

Validación de productos globales de análisis y reanálisis de precipitación para Bolivia (1987–2017) durante la estación lluviosa frente a Observaciones del SENAMHI

Validation of global precipitation analysis and reanalysis products for Bolivia (1987–2017) during the rainy season against SENAMHI observations as reference

Edgar Alejandro Tejerina Ramos^{1,*}, Marko J. Andrade Uzieda²

*Correo de correspondencia: 20190759@est.umss.edu

Resumen

En Bolivia, la escasez de estaciones meteorológicas, junto con su compleja topografía, limita la disponibilidad de información observacional. Por ello, este estudio evalúa la capacidad de los productos de precipitación para representar la precipitación mensual observada, mediante una validación estadística frente a registros puntuales en base a la precipitación diaria de 68 estaciones del Servicio Nacional de Meteorología e Hidrología (SENAMHI). Comparando seis productos Globales (ERA5, ERA5-Land, MERRA-2, JRA-3Q, NCEP/NCAR, NCEP/DOE) y un producto Global de interpolaciones de pluviómetros (GPCC), con el objetivo de determinar el mejor producto para estimar la precipitación mensual in situ para el periodo de lluvias de noviembre, diciembre, enero, febrero y marzo (NDEFM) de 1987 a 2017. Para la validación estadística se emplearon seis métricas estadísticas como la correlación de Pearson, el error cuadrático medio (RMSE), sesgo (Bias), el coeficiente de eficiencia de Nash-Sutcliffe (NSE), el índice de Kling-Gupta (KGE) y el Error Absoluto Medio (MAE), para evaluar el desempeño de los modelos en tres regiones fisiográficas: Altiplano, Valles y Llanos. Se realizó la distribución espacial para el mejor producto global por estación para las diferentes macro-regiones y su análisis para cada una de estas métricas resultando que MERRA-2 fue el modelo con mejor desempeño general, en las tres regiones del país seguido de GPCC especialmente en los llanos. Asimismo, ERA5 y ERA5-Land mostró un rendimiento favorable en algunas estaciones del altiplano y valles. Estos hallazgos validan el uso de productos globales y su potencial como alternativas a las observaciones locales, especialmente en regiones y zonas específicas. Útiles para aplicaciones hidrológicas y estudios referentes a la precipitación.

Palabras claves: precipitación mensual, validación climática, Bolivia, Andes Tropicales, productos de reanálisis.

Abstract

In Bolivia, the scarcity of meteorological stations, along with its complex topography, limits the availability of observational data. Therefore, this study evaluates the ability of precipitation products to represent observed monthly precipitation through statistical validation against point records based on daily precipitation from 68 stations of the National Meteorology and Hydrology Service (SENAMHI). Comparing six Global products (ERA5, ERA5-Land, MERRA-2, JRA-3Q, NCEP/NCAR, NCEP/DOE) and one Global rain gauge interpolation product (GPCC), with the objective of determining the best product to estimate in situ monthly precipitation for the November, December, January, February and March (NDEFM) rainy season from 1987 to 2017. For statistical validation, six statistical metrics were used, such as Pearson correlation, mean squared error (RMSE), bias, Nash-Sutcliffe efficiency coefficient (NSE), Kling-Gupta index (KGE) and Mean Absolute Error (MAE), to evaluate the performance of the models in three physiographic regions: Altiplano, Valleys and Plains. The spatial distribution of the best global product per station was performed for the different macro-regions, and its analysis for each of these metrics revealed that MERRA-2 was the model with the best overall performance in all three regions of the country, followed by GPCC, especially in the lowlands. Likewise, ERA5 and ERA5-Land showed favorable performance at some stations in the highlands and valleys. These findings validate the use of global products and their potential as alternatives to local observations, especially in specific regions and zones. They are useful for hydrological applications and precipitation studies.

Keywords: monthly precipitation, climate validation, Bolivia, Tropical Andes, reanalysis products.

1. Introducción

La representación precisa de los patrones espacio-temporales de precipitación es un insumo necesario para la gestión de recursos hídricos, la comprensión de la variabilidad climática y estudios referentes. (Espinoza, *et.al.*, 2010).

¹Departamento de Física, Facultad de Ciencias y Tecnología, Universidad Mayor de San Simón, Cochabamba, Bolivia. <https://orcid.org/0009-0009-0304-1821>

²Proyecto de Hidroclimatología, Departamento de Física, Facultad de Ciencias y Tecnología, Universidad Mayor de San Simón, Cochabamba, Bolivia. <https://orcid.org/0009-0001-7299-2534>

Sin embargo, la estimación de estos patrones derivada exclusivamente de observaciones terrestres suele presentar grandes incertidumbres en zonas con baja densidad de estaciones para superar estas limitaciones, se ha vuelto fundamental la validación de datos *in situ* con productos globales de precipitación, tales como modelos de circulación atmosférica y datos de reanálisis el uso de estos últimos especialmente para regiones con topografía compleja como la región andina, los cuales mejoran la estimación mensual mediante técnicas de fusión de datos y aprendizaje automático. (Rustemeier, *et.al.*, 2022).

Para mitigar estas restricciones estructurales, la comunidad científica internacional ha priorizado la evaluación y validación de bases de datos de cobertura global, tales como los productos de reanálisis atmosféricos y los data sets grillados observacionales interpolados. A diferencia de las observaciones directas de estaciones, los reanálisis climáticos asimilan de forma continua un volumen masivo de observaciones históricas (satelitales, de radiosondeo y de superficie) dentro de un modelo de circulación general físico y numérico consistente. Por su parte, los data sets de análisis observacional recurren a la interpolación rigurosa de registros en tierra. El uso adaptado de estas herramientas hidroclimáticas ha cobrado un papel fundamental en regiones con topografía accidentada como los Andes Tropicales, donde los gradientes de altitud alteran drásticamente la distribución de las lluvias a escalas micro y mesoclimáticas (Rustemeier, *et al.*, 2022).

De acuerdo con los estándares establecidos por la Organización Meteorológica Mundial (OMM), las investigaciones destinadas a validar bases de datos y productos climáticos grillados requieren el contraste formal con datos de referencia *in situ* sobre periodos climatológicos continuos de al menos 30 años (Gaitan & Biancari, 2024). En el territorio del Estado Plurinacional de Bolivia, este análisis demanda un enfoque diferenciado y regionalizado debido a que su compleja configuración geográfica divide al país en tres macro-regiones fisiográficas principales definidas por marcados umbrales altitudinales: el Altiplano, los Valles interandinos y los Llanos orientales (Montes de Oca, 1995).

En Perú, Imfeld *et al.* (2019) identificaron déficits críticos de precipitación en las tierras altas del sur empleando datos grillados y destacando la vulnerabilidad de las zonas altoandinas, mientras que Paredes Quispe (2024) evidenció limitaciones de resolución espacial al validar formalmente los modelos climáticos regionales del proyecto CORDEX en terrenos de topografía andina compleja. De forma análoga, en latitudes adyacentes, Gaitan y Biancari (2024) desarrollaron metodologías de corrección para bases de datos mensuales en la República Argentina con el fin de subsanar sesgos sistemáticos en zonas montañosas, y Santibáñez Gallegos (2024) demostró en Chile que la modelación de la disponibilidad hídrica futura depende críticamente de una validación y ajuste regional previo frente a las redes meteorológicas nacionales.

En Bolivia, la dinámica de la precipitación responde de forma diferenciada en cada piso ecológico. Mientras que el Altiplano exhibe un régimen semiárido de alta montaña altamente sensible al forzamiento de la radiación y a la variabilidad de los vientos del oeste, los Valles sufren de efectos de sombra de lluvia locales, y los Llanos están gobernados por el Sistema de Monzón Sudamericano y la incursión de humedad de la cuenca amazónica. El Servicio Nacional de Meteorología e Hidrología (SENAMHI) de Bolivia cumple un rol estratégico en la operación y mantenimiento de la red meteorológica oficial; sin embargo, las limitaciones presupuestarias e institucionales dificultan la densificación de estaciones en cuencas altas o regiones de difícil acceso, impulsando la exploración científica de fuentes alternativas robustas como los sensores remotos y los reanálisis globales (Salinas *et al.*, 2024). No obstante, para garantizar que un producto grillado sea climatológicamente representativo a escala sub-nacional, es mandatorio someterlo a un contraste cuantitativo estricto frente a las series observadas que hayan superado procesos analíticos rigurosos de control de calidad y homogeneización estadística (Andrade, *et al.*, 2021).

Considerando la oferta actual de datos hidroclimáticos espaciales, el presente estudio evalúa siete productos globales que presentan marcadas diferencias en sus resoluciones espaciales y sistemas de asimilación:

Tabla 1*Información de cada producto global analizado*

Nombre	Institución	Resolución Espacial	Temporal/unidades	Variable	Período disponible	Doi / referencia
ERA5	European Centre for Medium-Range Weather Forecasts (ECMWF)	$0.25^{\circ} \times 0.25^{\circ}$	diario-[m]	Total precipitation	1940–presente	10.24381/cds.f17050d7
ERA5-Land	ECMWF / Copernicus Climate Change Service (C3S)	$0.1^{\circ} \times 0.1^{\circ}$	diario-[m]	Total precipitation	1950–presente	10.24381/cds.e2161bac
GPCC	Deutscher Wetterdienst (DWD)	$1^{\circ} \times 1^{\circ}$	diaria-[mm]	precip	1891–presente	10.5676/DWD_GPCC/FD_M_V2022_250
JRA-3Q	Japan Meteorological Agency (JMA)	$0.25^{\circ} \times 0.25^{\circ}$	diaria-[$kg \cdot m^{-2} \cdot s^{-1}$]	tptrate1have-sfc-fc-gauss	1947–presente	10.5065/AVTZ-1H78
MERRA-2	NASA Global Modeling and Assimilation Office (GMAO)	$0.5^{\circ} \times 0.625^{\circ}$	diaria-[$kg \cdot m^{-2} \cdot s^{-1}$]	PRECTOTLA ND	1980–presente	10.5067/APIB0BA5PD2K
NCEP/NCAR	National Centers for Environmental Prediction (NCEP) / National Center for Atmospheric Research (NCAR)	$2.5^{\circ} \times 2.5^{\circ}$	diaria-[$kg \cdot m^{-2} \cdot s^{-1}$]	prate	1948–presente	10.1175/1520-0477(1996)077<0437:TNYRP>2.0.CO;2
NCEP/DOE	NCEP / U.S. Department of Energy (DOE)	$2.5^{\circ} \times 2.5^{\circ}$	diaria-[$kg \cdot m^{-2} \cdot s^{-1}$]	prate	1979–presente	10.1175/BAMS-83-11-1631

Dada la marcada estacionalidad climática de Bolivia, el núcleo de la actividad agrícola, la recarga de acuíferos y la ocurrencia de eventos hidrológicos extremos (desbordes, inundaciones y remociones en masa) se concentran fundamentalmente durante la temporada de lluvia. Dicho periodo se restringe de manera marcada a los meses de noviembre, diciembre, enero, febrero y marzo (NDEFM) (Espinoza, *et al.*, 2010; Imfeld, *et al.*, 2019). Por consiguiente, el objetivo general de este estudio consiste en evaluar el desempeño estadístico y la consistencia regional de estos siete productos globales en la estimación de la precipitación mensual acumulada durante el periodo lluvioso (NDEFM) de los años 1987 a 2017 frente a la red observacional del SENAMHI mediante seis métricas estadísticas, sirviendo como base científica para optimizar la toma de decisiones en la gestión del riesgo hídrico nacional.

2. Material y métodos

Metodología de los datos observacionales de SENAMHI

Como línea base de validación, se recopilieron las series de temporales de precipitación diaria acumulada de 68 estaciones meteorológicas estratégicamente distribuidas a lo largo del territorio nacional. Con el fin de cumplir y garantizar los estándares del análisis climatológico, el periodo temporal se fijó en 31 años continuos, abarcando desde 1987 hasta 2017. Las series temporales utilizados como referencia para la validación fueron provistos por el Proyecto de Hidroclimatología del Departamento de Física de la Universidad Mayor de San Simón (UMSS), quienes tienen acceso a la red oficial del SENAMHI que manejan un histórico de más de 1200 estaciones que miden la precipitación *in situ*, un filtrado del 30% de datos faltantes, aparte realizan en conjunto un proceso de control de calidad y homogeneización relativa utilizando la herramienta RHTestsV4. Finalmente realizan un rellenado de las series temporales utilizando algoritmos de inteligencia artificial. (Andrade, *et al.*, 2021).

Procesamiento numérico y extracción de datos

Debido a la heterogeneidad en la resolución espacial de los productos evaluados los cuales oscilan entre los 0.1° (~ 11 km) de ERA5-Land y los 2.5° (~ 250 km) de NCEP/NCAR, se optó por un enfoque de comparación coordenada-grilla directo. Bajo este criterio, se extrajo el valor de la grilla que interseca las coordenadas geográficas exactas (latitud y longitud) de cada estación meteorológica para esto se centró las coordenadas para cada producto global y se procedió a realizar una conversión de la latitud de 0° a 180° (Este) o de 0° a -180° (Oeste) para que coincidan con las coordenadas de referencia. Esta estrategia metodológica se justifica plenamente por la compleja topografía andina de Bolivia; la aplicación de interpolaciones espaciales o remuestreos introduciría un efecto de suavizado (spatial smoothing) artificial que alteraría la precisión original de los modelos. Posteriormente, los registros diarios extraídos se acumularon linealmente a escala mensual en milímetros [mm/mes]. El análisis estadístico se restringió exclusivamente al bloque estacional húmedo, comprendido entre los meses de noviembre y marzo (NDEFM), por ser el periodo que concentra la mayor disponibilidad hídrica del país.

El procesamiento de datos masivos y el cálculo numérico se estructuraron en el entorno de programación estadística R. Para la manipulación eficiente de los productos globales almacenados en formato NetCDF, se empleó la biblioteca ncdf4 (Versión 1.22). Los campos meteorológicos y el análisis espacial se gestionaron mediante las herramientas analíticas del paquete metR (Versión 0.15.0), mientras que la estructuración y depuración de las matrices de datos vectoriales se ejecutaron bajo el paradigma del paquete dplyr (Versión 1.1.4). La cartografía base y la delimitación de las fronteras administrativas de Bolivia se incorporaron a través de Rnaturalearth (Versión 1.0.1), y la generación de gráficos vectoriales de alta fidelidad se estandarizó mediante ggplot2 (Versión 3.5.0 / 3.5.1).

Para la validación, se utilizaron series temporales en resolución diaria a partir de las coordenadas de las 68 estaciones del SENAMHI, se extrajeron las series de precipitación de los siete productos globales evaluados presentados en la Tabla 1. Se realizó la debida conversión de cada variable para ERA5 y ERA5-Land de m a $mm/día$. Y el cambio de unidades de tasa a acumulación diaria específicamente para MERRA-2, JRA-3Q, NCEP/NCAR y NCEP/DOE (que normalmente viene en $kg \cdot m^{-2} \cdot s^{-1}$) a milímetros por día ($mm/día$), el producto GPCC ya viene en esas unidades. Posteriormente se procedió a realizar su filtrado para los meses de NDEFM y su acumulado mensual de cada mes.

Métricas estadísticas de evaluación

El desempeño cuantitativo de cada producto grillado frente a las observaciones de referencia del SENAMHI (O) se determinó mediante el cálculo sistemático de seis métricas estadísticas tradicionales e integradas para cada una de las series temporales mensuales corregidas:

Con las variables:

- P_i es el valor de precipitación estimado por el reanálisis en el mes i .
- O_i es el valor de precipitación observado en la estación del SENAMHI en el mes i .
- $\bar{P}$ y $\bar{O}$ corresponden a las medias aritméticas de las series estimadas y observadas, respectivamente.
- σ_P y σ_O representan las desviaciones estándar de las series estimadas y observadas.
- n es el número total de meses analizados dentro del bloque estacional húmedo.

- a) Coeficiente de Correlación de Pearson (r): Evalúa la fuerza y dirección de la asociación lineal entre la serie predicha por el producto (P) y la observada (O), con un rango ideal de 1:

$$r = \frac{\sum_{i=1}^n (P_i - \bar{P})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (P_i - \bar{P})^2 \sum_{i=1}^n (O_i - \bar{O})^2}}$$

- b) Raíz del Error Cuadrático Medio (*RMSE*): Cuantifica la magnitud promedio de los errores cometidos, penalizando de manera cuadrática las desviaciones mayores. Sus unidades están expresadas en mm/mes y su valor óptimo es 0:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2}$$

- c) Sesgo Sistemático (*Bias*): Determina la propensión del producto global a subestimar ($Bias < 0$) o sobreestimar ($Bias > 0$) los volúmenes totales de lluvia observados, con un valor ideal de 0:

$$Bias = \frac{1}{n} \sum_{i=1}^n (P_i - O_i)$$

- d) Coeficiente de Eficiencia de Nash-Sutcliffe (*NSE*): Métrica clásica en modelación hidrológica que determina la capacidad del producto para replicar la variabilidad temporal observada mejor de lo que lo haría la media climatológica simple de la estación. Rango de $-\infty$ a 1 (donde 1 indica ajuste perfecto y valores < 0 implican que la media observada es mejor predictor que el producto evaluado) (Nash & Sutcliffe, 1970):

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2}$$

- e) Coeficiente de Eficiencia de Kling-Gupta (*KGE*): Métrica integrada moderna que supera las limitaciones de subestimación de la variabilidad asociadas al NSE. Combina matemáticamente tres componentes independientes: la correlación lineal (r), el sesgo relativo (β) y la variabilidad relativa (γ). Su rango óptimo es 1 (Gupta, et al., 2009):

$$KGE = 1 - \sqrt{(r - 1)^2 + (\beta - 1)^2 + (\gamma - 1)^2}$$

Donde:

$$\beta = \frac{\bar{P}}{\bar{O}} ; \gamma = \frac{\sigma_P}{\sigma_O}$$

- f) Error Absoluto Medio (*MAE*): Métrica robusta no lineal que mide la magnitud promedio de los errores en valor absoluto, evitando la compensación mutua entre desviaciones positivas y negativas. Expresada en mm/mes, con un valor óptimo de 0 (Willmott & Matsuura, 2005):

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - O_i|$$

Zonificación topográfica y fisiográfica


A fin de identificar patrones espaciales lógicos y garantizar la representatividad sub-nacional, la base de datos de las 68 estaciones (Figura 1) se estratifica de forma rigurosa en tres macro-regiones fisiográficas mutuamente excluyentes basadas en umbrales topográficos continuos de elevación (Montes de Oca, 1995):

- Altiplano (24 estaciones): Zonas geográficas situadas a altitudes superiores a los 3,000 m s. n. m., caracterizadas por condiciones de alta montaña y altiplanicies andinas continentales.

- Valles (19 estaciones): Franja de altitud intermedia emplazada entre los 1,500 y 3,000 m s. n. m., correspondiente a las cuencas interandinas y la vertiente de transición orográfica.
- Llanos (25 estaciones): Regiones bajas localizadas por debajo del umbral de los 1,500 m s. n. m., representativas de las llanuras tropicales de la Amazonía, el Oriente y el Chaco boliviano.

Figura 1

Distribución espacial de las 68 estaciones




3. Resultados

Los análisis espaciales consolidados para el bloque estacional húmedo NDEFM (1987–2017) permitieron mapear y cuantificar con precisión el desempeño local de cada producto grillado. La distribución espacial detallada del producto que obtuvo el rendimiento óptimo por estación meteorológica se detalla visualmente y cuantitativamente de la siguiente manera.

Mapas

Se presenta los mapas de Bolivia mostrando cual es el mejor producto global en cada estación según los colores: celeste para ERA 5, amarillo para ERA 5 Land, rojo para GPCC, Azul para JRA 3Q, verde para MERRA 2, café para NCEP DOE, morado para NCEP NCAR. Utilizando formas para diferenciar las regiones 3 Macro-Regiones de Bolivia: cuadrados para el altiplano, círculos para los valles y triángulos para los llanos.

El análisis estadístico comparativo para la correlación en el Altiplano (24 estaciones) muestra una dominancia del reanálisis de MERRA-2, que exhibió los valores más elevados en 12 estaciones de la muestra. Le sigue ERA5 con mejor desempeño en 7 estaciones, GPCC en 3 y ERA5-Land y JRA-3Q ambos en 1 estación. En la zona de los Valles (19 estaciones), MERRA-2 mantiene su predominancia destacándose como el mejor en 12 estaciones, secundado por GPCC en 5 y ERA5 en 2. Para los Llanos (25 estaciones), el liderazgo se divide únicamente entre MERRA-2, que resulta superior en 15 estaciones, y GPCC, que lidera en los 10 restantes. Para la distribución espacial (Figura 2) de la correlación en el Altiplano MERRA-2 presenta una clara predominancia en las zonas menos elevadas, GPCC presenta una distribución más homogénea en todo el altiplano y los productos ERA5, ERA5-Land y JRA-3Q presentan una mejor distribución en las zonas más elevadas del altiplano. En los valles predomina el MERRA-2 a excepción de los valles bajo de Tarija donde aparece el GPCC y ERA5. Para los Llanos MERRA-2 y GPCC dominaron de manera homogénea.

Figura 2*Mejor correlación por estación*


Nota. Mejor modelo global para cada estación según la métrica de correlación. Los colores indican el modelo con mejor ajuste, las formas diferencian la macro-región (Altiplano, Valles, Llanos) y el fondo muestra la elevación en metros.

En cuanto al Error Cuadrático Medio (RMSE), la región del Altiplano (24 estaciones) exhibe una superioridad del modelo MERRA-2, el cual minimiza el error en 17 estaciones, frente a las 4 de GPCC, para ERA5-Land en 2 y una para ERA5. En los Valles (19 estaciones), se observa un rendimiento equiparable entre MERRA-2 y GPCC, registrando el menor error en 8 estaciones cada uno, seguidos por ERA5-Land en 2 estaciones y JRA-3Q en una. Por su parte, en los Llanos (25 estaciones), MERRA-2 vuelve a ser el modelo más preciso, presentando el menor RMSE en 16 estaciones, superando a GPCC que destaca en 8, y a ERA5-Land en una. En la distribución espacial (Figura 3) para el altiplano predomina MERRA-2, seguido del GPCC de manera casi homogénea ambos modelos. MERRA-2 en los valles centrales predomina MERRA-2, en los valles de La Paz y Tarija predominó GPCC seguido de ERA5-Land y JRA-3Q. Para los Llanos predominó MERRA-2 y GPCC a excepción del Chaco de Tarija donde solo GPCC y ERA5-Land aparecieron.

La evaluación del Sesgo (Bias) en el Altiplano (24 estaciones) evidencia que MERRA-2 proporciona los mejores resultados en 12, seguido de GPCC en 7, NCEP/DOE en 3 y ERA5 en 2. Para la región de los Valles (19 estaciones), GPCC se posiciona levemente por encima al registrar el menor sesgo en 8 estaciones, seguido muy de cerca por MERRA-2 que destaca en 7 estaciones, seguido de ERA5-Land en 2 y finalmente NCEP/DOE y JRA-3Q ambos en una. En los Llanos (25 estaciones), el rendimiento es más heterogéneo: MERRA-2 obtiene el mejor ajuste en 10 estaciones, mientras que GPCC, ERA5 y ERA5-Land empatan liderando en 4 estaciones cada uno, seguidos por JRA-3Q en 3. En la distribución espacial (Figura 4) para el Altiplano predomina MERRA-2, seguido de GPCC. En los valles centrales predomina MERRA-2 conjuntamente al GPCC, en los valles de Tarija predominó GPCC en conjunto a ERA5-Land. Para los Llanos el producto MERRA-2 predominó.

Figura 3


Mejor RMSE por estación



Nota. Mejor modelo global basado en RMSE. Los colores indican el modelo con mejor ajuste, las formas diferencian la macro-región (Altiplano, Valles, Llanos) y el fondo muestra la elevación en metros.

Figura 4


Mejor Bias por estación



Nota. Mejor modelo global para cada estación según la métrica de Bias. Los colores indican el modelo con mejor ajuste, las formas diferencian la macro-región (Altiplano, Valles, Llanos) y el fondo muestra la elevación en metros.

La métrica de Eficiencia de Kling-Gupta (KGE) en el Altiplano (24 estaciones) refleja un comportamiento muy competitivo; MERRA-2 logra la mayor eficiencia en 12 estaciones seguido del GPCC en 10 y finalmente ERA5 y ERA5-Land ambos en una. En los Valles (19 estaciones), la tendencia se invierte ligeramente a favor de GPCC, que presenta el mejor desempeño en 9 estaciones frente a las 7 lideradas por MERRA-2 seguido de ERA5, ERA5-Land y JRA-3Q los tres en una estación.


Figura 5
Mejor KGE por estación



Nota. Mejor modelo global para cada estación según la métrica de KGE. Los colores indican el modelo con mejor ajuste, las formas diferencian la macro-región (Altiplano, Valles, Llanos) y el fondo muestra la elevación en metros.

Finalmente, en los Llanos (25 estaciones) se repite el patrón dominante observado en la correlación: MERRA-2 es superior en 15 de ellas, mientras que GPCC muestra el mejor rendimiento en los 10 restantes. En la distribución espacial (Figura 5) para el KGE dominaron de manera homogénea MERRA-2 y GPCC en las 3 macro-regiones.

Figura 6
Mejor NSE por estación




Nota. Mejor modelo global para cada estación según la métrica de NSE. Los colores indican el modelo con mejor ajuste, las formas diferencian la macro-región (Altiplano, Valles, Llanos) y el fondo muestra la elevación en metros

La Eficiencia de Nash-Sutcliffe (NSE) en el Altiplano (24 estaciones) consolida a MERRA-2 como el modelo más robusto, dominando ampliamente al obtener los mejores valores en 17, GPCC queda en segundo lugar liderando en 4, tercero ERA5 con 2 y ERA5-Land en una. En los Valles (19 estaciones), MERRA-2 y GPCC empataron

nuevamente, demostrando ser los mejores en 8 estaciones cada uno, ERA5-Land en dos y JRA-3Q en una. Para la zona de los Llanos (25 estaciones), MERRA-2 sobresale otra vez al ser el más eficiente en 16 estaciones, secundado por GPCC en 8 y ERA5-Land en una. En la distribución espacial (Figura 6) para el NSE dominaron de manera homogénea MERRA-2 y GPCC en las 3 macro-regiones entre los paralelos 20 y 22 aparece el modelo ERA5-Land en algunas estaciones.

Por último, el Error Absoluto Medio (MAE) indica que en el Altiplano (24 estaciones) MERRA-2 presenta la menor magnitud de error en 17, dejando a GPCC como el mejor en 5 y dos para ERA5. En los Valles (19 estaciones), se mantiene la fuerte competencia observada en otras métricas de error, con MERRA-2 y GPCC como los modelos ganadores en 8 estaciones cada uno, ERA5-Land en 2 y JRA-3Q en una. En los Llanos (25 estaciones), MERRA-2 conserva su ventaja al registrar el menor MAE en 14 estaciones, seguido por GPCC que lidera en 10, y ERA5-Land en la estación restante. En la distribución espacial (Figura 7) para el NSE dominaron de manera homogénea MERRA-2 y GPCC en las 3 macro-regiones cerca del paralelo 22 aparece el modelo ERA5 y ERA5-Land en algunas estaciones.

Figura 7
Mejor MAE por estación



Nota. Mejor modelo global para cada estación según la métrica de MAE. Los colores indican el modelo con mejor ajuste, las formas diferencian la macro-región (Altiplano, Valles, Llanos) y el fondo muestra la elevación en metros.

Al analizar las magnitudes de las métricas en los puntos donde cada producto fue el mejor (Tabla 2), se confirma que MERRA-2 no solo domina en la cantidad y en la calidad de sus estimaciones espaciales. Este producto alcanza el coeficiente de correlación de Pearson más alto de la región (0.953) y los umbrales mínimos de error más destacables (RMSE desde 14.51 mm y MAE desde 9.09 mm). El GPCC, su competidor más cercano, presenta fluctuaciones más acotadas en su correlación (0.625 a 0.774), aunque logra picos de eficiencia muy competitivos, evidenciados en un KGE máximo de 0.901. En cuanto al sesgo (Bias), la respuesta de los modelos es variada; mientras MERRA-2 y GPCC oscilan entre subestimaciones y sobreestimaciones moderadas, destaca el comportamiento de NCEP/DOE, que en las estaciones donde fue seleccionado presenta una marcada tendencia a la subestimación (-13.88 a -5.61 mm).

Tabla 2*Métricas de la Región del Altiplano*

Altiplano							
Métrica	MERRA-2	GPCC	ERA5	ERA5-Land	JRA-3Q	NCEP/	NCEP/
Pearson	0.528 a 0.953	0.625 a 0.774	0.614 a 0.823	0.719	0.749	NA	NA
RMSE	14.51 a 47.22	34.45 a 50.59	79.68	34.86 a 35.38	NA	NA	NA
Bias	-3.26 a 16.62	-14.76 a 5.48	-5.03 a 23.10	NA	NA	-13.88 a	NA
KGE	0.220 – 0.897	0.413 – 0.901	0.380	0.508	NA	NA	NA
NSE	0.124 – 0.899	-1.123 a 0.572	0.310	0.310 a 0.489	NA	NA	NA
MAE	9.09 – 32.34	23.98 – 39.09	25.89 – 65.27	NA	NA	NA	NA

Nota. Rangos de variación (mínimo–máximo) de las métricas estadísticas para cada producto global evaluado sobre las estaciones de la región del Altiplano. Los rangos se calcularon de manera exclusiva a partir de los puntos donde cada modelo específico obtuvo el desempeño óptimo. El acrónimo NA indica que el producto no resultó seleccionado como el mejor en ninguna estación para dicha métrica.

Tabla 3*Métricas de la Región de los Valles*

Valles							
Métrica	MERRA-2	GPCC	ERA5	ERA5-Land	JRA-3Q	NCEP/	NCEP/
Pearson	0.501 a 0.907	0.625 a 0.822	0.702 a 0.737	NA	NA	NA	NA
RMSE	18.70 a 53.39	34.02 a 66.25	NA	55.96 a 57.82	61.23	NA	NA
Bias	-12.06 a 18.84	-7.14 a 20.70	NA	2.83 a 13.48	-16.79	18.88	NA
KGE	0.479 a 0.833	0.314 a 0.758	0.569	0.596	0.534	NA	NA
NSE	0.161 a 0.818	-0.432 a 0.594	NA	0.210 a 0.360	0.265	NA	NA
MAE	14.12 a 38.66	22.86 a 50.95	NA	43.28 a 45.68	48.16	NA	NA

Nota. Rangos de variación (mínimo–máximo) de las métricas estadísticas calculadas para los productos globales evaluados sobre la región fisiográfica de los Valles. Los valores corresponden exclusivamente a los puntos donde cada modelo demostró un desempeño óptimo. Se asigna la etiqueta NA en casos donde el producto carece de estaciones con rendimiento dominante en la métrica correspondiente

En la zona de los Valles (Tabla 3), donde el recuento de estaciones mostraba una fuerte competencia y empates entre MERRA-2 presentaba un mejor desempeño para los valles centrales en todas las métricas y GPCC especialmente en las zonas altas Tarija en todas las métricas (especialmente en RMSE, NSE y MAE), el análisis de los rangos permite desempatar la robustez de ambos modelos. MERRA-2 logra registrar los límites inferiores de error más bajos de la región (RMSE mínimo de 18.70 mm frente a los 34.02 mm de GPCC) y picos de correlación

superiores (0.907 frente a 0.822). Por otro lado, productos como ERA5-Land y JRA-3Q un mejor desempeño espacial en las zonas bajas y altas de los valles teniendo representatividad en esas zonas, a pesar de no ser los mejores debido a su reducido número de estaciones, exhiben magnitudes de error considerablemente más altas (RMSE superiores a 55.96 mm) y eficiencias (NSE) muy bajas, lo que sugiere que su capacidad para representar la precipitación en la compleja topografía de los valles es limitada.

Tabla 4

Métricas de la Región de los Llanos

Métrica	Llanos						
	MERRA-2	GPCC	ERA5	ERA5-Land	JRA-3Q	NCEP/	NCEP/
Pearson	0.694 a 0.936	0.513 a 0.890	NA	NA	NA	NA	NA
RMSE	27.80 a 80.01	34.41 a 80.21	NA	78.46	NA	NA	NA
Bias	-10.08 a 16.32	-11.42 a 1.53	1.2 a	-7.86 a 14.62	9.48 a	NA	NA
KGE	0.698 a 0.876	0.461 a 0.890	NA	NA	NA	NA	NA
NSE	0.364 a 0.868	0.434 a 0.780	NA	-0.075	NA	NA	NA
MAE	20.35 a 58.96	24.01 a 49.74	NA	59.49	NA	NA	NA

Nota. Rangos de variación (mínimo–máximo) de las métricas estadísticas para cada producto global evaluado sobre la región fisiográfica de los Llanos orientales. Los rangos representan los valores límite alcanzados en aquellos puntos de control meteorológico donde cada modelo resultó estadísticamente óptimo. La etiqueta NA indica la ausencia total de estaciones con rendimiento dominante en dicha celda.

Para los Llanos orientales (Tabla 4), los rangos de variación reafirman la clara supremacía de MERRA-2 previamente observada. Es notable la alta consistencia de este modelo: su umbral mínimo de correlación en las estaciones donde domina es excepcionalmente alto (0.694), alcanzando máximos de 0.936, y manteniendo valores de eficiencia KGE siempre por encima de 0.698. GPCC se consolida como el segundo modelo más viable, con correlaciones que llegan hasta 0.890, aunque con un límite inferior más castigado (0.513). Es importante notar que las magnitudes absolutas de los errores (RMSE de hasta 80.21 mm y MAE de hasta 59.49 mm) son sistemáticamente más elevadas en esta macrorregión en comparación con el Altiplano y los Valles; un comportamiento esperado y coherente con los regímenes pluviométricos mucho más abundantes que caracterizan a la Amazonía y los llanos bolivianos.

4. Discusión

Uso de modelos

La selección de los productos globales evaluados (Tabla 1) en este estudio abarca enfoques metodológicos distintos que deben ser considerados al interpretar los resultados. Por un lado, los productos de reanálisis (como MERRA-2, ERA5, ERA5-Land, JRA-3Q y los modelos de NCEP) se fundamentan en modelos dinámicos de predicción numérica del tiempo combinados con técnicas de asimilación de datos. El uso principal de estos reanálisis radica en su capacidad para representar procesos físicos complejos como el transporte de humedad, la convección y el

efecto orográfico de manera espacial y temporalmente continua por lo cuál se espera una estimación de la precipitación más precisa. En contraste, el GPCC es un producto puramente estadístico basado en interpolación de datos de pluviómetros terrestres. Por lo tanto, en este estudio, el GPCC se esperaba ser un data set con alto acierto, lo cual sorprende ser superado por las estimaciones de MERRA-2.

Limitaciones metodológicas: estacionalidad e incertidumbre observacional

La restricción metodológica del análisis al bloque húmedo de noviembre a marzo (NDEFM) resulta fundamental para los propósitos hidrológicos generales, pero introduce limitaciones importantes en la caracterización integral del desempeño de los reanálisis a escala anual, siendo estas limitaciones que durante los meses invernales de la estación seca (mayo a septiembre), las dinámicas hidroclimáticas cambian radicalmente: las lluvias disminuyen drásticamente y los vientos locales del oeste, los fenómenos de subsidencia y la ocurrencia de inversiones térmicas severas o densas capas de niebla orográfica controlan el microclima de los Valles interandinos y las laderas orientales. Sin embargo, dentro del periodo evaluado, las observaciones terrestres en el Altiplano sufren de errores sistemáticos por *undercatch* instrumental. La interacción de fuertes vientos y precipitación sólida provoca que los pluviómetros convencionales capturen volúmenes inferiores a los reales. Todo esto puede ser visto como una consecuencia, de una aparente "sobrestimación" detectada por MERRA-2 o también que SENAMHI la esté subestimando este detalle podría ser un fallo del modelo numérico o también una representación de estos fenómenos previamente mencionados en la determinación de la precipitación mensual.

El desafío topográfico y la resolución espacial

La compleja orografía boliviana (con marcados gradientes altitudinales y longitudinales) condiciona drásticamente la precipitación. Bajo esta premisa, se esperaba que ERA5-Land (ver Tabla 1) por su mayor resolución representara mejor esta heterogeneidad frente a su versión base (ERA5). Sin embargo, la mejora fue leve y no absoluta, siendo superado frecuentemente por MERRA-2 en terrenos complejos. Pese a ello, la alta variabilidad de ERA5 y ERA5-Land indica que siguen siendo herramientas robustas, cuya utilidad dependerá de la escala espacial y los objetivos específicos de cada investigación.

También se puede observar que existe una preferencia por ERA5 y ERA5-Land en las zonas cercanas al Chaco Boliviano donde estos productos sobresalen.

5. Conclusiones

El presente estudio tuvo como objetivo identificar el producto global con mejor desempeño estimando la precipitación mensual en Bolivia y para cada macro-región a partir de seis métricas estadísticas. La consistencia regional y la capacidad de estimación mensual de siete productos globales de precipitación frente a las redes observacionales del SENAMHI en Bolivia durante la temporada húmeda (NDEFM) para el periodo (1987-2017). MERRA -2 predominó como el producto global óptimo con una gran capacidad de estimar la precipitación mensual en las macro-regiones del país (Altiplano, Valles y Llanos) seguido de GPCC. En escala regional, la reanálisis MERRA-2 fue superior en altiplano en la mayoría de estaciones, más robusto, consistente y eficiente, liderando en las seis métricas cuantitativas evaluadas (*r*, *RMSE*, *Bias*, *KGE*, *NSE* y *MAE*) mostrando en las estaciones que fue superior obteniendo buenos valores en sus métricas. En la franja de los Valles subandinos MERRA-2 presentó el mejor desempeño en la mayoría de métricas que los demás productos globales compitiendo con GPCC en todas las métricas. Por ende, para esta región montañosa, se sugiere la implementación de técnicas de remuestreo mixto o fusiones multimodelos debido a que productos como ERA5 y ERA5-Land tenían representación puntual en la región del Chaco. En las llanuras tropicales de los Llanos, MERRA-2 domina en todas las métricas a excepción del Bias. No obstante, GPCC exhibe un comportamiento competente, permitiendo que las redes pluviométricas interpoladas

en tierra cobren máxima validez hidroclimática. Los reanálisis climáticos clásicos NCEP/NCAR Reanálisis 1 y NCEP/DOE Reanálisis 2 demostraron una incapacidad estadística absoluta para caracterizar los regímenes de precipitación subnacional en Bolivia, quedando completamente rezagados en todas las pruebas por su tosca resolución de 2.5°. Los productos de la familia de Copernicus, ERA5 y ERA5-Land, mostraron capacidades localizadas notables, particularmente en la resolución de gradientes térmicos y de humedad en laderas andinas específicas, sugiriendo su uso, como ensambles o el uso de algoritmos estadísticos de remoción de sesgo sistemático frente a las estaciones de tierra. Finalmente se recomienda realizar futuras validaciones de manera más regionalizada debido a que en la distribución espacial de este estudio se observó una preferencia de ciertas sub-regiones por modelos específicos.

Conflicto de intereses: Los autores declaran que no existe ningún conflicto de interés.

6. Referencias bibliográficas

- Andrade, M., Terrazas, J., & Guzmán, R. (2021). Homogeneización de series mensuales de temperatura y precipitación en Bolivia a partir de registros SENAMHI entre 1980 y 2015. *Ciencia y Tecnología*, 1(13), 78–86.
- ECMWF. (2024). ERA5-Land hourly data from 1950 to present. Copernicus Climate Change Service (C3S) Climate Data Store (CDS). <https://doi.org/10.24381/cds.e2161bac>
- Espinoza, J., Ronchail, J., Lavado-Casimiro, W., Carranza, J., Cochonneau, G., De Oliveira, E., “...” Guyot, J. (2010). *Variabilidad espacio-temporal de las lluvias en la cuenca amazónica y su relación con la variabilidad hidrológica regional. Un enfoque particular sobre la región andina*. Servicio Nacional de Meteorología e Hidrología del Perú.
- Gaitan, J. J., & Biancari, L. (2024). Nueva base de datos de precipitaciones mensuales de la república Argentina (PMRAv1), 2000-2022. *Meteorológica*, Artículo 032. <https://doi.org/10.24215/1850468Xe032>
- Global Modeling and Assimilation Office, & Pawson, S. (2015). *MERRA-2 tavgM_2d_slv_Nx: 2d, Monthly mean, Time-Averaged, Single-Level, Assimilation, Single-Level Diagnostics V5.12.4* [Dataset]. NASA Goddard Earth Sciences Data and Information Services Center. <https://doi.org/10.5067/AP1B0BA5PD2K> Date Accessed: 2026-07-15
- Gupta, H. V., Kling, H., Yilmaz, K. K., & Martinez, G. F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of Hydrology*, 377(1–2), 80–91. <https://doi.org/10.1016/j.jhydrol.2009.08.003>
- 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.f17050d7](https://doi.org/10.24381/cds.f17050d7)
- Imfeld, N., Barreto Schuler, C., Correa Marrou, K. M., Jacques-Coper, M., Sedlmeier, K., Gubler, S., ... Brönnimann, S. (2019). Summertime precipitation deficits in the southern Peruvian highlands since 1964. *International Journal of Climatology*, 39(11), 4497–4513. <https://doi.org/10.1002/joc.6087>
- Kalnay, E., Kanamitsu, M., Kistler, R., Collins, W., Deaven, D., Gandin, L., Iredell, M., Saha, S., White, G., Woollen, J., Zhu, Y., Chelliah, M., Ebisuzaki, W., Higgins, W., Janowiak, J., Mo, K. C., Ropelewski, C., Wang, J., Leetmaa, A., ... Joseph, D. (1996). The NCEP/NCAR 40-Year Reanalysis Project. *Bulletin of the American Meteorological Society*, 77(3), 437–447. [https://doi.org/10.1175/1520-0477\(1996\)077<0437:TNYRP>2.0.CO;2](https://doi.org/10.1175/1520-0477(1996)077<0437:TNYRP>2.0.CO;2)
- Kanamitsu, M., Ebisuzaki, W., Woollen, J., Yang, S.-K., Hnilo, J. J., Fiorino, M., & Potter, G. L. (2002). NCEP-DOE AMIP-II Reanalysis (R-2). *Bulletin of the American Meteorological Society*, 83(11), 1631–1643. <https://doi.org/10.1175/BAMS-83-11-1631>
- Montes de Oca, I. (1995). Geografía y clima de Bolivia. *Bulletin de l'Institut Français d'Études Andines*, 24(3), 357–368.
- Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I. A discussion of principles. *Journal of Hydrology*, 10(3), 282–290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
- Numerical Prediction Division, Information Infrastructure Department. (2022). The Japanese Reanalysis for

- Three Quarters of a Century. Data Integration and Analysis System. <https://doi.org/10.20783/DIAS.64>
- Paredes Quispe, J. A. (2024). Validación de modelos regionales climáticos del proyecto CORDEX en el Perú [Tesis de grado, Universidad Agraria La Molina]. Repositorio Institucional UNALM. <http://45.231.83.156/handle/20.500.12996/6542>
- Rustemeier, E., Hänsel, S., Finger, P., Schneider, U., & Ziese, M. (2022). GPCC Climatology Version 2022 at 1.0°: Monthly Land-Surface Precipitation Climatology for Every Month and the Total Year from Rain-Gauges built on GTS-based and Historical Data. Deutscher Wetterdienst. https://doi.org/10.5676/DWD_GPCC/CLIM_M_V_2022_100
- Salinas, W. J., Vargas, J. P. D., Encinas, C. A., & Cueto, A. M. (2024). Evaluación de la precisión y aplicabilidad de las estaciones meteorológicas portátiles de bajo costo en la validación y calibración de datos satelitales de precipitación en cuencas no monitoreadas. *Ciencia Latina Revista Científica Multidisciplinaria*, 8(3), 7482–7497. https://doi.org/10.37811/cl_rcm.v8i3.11929
- Santibáñez Gallegos, M. P. (2024). Evaluación del cambio de la disponibilidad hídrica para el período 2030-2050 en la cuenca del río Duqueco en base al modelo climático IPLS-CM5A-LR, región del Biobío, Chile [Tesis de grado, Universidad de Concepción]. Repositorio Institucional UdeC. <http://repositorio.udec.cl/jspui/handle/11594/11998>
- Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79–82. <https://doi.org/10.3354/cr030079>