



MODELACION HIDROLÓGICA CON PRECIPITACIONES OBTENIDAS POR SATÉLITE EN LA CUENCA DEL RÍO RAMIS PERÚ

HYDROLOGICAL MODELING WITH PRECIPITATIONS OBTAINED BY SATELLITE IN THE RAMIS RIVER BASIN PERU

Edwin Llanque Chayña¹

¹Universidad Nacional del Altiplano–Puno Av. Floral 1153, Maestría en Recursos Hídricos.

RESUMEN

En los últimos años, muchos investigadores han orientado sus estudios a aprovechar los beneficios que se pueden obtener a través de las Estimaciones de Precipitación Basadas en Satélite (EPB), en escalas de tiempo diarias, mensuales y anuales. El uso de EPBs es una de las alternativas para solucionar el problema de las cuencas con poco o ningún instrumento. El objetivo de la investigación es evaluar estimaciones de precipitación basadas en satélites, utilizando modelación hidrológica en la cuenca del río Ramis, Perú. La evaluación se llevó a cabo durante 16 años (2003 - 2019), utilizando EPBs, Tropical Rainfall Measurement Mission (TRMM-3B42) y Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks- Climate Data Record (PERSIANN-CDR). Los resultados de la comparación con estaciones meteorológicas indican que PERSIANN-CDR es mejor que TRMM-3B42 con $r = 0,50$ y $0,38$ respectivamente. Sin embargo, el uso de las EPBs como datos de entrada en el modelo hidrológico, Herramienta de Evaluación de Suelos y Aguas (SWAT), los resultados obtenidos calibrados para TRMM-3B42 son insatisfactorios, con $r = 0,77$, $NSE = -0,24$ y el porcentaje de sesgo $PBIAS = 56,50 \%$, para PERSIANN-CDR con $r = 0,63$, $NSE = -0,01$ y $PBIAS = 62,30 \%$. Obteniendo un buen resultado $r = 0,86$ y $NSE = 0,73$ al utilizar las medidas de las estaciones meteorológicas. La evaluación de los datos de entrada en el modelo hidrológico muestra la magnitud del error de los EPBs, cuyos datos de entrada deben ser corregidos antes de ser utilizados.

Palabras clave: Cuenca del río Ramis, modelización hidrológica, productos de precipitación satelital, PERSIANN-CDR, TRMM-3B42.

ABSTRACT

In recent years, many researchers have targeted their studies to take advantage the benefits that can be obtained through Satellite-based Precipitation Estimates (EPBs), on daily, monthly and annual time scales. The use of EPBs is one of the alternatives to solve the problem of basins with little or any instruments. The research objective is to evaluate precipitation estimates based on satellites, using hydrological modeling in the Ramis river basin, Peru. The evaluation was carried out during 16 years (2003 - 2019), using EPBs, Tropical Rainfall Measurement Mission (TRMM-3B42) and the Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks- Climate Data Record (PERSIANN-CDR). The results of the comparison with weather stations indicate that PERSIANN-CDR is better than TRMM-3B42 with $R^2 = 0.50$ and 0.38 respectively. However, using the EPBs as input data in the hydrological model, Soil and Water Assessment Tool (SWAT), the results obtained calibrated for TRMM-3B42 are unsatisfactory, with $r = 0.77$, $NSE = -0.24$ and the percentage bias ($PBIAS = 56.50 \%$), for PERSIANN-CDR with $r = 0.63$, $NSE = -0.01$ and $PBIAS = 62.30 \%$. Obtaining a good result $r = 0.86$ and $NSE = 0.73$ when using the measurements of the meteorological stations. The evaluation of input data in the hydrological model show the magnitude of the EPBs error, which input data must would be corrected before being used.

Keywords: Ramis River Basin, Hydrological Modeling, Satellite Precipitation Products, PERSIANN-CDR, TRMM-3B42

*Autor para correspondencia: chayña.nestor@gmail.com

ORCID:



INTRODUCCIÓN

La precipitación es un componente principal del ciclo hidrológico. Medidos a través de instrumentos basados en pluviómetros terrestres (Shen *et al.* 2022). Para su análisis en los recursos hídricos se debe contar con datos temporales fiables con buena calidad, por la falta de cobertura de estaciones hidrometeorológicas se recurre a otras fuentes para completar la información (Lakew *et al.* 2017). Información que proviene de imágenes satelitales con dificultades que tienen variabilidad temporal y espacial de la precipitación (Ibrahim *et al.* 2017 ; Gebregiorgis & Hossain 2013). Es preciso conocer las debilidades y fortalezas de las precipitaciones estimadas por satélite y ver si resulta ser útil (Paredes *et al.* 2016). El desafío es mejorar la estimación de precipitación en áreas con pocos pluviómetros distribuidos de manera desigual (Liu *et al.* 2022). Los productos de precipitación remota TRMM y PERSIANN en comparación con las observaciones pluviométricas, los productos de precipitación de sensores remotos pueden subestimar o sobrestimar la precipitación (Sun *et al.* 2018).

La cobertura con observaciones de satélites geoestacionarios ofrece la técnica de llenar los vacíos de las precipitaciones superficiales en áreas donde existe escasez de observaciones (Solimine *et al.* 2022). Un ejemplo es la Misión de Medición de Precipitaciones Tropicales de Estados Unidos y Japón (TRMM) lanzado al público en varias versiones de resoluciones temporales y espaciales como el TRMM 3B42 V7, y Estimación de precipitaciones a partir de información de sensores remotos utilizando redes neuronales artificiales – registro de datos climáticos. (PERSIANN-CDR) (Zhang *et al.* 2022). Estos se encuentran disponibles gratuitamente al público por lo que se promueve en gran medida su aplicación (Xiang *et al.* 2021). Algunos investigadores realizan comparaciones exhaustivas, la mayoría de los estudios se centraron en evaluar el rendimiento de los productos, generalmente tiene los mejores desempeños TRMM 3B42 muchos de ellos tienen comentarios útiles y hallazgos valiosos (Keikhosravi *et al.* 2020). El más utilizado con mejor rendimiento debido a su alta resolución espacio-temporal (0,25 x 0,25) para monitorear las ocurrencias de las precipitaciones con mayor precisión (Lin *et al.* 2022).

Los productos de precipitación históricos están diseñados para realizar estudios hidrológicos que requieren datos a largo plazo y coherentes para el análisis de tendencias (Huang *et al.* 2021). La precisión de los productos en las simulaciones en escorrentías aún se desconocen estos productos requieren evaluaciones en simulaciones hidrológicas (Eini *et al.* 2022). Con respecto a las precipitaciones estimadas por satélite está sujeto a las limitaciones como la incertidumbre (Shen *et al.* 2022). Es necesario conocer los caudales para evaluar la disponibilidad de agua en un punto de interés, realizando la simulación de la escorrentía con el modelo hidrológico SWAT es un modelo hidrológico semidistribuido (Charles *et al.* 2022). La herramienta de Evaluación de Suelo y Agua (SAWT) es usada de manera amplia para simular la cantidad de agua en cuencas hidrográficas, discretizando en respuestas de unidades hidrográficas (HRU) para representar la homogeneidad del tipo de suelo y uso de suelo en la cuenca (Huang *et al.* 2021).

Este análisis está representado en la ecuación de SWAT que refleja el equilibrio hidrológico para cuantificar la disponibilidad de la escorrentía superficial (Ding *et al.* 2022). La herramienta SWAT-CUP es utilizada generalmente para la validación y calibración automática del modelo SWAT, se calibran con respecto a los caudales observados (registrados) (Song *et al.* 2022). El estudio se realizó la calibración y validación en la versión 5.2.1 de ajustes e incertidumbre secuenciales (SUFI-2) de SWAT-CUP. Para facilitar el procedimiento en la calibración más precisa se utilizó caudales diarios, también se aplicó el conjunto de datos de las precipitaciones observadas de los pluviómetros que sirvió para la comparación (Mtibaa & Asano 2022).

Los parámetros utilizados para el proceso de calibración que gobiernan la incertidumbre de SWAT-CUP de uso común y sus rangos se realiza en base a funciones objetivas para asegurar que los resultados de la simulación sean lo más parecido posible a las observadas (Jimeno-Sáez *et al.* 2022). Para la evaluación de la incertidumbre se realiza mediante el criterio conocido de P factor, lo que nos da a conocer de los datos medidos que se encuentran dentro de la banda de incertidumbre del 95 % (95PPU) (Valeh *et al.* 2021).

Los objetivos de esta investigación son:

- Evaluar los datos de precipitación estimada por satélite TRMM-3B42 y PERSIANN-CDR con mediciones pluviométricas.
- Evaluar los datos de precipitación estimada por satélite TRMM-3B42 y PERSIANN-CDR como entrada en la modelación hidrológica.

MATERIALES Y MÉTODOS

Lugar de Estudio

La cuenca del río Ramis (CRR), está ubicada al sur de Perú en el departamento de Puno. La CRR se extiende desde el extremo sur latitud 14°03'26.6'' - 15°27'33.7'' y longitud oeste 69°25'26.4'' - 71°07'04.7'', cubriendo una extensión de 14596.284 km². La altitud de la CRR varía entre 3797 a 5743 m.s.n.m.

Hidrográficamente la CRR se ubica en la región hidrográfica del Titicaca, sistema hídrico Titicaca, Desaguadero, Poopo y Salar (TDPS). El límite de la cuenca desde aguas abajo inicia en la estación hidrométrica puente Ramis y su ubicación geográfica se encuentra en la latitud sur 15°15'19.11'' y longitud oeste 69°52'25.63''. En consecuencia, su recorrido hacia aguas abajo de la estación hidrométrica, se une con el río Huancané y en seguida desemboca al lago Titicaca.




Figura 1. Localización geográfica de la cuenca Ramis.

Descripción de Métodos

La muestra corresponde al registro de precipitaciones y temperaturas diarias de 17 años (enero del 2003 a diciembre del 2019) de las estaciones (Ananea, Arapa, Ayaviri, Azángaro, Chuquibambilla, Cojata, Crucero, Cuyo Cuyo, Huancané, Huaraya Moho, Juliaca, Lampa, Llally, Macusani, Muñani, Pampahuta, Progreso, Pucara, Putina, Santa Rosa y Taraco) que se ubican dentro y alrededor de la CRR, las estaciones meteorológicas son de tipo climatológica ordinaria (CO) y son de propiedad del SENAMHI. El mismo periodo de

datos fue considerado para los caudales medios diarios de la estación hidrométrica Ramis

- Se utilizó el modelo digital de elevación (DEM) de la Misión Topográfica Shuttle Radar (SRTM), satélite de observación de la tierra de la misión NASA y otros organismos como la Agencia Nacional de Inteligencia Geoespacial. El DEM se obtuvo de la página (<https://earthexplorer.usgs.gov/>). La información utilizada, es de 1 segundo de arco (~30 metros) (Roa Lobo & Kamp 2008). La resolución espacial DEM es uno de los factores más cruciales para modelar (Avand *et al.* 2022). Los DEM con las mismas resoluciones también fueron utilizados en las investigaciones de (Meza 2020), (Monteiro *et al.* 2018) y (Siev *et al.* 2016) obteniendo buenos resultados.
- El espectrorradiométrico de imágenes de resolución moderada (MODIS) de la NASA Terra Snow Cover proporciona albedo diario a una resolución de 500 metros (Sproles *et al.* 2020). Los datos de cobertura terrestre o uso de la tierra MCD12Q1 de nivel 3 es el conjunto de datos de cobertura terrestre de MODIS (Figura 5b). Son datos de observación anuales procesados de los satélites Terra y Aqua aplicados para representar los tipos de cobertura terrestre (Liang *et al.* 2015).
- Clase de suelo información proporcionada del mapa digital de suelos del mundo (DSMW), que es proporcionado la Organización de las Naciones Unidas para la Agricultura y la Alimentación (FAO), conjunto de datos que contiene características relacionados a la textura del suelo incluye las propiedades del suelo.

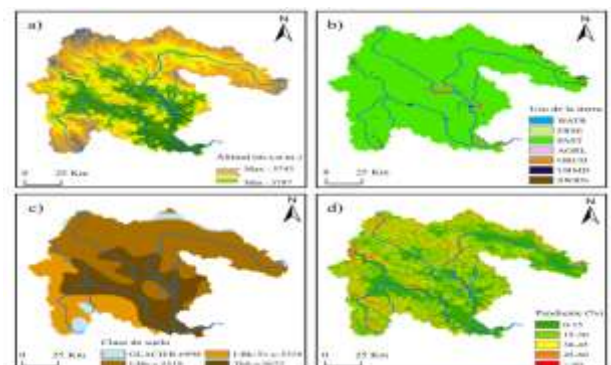


Figura 2. Características de a) altitud, b) uso de la tierra, c) clase de suelo y d) pendiente.

A los datos de precipitación, se verifica la homogeneidad eliminando las

perturbaciones de los registros de datos crudos que no han tenido el suficiente cuidado al momento de ser registro. cuando esto se presenta se hace ajustes con estimaciones estadísticas corrigiendo los cambios del comportamiento lo más cerca posible a los parámetros observados. Para el control de calidad de datos climatológicos se usa el paquete Climatol disponible para R, trabaja con datos diarios y se puede aplicar a diferentes variables climáticas con una tolerancia de datos faltantes muy alta (Pino-Vargas *et al.* 2022). Dentro de su análisis estadístico se encuentra la aplicación Standard Normal Homogeneity Test (SNHT) que comprueba la homogeneidad de los datos, esta prueba tiene el poder de detección que rellena los datos ausentes en todas las series y sub-series homogéneas. su operación se complica a través de una serie de procesos iterativos anidados (Guijarro 2018). Climatol utiliza el método de Paulhus & Kohler (1952), para completar los datos diarios mediante promedios de valores normalizados mediante división por sus respectivos valores medios. Asimismo, se puede obtener restando las medias o la estandarización completa denominado la media y desviación típica de una serie. Climatol analiza los datos con los parámetros disponibles en cada serie. Vuelve a calcular con las series rellenas que dará lugar a nuevas medidas y desviaciones típicas provisionales, repitiendo el proceso hasta redondear la precisión inicial de los datos.

Para la evaluación de los datos de precipitación estimada por satélite TRMM-3B42 y PERSIANN-CDR, utilizamos mediciones de temperatura máxima, temperatura mínima del aire como entradas al modelo hidrológico SWAT. ArcSWAT es una extensión e interfaz de ArcGIS (disponible en: <https://swat.tamu.edu/>) es un modelo hidrológico conceptual y semidistribuido, que simula datos de tiempo diario, las variables de entrada que utiliza el modelo SWAT son: 1) modelo de elevación

digital (DEM) que dividirá en cuencas y URH, 2) mapa de uso de tierra y 3) mapa de suelo (Vu *et al.* 2018). Uno de los primeros es delimitar la cuenca con el DEM y el punto de aforo de la estación hidrométrica, seguidamente se obtienen las unidades de respuesta hidrológica (HRU) que son áreas homogéneas en términos de uso de la tierra, clase de suelos y pendiente (Van *et al.* 2020), se utiliza también la dirección de flujo (DIR) proveniente del DEM y la acumulación de flujo (ACC) (Tam *et al.* 2019).

La base de datos ArcSWAT original SWAT2012.mdb que por defecto se instala en "C:\SWAT\ArcSWAT\Databases", es la base de datos disponible solo para Estados Unidos (EE. UU). La base de datos clase de suelo que utilizamos, corresponde a los datos del suelo mundial de la FAO, para modificar la base original de ArcSWAT utilizamos QGIS y SWAT Editor (disponible en: <https://swat.tamu.edu/>) que proporcionan la base de datos del suelo mundial de la FAO dentro de QSWATRef2012.mdb (usersoil).

Para el proceso de calibración, Healy & Essaid (2012) menciona que se debe seguir los siguientes pasos: Primero para el proceso de calibración y validación en SWAT es conveniente determinar los parámetros más sensibles con respecto a las entradas del modelo. La sensibilidad de un parámetro a menudo depende del valor de otros parámetros relacionados, con una desventaja que necesita un gran número de simulaciones. Para el proceso de calibración, utilizamos la herramienta de auto calibración SWAT - CUP (Calibration and Uncertainty Programs For SWAT) con el algoritmo Sequential Uncertainty Fitting 2 (SUFI - 2). Se tomó en cuenta 16 parámetros y sus rangos respectivos de acuerdo a van Griensven *et al.* (2006) y Neitsch *et al.* (2002). Entre los 16 parámetros, 9 gobiernan la respuesta del agua superficial y subterránea en SWAT, y los otros 7 parámetros gobiernan la respuesta de la cuenca (X. Zhang *et al.* 2008) (Tabla 1).

Tabla 1*Parámetros iniciales para calibración en el modelo SWAT.*

Parámetro	Descripción	Rango
Parámetros que gobiernan la respuesta del agua superficial		
1 <i>CN2</i>	Numero de curva	$\pm 20 \%$
2 <i>ESCO</i>	Factor de compensación de la evaporación del suelo	0 – 1
3 <i>SOL_AWC</i>	Capacidad de agua del suelo disponible	$\pm 20 \%$
Parámetros que gobiernan la respuesta del agua subterránea		
4 <i>GW_REVAP</i>	Coefficiente de reevaporación de agua subterránea	0,02 – 0,2
5 <i>REVAPMN</i>	Profundidad umbral del agua en el acuífero poco profundo para que se produzca la reevaporación (mm).	0 - 500
6 <i>GWQMN</i>	Umbral de profundidad del agua en el acuífero poco profundo requerido para que ocurra el flujo de retorno (mm)	0 – 5000
7 <i>GW_DELAY</i>	Retraso de aguas subterráneas (días)	0 – 50
8 <i>ALPHA_BF</i>	Constante de recesión de flujo base	0 – 1
9 <i>RCHRG_DP</i>	Fracción de percolación de acuíferos profundos	0 - 1
Parámetros que gobiernan la respuesta de la cuenca		
10 <i>CH_K2</i>	Conductividad hidráulica efectiva en aluvión del canal principal (mm h^{-1})	-0,01 - 150
11 <i>TIMP</i>	Factor de retraso de la temperatura de la capa de nieve	0 – 1
12 <i>SURLAG</i>	Coefficiente de retraso de la escorrentía superficial (día)	0 – 10
13 <i>SFTMP</i>	Temperatura base del derretimiento de la nieve ($^{\circ}\text{C}$)	0 – 5
14 <i>SMTMP</i>	Temperatura de las nevadas ($^{\circ}\text{C}$)	0 – 5
15 <i>SMFMX</i>	Factor de deshielo máximo para el 21 de junio ($\text{mm H}_2\text{O } ^{\circ}\text{C}^{-1} \text{ día}^{-1}$)	0 - 10
16 <i>SMFMN</i>	Factor de deshielo mínimo para el 21 de diciembre ($\text{mm H}_2\text{O } ^{\circ}\text{C}^{-1} \text{ día}^{-1}$)	0 - 10

Fuente: Zhang *et al.* (2008).**Método estadístico**

Para la calibración del modelo se requiere identificar parámetros que son más sensibles a cambios en sus valores, de modo que una variación mínima generaría cambios significativos en los resultados finales (Perez *et al.* 2017). Para evaluar la etapa de validación se utilizan los valores óptimos de los parámetros calibrados Wörner *et al.* (2019). La idoneidad de los datos de precipitación obtenidos por satélite PERSIANN-CDR y TRMM 3B42 para la simulación de caudales se evaluó utilizando el coeficiente de correlación (r), la raíz del error medio cuadrático (RMSE), la eficiencia de Nash (NSE), el porcentaje de sesgo (PBIAS) y el índice de concordancia (d) establecidas por (Moriassi *et al.* 2015).

RESULTADOS Y DISCUSIÓN

Para evaluación de los datos de precipitación estimada por satélite TRMM-3B42 y PERSIANN-CDR con mediciones pluviométricas basados en los resultados de análisis estadístico se puede apreciar que el coeficiente de correlación (r) al ser comparado entre los datos de precipitación observada y PERSIANN-CDR dio un valor mínimo ($r=0,23$; Macusani) y máximo ($r=0,50$; Pampahuta) y para el producto TRMM-3B42 los valores mínimos y máximos son de $r=0,06$ y $r=0,38$ respectivamente (Tabla 2). Una serie de diagramas de dispersión entre valores de

precipitación observada comparado con PERSIANN-CDR y TRMM-3B42 revelaron la relación de los productos de precipitación satelital. Los coeficientes de correlación lineal entre las EPBS y los datos de la estación meteorológica son bajos y los valores están sesgados.

En cuanto a error, la RMSE para PERSIANN-CDR dio como resultado valores de error más bajo de 4,41 mm/día para la estación Taraco y más alto de 7,09 mm/día para la estación Macusani, mientras que para TRMM-3B42 el RMSE más bajo fue 5,36 mm/día para la estación Cojata y el más alto 11,33 mm/día para la estación Macusani (Tabla 2).

Las EPBS PERSIANN-CDR al ser evaluados con la NSE se puede apreciar que, para el conjunto de estaciones, varía entre $NSE = -1.84$ y $NSE = 0,17$, siendo el más bajo para la estación Crucero y el más alto para la estación Pampahuta. Para TRMM-3B42 los valores de NSE oscilan entre -6,15 (Macusani) y -0,23 (Huaraya Moho). Según las discreciones de Moriasi *et al.* (2015) estos resultados serían “no

satisfactorios” ($NSE \leq 0,50$). Así también, para PBIAS, los resultados obtenidos de las EPBS PERSIANN-CDR y TRMM 3B42 están fuera del umbral $PBIAS \geq \pm 15$ establecido por Moriasi *et al.* (2015) encontrándose una sobre y subestimación de la precipitación por parte de las EPBS (Tabla 2).

Para los valores de aproximación del índice de concordancia (d) para PERSIANN-CDR indica una coincidencia entre 0,43 (Macusani) y 0,68 (Pampahuta), mientras que para TRMM-3B42 una coincidencia entre 0,17 (Apara) y 0,53 (Pampahuta) (Tabla 2).

En un trabajo similar, Liu *et al.* (2022) evaluó la estimación de precipitación para áreas con escasez de datos en la meseta de Qinghai-Tbet los resultados de RMSE es de 2,5% y un 4,5% respectivamente en comparación con los datos TRMM y datos pluviométricos, así mismo Eini *et al.* (2022) en la evaluación de producto PERSIANN en la estimación de precipitación presentan similitudes bastantes bajas, $RMSE = 3,76$ mm (PERSIANN-CDR).

Tabla 2

Resultados de indicadores estadísticos.

Estación	PERSIANN - CDR					TRMM - 3B42				
	r	RMSE	NSE	PBIAS	d	r	RMSE	NSE	PBIAS	d
Ananea	0,31	5,16	-0,90	82,40	0,52	0,19	7,11	-2,61	89,90	0,38
Arapa	0,39	4,77	-0,27	85,70	0,59	0,06	10,41	-5,04	68,40	0,17
Ayaviri	0,47	4,73	-0,14	67,10	0,65	0,38	7,83	-2,12	103,70	0,51
Azángaro	0,38	5,01	-0,41	89,20	0,58	0,26	7,56	-2,22	97,90	0,42
Chuquibambilla	0,47	4,89	0,00	46,40	0,67	0,37	7,91	-1,61	78,50	0,53
Cojata	0,37	4,87	-0,52	66,80	0,58	0,25	5,36	-0,84	10,60	0,48
Crucero	0,27	5,80	-1,84	155,60	0,45	0,20	8,73	-5,44	149,70	0,31
Cuyo Cuyo	0,29	5,75	-1,83	105,80	0,48	0,22	8,59	-5,32	87,90	0,33
Huancané	0,39	4,92	-0,18	71,00	0,59	0,26	5,98	-0,74	34,50	0,48
Huaraya Moho	0,36	5,75	0,03	16,80	0,55	0,23	6,47	-0,23	-28,70	0,45
Juliaca	0,44	4,53	0,00	48,00	0,63	0,27	7,72	-1,92	55,20	0,43
Lampa	0,49	4,46	0,12	28,90	0,67	0,32	8,18	-1,94	60,90	0,48
Llally	0,47	4,92	-0,01	49,20	0,66	0,37	8,44	-1,97	92,60	0,51
Macusani	0,23	7,09	-1,80	147,00	0,43	0,13	11,33	-6,15	168,40	0,24
Muñani	0,35	5,05	-0,51	88,70	0,57	0,25	6,95	-1,86	83,10	0,44
Pampahuta	0,50	4,62	0,17	29,30	0,68	0,38	8,28	-1,69	73,00	0,53
Progreso	0,36	5,31	-0,57	99,40	0,57	0,29	7,82	-2,41	110,10	0,44
Pucara	0,44	4,83	-0,01	46,60	0,64	0,32	8,18	-1,88	66,30	0,48
Putina	0,39	4,87	-0,47	90,30	0,59	0,27	6,85	-1,91	84,70	0,45
Santa Rosa	0,46	5,07	-0,21	57,40	0,65	0,37	7,85	-1,89	75,50	0,52
Taraco	0,43	4,41	-0,08	64,80	0,62	0,28	5,75	-0,84	43,00	0,49

Se consideraron 16 parámetros para la calibración del modelo SWAT. Se realizaron 50, 100, 500 y 1000 iteraciones utilizando la función objetivo Nash-Sutcliffe (NSE). Aunque es posible utilizar el Error Cuadrático Medio “MSE”, CHI2, bR2, PBIAS, SSQR, eficiencia de Kling-Gupta (KGE), RSR y modificación de NS (MNS), Nash-Sutcliffe (NSE) dio mejores resultados. El número de iteraciones en el cual se alcanzó un mayor NSE fue en la iteración 371 para PERSIANN-CDR de un total de 1000 iteraciones, para TRMM-3B42 fue en la iteración 247 de un total de

500 iteraciones y para los datos observados de precipitación fue en la iteración 16 de un total de 50 iteraciones. Encontramos que cuando se utilizan datos de precipitación observada, el número de iteraciones es menor que cuando se utilizan las EPBS, la selección de los parámetros para el análisis de sensibilidad y calibración se consideraron las siguientes estudios (Jimeno-Sáez *et al.* 2022 ; Swain *et al.* 2022 ; Admas *et al.* 2022), Jiang *et al.* (2022)) en base a los rangos . Los parámetros calibrados se presentan en la Tabla 3.

Tabla 3

Parámetros calibrados del modelo SWAT.

Parámetros	Extensión	Valores				
		Min.	Max.	Observado	PERSIANN-CDR	TRMM-3B42
CN2	.mgt	-0,2	0,2	0,14	-0,139	-0,1516
SOL_AWC(..)	.sol	-0,2	0,2	-0,036	-0,0666	-0,1796
GW_REVAP	.gw	0,02	0,2	0,1226	0,18425	0,1901
REVAPMN	.gw	0	500	225	337,75	73,50
GWQMN	.gw	0	5000	3650	4902,50	4045
GW_DELAY	.gw	0	50	19,50	38,725002	1,85
ALPHA_BF	.gw	0	1	0,21	0,3395	0,141
RCHRG_DP	.gw	0	1	0,91	0,0935	0,095
CH_K2	.rte	-0	150	97,4965	111,372429	124,648315
SURLAG	.hru	0	10	7,30	5,645	4,87
ESCO	.hru	0	1	0,25	0,1405	0,287
TIMP	.bsn	0	1	0,31	0,7205	0,123
SFTMP	.bsn	0,01	5	2,7545	0,336845	4,61577
SMTMP	.bsn	0,01	5	1,1577	3,071365	1,30241
SMFMX	.bsn	0,01	10	3,7063	0,994015	3,19681
SMFMN	.bsn	0,01	10	9,7003	3,431575	5,41459

Los indicadores estadísticos en la etapa de calibración y validación utilizando datos de entrada las EPBS dieron como resultado para PERSIANN-CDR un $r = 0,63$ (calibración) y $r = 0,59$ (validación), mientras que para TRMM-3B42 $r = 0,77$ (calibración) $r = 0,79$ (validación). En términos de error para PERSIANN-CDR

un RMSE = 89,76 (calibración) y RMSE = 99,41 (validación), mientras que para TRMM-3B42 un RMSE = 99,33 (calibración) y un RMSE = 144,49 (validación). Los hidrogramas de caudales observados y simulados mediante el uso de precipitaciones

observadas, PERSIANN-CDR y TRMM-3B42 se presenta en la Figura 3. Por otro lado, para PERSIANN-CDR la $NSE = -0,01$ (calibración) y $NSE = -0,47$ (validación), mientras que para TRMM-3B42 $NSE = -0,24$ (calibración) y $NSE = -2,1$ (validación). En cuanto al sesgo, los resultados para PERSIANN-CDR dieron un $PBIAS = 62,3 \%$ (calibración) y un $PBIAS = 89,3 \%$ (validación), mientras que para TRMM-3B42 un $PBIAS = 56,5 \%$ (calibración) y $PBIAS = 123,8 \%$ (validación). Según las discreciones de Moriasi *et al.* (2015) estos resultados serían “no satisfactorios” cuando se evalúa con NSE ($NSE \leq 0,50$). Así también, para $PBIAS$, los resultados obtenidos de las EPBS PERSIANN-CDR y TRMM 3B42 están fuera del umbral $PBIAS \geq \pm 15$ establecido por Moriasi *et al.* (2015) encontrándose una sobreestimación de la precipitación por parte de las EPBS (Tabla 4). Las EPBS TRMM-3B42 y PERSIANN-CDR no representan adecuadamente los caudales en la cuenca del río Ramis Perú. Lujano Laura *et al.* (2015) al utilizar datos de entrada el producto TRMM mensual, obtuvo resultados satisfactorios en la simulación de caudales del río Ramis, llegando a un $NSE = 0,78$ (calibración) y $NSE = 0,75$ (validación), los estudios de Ancoco & Tancayllo (2019) con información pluviométrica recopilada de la cuenca Ramis en la evaluación hidrología se obtuvieron los siguientes

resultados $NSE = 0,76$ (calibración) y $NSE = 0,79$ (validación).

Así también, el índice de concordancia (d) dio como resultado para PERSIANN-CDR $d = 0,74$ (calibración) y $d = 0,70$ (validación), mientras que para TRMM-3B42 $d = 0,80$ (calibración) y $d = 0,70$ (validación).

Por otro lado, al utilizar datos de precipitación observada se tuvo un coeficiente de correlación $r = 0,86$ en la etapa de calibración y un $r = 0,87$ en la etapa de validación, un $RMSE = 46,64$ (calibración) y un $RMSE = 41,23$ (validación), una $NSE = 0,73$ (calibración) y $NSE = 0,75$ (validación), un $PBIAS = -15,4$ (calibración) y la validación $1,7$ (validación). Estos resultados son “buenos” según las discreciones de Moriasi *et al.* (2015) ($0,70 < NSE \leq 0,80$). Así también, para $PBIAS$, los resultados obtenidos son satisfactorios para etapa de calibración ($\pm 10 \leq PBIAS < \pm 15$) y muy bueno para la etapa de validación ($PBIAS < \pm 5$), (Tabla 4).

Revelan algunos estudios los resultados de PERSIANN- CDR la calibración ($PBIAS = -43$) y para la etapa de validación ($PBIAS = -51$) (Eini *et al.* 2022). Los resultados estadísticos de rendimiento del modelo para TRMM la calibración ($PBIAS = -19,10$) y para la etapa de validación ($PBIAS = -24,80$) (Singh & Saravanan 2020).




Figura 3. Hidrograma de caudales observados y simulados mediante el uso de a) precipitaciones observadas, b) PERSIANN-CDR, c) TRMM-3B42.

Tabla 4

Indicadores estadísticos para las simulaciones de caudal utilizando diferentes conjuntos de datos de lluvia.

Indicador estadístico	Observado		PERSIANN -CDR		TRMM-3B42	
	Calibración	Validación	Calibración	Validación	Calibración	Validación
r	0,86	0,87	0,63	0,59	0,77	0,79
RMSE	46,64	41,23	89,76	99,41	99,33	144,49
NSE	0,73	0,75	-0,01	-0,47	-0,24	-2,1
PBIAS (%)	-15,4	1,7	62,3	89,3	56,5	123,8
d	0,91	0,93	0,74	0,7	0,8	0,7

CONCLUSIONES

- Al evaluar las estimaciones de precipitaciones diarias basadas en satélite PERSIANN-CDR y TRMM con datos de las estaciones meteorológicas, encontramos que los datos de satélite no brindan precipitaciones confiables sobre la cuenca del río Ramis, mostrando errores altos y valores sesgados.
- El uso de las estimaciones de precipitaciones diarias basadas en satélite PERSIANN-CDR y TRMM como entrada en el modelo hidrológico SWAT revelaron que ambos productos no muestran rendimientos adecuados para simular caudales en la cuenca del río Ramis.

AGRADECIMIENTOS

A la Universidad Nacional del Altiplano Puno
A la Escuela de Posgrado, Maestría en Recursos Hídricos.

REFERENCIAS

- Admas, B. F., Gashaw, T., Adem, A. A., Worqlul, A. W., Dile, Y. T., & Molla, E. (2022). Identification of soil erosion hot-spot areas for prioritization of conservation measures using the SWAT model in Ribb watershed, Ethiopia. *Resources, Environment and Sustainability*, 8(April), 100059. <https://doi.org/10.1016/j.resenv.2022.100059>
- Ancco, C., & Tancayllo, E. F. (2019). Estudio Hidrológico de la Unidad Hidrográfica del Río Ramis Memoria Final Estudio Hidrológico de la Unidad. *Autoridad Nacional Del Agua*, 01. <https://repositorio.ana.gob.pe/handle/20500.12543/4716?show=full>
- Avand, M., Kuriqi, A., Khazaei, M., &

- Ghorbanzadeh, O. (2022). DEM resolution effects on machine learning performance for flood probability mapping. *Journal of Hydro-Environment Research*, 40(June 2021), 1–16. <https://doi.org/10.1016/j.jher.2021.10.002>
- Charles, T. da S., Lopes, T. R., Duarte, N. S., Nascimento, J. G., Ricardo, H. de C., & Pacheco, A. B. (2022). *Estimating average annual rainfall by ordinary kriging and TRMM precipitation products in midwestern Brazil - ScienceDirect*. Journal of South American Earth Sciences. <https://doi.org/https://doi.org/10.1016/j.jsames.2022.103937>.
- Ding, B., Liu, H., Li, Y., Zhang, X., Feng, P., Liu, D. L., Marek, G. W., Ale, S., Brauer, D. K., Srinivasan, R., & Chen, Y. (2022). Post-processing R tool for SWAT efficiently studying climate change impacts on hydrology, water quality, and crop growth. *Environmental Modelling and Software*, 156, 105492. <https://doi.org/10.1016/j.envsoft.2022.105492>
- Eini, M. R., Rahmati, A., & Piniewski, M. (2022). Hydrological application and accuracy evaluation of PERSIANN satellite-based precipitation estimates over a humid continental climate catchment. *Journal of Hydrology: Regional Studies*, 41(April). <https://doi.org/10.1016/j.ejrh.2022.101109>
- Gebregiorgis, A. S., & Hossain, F. (2013). Understanding the dependence of satellite rainfall uncertainty on topography and climate for hydrologic model simulation. *IEEE Transactions on Geoscience and Remote Sensing*, 51(1), 704–718. <https://doi.org/10.1109/TGRS.2012.2196282>
- Guijarro, J. A. (2018). Homogeneización de series climáticas con Climatol. *Agencia Estatal de Meteorología (AEMET), D.T. En Islas Baleares, España*, 1, 22. http://www.climatol.eu/homog_climatol-en.pdf
- Healy, R. W., & Essaid, H. I. (2012). VS2DI: Model use, calibration, and validation. *Transactions of the ASABE*, 55(4), 1249–1260. <https://doi.org/10.13031/2013.42256>
- Huang, W. R., Liu, P. Y., & Hsu, J. (2021). Multiple timescale assessment of wet season precipitation estimation over Taiwan using the PERSIANN family products. *International Journal of Applied Earth Observation and Geoinformation*, 103(88), 102521. <https://doi.org/10.1016/j.jag.2021.102521>
- Ibrahim, M., Wisser, D., Ali, A., Diekkrüger, B., Seidou, O., Mariko, A., & Afouda, A. (2017). Water balance analysis over the Niger Inland Delta-Mali: Spatio-temporal dynamics of the flooded area and water losses. *Hydrology*, 4(3). <https://doi.org/10.3390/hydrology4030040>
- Jiang, D., Ao, C., Bailey, R. T., Zeng, W., & Huang, J. (2022). Simulation of water and salt transport in the Kaidu River Irrigation District using the modified SWAT-Salt. *Agricultural Water Management*, 272(July), 107845. <https://doi.org/10.1016/j.agwat.2022.107845>
- Jimeno-Sáez, P., Martínez-España, R., Casalí, J., Pérez-Sánchez, J., & Senent-Aparicio, J. (2022). A comparison of performance of SWAT and machine learning models for predicting sediment load in a forested Basin, Northern Spain. *Catena*, 212. <https://doi.org/10.1016/j.catena.2021.105953>
- Keikhosravi Kiany, M. S., Masoodian, S. A., Balling, R. C., & Montazeri, M. (2020). Evaluation of the TRMM 3B42 product for extreme precipitation analysis over southwestern Iran.

- Advances in Space Research*, 66(9), 2094–2112.
<https://doi.org/10.1016/j.asr.2020.07.036>
- Lakew, H. B., Moges, S. A., & Asfaw, D. H. (2017). Hydrological evaluation of satellite and reanalysis precipitation products in the Upper Blue Nile basin: A case study of Gilgel Abbay. *Hydrology*, 4(3).
<https://doi.org/10.3390/hydrology4030039>
- Liang, D., Zuo, Y., Huang, L., Zhao, J., Teng, L., & Yang, F. (2015). Evaluation of the consistency of MODIS land cover product (MCD12Q1) based on Chinese 30 m GlobeLand30 datasets: A case study in Anhui Province, China. *ISPRS International Journal of Geo-Information*, 4(4), 2519–2541.
<https://doi.org/10.3390/ijgi4042519>
- Lin, Q., Peng, T., Wu, Z., Guo, J., Chang, W., & Xu, Z. (2022). Performance evaluation, error decomposition and Tree-based Machine Learning error correction of GPM IMERG and TRMM 3B42 products in the Three Gorges Reservoir Area. *Atmospheric Research*, 268(December 2021), 105988.
<https://doi.org/10.1016/j.atmosres.2021.105988>
- Liu, Z., Yang, Q., Shao, J., Wang, G., & Liu, H. (2022). Improving daily precipitation estimation in the data scarce area by merging rain gauge and TRMM data with a transfer learning framework. *Journal of Hydrology*, 613(PB), 128455.
<https://doi.org/10.1016/j.jhydrol.2022.128455>
- Lujano Laura, E., Felipe Obando, O. G., Lujano Laura, A., & Quispe Aragón, J. (2015). Validación de la precipitación estimada por satélite TRMM y su aplicación en la modelación hidrológica del río Ramis Puno Perú. *Revista Investigaciones Altoandinas - Journal of High Andean Investigation*, 17(2), 221.
<https://doi.org/10.18271/ria.2015.116>
- Meza, J. C. (2020). Análisis comparativo de los modelos digitales de elevaciones SRTM y MDE-Ar 2.0 para la identificación de áreas de peligrosidad por inundaciones y anegamientos en un área urbana de llanura. *Geográfica Digital*, 17(33), 44.
<https://doi.org/10.30972/geo.17334015>
- Monteiro, E. S. V., Fonte, C. C., & de Lima, J. L. M. P. (2018). Analysing the potential of OpenStreetMap data to improve the accuracy of SRTM 30 DEM on derived basin delineation, slope, and drainage networks. *Hydrology*, 5(3), 1–27.
<https://doi.org/10.3390/hydrology5030034>
- Moriasi, D. N., Gitau, M. W., Pai, N., & Daggupati, P. (2015). Hydrologic and water quality models: Performance measures and evaluation criteria. *Transactions of the ASABE*, 58(6), 1763–1785.
<https://doi.org/10.13031/trans.58.10715>
- Mtibaa, S., & Asano, S. (2022). Hydrological evaluation of radar and satellite gauge-merged precipitation datasets using the SWAT model: Case of the Terauchi catchment in Japan. *Journal of Hydrology: Regional Studies*, 42(December 2021), 101134.
<https://doi.org/10.1016/j.ejrh.2022.101134>
- Neitsch, S. L., Arnold, J. G., & Srinivasan, R. (2002). Pesticides fate and transport predicted by the Soil and water Assessment Tool (SWAT) Atrazine, Metolachlor and Trifluralin in the Sugar Creek Watershed. *BRC Report*, 3.
- Paredes Trejo, F. J., Barbosa, H. A., Peñaloza-Murillo, M. A., Alejandra Moreno, M., & Farías, A. (2016). Intercomparison of improved satellite rainfall estimation with CHIRPS gridded product and rain gauge data

- over Venezuela. *Atmosfera*, 29(4), 323–342.
<https://doi.org/10.20937/ATM.2016.29.04.04>
- Paulhus, J. L. H., & Kohler, M. A. (1952). Monthly weather review. *Journal of the Franklin Institute*, 80(8), 129–133.
[https://doi.org/https://doi.org/10.1175/1520-0493\(1952\)080%3C0129:IOMPR%3E2.0.CO;2](https://doi.org/https://doi.org/10.1175/1520-0493(1952)080%3C0129:IOMPR%3E2.0.CO;2)
- Perez Valdivia, C., Cade Menun, B., & Mc Martin, D. W. (2017). Hydrological modeling of the pipestone creek watershed using the Soil Water Assessment Tool (SWAT): Assessing impacts of wetland drainage on hydrology. *Journal of Hydrology: Regional Studies*, 14(October), 109–129.
<https://doi.org/10.1016/j.ejrh.2017.10.004>
- Pino-Vargas, E., Chávarri-Velarde, E., Ingol-Blanco, E., Mejía, F., Cruz, A., & Vera, A. (2022). Impacts of Climate Change and Variability on Precipitation and Maximum Flows in Devil's Creek, Tacna, Peru. *Hydrology*, 9(1), 1–36.
<https://doi.org/10.3390/hydrology9010010>
- Roa Lobo, J., & Kamp, U. (2008). Modelos de Elevación Digital (MED) a partir de sistemas satelitales. Una introducción y análisis comparativo en la cordillera de Mérida-Venezuela. *Revista Geografica Venezolana*, 49(1), 11–42.
- Shen, Z., Yong, B., Yi, L., Wu, H., & Xu, H. (2022). From TRMM to GPM, how do improvements of post/near-real-time satellite precipitation estimates manifest? *Atmospheric Research*, 268(December 2021), 1–12.
<https://doi.org/10.1016/j.atmosres.2022.106029>
- Siev, S., Paringit, E. C., Yoshimura, C., & Hul, S. (2016). Seasonal changes in the inundation area and water volume of the Tonle Sap River and its floodplain. *Hydrology*, 3(4), 1–12.
<https://doi.org/10.3390/hydrology3040033>
- Singh, L., & Saravanan, S. (2020). Simulation of monthly streamflow using the SWAT model of the Ib River watershed, India. *HydroResearch*, 3, 95–105.
<https://doi.org/10.1016/j.hydres.2020.09.001>
- Solimine, S. L., Zhou, L., Raghavendra, A., & Cai, Y. (2022). Relationships between intense convection, lightning, and rainfall over the interior Congo Basin using TRMM data. *Atmospheric Research*, 273(September 2021), 106164.
<https://doi.org/10.1016/j.atmosres.2022.106164>
- Song, Y. H., Chung, E. S., & Shahid, S. (2022). Differences in extremes and uncertainties in future runoff simulations using SWAT and LSTM for SSP scenarios. *Science of the Total Environment*, 838(February), 156162.
<https://doi.org/10.1016/j.scitotenv.2022.156162>
- Sproles, E. A., Mullen, A., Hendriks, J., Gatebe, C., & Taylor, S. (2020). Autonomous aerial vehicles (AAVS) as a tool for improving the spatial resolution of snow albedo measurements in mountainous regions. *Hydrology*, 7(3), 1–16.
<https://doi.org/10.3390/hydrology7030041>
- Sun, Q., Miao, C., Duan, Q., Ashouri, H., Sorooshian, S., & Hsu, K. L. (2018). A Review of Global Precipitation Data Sets: Data Sources, Estimation, and Intercomparisons. *Reviews of Geophysics*, 56(1), 79–107.
<https://doi.org/10.1002/2017RG000574>
- Swain, S., Mishra, S. K., Pandey, A., Pandey, A. C., Jain, A., Chauhan, S. K., & Badoni, A. K. (2022). Hydrological modelling through SWAT over a Himalayan catchment using high-resolution geospatial inputs. *Environmental Challenges*,

- 8(July), 100579.
<https://doi.org/10.1016/j.envc.2022.100579>
- Tam, T. H., Abd Rahman, M. Z., Harun, S., Hanapi, M. N., & Kaoje, I. U. (2019). Application of satellite rainfall products for flood inundation modelling in Kelantan River Basin, Malaysia. *Hydrology*, 6(4).
<https://doi.org/10.3390/HYDROLOGY6040095>
- Valeh, S., Motamedvairi, B., Kiadaliri, H., & Ahmadi, H. (2021). Hydrological simulation of Ammameh basin by artificial neural network and SWAT models. *Physics and Chemistry of the Earth*, 123(March), 103014.
<https://doi.org/10.1016/j.pce.2021.103014>
- van Griensven, A., Meixner, T., Grunwald, S., Bishop, T., Diluzio, M., & Srinivasan, R. (2006). A global sensitivity analysis tool for the parameters of multi-variable catchment models. *Journal of Hydrology*, 324(1–4), 10–23.
<https://doi.org/10.1016/j.jhydrol.2005.09.008>
- van Tol, J., van Zijl, G., & Julich, S. (2020). Importance of detailed soil information for hydrological modelling in an urbanized environment. *Hydrology*, 7(2), 1–15.
<https://doi.org/10.3390/HYDROLOGY7020034>
- Vu, T. T., Li, L., & Jun, K. S. (2018). Evaluation of multi-satellite precipitation products for streamflow simulations: A case study for the Han River Basin in the Korean Peninsula, East Asia. *Water (Switzerland)*, 10(5).
<https://doi.org/10.3390/w10050642>
- Wörner, V., Kreye, P., & Meon, G. (2019). Effects of bias-correcting climate model data on the projection of future changes in high flows. *Hydrology*, 6(2).
<https://doi.org/10.3390/hydrology6020046>
- Xiang, S., Li, Y., Zhai, S., & Peng, J. (2021). Comparative analysis of precipitation structures in two Southwest China Vortex events over eastern Sichuan Basin by TRMM. *Journal of Atmospheric and Solar-Terrestrial Physics*, 221(June), 105691.
<https://doi.org/10.1016/j.jastp.2021.105691>
- Zhang, X., Srinivasan, R., Zhao, K., & Van Liew, M. (2008). Evaluation of global optimization algorithms for parameter calibration of a computationally intensive hydrologic model. *HYDROLOGICAL PROCESSES*, 20 August 2008.
<https://doi.org/10.1002/hyp>
- Zhang, Y., Wu, C., Yeh, P. J. F., Li, J., Hu, B. X., Feng, P., & Jun, C. (2022). Evaluation and comparison of precipitation estimates and hydrologic utility of CHIRPS, TRMM 3B42 V7 and PERSIANN-CDR products in various climate regimes. *Atmospheric Research*, 265(June 2021), 105881.
<https://doi.org/10.1016/j.atmosres.2021.105881>