que el cluster 2 tanto de sobreestimaciones (octubre) como subestimaciones (noviembre y

diciembre), mientras que el cluster 2 emite mayor cantidad de pronósticos que sobreestiman en el mes de noviembre. Por otro lado, los errores de dos categorías son mucho menos frecuentes que los de una categoría. En el cluster 1, se observan hacia el trimestre de verano, principalmente en las sobreestimaciones. Esto implica que los pronósticos tienden a prever una situación de precipitación sobrenormal ante eventos efectivamente subnormales. En el cluster 2 se observan errores de dos categorías a lo largo de todo el semestre estival, pero con baja frecuencia de ocurrencia comparado a los otros tipos de estimaciones.




Figura 5-5. Desempeño de los pronósticos probabilísticos en términos de eficiencia (coincidencia de categoría), subestimación de una y dos categorías (Sub1 y Sub2, respectivamente), y sobreestimación de una y dos categorías (Sobre1 y Sobre2, respectivamente). **Fila superior:** para cada cluster y en cada mes se indica la frecuencia porcentual con la que se observó cada tipo de estimación. **Fila inferior:** diferencia en la frecuencia porcentual de cada tipo de pronóstico para cada mes entre clusters (cluster 1 – cluster 2). Para un determinado tipo de estimación, las celdas de color violeta (verde) indican una mayor frecuencia de ocurrencia en el cluster 1 (cluster 2).

Si bien para un dado mes la frecuencia de casos de eficiencia de los esquemas predictivos predomina por sobre los demás tipos de estimación en ambos clusters, la climatología por definición también es eficiente en aproximadamente un tercio de los pronósticos emitidos. Para poder comparar el desempeño de los pronósticos estadísticos contra la eficiencia esperada por la climatología, se calculó para cada mes y cluster el valor del HSS_{clima} , es decir del HSS calculado tomando a la climatología como pronóstico de referencia (Figura 5-6). Los valores positivos del HSS_{clima} implican una mejora en los aciertos respecto a la referencia y, dado que la referencia es la climatología, también implican que el pronóstico cuenta con cierto grado de resolución. En este caso, en ningún mes se observa que HSS_{clima} tome valores negativos, es decir que en todos los meses el pronóstico probabilístico logra mejorar, o al menos reproducir, los aciertos y la resolución dados por la climatología. A excepción de octubre, a lo largo del semestre estival esta métrica muestra valores más favorables para el cluster 1, particularmente en noviembre y febrero ($HSS_{clima} = 0.5$, $HSS_{clima} = 0.42$, respectivamente). Por el contrario, en el cluster 2 la métrica se mantiene por debajo de 0.3 entre noviembre y marzo, alcanzando un mínimo cercano a cero en enero. Al igual que sucede en el cluster 1, los valores más altos del HSS_{clima} se observan en octubre y noviembre (comienzo y mediados de primavera), y en febrero, mes en el cual se dispone de la máxima cantidad de predictores a partir de los cuales desarrollar los modelos estadísticos.




Figura 5-6. Valores del HSS_{clima} a lo largo del semestre estival para el cluster 1 (violeta) y cluster 2 (verde). Los valores exactos de la métrica se indican en blanco. La referencia utilizada para calcular HSS_{clima} corresponde a probabilidades climatológicas.

En principio, la cantidad de aciertos de categoría cuantificada a través del HSS sería favorable para gran parte de los meses en la CRB. El tipo de evento pronosticado se obtuvo en función de cuál fue la categoría con mayor probabilidad de ocurrencia. Sin embargo, un sistema de pronóstico que presenta una tasa de aciertos satisfactoria podría aun así no presentar una buena correspondencia entre la probabilidad pronosticada y la frecuencia observada del evento, o brindar sistemáticamente probabilidades muy similares de ocurrencia entre distintas categorías como sucede con la climatología. En este sentido, se vuelven relevantes los atributos de confiabilidad, resolución, y agudeza, que se exhiben en las Figuras 5-7 para el cluster 1, y 5-8 para el cluster 2. Estas Figuras muestran los diagramas de confiabilidad para cada una de las tres categorías de pronóstico, incluyendo la curva de confiabilidad y el ajuste lineal pesado asociado a la curva. Además, se muestra el histograma de probabilidades pronosticadas para cada tipo de evento, vinculado al atributo de agudeza. En ambas Figuras, se combinaron los pronósticos de precipitación mensual de octubre a diciembre (OND) por un lado, y de enero a marzo (EFM) por el otro, con el propósito de evaluar cómo se comportan estos atributos según si se trata de pronósticos emitidos para los meses de la primavera o del verano. Para este análisis, la probabilidad pronosticada fue discretizada en intervalos de ancho 0.2, lo suficientemente fino para analizar el desempeño de los pronósticos a medida que varía la certeza de los mismos, pero también procurando disminuir las chances de encontrar intervalos vacíos.

La Figura 5-7 muestra los diagramas de confiabilidad y agudeza para el cluster 1. Durante la primavera (Figura 5-7 fila superior), las categorías subnormal y sobrenormal son las que mejor desempeño muestran en términos de la confiabilidad y resolución de los pronósticos, puesto que las curvas asociadas se posicionan cerca de la recta de pendiente unitaria. En particular, al discretizar la probabilidad pronosticada, surge nuevamente el sesgo negativo de los eventos subnormales que previamente se había notado en el diagrama de tendencia (Figura 5-4, panel superior izquierdo). El sesgo negativo en el diagrama de confiabilidad se produce porque la curva se posiciona por sobre la recta a 45° para todos los intervalos de probabilidad pronosticada. Esto implica que dicha probabilidad es sistemáticamente menor a la frecuencia con la que se observa la categoría subnormal. En el caso de los eventos sobrenormales, el sesgo negativo no se presenta en todos los intervalos de probabilidad, sino que cuando los pronósticos tienen más certeza de la ocurrencia del fenómeno (valores más altos de probabilidad), la frecuencia

observada del mismo es menor, lo que se traduce en que la pendiente del ajuste lineal es menor a la unidad. Este comportamiento se denomina *sobreconfianza*, y es un ejemplo de sesgo condicionado por la probabilidad de pronóstico (OMM, 2018b). Finalmente, la pendiente del ajuste lineal de la categoría normal sugiere que para este tipo de evento los pronósticos presentan la menor resolución, pues la frecuencia observada de los eventos normales varía muy poco según la probabilidad pronosticada. Además, el diagrama de agudeza vinculado a esta categoría muestra un histograma con frecuencia casi constante, lo que sugiere que el esquema predictivo tiene dificultad para emitir pronósticos con gran certeza de ocurrencia/no ocurrencia de precipitación normal. Por el contrario, los diagramas de agudeza de las categorías extremas tienden a emitir una mayor cantidad de pronósticos con baja probabilidad de ocurrencia (probabilidad < 0.2), que son altamente confiables según la curva de confiabilidad. Para estas categorías, el histograma no muestra un máximo en las probabilidades climatológicas (probabilidad en el rango 0.2 – 0.4, siguiendo la discretización empleada), lo cual es favorable en términos de agudeza a pesar de que el histograma no presenta forma de “U”.

Al pasar al análisis de los pronósticos de verano (Figura 5-7, fila inferior), no se distinguen cambios relevantes en la eficiencia de los pronósticos de la categoría normal, tanto a partir del diagrama de confiabilidad como del diagrama de agudeza. Sin embargo, al evaluar la pendiente de la curva de confiabilidad sí se destaca la pérdida de resolución en la predicción de los eventos subnormales y sobrenormales comparado con el trimestre anterior. Ambos tipos de eventos muestran cierto grado de sobreconfianza, aunque los eventos sobrenormales presentan una pendiente del ajuste lineal ligeramente más favorable que los eventos subnormales. El diagrama de agudeza vinculado a los eventos subnormales no presenta diferencias sustanciales en EFM respecto a OND, mientras que para la categoría sobrenormal existe cierta mejora en la agudeza por el aumento en la frecuencia con la que se pronostica la categoría de mayor certeza (probabilidad en el rango 0.8 – 1.0).




Figura 5-7. Diagrama de confiabilidad del cluster 1 (*primera columna*) para los pronósticos probabilísticos mensuales en el trimestre OND (*fila superior*) y EFM (*fila inferior*), considerando las categorías subnormal (rojo), normal (gris), y sobrenormal (verde). En ambas filas se incluye además el diagrama de agudeza de cada categoría (*segunda columna*), que exhibe el histograma de probabilidades pronosticadas. En el diagrama de confiabilidad se incluye la recta identidad (negra) y los ajustes lineales pesados de las curvas de confiabilidad (líneas punteadas).




Figura 5-8. Análogo a la Fig. 5-7 para el cluster 2.

La Figura 5-8 muestra los diagramas de confiabilidad y agudeza para el cluster 2. Al igual que para el cluster 1, el pronóstico de los eventos normales es el que peor desempeño muestra en términos de la confiabilidad y la resolución. De hecho, durante el verano el ajuste lineal de la curva de confiabilidad para esta categoría presenta una pendiente muy cercana a cero, lo que muestra que el pronóstico de los eventos normales no logra detectar esta categoría en las situaciones individuales, y tiene la misma eficiencia que un pronóstico basado en la climatología. Las categorías extremas muestran mejor resolución que la categoría normal, aunque la pendiente del ajuste lineal es sustancialmente menor que para los mismos eventos en el cluster 1, particularmente si se compara contra los pronósticos de primavera en el cluster 1. Por otro lado, a juzgar por el acercamiento de las curvas a la recta identidad, las categorías extremas tienden a presentar una mayor confiabilidad en los pronósticos de probabilidad de ocurrencia baja a intermedia (probabilidad en el rango 0.0 – 0.6, aproximadamente) en ambos trimestres, pero la

probabilidad de ocurrencia es fuertemente subestimada comparada a la realidad en las categorías de probabilidad más altas. Con respecto al atributo de agudeza, los pronósticos emitidos para la categoría subnormal no muestran grandes diferencias respecto al cluster 1, pues presentan la máxima frecuencia en bajas probabilidades de ocurrencia del evento (probabilidad < 0.2). La agudeza es más marcada en el caso de los pronósticos de sobrenormalidad, particularmente en la primavera, pues el histograma se acerca más a una forma de doble máximo tipo “U”, con baja frecuencia de pronósticos con probabilidad intermedia de ocurrencia del fenómeno.

Los diagramas de confiabilidad contienen mucha información respecto a la confiabilidad y resolución de los pronósticos para intervalos de probabilidad discretos. Para poder resumir estos atributos en métricas específicas, se obtuvieron el $RPSS_{clima}$ y el BSS_{clima} siguiendo a las ecuaciones (5.7) a (5.11). Ambas métricas fueron calculadas tomando a la climatología como pronóstico de referencia, de forma de poder analizar si existe una mejora relativa de los modelos de predicción en comparación a la frecuencia climatológica esperada. Ambas métricas fueron calculadas para cada cluster y para cada mes del semestre estival en forma individual. Asimismo, ambas métricas muestran valores positivos si efectivamente se observa una mejora respecto a la climatología.

La Figura 5-9 muestra la métrica $RPSS_{clima}$, que combina la eficiencia de pronóstico para las tres categorías de precipitación mensual. Esta métrica muestra valores favorables (positivos) en octubre, noviembre, y febrero para el cluster 1, y en octubre y febrero para el cluster 2. En el resto de los meses se muestra que los esquemas predictivos no logran aportar una mejora respecto al pronóstico por climatología. Sin embargo, como se observó en las Figuras 5-7 y 5-8, el desempeño de los pronósticos probabilísticos en términos de confiabilidad y resolución depende del tipo de evento. Esto implica, por ejemplo, que el menor desempeño de los pronósticos para eventos normales podría estar afectando la magnitud de la métrica.




Figura 5-9. Valores de $RPSS_{clima}$ tomando como referencia a la climatología en cada mes del semestre estival para ambos clusters. Valores positivos en verde (negativos en amarillo) indican una mejora (un empeoramiento) respecto a la climatología.



Figura 5-10. Valores de BSS_{clima} tomando como referencia a la climatología para las categorías subnormal (Sub), normal (Nor), y sobrenormal (Sobre) en cada mes del semestre estival para ambos clusters. Valores positivos en verde (negativos en amarillo) indican una mejora (un empeoramiento) respecto a la climatología

En la Figura 5-10 se presenta el valor de BSS_{clima} para cada tipo de evento, con el propósito de evaluar las diferencias en el desempeño según la categoría. Al emplear esta métrica, se observa que los esquemas predictivos presentan un mejor desempeño respecto a la climatología ($BSS_{clima} > 0$) principalmente en relación a los pronósticos de las categorías subnormal y sobrenormal. En el cluster 1, los modelos presentan buena confiabilidad y resolución relativa a la climatología a lo largo de toda la primavera para la categoría subnormal, mientras que los pronósticos de la categoría sobrenormal muestran un buen rendimiento en octubre y noviembre. En el verano, la eficiencia de los pronósticos subnormales decrece en relación a los meses anteriores, mientras que la categoría opuesta se asocia a estimaciones con BSS_{clima} favorable para febrero y marzo. En particular, el mes de febrero presenta BSS_{clima} positivo para las tres categorías de precipitación. Por otro lado, en líneas generales el cluster 2 presenta un peor rendimiento en relación a esta métrica si se compara con el cluster 1. Los pronósticos mejoran la estimación por climatología en términos de la confiabilidad y la resolución en octubre (especialmente para los eventos subnormales), y en febrero para las categorías subnormal y sobrenormal. En el resto de los casos, se observa que BSS_{clima} toma valores negativos, es decir que los pronósticos estadísticos no aportan una mejora respecto a la climatología.

Finalmente, se construyeron los diagramas ROC para evaluar el atributo de discriminación del pronóstico probabilístico, es decir la capacidad del mismo para distinguir un “sí evento” de un “no evento” dado el sistema de triple categoría de la precipitación (Figura 5-11). Idealmente, un esquema predictivo con capacidad de discriminación se vincula a una curva ROC que deja un área mayor a 0.5 bajo sí misma. En este caso, para su construcción se repitió la discretización del rango de probabilidades posibles en intervalos de ancho 0.2. Asimismo, al igual que en los diagramas de confiabilidad, se combinaron los pronósticos de precipitación mensual según si corresponden al trimestre de primavera (OND) o al de verano (EFM).




Figura 5-11. Diagrama ROC para los pronósticos probabilísticos mensuales en los trimestres OND y EFM para ambos clusters. En cada panel se indica la recta identidad (línea punteada) y las curvas ROC asociadas a cada tipo de categoría (subnormal, normal, y sobrenormal). Se incluye también el área bajo la curva (AUC) de cada categoría en la esquina inferior derecha de cada panel.

Observando las curvas ROC de la Figura 5-11, se destaca que la mejor capacidad de discriminación se tiene para los pronósticos de eventos subnormales y sobrenormales en el cluster 1. En estos casos, las curvas ROC se ubican por encima de la diagonal que representa ausencia de habilidad, es decir que para todos los intervalos de probabilidad considerados la tasa de aciertos supera a la tasa de falsa alarma. En la primavera, el AUC vinculado al pronóstico de eventos subnormales ($AUC = 0.84$) es mayor que para eventos

sobrenormales ($AUC = 0.75$), aunque ambos muestran un AUC mayor al umbral de no discriminación (0.5). En verano, esta relación se invierte de forma tal que los eventos sobrenormales son mejor detectados que los subnormales ($AUC = 0.76$ y $AUC = 0.67$, respectivamente). En contraste, las curvas ROC y los AUC asociados muestran una menor capacidad de discriminación de los eventos subnormales y sobrenormales en el cluster 2. Para esta región en ambos trimestres, las categorías extremas difieren menos entre sí en cuanto a la relación de aciertos versus falsas alarmas, como así también en el valor del AUC asociado. El contraste más grande entre categorías se observa en el verano (Figura 5-11, inferior derecha), cuando la curva ROC de eventos sobrenormales se acerca más al eje de aciertos y se aleja más de la recta identidad que la curva ROC subnormal ante situaciones de media y alta probabilidad de ocurrencia (lado izquierdo de la curva). Esto implica que, cuando el pronóstico tiene menos incertidumbre, la capacidad de distinguir un evento sobrenormal de otro tipo de evento es mayor que la capacidad de distinguir un evento subnormal. Por otro lado, así como se obtuvo para el diagrama de confiabilidad y para las métricas $RPSS_{clima}$ y BSS_{clima} , al evaluar el atributo de discriminación se observa que los eventos normales son los que peor desempeño presentan. En el cluster 1, esta categoría exhibe el menor AUC en ambos trimestres, especialmente en el verano. En el cluster 2, los pronósticos de eventos normales presentan una capacidad de discriminación similar a las otras categorías en la primavera, pero en verano esa capacidad decrece y se acerca fuertemente a la diagonal de no discriminación ($AUC = 0.52$).

La Figura 5-12 resume los anteriores valores del AUC de cada categoría en función del mes de pronóstico, con el propósito de evaluar si existe variabilidad intraestacional en la capacidad de discriminación de los eventos. En principio, existen pocos casos en los cuales el AUC no alcanza el umbral de no discriminación (enero en el cluster 1 y en el cluster 2 para la categoría normal, y diciembre para el cluster 2 en la categoría subnormal). Sin embargo, se destaca nuevamente que el cluster 1 tiende a mostrar valores más altos del AUC mensual en comparación al cluster 2. En el cluster 1, los pronósticos a nivel mensual muestran habilidad de discriminación en todos los meses para los eventos subnormales y sobrenormales. En particular, los eventos subnormales presentan el máximo AUC en noviembre y diciembre, mientras que los pronósticos de eventos sobrenormales se destacan por su habilidad principalmente a comienzos y mediados de la primavera, y hacia mediados y fines del verano. Por el contrario, el cluster 2 muestra en general menores magnitudes del AUC para las categorías extremas. Los pronósticos de

eventos subnormales presentan mejor habilidad en los meses de octubre y febrero, mientras que los sobrenormales muestran mejor desempeño a comienzos y mediados de la primavera, y hacia mediados y fines del verano. Así como se observó al emplear otras herramientas de verificación, los eventos normales muestran baja capacidad de discriminación en general, con mejoras relativas en noviembre en el cluster 1, y entre octubre y noviembre en el cluster 2.




Figura 5-12. Valores de AUC para las categorías subnormal (Sub), normal (Nor), y sobrenormal (Sobre) en cada mes del semestre estival para ambos clusters. Los cuadros con líneas en diagonal superpuestas indican que el AUC para ese mes y esa categoría es menor a 0.5.

A modo de síntesis de los resultados obtenidos, se indica en la Tabla 5-2 cómo fue el desempeño del pronóstico probabilístico según las métricas empleadas. En dicha Tabla se destaca el valor del HSS_{clima} , como una medida de la tasa de aciertos general de los pronósticos relativo al pronóstico por climatología (las celdas en sombreado verde más oscuro se corresponden con valores más favorables del HSS_{clima}). Asimismo, en sombreado celeste se indican:

- Los casos donde el diagrama de tendencia (DT) muestra un sesgo no condicionado de magnitud menor al 10%, comparado contra las observaciones.
- Los casos donde el BSS_{clima} muestra valores mayores o iguales a cero, como una medida de resolución y confiabilidad.
- Los casos donde el AUC es mayor o igual a 0.5, como una medida de discriminación.

A excepción del HSS_{clima} , en esta Tabla no se incluye una comparación de la magnitud relativa de las métricas, sino que simplemente se destacan aquellas cantidades que cumplen los criterios que se indican arriba. En la Tabla 5-2 se muestra que los pronósticos probabilísticos presentan grandes dificultades para representar eficientemente la ocurrencia de eventos normales, particularmente en términos de sesgo, confiabilidad y resolución. El cluster 1 presenta un mejor rendimiento que el cluster 2 en líneas generales, pues una mayor cantidad de métricas muestran magnitudes favorables para los atributos que caracterizan a los “buenos” pronósticos. En particular, la presencia de sesgos condicionados tiende a ser menor para los eventos sobrenormales que subnormales. Por otro lado, los pronósticos probabilísticos del cluster 2 presentan buena habilidad de discriminación para las categorías extremas, aunque tienen algunas dificultades en términos de sesgo no condicionado, resolución y confiabilidad. Combinando las métricas por categoría de la Tabla 5-2 con la tasa de aciertos relativa cuantificada mediante el HSS_{clima} , se puede destacar que los pronósticos del cluster 1 son particularmente eficientes para los meses de octubre, noviembre, y febrero, mientras que en el cluster 2 la eficiencia es máxima en octubre y febrero.

CLUSTER 1										
	HSS	Sub			Nor			Sobre		
		DT	BSS	AUC	DT	BSS	AUC	DT	BSS	AUC
Oct	0.34									
Nov	0.50									
Dic	0.11									
Ene	0.15									
Feb	0.42									
Mar	0.15									
CLUSTER 2										
	HSS	Sub			Nor			Sobre		
		DT	BSS	AUC	DT	BSS	AUC	DT	BSS	AUC
Oct	0.42									
Nov	0.23									
Dic	0.07									
Ene	0.0									
Feb	0.27									
Mar	0.07									

Tabla 5-2. Síntesis del desempeño del pronóstico probabilístico de triple categoría (subnormal “Sub”, normal “Nor”, y sobrenormal “Sobre”) según las herramientas empleadas para cada mes del semestre estival y cada cluster. El sufijo “clima” para las métricas HSS_{clima} y BSS_{clima} fue removido por conveniencia en la Tabla. En azul se somborean los casos donde la verificación es favorable según las métricas por categorías que se indican en el rótulo de columna (ver texto para detalles). La columna del HSS indica los valores exactos de dicha métrica, con la intensidad del sombreado según su magnitud.

5.4. Comparación con pronósticos dinámicos emitidos por centros operativos

Existen diversas fuentes de incertidumbre relacionadas al pronóstico a mediano plazo, vinculadas tanto a la naturaleza caótica de los procesos físicos que ocurren en el sistema climático, como a las limitaciones propias de los sistemas de pronóstico estadísticos y dinámicos (Doblas-Reyes et al., 2013). Si bien es recomendable combinar la mayor cantidad de herramientas de previsión posibles para la confección de un pronóstico probabilístico robusto, algunos autores han evaluado comparativamente la eficiencia de las predicciones estacionales de origen estadístico y de origen dinámico, encontrando que no existe un dominio total y sistemático de unas sobre otras (Moura y Hastenrath, 2004; Van Oldenborgh et al., 2005; Coelho et al., 2006; Eden et al., 2015). Por esta razón, a

continuación, se realizará un análisis comparativo de eficiencia de un conjunto de predicciones de origen dinámico emitidas por centros operativos internacionales versus las estimaciones a paso mensual dadas por los modelos estadísticos diseñados en este estudio.

5.4.1. Sistemas de pronóstico empleados y estrategia de comparación

Para este análisis, se emplearon los pronósticos de precipitación mensual de origen dinámico que se encuentran disponibles a través del portal del Copernicus Climate Change Service (C3S), un servicio implementado por el ECMWF con el objetivo de proveer a la comunidad de información del pasado, presente, y potencial futuro en forma abierta y gratuita (Buontempo et al., 2022). En particular, el C3S presta un servicio de pronóstico estacional multisistema, que incluye pronósticos creados en tiempo real y pronósticos retrospectivos o *hindcasts*. Dentro de las variables disponibles, se encuentra la precipitación acumulada a escala mensual en puntos de retícula bajo distintos desfases temporales de pronóstico (C3S, 2018).

En este estudio, se seleccionaron los sistemas de pronóstico provistos por el ECMWF, el Servicio Meteorológico de Alemania (Deutscher Wetterdienst, DWD), el Servicio Meteorológico de Francia (Météo-France, MF), y el departamento gubernamental de Canadá orientado a la coordinación de programas ambientales (Environment and Climate Change Canada, ECCC). Mediante el C3S, estas instituciones aportan previsiones determinísticas basadas en modelos numéricos acoplados con cobertura global (Tabla 5-3). Dichos modelos incluyen representaciones de la atmósfera, el océano, la criósfera, y la superficie continental, así como de los procesos de acople entre los mismos. Además, cada sistema de pronóstico incluye un ensamble constituido por un conjunto de miembros, obtenidos mediante la introducción de perturbaciones en las condiciones de inicialización de los modelos, como una forma de incorporar la incertidumbre dada por el conocimiento imperfecto de las condiciones iniciales reales del sistema climático (C3S, 2018). Por conveniencia de nomenclatura, los pronósticos provenientes de los modelos dinámicos serán referidos a partir de ahora en función del nombre del centro operativo de origen (Tabla 5-3).

Centro de origen del pronóstico	Nombre del sistema de pronóstico	Modelo	Período	Cantidad de miembros del ensamble	Referencia
ECMWF	SEAS5	Modelo acoplado <u>Atmósfera y suelo:</u> modelo IFS Cycle 43r1 (~36 km resolución horizontal) <u>Océano y criósfera:</u> modelo NEMO v3.4 (ORCA 0.25° resolución horizontal)	1984/1985-2019/2020	25 miembros durante hindcast (1984-2016), 51 miembros durante pronóstico operativo (2017-2020)	Johnson et al. (2019)
DWD	GCFS 2.0	Modelo acoplado <u>Atmósfera:</u> modelo ECHAM 6.3.04 (~100 km resolución horizontal) <u>Suelo:</u> modelo JSBACH (~100 km resolución horizontal) <u>Océano y criósfera:</u> modelo MPIOM 1.6.3 (~0.4° resolución horizontal)	1993/1994-2017/2018	30 miembros durante hindcast (1993-2017), 51 miembros durante pronóstico operativo (2018)	Fröhlich et al. (2021)
MF	Météo-France System 8	Modelo acoplado <u>Atmósfera:</u> modelo ARPEGE v6.4 (~0.5° resolución horizontal) <u>Suelo:</u> modelo SURFEX v8 (~0.5° resolución horizontal) <u>Océano y criósfera:</u> modelo NEMO v3.6 (ORCA 0.25° resolución horizontal)	1993/1994-2017/2018	25 miembros durante hindcast (1993-2016), 51 miembros durante pronóstico operativo (2017-2018)	Batté et al. (2021)
ECCC	CanCM4i	Modelo acoplado <u>Atmósfera y suelo:</u> modelo CanAM4 (~2.8° resolución horizontal) <u>Océano y criósfera:</u> modelo CanOM4 (~1.4° resolución longitudinal y ~0.94° resolución latitudinal)	1993/1994-2017/2018	10 miembros durante hindcast (1993-2016) y durante pronóstico operativo (2017-2018)	Lin et al. (2020)

Tabla 5-3. Sistemas de pronóstico basados en modelos dinámicos para el análisis de la comparación de eficiencia. Se incluye el centro operativo que aporta el pronóstico, nombre identificador del sistema, composición de los modelos acoplados, período para el análisis, cantidad de miembros y referencias.

Si bien los modelos presentan una variedad de resoluciones espaciales distintas (Tabla 5-3), los pronósticos de la precipitación acumulada mensual se encuentran disponibles en el C3S con una resolución horizontal común de 1°. Asimismo, todos los sistemas de pronóstico contenidos en el C3S presentan un período de hindcast que finaliza en el año 2016, momento a partir del cual se cuenta con pronósticos en tiempo real. Aun así, existen ciertas variaciones en el año de inicio de los períodos de hindcast. Para poder realizar una comparación de la eficiencia con los modelos estadísticos hallados en este estudio, idealmente se debería contar con pronósticos de la precipitación mensual en los semestres estivales de 1984/1985-2019/2020. Sin embargo, sólo ECMWF cuenta con pronósticos coincidentes con el período de verificación de los pronósticos estadísticos; el resto de los sistemas pone a disposición sus pronósticos con una cobertura temporal más acotada. Por esta razón, la comparación se llevó adelante considerando el período 1984/1985-2019/2020 para ECMWF (36 temporadas estivales), y el período 1993/1994-2017/2018 (25 temporadas estivales) para DWD, MF, y ECCC (Tabla 5-3). En todos los casos, el período de verificación incluye mayoritariamente pronósticos de hindcast, aunque se incluyen también algunos años de pronósticos en tiempo real (posterior a 2016). Si bien la habilidad estimada sobre el hindcast puede diferir de la habilidad de los pronósticos operativos (Johnson et al., 2019), se optó por incrementar el tamaño de la muestra de verificación de los modelos acoplados de forma que el cálculo de las métricas de desempeño se vea limitado lo menos posible por la cantidad de situaciones pronosticadas. Adicionalmente, se decidió tomar las estimaciones generadas por los modelos acoplados al comienzo del mes objetivo de pronóstico, en forma análoga a cómo se realizaría un pronóstico operativo de origen estadístico una vez conocidos los predictores del mes previo.

La Figura 5-13 muestra la grilla correspondiente a la resolución horizontal de 1° de los sistemas de pronóstico del C3S sobre la región de estudio. Debido a que la variable de interés es la precipitación mensual areal en la región, se seleccionaron aquellos puntos de retícula que estuvieran totalmente contenidos dentro de las áreas de la CRB asociadas al cluster 1 y al cluster 2. Para ello, se tomó la longitud de la estación más oriental del cluster 1 dentro de la CRB (Figura 2-19, estación Las Lomitas [24.70°S;60.58°O]) como límite geográfico de separación entre los puntos de retícula correspondientes a cada cluster. Luego, a lo largo del semestre estival para cada sistema de pronóstico y para cada cluster se obtuvo la serie temporal pronosticada de precipitación mensual areal como el promedio

aritmético de la precipitación mensual estimada en cada punto de retícula que corresponde al cluster (Figura 5-13).




Figura 5-13. Reticulado de los modelos globales con 1° de resolución horizontal sobre la región de estudio. En rosa (verde) se indican los puntos tomados para el promedio areal del cluster 1 (cluster 2).

Como se mencionó anteriormente, existen ciertas métricas que expresan la mejora relativa de un esquema predictivo contra un pronóstico de referencia. Anteriormente, en la sección 5.3, se empleó a la climatología como dicha referencia para la obtención de las métricas de confiabilidad y resolución (RPSS y BSS) y cantidad de aciertos (HSS). A partir de esta sección, se evaluará la eficiencia del pronóstico probabilístico de origen estadístico mediante estas métricas, considerando a los modelos acoplados como la nueva referencia. Así como en el caso anterior, contar con $RPSS > 0$ y $BSS > 0$ representa una mejora relativa en términos de confiabilidad y resolución del esquema predictivo estadístico por sobre el sistema de referencia (pronósticos dinámicos emitidos por centros operativos). Análogamente, obtener $HSS > 0$ implica una mejora en la tasa de aciertos del pronóstico probabilístico estadístico respecto a la referencia.

Para poder aplicar estas métricas de evaluación, se deben transformar las previsiones determinísticas dadas por los modelos acoplados en previsiones probabilísticas. Para un

mes particular, esto implica cuantificar la probabilidad de ocurrencia de cada tipo de evento (subnormal, normal, y sobrenormal) como la fracción de miembros del ensamble de cada sistema de pronóstico cuya estimación numérica corresponde a cada categoría. Sin embargo, se debe considerar que los modelos dinámicos pueden presentar sesgos sistemáticos que alejan a la climatología pronosticada de la realidad (Risbey et al., 2022). Este sesgo también puede verse reflejado en la función de distribución de la precipitación mensual. Para visualizar este punto, en la Figura 5-14 se muestran las funciones de densidad de la precipitación mensual areal del cluster 1, construidas a partir de los pronósticos emitidos por cada centro operativo, y considerando también los valores observados. Una función de densidad representa esquemáticamente a un histograma suavizado, de forma de evaluar la distribución de frecuencias observadas y pronosticadas de la variable. Se destaca en la Figura 5-14 que, a lo largo de todo el semestre estival, las funciones de densidad se encuentran desplazadas hacia la derecha de la función de densidad observada, es decir que los modelos tienden a estimar valores más altos de la precipitación que los efectivamente observados. Este sesgo es particularmente marcado para MF, cuya moda es aproximadamente el doble de la moda observada. Los modelos vinculados a ECMWF, DWD, y ECCC muestran un sesgo relativamente menor a MF. En particular, durante el verano, ECCC presenta una función de densidad localizada aproximadamente en el mismo rango de los valores observados. Asimismo, la forma de las funciones de densidad sugiere que la variabilidad de las estimaciones de los modelos tiende a ser menor a la variabilidad observada, en la mayor parte de los meses. Por otro lado, en la Figura 5-15 se muestran las funciones de densidad para la precipitación mensual del cluster 2. En este caso, existe una mayor coincidencia entre sistemas de pronóstico y, si bien la variabilidad pronosticada tiende a ser menor a la observada, los sesgos parecen ser menos marcados que en el cluster 1 a lo largo del semestre. Este contraste entre la distribución de valores estimados y observados se traduce en que los eventos sobrenormales podrían ser sobrepronosticados (especialmente en el cluster 1) si se consideraran los terciles observados como umbrales de clasificación de categoría, y lo opuesto para los eventos subnormales. Por esta razón, se calcularon los terciles de cada modelo dinámico para cada mes del semestre estival, en función de los valores que registra. De esta forma, para un sistema de pronóstico específico, la probabilidad de ocurrencia de una determinada categoría fue cuantificada como la fracción de miembros del ensamble cuya estimación cruda queda incluida en el rango de valores de esa categoría, limitado por los terciles propios de dicho sistema. El pronóstico probabilístico

obtenido en consecuencia fue utilizado como referencia para el cálculo de las métricas HSS, RPSS, y BSS (notadas como HSS_{mod} , $RPSS_{mod}$, y BSS_{mod} por emplear a las estimaciones derivadas de los modelos acoplados como referencia).




Figura 5-14. Funciones de densidad normalizadas para la precipitación areal observada (Obs), y la precipitación areal estimada por cada sistema de pronóstico (ECMWF, DWD, MF, ECCC) para cada mes del semestre estival en el cluster 1.




Figura 5-15. Análogo a la Figura 5-14 para el cluster 2.

5.4.2. Resultados de la comparación de desempeño

La Figura 5-16 muestra la magnitud del HSS_{mod} para cada uno de los sistemas de pronóstico seleccionados, en función del mes y del cluster. A diferencia de lo que se encontró para el HSS_{clima} (Figura 5-6), los valores de HSS_{mod} alcanzan valores negativos en ciertos casos, es decir que existen ocasiones donde los pronósticos estadísticos presentan mayor tasa de fallos de categoría que los pronósticos dinámicos. En líneas generales, para el cluster 1 el HSS_{mod} varía en forma similar al HSS_{clima} a lo largo del semestre estival, y no presenta grandes diferencias entre los distintos sistemas de pronóstico dinámicos, con valores positivos y máximos en noviembre, febrero, y octubre (a excepción del HSS_{mod} vinculado a MF, que presenta valores negativos en octubre). Por lo tanto, en dichos meses los modelos estadísticos del cluster 1 mejoran la frecuencia de aciertos de categoría respecto a los modelos dinámicos acoplados. Los meses de transición entre la primavera y verano (diciembre y enero) muestran una tasa de aciertos similar a la de los modelos dinámicos, mientras que hacia el final del verano (marzo) los aciertos de los modelos estadísticos tienden a superar a los aciertos de los modelos dinámicos, a excepción del ECMWF. A comparación del cluster 1, el cluster 2 presenta tasas de fallo más intensas en algunos meses y para algunos sistemas de pronóstico. Los pronósticos estadísticos de los meses de octubre y noviembre mejoran la tasa de aciertos de todos los modelos acoplados ($HSS_{mod} > 0$). En los meses de diciembre y enero, los modelos estadísticos exhiben tasas de fallos de categoría más altas que los sistemas dinámicos, especialmente en relación a ECMWF y MF; el mes de marzo también muestra valores negativos de HSS_{mod} en todos los casos. Dentro del trimestre de verano, el mes de febrero es el que mejor tasa de aciertos presenta en comparación a los sistemas de pronóstico dinámicos, a excepción del MF. En particular, para el cluster 2 las estimaciones dadas por MF son sistemáticamente más acertadas que las estimaciones brindadas por los pronósticos estadísticos a partir del mes de diciembre ($HSS_{mod} < 0$), mientras que en los dos primeros meses de la primavera sucede lo opuesto ($HSS_{mod} > 0$).




Figura 5-16. Valores del HSS_{mod} a lo largo del semestre estival para el cluster 1 (violeta) y cluster 2 (verde). Los valores exactos de la métrica se indican en blanco. La referencia utilizada para calcular HSS_{mod} corresponde a la probabilidad de acierto de cada modelo, indicado en la esquina superior izquierda de cada panel. Para los modelos indicados con asterisco, el cálculo del HSS_{mod} se realizó sobre el período 1993/1994-2017/2018. De lo contrario, el cálculo del HSS_{mod} se realizó sobre el período 1984/1985-2019/2020.

La Figura 5-17 muestra los valores del $RPSS_{mod}$ para cada sistema de pronóstico seleccionado. El cluster 1 muestra valores más favorables del $RPSS_{mod}$ en la primavera (particularmente octubre y noviembre) en comparación al verano en todos los casos, lo que implica que los modelos estadísticos mejoran la confiabilidad y resolución respecto a los modelos dinámicos para estos meses. Durante el verano, el mes de febrero es el que consistentemente muestra un mejor desempeño en términos del $RPSS_{mod}$, seguido del mes de marzo, que presenta valores positivos del $RPSS_{mod}$ para todos los sistemas dinámicos, a excepción del ECMWF. En particular, los modelos estadísticos del cluster 1 representan una mejora en términos de la confiabilidad y resolución al tomar como referencia a los sistemas DWD y ECCC, pues para estos sistemas se tiene que $RPSS_{mod} > 0$ en todos los meses del semestre estival (salvo enero). Por otro lado, el $RPSS_{mod}$ vinculado a los pronósticos en el cluster 2 tiende a mostrar valores más desfavorables en todos los

sistemas dinámicos en comparación a los mismos meses del cluster 1 ($RPSS_{mod,cluster2} < RPSS_{mod,cluster1}$), exceptuando solamente el caso del mes de octubre al tomar como referencia al ECCC. Los valores de la métrica son positivos en los meses de octubre, noviembre, y febrero al considerar los sistemas DWD, MF, y ECCC, mientras que las mejoras relativas de confiabilidad y resolución respecto a ECMWF sólo se observan en octubre para este cluster. Considerando la magnitud que toma el $RPSS_{mod}$, los modelos estadísticos mejoran particularmente las previsiones dadas por el sistema ECCC en el cluster 2.

Como se mencionó anteriormente, el RPSS es una métrica que sintetiza el desempeño de los pronósticos probabilísticos de triple categoría. Por esta razón, en la Figura 5-18 se muestra el BSS_{mod} , que cuantifica la capacidad de confiabilidad y resolución al igual que el $RPSS_{mod}$, pero discrimina por tipo de evento. Así como se obtuvo al analizar el BSS_{clima} (tomando a la climatología como referencia), los pronósticos estadísticos tienen dificultades para prever los eventos normales con confiabilidad y resolución en comparación a los modelos dinámicos. Por otro lado, para un mismo cluster y mes, los pronósticos de origen estadístico presentan un mejor desempeño para las categorías extremas, es decir, exhiben valores más altos de BSS_{mod} . En el cluster 1, los modelos estadísticos presentan mejoras en cuanto a confiabilidad y resolución para el pronóstico de eventos subnormales en la primavera, comparando contra todos los sistemas de pronóstico dinámico. Por su parte, los eventos sobrenormales tienden a asociarse a $BSS_{mod} > 0$ en octubre y noviembre, y presentan una disminución de dicha métrica hacia diciembre. Durante el verano, prevalece una disminución en el valor del BSS_{mod} en comparación a la primavera, particularmente en el mes de enero al tomar como referencia a los sistemas ECMWF y MF. En este trimestre, los eventos sobrenormales presentan valores más favorables o similares de BSS_{mod} que los eventos subnormales del mismo mes. Por el contrario, el cluster 2 muestra un peor desempeño en términos de confiabilidad y resolución en comparación al cluster 1, pues muestra una mayor cantidad de casos con $BSS_{mod} < 0$. En este caso, valores positivos de la métrica se encuentran principalmente en octubre, noviembre, y febrero, al igual que para el $RPSS_{mod}$. En octubre y febrero, el BSS_{mod} de los eventos subnormales es positivo y superior al BSS_{mod} de eventos sobrenormales tomando a cualquier sistema dinámico como referencia. Esto implica que los esquemas estadísticos detectan más eficientemente a los eventos subnormales que los sistemas dinámicos, mientras que las mejoras relativas en eventos

sobrenormales son menores. Por otro lado, en el mes de noviembre los eventos subnormales son pobremente detectados por los modelos estadísticos en comparación a los dinámicos ($BSS_{mod} < 0$); de hecho, los eventos sobrenormales e incluso los eventos normales muestran valores más altos de BSS_{mod} . Los modelos estadísticos presentan mayor cantidad de casos de $BSS_{mod} > 0$ al tomar como referencia a DWD y ECCC, pero aun así predominan los casos desfavorables de esta métrica en el cluster 2.



Figura 5-17. Valores de $RPSS_{mod}$ tomando como referencia a los modelos globales en cada mes del semestre estival para ambos clusters. Valores positivos en verde (negativos en amarillo) indican una mejora respecto a los modelos. Para los modelos indicados con asterisco, el cálculo del $RPSS_{mod}$ se realizó sobre el periodo 1993/1994-2017/2018. De lo contrario, el cálculo del $RPSS_{mod}$ se realizó sobre el periodo 1984/1985-2019/2020.




Figura 5-18. Valores de BSS_{mod} tomando como referencia a los modelos globales para las categorías subnormal (Sub), normal (Nor), y sobrenormal (Sobre) en cada mes del semestre estival para ambos clusters. Valores positivos en verde (negativos en amarillo) indican una mejora respecto a los modelos. Para los modelos indicados con asterisco, el cálculo del BSS_{mod} se realizó sobre el período 1993/1994-2017/2018. De lo contrario, el cálculo del BSS_{mod} se realizó sobre el período 1984/1985-2019/2020.

A modo de síntesis de los resultados obtenidos, se resume en la Tabla 5-4 cómo fue el desempeño del pronóstico probabilístico según HSS_{mod} y BSS_{mod} , empleando a los sistemas dinámicos como referencia. En dicha Tabla se destacan:

- En sombreado verde, los casos donde HSS_{mod} toma valores positivos, como una medida de la tasa de aciertos general de los pronósticos estadísticos relativa al pronóstico emitido por los modelos acoplados. También se señala el mes más eficiente según esta métrica.
- En sombreado celeste, los casos donde el BSS_{mod} muestra valores mayores o iguales a cero, como una medida de resolución y confiabilidad relativa al pronóstico emitido por los modelos acoplados.

CLUSTER 1																
	ECMWF				DWD*				MF*				ECCC*			
	HSS	BSS			HSS	BSS			HSS	BSS			HSS	BSS		
		Sub	Nor	Sobre		Sub	Nor	Sobre		Sub	Nor	Sobre		Sub	Nor	Sobre
Oct																
Nov	*				*				*				*			
Dic																
Ene																
Feb																
Mar																

CLUSTER 2																
	ECMWF				DWD*				MF*				ECCC*			
	HSS	BSS			HSS	BSS			HSS	BSS			HSS	BSS		
		Sub	Nor	Sobre		Sub	Nor	Sobre		Sub	Nor	Sobre		Sub	Nor	Sobre
Oct	*								*							
Nov					*								*			
Dic																
Ene																
Feb																
Mar																

Tabla 5-4. Síntesis del desempeño del pronóstico probabilístico de triple categoría (subnormal “Sub”, normal “Nor”, y sobrenormal “Sobre”) en comparación a los sistemas de pronóstico de origen dinámico, para cada mes y cada cluster. El sufijo “mod” para las métricas HSS_{mod} y BSS_{mod} fue removido por conveniencia en la Tabla. En azul se somborean los casos donde BSS_{mod} es positivo para cada tipo de evento. En sombreado verde se indican los casos con $HSS_{mod} > 0$, con el asterisco señalando el mes de mayor HSS_{mod} . Las celdas en blanco indican que el HSS_{mod} o el BSS_{mod} son menores a cero. Para los sistemas de pronóstico dinámicos acompañados de un asterisco, la verificación se realizó sobre el período 1993/1994-2017/2018. De lo contrario, la verificación se realizó sobre el período 1984/1985-2019/2020.

En la Tabla 5-4 no se incluye una comparación de la magnitud relativa de las métricas, sino que simplemente se destacan aquellas cantidades que cumplen los criterios que se indican arriba. En la Tabla 5-4 se muestra que los modelos estadísticos presentan dificultades para mejorar la confiabilidad y resolución en el pronóstico de los eventos normales, comparado contra los modelos de origen dinámico. El cluster 1 presenta un mejor rendimiento que el cluster 2 en líneas generales, pues existen más casos con $HSS_{mod} > 0$ y $BSS_{mod} > 0$ (especialmente en las categorías subnormal y sobrenormal). Asimismo,

los modelos estadísticos del cluster 1 mejoran principalmente las estimaciones dadas por el sistema ECCC. El valor máximo de HSS_{mod} se observa entre octubre y noviembre para ambos clusters y relativo a todos los sistemas dinámicos, acompañado en gran parte de los casos con mejoras en términos de la confiabilidad y resolución para eventos no normales. Esto indicaría que los modelos estadísticos aportan cierto valor agregado principalmente en la previsión de comienzos y mediados de la primavera en la CRB.

5.5. Síntesis

En este Capítulo, se realizó la verificación de los pronósticos probabilísticos categóricos contruidos a partir de los modelos estadísticos diseñados en el Capítulo 4. Este tipo de pronóstico permite, a diferencia del enfoque determinístico, cuantificar la incerteza ligada a las estimaciones. En particular, se empleó un sistema de triple categoría, en el cual para cada mes objetivo y para cada cluster se obtuvo la probabilidad pronosticada de ocurrencia de precipitación areal subnormal, normal, y sobrenormal.

Se emplearon distintas herramientas de verificación orientadas a caracterizar una variedad de atributos deseables en el pronóstico probabilístico. En el análisis, surgió que el desempeño en la previsión estadística de los eventos no normales es superior al de los eventos normales. Asimismo, los modelos estadísticos presentan mayor eficiencia en el cluster 1, particularmente en los dos primeros meses de la primavera cuando se observan mejoras en la tasa de aciertos, confiabilidad, y resolución respecto a las chances climatológicas de ocurrencia. La previsión de los eventos subnormales en el cluster 1 presenta mejores indicadores de éxito que los eventos sobrenormales durante la primavera, mientras que lo opuesto ocurre en el verano. Aun así, se observa cierta sobreconfianza en los pronósticos de estas categorías. Esta problemática podría ser resuelta mediante un proceso adicional de calibración de los pronósticos, aunque sería a expensas de la agudeza de los mismos (Owens y Hewson, 2018; OMM, 2020). Por el contrario, los modelos del cluster 2 muestran mayores dificultades que los del cluster 1, especialmente en términos de la resolución y confiabilidad de los pronósticos. En particular, el mejor desempeño en el cluster 2 combinando todas las métricas de

evaluación se tiene en los meses de octubre (primavera) y febrero (mes de verano con la mayor cantidad de predictores disponibles).

Adicionalmente, se contrastó la eficiencia del pronóstico probabilístico estadístico de la precipitación mensual con el desempeño del pronóstico probabilístico emitido a través de modelos dinámicos acoplados disponibles en el C3S. Para ello, se emplearon específicamente dos métricas de evaluación para cuantificar la proporción de aciertos y la capacidad de confiabilidad y resolución de los pronósticos estadísticos, relativizadas en función de los modelos dinámicos. Con estas herramientas, se encontró que los modelos estadísticos presentan un mejor desempeño en relación a pronósticos dinámicos en el cluster 1 que en el cluster 2, particularmente en los meses de primavera para las categorías no normales.

Capítulo 6

Conclusiones

En el marco de los servicios climáticos, el pronóstico a mediano plazo es una herramienta de gran relevancia para la mitigación de impactos negativos y la optimización de los recursos en múltiples sectores productivos (OMM, 2020). En los últimos años, se ha evidenciado un fuerte desarrollo en la diversidad y complejidad de las estrategias de previsión subestacional y estacional. Estos avances fueron propiciados por las mejoras en las redes de observación, en los métodos de asimilación y en el diseño de los modelos, así como en la capacidad de cómputo y almacenamiento que permiten avanzar en la resolución y tamaño de los ensambles. La organización de actividades internacionales coordinadas referidas al pronóstico climático también colaboró para este desarrollo (Merryfield et al., 2020). En este contexto, también surgen esfuerzos por obtener perspectivas a mediano plazo de variables climáticas a escala local, como una manera de ampliar el abanico de posibles evoluciones futuras de distintas variables, considerando que la incertidumbre es inherente al sistema climático.

En esta tesis doctoral, el objetivo fue desarrollar y evaluar el desempeño de un conjunto de modelos de origen estadístico para la predicción de la precipitación acumulada mensual en la Cuenca del Río Bermejo. Se trata de una cuenca binacional, compartida entre Bolivia y Argentina, pero el 90% del área de la misma se emplaza en territorio argentino. En particular, los modelos se orientaron hacia el pronóstico de la precipitación media areal en regiones específicas del sector argentino de la cuenca (CRB). A continuación, se resumen algunas conclusiones derivadas de lo analizado en los capítulos previos.

Esta cuenca se localiza en el norte de Argentina, en una zona con gran variación en pendiente y altitud del terreno, particularmente en su sector occidental. Los datos pluviométricos tomados in situ muestran que la CRB presenta un régimen hidroclimatológico marcado, con valores acumulados de precipitación concentrados principalmente entre los meses de octubre y marzo, y la presencia de una estación seca

en los meses de invierno austral en las subcuencas del sector superior. Además, el caudal en distintos puntos de aforo muestra que el año hidrológico en la CRB inicia entre septiembre y octubre, y alcanza su máximo hacia el final del semestre de análisis. Asimismo, se encontró que existe una relación significativa entre la precipitación mensual en el sector superior de la cuenca, y los caudales medio mensual y máximo diario en el sector inferior de la cuenca, tanto en forma simultánea como desfasada en un mes. Esto destaca que la perspectiva de la precipitación podría ser una herramienta de utilidad para inferir cómo respondería el caudal del sector inferior. Por otro lado, si bien se observaron predominantemente tendencias al decrecimiento en la precipitación anual y en la precipitación acumulada en el semestre estival, sólo resultaron estadísticamente significativas en sitios puntuales.

A partir de la metodología de *k*-medoides, se identificaron dos conjuntos de estaciones con símil variabilidad interanual de la precipitación estival en el sector donde se emplaza la CRB: el cluster 1, en el sector centro-oeste de la región de estudio, y el cluster 2, en el extremo este. A partir de esta regionalización, para cada cluster y cada mes del semestre estival, se definieron las series temporales de precipitación acumulada areal. Luego, se exploraron potenciales fuentes de predictibilidad, tanto regionales como remotas, definidas a partir de diversos indicadores. Parte de estos indicadores fueron preestablecidos en función de la bibliografía existente sobre fuentes de variabilidad de la precipitación en Sudamérica, mientras que los indicadores restantes fueron obtenidos a partir de un análisis de correlación lineal desfasada entre variables climáticas y las series de precipitación mensual, considerando la causalidad física de los mismos. Todos los indicadores utilizados fueron definidos en el mes previo al mes objetivo de pronóstico.

En particular, a partir de los indicadores hallados se identificaron cuatro grupos de predictores. En primer lugar, se agruparon los predictores directamente vinculados a los modos de variabilidad de SST en los océanos Pacífico (ENSO) e Índico (DOI/IOBW). La presencia del ENSO en fase cálida se vincula a condiciones más húmedas en la primavera para toda la región, pero particularmente en el cluster 2. Por el contrario, en el cluster 1 la situación se revierte en el verano, cuando condiciones más húmedas se observan luego de un enfriamiento anómalo del Pacífico tropical central. En segundo lugar, se identificaron predictores que señalan la presencia de un tren de ondas de latitudes medias, y que podrían vincularse al patrón dipolar de precipitación observado en estudios de escala intraestacional entre el norte argentino y la región de desarrollo de la SACZ en

verano. En tercer lugar, se identificaron predictores asociados a la variabilidad en la circulación dada por el AA. Finalmente, se identificaron predictores que sugieren que los cambios en la fecha de activación del SAMS podrían propiciar cambios en los valores esperados de la precipitación, especialmente en la primavera. El análisis exploratorio de predictores de la precipitación puso en evidencia que existe cierta variabilidad en la influencia de los predictores a lo largo del semestre estival, y resalta la necesidad de acudir a indicadores definidos en forma individual para cada cluster (*particulares*), con el propósito de complementar la información que aportan los indicadores preestablecidos (*generales*). Sin la inclusión de los indicadores particulares, no se habría contado con una cantidad suficiente de predictores para la construcción de los modelos de predicción, particularmente hacia el verano.

A partir de los predictores encontrados, se construyeron los modelos de predicción de la precipitación mensual para cada cluster y para cada mes del semestre de estudio en base a cuatro técnicas de aprendizaje estadístico: RLM, GAM, SVR, y ANN. En este proceso, considerando la limitación en la cantidad de observaciones para entrenamiento y testeo, se optó por emplear la estrategia de LOOCV. En particular, el cluster 1 muestra consistentemente mayor eficiencia que el cluster 2 desde la visión determinística del pronóstico, particularmente en los meses de primavera. Asimismo, de todas las técnicas consideradas, ANN fue la que mejor resultados brindó en términos de precisión, variabilidad, y correspondencia temporal con los valores observados. Aun así, todos los modelos tienen dificultad para reproducir la dispersión de la precipitación observada en ambos clusters.

Si bien la representación numérica precisa de la precipitación acumulada mensual es un claro desafío para los modelos obtenidos, la perspectiva a mediano plazo puede estructurarse como un pronóstico categórico probabilístico. Esto aborda dos problemáticas simultáneamente. Por un lado, prever la ocurrencia de que la precipitación supere o no un umbral es una herramienta útil para la gestión de recursos independientemente de que se disponga de un valor numérico preciso de la precipitación acumulada. Por otro lado, el carácter probabilístico permite reconocer la presencia de la incertidumbre inherente a la predicción, y brinda información adicional para los tomadores de decisión. Por esta razón, se trabajó con un sistema de pronóstico de triple categoría, donde las mismas fueron definidas a partir de los terciles climatológicos correspondientes a cada mes y cada cluster. Para la confección del pronóstico

probabilístico, se consideró una estrategia de ensamble de los modelos previamente construidos que superaran cierto umbral de eficiencia dado por el coeficiente de determinación ajustado sobre los datos de entrenamiento.

El análisis de eficiencia categórico se basó en una serie de atributos característicos de los pronósticos probabilísticos. Consistentemente con lo encontrado en el análisis determinístico, el cluster 1 mostró mejor desempeño que el cluster 2, especialmente en términos de confiabilidad, resolución, y discriminación de los distintos tipos de eventos. En particular, la habilidad de pronóstico en el cluster 1 se concentra en la detección de eventos subnormales (principalmente en primavera) y sobrenormales (principalmente en verano).

Finalmente, el desempeño del pronóstico probabilístico derivado de los modelos estadísticos fue contrastado contra los sistemas de pronóstico dinámicos disponibles en el C3S para la región de estudio. El cluster 1 mostró una mejora comparativa de eficiencia en términos de cantidad de aciertos de categoría y de confiabilidad-resolución, principalmente para eventos no normales durante la primavera. Por el contrario, el cluster 2 tiene mayores dificultades para mejorar los atributos dados por los sistemas de pronóstico dinámicos en gran parte del semestre estival.

En síntesis, la metodología empleada en esta tesis mostró que los modelos empíricos tienden a mostrar un mejor rendimiento general para la primavera, especialmente en la región ubicada en el centro-oeste de la cuenca. Durante el verano, cuando es esperable que disminuya la señal de fuentes remotas (Cai et al., 2020), el desempeño de los modelos muestra más fallas. Sin embargo, dentro del verano, el mes de febrero es el que presenta una buena eficiencia relativa a lo largo de todo el análisis. Dicho mes es el que mayor cantidad de predictores presenta en todo el semestre en ambos clusters, lo que podría sugerir que contar con una mayor cantidad de indicadores ayuda a compensar parcialmente la caída en la eficiencia en el verano.

Las técnicas de modelado empírico presentan ciertas limitaciones, que fueron mencionadas a lo largo de esta tesis. En principio, la calidad de los datos es fundamental para poder representar lo más fehacientemente posible a los procesos climáticos subyacentes. En este sentido, la conjunción de distintas fuentes de datos pluviométricos en el sector de análisis fue esencial para poder complementar las observaciones dadas por la red oficial del SMN.

En segundo lugar, la elección de los predictores es clave para la obtención de buenas predicciones. En este trabajo se lograron hallar indicadores climáticos para cada mes y cada cluster del semestre estival. Si bien existe una parte de la incertidumbre de la predicción que es irreducible, queda pendiente explorar qué otros indicadores podrían aportar una señal que no fue detectada mediante la metodología lineal empleada para la búsqueda de predictores. Este punto podría volverse particularmente relevante para la predicción de la precipitación en los meses de verano, cuando los procesos locales se vuelven preponderantes (Grimm y Zilli, 2009), y los modelos presentan mayor tasa de fallos.

Finalmente, otro aspecto a ser considerado en los estudios de predictibilidad estadística es el de los algoritmos de aprendizaje seleccionados. En este estudio se consideraron cuatro grandes familias de técnicas, de las cuales las redes neuronales artificiales multicapa mostraron un mejor desempeño desde múltiples aspectos. Esto abre la posibilidad de profundizar aún más la aplicación de las redes neuronales artificiales en el campo de la perspectiva a mediano plazo. En particular, sería interesante poder evaluar variantes más complejas de esta técnica para el pronóstico de la precipitación mensual y estacional. Una posible ruta de exploración implica trabajar con una mayor diversidad de arquitecturas de las redes neuronales multicapa, pero también sería valioso poder aplicar técnicas tales como las redes neuronales recurrentes, que procesarían información temporal e incorporarían el concepto de memoria en el algoritmo, o las redes neuronales convolucionales, que optimizarían la información espacial de las variables climáticas.

Esta tesis doctoral ha brindado un avance para la perspectiva a mediano plazo de la precipitación en la CRB, una región donde dicha variable representa un recurso de relevancia para el aspecto productivo e hidrológico. Los resultados hallados plantean nuevos desafíos en búsqueda de mejorar la eficiencia de los pronósticos, y de implementar operativamente las predicciones probabilísticas para la región.

Referencias

- Abudu, S., King, J. P., y Pagano, T. C. (2010). Application of Partial Least-Squares Regression in Seasonal Streamflow Forecasting. *Journal of Hydrologic Engineering*, 15(8), 612–623. doi:10.1061/(asce)he.1943-5584.0000216
- Akaike, H. (1974). A New Look at the Statistical Model Identification, *IEEE T. Automat. Contr.*, 19, 716–723.
- Alexandersson, H. (1986). A homogeneity test applied to precipitation data. *J. Climatol.*, 6: 661-675. <https://doi.org/10.1002/joc.3370060607>.
- Almeira, G. J., y Scian, B. (2006). Some atmospheric and oceanic indices as predictors of seasonal rainfall in the Del Plata Basin of Argentina. *Journal of Hydrology*, 329(1-2), 350-359.
- Álvarez, M.S., Vera, C.S., Kiladis, G.N, y Liebmann, B. (2016). Influence of the Madden Julian Oscillation on precipitation and surface air temperature in South America. *Clim Dyn* 46, 245–262. <https://doi.org/10.1007/s00382-015-2581-6>
- Alves, L. M., y Marengo, J. (2010). Assessment of regional seasonal predictability using the PRECIS regional climate modeling system over South America. *Theoretical and Applied Climatology*, 100(3-4), 337– 350. <https://doi.org/10.1007/s00704-009-0165-2>
- Amsler, M. L., y Drago, E. C. (2009). A review of the suspended sediment budget at the confluence of the Paraná and Paraguay Rivers. *Hydrological Processes*, 23(22), 3230–3235. <https://doi.org/10.1002/hyp.739>
- Anderson, R. L. (1942). Distribution of the serial correlation coefficients. *Annals of Mathematical Statistics*, 13(1), 1–13.
- Anderson T. W., y Darling D. A. (1954). A test of goodness of fit. *J. Am. Stat. Assoc.* 49: 765–769.
- Andrade K.M., Cavalcanti I.F.A. (2018). Atmospheric characteristics that induce extreme precipitation in frontal systems over Southeastern Brazil during summer: Observations and atmospheric model simulation. *Int J Climatol*, 38: 5368–5385. <https://doi.org/10.1002/joc.5744>
- Andreoli, R. V., y Kayano, M. T. (2005). ENSO-related rainfall anomalies in South America and associated circulation features during warm and cold Pacific decadal oscillation regimes. *International Journal of Climatology*, 25(15), 2017–2030. doi:10.1002/joc.1222

- Andrian, L.G., Osman, M. y Vera, C.S. (2023). Climate predictability on seasonal timescales over South America from the NMME models. *Clim Dyn* 60, 3261–3276. <https://doi.org/10.1007/s00382-022-06506-8>
- Anochi, J. A., de Almeida, V. A., y de Campos Velho, H. F. (2021). Machine Learning for Climate Precipitation Prediction Modeling over South America. *Remote Sensing*, 13(13), 2468. <https://doi.org/10.3390/rs13132468>
- Arias, P.A., Bellouin, N., Coppola, E., Jones, R.G., Krinner, G., Marotzke, J., Naik, V., Palmer, M.D., Plattner, G.-K., Rogelj, J., Rojas, M., Sillmann, J., Storelvmo, T., Thorne, P.W., Trewin, B., Achuta Rao, K., Adhikary, B., Allan, R.P., Armour, K., Bala, G., Barimalala, R., Berger, S., Canadell, J.G., Cassou, C., Cherchi, A., Collins, W., Collins, W.D., Connors, S.L., Corti, S., Cruz, F., Dentener, F.J., Dereczynski, C., Di Luca, A., Diongue Niang, A., Doblas-Reyes, F.J., Dosio, A., Douville, H., Engelbrecht, F., Eyring V., Fischer, E., Forster, P., Fox-Kemper, B., Fuglestad, J.S., Fyfe, J.C., Gillett, N.P., Goldfarb, L., Gorodetskaya, I., Gutierrez, J.M., Hamdi, R., Hawkins, E., Hewitt, H.T., Hope, P., Islam, A.S., Jones, C., Kaufman, D.S., Kopp, R.E., Kosaka, Y., Kossin, J., Krakovska, S., Lee, J.-Y., Li, J., Mauritsen, T., Maycock, T.K., Meinshausen, M., Min S.-K., Monteiro, P.M.S., Ngo-Duc, T., Otto, F., Pinto, I., Pirani, A., Raghavan, K., Ranasinghe, R., Ruane, A.C., Ruiz, L., Sallée, J.-B., Samset, B.H., Sathyendranath, S., Seneviratne, S.I., Sörensson, A.A., Szopa, S., Takayabu, I., Tréguier, A.-M., van den Hurk, B., Vautard, R., von Schuckmann, K., Zaehle, S., Zhang, X., y Zickfeld, K. (2021). Technical Summary. En Masson-Delmotte, V., Zhai, P., Pirani, A., Connors, S.L., Péan, C., Berger, S., Caud, N., Chen, Y., Goldfarb, L., Gomis, M.I., Huang, M., Leitzell, K., Lonnoy, E., Matthews, J.B.R., Maycock, T.K., Waterfield, T., Yelekçi, O., Yu, R., y Zhou, B. (eds.), *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press, Cambridge, Reino Unido y New York, NY, Estados Unidos, pp. 33–144. <https://doi.org/10.1017/9781009157896.002>.
- Arrieta, J., y Pastor, C. (1998). *Relevamiento Socioeconómico y Ambiental de las Comunidades del Tramo Medio e Inferior de la Cuenca del Río Bermejo. Informe y Anexos. Elemento: 2.5: Uso del Suelo en la Cuenca del Río Inferior*. Buenos Aires. Documento extraído de la página de la Comisión Regional del Río Bermejo (COREBE): <http://corebe.org.ar/web2015/documentacion/> en enero 2020.
- Ancapichún, Santiago, y Garcés-Vargas, José. (2015). Variabilidad del Anticiclón Subtropical del Pacífico Sudeste y su impacto sobre la temperatura superficial del mar frente a la costa centro-norte de Chile. *Ciencias marinas*, 41(1), 1-20. Epub 00 de marzo de 2015. <https://doi.org/10.7773/cm.v41i1.2338>

- Asadieh, B. y Krakauer, N. Y. (2015). Global trends in extreme precipitation: climate models versus observations, *Hydrol. Earth Syst. Sci.*, 19, 877–891, <https://doi.org/10.5194/hess-19-877-2015>.
- Ay, M., y Kisi, O. (2015). Investigation of trend analysis of monthly total precipitation by an innovative method. *Theoretical and Applied Climatology*, 120, 617–629. <https://doi.org/10.1007/s00704-014-1198-8>
- Ayala, S.N. (2019). La posibilidad del pronóstico estadístico de precipitación de primavera en la cuenca del río Bermejo. *Tesis de grado*. Departamento de Ciencias de la Atmósfera y los Océanos, Facultad de Ciencias Exactas y Naturales, Universidad de Buenos Aires.
- Ayala, S.N., González, M.H. y Rolla, A. L. (2021). A statistical forecast scheme of precipitation in the Upper Bermejo River Basin in Argentina. *International Journal of River Basin Management*, DOI: 10.1080/15715124.2021.1932952
- Balmaceda-Huarte, R., Baño-Medina, J., Olmo, M.E., Bettolli M.L. (2024). On the use of convolutional neural networks for downscaling daily temperatures over southern South America in a climate change scenario. *Clim Dyn* 62, 383–397. <https://doi.org/10.1007/s00382-023-06912-6>
- Balmaceda-Huarte, R., Olmo, M. E., Bettolli, M. L., Poggi, M. M. (2021). Evaluation of multiple reanalyses in reproducing the spatio-temporal variability of temperature and precipitation indices over southern South America. *Int J Climatol.*, 41: 5572–5595. <https://doi.org/10.1002/joc.7142>
- Barreiro, M. Influence of ENSO and the South Atlantic Ocean on climate predictability over Southeastern South America. *Clim Dyn* 35, 1493–1508 (2010). <https://doi.org/10.1007/s00382-009-0666-9>
- Barros, V., y Camilloni, I. (2016). La Argentina y el cambio climático: de la física a la política. Eudeba, Ciudad Autónoma de Buenos Aires, Argentina, 286. ISBN 978-950-23-2655-9.
- Barros, V., Castaneda, M. E., y Doyle, M. (2000). Recent precipitation trends in Southern South America to the east of the Andes: An indication of a mode of climatic variability. En Smolka, P., y Volkheimer, W. (eds.), *Southern Hemisphere Paleo and Neoclimates Key*. Springer, Berlin. <https://doi.org/10.1007/978-3-642-59694-013>
- Batté, L., Dorel, L., Ardilouze, C., y Guérémy, J. F. (2021). Documentation of the METEO-FRANCE seasonal forecasting system 8. *Meteo-France* <http://www.umr-cnrm.fr/IMG/pdf/system8-technical.pdf>

- Beck, H., Zimmermann, N., McVicar, T., Vergopolan N., Berg, A., Wood, E. (2018). Present and future Köppen-Geiger climate classification maps at 1-km resolution. *Sci Data* **5**, 180214. <https://doi.org/10.1038/sdata.2018.214>
- Begueria S., Vicente-Serrano S.M., Reig F., Latorre B. (2013). Standardized precipitation evapotranspiration index (SPEI) revisited: parameter fitting, evapotranspiration models, tools, datasets and drought monitoring. *Int. J. Climatol.* 34: 3001–3023.
- Belkin, M., Hsu, D., Ma, S., y Mandal, S. (2019). Reconciling modern machine-learning practice and the classical bias–variance trade-off. *Proceedings of the National Academy of Sciences*, 201903070. doi:10.1073/pnas.1903070116
- Birkel, S. D., Mayewski, P. A., Perry, L. B., Seimon, A., Andrade-Flores, M. (2022). Evaluation of reanalysis temperature and precipitation for the Andean Altiplano and adjacent Cordilleras. *Earth and Space Science*, 9, e2021EA001934. <https://doi.org/10.1029/2021EA001934>.
- Bojinski, S., Verstraete, M., Peterson, T. C., Richter, C., Simmons, A., y Zemp, M. (2014). The Concept of Essential Climate Variables in Support of Climate Research, Applications, and Policy. *Bulletin of the American Meteorological Society*, 95(9), 1431-1443. <https://doi.org/10.1175/BAMS-D-13-00047.1>
- Brands, S., Manzanar, R., Gutiérrez, J. M., y Cohen, J. (2012). Seasonal predictability of wintertime precipitation in Europe using the snow advance index. *Journal of Climate*, 25(12), 4023-4028.
- Brownlee, J. (2018). What is the Difference Between a Batch and an Epoch in a Neural Network. *Machine learning mastery*, 20, 1-5.
- Budgaga, W., M. Malensek, S. Pallickara, N. Harvey, S. Pallickara, y S. Pallickara. (2016). Predictive analytics using statistical, learning, and ensemble methods to support real-time exploration of discrete event simulations. *Future Generation Computer Systems* 56:360–74. doi: <https://doi.org/10.1016/j.future.2015.06.013>
- Buishand, T.A. (1982). Some methods for testing the homogeneity of rainfall records. *J. Hydrol.* 58, 11–27.
- Buontempo, C., Burgess, S. N., Dee, D., Pinty, B., Thépaut, J., Rixen, M., Almond, S., Armstrong, D., Brookshaw, A., Alos, A. L., Bell, B., Bergeron, C., Cagnazzo, C., Comyn-Platt, E., Damasio-Da-Costa, E., Guillory, A., Hersbach, H., Horányi, A., Nicolas, J., Obregon, A., Ramos, E. P., Raoult, B., Muñoz-Sabater, J., Simmons, A., Soci, C., Suttie, M., Vamborg, F., Varndell, J., Vermoote, S., Yang, X., y Garcés de Marcilla, J. (2022). The Copernicus Climate

- Change Service: Climate Science in Action. *Bulletin of the American Meteorological Society*, 103(12), E2669-E2687. <https://doi.org/10.1175/BAMS-D-21-0315.1>
- Cai, W., McPhaden, M.J., Grimm, A.M., Rodrigues R.R., Taschetto, A. S., Garreaud, R. D., Dewitte, B., Poveda, G., Ham Y., Santoso, A., Ng, B., Anderson, W., Wang, G., Geng, T., Jo, H., Marengo, J.A., Alves, L.M., Osman, M., Li, S., Wu, L., Karamperidou, C., Takahashi, K., y Vera, C. (2020). Climate impacts of the El Niño–Southern Oscillation on South America. *Nat Rev Earth Environ*, 1, 215–231. <https://doi.org/10.1038/s43017-020-0040-3>
- Camilloni, I., y Barros, V. (2000). The Parana river response to El Nino 1982–83 and 1997–98 events. *Journal of Hydrometeorology*, 1(5), 412–430.
- Camiolo, M. D., Cozzolino, E., y Jaureguizar, A. J. (2018). Material particulado en suspensión en el Río de la Plata: Importancia del río Bermejo en su variabilidad espacio-temporal. *Revista de Teledetección*, 51(51), 1–18. <https://doi.org/10.4995/raet.2018.9864>
- Capotondi, A., y Sardeshmukh, P.D. (2015). Optimal precursors of different types of ENSO events. *Geophys. Res. Lett.*, 42, 9952–9960, doi:10.1002/2015GL066171.
- Capotondi, A., Wittenberg, A. T., Newman, M., Di Lorenzo, E., Yu, J., Braconnot, P., Cole, J., Dewitte, B., Giese, B., Guilyardi, E., Jin, F., Karnauskas, K., Kirtman, B., Lee, T., Schneider, N., Xue, Y., y Yeh, S. (2015). Understanding ENSO Diversity. *Bulletin of the American Meteorological Society*, 96(6), 921–938. <https://doi.org/10.1175/BAMS-D-13-00117.1>
- Carabajal, M. I. (2020). Coproducción de conocimiento: el caso de la reunión de tendencia climática trimestral de Argentina. *Revista Iberoamericana De Ciencia, Tecnología Y Sociedad* - CTS, 15(44). Extraído de <https://ojs.revistacts.net/index.php/CTS/article/view/164>
- Carvalho L.M.V., Cavalcanti I.F.A. (2016). The South American monsoon system. En: Carvalho L.M.V., Jones C. (eds.), *The monsoons and climate change: observations and modeling*. Springer International Publishing; 2016. p. 121–48.
- Carvalho, L. M. V., Jones, C., y Liebmann, B. (2004). The South Atlantic Convergence Zone: Intensity, Form, Persistence, and Relationships with Intraseasonal to Interannual Activity and Extreme Rainfall. *J. Climate*, 17, 88–108, [https://doi.org/10.1175/1520-0442\(2004\)017<0088:TSACZI>2.0.CO;2](https://doi.org/10.1175/1520-0442(2004)017<0088:TSACZI>2.0.CO;2).
- Carvalho, L. M., Silva, A. E., Jones, C., Liebmann, B., Silva Dias, P. L., y Rocha, H. R. (2011). Moisture transport and intraseasonal variability in the South America monsoon system. *Climate dynamics*, 36, 1865–1880.

- Castino, F., Bookhagen, B., y Strecker, M. R. (2017). Oscillations and trends of river discharge in the southern Central Andes and linkages with climate variability. *Journal of Hydrology*, 555, 108–124. <https://doi.org/10.1016/j.jhydrol.2017.10.001>
- Castino, F., Bookhagen, B. y Strecker, M.R. (2017). Rainfall variability and trends of the past six decades (1950–2014) in the subtropical NW Argentine Andes. *Clim Dyn*, 48, 1049–1067. <https://doi.org/10.1007/s00382-016-3127-2>
- Chambers, D. P., Tapley, B. D., y Stewart, R.H. (1999). Anomalous warming in the Indian Ocean coincident with El Niño. *J. Geophys. Res.*, 104(C2), 3035–3047, doi:10.1029/1998JC900085.
- Chan, S. C., S. K. Behera, y T. Yamagata. (2008). Indian Ocean Dipole influence on South American rainfall. *Geophys. Res. Lett.*, 35, L14S12, doi:10.1029/2008GL034204.
- Chen, J., Wu, X., Finlayson, B., Webber, M., Wei, T., Li, M., and Chen, Z. (2014). Variability and trend in the hydrology of the Yangtze River, China: Annual precipitation and runoff. *Journal of Hydrology*, 513, 403–412. <http://dx.doi.org/10.1016/j.jhydrol.2014.03.044>
- Cionni, I., Lledó, L., Torralba, V., Dell'Aquila, A. (2022). Seasonal predictions of energy-relevant climate variables through Euro-Atlantic Teleconnections. *Climate Services*, 26, 100294. <https://doi.org/10.1016/j.cliser.2022.100294>
- COBINABE (2010). *Generación y transporte de sedimentos en la Cuenca Binacional del Río Bermejo. Caracterización y análisis de los procesos intervinientes. Programa Estratégico de Acción para la Cuenca Binacional del río Bermejo* (ISBN 978-987-25793-7-1), 230 pp.
- Coelho, C.A.S. (2013). Comparative skill assessment of consensus and physically based tercile probability seasonal precipitation forecasts for Brazil. *Meteorol. Appl.* 20 (2), 236–245. <https://doi.org/10.1002/met.1407>
- Coelho, C. A. S., Stephenson, D. B., Balmaseda, M., Doblas-Reyes, F. J., y van Oldenborgh, G. J. (2006). Toward an Integrated Seasonal Forecasting System for South America. *Journal of Climate*, 19(15), 3704–3721. <https://doi.org/10.1175/JCLI3801.1>
- Collazo, S., Barrucand, M. y Rusticucci, M. (2022). Seasonal forecast of the percentage of days with extreme temperatures in central-northern Argentina: An operational statistical approach. *Climate Services*, 26, 100293. <https://doi.org/10.1016/j.cliser.2022.100293>
- Collazo, S., Barrucand, M. y Rusticucci, M. (2019). Summer seasonal predictability of warm days in Argentina: statistical model approach. *Theor Appl Climatol*, 138, 1853–1876. <https://doi.org/10.1007/s00704-019-02933-6>

- Copernicus Climate Change Service, Climate Data Store. (2018). Seasonal forecast monthly statistics on single levels. *Copernicus Climate Change Service (C3S) Climate Data Store (CDS)*. DOI: 10.24381/cds.68dd14c3 (Acceso en septiembre de 2024).
- Cortes, C., Vapnik, V. (1995). Support-vector networks. *Mach Learn*, 20:273–297. <https://doi.org/10.1007/BF00994018>
- Croquette M., Eldin G., Grados C., Tamayo M. (2007). On differences in satellite wind products and their effects in estimating coastal upwelling processes in the south-east Pacific. *Geophys. Res. Lett.* 34(11). <http://dx.doi.org/10.1029/2006GL027538>
- Da Silva, A. E., y de Carvalho, L. M. V. (2007). Large-scale index for South America Monsoon (LISAM). *Atmospheric Science Letters*, 8(2), 51–57. doi:10.1002/asl.150
- Dantas, L. G., Santos, C. A. C. d., Olinda, R. A. d., Brito, J. I. B. d., Santos, C. A. G., Martins, E. S. P. R., de Oliveira, G., y Brunsell, N. A. (2020). Rainfall Prediction in the State of Paraíba, Northeastern Brazil Using Generalized Additive Models. *Water*, 12(9), 2478. <https://doi.org/10.3390/w12092478>
- Dar, Y., Muthukumar, V., y Baraniuk, R. G. (2021). A farewell to the bias-variance tradeoff? an overview of the theory of overparameterized machine learning. *arXiv preprint arXiv:2109.02355*.
- Davey, M. K., Brookshaw, A, y Ineson, S. (2014) The probability of the impact of ENSO on precipitation and near-surface temperature. *Climate Risk Manage.*, 1, 5–24, <https://doi.org/10.1016/j.crm.2013.12.002>
- de Luis, M., Čufar, K., Saz, M. A., Longares, L. A., Ceglar, A., and Kajfež-Bogataj, L. (2014). Trends in seasonal precipitation and temperature in Slovenia during 1951–2007. *Reg Environ Change*, 14, 1801– 1810. <https://doi.org/10.1007/s10113-012-0365-7>
- Dee, D.P., Uppala, S.M., Simmons, A.J., Berrisford, P., Poli, P., Kobayashi, S., Andrae, U., Balmaseda, M.A., Balsamo, G., Bauer, P., Bechtold, P., Beljaars, A.C.M., van de Berg, L., Bidlot, J., Bormann, N., Delsol, C., Dragani, R., Fuentes, M., Geer, A.J., Haimberger, L., Healy, S.B., Hersbach, H., Hólm, E.V., Isaksen, L., Kållberg, P., Köhler, M., Matricardi, M., McNally, A.P., Monge-Sanz, B.M., Morcrette, J.J., Park, B. K., Peubey, C., de Rosnay, P., Tavolato, C., Thépaut, J.N. and Vitart, F. (2011). The ERA-Interim reanalysis: configuration and performance of the data assimilation system. *Q.J.R. Meteorol. Soc.*, 137: 553–597. <https://doi.org/10.1002/qj.828>

- Degola, T. S. D. (2013). Impacts and Variability of the South Atlantic Subtropical Anticyclone on Brazil in the Present Climate and in Future Scenarios. *Dissertation/master's thesis*, University of São Paulo, São Paulo.
- Denby, B., Schaap, M., Segers, A., Builtjes, P., Horalek, J. (2008). Comparison of two data assimilation methods for assessing PM10 exceedances on the European scale. *Atmos. Environ*, 42, 7122–7134.
- di Piazza, A., Conti, F. L., Noto, L. V., Viola, F., La Loggia, G. (2011). Comparative analysis of different techniques for spatial interpolation of rainfall data to create a serially complete monthly time series of precipitation for Sicily, Italy. *Int. J. Appl. Earth Obs.*, 13, pp. 396–408.
- Doblas-Reyes, F., Andreu-Burillo, I., Chikamoto, Y., García-Serrano, J., Guemas, V., Kimoto, M., Mochizuki, T., Rodrigues, L.R.L., van Oldenborgh G.J. (2013a). Initialized near-term regional climate change prediction. *Nat Commun*, 4, 1715. <https://doi.org/10.1038/ncomms2704>
- Doblas-Reyes, F. J., García-Serrano, J., Lienert, F., Biescas, A. P., y Rodrigues, L. R. (2013b). Seasonal climate predictability and forecasting: status and prospects. *Wiley Interdisciplinary Reviews: Climate Change*, 4(4), 245–268.
- Dogliotti, A. I., Ruddick, K., y Guerrero, R. (2016). Seasonal and interannual turbidity variability in the Río de la Plata from 15 years of MODIS: El Niño dilution effect. *Estuarine, Coastal and Shelf Science*, 182, 27–39. <https://doi.org/10.1016/j.ecss.2016.09.013>
- Doyle, M. E., y V. R. Barros. (2002). Midsummer Low-Level Circulation and Precipitation in Subtropical South America and Related Sea Surface Temperature Anomalies in the South Atlantic. *J. Climate*, 15, 3394–3410, [https://doi.org/10.1175/1520-0442\(2002\)015<3394:MLLCAP>2.0.CO;2](https://doi.org/10.1175/1520-0442(2002)015<3394:MLLCAP>2.0.CO;2)
- Doyle, M., Saurral, R., y Barros, V. (2012). Trends in the distributions of aggregated monthly precipitation over the La Plata Basin. *International Journal of Climatology*, 32, 2149–2162.
- Eden, J. M., van Oldenborgh, G. J., Hawkins, E., y Suckling, E. B. (2015). A global empirical system for probabilistic seasonal climate prediction, *Geosci. Model Dev.*, 8, 3947–3973. <https://doi.org/10.5194/gmd-8-3947-2015>
- Efron, B. y Gong, G. (1983). A Leisurely Look at the Bootstrap, the Jackknife, and Cross-Validation. *The American Statistician*, 37, 1, 36–48.
- Elsner, J. B. y Schmertmann, C. P. (1994). Assessing Forecast Skill through Cross Validation. *Wea. Forecasting*, 9, 619–624.

- Espinoza, J.C., Garreaud, R., Poveda, G., Arias, P.A., Molina-Carpio, J., Masiokas, M., Viale, M. y Scaff, L. (2020) Hydroclimate of the Andes part I: Main climatic features. *Frontiers in Earth Science*, 8, 64. <https://doi.org/10.3389/feart.2020.00064>.
- Ferrero, M. E., Villalba, R., Membiela, M. D., Hidalgo, L. F., y Luckman, B. H. (2015). Tree-ring based reconstruction of Río Bermejo streamflow in subtropical South America. *Journal of Hydrology*, 525, 572–584. <https://doi.org/10.1016/j.jhydrol.2015.04.004>
- Fogt, R.L., Bromwich, D.H. y Hines, K.M. (2011). Understanding the SAM influence on the South Pacific ENSO teleconnection. *Clim Dyn*, 36, 1555–1576. <https://doi.org/10.1007/s00382-010-0905-0>
- Folland, C.K., Scaife, A.A., Lindesay, J. y Stephenson, D.B. (2012). How potentially predictable is northern European winter climate a season ahead?. *Int. J. Climatol.*, 32: 801-818. <https://doi.org/10.1002/joc.2314>
- Frauen, C., Dommenges, D., Tyrrell, N., Rezný, M., y Wales, S. (2014). Analysis of the Nonlinearity of El Niño–Southern Oscillation Teleconnections. *Journal of Climate*, 27(16), 6225-6244. <https://doi.org/10.1175/JCLI-D-13-00757.1>
- Fröhlich, K., Dobrynin, M., Isensee, K., Gessner, C., Paxian, A., Pohlmann, H., Haak, H., Brune S., Früh, B., y Baehr, J. (2021). The German Climate Forecast System: GCFS. *Journal of Advances in Modeling Earth Systems*, 13, e2020MS002101. <https://doi.org/10.1029/2020MS002101>
- Gan, M. A., Kousky, V. E., y Ropelewski, C. F. (2004). The South America Monsoon Circulation and Its Relationship to Rainfall over West-Central Brazil. *Journal of Climate*, 17(1), 47-66. [https://doi.org/10.1175/1520-0442\(2004\)017<0047:TSAMCA>2.0.CO;2](https://doi.org/10.1175/1520-0442(2004)017<0047:TSAMCA>2.0.CO;2)
- Gan, M.A., Rao, V.B. y Moscati, M.C.L. (2005), South American monsoon indices. *Atmosph. Sci. Lett.*, 6: 219-223. <https://doi.org/10.1002/asl.119>
- Garbarini, E.M., González, M.H., Rolla, A.L. (2021). Modulation of seasonal precipitation in Argentina by the South Pacific high. *Int J Climatol.* 41 (Suppl. 1): E3279–E3297. <https://doi.org/10.1002/joc.6924>
- Garbarini, E.M., González, M.H., Rolla, A.L. (2019). The influence of Atlantic High on seasonal rainfall in Argentina. *Int J Climatol.*; 39: 4688–4702. <https://doi.org/10.1002/joc.6098>
- Garreaud, R., y Aceituno, P. (2001). Interannual Rainfall Variability over the South American Altiplano. *Journal of Climate*, 14(12), 2779-2789. [https://doi.org/10.1175/1520-0442\(2001\)014<2779:IRVOTS>2.0.CO;2](https://doi.org/10.1175/1520-0442(2001)014<2779:IRVOTS>2.0.CO;2)

- Garreaud R.D., Battisti D.S. (1999). Interannual (ENSO) and interdecadal (ENSO-like) variability in the Southern Hemisphere tropospheric circulation. *J. Climate* 12: 2113–2123. [http://dx.doi.org/10.1175/1520-0442\(1999\)0122.0.CO;2](http://dx.doi.org/10.1175/1520-0442(1999)0122.0.CO;2)
- Garreaud, R., Vuille, M., Compagnucci, R. y Marengo, J. (2009) Present-day south american climate. *Palaeogeography, Palaeoclimatology, Palaeoecology*, 281, 180–195. <https://doi.org/10.1016/j.palaeo.2007.10.032>
- Gemmer, M., Becker, S., y Jiang, T. (2004). Observed monthly precipitation trends in China 1951–2002. *Theoretical and Applied Climatology*, 77, 39–45. <https://doi.org/10.1007/s00704-003-0018-3>
- Gissila, T., Black, E., Grimes, D.I.F. y Slingo, J.M. (2004). Seasonal forecasting of the Ethiopian summer rains. *Int. J. Climatol.*, 24: 1345-1358. <https://doi.org/10.1002/joc.1078>
- Giuliani, M., Bosso, F., Bertini, C., Solomatine, D., y van Andel, S. J. (2024). Leveraging climate data at different spatial scales via machine learning to improve sub-seasonal drought predictions. *EGU General Assembly 2024*, Vienna, Austria, 14–19 Apr 2024, EGU24-12131, <https://doi.org/10.5194/egusphere-egu24-12131>
- Gizaw M.S., Gan T.Y. (2016). Regional flood frequency analysis using support vector regression under historical and future climate. *J Hydrol* 538:387–398
- Gong, T., Feldstein, S. B., y Luo, D. (2010). The Impact of ENSO on Wave Breaking and Southern Annular Mode Events. *Journal of the Atmospheric Sciences*, 67(9), 2854-2870. <https://doi.org/10.1175/2010JAS3311.1>
- González, M., y Barros, V. (2002). On the forecast of the onset and end of the convective season in the Amazon. *Theoretical and Applied Climatology*, 73, 169-187.
- González, M. y Barros, V. (1998). The relationship between tropical convection in South America and the end of the dry period in subtropical Argentina. *Int. J. Climatol.*, 18: 1669-1685. [https://doi.org/10.1002/\(SICI\)1097-0088\(199812\)18:15<1669::AID-JOC340>3.0.CO;2-1](https://doi.org/10.1002/(SICI)1097-0088(199812)18:15<1669::AID-JOC340>3.0.CO;2-1)
- González, M. H., Cariaga, M. L. y Skansi, M. M. (2012). Some Factors That Influence Seasonal Precipitation in Argentinean Chaco. *Advances in Meteorology*, Article ID 359164, 13 p.
- González, M., Dominguez, D., y Nuñez, M. (2012). Long term and interannual rainfall variability in argentinean Chaco Plain region. In: Martín, O., and Roberts, T. (eds.), *Rainfall: Behavior, Forecasting and Distribution*. Nova Science Publishers, 68–89. ISBN: 978-1-62081-5519.

- González, M. H. y Murgida, A. M. (2012). Seasonal Summer rainfall prediction in Bermejo River Basin in Argentina. En: Hannachi, A. (ed.) *Climate Variability-Some Aspects, Challenges and Prospects*, p. 141-160, University of Reading, INTech, Reading, Reino Unido.
- González, M. H., y Rolla, A. L. (2022). Data mining techniques applied to statistical prediction of monthly precipitation in Gran Chaco Argentina. *Theoretical and Applied Climatology*, 150(3), 1027-1043.
- González, M.H., Rolla, A.L. y Sanchez, M.V. (2023). Seasonal probabilistic precipitation prediction in Comahue region (Argentina) using statistical techniques. *Theor Appl Climatol*, 151, 1483–1495. <https://doi.org/10.1007/s00704-022-04324-w>
- González, M., Vera, C. S., Liebmann, B., Marengo, J. A., Kousky, V., y Allured, D. (2007). The nature of the rainfall onset over central South America. *Atmósfera*, 20(4), 377-394.
- Grimm, A. M. (2019). Madden–Julian Oscillation impacts on South American summer monsoon season: precipitation anomalies, extreme events, teleconnections, and role in the MJO cycle. *Climate Dynamics*. doi:10.1007/s00382-019-04622-6
- Grimm, A. M. (2003). The El Niño Impact on the Summer Monsoon in Brazil: Regional Processes versus Remote Influences. *Journal of Climate*, 16(2), 263–280. doi:10.1175/1520-0442(2003)016<0263:teniot>2.0.co
- Grimm, A. M., y Saboia, J.P.J. (2015). Interdecadal Variability of the South American Precipitation in the Monsoon Season. *J. Climate*, 28, 755–775, <https://doi.org/10.1175/JCLI-D-14-00046.1>.
- Grimm, A. M., y Zilli, M. T. (2009). Interannual Variability and Seasonal Evolution of Summer Monsoon Rainfall in South America. *Journal of Climate*, 22(9), 2257-2275. <https://doi.org/10.1175/2008JCLI2345.1>
- Günther, F., y Fritsch, S. (2010). Neuralnet: training of neural networks. *R J.*, 2(1), 30.
- Haerter, J. O., Hagemann, S., Moseley, C., y Piani, C. (2011). Climate model bias correction and the role of timescales. *Hydrol. Earth Syst. Sci.*, 15, 1065–1079, <https://doi.org/10.5194/hess-15-1065-2011>.
- Hannaford, J., y Buys, G. (2012). Trends in seasonal river flow regimes in the UK. *Journal of Hydrology*, 475, 158–174. <https://doi.org/10.1016/j.jhydrol.2012.09.044>.
- Hastie, T., Tibshirani, R. (1986). Generalized Additive Models. *Statistical Science*. *Statist. Sci.* 1(3), 297-310.

- Haylock, M. R., Peterson, T. C., Alves, L. M., Ambrizzi, T., Anunciacao, Y. M. T., Baez, J., Barros, V. R., Berlato, M. A., Bidegain, M., Coronel, G., Corradi, V., Garcia, V. J., Grimm, A. M., Karoly, D., Marengo, J. A., Marino, M. B., Moncunill, D. F., Nechet, D., Quintana, J., Rebello, E., Rusticucci, M., Santos, J. L., Trebejo, I., y Vincent, L. A. (2006). Trends in total and extreme south American rainfall in 1960–2000 and links with sea surface temperature. *Journal of Climate*, 19(8), 1490–1512.
- He, C., Wu, B., Zou, L., y Zhou, T. (2017). Responses of the summertime subtropical anticyclones to global warming. *J. Clim.* 30, 6465–6479. doi: 10.1175/JCLI-D-16-0529.1
- Herrera, N. (2022). Pronóstico trimestral estadístico y estadístico-dinámico del Servicio Meteorológico Nacional. *Nota Técnica SMN* 2022-118. <https://repositorio.smn.gob.ar/handle/20.500.12160/1789>
- Hersbach, H., Bell, B., Berrisford, P., Biavati, G., Horányi, A., Muñoz Sabater, J., Nicolas, J., Peubey, C., Radu, R., Rozum, I., Schepers, D., Simmons, A., Soci, C., Dee, D., Thépaut, J.-N. (2023). ERA5 monthly averaged data on single levels from 1940 to present. Copernicus Climate Change Service (C3S) Climate Data Store (CDS), DOI: 10.24381/cds.fl7050d7
- Hersbach H., Bell B., Berrisford P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., Nicolas, J., Peubey, C., Radu, R., Schepers, D., Simmons, A., Soci, C., Abdalla, S., Abellan, X., Balsamo, G., Bechtold, P., Biavati, G., Bidlot, J., Bonavita, M., De Chiara, G., Dahlgren, P., Dee, D., Diamantakis, M., Dragani, R., Flemming, J., Forbes, R., Fuentes, M., Geer, A., Haimberger, L., Healy, S., Hogan, R.J., Hólm, E., Janisková, M., Keeley, S., Laloyaux, P., Lopez, P., Lupu, C., Radnoti, G., de Rosnay, P., Rozum, I., Vamborg, F., Villaume, S., Thépaut, J.N. (2020). The ERA5 global reanalysis. *Q J R Meteorol Soc*, 146: 1999–2049. <https://doi.org/10.1002/qj.3803>
- Hidalgo-Muñoz, J. M., Gámiz-Fortis, S.R., Castro-Díez, Y., Argüeso, D., y Esteban-Parra, M.J. (2015). Long-range seasonal streamflow forecasting over the Iberian Peninsula using large-scale atmospheric and oceanic information, *Water Resour. Res.*, 51, 3543–3567, doi:10.1002/2014WR016826.
- Horel, J. D., Hahmann, A.N. y J. E. Geisler. (1989) An investigation of the annual cycle of convective activity over the tropical Americas. *J. Climate*, 2, 1388–1403
- Huang, B., Peter W. Thorne, Banzon, V.F., Boyer, T., Chepurin, G., Lawrimore, J.H., Menne, M.J., Smith, T.M., Vose, R.S., y Zhang, H.-M. (2017). Extended Reconstructed Sea Surface Temperature version 5 (ERSSTv5), Upgrades, validations, and intercomparisons. *Journal of Climate*, doi: 10.1175/JCLI-D-16-0836.1

- Hurtado, S.I., Perri, D.V., Calianno, M., Martin-Albarracin, V. L., Easdale, M. H. (2024). Monthly gridded precipitation databases performance evaluation in North Patagonia, Argentina. *Theor Appl Climatol*, 155, 8771–8783. <https://doi.org/10.1007/s00704-024-05153-9>.
- Hurtado S.I., Zaninelli P.G., Agosta E.A., Ricetti L. (2021). Infilling methods for monthly precipitation records with poor station network density in subtropical Argentina. *Atmos. Res.*, 254, Article 105482.
- Iacovone, M.F., Pántano, V.C. y Penalba, O.C. (2024). The relationship between ENSO, IOD and SAM with extreme rainfall over South America. *Stoch Environ Res Risk Assess*, 38, 1769–1782. <https://doi.org/10.1007/s00477-023-02653-4>
- IPCC. (2021). Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Masson-Delmotte, V., P. Zhai, A. Pirani, S.L. Connors, C. Péan, S. Berger, N. Caud, Y. Chen, L. Goldfarb, M.I. Gomis, M. Huang, K. Leitzell, E. Lonnoy, J.B.R. Matthews, T.K. Maycock, T. Waterfield, O. Yelekçi, R. Yu, and B. Zhou (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, In press, doi:10.1017/9781009157896.
- James, G., Witten, D., Hastie, T., y Tibshirani, R. (2013). *An introduction to statistical learning* (Vol. 112, p. 18). New York: Springer.
- Jobbágy, E., Noretto, M., Santoni, C., y Baldi, G. (2008). El desafío ecohidrológico de las transiciones entre sistemas leñosos y herbáceos en la llanura Chaco-Pampeana. *Ecología Austral*, 18, 305–322.
- Johnson, S. J., Stockdale, T. N., Ferranti, L., Balmaseda, M. A., Molteni, F., Magnusson, L., Tietsche, S., Decremmer, D., Weisheimer, A., Balsamo, G., Keeley, S. P. E., Mogensen, K., Zuo, H., y Monge-Sanz, B. M. (2019). SEAS5: the new ECMWF seasonal forecast system. *Geosci. Model Dev.*, 12, 1087–1117. <https://doi.org/10.5194/gmd-12-1087-2019>
- Kiladis, G.N., y Mo, K.C. (1998). Interannual and Intraseasonal Variability in the Southern Hemisphere. En: Karoly, D.J., Vincent, D.G. (eds.) *Meteorology of the Southern Hemisphere*. Meteorological Monographs. American Meteorological Society, Boston, MA. https://doi.org/10.1007/978-1-935704-10-2_11
- Kim, T.W., Valdés, J.B., Nijssen, B., Roncayolo, D. (2006). Quantification of linkages between large-scale climatic patterns and precipitation in the Colorado River Basin. *J. Hydrol.* 321 (1), 173–186.

- Kousky, V. E. (1988). Pentad outgoing longwave radiation climatology for the South American sector. *Revista Brasileira de Meteorologia*, 3(1), 217-231.
- Lamb, K.W., Piechota, T.C., Aziz, O.A., y Tootle, G.A. (2011). A basis for extending long-term streamflow forecasts in the Colorado River Basin. *Journal of Hydrologic Engineering*. DOI: 10.1061/(ASCE)HE.1943-5584.0000153.
- Lee, S., y Berbery, E.H. (2012). Land Cover Change Effects on the Climate of the La Plata Basin. *J. Hydrometeor.*, 13, 84–102, <https://doi.org/10.1175/JHM-D-11-021.1>.
- Leyba, I.M., Solman, S.A., Saraceno, M., Martínez, J.A. y Domínguez, F. (2023). The South Atlantic Ocean as a moisture source region and its relation with precipitation in South America. *Clim Dyn*, 61, 1741–1756. <https://doi.org/10.1007/s00382-022-06653-y>
- Li, P.-H., Kwon, H.-H., Sun, L., Lall, U. and Kao, J.-J. (2010), A modified support vector machine based prediction model on streamflow at the Shihmen Reservoir, Taiwan. *Int. J. Climatol.*, 30: 1256-1268. <https://doi.org/10.1002/joc.1954>
- Liebmann, B., Kiladis, G. N., Vera, C. S., Saulo, A. C., y Carvalho, L. M. V. (2004a). Subseasonal Variations of Rainfall in South America in the Vicinity of the Low-Level Jet East of the Andes and Comparison to Those in the South Atlantic Convergence Zone. *Journal of Climate*, 17 (19), 3829-3842. [https://doi.org/10.1175/1520-0442\(2004\)017<3829:SVORIS>2.0.CO;2](https://doi.org/10.1175/1520-0442(2004)017<3829:SVORIS>2.0.CO;2)
- Liebmann, B., Vera, C., Carvalho, L., Camilloni, I., Hoerling, M., Allured, D., Barros, V., Baez, J., y Bidegain, M. (2004b). An observed trend in central south American precipitation. *Journal of Climate*, 17, 4357–4367.
- Lim, E., Hendon, H. H., y Rashid, H. (2013). Seasonal Predictability of the Southern Annular Mode due to Its Association with ENSO. *Journal of Climate*, 26(20), 8037-8054. <https://doi.org/10.1175/JCLI-D-13-00006.1>
- Lin, H., Merryfield, W. J., Muncaster, R., Smith, G. C., Markovic, M., Dupont, F., Roy, F., Lemieux, J.-F., Dirkson, A., Kharin, V. V., y Lee, W. S. (2020). The Canadian Seasonal to Interannual Prediction System Version 2 (CanSIPsv2). *Weather and Forecasting*, 35, 1317–1343, <https://doi.org/10.1175/WAF-D-19-0259.1>
- Longobardi, A., y Villardi, P. (2010). Trend analysis of annual and seasonal rainfall time series in the Mediterranean area. *International Journal of Climatology*, 30, 1538–1546. <https://doi.org/10.1002/joc.2001>

- Lovino, M. A., Müller, G. V., Pierrestegui, M. J., Espinosa, E., y Rodríguez, L. (2022). Extreme precipitation events in the Austral Chaco region of Argentina. *International Journal of Climatology*, 42(11), 5985–6006. <https://doi.org/10.1002/joc.7572>
- Lovino M.A., Muller O.V., Berbery E.H., Muller G.V. (2018). How have daily climate extremes changed in the recent past over northeastern Argentina? *Global Planet Change* 168: 78–97. doi:10.1016/j.gloplacha.2018.06.008
- Mammone, A., Turchi, M. y Cristianini, N. (2009). Support vector machines. *WIREs Comp Stat*, 1: 283-289. <https://doi.org/10.1002/wics.49>
- Mantua N.J., Hare S.R., Zhang Y., Wallace J.M., y Francis R.C. (1997). A Pacific interdecadal climate oscillation with impacts on salmon production. *Bulletin of the American Meteorological Society*, 78: 1069–1079.
- Marengo J.A., Liebmann B., Grimm A.M., Misra V., Silva Dias P.L., Cavalcanti I.F.A., Carvalho L.M.V., Berbery H., Ambrizzi T., Vera C.S., Saulo A.C., Nogues Paegle J., Zipser E., Seth A., Alves L.M. 2010. Recent developments on the South American monsoon system. *Int. J. Climatol.* 32: 1–21, doi: 10.1002/joc.2254.
- Marengo, J. A., Liebmann, B., Kousky, V. E., Filizola, N. P., y Wainer, I. C. (2001). Onset and end of the rainy season in the Brazilian Amazon Basin. *Journal of Climate*, 14(5), 833-852.
- Mariotti, A., Ruti, P.M. y Rixen, M. (2018). Progress in subseasonal to seasonal prediction through a joint weather and climate community effort. *npj Clim Atmos Sci*, 1, 4. <https://doi.org/10.1038/s41612-018-0014-z>
- Martinez, C., Munoz, Á. G. Goddard, L., Kushnir, Y., Ting, M., 2022. Seasonal prediction of the Caribbean rainfall cycle. *Climate Services*, 27, 100309. <https://doi.org/10.1016/j.cliser.2022.100309>
- Mason, S. (2008). From Dynamical Model Predictions to Seasonal Climate Forecasts. En: Troccoli, A., Harrison, M., Anderson, D.L.T., y Mason, S. (eds.) *Seasonal Climate: Forecasting and Managing Risk* (pp. 205-234). Dordrecht: Springer Netherlands.
- Mason, S., y Baddour, O. (2008). Statistical Modelling. En: Troccoli, A., Harrison, M., Anderson, D.L.T., y Mason, S. (eds.) *Seasonal Climate: Forecasting and Managing Risk*, (pp. 205-234). Dordrecht: Springer Netherlands.
- Mason, S.J. y Stephenson, D.B. (2008). How Do We Know Whether Seasonal Climate Forecasts are Any Good?. En: Troccoli, A., Harrison, M., Anderson, D.L.T., y Mason, S. (eds.) *Seasonal Climate: Forecasting and Managing Risk* (pp. 205-234). Dordrecht: Springer Netherlands.

- Massey F. J. Jr. (1951). The Kolmogorov-Smirnov test for goodness of fit. *J. Am. Stat. Assoc.* 46: 68–78.
- Mathivha, F., Sigauke, C., Chikoore, H., y Odiyo, J. (2020). Short-Term and Medium-Term Drought Forecasting Using Generalized Additive Models. *Sustainability*, 12(10), 4006. <https://doi.org/10.3390/su12104006>
- McKee T.B.N., Doesken J., y Kleist J. (1993), The relationship of drought frequency and duration to time scales. En Proceedings of Eighth Conference on Applied Climatology. American Meteorological Society: Anaheim, CA; 179–184.
- McLaughlin, D. (2002). An integrate approach to hydrologic data assimilation: Interpolation, smoothing, and filtering, *Adv. Water Resour.*, 25, 1275–1286.
- McQueen, J. (1967) Some Methods for Classification and Analysis of Multivariate Observations. *Computer and Chemistry*, 4, 257-272.
- Mendoza, P. A., Rajagopalan B., Clark M.P., Cortés G., y McPhee, J. (2014), A robust multimodel framework for ensemble seasonal hydroclimatic forecasts, *Water Resour. Res.*, 50, 6030–6052, doi:[10.1002/2014WR015426](https://doi.org/10.1002/2014WR015426).
- Merryfield, W. J., Baehr, J., Batté, L., Becker, E. J., Butler, A. H., Coelho, C. A. S., Danabasoglu, G., Dirmeyer, P. A., Doblas-Reyes, F. J., Domeisen, D. I. V., Ferranti, L., Ilynia, T., Kumar, A., Müller, W. A., Rixen, M., Robertson, A. W., Smith, D. M., Takaya, Y., Tuma, M., Vitart, F., White, C. J., Alvarez, M. S., Ardilouze, C., Attard, H., Baggett, C., Balmaseda, M. A., Beraki, A. F., Bhattacharjee, P. S., Bilbao, R., de Andrade, F. M., DeFlorio, M. J., Díaz, L. B., Ehsan, M. A., Fragkoulidis, G., Gonzalez, A. O., Grainger, S., Green, B. W., Hell, M. C., Infanti, J. M., Isensee, K., Kataoka, T., Kirtman, B. P., Klingaman, N. P., Lee, J., Mayer, K., McKay, R., Mecking, J. V., Miller, D. E., Neddermann, N., Justin Ng, C. H., Ossó, A., Pankatz, K., Peatman, S., Pegion, K., Perlwitz, J., Recalde-Coronel, G. C., Reintges, A., Renkl, C., Solaraju-Murali, B., Spring, A., Stan, C., Sun, Y. Q., Tozer, C. R., Vigaud, N., Woolnough, S., y Yeager, S. (2020). Current and Emerging Developments in Subseasonal to Decadal Prediction. *Bulletin of the American Meteorological Society*, 101(6), E869-E896. <https://doi.org/10.1175/BAMS-D-19-0037.1>
- Miyasaka, T., y Nakamura, H. (2010). Structure and mechanisms of the Southern Hemisphere summertime subtropical anticyclones. *J. Clim.* 23, 2115–2130. doi: 10.1175/2009JCLI3008.1
- Mo, K. C. (2000) Relationships between low-frequency variability in the Southern Hemisphere and sea surface temperature anomalies. *J. Climate*, 13, 3599–3620.

- Mo, K. C., y R. W. Higgins, 1998: The Pacific–South American modes and tropical convection during the Southern Hemisphere winter. *Mon. Wea. Rev.*, 126, 1581–1596.
- Montini, T. L., Jones, C., y Carvalho, L. M. V. (2019). The South American low-level jet: A new climatology, variability, and changes. *Journal of Geophysical Research: Atmospheres*, 124, 1200–1218. <https://doi.org/10.1029/2018JD029634>
- Morello, J., Matteucci, S., Rodríguez, A., y Silva, M. (2012). Ecorregiones y complejos ecosistémicos argentinos. *Orientación Gráfica Editora*.
- Mouatadid, S., Raj, N., Deo, R. C., y Adamowski, J. F. (2018). Input selection and data-driven model performance optimization to predict the Standardized Precipitation and Evaporation Index in a drought-prone region. *Atmospheric research*, 212, 130-149.
- Moura, A. D., and S. Hastenrath (2004). Climate prediction for Brazil’s Nordeste: Performance of empirical and numerical modeling methods. *J. Climate*, 17(3), 2667–2672. [https://doi.org/10.1175/1520-0442\(2004\)017<2667:CPFBNP>2.0.CO;2](https://doi.org/10.1175/1520-0442(2004)017<2667:CPFBNP>2.0.CO;2)
- Muñoz-Sabater J., Dutra, E., Agustí-Panareda, A., Albergel, C., Arduini, G., Balsamo, G., Boussetta, S., Choulga, M., Harrigan, S., Hersbach, H., Martens, B., Miralles, D. G., Piles, M., Rodríguez-Fernández, N. J., Zsoter, E., Buontempo, C., y Thépaut, J.-N. (2021). ERA5-Land: A state-of-the-art global reanalysis dataset for land applications, *Earth Syst. Sci. Data*, 13, 4349–4383. <https://doi.org/10.5194/essd-13-4349-2021>.
- Murgida, A., Gonzalez, M., y Tiessen, H. (2014). Rainfall trends, land use change and adaptation in the Chaco salteno region of Argentina. *Regional Environmental Change*, 14, 1387–1394.
- Murphy, A.H. (1993). What is a good forecast? An essay on the nature of goodness in weather forecasting. *Weather Forecasting*, 8:281–293.
- National Research Council. (2010). Assessment of Intraseasonal to Interannual Climate Prediction and Predictability. *The National Academies Press*. Washington, DC. <https://doi.org/10.17226/12878>.
- Newman, M., Alexander, M. A., Ault, T. R., Cobb, K. M., Deser, C., Di Lorenzo, E., Mantua, N. J., Miller, A. J., Minobe, S., Nakamura, H., Schneider, N., Vimont, D. J., Phillips, A. S., Scott, J. D., y Smith, C. A. (2016). The Pacific Decadal Oscillation, Revisited. *Journal of Climate*, 29(12), 4399-4427. <https://doi.org/10.1175/JCLI-D-15-0508.1>
- Oliveri, P.C. y González, M.H. (2020). The role of the coastal oceans on the seasonal mean air temperature in Argentina. *Atmósfera*, 33(2), 187-199. <https://doi.org/10.20937/atm.52657>

- Olmo, M.E., Balmaceda-Huarte, R. y Bettolli, M. (2022a). Multi-model ensemble of statistically downscaled GCMs over southeastern South America: historical evaluation and future projections of daily precipitation with focus on extremes. *Clim Dyn* 59, 3051–3068. <https://doi.org/10.1007/s00382-022-06236-x>
- Olmo, M. E., Weber, T., Teichmann, C., y Bettolli, M. L. (2022b). Compound events in South America using the CORDEX-CORE ensemble: Current climate conditions and future projections in a global warming scenario. *Journal of Geophysical Research: Atmospheres*, 127, e2022JD037708. <https://doi.org/10.1029/2022JD037708>
- OMM (2018a). *Guía de Prácticas Climatológicas (OMM-N°100)*. ISBN 978-92-63-30100-0. Ginebra, Suiza.
- OMM (2018b). *Guidance on Verification of Operational Seasonal Forecasts (OMM-N°1220)*. ISBN 978-92-63-11220-0. Ginebra, Suiza.
- OMM (2020). *Guidance on Operational Practices for Objective Seasonal Forecasting (OMM-N°1246)*. ISBN 978-92-63-11246-9. Ginebra, Suiza.
- Önöz, B., y Bayazit, M. (2012). Block bootstrap for Mann-Kendall trend test for serially dependent data. *Hydrological Processes*, 26(23), 3552–3560.
- Organización Meteorológica Mundial (2018a). *Guía de Prácticas Climatológicas (OMM-N°100)*. Ginebra, Suiza.
- Osman, M., Domeisen, D., Robertson, A. W., y Weisheimer, A. (2023). Sub-seasonal to decadal predictions in support of climate services. *Climate Services*, 30, 100397, <https://doi.org/10.3929/ethz-b-000618833>.
- Osman, M., y Vera, C. S. (2017). Climate predictability and prediction skill on seasonal time scales over South America from CHFP models. *Climate Dynamics*, 49(7-8), 2365–2383. <https://doi.org/10.1007/s00382-016-3444-5>
- Owens, R.G., Hewson, T.D. (2018). ECMWF Forecast User Guide. Reading: *ECMWF*. DOI: 10.21957/m1cs7h
- Pal, I., Lall, U., Robertson, A. W., Cane, M. A., and Bansal, R. (2013) Predictability of Western Himalayan River flow: melt seasonal inflow into Bhakra Reservoir in northern India, *Hydrol. Earth Syst. Sci.*, 17, 2131–2146, <https://doi.org/10.5194/hess-17-2131-2013>.
- Palmer, W. C. (1965). Meteorological drought, Research paper No. 45, US Weather Bureau, Washington, DC.

- Palmer, T.N., Doblas-Reyes, F.J, Hagedorn, R. y Weisheimer, A. (2005). Probabilistic prediction of climate using multi-model ensembles: from basics to applications. *Phil. Trans. R. Soc.* B3601991–1998. <http://doi.org/10.1098/rstb.2005.1750>
- Pezza A.B., Simmonds I., Renwick J.A. (2007). Southern Hemisphere cyclones and anticyclones: Recent trends and links with decadal variability in the Pacific Ocean. *Int. J. Climatol.* 27: 1403–1419. <http://dx.doi.org/10.1002/Joc.1477>
- Poggi, M. M., Skansi M. M., de Elía R. (2021). Metodología de verificación del pronóstico estacional por consenso. *Nota Técnica SMN* 2021-110 <https://repositorio.smn.gob.ar/handle/20.500.12160/1724>
- Poveda, G. y Mesa, O. J. (1999). La corriente de chorro superficial del oeste (del Choco) y otras dos corrientes de chorro en Colombia: climatología y variabilidad durante las fases del ENSO. *Rev. Acad. Colomb. Cienc.* 23, 517–528.
- Prieto, M.R., Rojas, F. (2015). Determination of droughts and high floods of the Bermejo River (Argentina) based on documentary evidence (17th to 20th century). *J. Hydrol.*, <http://dx.doi.org/10.1016/j.jhydrol.2015.06.035>
- R Core Team. (2021). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
- Raymond, C., Horton, R.M., Zscheischler, J., Martius O., AghaKouchak A., Balch, J., Bowen, S., Camargo, S., Hess, J., Kornhuber, K., Oppenheimer, M., Ruane, A., Wahl, T., White, K. (2020). Understanding and managing connected extreme events. *Nat. Clim. Chang.* 10, 611–621. <https://doi.org/10.1038/s41558-020-0790-4>
- Reboita, M.S., Ambrizzi, T., Crespo, N.M., Dutra, L.M.M., Ferreira, G.W.d.S., Rehbein, A., Drumond, A., da Rocha, R.P. and Souza, C.A.d. (2021), Impacts of teleconnection patterns on South America climate. *Ann. N.Y. Acad. Sci.*, 1504: 116-153. <https://doi.org/10.1111/nyas.14592>
- Reboita, M. S., Ambrizzi, T., y Rocha, R. P. D. (2009). Relationship between the southern annular mode and southern hemisphere atmospheric systems. *Revista Brasileira de Meteorologia*, 24, 48-55.
- Reboita, M. S., Gan, M. A., da Rocha, R. P., y Ambrizzi, T. (2010). Regimes of precipitation in South America: a bibliographical review. *Braz. J. Meteorol.* 25, 185–204. doi: 10.1590/S0102-77862010000200004

- Renom, M., Rusticucci, M. y Barreiro, M. (2011). Multidecadal changes in the relationship between extreme temperature events in Uruguay and the general atmospheric circulation. *Clim Dyn* 37, 2471–2480 (2011). <https://doi.org/10.1007/s00382-010-0986-9>
- Reynolds, A. P., Richards, G., de la Iglesia, B., y Rayward-Smith, V. J. (2006). Clustering Rules: A Comparison of Partitioning and Hierarchical Clustering Algorithms. *Journal of Mathematical Modelling and Algorithms*, 5(4), 475–504. doi:10.1007/s10852-005-9022-1
- Risbey, J. S., Squire, D. T., Baldissera Pacchetti, M., Black, A. S., Chapman, C. C., Dessai, S., Irving, D. B., Matear, R. J., Monselesan, D. P., Moore, T. S., Richardson, D., Sloyan, B. M., y Tozer, C. R. (2022). Common Issues in Verification of Climate Forecasts and Projections. *Climate*, 10(6), 83. <https://doi.org/10.3390/cli10060083>
- Rodwell, M. J., y Hoskins, B. J. (2001). Subtropical Anticyclones and Summer Monsoons. *Journal of Climate*, 14 (15), 3192-3211. [https://doi.org/10.1175/1520-0442\(2001\)014<3192:SAASM>2.0.CO;2](https://doi.org/10.1175/1520-0442(2001)014<3192:SAASM>2.0.CO;2)
- Ropelewski, C. F., y Bell, M. A. (2008). Shifts in the Statistics of Daily Rainfall in South America Conditional on ENSO Phase. *Journal of Climate*, 21(5), 849-865. <https://doi.org/10.1175/2007JCLI1617.1>
- Rutllant J. (2004). Aspectos de la circulación atmosférica de gran escala asociada al ciclo ENOS 1997–1999 y sus consecuencias en el régimen de precipitación en Chile central. En: Avaria S, Carrasco J, Rutland J, Yáñez E (eds.), El Niño–La Niña 1997–2000: Su efecto en Chile. Comité Oceanográfico Nacional. CONA, Valparaíso, pp. 61–76.
- Saji, N. H., Ambrizzi, T., y Simone, S. (2005). Indian Ocean Dipole mode events and austral surface temperature anomalies. *Dyn. Atmos. Oceans*, 39, 87–101.
- Saji, N., Goswami, B., Vinayachandran, P., Yamagata T. (1999) A dipole mode in the tropical Indian Ocean. *Nature*, 401, 360–363. <https://doi.org/10.1038/43854>
- Sambrook Smith, G. H., Best, J. L., Leroy, J. Z., y Orfeo, O. (2016). The alluvial architecture of a suspended sediment dominated meandering river: The Río Bermejo, Argentina. *Sedimentology*, 63(5), 1187– 1208. <https://doi.org/10.1111/sed.12256>
- Santos Burguete, C., y Pastor Saavedra, M.A. (2018). Verificación Probabilista. En: Burguete C.S. (ed.) Física del caos en la predicción meteorológica, Agencia Estatal de Meteorología, Madrid, España.
- Schöngart, J. y Junk, W. J. (2007). Forecasting the flood-pulse in Central Amazonia by ENSO-indices. *J. Hydrol.*, 335, 124-132.

- Schott F.A., Xie S., McCreary J.P. (2009). Indian Ocean circulation and climate variability. *Rev Geophys*, 47:RG1002
- Seager, R., Murtugudde, R., Naik, N., Clement, A., Gordon, N., y Miller, J. (2003). Air–sea interaction and the seasonal cycle of the subtropical anticyclones. *J. Clim.* 16, 1948–1966. doi: 10.1175/1520-0442(2003)016<1948:AIATSC>2.0.CO;2
- Sena, A. C. T., y Magnúsdóttir, G. (2021). Influence of the Indian Ocean Dipole on the Large-Scale Circulation in South America. *Journal of Climate*, 34(15), 6057–6068. <https://doi.org/10.1175/JCLI-D-20-0669.1>
- Seneviratne, S.I., Zhang, X., Adnan, M., Badi, W., Dereczynski, C., Di Luca, A., Ghosh, S., Iskandar, I., Kossin, J., Lewis, S., Otto, F., Pinto, I., Satoh, M., Vicente-Serrano, S.M., Wehner, M., y Zhou, B. (2021). Weather and Climate Extreme Events in a Changing Climate. En: Masson-Delmotte, V., Zhai, P., Pirani, A., Connors, S.L., Péan, C., Berger, S., Caud, N., Chen, Y., Goldfarb, L., Gomis, M.I., Huang, M., Leitzell, K., Lonnoy, E., Matthews, J.B.R., Maycock, T.K., Waterfield, T., Yelekçi, O., Yu, R., y Zhou, B. (eds.) *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, pp. 1513–1766, doi: 10.1017/9781009157896.013
- Shapiro S.S., Wilk M.B. (1965). An analysis of variance test for normality (complete samples). *Biometrika* 52: 591–611.
- Sharda, V., Srivastava, P., Ingram, K., Chelliah, M. y Kalin, L. (2012). Quantification of El Niño Southern Oscillation impact on precipitation and streamflows for improved management of water resources in Alabama. *Journal of soil and water conservation*, 67(3), 158–172.
- Shi, P., Yang, T., Xu, C.-Y., Yong, B., Shao, Q., Li, Z., Wang, X., Zhou, X. y Li, S. (2017). How do the multiple large-scale climate oscillations trigger extreme precipitation? *Glob. Planet. Chang*, 157, 48–58.
- Sienz, F., Bothe, O., y Fraedrich, K. (2012). Monitoring and quantifying future climate projections of dryness and wetness extremes: SPI bias, *Hydrol. Earth Syst. Sci.*, 16, 2143–2157, <https://doi.org/10.5194/hess-16-2143-2012>.
- Silva V.B.S., Berbery E.H. (2006). Intense rainfall events affecting the La Plata basin. *Journal of Hydrometeorology*, 7: 769–787

- Silva, G.A.M., Drumond, A. y Ambrizzi, T. (2011). The impact of El Niño on South American summer climate during different phases of the Pacific Decadal Oscillation. *Theor Appl Climatol*, 106, 307–319. <https://doi.org/10.1007/s00704-011-0427-7>
- Silva, V.B.S. y Kousky, V.E. (2012). The South American monsoon system: climatology and variability. En: Wang, S.-Y. y Gillies, R. (eds.) *Modern climatology*. Rijeka, Croatia: IntechOpen, pp. 123–152.
- Silvestri, G. E., y Vera, C. S. (2003). Antarctic Oscillation signal on precipitation anomalies over southeastern South America. *Geophys. Res. Lett.*, 30, 2115, doi:10.1029/2003GL018277, 21.
- Singhrattna, N., Babel, M. S., y Perret, S. R. (2012). Hydroclimate variability and long-lead forecasting of rainfall over Thailand by large-scale atmospheric variables. *Hydrological Sciences Journal*, 57(1), 26–41. <https://doi.org/10.1080/02626667.2011.633916>
- Sinha, T. y Sankarasubramanian, A. (2013). Role of climate forecasts and initial conditions in developing streamflow and soil moisture forecasts in a rainfall–runoff regime, *Hydrol. Earth Syst. Sci.*, 17, 721–733, <https://doi.org/10.5194/hess-17-721-2013>.
- Skansi, M., Brunet, M., Sigró, J., Aguilar, E., Groening, J. A. A., Bentancur, O. J., Geier, Y. R. C., Amaya, R. L. C., Jácome, H., Ramos, A. M., Rojas, C.O., Pasten, A.M., Mitro S.S., Jiménez, C.V., Martínez, R., Alexander, L.V., Jones P.D. (2013). Warming and wetting signals emerging from analysis of changes in climate extreme indices over South America. *Global Planet. Change*, 100, pp. 295-307.
- Smola, A. J., y Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199–222. doi:10.1023/b:stco.0000035301.49549.88
- Solman, S. A., y Orlanski, I. (2010). Subpolar High Anomaly Preconditioning Precipitation over South America. *Journal of the Atmospheric Sciences*, 67(5), 1526-1542. <https://doi.org/10.1175/2009JAS3309.1>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., y Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
- Stagge, J.H., Tallaksen, L.M., Gudmundsson, L., Van Loon, A.F. and Stahl, K. (2015). Candidate Distributions for Climatological Drought Indices (SPI and SPEI). *Int. J. Climatol.*, 35: 4027-4040. <https://doi.org/10.1002/joc.4267>
- Stephenson, D.B. (2008). An Introduction to Probability Forecasting. En: Troccoli, A., Harrison, M., Anderson, D.L.T., y Mason, S. (eds.) *Seasonal Climate: Forecasting and Managing Risk* (pp. 205-234). Dordrecht: Springer Netherlands.

- Stone, M., Brooks, R.J. (1990). Continuum Regression: Cross-Validated Sequentially Constructed Prediction Embracing Ordinary Least Squares, Partial Least Squares and Principal Components Regression. *J. Roy. Stat. Soc.: Ser. B (Methodol.)*, 52 (2), 237–269. <http://www.jstor.org/stable/2345437>.
- Subsecretaría de Agricultura (Dirección Nacional de Agricultura), *Estimaciones Agrícolas*, disponible en <https://datosestimaciones.magyp.gob.ar/reportes.php?reporte=Estimaciones>. Consultado en noviembre de 2022.
- Strub P.T., Mesías J.M., Montecino V., Rutllant J., Salinas S. (1998). Coastal ocean circulation off western South America. Coastal segment. In: Robinson A.R., Brink K.H. (eds.), *The Sea*. John Wiley, New York, pp. 273–313.
- Sun, X., Cook, K. H., y Vizzy, E. K. (2017). The South Atlantic Subtropical High: Climatology and Interannual Variability. *Journal of Climate*, 30(9), 3279–3296. <https://doi.org/10.1175/JCLI-D-16-0705.1>
- Takahashi, K., Dewitte, B. (2016). Strong and moderate nonlinear El Niño regimes. *Clim Dyn* 46, 1627–1645. <https://doi.org/10.1007/s00382-015-2665-3>
- Tang, Y., Zhang, R. H., Liu, T., Duan, W., Yang, D., Zheng, F., Ren, H., Lian, T., Gao, C., Chen, D., y Mu, M. (2018). Progress in ENSO prediction and predictability study. *National Science Review*, 5(6), 826–839.
- Taschetto, A.S., Ambrizzi, T. (2012). Can Indian Ocean SST anomalies influence South American rainfall?. *Clim Dyn*, 38, 1615–1628. <https://doi.org/10.1007/s00382-011-1165-3>
- Taylor, K. E. (2001). Summarizing multiple aspects of model performance in a single diagram. *J. Geophys. Res.*, 106, D7, 7183–7192.
- Tedeschi, R. G., Grimm, A. M., y Cavalcanti, I. F. A. (2014). Influence of Central and East ENSO on extreme events of precipitation in South America during austral spring and summer. *International Journal of Climatology*, 35(8), 2045–2064. doi:10.1002/joc.4106
- Tencer B., Bettolli M.L., Rusticucci M. (2016). Compound temperature and precipitation extreme events in southern South America: associated atmospheric circulation, and simulations by a multi-RCM ensemble. *Clim Res* 68:183–199. <https://doi.org/10.3354/cr01396>
- Thompson, D. W. J., y Wallace, J. M. (2000). Annular modes in the extratropical circulation. Part I: Month-to-month variability. *J. Climate*, 13, 1000–1016.
- Tibshirani, R. (1996). Regression Selection and Shrinkage via the Lasso. *Journal of the Royal Statistical Society. Series B (Methodological)*, 58, 1, 267–288.

- Toth Z., Talagrand, O., Candille, G., y Zhu, Y. (2003). Probability and Ensemble Forecasts. En: Jolliffe, I.T., Stephenson, D.B. (eds.) *Forecast Verification. A Practitioner's Guide in Atmospheric Science* (pp. 137-164). John Wiley & Sons. West Sussex, Reino Unido.
- Tuo, Y., Duan, Z., Disse, M., Chiogna, G. (2016). Evaluation of precipitation input for SWAT modeling in alpine catchment: a case study in the Adige River basin (Italy). *Sci. Total Environ.*, 573, pp. 66-82. <https://doi.org/10.1016/j.scitotenv.2016.08.034>.
- van Oldenborgh, G. J., Balmaseda, M. A., Ferranti, L., Stockdale, T. N., y Anderson, D. L. T. (2005). Did the ECMWF seasonal forecast model outperform a statistical model over the last 15 years? *J. Climate*, 18, 2970–2989.
- van Straaten, C., Whan, K., Coumou, D., van den Hurk, B., y Schmeits, M. (2022). Using Explainable Machine Learning Forecasts to Discover Subseasonal Drivers of High Summer Temperatures in Western and Central Europe. *Mon. Wea. Rev.*, 150, 1115–1134, <https://doi.org/10.1175/MWR-D-21-0201.1>.
- Vasconcellos, F.C. y Cavalcanti, I.F.A. (2010). Extreme precipitation over Southeastern Brazil in the austral summer and relations with the Southern Hemisphere annular mode. *Atmosph. Sci. Lett.*, 11: 21-26. <https://doi.org/10.1002/asl.247>
- Vera, C. S., Alvarez, M. S., Gonzalez, P. L. M., Liebmann, B., y Kiladis, G. N. (2017). Seasonal cycle of precipitation variability in South America on intraseasonal timescales. *Climate Dynamics*. doi:10.1007/s00382-017-3994-1
- Vera, C., Higgins, W., Amador, J., Ambrizzi, T., Garreaud, R., Gochis, D., Gutzler, D., Lettenmaier, D., Marengo, J., Mechoso, C. R., Nogues-Paegle, J., Dias, P. L. S., y Zhang, C. (2006). Toward a Unified View of the American Monsoon Systems. *kg*, 19(20), 4977-5000. <https://doi.org/10.1175/JCLI3896.1>
- Vera, C., Silvestri, G., Barros, V., y Carril, A. (2004). Differences in El Niño Response over the Southern Hemisphere. *Journal of Climate*, 17(9), 1741-1753. [https://doi.org/10.1175/1520-0442\(2004\)017<1741:DIENRO>2.0.CO;2](https://doi.org/10.1175/1520-0442(2004)017<1741:DIENRO>2.0.CO;2)
- Vicente-Serrano S.M., Begueria S., Lopez-Moreno J.I. (2010). A multi-scalar drought index sensitive to global warming: the standardized precipitation evapotranspiration index – SPEI. *J. Clim.* 23: 1696–1718.
- von Storch, V. H. (1995). Misuses of statistical analysis in climate research. En von Storch, V. H., and Navarra, A. (eds.), *Analysis of Climate Variability: Applications of Statistical Techniques*. Springer- Verlag, Berlin, 11–26.

- Wagner P. D., Fiener P., Wilken F., Kumar S., Schneider K. (2012). Comparison and evaluation of spatial interpolation schemes for daily rainfall in data scarce regions. *J. Hydrol.*, 464–465, pp. 388-400.
- Wang, S.C. (2003). Artificial Neural Network. En: *Interdisciplinary Computing in Java Programming*. The Springer International Series in Engineering and Computer Science, vol 743. Springer, Boston, MA. https://doi.org/10.1007/978-1-4615-0377-4_5
- Weigel, A. P., Liniger, M. A., y Appenzeller, C. (2007). The discrete Brier and ranked probability skill scores. *Monthly Weather Review*, 135(1), 118-124.
- Welch, B. L. (1947). The generalization of "student's" problem when several different population variances are involved., *Biometrika*, 34 (1/2): 28–35, doi:10.2307/2332510
- White, C.J., Carlsen, H., Robertson, A.W., Klein, R.J.T., Lazo, J.K., Kumar, A., Vitart, F., Coughlan de Perez, E., Ray, A.J., Murray, V., Bharwani, S., MacLeod, D., James, R., Fleming, L., Morse, A.P., Eggen, B., Graham, R., Kjellström, E., Becker, E., Pegion, K.V., Holbrook, N.J., McEvoy, D., Depledge, M., Perkins-Kirkpatrick, S., Brown, T.J., Street, R., Jones, L., Remenyi, T.A., Hodgson-Johnston, I., Buontempo, C., Lamb, R., Meinke, H., Arheimer, B. y Zebiak, S.E. (2017). Potential applications of subseasonal-to-seasonal (S2S) predictions. *Met. Apps*, 24: 315-325. <https://doi.org/10.1002/met.1654>
- Widmann, M., Bretherton, C. S., y Salathé, E. P. (2003). Statistical Precipitation Downscaling over the Northwestern United States Using Numerically Simulated Precipitation as a Predictor. *J. Climate*, 16, 799–816, [https://doi.org/10.1175/1520-0442\(2003\)016<0799:SPDOTN>2.0.CO;2](https://doi.org/10.1175/1520-0442(2003)016<0799:SPDOTN>2.0.CO;2).
- Wilks, D. S. (2011). *Statistical Methods in the Atmospheric Sciences*. 3rd. ed., Academic Press, 676p.
- Wilks, D.S. y A.H. Murphy (1998). A case study of the use of statistical models in forecast verification: Precipitation probability forecasts. *Weather Forecasting*, 13:795–810.
- Wu, Yc., Feng, Jw. (2018). Development and Application of Artificial Neural Network. *Wireless Pers Commun*, 102, 1645–1656. <https://doi.org/10.1007/s11277-017-5224-x>
- Yin, Z., y Wang, H. (2017). Statistical Prediction of Winter Haze Days in the North China Plain Using the Generalized Additive Model. *Journal of Applied Meteorology and Climatology*, 56(9), 2411-2419. <https://doi.org/10.1175/JAMC-D-17-0013.1>
- Yue, S., Pilon, P., Phinney, B., y Cavadias, G. (2002). The influence of autocorrelation on the ability to detect trend in hydrological series. *Hydrological Processes*, 16, 1807–1829.

- Zargar, A., Sadiq, R., Naser, B., y Faisal, K.I. (2011). A review of drought indices. *Environmental Reviews*. 19(NA): 333-349. <https://doi.org/10.1139/a11-013>
- Zhang, H., Delworth, T. L., Zeng, F., Vecchi, G., Paffendorf, K., y Jia, L. (2016). Detection, Attribution, and Projection of Regional Rainfall Changes on (Multi-) Decadal Time Scales: A Focus on Southeastern South America. *Journal of Climate*, 29(23), 8515-8534. <https://doi.org/10.1175/JCLI-D-16-0287.1>
- Zhang Y., Norris J., Wallace J.M. (1998). Seasonality of large-scale atmosphere-ocean interaction over the North Pacific. *Journal of Climate*, 11: 2473–2481.
- Zhang, Z., Zhang, K., y Khelifi, A. (2018). Multivariate time series analysis in climate and environmental research (p. 287). Cham: Springer International Publishing.
- Zhou, J. y Lau, K.-M. (2001). Principal modes of interannual and decadal variability of summer rainfall over South America. *Int. J. Climatol.*, 21: 1623-1644. <https://doi.org/10.1002/joc.700>
- Zhou, J., y Lau, K. (1998). Does a Monsoon Climate Exist over South America?. *Journal of Climate*, 11(5), 1020-1040. [https://doi.org/10.1175/1520-0442\(1998\)011<1020:DAMCEO>2.0.CO;2](https://doi.org/10.1175/1520-0442(1998)011<1020:DAMCEO>2.0.CO;2)
- Zwiers, F.W. y von Storch, H. (2004). On the role of statistics in climate research. *Int. J. Climatol.*, 24: 665-680. <https://doi.org/10.1002/joc.1027>

Anexo




Figura A-2-1. Series temporales de precipitación acumulada en el semestre estival (1984/1985-2017/2018) para las tres estaciones con tendencias lineales significativas al 95% de confianza: El Molino en el BS, Rivadavia en el BMI, y Tres Isletas en el centro de Chaco (curva negra). Se superpone el promedio móvil considerando una ventana de 11 años (curva naranja).




Figura A-2-2. Resultado de la clusterización por *k*-mekoides sobre las anomalías estandarizadas de precipitación acumulada en OND (*fila superior*) y EFM (*fila inferior*), considerando las métricas de **a), c)** Suma Total de Cuadrados Intra-Cluster y **b), d)** Ancho Promedio de Silueta.




Figura A-3-1. Coeficiente de correlación de Pearson entre la precipitación areal de cada cluster (a nivel mensual en el semestre estival, y a nivel estacional en OND y EFM) y los indicadores generales observados con un desfase de dos meses. En el caso de la precipitación estacional, los indicadores están monitoreados dos meses antes del inicio del trimestre. En letra azul cursiva (negra) se destacan las correlaciones significativas al 90% (95%) de confianza mediante un test T-Student. Las celdas de tonalidad violeta (verde) representan correlaciones positivas (negativas), las más oscuras con mayor magnitud.

Umbral $\text{AdjR}^2 = 0.5$




Figura A-4-1. Proporción de modelos de precipitación mensual que cumplen la condición de $\text{AdjR}^2 \geq 0.5$ por cada tipo de técnica en 1984/1985-2019/2020 para el cluster 1 (**primera fila**) y el cluster 2 (**segunda fila**), discriminando los modelos según trimestre de pertenencia: OND (**primera columna**) y EFM (**segunda columna**). En la esquina superior izquierda de cada panel se indica la cantidad total de modelos que cumple la condición sobre el AdjR^2 .