

DOI: 10.24850/j-tyca-14-02-04

Artículos

Validación y corrección de estimaciones de precipitación satelital utilizando observaciones en superficie en la región pampeana argentina

Validation and correction of satellite-estimated precipitation using ground observations in the Pampean region of Argentina

Martin Blanco¹, ORCID: <https://orcid.org/0000-0002-3461-3484>

Eleonora Demaria², ORCID: <https://orcid.org/0000-0003-3051-1058>

Georgina Cazenave³

Erik Zimmermann⁴

¹Instituto de Hidrología de Llanuras "Dr. Eduardo Jorge Usunoff" (IHLLA), Buenos Aires, Argentina / Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET), martinblanco@ihlla.org.ar

²Pima County Regional Flood Control District, Tucson, AZ, USA, eleonora.demaria@pima.gov

³Instituto de Hidrología de Llanuras "Dr. Eduardo Jorge Usunoff" (IHLLA), Buenos Aires, Argentina, cazenave@ihlla.org.ar



⁴Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET) / Universidad Nacional de Rosario, Facultad de Ciencias Exactas Ingeniería y Agrimensura (UNR), Rosario, Argentina, erikz@fceia.unr.edu.ar

Autor para correspondencia: Martin Blanco, martinblanco@ihlla.org.ar

Resumen

Las estimaciones de precipitación basadas en satélites representan una valiosa fuente de información alternativa para diferentes aplicaciones hidrológicas, por lo que entender la habilidad de los productos satelitales para capturar la variabilidad espacial y temporal de la precipitación es crucial para el desarrollo de sistemas de monitoreo y alerta hidrometeorológica. En este trabajo se evalúa la confiabilidad de tres productos de precipitación satelital (PPS) en la región pampeana argentina, antes y después de aplicarles el método de corrección de sesgo *Quantile Mapping*. Los PPS usados son TMPA, CMORPH e IMERG, todos en sus versiones en tiempo casi real. La evaluación se realizó mediante estadísticos categóricos y descriptivos a fin de conocer su capacidad en proporcionar estimaciones confiables y detectar correctamente la magnitud de los eventos. El análisis de los estadísticos categóricos se realizó a nivel diario; en este caso, los PPS estiman mejor las observaciones para intensidades bajas (menores a 5 mm) y medias (entre 5 y 20 mm) que para intensidades altas (mayores a 20 mm). La evaluación de estadísticos descriptivos a nivel mensual mostró que el

CMORPH tiene mayor capacidad de detección en los trimestres EFM y AMJ, mientras que el IMERG obtuvo los menores errores para los trimestres JAS y OND. La incorporación de un método de remoción del sesgo en el proceso de validación de los PPS introdujo mejoras significativas en los estadísticos evaluados. Especialmente el CMORPH superó su rendimiento al compararlo con el IMERG, siendo el TMPA el que mayores errores presenta en la región.

Palabras clave: productos de precipitación satelital, tiempo casi real, corrección de sesgos, validación.

Abstract

Satellite-estimated precipitation represent an alternative source of information for different hydrological applications, hence understanding the skill of satellite products to capture the spatial and temporal variability of precipitation is crucial for the development of hydrometeorological monitoring and early warning systems. This study evaluates the reliability of three satellite precipitation products (SPP) in the Pampean region of Argentina, before and after applying the Quantile Mapping bias correction method. The SPP used are TMPA, CMORPH and IMERG in their near real time versions. The evaluation was carried out using categorical and descriptive statistics in order to assess their skills to provide reliable estimates and correctly detect the magnitude of precipitation events. The categorical statistical analysis was carried out at a daily time step, in this case SPPs better estimate the observations for low intensities (less than

5 mm) and medium (between 5 and 20 mm) than for high intensities (greater than 20 mm). The evaluation of the descriptive statistics at the monthly level showed that the CMORPH has the highest detection skill in the EFM and AMJ quarters, while the IMERG obtained the lowest errors for the JAS and OND quarters. The incorporation of a bias removal method in the SPP validation process introduced significant improvements in the evaluated statistics. Especially the CMORPH which significantly improved its performance when compared with the IMERG, being the TMPA the one showing the larger errors in the region.

Keywords: Satellite precipitation products, near real time, bias correction, validation.

Recibido: 15/07/2021

Aceptado: 29/09/2021

Introducción

La precipitación es la variable climática de mayor importancia del sistema hidrológico, por lo que entender su comportamiento espacial y temporal es necesario tanto para el desarrollo de sistemas de monitoreo y alerta



hidrometeorológica como para la toma de decisiones en las áreas de meteorología, hidrología y agricultura. Históricamente, la precipitación se observa en estaciones meteorológicas en superficie, las cuales proporcionan mediciones directas, pero por lo general no están distribuidas de forma uniforme y están sujetas a errores asociados con el tipo de precipitación, viento y falta de mantenimiento, entre otros factores. Fue en la década de 1970 donde se desarrollaron las primeras técnicas para estimar la precipitación a partir de observaciones radiométricas de satélites. Al inicio, la precipitación se estimaba con sensores de longitud de onda visibles o infrarrojos, a través de la reflectividad y la temperatura del tope de las nubes. Después, la introducción de sensores de microondas pasivos que penetran las nubes y miden el tamaño de las gotas de lluvia permitió una disminución de la incertidumbre en la precipitación estimada (Ebert, Janowiak, & Kidd, 2007).

En los últimos años se han desarrollado diversos productos de precipitación satelital (PPS) usando distintas técnicas para estimar la precipitación con base en la información combinada de varios satélites, entre los que se puede mencionar el *Multi-satellite Precipitation Analysis* (TMPA) de la *Tropical Rainfall Measuring Mission* (TRMM) (Huffman *et al.*, 2007), el producto *Climate Prediction Center* (CPC), *Morphing Technique Product* (CMORPH) (Joyce, Janowiak, Arkin, & Xie, 2004), y el *Integrated Multi-Satellite Retrievals for GPM* (IMERG) estimado con la misión del *Global Precipitation Measurement* (GPM) (Huffman *et al.*, 2014).

Por lo general, los satélites no pueden ofrecer el mismo detalle a escala temporal con actualizaciones rápidas como las estaciones en superficie con transmisión en tiempo real; pero la cobertura satelital posee numerosas ventajas que hacen sus usos atractivos para diferentes disciplinas. En este sentido, se puede mencionar que los PPS se encuentran sistemáticamente disponibles en todo el mundo; tienen medición continua; proporcionan datos espacialmente uniformes con amplia resolución espacial, que incluye las vastas áreas oceánicas; se pueden descargar de forma gratuita, y algunos productos tienen disponibilidad en tiempo casi real. Sin embargo, los PPS también presentan algunas limitaciones, como lo demuestran diferentes evaluaciones con observaciones en superficie realizadas en diversas regiones geográficas (Hong, Hsu, Moradkhani, & Sorooshian, 2006; Hossain & Anagnostou, 2004; Hossain & Anagnostou, 2006; Iida, Kubota, Iguchi, & Oki, 2010; Tang, Hossain, & Huffman, 2010; Tang & Hossain, 2009; Yilmaz *et al.*, 2005). Estos estudios señalan sesgos importantes en los PPS a causa de distintas fuentes de incertidumbre, como errores en el muestreo debido a la discontinuidad espacial y temporal de las mediciones, y/o problemas de calibración en los sensores satelitales.

Además, existen otros factores que pueden influir en los errores de los PPS, como el régimen de precipitación o la topografía de cada región en particular. Zambrano-Bigiarini, Nauditt, Birkel, Verbist y Ribbe (2017) evaluaron siete PPS en Chile y demostraron que el ajuste con las observaciones era mayor en zonas húmedas con elevaciones bajas y

medias (0-1 000 msnm) que en las regiones áridas del norte y el extremo sur. Tales resultados indican que los PPS deben evaluarse en términos de error con observaciones en superficie, ya que su rendimiento podría variar según su ubicación geográfica, como lo demuestran diversos estudios realizados en diferentes partes del mundo (Aslami, Ghorbani, Sobhani, & Esmali, 2019; Basheer & Elagib, 2019; Gella, 2019; Tan & Duan, 2017; Tan & Santo, 2018). En Sudamérica, los análisis de PPS han arrojado resultados heterogéneos (Baez-Villanueva *et al.*, 2018; Dinku, Ruiz, Connor, & Ceccato, 2010; Melo *et al.*, 2015; Oreggioni-Weiberlen & Báez-Benítez, 2018; Palharini *et al.*, 2020; Zambrano-Bigiarini *et al.*, 2017). El sesgo en los PPS se reconoció como un problema relevante en varias cuencas de todo el mundo, y se demostró que los métodos de corrección de sesgo reducen de manera significativa los errores en caudales simulados (Maggioni & Massari, 2018).

Hobouchian, Salio, García-Skabar, Vila y Garreaud (2017) realizaron una validación de cuatro estimaciones de precipitación diaria por satélite sobre los Andes subtropicales; sus resultados indican una disminución en los errores en la época invernal, que coincide con la temporada de lluvias. Tanto este análisis como la validación de seis PPS hecha en el sur de Sudamérica por Salio, Hobouchian, García-Skabar y Vila (2015) destaca que las estimaciones que incluyen información de microonda captura mejor la precipitación que aquellas que no las consideran, además demostraron que los productos con menor sesgo son los que están calibrados con observaciones en superficie, como es el caso

de TMPA (3B42), sin embargo, tienen una limitación para su uso, pues sólo se encuentran disponibles después de dos meses de publicarse su versión sin corrección.

La región pampeana es una zona con características típicas de llanura, que constituye un ambiente vulnerable ante eventos hidrológicos extremos tanto de déficit como de exceso hídrico. Frente a situaciones de exceso, la baja pendiente topográfica junto con otros factores impide la salida superficial de importantes volúmenes de agua, por lo que suelen ocurrir grandes episodios de inundaciones en una fracción significativa del paisaje (Aragón, Jobbágy, & Viglizzo, 2011). Las llanuras de Argentina tienen una gran preponderancia socioeconómica, pues destacan por su gran extensión y la calidad de sus tierras, lo que las convierte en una de las principales regiones del mundo en la producción de trigo, maíz y soja, y la cría de ganado vacuno. Esta gran presión productiva, sumado a la falta de sistemas de alerta y monitoreo de crecidas, las convierte en sistemas muy vulnerables, lo que motivó la elección de PPS en tiempo casi real para su evaluación en el presente trabajo.

Los objetivos de este trabajo son: 1) evaluar la capacidad para detectar frecuencias y magnitudes de precipitación diaria y trimestral de tres PPS en su versión en tiempo casi real, usando observaciones pluviométricas en superficie en una zona de llanura; 2) seleccionar el PPS que mejor representa la variabilidad espacio-temporal de la precipitación en la región, y 3) estimar el impacto de la remoción de sesgos entre los PPS y las observaciones de superficie.

Datos

Zona de estudio

La región pampeana se ubica en el centro-este de Argentina en Sudamérica. Comprende el sur de las provincias de Entre Ríos y Santa Fe, el sureste de Córdoba, el noreste de La Pampa, parte de San Luis y la mayor parte de la provincia de Buenos Aires (Figura 1). Es una llanura extensa, que abarca un área de unos 600 000 km² (Aliaga, Ferrelli, & Piccolo, 2017); la economía se basa sobre todo en la producción e industrialización agrícola-ganadera, siendo el área de secano más productiva del país, concentrando más del 90 % de la producción de soja, y entre el 80 y 90 % de la producción de trigo, maíz, sorgo, cebada y girasol (Magrin, Travasso, López, Rodríguez, & Lloveras 2007).

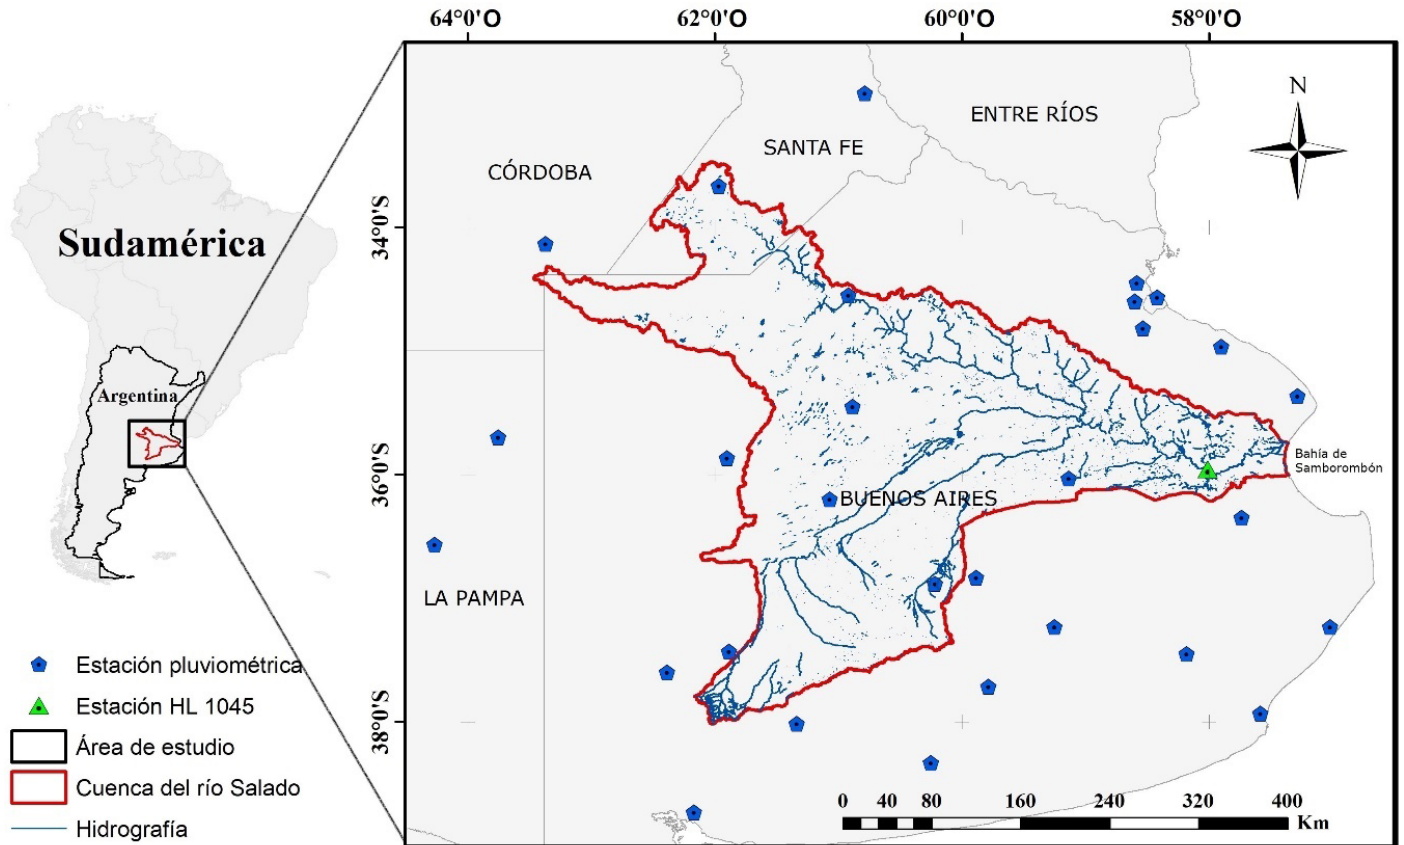


Figura 1. Ubicación de la zona de estudio y las estaciones pluviométricas en superficie.

La principal característica de la región pampeana es su relieve plano, constituido por una llanura de bajo gradiente topográfico (pendientes $< 0.1\%$), elevaciones menores de 200 msnm y redes de drenaje poco desarrolladas. En épocas húmedas, esta baja energía morfológica condiciona la formación de inundaciones temporarias,

anegamiento del suelo, acumulación de sales cerca de la superficie, y desarrollo de bañados y lagunas poco profundas (Fuschini-Mejía, 1994).

Uno de los principales sistemas hídricos en la región pampeana es la cuenca del río Salado, la cual abarca un área aproximada de 90 000 km² y está ubicada principalmente en la Provincia de Buenos Aires. La cuenca del río Salado tiene sus nacientes al sureste de la provincia de Córdoba y suroeste de Santa Fe; desemboca en la bahía de Samborombón en el océano Atlántico (Figura 1) y tiene un caudal medio diario de 210 m³/s, registrado en la estación HL 1045 para el periodo 1990-1998. Durante periodos de exceso hídrico se han observado caudales extremos, como es el caso de las inundaciones ocurridas en diciembre de 1985 (1 454 m³/s), julio de 1993 (1 380 m³/s) y abril de 2002 (1 429 m³/s).

El área de estudio seleccionada está limitada por los meridianos 56° 30' W y 64° 30' W y los paralelos 32° 30' S y 39° 00' S (Figura 1), e incluye la cuenca del río Salado. El clima es templado húmedo, la temperatura media anual es de 16 °C, con un promedio máximo en enero de 24 °C y mínimo en junio de 9 °C. La precipitación media anual es de unos 1 050 mm en el noreste, disminuyendo de forma gradual a unos 650 mm hacia el suroeste. Esta región tiene diferentes regímenes de precipitación entre las estaciones cálidas y frías. Durante el invierno (junio, julio y agosto), la precipitación está asociada con frentes fríos que provocan precipitaciones de baja intensidad y gran extensión espacial; mientras que en los meses de primavera (octubre, noviembre y diciembre) y verano (enero, febrero y marzo), la precipitación está

asociada con frecuencia a la presencia de frentes cálidos y las denominadas tormentas de masa de aire, que se caracterizan por fuertes precipitaciones de origen convectivo.

Estaciones pluviométricas en superficie

Se recopiló información de 29 estaciones pluviométricas en superficie, pertenecientes al Servicio Meteorológico Nacional (SMN) y al Instituto Nacional de Tecnología Agropecuaria (INTA), ubicadas en la provincia de Buenos Aires, sur de Santa Fe, sur de Córdoba y al este de La Pampa, como se observa en la Figura 1. Los datos medidos por las estaciones son la precipitación diaria acumulada (denominados “datos observados” para este análisis) a las 12:00 UTC (9:00 AM hora local).

Productos de precipitación satelital

La *National Aeronautics and Space Administration* (NASA) y la *Japan Aerospace Exploration Agency* (JAXA), en el año 1997 lanzan el satélite TRMM, diseñado para monitorear y estudiar las precipitaciones tropicales. Cuenta con cinco sensores a bordo, de los cuales tres son para la medición de lluvia: un radar de precipitación (PR), que proporciona datos de intensidad, distribución y tipo de lluvia; un sensor de imágenes de microondas pasivo (TMI), que cuantifica vapor de agua, agua en las nubes e intensidad de lluvia; y un escáner del visible y del infrarrojo (VIRS), siendo el principio de observación y el ancho de banda de cada uno diferente: 760, 720 y 215 km, respectivamente. La información registrada por estos sensores es publicada por la NASA.

Para este trabajo se usaron datos de análisis de precipitación multisatélite TRMM en tiempo real (Huffman *et al.*, 2007), que se encuentra en la versión 7. El producto usado es el 3B42RT (a partir de ahora se denominará TMPA), que cuenta con una cobertura global desde 60° norte a 60° sur; su resolución espacial es de 0.25° y temporal de tres horas. Los archivos son de acceso público y están disponibles desde marzo del año 2000, aunque no incluyen las medidas de calibración usando observaciones pluviométricas de superficie como el producto 3B42, las estimaciones de precipitación están disponibles con una demora de unas

ocho horas, lo que resulta adecuado para las actividades de monitoreo y modelado en tiempo casi real.

El algoritmo de estimación de precipitación CMORPH fue desarrollado en EUA por la *National Oceanic and Atmospheric Administration* (NOAA). Las estimaciones de precipitación se basan solo en datos de sensores microondas pasivos (Joyce *et al.*, 2004) y las imágenes IR no se utilizan para estimar la precipitación sino solo para interpolar entre dos campos de intensidad de lluvia derivados de sensores microondas. El producto de precipitación que se usó en este trabajo fue CMORPH, en sus versiones 1.0 (para el periodo 2001-2014) y después se usó la versión 0.x hasta diciembre de 2017. Los datos de este producto tienen la misma cobertura, resolución espacial y temporal que el producto TMPA.

La misión GPM es una red internacional de satélites que proporciona observaciones globales de lluvia que nace sobre la base del éxito de la misión TRMM. El algoritmo IMERG combina información de la constelación de satélites GPM para estimar la precipitación sobre la mayor parte de la superficie de la Tierra. En la última versión v.6 (Huffman *et al.*, 2019), el algoritmo fusiona las estimaciones de precipitación tempranas recopiladas durante la operación del satélite TRMM (2000-2015) con estimaciones de precipitación más recientes recopiladas durante la operación del satélite GPM (2014-presente).

El IMERG ofrece tres tipos diferentes de productos: el producto “Final”, que está disponible 3.5 meses después del periodo de

observación; el producto “Late” disponible luego de 14 horas, y el producto “Early”, que se encuentra disponible a solo cuatro horas de su tiempo de observación. Este último producto es el utilizado en el presente trabajo, y cuenta con una distribución espacial de $0.1^\circ \times 0.1^\circ$, temporal de 30 minutos y cobertura global de 90° norte a 90° sur.

Metodología

Evaluación de los PPS

Para evaluar de forma adecuada la precipitación entre los PPS y los datos observados es necesario tomar en cuenta el desajuste de escala espacial entre ellos. Los PPS están disponibles a escala de cuadrícula o píxel (0.1° para el producto IMERG y 0.25° para los productos CMORPH y TMPA), mientras que los datos observados representan la precipitación puntual.

En este estudio, la evaluación se llevó a cabo en dos escalas espaciales diferentes: 1) píxel (PPS) *versus* punto (dato observado), y 2) píxel (PPS) *versus* píxel (dato observado). La primera escala permite

evaluar el comportamiento del píxel más cercano de los PPS respecto a cada estación pluviométrica (dato observado), en este caso se usó una resolución temporal diaria. Mientras que la segunda escala permite evaluar el comportamiento de los PPS de manera distribuida en la zona de estudio; para que esta evaluación fuera posible fue necesario realizar una interpolación de los datos observados y un remuestreo de los datos del producto IMERG para que el tamaño del píxel sea compatible (0.25°); la resolución temporal usada fue mensual.

Algunos investigadores (Borges, Franke, Da-Anunciação, Weiss, & Bernhofer, 2016; Cisneros-Iturbe, Bouvier, & Domínguez-Mora, 2001) han argumentado que la interpolación podría generar alguna incertidumbre asociada con el método de cálculo o con la densidad de las estaciones de medición; por otro lado, el error de muestreo espacial disminuye al aumentar el tiempo de acumulación de la precipitación (Maggioni & Massari, 2018; Villarini, Mandapaka, Krajewski, & Moore, 2008); por tal razón y para disminuir estos errores en la escala espacial píxel *versus* píxel se evaluó con una resolución temporal mensual.

La evaluación de los diferentes productos se realizó de dos maneras: aplicando estadísticos categóricos que permiten evaluar la capacidad de detección de la precipitación de los PPS respecto a los datos observados, y los estadísticos descriptivos que permiten conocer cuantitativamente los errores y correlaciones que existen entre los datos observados y los PPS.

Los estadísticos categóricos se usaron considerando los distintos umbrales de precipitación (0.5, 1, 2, 3, 4, 5, 10, 15, 20, 25, 30, 35, 40, 45 y 50 mm/día). Se clasificó cada evento a partir de la propuesta de Ebert *et al.* (2007) usando las siguientes categorías: acierto (H, la precipitación observada y del PPS están por encima del umbral); sorpresa (M, la precipitación observada está por encima del umbral y la del PPS por debajo), y falsa alarma (F, la precipitación del PPS está por encima del umbral y la observada por debajo).

Los estadísticos categóricos aplicados son los siguientes: el *bias score* (BIASS), la probabilidad de detección (POD), la relación de falsa alarma (FAR) y el *equitable threat score* (ETS); sus fórmulas se presentan en la Tabla 1. El BIASS es la relación entre la cantidad de eventos de precipitación estimada y la cantidad de eventos de precipitación observada, el cual indica si la precipitación estimada tiene una tendencia a subestimar ($BIASS < 1$) o sobrestimar ($BIASS > 1$), pero no brinda una medida de dicha magnitud (solo mide frecuencias relativas); la POD muestra qué fracción de eventos observados se capturó correctamente (sensible a los aciertos, pero ignora las falsas alarmas); la FAR muestra la fracción de los eventos estimados por los PPS que en realidad no ocurrieron (sensibles a las falsas alarmas, pero ignora las sorpresas); y el ETS calcula la fracción de precipitación correctamente estimada considerando el número de aciertos aleatorios.

Tabla 1. Estadísticos categóricos usados en la evaluación de los PPS. H: la precipitación observada y del PPS están por encima del umbral; M: la precipitación observada está por encima del umbral y la del PPS por debajo; F: la precipitación del PPS está por encima del umbral y la observada por debajo; T representa el número total de eventos.

Índice	Ecuación	Valor ideal
<i>Bias score</i>	$\text{BIASS} = \frac{H + F}{H + M}$	1
Probabilidad de detección	$\text{POD} = \frac{H}{H + M}$	1
Relación de falsa alarma	$\text{FAR} = \frac{F}{H + F}$	0
<i>Equitable threat score</i>	$\text{ETS} = \frac{H - \frac{(H+M) \cdot (H+F)}{T}}{H + M + F - \frac{(H+M) \cdot (H+F)}{T}}$	1

El segundo método consistió en la aplicación de estadísticos descriptivos para cuantificar la magnitud de los errores entre las observaciones de superficie y los PPS. Además de usar la relación punto *versus* píxel con resolución temporal diaria, también se usó la relación píxel *versus* píxel a una resolución temporal mensual. Para que esta última relación sea posible fue necesario realizar una distribución espacial de los datos observados de precipitación. Tal distribución espacial se hizo con el método de la *Inverse Distance Weighting* (IDW), usando herramientas de sistemas de información geográfica.

El método IDW posee una larga historia de uso y confiabilidad, debido en particular a su simplicidad en la formulación y su amplia aplicación en los entornos operativos; con frecuencia es utilizado para interpolar la precipitación (Campozano, Sánchez, Avilés, & Samaniego, 2014; Guevara-Ochoa *et al.*, 2017; Kim & Ryu, 2016). Con este método, el valor estimado se obtiene a través de un promedio ponderado de todos los valores que se encuentren dentro de un área de búsqueda. El método asigna el mayor peso al punto más cercano, el cual va disminuyendo a medida que aumenta la distancia. Su ecuación se expresa como:

$$W_p = \frac{\sum_{i=1}^n \frac{W_i}{(d_i)^\beta}}{\sum_{i=1}^n \left(\frac{1}{d_i}\right)^\beta} \quad (1)$$

donde W_p es el valor estimado en el punto p ; n , el número de puntos usado en la interpolación; W_i , el valor conocido en el i -ésimo punto; d_i , la distancia desde el punto conocido i al punto a estimar p , y β es la potencia de la inversa de la distancia.

Para evaluar el desempeño de los PPS y compararlos con datos de precipitación en superficie se utilizaron diferentes estadísticos descriptivos (Aslami *et al.*, 2019; Tan & Duan, 2017). El coeficiente de correlación de Pearson (R) se usó para evaluar el grado de concordancia entre los PPS y los datos observados, que varía entre -1 y 1. La raíz del error medio cuadrático (RMSE) representa la desviación estándar de la

muestra de las diferencias entre los valores estimados y los valores observados. El sesgo estadístico (BIAS) es la diferencia promedio entre los PPS y los datos observados; este estadístico se utilizó para estimar el porcentaje de subestimación o sobrestimación entre las variables. Además, para evaluar la habilidad del producto se calculó el índice de Nash-Sutcliffe (NSE), que oscila entre $-\infty$ y 1 (Tabla 2).

Tabla 2. Estadísticos descriptivos usados en la evaluación de los PPS: m : tamaño de la muestra; S_n : estimaciones de precipitación satelital; O_n : observaciones en superficie; \bar{S} : media aritmética de las estimaciones de precipitación satelital; \bar{O} : media aritmética de las observaciones en superficie.

Métrica estadística	Ecuación	Valor ideal
Coeficiente de correlación de Pearson	$R = \frac{\sum_{k=1}^m (S_n - \bar{S})(O_n - \bar{O})}{\sqrt{\sum_{k=1}^m (S_n - \bar{S})^2} \sqrt{\sum_{k=1}^m (O_n - \bar{O})^2}}$	1
Raíz del error medio cuadrático	$RMSE = \sqrt{\frac{1}{m} \sum_{k=1}^m (S_n - O_n)^2}$	0
Sesgo estadístico	$BIAS = \frac{\sum_{k=1}^m (S_n - O_n)}{\sum_{k=1}^m O_n} \times 100$	0
Índice de eficiencia de Nash-Sutcliffe	$NSE = 1 - \frac{\sum_{k=1}^m (O_n - S_n)^2}{(\sum_{k=1}^m (O_n - \bar{O})^2)}$	1

Corrección del BIAS de los PPS

Luego de realizar la evaluación de los PPS respecto a los datos observados se aplicó la corrección del sesgo. El procedimiento utilizado es el *Quantile Mapping* (QM), el cual es un método no paramétrico (Fang, Yang, Chen, & Zammit, 2015), que consiste en implementar transformaciones estadísticas para corregir el sesgo los PPS. Este enfoque se basa en la relación de cuantiles para hacer converger la función de distribución empírica de probabilidad acumulada de las variables simuladas a las observadas. Algunos autores han usado con éxito dicho método para la corrección del sesgo de precipitación y temperatura en modelos climáticos globales y regionales (Heo, Ahn, Shin, Kjeldsen, & Jeong, 2019; Ines & Hansen, 2006; Luo *et al.*, 2018; Themeßl, Gobiet, & Heinrich, 2012).

La corrección del sesgo se realizó construyendo las funciones de distribución acumulada mensual de los PPS y los datos observados utilizando una función de transferencia que permite trasladar los PPS sin corregir a PPS corregidos. Por lo tanto, la función de distribución acumulada de los PPS se transforma para que coincida con el conjunto de los datos observados. En la Figura 2 se presenta un esquema del método QM utilizado en este trabajo. La ecuación usada para la corrección del sesgo es la siguiente:

$$P_c = F_o^{-1}(F_s(P_s)) \quad (2)$$

donde P_c es el valor del PPS corregido; P_s , el valor del PPS a corregir; F_o^{-1} , la inversa de la función de distribución acumulada de los datos observados, y F_s es la función de distribución acumulada del PPS utilizado.

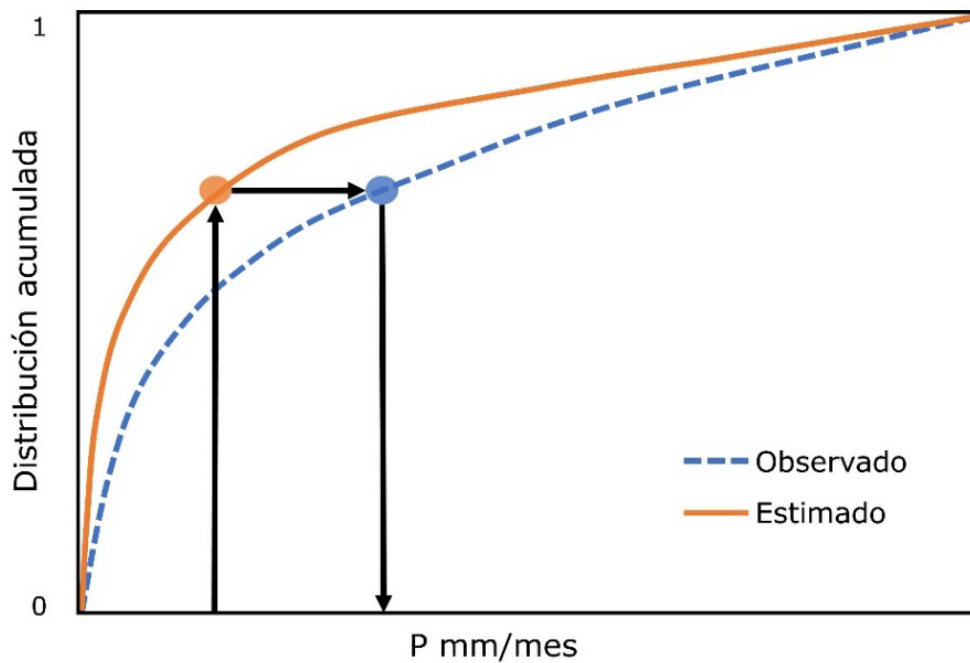


Figura 2. Representación gráfica del método de QM.

El método QM se aplicó a las distribuciones de precipitación mensual, y la relación entre el PPS y el PPS corregido se usó para desagregar temporalmente los datos corregidos del nivel mensual al diario.

Luego de hacer la corrección del sesgo a los PPS se actualizó el cálculo de los estadísticos descriptivos. La evaluación de los PPS se hizo para ambas escalas espaciales (punto *versus* píxel y píxel *versus* píxel), luego se compararon los productos en sus versiones corregidas y sin corregir. Para diferenciar los PPS de los PPS corregidos se agregó -C al final del nombre de cada producto. La Figura 3 presenta un esquema de la metodología descrita en las etapas anteriores.

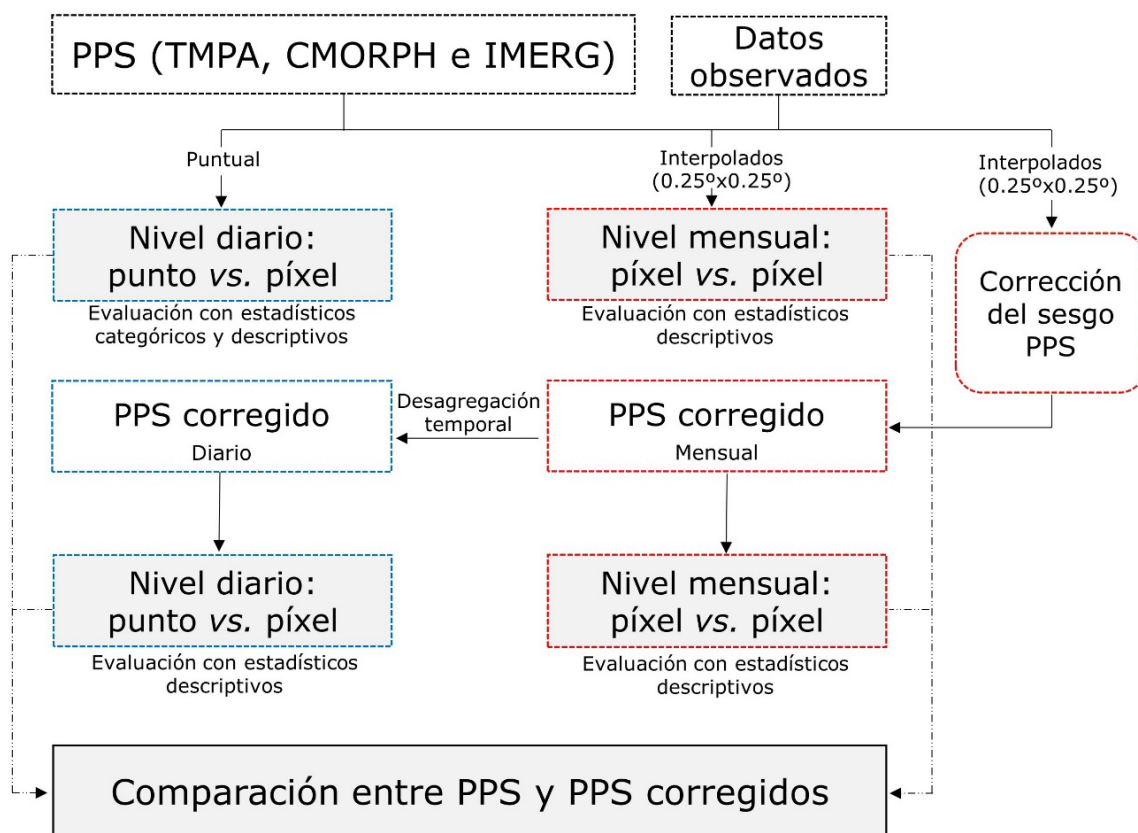


Figura 3. Esquema de la metodología.

Resultados

Análisis de la variabilidad temporal y espacial de la precipitación

La Figura 4 muestra la precipitación media mensual para la región de estudio, las máximas y mínimas son referidas a las distintas estaciones, considerando la precipitación media en cada una. Los resultados muestran que el 65 % de la precipitación ocurre entre los meses de octubre a marzo, en donde se hace evidente la influencia del anticiclón del Atlántico sur, que genera el ingreso de masa de aire cálido y húmedo; este efecto disminuye de forma marcada en los meses más fríos de abril a septiembre, donde el anticiclón se desplaza hacia el norte, limitando el ingreso de masas de aire húmedo. En relación con la precipitación media, los menores valores ocurren en el mes de junio con 33 mm; también se observa la presencia de dos máximos anuales, el principal en el mes de febrero con 116 mm y el segundo en el mes de octubre con 105 mm.

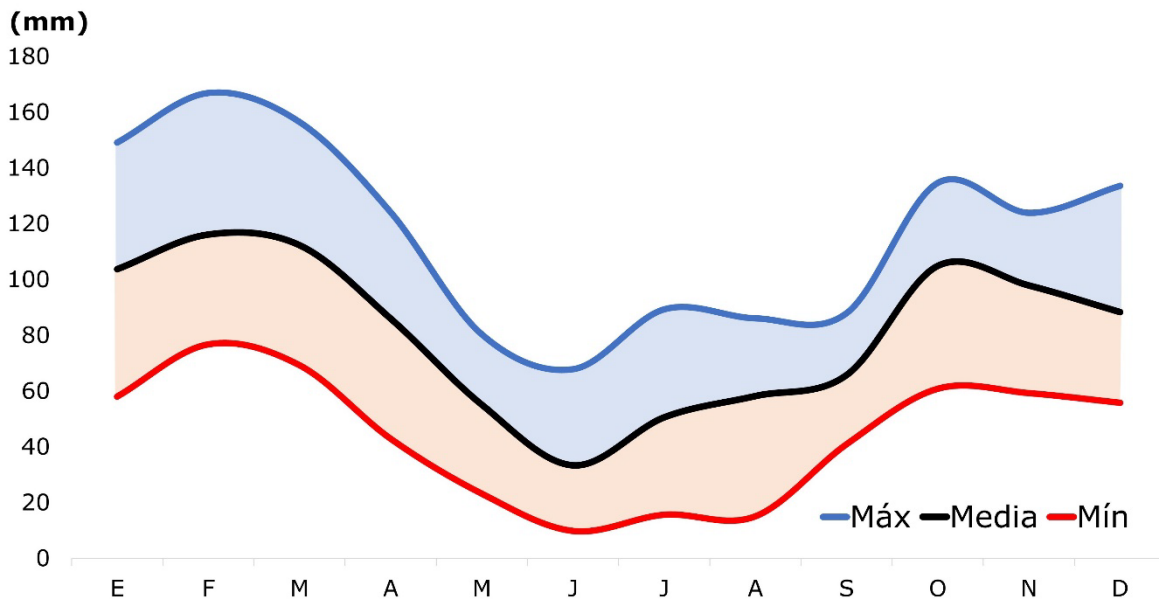


Figura 4. Precipitación media mensual para las estaciones pluviométricas en superficie. Periodo 2001-2017.

La Figura 5 muestra cómo la distribución espacio-temporal de la precipitación varía en función de la proximidad de las estaciones de superficie al océano Atlántico. Por ejemplo, las estaciones Rosario Aero, Laboulaye Aero y Santa Rosa Aero se encuentran en la zona de influencia continental, donde hay una estacionalidad más marcada, con 75 % de la precipitación ocurriendo en el semestre cálido (de octubre a marzo). Esta marcada variación estacional se debe a que el aporte de humedad desde el centro-norte del país se encuentra con una superficie más caliente, lo que favorece a la formación de precipitación de origen convectivo durante

este periodo. En contraste, las estaciones La Plata Aero, Azul Aero, Bahía Blanca Aero y Mar del Plata Aero están dentro de la zona con influencia marítima, en la que se refleja una estacionalidad menos marcada, con un 60 % de la precipitación en los mismos meses.

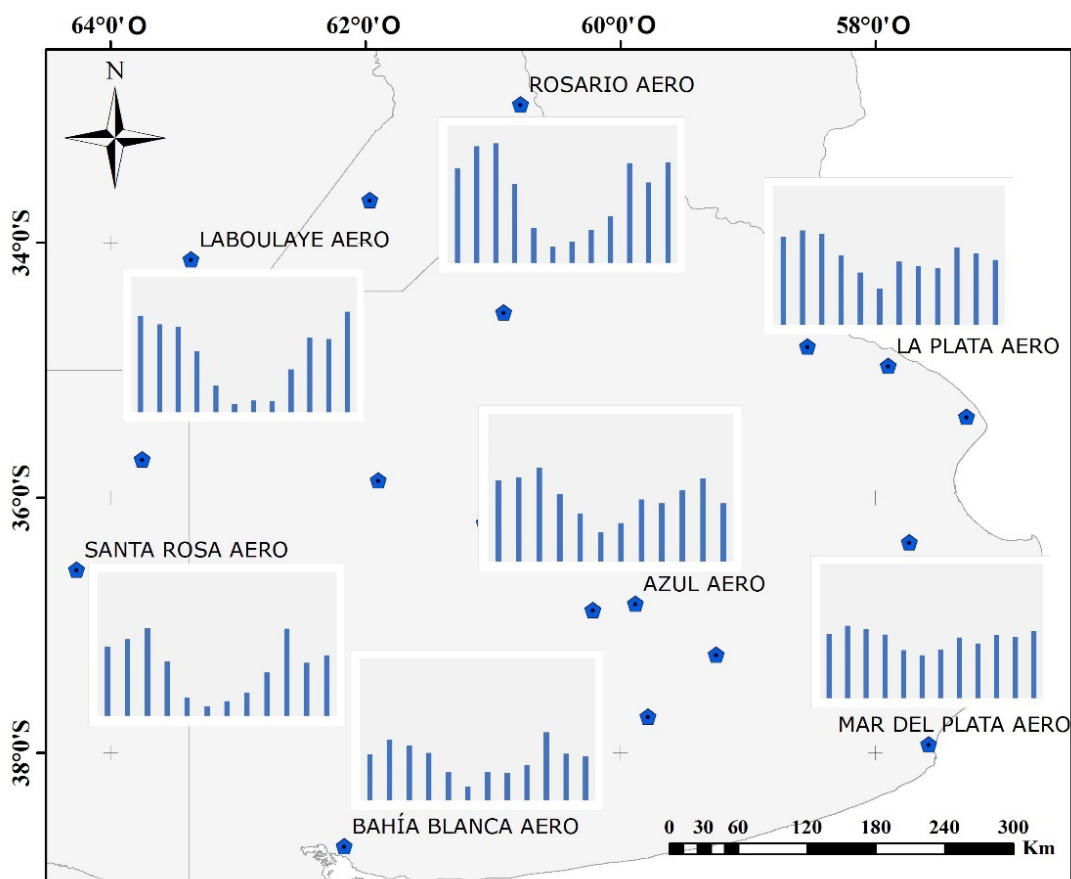


Figura 5. Ubicación geográfica de las estaciones pluviométricas en superficie y régimen estacional de precipitación. Periodo 2001-2017.

En la distribución espacial de la precipitación anual (Figura 6a) se observa una tendencia decreciente que va desde el noreste, con valores superiores a 1 050 mm/año, al suroeste, con valores inferiores a 650 mm/año. Los tres PPS presentados en la Figura 6 (b, c y d) siguen el mismo patrón de distribución espacial que la precipitación observada, sin embargo, todos los productos tienen tendencia a sobrestimar la precipitación, siendo el más evidente el producto IMERG, con valores mayores a 2 000 mm/año en la parte noreste de la región y mínimos cercanos a los 1 000 mm/año en la zona suroeste.

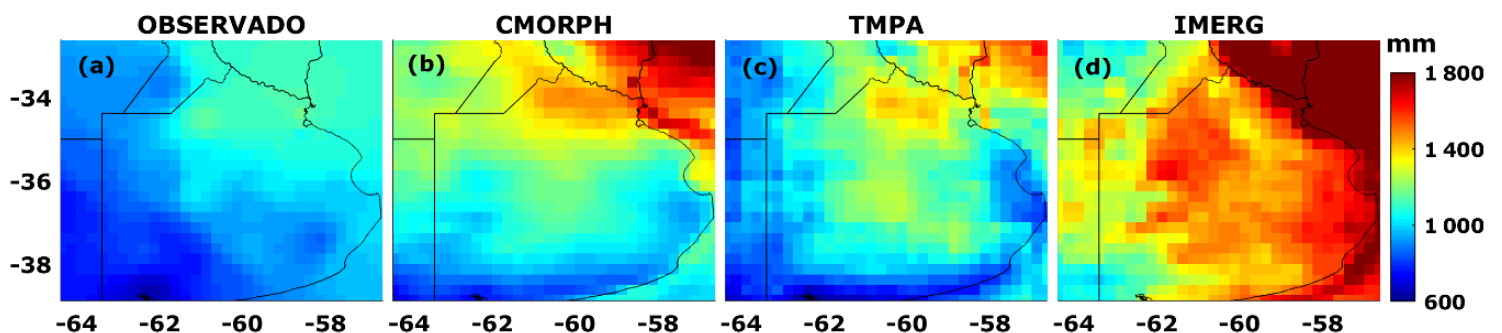


Figura 6. Distribución espacial de la precipitación observada y estimada por los distintos PPS (mm/año). Periodo 2001-2017.

Al comparar la precipitación trimestral promedio de los PPS con los datos observados en superficie (Figura 7), se aprecia que éstos capturan la variabilidad espacial, pero no la magnitud de la precipitación en la región. La precipitación acumulada en las estaciones de superficie fue mayor en EFM y OND; para estos casos, el promedio resultó 330 y 295

mm, respectivamente. En estos dos trimestres, los PPS sobrestiman la precipitación observada en casi toda la región de estudio, siendo más notable esta diferencia en el producto IMERG, para el cual se obtuvo un valor medio de 530 mm (EFM) y 440 mm (OND), seguido del producto CMORPH, con un promedio de 485 mm (EFM) y 405 mm (OND); por último, el TMPA mostró resultados más cercanos a los observados, con valores promedios de 398 mm (EFM) y 327 mm (OND). Por otra parte, la precipitación acumulada en las estaciones de superficie resultó menor en AMJ y JAS, para los cuales corresponden valores de 166 y 162 mm. Durante estos trimestres, en el oeste de la región los tres PPS muestran una subestimación de la precipitación, mientras que en el este tienden a sobrestimar. Específicamente en JAS, los productos CMORPH y TMPA subestimaron la precipitación con valores medios de 146 y 135 mm, respectivamente; a su vez, en AMJ, el único producto que subestima es el CMORPH, para el cual se obtuvo un promedio de 163 mm.

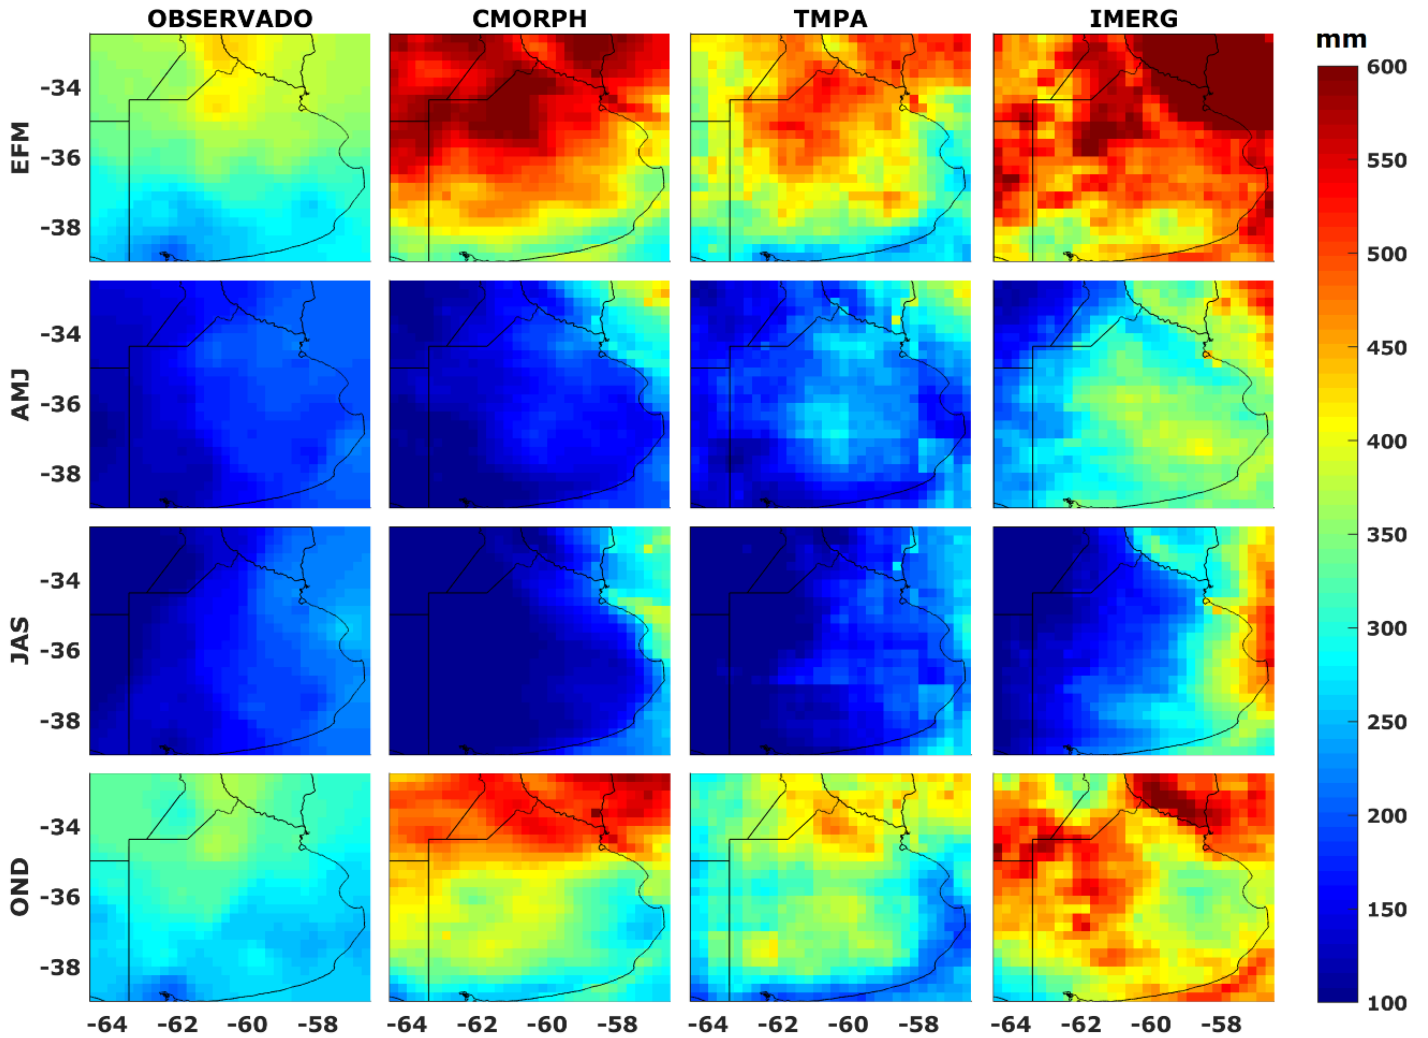


Figura 7. Distribución espacial de la precipitación promedio trimestral en mm. Periodo 2001-2017.

Evaluación de PPS

Nivel diario: punto vs. píxel

Los coeficientes estadísticos POD, FAR, BIAS y ETS (Tabla 1) muestran que los PPS capturan las observaciones para intensidades bajas (hasta 5 mm) y medias (entre 5 y 20 mm). Mientras que para intensidades altas (mayores a 20 mm), el BIAS es superior a 1 para todos los PPS, lo que indica una sobrestimación en este tipo de eventos, siendo el TMPA el que representa mejor a las tormentas intensas en la región. También se observa que el IMERG sobrestima de modo considerable el número de eventos de precipitación respecto a los otros dos productos, esto es evidente con una alta POD y FAR. En cuanto a la relación entre el número de falsas alarmas y la cantidad de eventos de precipitación estimada y a la fracción de precipitación estimada de forma correcta, el producto CMORPH fue el que presentó mejores resultados, como lo indican el índice FAR y ETS, respectivamente (Figura 8).




Figura 8. Gráfico de POD, FAR, BIAS y ETS en función de los umbrales de precipitación diaria. Periodo 2001-2017.

El impacto de la corrección del sesgo en los datos de PPS se evaluó con las cuatro métricas estadísticas descriptivas presentadas en la Tabla 2. En cada estadístico se utilizaron diagramas de cajas para comparar similitudes en términos de simetría, dispersión y para determinar la existencia de valores extremos entre la distribución de los valores de las estimaciones y la distribución de los datos observados. Los resultados indican que el método de remoción del sesgo ha incrementado de forma satisfactoria el ajuste entre PPS y las observaciones en superficie, como se evidencia con la reducción del BIAS, RMSE, y en el aumento de NSE y R (Figura 9).

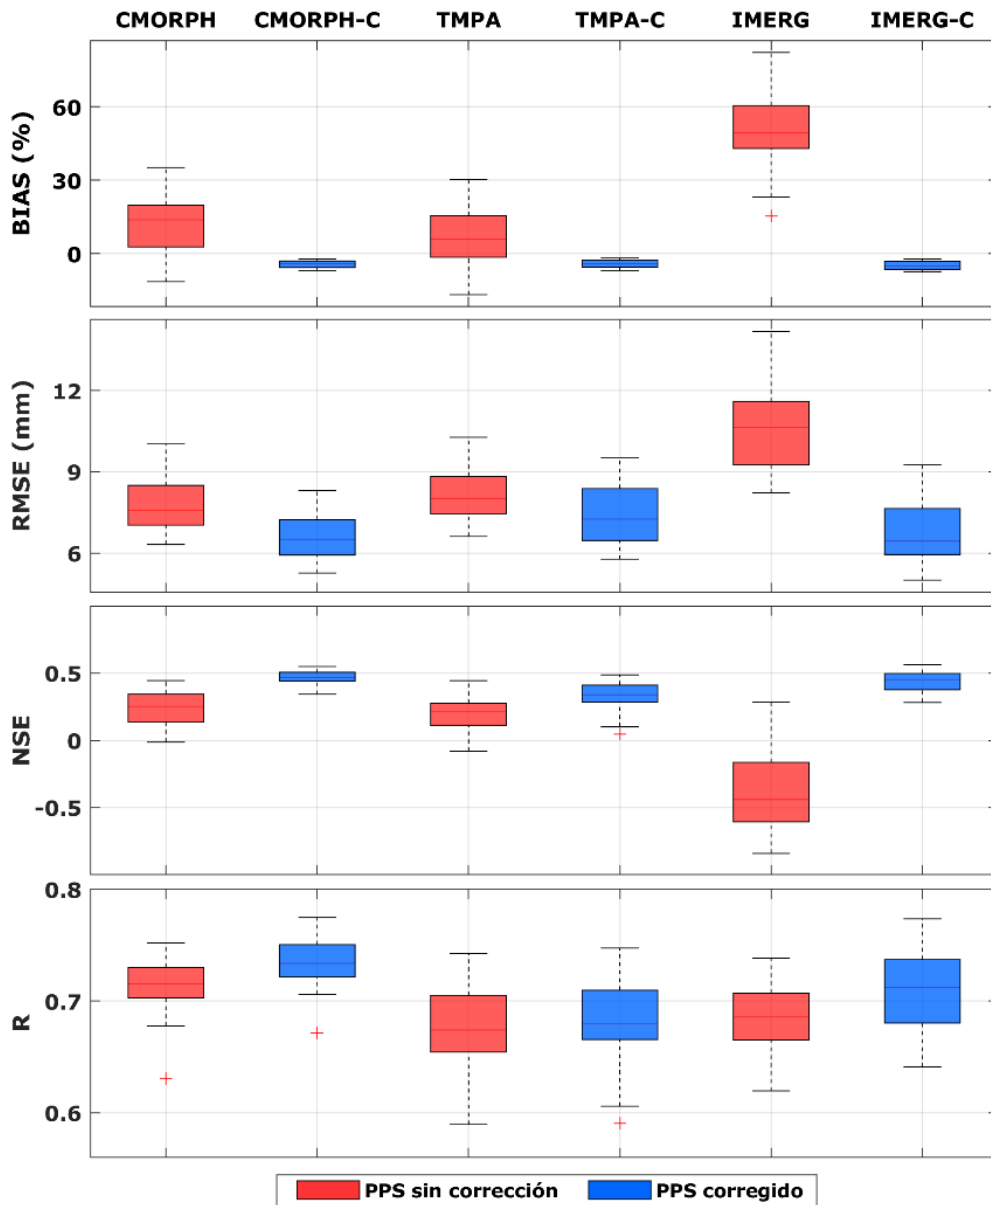


Figura 9. Diagrama de cajas de los coeficientes estadísticos descriptivos calculados para las precipitaciones diarias. Periodo 2001-2017.

En el caso del BIAS, se observa que todos los PPS sin corregir presentan valores positivos mayores al 6 %, destacando al IMERG con un mayor grado de sobrestimación de la precipitación de 53 %; por otra parte, todos los PPS corregidos arrojaron valores del BIAS similares, en todos los casos cercanos a cero. Analizando los resultados del RMSE, se encontró que el producto CMORPH corregido (CMORPH-C) muestra el menor error medio cuadrático total y es similar al IMERG corregido (IMERG-C), en ambos casos con valores medios cercanos a 6.5 mm, mientras que el TMPA corregido (TMPA-C) presenta un valor medio cercano a 7.3 mm. Luego de realizar la corrección del sesgo, se observa una mejora significativa del NSE del producto IMERG, mientras que el CMORPH y el TMPA mejoran este estadístico en menor medida; en dicho caso, los productos corregidos proporcionan valores de NSE más cercanos a 1, siendo el producto CMORPH-C el que tiene mayor habilidad predictiva. La magnitud del R en todos los PPS sin corregir mostraron valores cercanos a 0.7; luego de ser corregidos, los productos tienen un mejor ajuste respecto a los datos observados, siendo el producto CMORPH-C el que presenta mayor correlación. En general, el producto CMORPH-C muestra un mejor ajuste con las observaciones al compararlo con el TMPA-C y el IMERG-C.

Los estadísticos descriptivos para las diferentes épocas del año se muestran en los diagramas de cajas de la Figura 10. En el caso del BIAS, y analizando en primer lugar los productos sin corregir, se observa para

el CMORPH que los trimestres de EFM y OND (periodo cálido con mayor cantidad de precipitación) presentan un sesgo positivo mayor a 28 % en promedio para las 29 estaciones, mientras que los trimestres de AMJ y JAS (periodo frío con menor cantidad de precipitación) tienen un sesgo negativo en promedio de 15 y 28 %, respectivamente. El TMPA presenta sesgo negativo (15 %) durante el trimestre de JAS, mientras que el IMERG presenta un sesgo positivo para todos los trimestres del año, variando entre 31 % en JAS y 76 % en AMJ, lo que indica una sobrestimación en los valores de precipitación. En cuanto al comportamiento del BIAS de los PPS corregidos, mostraron valores cercanos a cero en todos los trimestres.




Figura 10. Diagrama de cajas de los coeficientes estadísticos descriptivos calculados para la precipitación trimestral. Periodo 2001-2017.

Al analizar los resultados del RMSE, se observa que en los trimestres de EFM, AMJ y OND, el producto que presenta el menor error es el CMORPH-C, con valores promedios diarios de 8.1, 5.4 y 7 mm, respectivamente, mientras que para los meses de JAS, el producto IMERG-C es el que muestra mejor ajuste con un promedio de 4.6 mm. En el caso del NSE para cada trimestre, se observó que en todos los casos los PPS corregidos mejoran su ajuste; se repite el comportamiento de los resultados del RMSE donde el producto CMORPH-C representa mejor los trimestres con mayor precipitación (EFM, AMJ y OND), con valores cercanos a 0.5; mientras que el producto IMERG-C es el que mejor captura la precipitación observada para el trimestre de JAS, con un promedio de 0.55. Finalmente, el R muestra valores similares en todos los PPS y al ser corregidos mejoran alrededor del 2 %. Sin embargo, se observan valores coherentes a los estadísticos RMSE y NSE, ya que al igual que ellos, el producto IMERG-C presenta el mayor índice de correlación en el trimestre JAS, mientras que el CMORPH-C presenta un mejor ajuste para el resto de los trimestres.

Nivel mensual: píxel vs. píxel



La distribución espacial de los distintos estadísticos se realizó con datos de precipitación a nivel mensual. Para ellos, los datos de precipitación observada han sido interpolados a la misma resolución espacial de los PPS para poder realizar la evaluación píxel por píxel. La Figura 11 muestra la distribución espacial del BIAS para el periodo 2001-2017. En el trimestre EFM, donde se registra la mayor cantidad de precipitación, se aprecia un BIAS positivo en la mayor parte de la región, siendo el producto IMERG el que mayor sobrestimación presenta, con un promedio de 60 %, mientras que los productos CMORPH y TMPA sobrestiman las observaciones en promedio para la región pampeana, en un 47 y un 20 %, respectivamente.




Figura 11. BIAS en porcentaje correspondiente a los trimestres EFM, AMJ, JAS y OND. Periodo 2001-2017.

El trimestre AMJ muestra un BIAS negativo de 4 % para el producto CMORPH y positivos de 21 y 84 % para los productos TMPA e IMERG,

respectivamente. Durante el trimestre JAS, los productos CMORPH y TMPA presentaron BIAS negativos con valores de 20 y 12 %, respectivamente. Para el producto IMERG, se observa que en el oeste de la región presenta valores negativos, sin embargo, el promedio para toda el área muestra un BIAS positivo de 32 %. En el trimestre OND, al igual que en el trimestre EFM se aprecia un BIAS positivo en los tres PPS, siendo el producto IMERG el que mayor sobrestimación presenta con un promedio de 49 %; los productos CMORPH y TMPA sobrestiman las observaciones, en un 37 y 11 %, respectivamente.

Después de haber calculado la magnitud del sesgo para cada estación (Figura 11), se procedió a removerlo usando el método QM. La Figura 12 muestra el R entre los datos observados, y los PPS antes y después de la corrección del sesgo para los diferentes trimestres analizados. Se observa que el producto CMORPH-C tiene un mejor desempeño en los trimestres de EFM y AMJ, con valor promedio de 0.7 y 0.8, respectivamente, seguido del producto IMERG-C, con valores de 0.69 y 0.79, respectivamente. En cuanto a los trimestres JAS y OND, el producto IMERG-C es el que presenta mejores resultados, con valores de 0.75 y 0.73, respectivamente, seguido por el producto CMORPH-C, con 0.74 en JAS y 0.70 en OND. Por otra parte, en todos los casos, el producto TMPA-C presentó las correlaciones más bajas al compararlos con los productos CMORPH-C e IMERG-C.

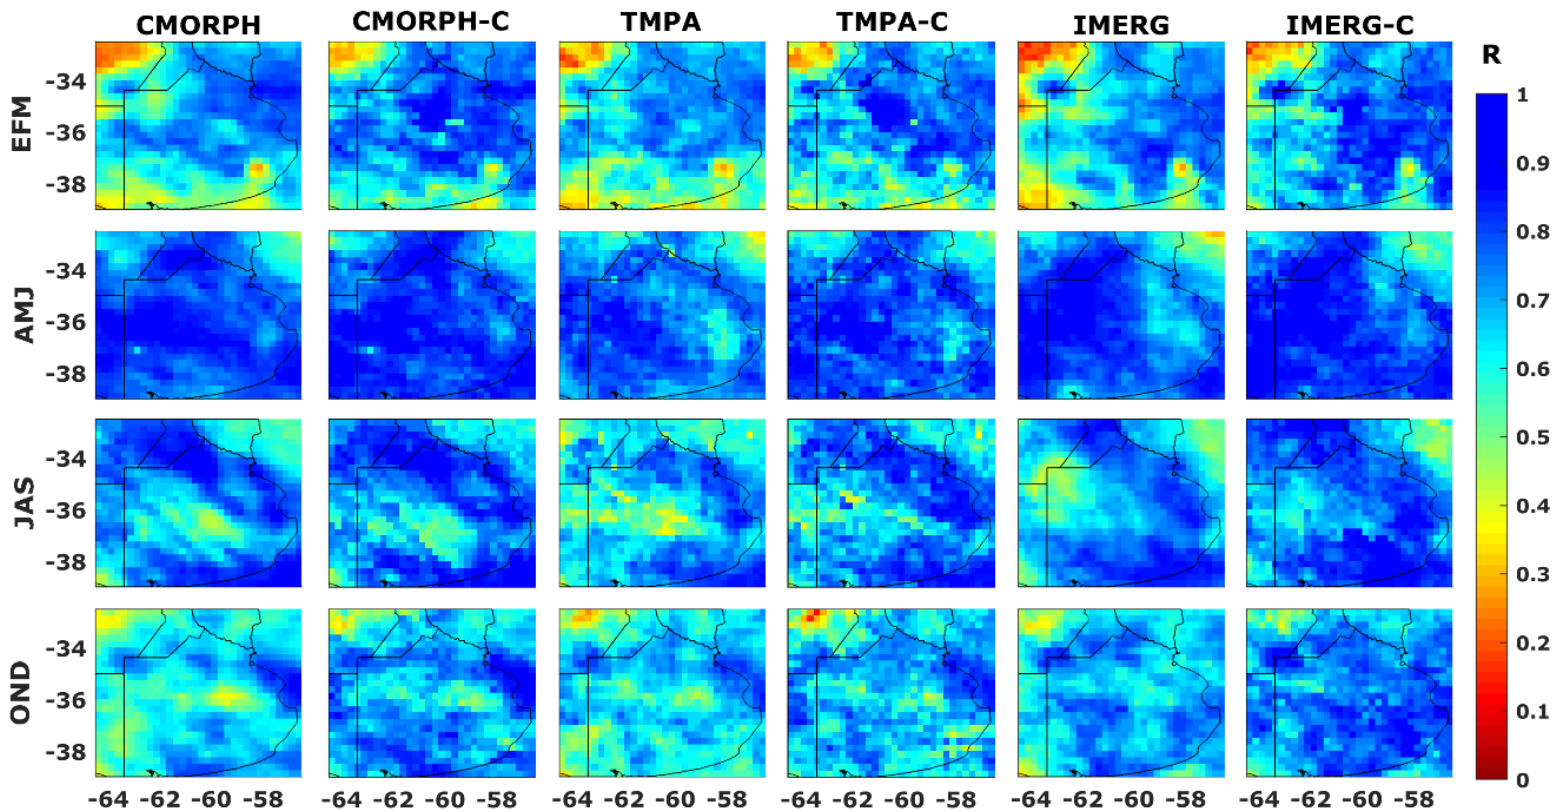


Figura 12. R correspondiente a los trimestres EFM, AMJ, JAS y OND. Periodo 2001-2017.

En general, los datos trimestrales de precipitación sin corregir de los tres PPS mostraron buen ajuste al compararlos con los datos observados; los valores de R promedio varían entre 0.62 y 0.78. Los mejores ajustes se obtuvieron para los PPS corregidos con R promedio que oscila entre 0.67 y 0.80. Esto indica un aumento en la correlación entre 4 y 5 % en promedio para la región de estudio.

Al analizar los resultados para el RMSE (Figura 13), se observa que todos los PPS corregidos presentan menor error al compararlos con los PPS sin corregir. En general, el producto que presenta menor error promedio para la región es el IMERG-C, con un valor promedio mensual de 35 mm; luego el CMORPH-C, con un error de 36 mm, y por último el TMPA-C, con 37 mm. Los errores obtenidos siguen el mismo patrón con las relaciones encontradas a partir del R, donde el producto CMORPH-C presentó los errores más bajos en los trimestres de EFM con 42 mm y AMJ con 27 mm, mientras que los trimestres de JAS y OND mostraron errores más bajos en el producto IMERG-C con 29 mm y 39 mm, respectivamente.




Figura 13. RMSE correspondiente a los trimestres EFM, AMJ, JAS y OND. Periodo 2001-2017.

Discusión

En el año 1997 fue lanzado el satélite TRMM, el cual estaba diseñado específicamente para monitorear y estudiar precipitaciones tropicales y subtropicales; desde entonces, profesionales y científicos han estado evaluando el desempeño de las estimaciones de precipitación obtenidas por el satélite mediante diferentes algoritmos (Huffman *et al.*, 2007; Huffman *et al.*, 2014; Joyce *et al.*, 2004). Estos productos se encuentran en diversas versiones, aquellos obtenidos en tiempo casi real y los obtenidos a posteriori (versión final). Los primeros se adquieren con un retraso entre 4 y 24 horas, y debido a la inmediatez en la obtención de los datos, estos productos no están calibrados con precipitaciones en superficie. Los segundos están disponibles en diferentes periodos, que varían dependiendo del tiempo de calibración de los mismos, en algunos casos se obtienen 2 o 3 meses después del mes de la observación y son corregidos con datos de precipitación global; por ejemplo, el producto IMERG en su versión final realiza la corrección con el análisis del medidor de precipitación del *Global Precipitation Climatology Center* (GPCC) (Huffman *et al.*, 2014).

A fin de verificar las similitudes y/o diferencias entre los PPS corregidos con datos regionales y los PPS en su versión final calibrada con datos globales, se compararon los resultados obtenidos en este estudio

con los hallazgos de trabajos previos (Tabla 3). Se seleccionaron aquellos donde el área de estudio se encontraba en Sudamérica con una escala temporal diaria en diferentes periodos de tiempo. En general, se encontró que los tres PPS tienen buena correlación en la mayor parte de Sudamérica con excepción de aquellos evaluados en cuencas con topografía compleja (Baez-Villanueva *et al.*, 2018; Hobouchian *et al.*, 2017), esto posiblemente se deba a la falta de observaciones de pluviómetros en las regiones montañosas.

Tabla 3. Comparación de los PPS en tiempo casi real corregidos en este trabajo con los PPS en su versión final de otros estudios realizados a escala diaria en Sudamérica.

Referencia	Área de estudio	Periodo	CMORPH		TMPA		IMERG	
			R	RMSE (mm/día)	R	RMSE (mm/día)	R	RMSE (mm/día)
Este trabajo	Región pampeana argentina	De 01/01/2001 a 31/12/2017	0.73	6.6	0.68	7.4	0.73	6.7
Salio <i>et al.</i> (2015)	Sudamérica	De 01/12/2008 a 30/11/2010	0.63	-	0.82	-	-	-
Baez-Villanueva <i>et al.</i> (2018)	Colombia (cuenca Magdalena)	De 01/01/2001 a 31/12/2014	0.33	8.8	0.57	9.0	-	-
Oreggioni-Weiberlen y Báez-Benítez (2018)	Paraguay	De 1998 a 2012	0.45 a 0.77	9.0 a 12.0	0.59 a 0.77	7.0 a 11.0	-	-
Hobouchian <i>et al.</i> (2017)	Chile-Argentina (Andes subtropicales)	De 01/01/2004 a 31/12/2010	0.26	-	0.33	-	-	-
Palomino-Ángel, Anaya-Acevedo y Botero (2019)	Colombia (Chocó biogeográfico)	De 2014 a 2017	-	-	0.31	15.5	0.41	14.6
Nascimento <i>et al.</i> (2021)	Brasil (estado de Paraná)	De 06/2000 a 12/2018	-	-	-	-	0.44	11.3 a 14.8

Al evaluar los resultados del coeficiente de correlación de los PPS, se destaca que tanto para el CMORPH como el IMERG, la mayor similitud

es la obtenida en la evaluación realizada en este estudio; para el caso del TMPA, el mejor resultado lo obtuvieron Salio *et al.* (2015) con un R de 0.82; sin embargo, es necesario mencionar que éste considera solo dos años de registros en comparación con los 17 años usados en este análisis.

Por otra parte, los tres PPS corregidos en este trabajo obtuvieron errores más bajos con un RMSE que varía entre 6.6 y 7.4 mm/día, en comparación con los resultados de otros autores mostrados en la Tabla 3. Ello podría estar relacionado con la cantidad de estaciones usadas en este estudio, donde la corrección se realizó utilizando 29 estaciones en superficie, mientras que los productos de precipitación global usados para corregir los PPS en su versión final posiblemente utilicen menor densidad de estaciones, lo que podría traer como consecuencia una precipitación sesgada.

Este estudio demuestra que la aplicación del método de corrección de sesgo QM mejora el rendimiento de los PPS para capturar la precipitación en la región. Además, permite obtener un producto en tiempo casi real a diferencia de los productos en su versión final que tienen demora de más de un mes. Asimismo, se confirma la necesidad de realizar una evaluación específica en cada región donde se requiera seleccionar un PPS.

Conclusiones

La disponibilidad actual de la precipitación obtenida a través de sensores remotos presentó la oportunidad de evaluar la confiabilidad de tres PPS (IMERG, TMPA y CMORPH) en su versión en tiempo casi real, usando como referencia 29 estaciones pluviométricas distribuidas en la región pampeana ubicada en el sureste de Argentina. Con la aplicación de estadísticos categóricos y descriptivos se demostró que estos productos tienden a sobrestimar la cantidad de precipitación a nivel diario en la región.

El análisis realizado muestra que el producto IMERG tiene mejor capacidad para detectar la precipitación, sin embargo presenta mayor número de falsas alarmas y sesgo. Mientras, el producto CMORPH representa mejor la fracción de eventos observados que se estimaron correctamente y muestra valores de BIAS más bajos para intensidades altas. Por último, el producto TMPA es el que resulta menos adecuado para detectar la precipitación en la región.

La incorporación de un método de remoción del sesgo en los PPS, como el *Quantile Mapping*, introdujo mejoras significativas en los estadísticos evaluados. En especial, el producto CMORPH superó su capacidad para detectar la precipitación al compararlo con el IMERG.

Luego de la corrección de los PPS mejoran su correlación mensual entre 4 y 5 %, mientras que la correlación diaria aumenta alrededor del 2 %. La corrección del sesgo lograda mejoró la calidad de los PPS, y en consecuencia su uso tiene una influencia positiva sobre diferentes aplicaciones hidrometeorológicas.

La habilidad a nivel trimestral de los PPS respecto a las estaciones en superficie demostró que luego de la corrección del sesgo, el producto CMORPH muestra mejores resultados para representar la precipitación en todos los trimestres, excepto el trimestre JAS, donde el producto IMERG capturó mejor la precipitación. En general, el TMPA tuvo el desempeño menos favorable entre los PPS evaluados.

El análisis de la distribución espacial de la precipitación mensual de los datos observados permitió evaluar el comportamiento de los PPS en toda la región de estudio. A pesar de que la media espacial fue similar entre los productos, la confiabilidad de los PPS varía ampliamente dentro de la región de estudio. Esto demuestra la importancia de poder validar y corregir los PPS con datos de superficie provenientes de una red de observaciones lo suficientemente densa como para capturar la variabilidad espacial de la precipitación. Los productos CMORPH e IMERG mostraron desempeños muy similares. Los trimestres de EFM y OND, donde la mayoría de los eventos provienen de fenómenos convectivos y que coincide con los trimestres de mayor cantidad de precipitación, presentaron mayor RMSE con un valor promedio para la región de 43 mm en el trimestre EFM y 27 mm en OND. Por otra parte, en los trimestres

AMJ y JAS, donde sólo ocurre el 25 % de las precipitaciones y la mayoría son de origen estratiforme, ocurren los menores RMSE, con un valor aproximado para la región de 28 mm.

Si bien estos productos satelitales han mejorado de modo significativo su resolución espacial y temporal con respecto a versiones anteriores, es necesario profundizar la evaluación de estas estimaciones, y continuar con la instalación de estaciones en superficie que permitan tener un monitoreo adecuado de la precipitación. Este estudio podría servir de referencia para los investigadores que deseen aplicar o evaluar los PPS en tiempo casi real para ser usados en aplicaciones hidrológicas como pronósticos de caudal para sistemas de alerta de inundaciones en la región.

Agradecimientos

Los autores agradecen a la Comisión de Investigaciones Científicas de la Provincia de Buenos Aires (CIC) y al Servicio Meteorológico Nacional de Argentina por proveer los datos de las estaciones meteorológicas; así como a la ingeniera Ninoska Briceño, por su invaluable contribución en la discusión de resultados preliminares.

Referencias

Aliaga, V. S., Ferrelli, F., & Piccolo, M. C. (2017). Regionalization of climate over the Argentine Pampas. *International Journal of*



- Climatology*, 37(S1), 1237-1247. Recuperado de <https://doi.org/https://doi.org/10.1002/joc.5079>
- Aragón, R., Jobbágy, E. G., & Viglizzo, E. F. (2011). Surface and groundwater dynamics in the sedimentary plains of the Western Pampas (Argentina). *Ecohydrology*, 4(3), 433-447. Recuperado de <https://doi.org/https://doi.org/10.1002/eco.149>
- Aslami, F., Ghorbani, A., Sobhani, B., & Esmali, A. (2019). Comprehensive comparison of daily IMERG and GSMaP satellite precipitation products in Ardabil Province, Iran. *International Journal of Remote Sensing*, 40(8), 3139-3153. Recuperado de <https://doi.org/10.1080/01431161.2018.1539274>
- Baez-Villanueva, O. M., Zambrano-Bigiarini, M., Ribbe, L., Nauditt, A., Giraldo-Osorio, J. D., & Thinh, N. X. (2018). Temporal and spatial evaluation of satellite rainfall estimates over different regions in Latin-America. *Atmospheric Research*, 213, 34-50. Recuperado de <https://doi.org/https://doi.org/10.1016/j.atmosres.2018.05.011>
- Basheer, M., & Elagib, N. A. (2019). Performance of satellite-based and GPCP 7.0 rainfall products in an extremely data-scarce country in the Nile Basin. *Atmospheric Research*, 215, 128-140. Recuperado de <https://doi.org/https://doi.org/10.1016/j.atmosres.2018.08.028>
- Borges, P. de A., Franke, J., Da-Anunciação, Y. M. T., Weiss, H., & Bernhofer, C. (2016). Comparison of spatial interpolation methods for the estimation of precipitation distribution in Distrito Federal,

- Brazil. *Theoretical and Applied Climatology*, 123(1-2), 335-348.
Recuperado de <https://doi.org/10.1007/s00704-014-1359-9>
- Campozano, L., Sánchez, E., Avilés, Á., & Samaniego, E. (2014). Evaluation of infilling methods for time series of daily precipitation and temperature: The case of the Ecuadorian Andes. *Maskana*, 5(1 SE-Artículos científicos), 99-115. Recuperado de <https://doi.org/10.18537/mskn.05.01.07>
- Cisneros-Iturbe, H. L., Bouvier, C., & Domínguez-Mora, R. (2001). Aplicación del método kriging en la construcción de campos de tormenta en la ciudad de México. *Ingeniería Hidráulica en México*, 16(3), 5-14.
- Dinku, T., Ruiz, F., Connor, S. J., & Ceccato, P. (2010). Validation and intercomparison of satellite rainfall estimates over Colombia. *Journal of Applied Meteorology and Climatology*, 49(5), 1004-1014. Recuperado de <https://doi.org/10.1175/2009JAMC2260.1>
- Ebert, E. E., Janowiak, J. E., & Kidd, C. (2007). Comparison of near-real-time precipitation estimates from satellite observations and numerical models. *Bulletin of the American Meteorological Society*, 88(1), 47-64. Recuperado de <https://doi.org/10.1175/BAMS-88-1-47>.
- Fang, G. H., Yang, J., Chen, Y. N., & Zammit, C. (2015). Comparing bias correction methods in downscaling meteorological variables for a hydrologic impact study in an arid area in China. *Hydrology and*

- Earth System Sciences*, 19(6), 2547-2559. Recuperado de <https://doi.org/10.5194/hess-19-2547-2015>
- Fuschini-Mejía, M. C. (1994). *El agua en las llanuras*. Montevideo, Uruguay: Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura/ Oficina Regional de Ciencia y Tecnología para América Latina y el Caribe (UNESCO/ORCYT).
- Gella, G. W. (2019). Statistical evaluation of high resolution satellite precipitation products in arid and semi-arid parts of Ethiopia: A note for hydro-meteorological applications. *Water and Environment Journal*, 33(1), 86-97. Recuperado de <https://doi.org/https://doi.org/10.1111/wej.12380>
- Guevara-Ochoa, C., Briceño, N., Zimmermann, E., Vives, L., Blanco, M., Cazenave, G., & Ares, G. (2017). Relleno de series de precipitación diaria para largos periodos de tiempo en zonas de llanura. Caso de estudio cuenca superior del arroyo del azul. *Geoacta (Argentina)*, 42(1), 38-60.
- Heo, J. H., Ahn, H., Shin, J. Y., Kjeldsen, T. R., & Jeong, C. (2019). Probability distributions for a quantile mapping technique for a bias correction of precipitation data: A case study to precipitation data under climate change. *Water (Switzerland)*, 11(7), 1475. Recuperado de <https://doi.org/10.3390/w11071475>
- Hobouchian, M. P., Salio, P., García-Skabar, Y., Vila, D., & Garreaud, R. (2017). Assessment of satellite precipitation estimates over the slopes of the subtropical Andes. *Atmospheric Research*, 190, 43-54.

- Recuperado de
<https://doi.org/https://doi.org/10.1016/j.atmosres.2017.02.006>
- Hong, Y., Hsu, K., Moradkhani, H., & Sorooshian, S. (2006). Uncertainty quantification of satellite precipitation estimation and Monte Carlo assessment of the error propagation into hydrologic response. *Water Resources Research*, 42(8), W08421. Recuperado de <https://doi.org/https://doi.org/10.1029/2005WR004398>
- Hossain, F., & Anagnostou, E. N. (2004). Assessment of current passive-microwave- and infrared-based satellite rainfall remote sensing for flood prediction. *Journal of Geophysical Research: Atmospheres*, 109, D07102. Recuperado de <https://doi.org/https://doi.org/10.1029/2003JD003986>
- Hossain, F., & Anagnostou, E. N. (2006). A two-dimensional satellite rainfall error model. *IEEE Transactions on Geoscience and Remote Sensing*, 44(6), 1511-1522. Recuperado de <https://doi.org/10.1109/TGRS.2005.863866>
- Huffman, G. J., Adler, R. F., Bolvin, D. T., Gu, G., Nelkin, E. J., Bowman, K. P., Hong, Y., Stocker, E. F., & Wolff, D. B. (2007). The TRMM Multisatellite Precipitation Analysis (TMPA): Quasi-global, multiyear, combined-sensor precipitation estimates at fine scales. *Journal of Hydrometeorology*, 8(1), 38-55. Recuperado de <https://doi.org/10.1175/JHM560.1>
- Huffman, G. J., Bolvin, D. T., Braithwaite, D., Hsu, K., Joyce, R., Kidd, C., Nelkin, E. J., Sorooshian, S., Tan, J., & Xie, P. (March, 2019). NASA

- Global Precipitation Measurement (GPM) Integrated Multi-satellitE Retrievals for GPM (IMERG). *Algorithm Theoretical Basis Document (ATBD) Version 06*. Clear Lake, USA: National Aeronautics and Space Administration (NASA). Recuperado de https://pmm.nasa.gov/sites/default/files/document_files/IMERG_ATBD_V06.pdf
- Huffman, G. J., Bolvin, D. T., Braithwaite, D., Hsu, K., Joyce, R., & Xie, P. (2014). NASA Global Precipitation Measurement (GPM) Integrated Multi-satellitE Retrievals for GPM (IMERG). *Algorithm Theoretical Basis Document (ATBD) Version 4.4*. Clear Lake, USA: National Aeronautics and Space Administration (NASA). Recuperado de https://pmm.nasa.gov/sites/default/files/document_files/IMERG_ATBD_%0AV4.4.pdf.
- Iida, Y., Kubota, T., Iguchi, T., & Oki, R. (2010). Evaluating sampling error in TRMM/PR rainfall products by the bootstrap method: Estimation of the sampling error and its application to a trend analysis. *Journal of Geophysical Research: Atmospheres*, 115, D22119. Recuperado de <https://doi.org/https://doi.org/10.1029/2010JD014257>
- Ines, A. V. M., & Hansen, J. W. (2006). Bias correction of daily GCM rainfall for crop simulation studies. *Agricultural and Forest Meteorology*, 138(1-4), 44-53. Recuperado de <https://doi.org/10.1016/j.agrformet.2006.03.009>
- Joyce, R. J., Janowiak, J. E., Arkin, P. A., & Xie, P. (2004). CMORPH: A method that produces global precipitation estimates from passive

- microwave and infrared data at high spatial and temporal resolution. *Journal of Hydrometeorology*, 5(3), 487-503. Recuperado de [https://doi.org/10.1175/1525-7541\(2004\)005<0487:CAMTPG>2.0.CO;2](https://doi.org/10.1175/1525-7541(2004)005<0487:CAMTPG>2.0.CO;2)
- Kim, J., & Ryu, J. H. (2016). A heuristic gap filling method for daily precipitation series. *Water Resources Management*, 30(7), 2275-2294. Recuperado de <https://doi.org/10.1007/s11269-016-1284-z>
- Luo, M., Liu, T., Meng, F., Duan, Y., Frankl, A., Bao, A., & De-Maeyer, P. (2018). Comparing bias correction methods used in downscaling precipitation and temperature from regional climate models: A case study from the Kaidu River Basin in Western China. *Water (Switzerland)*, 10(8), 1-21. Recuperado de <https://doi.org/10.3390/w10081046>
- Maggioni, V., & Massari, C. (2018). On the performance of satellite precipitation products in riverine flood modeling: A review. *Journal of Hydrology*, 558, 214-224. Recuperado de <https://doi.org/https://doi.org/10.1016/j.jhydrol.2018.01.039>
- Magrin, G. O., Travasso, M. I., López, G. M., Rodríguez, G. R., & Lloveras, A. R. (2007). Vulnerabilidad de la producción agrícola en la región pampeana argentina. In: *Componente B3 de la 2da Comunicación Nacional de Cambio Climático*. Recuperado de http://climayagua.inta.gob.ar/sites/default/files/cambiocli/Vulnerabilidad_Produccion_Agricola_Region_Pampeana.pdf

- Melo, D. de C. D., Xavier, A. C., Bianchi, T., Oliveira, P. T. S., Scanlon, B. R., Lucas, M. C., & Wendland, E. (2015). Performance evaluation of rainfall estimates by TRMM Multi-satellite Precipitation Analysis 3B42V6 and V7 over Brazil. *Journal of Geophysical Research: Atmospheres*, 120(18), 9426-9436. Recuperado de <https://doi.org/https://doi.org/10.1002/2015JD023797>
- Nascimento, J. G., Althoff, D., Bazame, H. C., Neale, C. M. U., Duarte, S. N., Ruhoff, A. L., & Gonçalves, I. Z. (2021). Evaluating the latest imerg products in a subtropical climate: The case of paraná state, brazil. *Remote Sensing*, 13(5), 1-20. Recuperado de <https://doi.org/10.3390/rs13050906>
- Oreggioni-Weiberlen, F., & Báez-Benítez, J. (2018). Assessment of satellite-based precipitation estimates over Paraguay. *Acta Geophysica*, 66(3), 369-379. Recuperado de <https://doi.org/10.1007/s11600-018-0146-x>
- Palharini, R. S., Vila, D. A., Rodrigues, D. T., Quispe, D. P., Palharini, R. C., de Siqueira, R. A., & de Sousa Afonso, J. M. (2020). Assessment of the extreme precipitation by satellite estimates over South America. *Remote Sensing*, 12(13), 2085. Recuperado de <https://doi.org/10.3390/rs12132085>
- Palomino-Ángel, S., Anaya-Acevedo, J. A., & Botero, B. A. (2019). Evaluation of 3B42V7 and IMERG daily-precipitation products for a very high-precipitation region in northwestern South America.

- Atmospheric Research*, 217, 37-48. Recuperado de <https://doi.org/10.1016/j.atmosres.2018.10.012>
- Salio, P., Hobouchian, M. P., García-Skabar, Y., & Vila, D. (2015). Evaluation of high-resolution satellite precipitation estimates over southern South America using a dense rain gauge network. *Atmospheric Research*, 163, 146-161. Recuperado de <https://doi.org/https://doi.org/10.1016/j.atmosres.2014.11.017>
- Tan, M. L., & Duan, Z. (2017). Assessment of GPM and TRMM Precipitation Products over Singapore. *Remote Sensing*, 9(7), 720. Recuperado de <https://doi.org/10.3390/rs9070720>
- Tan, M. L., & Santo, H. (2018). Comparison of GPM IMERG, TMPA 3B42 and PERSIANN-CDR satellite precipitation products over Malaysia. *Atmospheric Research*, 202, 63-76. Recuperado de <https://doi.org/https://doi.org/10.1016/j.atmosres.2017.11.006>
- Tang, L., & Hossain, F. (2009). Transfer of satellite rainfall error from gaged to ungaged locations: How realistic will it be for the Global Precipitation Mission? *Geophysical Research Letters*, 36(10), L10405. Recuperado de <https://doi.org/https://doi.org/10.1029/2009GL037965>
- Tang, L., Hossain, F., & Huffman, G. J. (2010). Transfer of satellite rainfall uncertainty from gauged to ungauged regions at regional and seasonal time scales. *Journal of Hydrometeorology*, 11(6), 1263-1274. Recuperado de <https://doi.org/10.1175/2010JHM1296.1>

- Thiemeßl, M. J., Gobiet, A., & Heinrich, G. (2012). Empirical-statistical downscaling and error correction of regional climate models and its impact on the climate change signal. *Climatic Change*, 112(2), 449-468. Recuperado de <https://doi.org/10.1007/s10584-011-0224-4>
- Villarini, G., Mandapaka, P. V., Krajewski, W. F., & Moore, R. J. (2008). Rainfall and sampling uncertainties: A rain gauge perspective. *Journal of Geophysical Research Atmospheres*, 113(11), D11102. Recuperado de <https://doi.org/10.1029/2007JD009214>
- Yilmaz, K. K., Hogue, T. S., Hsu, K., Sorooshian, S., Gupta, H. V, & Wagener, T. (2005). Intercomparison of rain gauge, radar, and satellite-based precipitation estimates with emphasis on hydrologic forecasting. *Journal of Hydrometeorology*, 6(4), 497-517. Recuperado de <https://doi.org/10.1175/JHM431.1>
- Zambrano-Bigiarini, M., Nauditt, A., Birkel, C., Verbist, K., & Ribbe, L. (2017). Temporal and spatial evaluation of satellite-based rainfall estimates across the complex topographical and climatic gradients of Chile. *Hydrology and Earth System Sciences*, 21(2), 1295-1320. Recuperado de <https://doi.org/10.5194/hess-21-1295-2017>