Horizonte Académico
Revista Multidisciplinaria
Recibido:09/10/2025 Aprobado:10/11/2025

DOI: https://doi.org/10.70208/3007.8245.v5.n3.297

Aplicación de redes neuronales artificiales para el ajuste de precipitaciones mensuales obtenidas en terreno y por satélite, en la cuenca del valle alto - cochabamba

Reymundo Blanco Caseres
r_blancoc@hotmail.com
Investigador Centro Agua, FCAN – UTO
Researcher, Water Center, FCAN – UTO

Pedro Roman Vallejos Mamani
Investigación Científica y Tecnológica UTO
Director of Scientific and Technological Research UTO

Amilkar Ernesto Ilaya Ayza
Posgrado FNI – UTO
Director of Postgraduate FNI - UTO

RESUMEN

La precipitación pluvial es una variable climática de gran importancia para el estudio de los sistemas hidrológicos. El entendimiento de su comportamiento temporal y espacial es de sumo interés para la planificación de los recursos hídricos. La precipitación estimada por satélite permite disponer en tiempo real de datos que se ajustan a la necesidad de estos modelos distribuidos, proporcionando información en regiones que son inaccesibles para otros sistemas de observación tales como pluviómetros y radar. Durante el periodo del año 2018 a 2023 se desarrollaron varios estudios integrales en la cuenca del Valle Alto y Komer Qhocha del Departamento de Cochabamba, referidos principalmente a la Hidrología e Hidrogeología, realizándose la evaluación de la precipitación combinada por satélite, el estudio considero la utilización de los datos pluviométricos TRMM y GPM, los mismos se descargaron de la plataforma Giovanni (https://giovanni.gsfc.nasa.gov/giovanni/?) de la Agencia Espacial NASA de los Estados Unidos, datos que se encuentran a libre disposición de la comunidad científica. Los datos descargados del TRMM cubren el periodo de enero de 1998 a junio de 2023. En el caso de GPM, el periodo considerado va de abril de 2014 a junio de 2023. En ambos casos, es el periodo en el cual se dispone de información.

Palabras clave: Cuenca, modelo hidrológico, hidrogramas, flujo acumulado, tipología.

Application of artificial neural networks for adjusting monthly precipitation obtained in the field and by satellite, in the upper valley basin – cochabamba

ABSTRACT

The pluvial precipitation is a climatic variable of great importance for the study of the hydrological systems. The understanding of their temporal and spatial behavior is of great interest for the planning of water resources. The pluvial estimated by satellite allows to have data in real time that is adjusted to the need of these distributed models, providing information in regions that are inaccessible to other observing systems such as rain gauges and radar. During the period from 2018 to 2023, several comprehensive studies were conducted in the Valle Alto and Komer Qhocha basins of the Cochabamba Department, primarily focused on hydrology and hydrogeology. A combined precipitation assessment was performed using satellite data. The study utilized TRMM and GPM rainfall data, which were downloaded from the Giovanni platform (https://giovanni.gsfc.nasa.gov/giovanni/?) of the United States NASA space agency. This data is freely available to the scientific community. The downloaded TRMM data covers the period from January 1998 to June 2023. For GPM, the period considered is from April 2014 to June 2023. In both cases, this is the period for which information is available.

Keywords: Basin, hydrological model, hydrographs, accumulated flow, typology

INTRODUCCIÓN

La eficacia de los modelos distribuidos depende de la disponibilidad de los datos de entrada. Y, siendo la lluvia una variable clave en el balance hidrológico, es fundamental una mejor comprensión de su distribución espacio temporal.

La estimación de lluvia por satélite está sujeta a errores debido a problemas de instrumentación, naturaleza del sistema de medición, simplificaciones teóricas, relación no lineal entre la variable observada (temperatura) y la lluvia, etc. Estos errores introducen incertidumbre a los algoritmos; por lo que es necesario validar con mediciones de pluviómetros y/o radares en una amplia gama de condiciones meteorológicas y regímenes climáticos.

El desafío principal es cómo beneficiarse de las fortalezas de los diferentes tipos de sensores de satélites y minimizar sus limitaciones. El análisis de precipitaciones puede ser utilizado en la elaboración de alertas tempranas ante la variación de precipitación, para ello, la medición de la precipitación puede realizarse por varios métodos, entre ellos: manejo de pluviómetros, uso de sensores satelitales o manejo de radares satelitales. En el caso de Bolivia, los datos de precipitación y temperatura son captados a través del uso de pluviómetros y estaciones meteorológicas terrestres. El Servicio Nacional de Meteorología e Hidrología (SENAMHI), entidad encargada de recopilar la información, cuenta con un total de 699 estaciones pluviométricas distribuidas en todo el país, de las cuales 547 se encuentran funcionando [3]. Su distribución se halla centrada en los ejes metropolitanos y sus alrededores. Esto se debe a la dificultad que implica el manejo, control y mantenimiento que las estaciones requieren. Debido a esto, el análisis de precipitaciones utilizando únicamente datos de estaciones terrestres presenta varios inconvenientes, es por ello que se puede utilizar información satelital para completar y generar información de precipitación.

Objetivos

Objetivo General

Determinar la arquitectura de la red neuronal artificial que permita ajustar la precipitación mensual por satélite, de las plataformas TRMM y GPM, y la precipitación mensual en las estaciones

meteorológicas terrenas del SENAMHI, ENDE; para la cuenca del Valle Alto del Departamento de Cochabamba, considerando también la ubicación y la elevación de las estaciones meteorológicas.

Objetivos Específicos

Definir las estaciones climatológicas terrenas en el área de estudio

Analizar la robustez de las estaciones meteorológicas seleccionadas en base a criterios hidrológicos.

Evaluar diversas configuraciones de redes neuronales para el ajuste de precipitación por satélite y precipitación en terreno.

Marco teórico conceptual

Precipitación

La precipitación es la una variable espacio temporal, nube formada por gotas y cristales de hielo, procedentes del cambio de estado del vapor de agua de una masa de aire que al ascender a la atmósfera se enfría y llega a saturarse, son dos fuerzas fundamentales que actúan en la gota de agua: el arrastre por la corriente de agua ascendente y el peso de la propia gota (Fundación Española Para la Ciencia y la Tecnología, 2004).

Tipos de precipitación

Existen diferentes tipos de precipitación, clasificados como: precipitación convectiva, precipitación orográfica y precipitaciones frontales (Musy, 2001).

Altura de precipitación

La altura de precipitación es la forma de medir las precipitaciones de lluvia y nieve. Representa al espesor en milímetros de la capa de agua acumulada sobre un suelo horizontal por una o varias precipitaciones, si no hubiera infiltración, ni evaporación y si las precipitaciones que caen bajo forma sólida se encontraran fundidas. En cantidad corresponde al número de litros por metro cuadrado. Si llueve un litro en 1 m2 significa que sobre ese terreno se deposita una capa de 1 mm de agua. Asimismo, es expresada en mm de agua por unidad de superficie, que es lo mismo que l/m2 (Juncosa, 2005).

Tiempo de duración

El tiempo de duración es el tiempo que transcurre entre el comienzo y el fin de la tormenta o lluvia. La intensidad y duración son generalmente obtenidas del pluviograma o banda pluviográfica (Musy, 2001).

Intensidad

La intensidad representa la cantidad de agua caída por unidad de tiempo, altura máxima de agua caída en cada evento de precipitación (Musy, 2001).

Precipitación media mensual

Es la media aritmética de las precipitaciones mensuales, de un cierto mes, a lo largo de una serie de años; es decir, si la serie es de 30 años sería hacer la media de los 30 meses, por ejemplo, enero, que hay en la serie (Juncosa, 2005).

Satélites

Los satélites son cuerpos que giran al alrededor de un objeto de mayor tamaño, podrían ser naturales como las lunas y artificiales que son construidos por el hombre. Los satélites artificiales, de los que se hablaran en este trabajo, observan el planeta mediante sensores multiespectrales, la finalidad que tienen es la de localizar recursos naturales, vigilar las condiciones de cultivos y el grado de deforestación, el avance de la contaminación y la variabilidad meteorológica como la precipitación, temperatura radiación solar (Caicedo Carrascal, 2008).

Misión de medición de lluvia tropical (TRMM)

El proyecto Misión de Medición de Lluvia Tropical (Tropical Rainfall Measuring Mission - TRMM) es una misión conjunta entre la NASA y la Agencia de Exploración Aeroespacial de Japón (JAXA), el objetivo principal es monitorear a las precipitaciones tropicales. El satélite TRMM fue lanzado el 27 de noviembre de 1997 y se encuentra a una altura de 350 Km. Este satélite está diseñado para monitorear y estudiar la lluvias tropicales y subtropicales, brindando información con alta resolución temporal y con una alta cobertura espacial (Massagli, Daniel del C, & Andrade, 2011). Su lanzamiento se realizó a causa de la destrucción de la selva ecuatorial, la desertificación subtropical, el crecimiento del agujero de la capa de ozono y el cambio de los patrones climáticos (Agua, 2019).

Medición de la Precipitación Global (GPM)

El GPM (Global Precipitation Measurement o Medición de la Precipitación Global), es una misión cooperativa internacional entre Estados Unidos y Japón, con las agencias NASA y JAXA, respectivamente una plataforma de seguimiento y expansión a TRMM (Tropical Rainfall Measuring Mission), comprende de una red internacional de satélites, que fueron lanzados el 27 de febrero de 2014 con el propósito de proveer la nueva generación de observaciones de precipitación global. Una evolución de la misión TRMM, que utiliza una constelación de satélites renovada, adquiere datos entre las latitudes 65° Norte a 65° Sur, orbita a una altura de 407 km, e integra nuevos instrumentos y algoritmos de análisis, tomando en cuenta la retroalimentación de la TRMM para su calibración, hasta mediados de 2018 (Earth Observation Center JAXA, 2017).

Redes Neuronales Artificiales

Las redes neuronales artificiales constituyen una herramienta en hidrología, utilizado en problemas de predicción de lluvias, caudales y transformación de lluvia escorrentía. Asimismo, permite optimizar el proceso de gestión y monitoreo de aguas superficiales y subterráneas (Obregón, Fragala, & Prada, 2015).

Las redes neuronales artificiales, son algoritmos matemáticos con la capacidad de aprender de datos, reconocimiento y predicción. Para la mejor estructura el encontrar la capa de entrada, ocultas y de salida consisten en la forma más sencilla de la arquitectura de una red neuronal (Shuang, Liu, Tang, Liu, & Shuang, 2017).

El modelo de una red neuronal consta de un número diferente de neuronas, el cual está conectado con diferentes valores de peso, la capacidad de entrenamiento de la red neuronal donde los pesos de conexión son determinados mediante un método de aprendizaje. Para este aprendizaje se ajustan cada peso de conexión en la red neuronal (Negnevitsky, 2002).

METODOLOGÍA

Delimitación área de estudio

El área de estudio contempla las 10 sub cuenca del Valle Alto, laguna Vacas y las cuencas Komer Qhocha de Cochabamba, que abarca a 16 municipios: Arbieto, Tarata, Anzaldo, Sacabamba, Tolata,

Cliza, Toco, San Benito, Punata, Villa Rivero, Tacachi, Villa Gualberto Villarroel, Arani, Alalay, Tiraque y Vacas. Siendo objeto de estudio la priorización de todas las cuencas que se encuentran en esta zona.

La zona de influencia se encuentra ubicada aproximadamente a 30 km de la ciudad de Cochabamba, cuyas coordenadas geográficas en UTM, Zona 19 y 20 corresponden a: Mínimo (X, Y), (790912 :8013934); Máximo (X, Y), (876924: 8096541).

Enfoque Procedimental

Para construir la base de datos utilizada en el presente estudio, se han considerado los datos oficiales de SENAMHI y ENDE.

La estrategia de trabajo fue inicialmente reconstruir una base de estaciones robustas que servirán para los fines del balance hídrico, basados en el análisis del parámetro precipitación inicialmente, para después tener un referencial con éstas para proceder con el análisis de otros parámetros (análisis combinado con disponibilidad de información satelital).

Se utiliza una metodología de análisis de datos en la cual se jerarquizan las estaciones, formando un grupo con las que presentan más robustez de información (Grupo 1: Clases AAA, AA y A) y otro con las de menos seguridad de información (Grupo 2: Clases B, C y D). Inicialmente se procede a rellenar los vacíos de datos de las estaciones más robustas (Grupo 1) con un método de relleno "uno a uno" y de complejidad mayor (Relleno por tipología), para que después, este grupo de estaciones con datos robustos (rellenado y consolidado), sirva para el tratamiento de datos de las estaciones del grupo 2, con un método de relleno más general.

Posteriormente, las estaciones más robustas son utilizadas para el ajuste de datos satelitales, y de esta forma consolidar una base de datos con estaciones ficticias en grillas para que se pueda tener una mejor representación espacial del fenómeno de precipitación.

En el diagrama de flujo mostrado en la Figura 1, se detalla el procedimiento completo a seguir para la construcción de la base de datos final.

Figura 1: Diagrama de flujo para la consolidación de la base de datos de precipitaciones

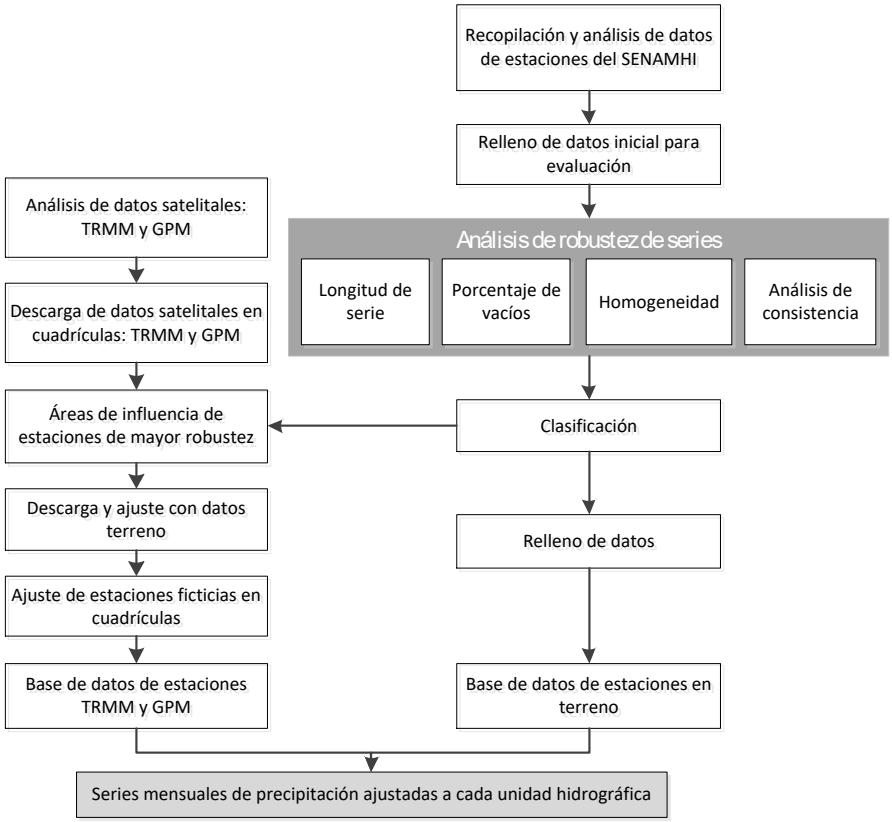

Fuente elaboración propia. 2025

Clasificación

Para realizar la clasificación, se utilizó un método basado en el estudio del balance hídrico de la cuenca del TDPS (2016), que evalúa los cuatro criterios mencionados anteriormente, y los relaciona luego a través de una multiplicación de los resultados de dicha evaluación.

Los criterios utilizados fueron: Clasificación 1. Criterio basado en la longitud de registro, Clasificación 2. Criterio basado en el porcentaje de vacíos del registro, Clasificación 3. Criterio basado en el número de test de homogeneidad cumplidos por la estación de estudio, Clasificación 4. Criterio basado en la cantidad de quiebres evaluado por el método de dobles acumuladas:

En base a estos criterios, se clasificaron a las estaciones en el área de influencia de la cuenca del Valle Alto y Komer Qhocha.

Cuadro 1: Estaciones clasificadas según su grado de confiabilidad

N°	Estación	Literal	Confiabilidad
1	Arani	AAA	Muy Alta
2	San Benito	AAA	Muy Alta
3	La Tamborada	AAA	Muy Alta
4	Capinota	AA	Alta
5	Anzaldo	A	Muy Buena
6	Alalay	A	Muy Buena
7	Colomi	A	Muy Buena
8	Mizque	A	Muy Buena
9	Tarata	B	Buena
10	Tiraque	B	Buena
11	Punata Aut	C	Baja
12	ArbietoAut	C	Baja
13	San Benito Aut	C	Baja
14	Chaupisuyo	C	Baja
15	K'aspiKancha	C	Baja
16	Koari	C	Baja
17	Sacabamba	C	Baja
18	Paracti	C	Baja
19	San Jacinto Barro Negro	C	Baja
20	Cayarani	C	Baja
21	Molle Molle	C	Baja
22	Toro Toro Potosí	C	Baja
23	Santivañez	C	Baja
24	Acasio	C	Baja
25	Embalse Corani	C	Baja

Fuente: Elaboración propia. 2025

Para realizar el estudio hidrológico, se utilizaron las estaciones A, AA y AAA. Asimismo, para complementar la información, se recurrió al uso de las estaciones B.

Figura 2: Estaciones principales SENAMHI y ENDE

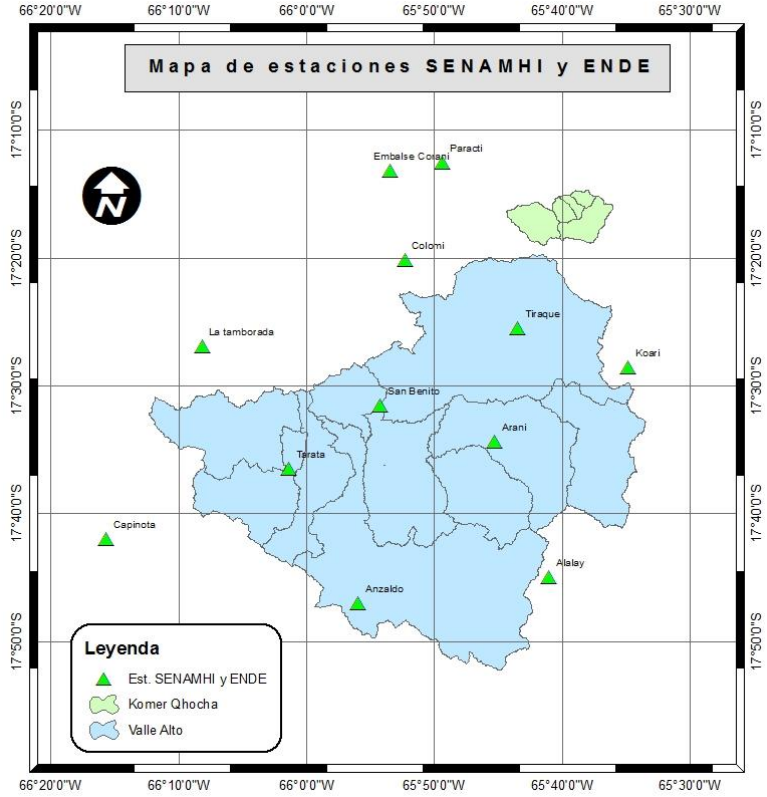

Fuente: Elaboración propia. 2025

Base De Datos Corregida De Estaciones Del Senamhi Y Ende

Como resultado del proceso de relleno final, se obtuvo la base de datos de las estaciones meteorológicas de SENAMHI y ENDE, que se encuentran en el área de estudio.

Datos de precipitaciones por satélite

Los satélites y otros sistemas de teledetección, tales como los radares meteorológicos, proporcionan abundante información complementaria, sobre todo para zonas donde se carece de datos. Aunque, todavía no tienen la capacidad de ofrecer, con la exactitud y homogeneidad necesarias, mediciones de muchos de los elementos de los que informan las estaciones terrestres.

Dada la cobertura espacial que ofrecen, complementan las redes de superficie, pero no las sustituyen. La teledetección permite alcanzar una mayor cobertura espacial, y muchas veces temporal, que las observaciones in situ. Los datos obtenidos por teledetección también complementan las observaciones efectuadas en otras plataformas.

Actualmente, son de libre disposición los productos de Tropical Rainfall Measuring Mission (TRMM) y Global Precipitation Mission (GPM), que permiten conocer la precipitación en el cinturón ecuatorial del planeta.

La misión TRMM ha estado proporcionando mediciones de precipitación sobre océanos y continentes entre las latitudes 35°N a 35°S, desde noviembre de 1997 a la fecha. En estos años de vigencia, se realizaron muchos estudios a partir de los productos TRMM que evidencian un sesgo importante y errores aleatorios en la precipitación en zonas de topografía compleja.

Por esta razón surge el proyecto de la NASA (National Aeronautics and Space Administration) y la agencia japonesa JAXA (Japan Aerospace Exploration Agency), que desarrolla The Global Precipitation Mission (GPM), con la finalidad de ser la siguiente generación de productos satelitales de precipitación, además de tener la misión principal de mejorar el entendimiento de la variabilidad espacio-temporal de la precipitación global. Se cuenta con datos desde abril de 2014.

Tanto el TRMM como el GPM ofrecen productos grillados de precipitación. El TRMM provee los productos 3B42 real-time (3B42RT) y 3B42 versión 7 (3B42V7), los cuales han sido ampliamente estudiados y aplicados a la simulación y predicción hidrológica. La resolución espacial de estos productos es de 0. 25°, lo que implica aproximadamente 27 km en la zona de estudio.

Por otro lado, el GPM cuenta con el producto Day-1 multi-satellite precipitation dado por el algoritmo Integrated Multisatellite Retrievalsfor GPM (IMERG). La resolución espacial de este satélite mejora al TRMM, ya que se tienen grillas de 0. 1° de lado, aproximadamente 10 km de lado. Aunque se puede considerar que es un valor grande, esta plataforma es la de mejor resolución espacial existente a la fecha.

RESULTADOS

Descarga de datos de precipitaciones por satélite trmm y gpm

Los datos pluviométricos TRMM y GPM se descargaron de la plataforma Giovanni (https://giovanni.gsfc.nasa.gov/giovanni/?) de la Agencia Espacial NASA de los Estados Unidos, datos que se encuentran a libre disposición de la comunidad científica.

Para la descarga de series temporales mensuales, es necesario introducir las coordenadas de la estación que se utilizará como referencia, otro dato importante son las fechas de inicio y fin del periodo de tiempo requerido.

En el presente proyecto trabajaremos con las series temporales descargadas en formato ASCII CSV, con el valor acumulado mensual.

Los datos descargados del TRMM cubren el periodo de enero de 1998 a junio de 2023. En el caso de GPM, el periodo considerado va de abril de 2014 a junio de 2023. En ambos casos, es el periodo en el cual se dispone de información.

Las estaciones consideradas como base para el ajuste, tanto para el análisis de las precipitaciones del TRMM como para el GPM fueron:

Cuadro 2: Estaciones utilizadas para el ajuste de datos de precipitación por satélite

N°	Estación	Confiabilidad
1	Arani	AAA
2	San Benito	AAA
3	La Tamborada	AAA
4	Capinota	AA
5	Anzaldo	A
6	Colomi	A
7	Tarata	B
8	Tiraque	B
9	Koari	C
10	Paracti	C
11	Embalse Corani	C

Figura 3: Selección de la serie temporal para descargar precipitaciones de TRMM y GPM

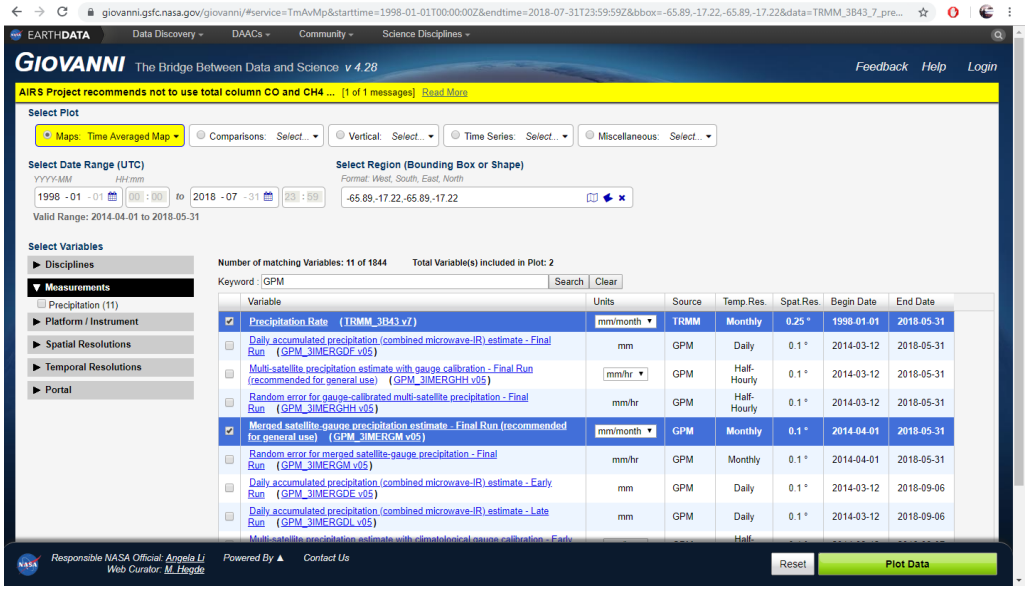

Fuente: https://giovanni.gsfc.nasa.gov/giovanni/?

Ajuste de precipitaciones por satélite con datos de terreno – trmm

Para consolidar la base de datos de precipitaciones, se realizó una comparación y ajuste de la información original de SENAMHI y ENDE con la información TRMM. Debido a la limitación de información temporal del TRMM, se consideró el periodo de 1998 a 2023 para la elaboración del ajuste. Aparte de los coeficientes de correlación de Pearson, los indicadores estadísticos utilizados para asegurar un buen ajuste están detallados en el siguiente cuadro:

Cuadro 3: Métricas estadísticas utilizadas en la comparación de precipitaciones en terreno y precipitaciones por satélite

Métrica estadística	Ecuación	Valor ideal
Desviación estándar (DE)	$\sigma_f = \sqrt{\frac{1}{N}\sum_{n=1}^{N}(f_n - \bar{f})^2}$	0
Sesgo estadístico (BIAS)	$BIAS = \frac{\frac{1}{N}\sum_{n=1}^{N}(f_n - \bar{f})^2}{\sum_{n=1}^{N} r_n}$	0
Raíz del error cuadrático medio (RMSE)	$RMSE = \sqrt{\frac{1}{N}\sum_{n=1}^{N}(f_n - r_n)^2}$	0
Índice de eficiencia de Nash-Sutcliffe (NSE)	$NSE = 1 - \frac{\sum_{n=1}^{N}(f_n - r_n)^2}{\sum_{n=1}^{N}(r_n - \bar{r})^2}$	1

Dónde:

f_n = variable a comparar

f = estimación de la precipitación por satélite

r = variable de referencia

r_n = precipitación en la estación terrena

Cuadro 4: Coeficiente de correlación entre las precipitaciones medidas en terreno y las precipitaciones por satélite TRMM

N°	Estación	Confiabilidad	Coeficiente de correlación de Pearson
1	Arani	AAA	0.816
2	San Benito	AAA	0.890
3	La Tamborada	AAA	0.885
4	Capinota	AA	0.889
5	Anzaldo	A	0.843
6	Colomi	A	0.827
7	Tarata	B	0.915
8	Tiraque	B	0.800
9	Koari	C	0.877
10	Paracti	C	0.865
11	Embalse Corani	C	0.865

Fuente: Elaboración propia. 2025

Ecuación de ajuste de precipitaciones trmm

Los datos de la precipitación por satélite registran muy bien la presencia de precipitaciones en la zona de estudio, sin embargo, se tiene en muchos casos un sesgo muy elevado con respecto al valor de la intensidad, que puede incluso duplicar o triplicar estos valores medidos en tierra.

En los siguientes gráficos, se muestran las precipitaciones medidas y las precipitaciones por satélite TRMM para algunas de las estaciones evaluadas.

Figura 4: Comparación entre precipitaciones en terreno y precipitaciones por satélite TRMM

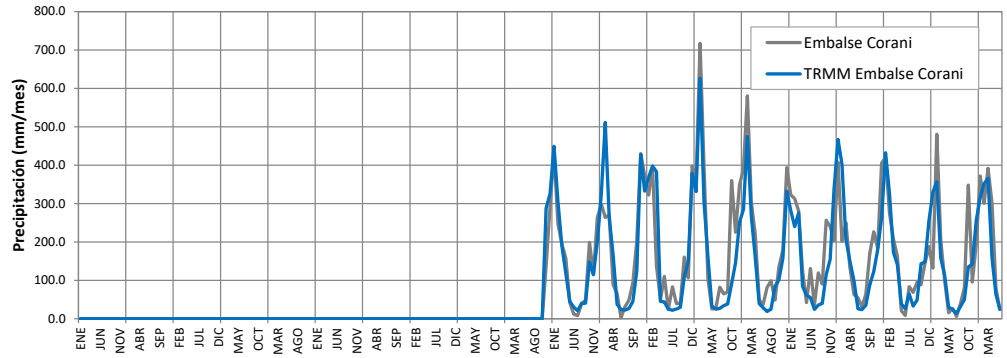

Fuente: Elaboración propia. 2025

El ajuste se realizará mediante un análisis de regresión múltiple, incluyendo los criterios de localización de la estación meteorológica, tanto en latitud, longitud como elevación.

$$P_c = A + B \cdot P_{TRMM}^{n} + C \cdot W + D \cdot S + E \cdot Elev$$

Donde:

P_c = precipitación corregida o ajustada

A, B, C, D, E = coeficientes de ajuste

P_{TRMM} = Precipitación satelital TRMM

n = exponente de ajuste

W = coordenada oeste de la estación meteorológica

S = coordenada sur de la estación meteorológica

$Elev$ = elevación de la estación meteorológica

Con la siguiente condición garantizamos no tener valores de precipitación negativos.

$$P = \begin{cases} SiP_c > 0; P = P_c \\ enotroscasos: P = 0 \end{cases}$$

El ajuste se realiza con un proceso de optimización, minimizando la raíz del error cuadrático medio de las estaciones consideradas.

Por otro lado, para un mejor ajuste es necesario conformar dos grupos de datos o clústeres. Estos permitirán tener un mejor ajuste en las zonas evaluadas, por lo tanto se tendrá una ecuación para cada uno de ellos.

El primer clúster para el ajuste estaciones TRMM está conformado por las estaciones: Anzaldo, San Benito, Capinota, La Tamborada, Tarata, Tiraque (Que cubre el área del Valle Alto).

El segundo clúster lo conforman las estaciones cercanas a Komer Qhocha: Colomi, Paracti.

Las métricas de la estación Embalse Corani muestran un buen ajuste, con un Índice de Nash-Sutclife de 0.75 y un sesgo estadístico de 6.42%, además de un coeficiente de correlación de Perason de 0.90. Esto nos indica que el sensor TRMM presente un buen ajuste en esta zona, a diferencia de la comparación con otras estaciones. El proceso de ajuste incluyendo a ésta estación a los clústeres muestra una reducción de la calidad de ajuste de la estación Embalse Corani, por lo que no se la considera en ninguno de los dos clústeres.

En el primer clúster, se determinó la siguiente ecuación de ajuste para la precipitación en mm/mes:

$$P_c = -1165.5193 + 6.4999 \cdot P_{TRMM}^{0.6148} + 1.5034 \cdot W - 76.0773 \cdot S - 0.0455 \cdot Elev$$

Las mejoras en los indicadores estadísticos para el primer clúster son:

Cuadro 5: Métricas estadísticas iniciales y después del ajuste, clúster 1 TRMM

N°	Estación	Inicial / Ajustado	Número total de datos	Desviación estándar	índice Nash-Sutclife	Raíz del error cuadrático medio	Sesgo estadístico BIAS (%)	Coeficiente de correlación de Pearson
1	Anzaldo	Inicial	234	64.81	0.13	51.17	28.47	0.84
		Ajustado	234	49.99	0.70	30.26	9.96	0.84
2	San Benito	Inicial	234	60.25	-0.89	58.20	44.36	0.89
		Ajustado	234	42.38	0.75	21.31	5.95	0.88
3	Capinota	Inicial	234	57.77	0.69	30.31	8.66	0.89
		Ajustado	234	50.57	0.79	24.86	5.83	0.89
4	La Tamborada	Inicial	192	61.61	0.16	46.53	28.52	0.88
		Ajustado	192	46.75	0.77	24.33	7.80	0.89
5	Tarata	Inicial	234	56.44	0.08	41.41	20.16	0.91

		Ajustado	234	42.21	0.82	18.40	3.98	0.91
6	Tiraque	Inicial	234	101.22	-2.66	116.40	112.45	0.80
		Ajustado	234	58.11	0.63	36.90	11.30	0.80

El ajuste muestra una notable mejora en los indicadores estadísticos. En el caso del índice de Nash-Sutclife, este valor supera a 0.7 en la mayoría de las estaciones. El error cuadrático medio se reduce notablemente. El sesgo estadístico en todas las estaciones está por debajo de 20%, casi en todas por debajo de 10%, excepto en Tiraque. De forma general, el coeficiente de correlación de Pearson se mantiene o mejora. Por lo tanto, la ecuación de ajuste permitirá ajustar a las estaciones ficticias TRMM con una notable confiabilidad.

A continuación, se muestra el ajuste de las estaciones de forma gráfica.

Figura 5: Comparación entre precipitaciones en terreno y precipitaciones ajustadas para sensor TRMM, Clúster 1

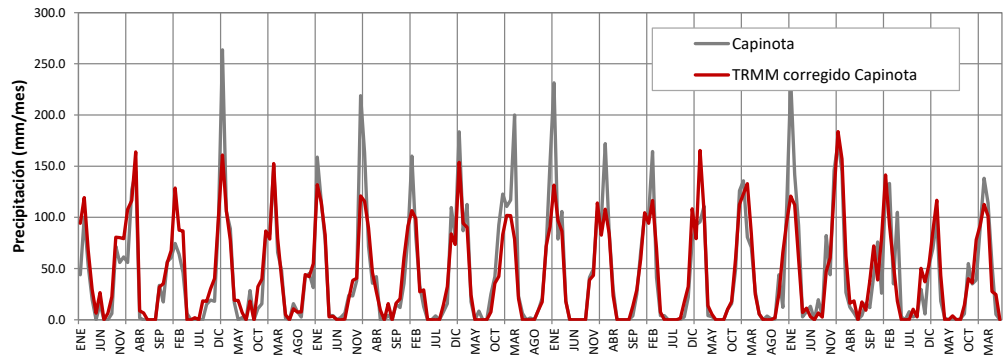

Fuente: Elaboración propia. 2025

El segundo clúster está definido por la siguiente ecuación:

$$P_c = 13764.3686 + 8.2097 \cdot P_{TRMM}^{0.64016} + 10.1093 \cdot W + 758.6284 \cdot S - 0.0251 \cdot Elev$$

Tras el ajuste, las métricas estadísticas, al igual que en clúster 1, mejoran.

Cuadro 6: Métricas estadísticas iniciales y después del ajuste, clúster 2 TRMM

Nº	Estación	Inicial / Ajustado	Número total de datos	Desviación estándar	índice Nash-Sutclife	Raíz del error cuadrático medio	Sesgo estadístico BIAS (%)	Coeficiente de correlación de Pearson
6	Colomi	Inicial	234	74.93	-0.97	74.54	49.33	0.83
		Ajustado	234	55.11	0.59	34.14	10.35	0.82
10	Paracti	Inicial	116	142.59	0.72	75.35	27.28	0.86
		Ajustado	116	130.88	0.75	71.30	24.42	0.86

Fuente: Elaboración propia. 2025

Los indicadores estadísticos mejoran, aunque no como en el clúster 1. El índice de Nash-Sutclife mejora notablemente y el sesgo estadístico es inferior a 25% en ambas estaciones, siendo marcadamente bajo en Colomi.

En los gráficos a continuación se muestra el ajuste gráfico.

Figura 6: Comparación entre precipitaciones en terreno y precipitaciones ajustadas para sensor TRMM, Clúster 2

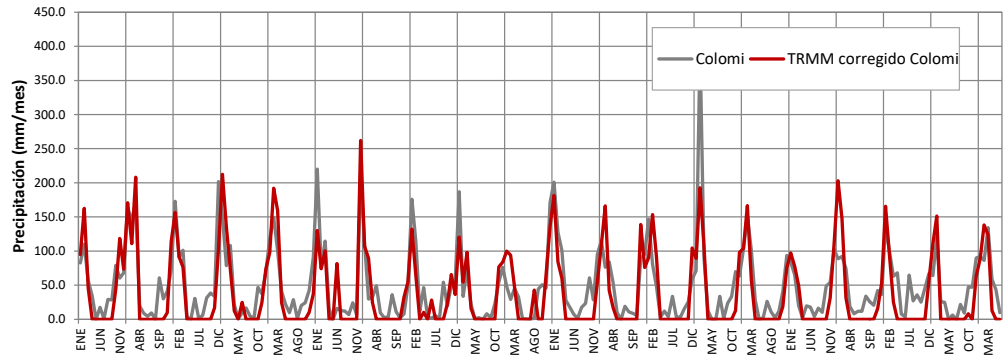

Fuente: Elaboración propia. 2025

ESTACIONES FICTICIAS TRMM

Con el fin de tener mayor cantidad de datos hidrológicos en las cuencas de estudio, se diseñó una grilla de 7 estaciones ficticias para el sensor TRMM a nivel mensual, considerando que la distancia entre ellas es de 0.25°. Definidas las ubicaciones de cada una de las estaciones TRMM, se procedió

con la descarga de datos de precipitación para posteriormente ajustarlas en base a las ecuaciones calculadas en el anterior acápite.

Figura 7: Estaciones ficticias TRMM

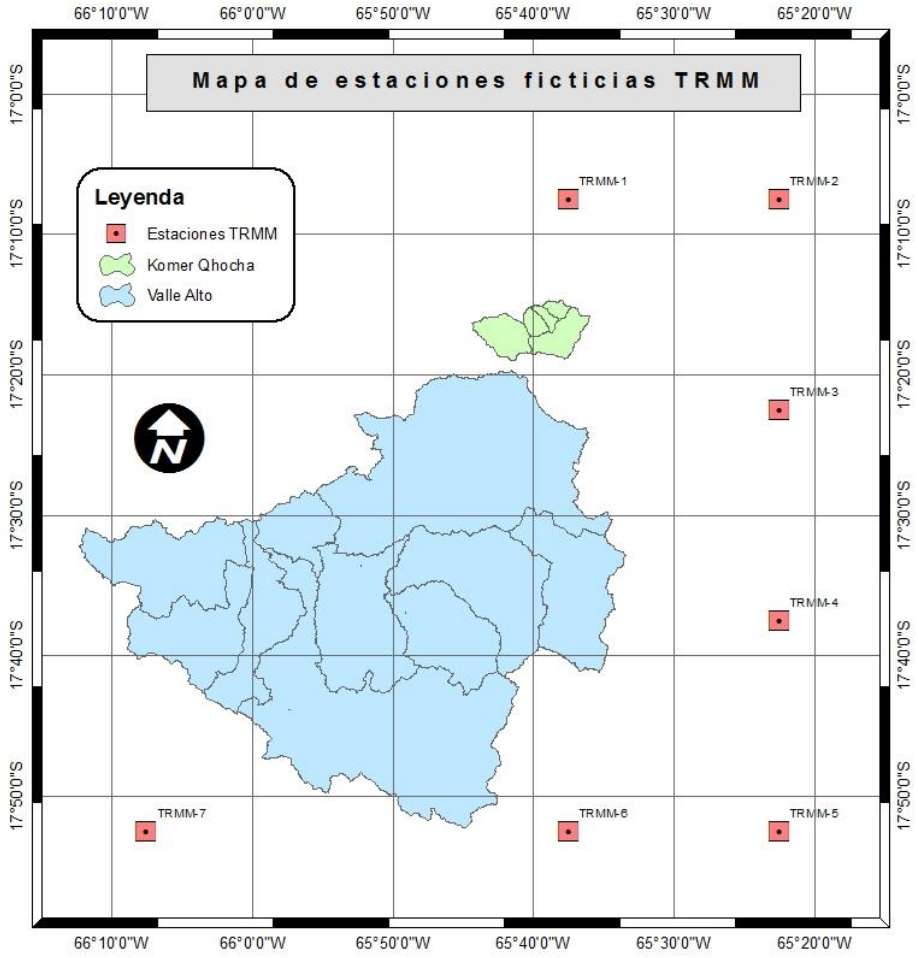

Fuente: Elaboración propia. 2025

Figura 8: Precipitaciones corregidas estación TRMM-1, Clúster 2

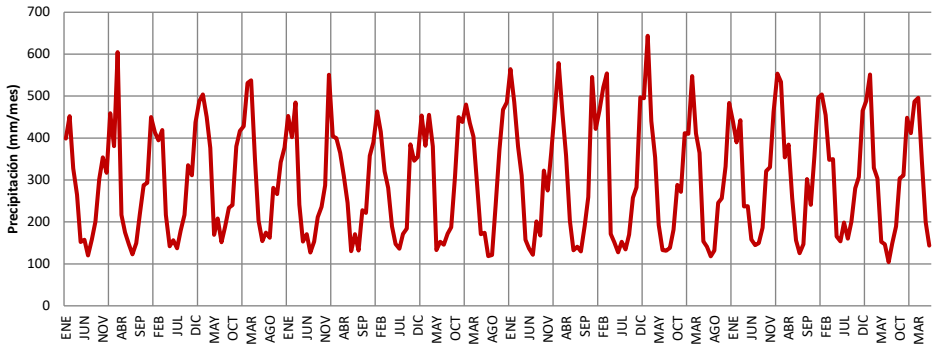

Fuente: Elaboración propia. 2025

Figura 9: Precipitaciones corregidas estación TRMM-4, Clúster 1

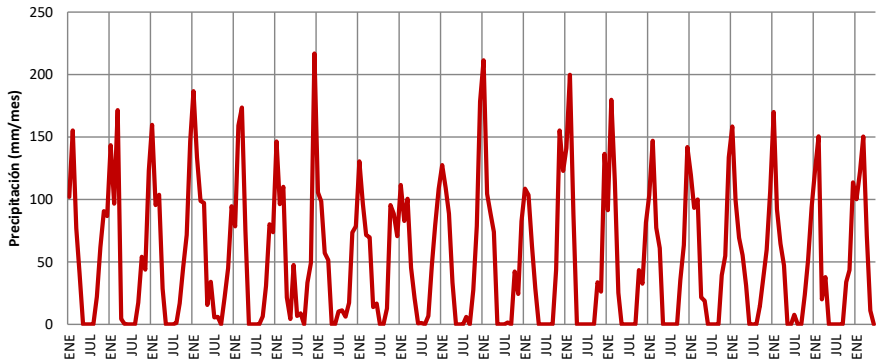

Fuente: Elaboración propia. 2025

Ajuste De Precipitaciones Por Satélite Con Datos De Terreno – Gpm

Al igual que los datos de precipitación TRMM, procedemos con el ajuste de la serie temporal de precipitaciones del sensor GPM. El periodo analizado para el ajuste cubre el 2014 hasta 2023.

Cuadro 7: Coeficiente de correlación entre las precipitaciones medidas en terreno y las precipitaciones por satélite GPM

N°	Estación	Confiabilidad	Coeficiente de correlación de Pearson
1	Arani	AAA	0.904
2	San Benito	AAA	0.899
3	Capinota	AA	0.852
4	Anzaldo	A	0.738
5	Colomi	A	0.919
6	Tarata	B	0.867
7	Tiraque	B	0.807
8	Paracti	C	0.843

Fuente: Elaboración propia

No tomamos en cuenta la estación Alalay ni La Tamborada porque no coinciden con el periodo de estudio de los datos GPM.

Figura 10: Comparación entre precipitaciones en terreno y precipitaciones por satélite GPM

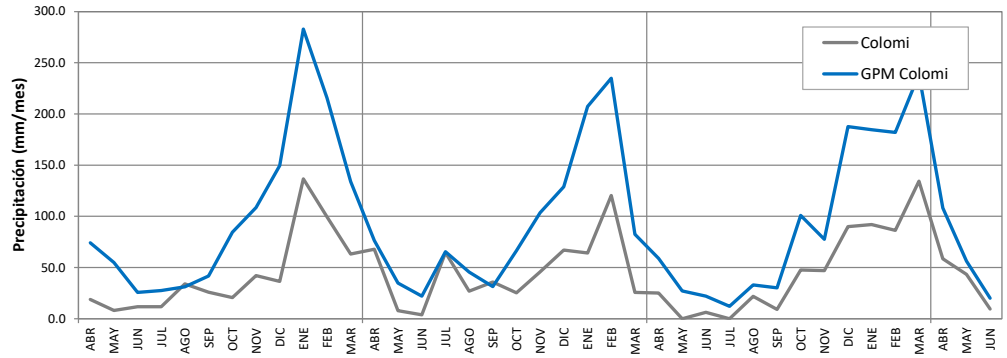

Fuente: Elaboración propia. 2025

Definición De Clústeres O Zonas De Mejor Ajuste De Estaciones Gpm

Para el ajuste de las estaciones ficticias GPM, se establecen tres clústeres para un mejor ajuste.

El primer clúster está conformado por las estaciones: Paracti, Tiraque

El segundo clúster: Colomi, Arani, San Benito

El tercer clúster: Tarata, Anzaldo, Capinota

c.2. Ecuación De Ajuste De Precipitaciones Gpm

Para el primer clúster se determinó la siguiente ecuación:

$$P_c = 108.3856 + 77.2925 \cdot P_{TRMM}^{0.3507} + 3.6244 \cdot W - 3.3112 \cdot S - 0.0719 \cdot Elev$$

Los indicadores estadísticos mejoran después del ajuste, éstos son desglosados en el siguiente cuadro.

Cuadro 8: Métricas estadísticas iniciales y después del ajuste, clúster 1 GPM

N°	Estación	Inicial / Ajustado	Número total de datos	Desviación estándar	índice Nash-Sutclife	Raíz del error cuadrático medio	Sesgo estadístico BIAS (%)	Coeficiente de correlación de Pearson
1	Paracti	Inicial	39	114.55	0.56	86.07	117.89	0.84
		Ajustado	39	119.88	0.74	66.54	70.46	0.86
2	Tiraque	Inicial	39	71.91	0.58	47.85	86.89	0.81
		Ajustado	39	74.10	0.59	47.29	84.86	0.80

La poca cantidad de datos disponibles para el GPM hace que los indicadores estadísticos no sean los deseables, sin embargo, se observa que tras el ajuste mejoran.

Figura 11: Comparación entre precipitaciones en terreno y precipitaciones ajustadas para sensor GPM, Clúster 1

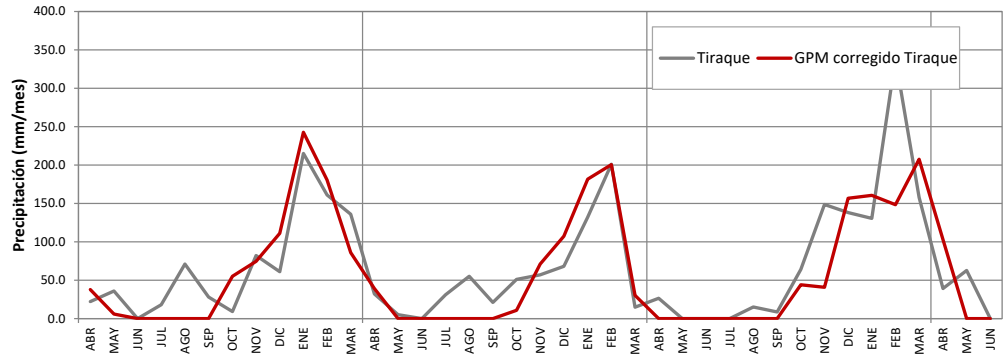

Fuente: Elaboración propia

El ajuste del primer clúster para las precipitaciones GPM es descrito en el Anexo 15.

El segundo clúster se ajusta a la ecuación:

$$P_c = -56.5065 + 0.3043 \cdot P_{TRMM}^{1.0875} - 14.7880 \cdot W + 50.9741 \cdot S - 0.0100 \cdot Elev$$

Las métricas estadísticas del ajuste de las estaciones terrenas con las estaciones ficticias GPM para el segundo clúster son expuestas en la siguiente tabla:

Cuadro 9: Métricas estadísticas iniciales y después del ajuste, clúster 2 GPM

N°	Estación	Inicial / Ajustado	Número total de datos	Desviación estándar	índice Nash-Sutclife	Raíz del error cuadrático medio	Sesgo estadístico BIAS (%)	Coeficiente de correlación de Pearson
1	Colomi	Inicial	39	62.68	-2.11	64.43	239.43	0.92
		Ajustado	39	36.54	0.84	14.57	12.25	0.92
2	Arani	Inicial	39	55.95	-2.33	60.12	338.64	0.90
		Ajustado	39	31.98	0.82	13.89	18.09	0.91
3	San Benito	Inicial	39	48.79	-0.94	46.86	210.25	0.90
		Ajustado	39	30.25	0.79	15.25	22.26	0.90

Fuente: Elaboración propia. 2025

Hay una notoria mejora en lo que respecta al índice de Nash-Sutclife, de valores negativos se alcanzan valores cercanos a 1 tras el ajuste. Lo mismo sucede con el BIAS, pues las precipitaciones por satélite GPM tienen un gran sesgo inicial, con respecto a las estaciones terrenas, pero el ajuste permite reducir este valor.

Figura 12: Comparación entre precipitaciones en terreno y precipitaciones ajustadas para sensor GPM, Clúster 2

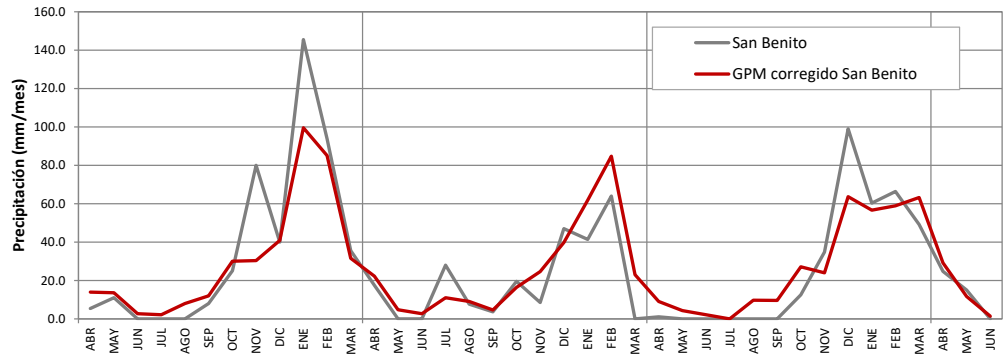

Fuente: Elaboración propia. 2025

La ecuación que permite un buen ajuste para las estaciones comprendidas en el clúster 3 es la siguiente:

$$P_c = 683.4901 + 29.2876 \cdot P_{TRMM}^{0.3345} - 5.0076 \cdot W + 52.1342 \cdot S - 0.0632 \cdot Elev$$

Las métricas estadísticas del ajuste de las estaciones terrenas con las estaciones ficticias GPM para el segundo clúster son expuestas en el siguiente cuadro:

Cuadro 10: Métricas estadísticas iniciales y después del ajuste, clúster 3 GPM

Nº	Estación	Inicial / Ajustado	Número total de datos	Desviación estándar	índice Nash-Sutclife	Raíz del error cuadrático medio	Sesgo estadístico BIAS (%)	Coeficiente de correlación de Pearson
1	Tarata	Inicial	39	48.28	-0.77	44.06	164.22	0.87
		Ajustado	39	31.94	0.74	16.77	23.79	0.86
2	Anzaldo	Inicial	39	48.40	-7.27	62.24	558.43	0.74

		Ajustado	39	21.67	0.49	15.42	34.29	0.75
3	Capinota	Inicial	39	49.15	0.41	32.60	74.38	0.85
		Ajustado	39	38.29	0.73	22.19	34.47	0.86

Fuente: Elaboración propia. 2025

Tras el ajuste de las estaciones terrenas con las estaciones ficticias GPM, se observa que se reduce el gran sesgo positivo inicial. También, los valores negativos del índice de Nash-Sutclife se convierten en positivos y más cercanos al ideal de 1.

Figura 13: Comparación entre precipitaciones en terreno y precipitaciones ajustadas para sensor GPM, Clúster 2

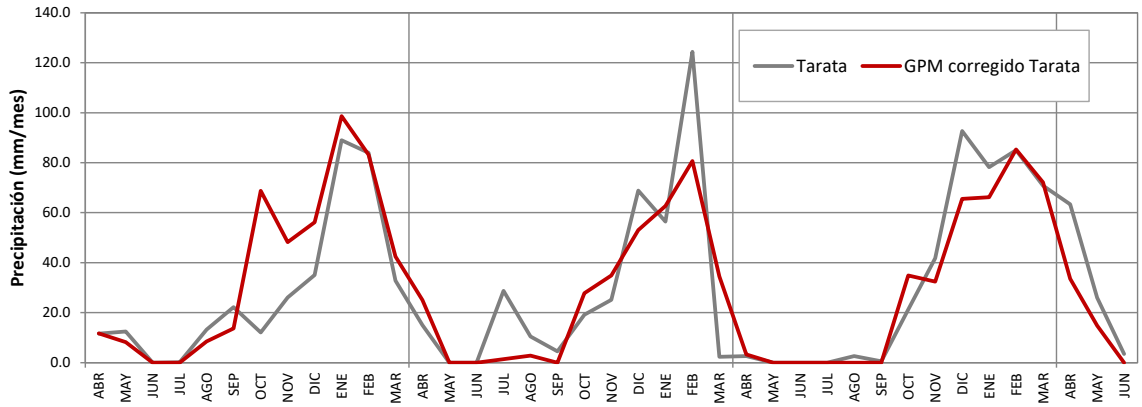

Fuente: Elaboración propia. 2025

Estaciones ficticias gpm

En base al tamaño de las grillas otorgadas por las imágenes del sensor GPM (0. 1°x0.1°), se definen las coordenadas de las estaciones ficticias GPM, posteriormente, se asigna a la estalación a un clúster para su respectiva corrección.

Figura 14: Estaciones ficticias GPM

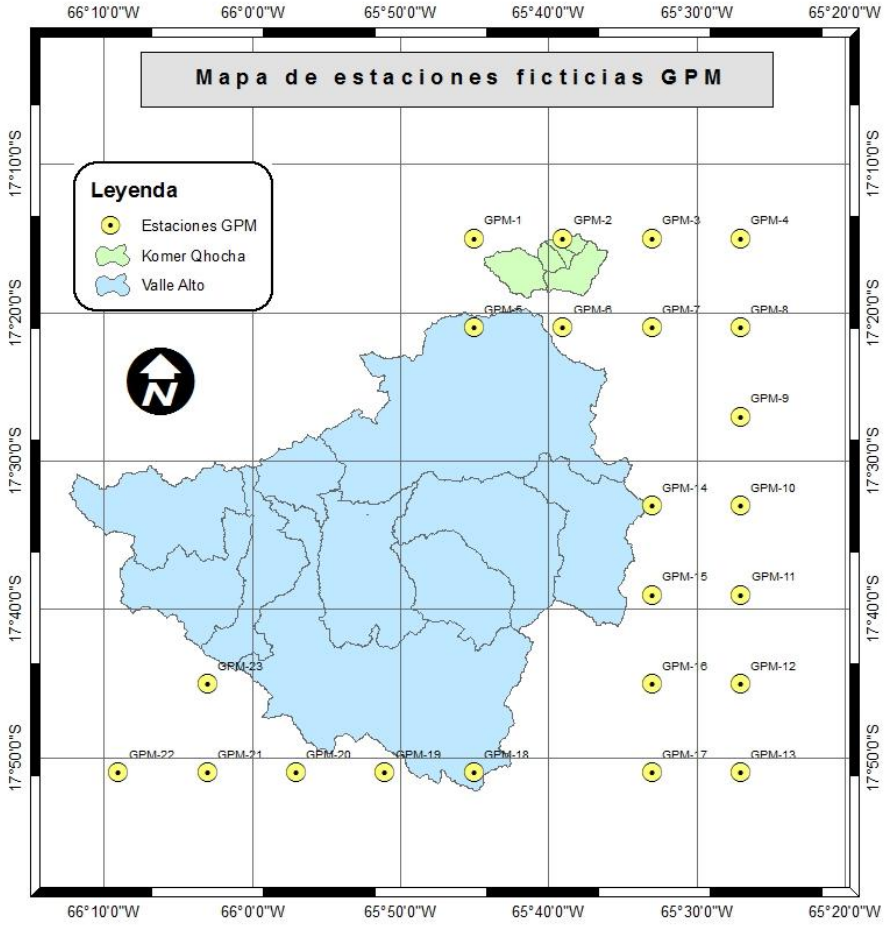

Fuente: Elaboración propia. 2025

En base a las coordenadas y los datos descargados para el sensor GPM, se calculan las precipitaciones corregidas para las estaciones ficticias.

Figura 15: Estación GPM-1, clúster 1

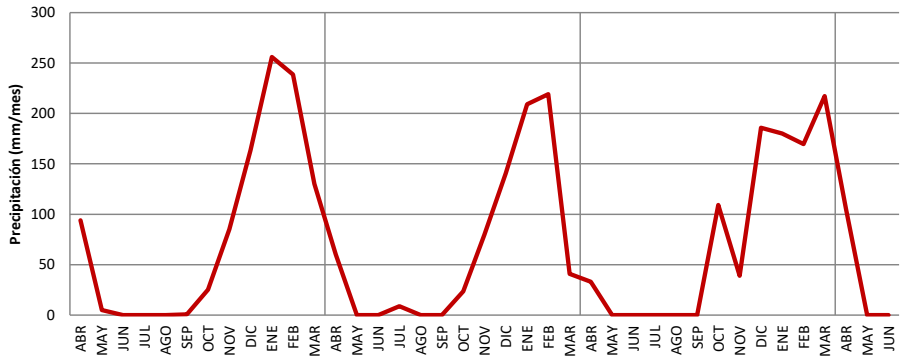

Fuente: Elaboración propia. 2025

Figura 16: Estación GPM-9, clúster 2

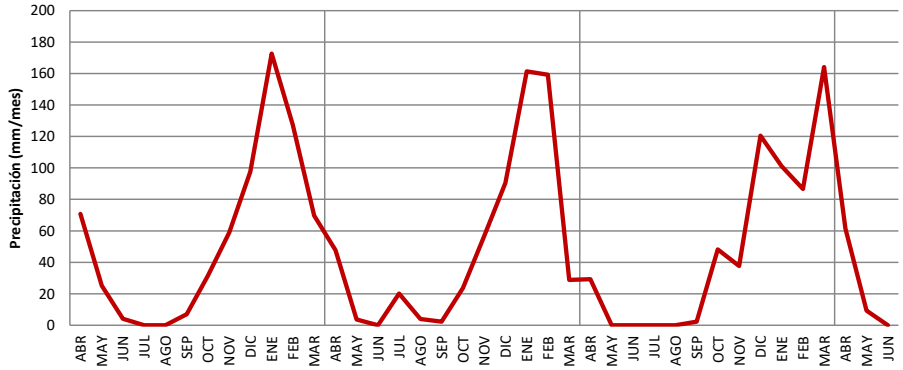

Fuente: Elaboración propia. 2025

Figura 17: Estación GPM-11, clúster 3

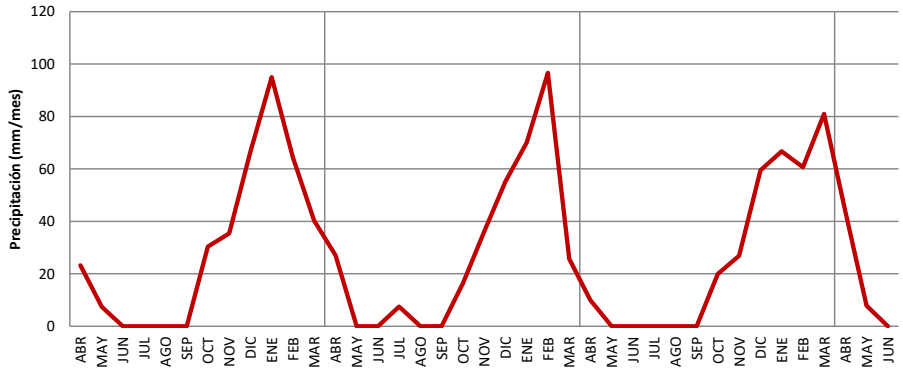

Fuente: Elaboración propia. 2025

Precipitación en las cuencas de estudio

Con la base de datos de las estaciones del SENAMHI, ENDE, GPM y TRMM, se elaboraron mapas de precipitaciones promedio para cada mes, para el periodo en el cual existe mayor cantidad de información (2014 – 2023). Es importante notar que hay un patrón común en las precipitaciones, mostrando en cada mes que el mayor volumen de precipitación se produce en Komer Qhocha.

CONCLUSIONES

Los productos de precipitación estimada desde satelitales: TRMM, GPM fueron evaluados en la cuenca del Valle Alto y Komer Qhocha, para el periodo 2014-2023. Ambos productos presentan una tendencia general a sobrestimar la precipitación medida en tierra, de hasta el 20%. No obstante, se observó que ambos productos coinciden que la zona este presenta mayor precipitación.

En el caso de los procesos de elaboración del producto combinado, se observa que la tendencia de corrección se da a la subestimación de valores. En ciertos periodos y subcuencas, no es necesario realizar más de 3 iteraciones que permitan corregir los datos, pero en los casos que muestran un mayor error.

Ambos productos desarrollados presentan un margen de error muy bajo con respecto a los datos de SENAMHI. Por un lado, TRMM subestima ligeramente el valor general de las precipitaciones en la toda la cuenca de estudio, teniendo valores menores al 5% de error.

Por el otro lado, GPM presenta una ligera sobreestimación en la cuenca de estudio, presentando valores de error relativo en el rango del 5%. GPM aun arrastra ciertos problemas de subestimación de su producto base en la cuenca, llegando a un 40% de error máximo en ella.

El producto generado en este estudio, ajustado entre TRMM, GPM y los datos de SENAMHI, ha demostrado una mejoría notoria espacial y temporal. Este producto ha sido evaluado con la precipitación grillada GPM. Realizando dicho producto combinado, se podría realizar un análisis del comportamiento de ajuste entre ambos productos, determinar si alguno de ellos presenta mejores resultados y si estos están condicionados a algún factor morfológico de la zona estudio.

REFERENCIAS BIBLIOGRAFICAS

Available: http://censosbolivia.ine.gob.bo/censofichacomunidad/c_pdfm/generar_pdf/02/01/05/x. [2018].

Earth Observation Research Center (2015), Japan Aerospace Exploration Agency (JAXA), «Global Satellite Mapping of Precipitation Microwave-IR Combined Product (GSMaP_MVK) and Gauge-calibrated Rainfall Product (GSMaP_Gauge), Reanalysis Products (GSMaP_RNL), and Gauge-calibrated Reanalysis Product (GSMaP_Gauge_RNL) Data Format Description V6, » EORC, Tsukuba, Ibaraki, Japón.

Ardila León, J. F., & Quintero Delgado, O. Y. (2013). Aplicación de la teledetección y los sistemas de información geográfica en la interpretación de zonas inundables. caso de estudio: Río Soapaga, Sector Paz de Río, Boyacá. Ciencia e Ingeniería Neogranadina.

Asurza Véliz, F. A., Cayo Ramos, L., & Lavado Casimiro, W. S. (2018 de febrero de 2018). Evaluación de los productos Tropical Rainfall Measuring Mission (TRMM) y Global Precipitation Measurement (GPM) en el modelamiento hidrológico de la cuenca del río Huancané, Perú. Scientia Agropecuaria, 53-52.

Autores, V. (2012). Redes Neuronales Artificiales. Universidad de Valencia.

Basogain Olabe, X. (2012). Redes Neuronales Artificiales y sus Aplicaciones.

Blacutt. Luis A. (2015). «Precipitation comparison for the CFSR, MERRA, TRMM3B42 and Combined Scheme datasets in Bolivia, » vol. 163,

Brameir, M., & Banzhaf, W. (2007). Linear Genetic Programming. United States of America: Springer.

Castiblanco, C. M. (2002). Manejo y Análisis de Imágenes de Satélite Aplicadas en Estudios Hidrológicos de Cuencas Mediante el SIG-GRASS. Bogotá. Universidad Nacional de Colombia.

C. Funk, P. Peterson, M. Landsfeld, D. Pedreros, J. Verdin, S. Shukla, G. Husak, J. Rowland, L. Harrison, A. Hoell y J. Michaelsen, «The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes, » 2015. [En línea]. Available: https://www.nature.com/articles/sdata201566. [2018].

Corponariño. (2008-2009). Ordenamiento del recurso hídrico. Coorporacion Autonoma Regional de Nariño.

Corrales Martinez, M. A. (2011). Balance Hidrológico. 2.

CRQ. (2016). Oferta, demanda hidrica e indice de uso del agua (IUA) de las unidades de manejo de cuenca del Departamento del Quindio. Coorporacion autonomo regional del Quindo, 2.

Erick, L. (2018). El Coeficiente de Correlación. 1-64.

Felipe del Angel, J. E., & Garcia Garcia, E. (s.f.). Precipitación. Ingeneiría Civil ITCA.

Flores Quisbert, A., Martinez Rios, Á., Lazarte Alanes, B., Viscarra Lopez, E., Zunagua Gonzales, F., Ignacio Campos, G.,Gutiérrez Choque, Z. (2016-2020). Plan territorial de desarrollo integral del Departamentode Oruro. Oruro.

Flórez López, R., & Fenández, F. J. (2012). Las Redes Neuronales Artificiales, Fundamentos Teóricos y aplicaciones prácticas.

French, M., Krajewski, W., & Cuykendall, R. (1992). Rainfall forecasting in space and time using neural network, J. Hydrol. 1-31.

Fundación Española Para la Ciencia y la Tecnología. (2004). Meteorología y Climatología. M-XXXXX-2004.

Gálvez, J., Saubes, N., Gándara, A., & Pérez, G. (2015). Balance hidrológico de las subcuencas de la República de Guatemala. Instituto de Agricultura, Recursos Naturales y Ambiente de la Universidad Rafael Landívar., 15.

Gupta, H., Sorooshian, S., & Yapo, P. O. (1999). Statusof automatic calibration for hydrologic models: Comparison with multilevel expert calibration. JournalofHydrologicEngineering, 135-143.

Gutierrez Marcillo, P. A. (2013-2014). Imagenes Satelitales. Universidad Agraria del Ecuadorescuela de Ingieneria Ambiental, 1-5.

Hernandez Cardosa, A. (2012). Algoritmos de Aprendizaje.

Hoyos, D. M. (2015). Precipitación Actual mediante datos GPM. Programa Regional de Empleo de Información, 3.

K. Takido, O. C. Saavedra Valeriano, M. Ryo, K. Tanuma, T. Ushio y T. Kubota, (2016). «Spatiotemporal Evaluation of the Gauge-Adjusted Global Satellite Mapping, » Journal of the Meteorological Society of Japan, Japón.

Ministerio de Medio Ambiente y Agua. (2016). "Estimación de demanda Hídrica Multisectorial del Sistema Titicaca – Desaguadero – Poopó – Salar de Coipasa (TDPS)". La Paz.

Ministerio de Medio Ambiente y Agua de Bolivia, (2017). Transferencia de Tecnología de GMET "Gridded Meteorological Ensemble Tool", La Paz.

Ortega, H. M. (2018). Evaluación de la influencia de la incorporación de datos de precipitación satelital (tmpa-3b42r) sobre la simulación hidrológica a escala diaria en la Cuenca alta del río Guayllabamba. 62.

Oruro, G. A. (2016). Plan Territorial de Desarrollo Integral de Oruro. Oruro.

Paguay, S. J. (julio de 2018). Evaluación del servicio ecosistémico correspondiente a la producción de agua en la Cuenca alta del Río Guayllabamba utilizando el modelo computacional invest. Quito.

Pérez, F. P., & Gutiérrez, J. F. (1987). Agua y medio ambiente. Observatorio Medioambiental.

Petrenko, B., & Spencer, R. W. (1999). Low-dimensional parameterization of the Kummerow's microwave radiative transfer model for the atmosphere with precipitation. In Geoscience and Remote Sensing Symposium.

Planeacion Ecologica Ltda y Ecoforest Ltda, (2015). «Anexo 5 - Soporte Plan de Manejo de Ordenamiento de una Cuenca, POMCA rio Bogotá. Elaboracion del Diagnóstico, Prospectiva y Formulación de la Cuenca,» mayo 2015. [En línea]. Available: https://ccxsuesca.files.wordpress.com/2015/05/anexo_5-soporte_pomca_rio_bogota.pdf.

Plataforma Giovanni (https://giovanni.gsfc.nasa.gov/giovanni/?) 2023. Agencia Espacial NASA de los Estados Unidos.

SENAMHI, (2023) «Base de Datos Sistema Meteorológico,» 2016. [En línea]. Available: http://www.senamhi.gob.bo/web/public/sismet.

SENAMHI, «Sistema Integrado de Gestión de Estaciones (SIGE),» (2023). Available: http://www.senamhi.gob.bo/web/public/sige.

T. Kubota, K. Okamoto, S. Shige, T. Ushio, T. Iguchi, N. Takahashi, K. Iwanami, K. Aonashi, M. Kachi, R. Oki y C. (2018), «The Global Satellite Mapping of Precipitation (GSMaP) Project, » 7 Diciembre 2007. [En línea]. Available: http://sharaku.eorc.jaxa.jp/GSMaP_crest/pdf/gpm_gsmap.pdf.

Trenberth et al. (2007). Estimaciones del presupuesto del agua y su ciclo anual utilizando datos de observación y modelo. Hidrometeorologia.

Universidad de Guadalajara. (2021). Obtenido de http://proton.ucting.udg.mx/posgrado/cursos/idc/neuronales2/RNArtificial.htm http://proton.ucting.udg.mx/posgrado/cursos/idc/neuronales2/RNArtificial.htm

Universidad de Windsor. (20 de octubre de 2021). Inteligencia Artificial. Redes Neuronales. Obtenido de http://www.itnuevolaredo.edu.mx/takeyas/Apuntes/Inteligencia%20Artificial

UTP, F. d. (2012). Principales Tipos de Redes Neuronales.

Villanueva Espinoza, M. d. (2012). Las Redes Neuronales Artificiales y su importancia como herramienta en la toma de decisiones.

Vallejos A. G., Ancalle S. A., Escalera A. C. y Saavedra O. V., (2018). «Analyzing Areal Precipitation at Key Basins in Cochabamba Using Satellite-Based, » 2016. [En línea]. Available: http://www.upb.edu/revista-investigacion-desarrollo/index.php/id/article/view/10/27.

Vivancos, J., Llastarri, A., Grau, M., & Vivancos, D. (2019). La tierra a la vista de satélite. Obtenido de Portada: http://concurso.cnice.mec.es/cnice2006/material121/