



VNIVERSITAT  
DE VALÈNCIA

# ESPACIALIZACIÓN A ALTA RESOLUCIÓN DE LA PRECIPITACIÓN EN LOS ANDES TROPICALES (CORDILLERA BLANCA-PERÚ)



**Autor:** Edwin Anibal Loarte Cadenas

**Directores:** Dr. Ernesto López Baeza

Dr. Johannes Hunink



VNIVERSITAT  
DE VALÈNCIA

**UNIVERSITAT DE VALÈNCIA**

**FACULTAT DE FÍSICA**

**Departamento de Física de la Tierra y Termodinámica**



**TESIS DOCTORAL EN TELEDETECCION**

---

**ESPACIALIZACIÓN A ALTA RESOLUCIÓN DE LA  
PRECIPITACIÓN EN LOS ANDES TROPICALES (CORDILLERA  
BLANCA-PERÚ)**

---

Por:

**EDWIN ANIBAL LOARTE CADENAS**

Directores:

**DR. ERNESTO LÓPEZ BAEZA  
DR. JOHANNES HUNINK**

Octubre-2022





Ernesto López Baeza, Profesor Honorario del Departamento de Física de la Tierra y Termodinámica de la Facultad de Física de la Universitat de València, y Johannes Hunink, Director e Hidrólogo de FutureWater,

**CERTIFICAN:** Que la presente Memoria titulada “*Espacialización A Alta Resolución De La Precipitación En Los Andes Tropicales (Cordillera Blanca-Perú)*”, ha sido realizada bajo nuestra dirección en el Departamento de Física de la Tierra y Termodinámica de esta Facultad, por D. Edwin Loarte Cadenas, y constituye su Tesis Doctoral para optar al grado de Doctor en Teledetección.

Y para que así conste, en cumplimiento de la legislación vigente firmamos el presente certificado en Burjassot, a 28 de octubre de 2022.

LOPEZ BAEZA  
ERNESTO -  
22900895W

Firmado digitalmente  
por LOPEZ BAEZA  
ERNESTO -  
22900895W  
Fecha: 2022.10.31  
23:33:33 +01'00'

HUNINK  
JOHANNES  
S -  
X7047297M

Digitally signed by HUNINK  
JOHANNES - X7047297M  
DN: C=ES,  
SERIALNUMBER=IDCES-X7047297  
M, G=JOHANNES, SN=HUNINK,  
CN=HUNINK JOHANNES -  
X7047297M  
Reason: I'm the author of this  
document  
Location: your signing location here  
Date: 2022.10.31 23:21:12+01'00'  
Foxit PDF Reader Version: 11.1.0

Fdo.: Ernesto López Baeza

Fdo.: Johannes Hunink

## DEDICATORIA

A mis hijas Daphne y Amira, a mis padres Miguel Bernardo Loarte Cruzate y Magda Celestina Cadenas Luna por el amor y sacrificio que pusieron en mi formación personal y académica.

A mis hermanos Maritza, Betsy, Elita, Stiner y Clarita por estar siempre a mi lado brindándome su incondicional apoyo.

A mis compañeros, profesores y asesores; que siempre creyeron en mí.

## AGRADECIMIENTOS

Quiero expresar mi más sincero agradecimiento, a todas las personas e instituciones que han hecho posible la realización de este trabajo y de manera especial:

A mis amigos del Instituto Nacional de Investigación en Glaciares y Ecosistemas de Montaña (INAIGEM) y de la Autoridad Nacional del Agua (ANA), al proyecto AgroClim-Huaraz, en especial a Katy Medina, Hairo León y Eduardo Villavicencio quienes me brindaron su apoyo, proporcionaron información y datos para la realización de este trabajo.

A mis asesores Dr. Ernesto López Baeza y Dr. Johannes Hunink; por la confianza, el tiempo y la paciencia, así como por los aportes y el constante asesoramiento en el tema; haciendo posible el desarrollo de la presente investigación.

Esta investigación ha sido financiada por el Concytec/ProCiencia, la Embajada Británica, el NERC y el Fondo Newton-Paulet en el marco de la convocatoria E031-2018-01-NERC “Círculos de Investigación en Glaciares”. [Contrato N°08-2019-FONDECYT], proyecto “Peruvian Glacier Retreat and its Impact on Water Security - Peru GROWS”.

## RESUMEN

El presente estudio tuvo como objetivo espacializar a alta resolución de la precipitación (HiP-RI) en los Andes Tropicales, Cordillera Blanca-Perú a partir de datos espaciales, variables predictoras y mediciones in situ de estaciones meteorológicas. Para el desarrollo de la investigación se usaron datos y técnicas dentro de la teledetección, análisis estadísticos para el modelamiento y validación de la precipitación espacializada y datos in situ tomados por las estaciones meteorológicas

Los resultados obtenidos de aplicar el modelamiento en la especialización de la precipitación en los Andes Tropicales generaron información espacial de 500 m, 1 km, 2 km, 3 km y 4 km desde el 2012 al 2020. La precisión del modelo alcanza un  $R^2$  de 0.62 con un RMSE de 54, mostrando una mejor predicción en comparación a otros métodos de interpolación y productos grillados con una resolución espacial más gruesa.

El HiP-RI basado en variables predictoras fue capaz de realizar un análisis inicial entre los valores de precipitación in situ y los satelitales, para escoger los mejores productos para cada fecha. Además, se lograron ajustar los coeficientes de todas las variables predictoras para aumentar la confiabilidad en la predicción y se realizó una estimación basada en la regionalización realizada en base al NDVI y que varía mensualmente para cada estimación. En los meses de octubre, noviembre, diciembre, enero, febrero y marzo (época húmeda) y para los meses de abril, mayo, junio, julio, agosto y septiembre; la precisión de los valores obtenidos durante la temporada húmeda (RMSE=46.1) es cercana a la obtenida durante la época seca (RMSE=75.1), mientras que el mes de enero presenta el mejor ajuste (RMSE=37.1).

Además, se encontró una importante relación de los eventos extremos del ENSO (temperatura superficial del mar) y el modelo de precipitación HiP-RI, los valores de temperatura superficial del mar de la zona 1+2 y HiP-RI de la zona de montañas presentaron un valor de correlación de 0.6303 para el coeficiente de determinación ( $R^2$ ) y 0.6328 para la eficiencia de Nash-Sutcliffe (NSE).

Estos datos generados en esta investigación serán de gran utilidad a los tomadores de decisiones para la adecuada gestión del recurso hídrico.

## ABSTRACT

The objective of this study was to spatialize high resolution precipitation (HiP-RI) in the tropical Andes, Cordillera Blanca-Peru, using spatial data, predictor variables and in situ measurements from meteorological stations. For the development of the research, remote sensing data and techniques were used, statistical analysis for modeling and validation of spatialized precipitation and in situ data taken by meteorological stations.

The results obtained from applying the modeling in the specialization of precipitation in the tropical Andes generated spatial information of 500 m, 1 km, 2 km, 3 km and 4 km from 2012 to 2020. The accuracy of the model reaches an  $R^2$  of 0.62 with an RMSE of 54, showing a better prediction compared to other interpolation methods and gridded products with a coarser spatial resolution.

The HiP-RI based on predictor variables was able to perform an initial analysis between in situ and satellite precipitation values to choose the best products for each date. In addition, the coefficients of all the predictor variables were adjusted to increase the reliability of the prediction and an estimate was made based on the regionalization based on the NDVI, which varies monthly for each estimate. In the months of October, November, December, January, February and March (wet season) and for the months of April, May, June, July, August and September; the precision of the values obtained during the wet season (RMSE=46.1) is close to that obtained during the dry season (RMSE=75.1), while the month of January presents the best fit (RMSE=37.1).

In addition, a significant relationship was found between ENSO (sea surface temperature) extreme events and the HiP-RI precipitation model, the sea surface temperature values of zone 1+2 and HiP-RI of the mountain zone presented a correlation value of 0.6303 for the coefficient of determination ( $R^2$ ) and 0.6328 for the Nash-Sutcliffe efficiency (NSE).

The data generated in this research will be very useful to decision makers for the proper management of water resources.

## ÍNDICE

|                                                                                             |           |
|---------------------------------------------------------------------------------------------|-----------|
| <b>RESUMEN.....</b>                                                                         | <b>8</b>  |
| <b>ABSTRACT .....</b>                                                                       | <b>9</b>  |
| <b>CAPÍTULO I.....</b>                                                                      | <b>1</b>  |
| <b>INTRODUCCIÓN.....</b>                                                                    | <b>1</b>  |
| 1.1.    Antecedentes.....                                                                   | 3         |
| 1.2.    Planteamiento del problema.....                                                     | 9         |
| 1.3.    Hipótesis.....                                                                      | 9         |
| 1.4.    Objetivos.....                                                                      | 10        |
| 1.5.    Justificación. ....                                                                 | 10        |
| <b>CAPÍTULO II.....</b>                                                                     | <b>12</b> |
| <b>MARCO TEÓRICO .....</b>                                                                  | <b>12</b> |
| 2.1.    Conceptos de productos satelitales para la espacialización de la precipitación..... | 12        |
| 2.2.    Conceptos básicos .....                                                             | 30        |
| <b>CAPÍTULO III.....</b>                                                                    | <b>32</b> |
| <b>METODOLOGÍA .....</b>                                                                    | <b>32</b> |
| 3.1.    Área de estudio .....                                                               | 32        |
| 3.2.    Diseño de la investigación. ....                                                    | 34        |
| 3.3.    Materiales y equipos .....                                                          | 34        |
| 3.4.    Metodología .....                                                                   | 35        |
| <b>CAPÍTULO IV .....</b>                                                                    | <b>51</b> |
| <b>RESULTADOS.....</b>                                                                      | <b>51</b> |
| 4.1.    Análisis de productos satelitales de precipitación. ....                            | 51        |
| 4.2.    Modelo de espacialización de la precipitación.....                                  | 52        |
| 4.3.    Validación del modelo de precipitación .....                                        | 55        |
| 4.4.    Relación del ENSO y la precipitación (HIP-RI).....                                  | 58        |
| <b>CAPITULO V .....</b>                                                                     | <b>64</b> |
| <b>CONCLUSIONES Y RECOMENDACIONES .....</b>                                                 | <b>64</b> |
| 5.1.    Conclusiones.....                                                                   | 64        |
| 5.2.    Recomendaciones y trabajos futuros.....                                             | 65        |
| <b>REFERENCIAS BIBLIOGRÁFICAS .....</b>                                                     | <b>65</b> |
| <b>ANEXOS .....</b>                                                                         | <b>73</b> |

## LISTA DE FIGURAS

|                                                                                                                                                                                                                                                |    |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| FIGURA 1. RED DE MEDICIÓN PLUVIOMÉTRICA. ....                                                                                                                                                                                                  | 16 |
| FIGURA 2. LOCALIZACIÓN DEL ÁREA DE ESTUDIO USANDO UN MODELO DE ELEVACIÓN DIGITAL DE 30 M. LOS RANGOS DE ELEVACIÓN SE MUESTRAN EN LA LEGENDA, SE MUESTRAN TAMBIÉN LAS ESTACIONES METEOROLÓGICAS PARA EL MODELAMIENTO Y PARA LA VALIDACIÓN. .... | 33 |
| FIGURA 3. SERIE TEMPORAL DE LA PRECIPITACIÓN (2012-2020) DONDE LA LÍNEA AZUL Y LA LÍNEA ROJA INDICAN EL LÍMITE DETERMINADO POR EL FILTRO. ....                                                                                                 | 39 |
| FIGURA 4. FRECUENCIA DE USO DE LOS DISTINTOS PRODUCTOS RASTER EN EL MODELO DE PRECIPITACIÓN. ....                                                                                                                                              | 40 |
| FIGURA 5. DATOS COMPLETADOS CON LOS PRODUCTOS GPM (LÍNEA NEGRA), DATOS ORIGINALES (LÍNEA AZUL OSCURO) Y LA LÍNEA CELESTE INDICA LA DATA DEPURADA. ....                                                                                         | 41 |
| FIGURA 6. A: RASTER CON SUS VALORES NORMALES DE NDVI Y B: VALORES CORREGIDOS DE NDVI EN ZONAS GLACIARES APLICANDO EL FILTRO DE DILATACIÓN. ....                                                                                                | 43 |
| FIGURA 7. C: VALORES ORIGINALES DE NDVI EN LA ZONA COSTA Y D: VALORES CORREGIDOS DE NDVI CON EL FILTRO DE EROSIÓN. ....                                                                                                                        | 44 |
| FIGURA 8. A: DESFASE ENTRE LA PRECIPITACIÓN MÁXIMA Y EL PICO DEL NDVI (LÍNEA DISCONTINUA) Y LA CORRECCIÓN DEL NDVI (DESPLAZADA). B: GRÁFICO DE CAJAS QUE MUESTRA LOS DÍAS DE RETRASO ENTRE EL NDVI Y LA PRECIPITACIÓN. ....                    | 45 |
| FIGURA 9. REGIONALIZACIÓN REALIZADA EN BASE AL ANÁLISIS DE LOS DATOS DE NDVI. ....                                                                                                                                                             | 47 |
| FIGURA 10. PRUEBA DE DISTINTOS FILTROS PARA OBTENER EL PRODUCTO FINAL DE PRECIPITACIÓN. ....                                                                                                                                                   | 49 |
| FIGURA 11. DIAGRAMA DE FULJO PARA LA MODELIZACIÓN DE LA PRECIPITACIÓN. ....                                                                                                                                                                    | 50 |
| FIGURA 12. PRODUCTOS ORIGINALES CHIRPS, PERSIANN Y GPM ANTES DE LA MODELIZACIÓN DE LA PRECIPITACIÓN. ....                                                                                                                                      | 52 |
| FIGURA 13. COMPARACIÓN DE LOS COEFICIENTES DE DETERMINACIÓN DE LOS DISTINTOS PRODUCTOS DE PRECIPITACIÓN Y EL MODELO. ....                                                                                                                      | 53 |
| FIGURA 14. COMPARACIÓN DE LOS COEFICIENTES DEL MODELO A DIFERENTE RESOLUCIÓN ESPACIAL. ....                                                                                                                                                    | 53 |
| FIGURA 15. COMPARACIÓN ESTADÍSTICA ENTRE LOS VALORES DE PRECIPITACIÓN OBTENIDOS Y LOS VALORES OBSERVADOS. ....                                                                                                                                 | 54 |
| FIGURA 16. REJILLA FINAL OBTENIDA DEL MODELO DE PRECIPITACIÓN EN LA CUENCA DEL RÍO SANTA. ....                                                                                                                                                 | 55 |
| FIGURA 17. COMPARACIÓN ESPACIAL DE LA PRECIPITACIÓN OBTENIDA POR EL MODELO, DOS MÉTODOS DE INTERPOLACIÓN Y UN MODELO DE REJILLA. ....                                                                                                          | 56 |
| FIGURA 18. COEFICIENTE DE DETERMINACIÓN Y ERROR CUADRÁTICO MEDIO DE LOS DATOS OBTENIDOS DEL MODELO, MÉTODOS DE INTERPOLACIÓN Y PISCO. ....                                                                                                     | 57 |
| FIGURA 19. COMPARACIÓN DE LA PRECIPITACIÓN DURANTE LA TEMPORADA SECA (A) Y HÚMEDA (B). ....                                                                                                                                                    | 58 |
| FIGURA 20. SECTORES DENTRO DEL ÁMBITO DE ESTUDIO Y EL DEPARTAMENTO DE ANCASH. LA COSTA EN COLOR CELESTE Y LAS MONTAÑAS EN COLOR MORADO. ....                                                                                                   | 59 |
| FIGURA 21. RELACIÓN ENTRE LOS ENSO Y LA PRECIPITACIÓN (HIP-RI) EN LA COSTA PERUANA. A: DATOS ORIGINALES DEL ENSO, B: DATOS DEL ENSO DESPLAZADO. ....                                                                                           | 60 |
| FIGURA 22. CORRELACIÓN EL ENSO EN LA ZONA 3.4 Y LA PRECIPITACIÓN (HIP-RI) EN LA COSTA. A: DATA ORIGINAL. B: DATA DESPLAZADA EN 4 MESES. C: DATOS DESPLAZADOS Y QUITANDO LOS EVENTOS NIÑO Y NIÑA. ....                                          | 60 |
| FIGURA 23. CORRELACIÓN EL ENSO EN LA ZONA 1+2 Y LA PRECIPITACIÓN (HIP-RI) EN LA COSTA. A: DATA ORIGINAL. B: DATA DESPLAZADA EN 4 MESES. C: DATOS DESPLAZADOS Y QUITANDO LOS EVENTOS NIÑO Y NIÑA. ....                                          | 61 |
| FIGURA 24. RELACIÓN ENTRE LOS ENSO Y LA PRECIPITACIÓN (HIP-RI) EN LAS MONTAÑAS. A: DATOS ORIGINALES DEL ENSO, B: DATOS DEL ENSO DESPLAZADO. ....                                                                                               | 61 |
| FIGURA 25. CORRELACIÓN EL ENSO EN LA ZONA 3.4 Y LA PRECIPITACIÓN (HIP-RI) EN LAS MONTAÑAS. A: DATA ORIGINAL. B: DATA DESPLAZADA EN 4 MESES. C: DATOS DESPLAZADOS Y QUITANDO LOS EVENTOS NIÑO Y NIÑA. ....                                      | 62 |
| FIGURA 26. CORRELACIÓN EL ENSO EN LA ZONA 1+2 Y LA PRECIPITACIÓN (HIP-RI) EN LAS MONTAÑAS. A: DATA ORIGINAL. B: DATA DESPLAZADA EN 4 MESES. C: DATOS DESPLAZADOS Y QUITANDO LOS EVENTOS NIÑO Y NIÑA. ....                                      | 63 |



## LISTA DE TABLAS

|                                                                                                           |    |
|-----------------------------------------------------------------------------------------------------------|----|
| TABLA 1. PROYECTOS SATELITALES PARA MEDICIÓN DE LA PRECIPITACIÓN.....                                     | 15 |
| TABLA 2. EXTENSIÓN DE LOS DIFERENTES PRODUCTOS SATELITALES SEGÚN LA RESOLUCIÓN DEL MODELO A OBTENER. .... | 37 |
| TABLA 3. LISTA DE ESTACIONES ESCOGIDAS PARA EL MODELAMIENTO. ....                                         | 38 |
| TABLA 4. LISTADO DE LIBRERÍAS EMPLEADAS EN EL MODELO. ....                                                | 47 |

## LISTA DE ANEXOS

|                                                                                                               |    |
|---------------------------------------------------------------------------------------------------------------|----|
| ANEXO 1. EJEMPLOS DE DESCARGA DE PRODUCTOS SATELITALES.....                                                   | 73 |
| ANEXO 2. LISTA DE PRODUCTOS SATELITALES QUE MIDEN PRECIPITACIÓN, NDVI Y DEM A NIVEL MUNDIAL. ....             | 77 |
| ANEXO 3. COMPARACIÓN DE LA PRECIPITACIÓN ESTIMADA CON EL MODELO A NIVEL MENSUAL PARA UN AÑO HIDROLÓGICO. .... | 78 |

## CAPÍTULO I

### INTRODUCCIÓN

La precipitación es una variable de gran importancia que influye en la variabilidad interanual y la evolución a largo plazo del balance hídrico. Por tanto, una adecuada evaluación de esta variable es clave para predecir adecuadamente el futuro de los recursos hídricos, en especial de los glaciares localizados en la Cordillera Blanca y la evolución a largo plazo del balance hídrico (Mourre et al., 2016). La fuerte estacionalidad de las precipitaciones es controlada por la circulación de vientos provenientes del este que transportan la humedad de la llanura amazónica (Aceituno, 1988) y un flujo del oeste que provoca condiciones secas debido a la corriente de Humboldt (Garreaud et al., 2003), dando origen a dos estaciones distintas como la estación húmeda de setiembre a abril con un promedio del 80% de la precipitación anual y la estación seca de mayo a agosto. Según Lavado et al. (2012) la cuenca del río Santa pertenece a un área donde se observan anomalías positivas en las precipitaciones durante los eventos de la Niña. La climatología de las precipitaciones también se caracteriza por fuertes gradientes espaciales, la influencia de la topografía se vuelve cada vez más

importante cuando se consideran escalas temporales más pequeñas en las que los procesos convectivos y orográficos tienen una profunda influencia ([Mourre et al., 2016](#)), esto se ve reflejado en el patrón de las precipitaciones dando como resultado altas cantidades de precipitación en las laderas de barlovento de los Andes, en situaciones de flujos del este y cantidades de precipitación mucho más pequeñas en el lado de sotavento, incluso en altitudes elevadas. La estimación de la precipitación en una amplia gama de escalas de interés para climatólogos, meteorólogos e hidrólogos es, por tanto, especialmente desafiante en esta región caracterizada por características geográficas muy poco comunes y muy cambiantes. La influencia en el ciclo hidrológico relacionada con la variabilidad de las precipitaciones hace que estudiar este parámetro sea de gran importancia.

En este trabajo los datos de teledetección empleados fueron: modelo de elevación digital (DEM) SRTM, índice de vegetación de diferencia normalizada (NDVI) MODIS a través del algoritmo BOKU y datos de precipitación CHIRPS: Climate Hazards Group InfraRed Precipitation with Station Data, PISCO: Peruvian Interpolate data of the SENAMHI's Climatological and hydrological Observations, GPM: Global Precipitation Measurement, y PERSIANN: Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks. Y los datos de campo son: de las estaciones ubicadas dentro y alrededor de la Cordillera Blanca; estos datos fueron obtenidos y procesados mediante el análisis, modelamiento y técnicas de teledetección, complementadas con técnicas estadísticas.

El presente trabajo busca determinar la espacialización de la precipitación para toda la cuenca del río Santa, especialmente en las partes altas de la cordillera, con la finalidad de que se pueda tener información validada y de buena calidad con respecto a la precipitación, permitiendo evaluar su comportamiento e influencia en el clima de montaña.

A continuación, en los siguientes párrafos, se desarrollará los detalles de la espacialización a alta resolución de la precipitación en los Andes Tropicales, Cordillera Blanca-Perú.

## 1.1. Antecedentes.

La [Organización Meteorológica Mundial \(2011\)](#) señala que la cantidad total de precipitación que llega al suelo durante un período de tiempo, se expresa en términos de profundidad que alcanzaría sobre una proyección horizontal de la superficie terrestre. La medición de esta proyección en profundidad o lámina de agua puede realizarse a través de dos métodos, el primero a través de instrumentos de medición (pluviómetros y pluviógrafos) asociados a estaciones meteorológicas y el segundo mediante la teledetección empleando diferentes plataformas satelitales ([Organización Meteorológica Mundial, 2017](#)).

La necesidad de conocer el ciclo hidrológico del agua a una escala local, regional, continental y global ha generado que ambos métodos se desarrollen con intensidad. En el caso de los datos obtenidos por instrumentos de medición, la información se ha aplicado para estudios tanto locales como continentales, por ejemplo, [Lloyd et al. \(1988\)](#) empleó 2 pluviómetros asociados a estaciones meteorológicas automáticas para determinar la cantidad de precipitación en un bosque amazónico. Otro estudio donde se emplearon estos datos para medir la precipitación a una escala más grande, fue el desarrollado por [Wilson et al. \(1992\)](#) donde se emplearon medidores de precipitación para diseñar un modelo estocástico de la precipitación diaria, con la finalidad de estudiar la circulación atmosférica en Canadá. Un punto importante que se menciona en ambos casos es la aplicación del control de calidad a las mediciones de precipitación ([de Vos et al., 2019](#); [Groisman & Legates, 1994](#)). Para ello la Organización Meteorológica Mundial (OMM) ha establecido una serie de criterios a tener en cuenta a la hora de la instalación y medición de la precipitación empleando distintos instrumentos:

- Ubicación del instrumento de medición: considerar el efecto del viento, distancia a posibles interceptores de lluvia y a una altura del suelo superior a 1 m.
- Instrumentos de medición: existen varios tipos como los pluviómetros estándar, pluviómetros totalizadores, pluviógrafo de pesada, pluviógrafo de flotador, pluviógrafo de cubeta basculante, pluviógrafo de intensidad y los distrómetros.

- En la medición: dependiendo del instrumento instalado, la medición de la precipitación varía y en gran medida los errores serán cometidos por el registrador de los datos y el tipo de programación que tenga el instrumento si está asociado a una estación meteorológica.

También, se ha trabajado en diferentes procesos para poder depurar los datos errados en la medición de la precipitación, un claro ejemplo de estos procesos fue desarrollado por [Hunziker et al. \(2017\)](#) para toda la región andina de Bolivia y Perú. Con ello, los estudios de la precipitación local y continental se pueden realizar con un alto grado de eficiencia y eficacia.

Sin embargo, establecer una red de estaciones para medir la precipitación a una escala global es muy complicado, por ello se ha optado por emplear el segundo método para realizar estas mediciones a una escala más amplia, y este método se basa en la medición de la precipitación a través de plataformas satelitales ([Collier, 2000](#)). La estimación de la precipitación de lluvia desde el espacio se basa en la medición de la cantidad de radiación reflejada y emitida a través de las cimas de las nubes ([OMM, 2011](#)). Existen un gran número de técnicas que hacen uso de procedimientos muy diversos. Así, los satélites que emplean el espectro visible e infrarrojo se basan en que la intensidad de lluvia varía con la tasa de dilatación de la parte superior de las nubes a baja temperatura, a pesar de que las temperaturas muy bajas en las cimas de las nubes no son siempre imprescindibles para que haya precipitación. Otros satélites emplean microondas pasivas, que permiten efectuar mediciones físicamente más ajustadas a la precipitación real, especialmente en las franjas de mayor longitud de onda. Estas microondas miden la precipitación mediante la absorción y dispersión de estas microondas debido a la presencia de gotas de agua. A pesar de que la información proveída es abundante y con un nivel de precisión aceptable, al igual que las mediciones en campo, los valores obtenidos necesitan ser corregidos, así como lo señala [Bell et al. \(1990\)](#) que encontró algunos errores en la medición de la precipitación por parte de la Tropical Rainfall Measuring Mission (TRMM), que muestra un error del 10% en las mediciones de la precipitación promedio en áreas de 500 x 500 km<sup>2</sup>. Por ello, el autor precisa que, si bien

las mediciones por satélite ayudan a entender el comportamiento de la precipitación sobre una zona, es necesario realizar ajustes para obtener una espacialización más adecuada de la precipitación.

Es así como empiezan a surgir modelos de espacialización empleando datos satelitales y datos in situ, modelos que permiten realizar correlaciones entre las mediciones tomadas por ambos métodos, ajustándose así los valores obtenidos y depurándose ciertos errores gracias a la complementariedad de ambos tipos de información. Este trabajo conjunto ha hecho posible la generación de diversos modelos de precipitación, por ejemplo, en 2014 se elaboró el modelo Global Precipitation Climatology Centre (GPCC), el cual fue validado y controlado con datos in situ, es decir con mediciones de precipitación de 67200 estaciones de pluviómetros ([Schneider et al., 2014](#)). A este modelo se le suma también el reciente WorldClim 2 ([Fick & Hijmans, 2017](#)) que ha estimado la precipitación mensual en el período de 1970 al 2000, empleando datos satelitales y alrededor de 60000 estaciones meteorológicas en todo el mundo. En ambos casos los resultados obtenidos generaron correlaciones aproximadas de 0.99 entre la precipitación medida por los satélites y los datos in situ, generando así modelos mejorados que indican un comportamiento más preciso de la precipitación que, por ende, permite generar estudios con mejores resultados a la hora de evaluar el ciclo hidrológico del agua en diferentes disciplinas, como la hidrología.

Actualmente se cuenta con diversas fuentes de información donde este tipo de información está disponible, uno de los productos más conocidos son los datos de reanálisis que se pueden encontrar en la plataforma NCEP-NCAR de la Administración Nacional de la Aeronáutica y del Espacio (NASA). Estos datos albergan información de la tasa de precipitación media mensual (mm/día) obtenida de las misiones CMAP Precipitation desde 1979 hasta la actualidad ([Xie y Arkin, 1997](#)) y también el conjunto de datos GPCC desde 1901 hasta la actualidad ([Schneider et al., 2014](#)). También se cuenta con la precipitación medida por la constelación de satélites TRMM-GPM que cuenta con una resolución espacial de 5 km y tiene 3 niveles de información: nivel 1, nivel 2 y nivel 3 (datos procesados).

El conjunto de datos Climate Hazards Group InfraRed Precipitation with Station data (CHIRPS) muestra información relacionada con la precipitación a una escala casi global de más de 30 años. CHIRPS incorpora imágenes satelitales con una resolución de 0.05 ° con datos in situ para crear series de tiempo de lluvia para el análisis de tendencias.

Por otro lado, se tienen los datos de Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks (PERSIANN) desarrollado por el Centro de Hidrometeorología y Detección Remota en la Universidad de California. El algoritmo PERSIANN se basa en las imágenes infrarrojas de onda larga geoestacionarias para generar lluvia global, donde el producto de lluvia cubre 60°S a 60°N a nivel mundial y se tienen datos desde el año 2000 hasta la actualidad. Como dato no menor, también se puede contar con el Índice de Precipitación Global (GPI) del satélite GOES, datos disponibles desde el año 1987 hasta 1996, de resolución mensual, en la plataforma de NCEP-NCAR.

En el caso de Perú, se cuenta con el producto Peruvian Interpolate data of the SENAMHI's Climatological and hydrological Observations (PISCO) que se obtuvo a partir de estaciones meteorológicas del SENAMHI y datos espaciales obtenidos de CHIRP (datos satelitales sin emplear información pluviométrica, previo al producto final CHIRPS). El resultado fue una rejilla de 5 x 5 km<sup>2</sup> para el período de 1986 hasta 2016, que se emplea para el estudio del seguimiento de sequías, precipitación extrema, inundaciones y seguimiento diario de la precipitación.

Con estos modelos y métodos se han realizado diversos estudios. Sin embargo, algo que ha supuesto un gran reto en relación con los estudios de precipitación ha sido los ámbitos de montaña. Las altitudes superiores a las 5000 m s.n.m. generan una gran cantidad de incertidumbre, ya que la escasa o nula presencia de estaciones pluviométricas y la resolución espacial gruesa (en el mejor de los casos 1 km), impiden que los valores obtenidos puedan no ser los correctos. A pesar de ello, diversas investigaciones han tratado de lidiar con estas incertidumbres, y una de las regiones donde se ha desarrollado este tipo de estudios es la región montañosa de los Alpes. [Lassegues \(2018\)](#) probó varias



técnicas de espacialización para el sector occidental de los Alpes, proceso que realizó a diferentes escalas temporales entre los años 1990 y 2012, donde se adaptó el método Aurelhy que emplea la elevación y los componentes principales de la topografía como predictores, así como la climatología de la zona. Los resultados correspondientes a la división climatológica mostraron ser de buena calidad, confirmando que el método Aurelhy era una herramienta de espacialización bastante fiable, puesto que puede estimar los predictores topográficos más importantes después de la elevación para una región particular. Sin embargo, las pruebas producidas en este estudio pudieron no ser suficientes ya que aquí solo se probaron tres posibilidades para los paisajes de Aurelhy. Esto sugiere la necesidad de realizar más pruebas en el futuro. La continuidad de los datos puede ser un factor significativamente limitante del estudio, ya que su densidad es muy importante y, en muchas de las estaciones, se han encontrado datos diarios incompletos por lo que la estimación de la precipitación a gran altura sigue siendo una cuestión difícil.

Esta problemática también se abordó en Asia, puntualmente en el área montañosa de Tianshan. [Zhao et al. \(2015\)](#) evaluó la utilidad de tres conjuntos de datos de precipitación, incluidos TRMM 3B43 V6, 3B43 V7 y la integración de datos de observación de precipitación asiática con respecto a la evaluación con datos de pluviómetros. Los resultados sugieren que las mediciones de precipitación solo proporcionaron información precisa a pequeña escala, mientras que la percepción remota por satélite de la precipitación tenía ventajas obvias a escala de cuenca o a gran escala, especialmente en áreas montañosas remotas. Sin embargo, la interacción entre las variables climáticas, topográficas y ambientales sobre el área montañosa hace que la detección de la variación espacial en la precipitación sea extremadamente compleja. Afortunadamente, con la mejora de la precisión, los conjuntos de datos de precipitación basados en la teledetección satelital proporcionan a los investigadores amplias perspectivas sobre áreas montañosas remotas.

En las zonas montañosas tropicales, [Hunink et al. \(2014\)](#) aplicó un método de espacialización para lograr una alta resolución en la distribución de la precipitación, empleando productos TRMM con observaciones de teledetección sobre vegetación y de

topografía para cuantificar la distribución espacial de la precipitación en áreas donde faltan observaciones directas. Los resultados muestran que alrededor del 40% de la variación en la precipitación semanal se explica por la influencia de variables distintas. Durante los períodos más secos del año, la vegetación es la variable más importante. En las áreas muy húmedas y durante los períodos húmedos, la vegetación generalmente se encuentra en una fase de desarrollo de clímax sin tendencias de desarrollo que se correlacionan con la lluvia, y las otras variables dominan la estimación de la precipitación. Se encontró también que la estimación está condicionada por la densidad de la red de estaciones meteorológicas y la variabilidad de la lluvia temporal. Concluyendo así que la metodología aplicada es útil para áreas con condiciones variables muy altas, donde hay suficientes datos de tierra disponibles para establecer las relaciones con los diferentes conjuntos de datos de teledetección.

En el Perú se emplearon datos satelitales y mediciones in situ para poder estimar la variabilidad espacial de la precipitación. Así, [Condom et al. \(2011\)](#), emplearon los datos TRMM 3B43 desde 1998 hasta 2007 y datos de estaciones meteorológicas ubicadas a más de 3000 m s.n.m. para el mismo período, encontrándose que la precipitación mensual total en las 29 estaciones del SENAMHI ubicadas por encima de 3000 m se caracterizó por una fuerte estacionalidad, mostrando valores elevados durante el período húmedo (enero a marzo) y valores más bajos durante la estación seca (junio a agosto). El principal problema era que la mala distribución de las estaciones meteorológicas no permitía una espacialización adecuada de la precipitación en las regiones montañosas. Es por esto por lo que, para subsanar estas limitaciones, se emplearon los productos TRMM, para lo que, primeramente, se realizó una corrección mediante dos modelos, uno aditivo y otro multiplicativo, los cuales se aplicaron a los datos mensuales de TRMM 3B43. Sin corrección, en el período de octubre a marzo, los datos in situ fueron mayores que los datos TRMM 3B43. En el período de mayo a agosto, los datos de TRMM 3B43 sobreestimaron los datos in situ. Teniendo en cuenta los modelos de corrección, el modelo aditivo fue más preciso para todas las regiones estudiadas.

Por último, un estudio realizado por [Alzate et al. \(2018\)](#) y [Rauthe et al. \(2013\)](#) mostró que emplear el modelo adecuado para espacializar la precipitación es importante,

ya que el modelo definirá las variables necesarias para que el resultado sea adecuado. En estos estudios se compararon los métodos Spline e IDW frente al modelo Regnie. Se comprobó que la incorporación del DEM y sus derivadas (elevación, pendiente, exposición) en el modelo Regnie mejoraron la precisión y resolución espacial de las interpolaciones de precipitación frente a los métodos Spline e IDW. Sin embargo, la alta variabilidad de los datos y la naturaleza de los estadísticos de evaluación no permitieron que los resultados fueran claramente mejores que los otros dos métodos. Afortunadamente, el modelo Regnie permitió la generación de superficies espaciales de precipitación más ajustadas a la realidad y con mayor detalle espacial.

## **1.2. Planteamiento del problema.**

El estudio y el mejoramiento de los productos de precipitación dentro de los recursos hídricos de alta montaña adquiere un papel de gran importancia para proporcionar información adecuada de gestión, siendo entonces que los estudios de teledetección proporcionan datos y metodologías que contribuyen significativamente al estudio de los recursos hídricos y del cambio climático en un contexto regional y local, resulta entonces que los datos de precipitación obtenidos de estaciones in situ y la información satelital se complementan y se hace de gran importancia hoy en día. Todo ello nos lleva a la siguiente interrogante:

¿Será posible espacializar a alta resolución la precipitación en los Andes Tropicales, Cordillera Blanca-Perú, mejorándola significativamente?

## **1.3. Hipótesis.**

Es posible espacializar a alta resolución la precipitación en los Andes Tropicales, Cordillera Blanca-Perú, mejorándola significativamente, empleando variables predictoras.

## **1.4. Objetivos**

### **1.4.1. Objetivo general.**

Espacializar a alta resolución la precipitación en los Andes Tropicales, Cordillera Blanca-Perú a partir de datos espaciales, variables predictoras y mediciones in situ de estaciones meteorológicas.

### **1.4.2. Objetivos específicos.**

- Adecuar y procesar los productos satelitales de precipitación (CHIRPS, PERSIANN, PISCO, GPM y PERSIANN CHRS), vegetación (NDVI) y modelos digitales de elevación (DEM) para emplearlos como variables predictoras de precipitación.
- Construir un modelo basado en variables predictoras para la espacialización de la precipitación en el área de estudio.
- Obtener los valores de precipitación para todo el ámbito de estudio durante un período comprendido para los años 2012-2020, tanto para la temporada húmeda como para la temporada seca.

## **1.5. Justificación.**

La precipitación es un elemento importante en la climatología de montaña, ya que no solo influye en el clima local, sino también de manera directa en el ciclo hidrológico y por ende, desde un punto de vista socioeconómico, los cambios potencialmente drásticos que pueden generarse en el ciclo del agua relacionados con la variabilidad de las precipitaciones y los cambios a largo plazo, también pueden afectar el acceso al agua potable en las zonas urbanas, los rendimientos de los proyectos agrícolas y la operación de numerosas centrales hidroeléctricas. Por ello, es importante estimar las cantidades

acumuladas de precipitación, así como su frecuencia de ocurrencia, para tener un mejor conocimiento de la influencia de las precipitaciones en la disponibilidad hídrica, en este caso, de la Cordillera Blanca.

## **CAPÍTULO II**

### **MARCO TEÓRICO**

#### **2.1. Conceptos de productos satelitales para la espacialización de la precipitación.**

##### **2.1.1. Precipitación**

Se refiere a los elementos líquidos o sólidos procedentes de la condensación o sublimación del vapor de agua que caen de las nubes o son depositados desde el aire al suelo, y que se define como la cantidad de agua caída sobre una unidad de superficie horizontal por unidad de tiempo ([OMM & UNESCO, 1998](#)).

- **Precipitación líquida:** su formación se debe a que las masas de aire cálido y frío se mueven, entrando en interacción unas con otras. Las zonas de contacto reciben el nombre de frentes. Una masa de aire frío puede empujar a otra de aire caliente, en cuyo caso a la zona de interacción se le denomina frente frío. En la ascensión, el vapor de agua se va condensando en pequeñas gotitas, apareciendo las nubes. Cuando las gotas alcanzan un tamaño superior a los 500 mm, el agua precipita en forma de llovizna ([Shukla et al., 2008](#)).
- **Precipitación sólida:** precipitación atmosférica de cristales de hielo; agregado débil y poroso de cristales o fragmentos de cristales de hielo sobre cualquier superficie ([OMM & UNESCO, 1998](#)).

La formación física de las nevadas están controladas por una gama de complejos procesos físicos y químicos que ocurren en escalas espaciales que van desde las dimensiones atómicas de una molécula de agua hasta el tamaño del sistema de nubes precipitadas y en escalas temporales que van desde el tiempo de crecimiento de partículas de hielo por difusión hasta la vida útil de un sistema de nubes precipitantes, estos procesos ocurren en una atmósfera turbulenta e involucran tres fases de agua ([Barrie, 1991](#)).

### 2.1.2. Proyectos satelitales que miden precipitación

La contribución más importante que pueden hacer las observaciones satelitales a las estimaciones de las precipitaciones climatológicas es que sus observaciones pueden hacerse casi globalmente. El primer satélite de televisión y observación infrarroja (TIROS-1) se lanzó en abril de 1960, produciendo imágenes de nubes en partes del globo que podrían compararse con observaciones meteorológicas coincidentes ([Kidd, 2001](#); [Marcos, 2018](#)). Las actuales series de satélites en órbita polar de la Administración Nacional Oceanográfica y Atmosférica (NOAA) son descendientes directos del satélite TIROS-1 y se caracterizan por una cobertura de satélite dual del globo dos veces

al día a una resolución básica de 1 km. La actual serie de satélites NOAA comenzó en 1979 con el lanzamiento de NOAA-6 (conocido como NOAA-A) y sigue con el satélite más recientemente lanzado, NOAA-16 el 21 de septiembre de 2000. El buen resultado obtenido a través de la serie de satélites TIROS hizo que la ESSA (Environmental Science Services Administration) lanzara una serie de nueve satélites operacionales de nombres ESSA-1 a ESSA-9 ([Marcos, 2018](#)). La NASA desarrolló otra serie de siete satélites, llamados NIMBUS, dedicados a la investigación científica. Dichos satélites se utilizaron con éxito como banco de pruebas para el desarrollo de futuros instrumentos de órbita polar, tales como instrumentos de imagen IR, radiómetros de microondas y sondeadores en el IR, entre otros. Los primeros experimentos con radiometría de microondas pasivas comenzaron en 1972 con el lanzamiento del radiómetro de microondas de barrido eléctrico de órbita polar (ESMR-5) que funcionaba a 19 GHz, proporcionando observaciones polarizadas duales en tres frecuencias (19.35, 37.0 y 85.5 GHz ) y un canal polarizado verticalmente (22.235 GHz) con una resolución en la frecuencia más alta de  $13 \times 15$  km ([Kidd, 2001](#)).

El satélite TRMM se lanzó en 1997 y se encuentra en una órbita terrestre baja, sincrónica al Sol y lleva sensores diseñados para mejorar nuestra comprensión de la lluvia. Esto, junto con el Escáner Visible e Infrarrojo (VIRS) derivado de AVHRR, constituye los sensores pasivos de lluvia. Quizás su instrumento más significativo de este satélite es el radar activo de precipitación por microondas (PR) capaz de proporcionar información sobre la distribución horizontal y vertical de la lluvia a resoluciones de 4 km y 250 m ([Kidd, 2001](#); [Martin & Scherer, 1973](#)). CHIRPS se basa en enfoques previos de técnicas de interpolación "inteligentes" y estimaciones de precipitación de alta resolución y largo período basadas en observaciones infrarrojas de la duración de la nube fría (CCD), incorpora estimaciones de precipitación basadas en CCD de 0.05 ° diarias, pentadales y mensuales de 1981 al presente ([Funk et al., 2015](#)). PERSIANN utiliza principalmente datos de temperatura de brillo infrarrojo de satélites geoestacionarios para estimar la tasa de lluvia, actualizando sus



parámetros utilizando observaciones PMW de satélites de baja órbita. El producto de tasa de lluvia de 0.25 ° cada media hora de PERSIANN está disponible para marzo de 2000 a la fecha (Ashouri et al., 2015). La misión GPM debe consistir en una constelación mixta de satélites en órbita no sincrónica y sincrónica al Sol para tener la capacidad de proporcionar recuperaciones físicas a nivel mundial, con un muestreo de ~3h asegurado en cualquier momento (Smith et al., 2007). Otras misiones satelitales para medir la precipitación se indican a continuación:

Tabla 1. Proyectos satelitales para medición de la precipitación.

| Product             | Temporal resolution | Spatial resolution | Period                        | Coverage         |
|---------------------|---------------------|--------------------|-------------------------------|------------------|
| GPCP                | Monthly/Pentad      | 2.5°               | 1979–(delayed) present        | 90°S–90°N        |
| GPCP-IDD            | Daily               | 1°                 | 1996–(delayed) present        | 90°S–90°N        |
| CMAP                | Monthly/Pentad      | 2.5°               | 1979–(delayed) present        | 90°S–90°N        |
| TMPA v7             | 3 hourly            | 0.25°              | 1998–(delayed) present        | 50°S–50°N        |
| CMORPH              | 0.5 h               | ~0.07°*            | 2002–present                  | 60°S–60°N        |
| PERSIANN            | 0.5 h               | 0.25°              | 2000–present                  | 60°S–60°N        |
| PERSIANN-CCS        | 0.5 h               | 0.04°              | 2003–present                  | 60°S–60°N        |
| <b>PERSIANN-CDR</b> | <b>Daily</b>        | <b>0.25°</b>       | <b>1983–(delayed) present</b> | <b>60°S–60°N</b> |

Fuente: modificado de Smith et al. (2007)

### 2.1.3. Red de estaciones terrestres de medición de precipitación

La distribución de estaciones pluviométricas sobre la tierra varía enormemente. Algunas regiones tienen una alta densidad de estaciones, mientras que en otras muy pocas están disponibles. Esta red de medición es administrada por el Sistema Mundial de Telecomunicaciones (GTS), a continuación, se muestran las estaciones pluviométricas distribuidas a nivel internacional (Kidd, 2001).



Figura 1. Red de medición pluviométrica (Kidd, 2001).

Si bien algunas áreas terrestres están poco cubiertas (norte de África y parte Sudamérica), las mediciones sobre los océanos son mucho más escasas y muchos de las estaciones que están ubicadas en islas pueden no ser representativas de las áreas oceánicas circundantes. Sobre todo, debe recordarse que un pluviómetro solo registra la lluvia para un área muy pequeña, que a menudo se considera representativa de una región más grande. Otro problema identificado es que la mayoría de países con regímenes políticos estables, generalmente pueden garantizar un suministro adecuado de datos con un alto grado de calidad, pero en aquellas regiones de inestabilidad política, los registros a menudo son menos confiables, lo que resulta en interrupciones en los registros de lluvia o en el peor de los casos, un cese completo de los datos (Kidd, 2001). Actualmente la OMM también ha integrado una red de estaciones para observaciones del clima (incluye medición de precipitación) que cuenta con más de 10000 estaciones meteorológicas de superficie, automáticas o dotadas de personal, 1000 estaciones en altitud, 7000 en buques, 100 boyas fondeadas y 1000 boyas a la deriva, cientos de radares meteorológicos y 3000 aeronaves comerciales especialmente equipadas (OMM, 2010). A nivel local también existen diversas redes gestionadas por las autoridades competentes, por ejemplo, el Sistema de Telecomunicaciones de Oklahoma (OLETS) tiene una red que consta de 108 estaciones meteorológicas (Elliott et al., 1994), y en

Corea del Sur se cuenta con una red de 520 estaciones pluviométricas que está a cargo de la Administración Meteorológica de Corea del Sur (KMA). En Perú se estableció una red meteorológica administrada por el Servicio Nacional de Meteorología e Hidrología (SENAMHI) que cuenta con más de 100 estaciones meteorológicas ([Schwarb et al., 2011](#)).

#### **2.1.4. Modelización para fusionar datos terrestres y satelitales**

La modelización para poder corregir los datos satelitales de precipitación se basa en algoritmos; algunos de los más empleados para este fin son:

##### **➤ Algoritmos TMPA**

Las estimaciones de TMPA (TRMM Multi-Satellite Precipitation Analysis) se desarrollan en cuatro etapas: 1) Se calibran y combinan las estimaciones de precipitación de microondas, 2) Se crean estimaciones de precipitación infrarroja utilizando la precipitación de microondas calibrada, 3) Se combinan las estimaciones de microondas e IR y 4) Se incorporan los datos de pluviómetros ([Huffman et al., 2007](#)). En esta última etapa los datos de los pluviómetros se emplean para ajustar los valores obtenidos mediante satélites, y esta relación se calcula para cada cuadro de cuadrícula sobre tierra; la estimación multisatélite se multiplica por la relación del análisis de medidor promedio a gran escala con el promedio a gran escala de la estimación multisatélite. La estimación multisatélite ajustada al medidor y el análisis del medidor se combinan con la varianza de error inverso ([Huffman et al., 1997](#)).

##### **➤ Método SPHEREMAP**

Esta función de interpolación estima un valor en cada nodo de una red predeterminada de un pequeño número de puntos de datos cercanos. Desarrollado para la interpolación dentro de dos espacios cartesianos, el procedimiento da cuenta de la distancia y las relaciones direccionales entre los

datos vecinos y los puntos de la cuadrícula. El algoritmo también tiene una capacidad de extrapolación limitada que permite que los puntos de la cuadrícula tomen valores fuera del rango de los datos, el procedimiento de interpolación requiere que el valor de cada punto de datos cercano influya en la estimación del valor donde se aplican los datos satelitales (Willmott et al., 1985).

➤ **Algoritmos físicos para la evaluación individual de tormentas**

Los modelos de radiación en la nube se están probando en un intento por mejorar la estimación de la tasa de lluvia de diferentes categorías de nubes, para explorar las relaciones entre la radiación MW que emerge de las nubes y las mezclas distribuidas verticalmente de hidrometeoros líquidos y congelados dentro de las nubes.

➤ **Técnicas de conjuntos de datos fusionados**

Dado que se sabe que los datos VIS, IR y MW pasivos proporcionan diferentes tipos y grados de información sobre los sistemas de lluvia observados desde las altitudes de los satélites, se ha sugerido que se debería lograr un mejor rendimiento del algoritmo de lluvia satelital combinando la lluvia/no lluvia y las capacidades de evaluación de la intensidad de la lluvia de los datos de todas estas bandas de ondas diferentes en técnicas únicas, unificadas o fusionadas. Recientemente se ha logrado un progreso significativo en esta dirección combinando IR geoestacionario y datos de MW pasivos de órbita polar corregidos mediante estaciones meteorológicas para capitalizar simultáneamente la alta capacidad de los algoritmos pasivos de MW para identificar áreas de lluvia instantánea y evaluar las tasas de lluvia, y en la utilidad de los datos IR geoestacionarios mucho más frecuentes para proporcionar evidencia necesaria del crecimiento y movimiento de las nubes, incluso cuando estos son rápidos (Barrett & Beaumont, 1994).

### 2.1.5. TRMM GPM

La instrumentación del satélite TRMM consiste en el primer radar meteorológico espacial cuantitativo, un radiómetro de microondas pasivo multicanal y un AVHRR (Radiómetro avanzado de muy alta resolución). La órbita del satélite es de baja altitud (aproximadamente 320 km) para alta resolución y baja inclinación (30° a 35°) para visitar cada área de muestreo en los trópicos aproximadamente dos veces al día a una hora diferente del día (Simpson et al., 1988). Tiene una resolución espacial de  $0.25^\circ \times 0.25^\circ$  de latitud / longitud para garantizar que el cuadro de la cuadrícula sea algo más grande que el tamaño de huella típico para las estimaciones de precipitación de microondas pasivas. La resolución temporal se eligió como 3 h porque (1) permite resolver el ciclo diurno, (2) coincide con el intervalo obligatorio para imágenes de disco completo de la constelación internacional de satélites geosíncronos (geo), y (3) proporciona un compromiso razonable entre la cobertura espacial y la frecuencia temporal para cuadricular las estimaciones asinópticas de microondas de los satélites (Huffman et al., 2010). Existen también diferentes productos derivados de TRMM, siendo los más importantes:

- **TRMM 3B43:** el algoritmo 3B43 proporciona la mejor estimación de la precipitación mensual total en un registro completo desde enero de 1998 hasta diciembre de 2007. Este conjunto de datos es el resultado de la combinación de conjuntos de datos de precipitación. Los sensores de lluvia muestrean la atmósfera regional solo a intervalos de tiempo discretos, a veces faltan tormentas de corta duración. Muchos estudios teóricos han demostrado que el error de muestreo temporal para la precipitación promedio varía de 8 a 12% por mes (Condom et al., 2011).
- **TRMM 3B42\_V07:** el propósito del algoritmo 3B42 es producir estimaciones de error de precipitación fusionada ajustada por TRMM (IR) y precipitación media

cuadrática (RMS). El algoritmo consta de dos pasos separados. El primer paso utiliza los datos de órbita TRMM VIRS y TMI y los parámetros mensuales de calibración TMI / TRMM Combined Instrument (TCI) para producir parámetros mensuales de calibración IR. El segundo paso utiliza estos parámetros de calibración IR mensuales derivados para ajustar los datos de precipitación IR combinados, que consisten en datos GMS, GOES-E, GOES-W, Meteosat-7, Meteosat-5 y NOAA-12. Luego, la corrección del medidor se realiza utilizando la base de datos procesada uniformemente por el Centro Global de Climatología de Precipitación (GPCC). Las estimaciones finales de precipitación IR ajustada y cuadrículada (mm/h) y el error de precipitación RMS tienen una resolución temporal de 3 horas y una resolución espacial de 0.25 grados por 0.25 grados ([Hunink et al., 2014](#); [Simpson et al., 1988](#)).

- **TRMM 2B31\_V07:** el producto 2B31 es una tasa de lluvia PR/TMI combinada, para este producto, los datos se procesaron de 1998 a 2006 y cada una de las órbitas (aproximadamente 16/ día) se ajustó a una cuadrícula igualmente espaciada con una interpolación bilineal para tener en cuenta las diferencias de proyección y resolución. Antes de la calibración de lluvia, los datos de TRMM 2B31 se escalan con el número de mediciones en cada celda de la cuadrícula, porque las latitudes más altas se miden con mayor frecuencia debido a las rutas orbitales de TRMM. Para convertir la tasa de lluvia 2B31 en lluvia absoluta, los datos escalados se calibran con datos de lluvia medidos de las estaciones de 1970. El producto final tiene una resolución temporal mensual promedio y una resolución espacial de 4 × 4 km ([Hunink et al., 2014](#)).

#### 2.1.6. CHIRP-CHIRPS

- **CHIRP (Climate Hazards Group InfraRed Precipitation):** los campos CHIRP son variaciones de la media CHPclim. El enfoque utiliza la calibración local de las estimaciones de precipitación satelital con estadísticas TIR CCD, se usan datos históricos de precipitación diaria para i) definir un umbral de temperatura CCD

óptimo para una región determinada, y ii) desarrollar relaciones de regresión que traducen los valores CCD en estimaciones de precipitación en milímetros. El procedimiento de estimación CHIRP usa un umbral CCD fijo de 235°K, como se usa en el Índice de precipitación global y calibra las regresiones CCD usando precipitación pentadal TMPA 3B42 de 0.25 ° de 2000–2013 ([Funk et al., 2015](#)).

- **CHIRPS (Climate Hazards Group InfraRed Precipitation with Station data):** es un algoritmo de ponderación de distancia inversa modificado que tiene varias características únicas. El primero de ellos es el uso de CHIRP para definir una distancia de descorrelación local; esta distancia es donde la correlación estimada punto a punto es cero. Para generar estos valores, se utilizaron series temporales de datos CHIRP para calcular la correlación promedio a una distancia de 1.5 ° para cada celda de la cuadrícula. Esta correlación, y el supuesto de que la correlación esperada es 1 cuando la distancia es 0, permite estimar una pendiente de descorrelación, que se utiliza para estimar la distancia de correlación cero. La estructura de correlación evoluciona en el espacio y el tiempo, y tiende a ser más fuerte en áreas de convección pesada y bien organizada. Para cualquier píxel dado, el procedimiento de combinación CHIRPS se basa en un promedio ponderado de las proporciones entre las cinco estaciones más cercanas ([Funk et al., 2015](#)).

#### **2.1.7. PERSIANN**

El actual sistema operativo PERSIANN (Climate Hazards Group InfraRed Precipitation) desarrollado por el Centro de Hidrometeorología y Detección Remota (CHRS) de la Universidad de California, utiliza procedimientos de clasificación/aproximación de funciones de redes neuronales para calcular una estimación de la tasa de lluvia en cada píxel de 0.25° x 0.25° de la imagen de temperatura de brillo infrarrojo proporcionada por satélites geoestacionarios. Una función de entrenamiento adaptativo facilita la actualización de los parámetros de la red siempre que haya estimaciones independientes de lluvia

disponibles. El sistema PERSIANN se basó en imágenes infrarrojas geoestacionarias y luego se extendió para incluir el uso de imágenes infrarrojas y visibles durante el día. El algoritmo PERSIANN utilizado se basa en las imágenes infrarrojas de onda larga geoestacionarias para generar lluvia global. El producto de lluvia cubre 60°S a 60°N a nivel mundial ([Ashouri et al., 2015](#)).

- **PERSIANN-CCS:** el sistema de clasificación PERSIANN-Cloud (PERSIANN-CCS) está en alta resolución global en tiempo real (0.04 ° x 0.04 ° o 4km x 4km;) este producto de precipitación satelital fue desarrollado por el Centro de Hidrometeorología y Teledetección (CHRS) de la Universidad de California. El sistema PERSIANN-CCS permite la categorización de las características del parche en la nube según la altura de la nube, la extensión de área y la variabilidad de la textura estimada a partir de imágenes satelitales. En el corazón de PERSIANN-CCS se encuentra el algoritmo de segmentación de nubes de umbral variable. En contraste con el enfoque tradicional de umbral constante, el umbral variable permite la identificación y separación de parches individuales de nubes. Los parches individuales se pueden clasificar según la textura, las propiedades geométricas, la evolución dinámica y la altura de la parte superior de la nube.
- **PERSIANN-CDR:** estimación de la precipitación a partir de información de detección remota utilizando redes neuronales artificiales - Registro de datos climáticos proporciona estimaciones diarias de lluvia a 0.25 grados para la banda de latitud 60N-60S durante el período del 01/01/1983 al 31/12/2015 (presente retrasado). PERSIANN-CDR tiene como objetivo abordar la necesidad de un conjunto de datos de precipitación global, de alta resolución y a largo plazo para estudiar los cambios y tendencias en la precipitación diaria, especialmente los eventos de precipitación extrema, debido al cambio climático y la variabilidad natural. PERSIANN-CDR se genera a partir del algoritmo PERSIANN utilizando datos infrarrojos GridSat-B1 y se ajusta utilizando el producto mensual del Proyecto de Climatología Global de



Precipitación (GPCP) para mantener la consistencia de los dos conjuntos de datos a una escala mensual de 2.5 grados en todo el registro. El producto PERSIANN-CDR está disponible para el público como un registro de datos climáticos operativos a través del sitio web del Programa CDR de NOAA NCDC en la categoría de CDR atmosféricos.

#### **2.1.8. PISCO**

La generación de PISCO precipitación diario (PISCOpd) y precipitación mensual (PISCOpm) puede dividirse en 3 subprocesos: Control de calidad de la información pluviométrica, análisis exploratorio de la información satelital y la mezcla de datos basado en técnicas geoestadísticas. El primer subproceso consistió en la evaluación general de los datos de precipitación para cada estación, rangos fijos, coherencia temporal y espacial. Aquellos valores que superan los límites establecidos fueron eliminados. Debido a que un solo proceso de control de calidad no es apto para series climáticas.

Seguidamente se realiza una búsqueda de información satelital, para PISCO se emplearon los datos CHIRP ya que presentan un mejor control de calidad que los datos CHIRPS. Finalmente, para la mezcla a paso mensual de la precipitación se ha utilizado la técnica geoestadística Kriging con Deriva Externa (KED) por ser una técnica robusta. En esta metodología, la variable a regionalizar es la precipitación observada y la covariable es la precipitación estimada por el producto CHIRP. A paso diario se utiliza una modificación de la técnica de interpolación “inverso de la distancia ponderada” junto a una corrección de sesgo basado en valores mensuales, además a partir de la optimización de parámetros de interpolación se plantea la caracterización de la estructura espacial. El proceso de mezcla se realizó de manera independiente para cada mes y día de las series históricas ([Aybar et al., 2017](#)).

### 2.1.9. Variables que influyen en la precipitación

#### ➤ **Modelo de elevación digital (DEM)**

Normalmente los modelos de elevación digital son necesarios para predecir la precipitación, ya que la topografía influye en los patrones de precipitación. Algunos de estos elementos que intervienen en esta variación son la altitud, orientación y pendiente ([Rauthe et al., 2013](#)). Estos influyen en las precipitaciones, ya que tienen efectos focalizados al momento de interpolar la precipitación, y se ha demostrado que el incluir estas variables mejora el modelo de interpolación que se esté empleando en el estudio de la precipitación a escala regional ([Alzate et al., 2018](#); [Hunink et al., 2014](#)).

#### ➤ **Índice de vegetación de diferencia normalizada (NDVI)**

El NDVI se emplea como proxy de la dinámica temporal y espacial de la precipitación. La respuesta vegetativa a la precipitación puede ser relativamente rápida en condiciones áridas, semiáridas y subhúmedas. La relación de NDVI y precipitación se ha utilizado previamente para convertir la distribución espacial de la precipitación TRMM de resoluciones temporales diarias a anuales ([Georganos et al., 2017](#); [Hunink et al., 2014](#)).

#### ➤ **Temperatura del aire**

La temperatura es una variable que puede mejorar la identificación de la fase de precipitación cuando el gradiente de temperatura se considera junto con la temperatura de la superficie. Sin embargo, aunque el uso del gradiente de temperatura o el nivel de congelación junto con la temperatura de la superficie aumenta, muestra no ser una variable demasiado importante ([Froidurot et al., 2014](#)).

➤ **Humedad relativa**

El efecto de la humedad del aire sobre la fase de precipitación, no es muy relevante pero puede emplearse para explicar el comportamiento de los hidrometeoros que se mezclan con otros elementos en el momento de producir precipitación ([Froidurot et al., 2014](#)).

## 2.1.10. Índices de cobertura vegetal:

➤ **NDVI - Normalized Difference Vegetation Index**

El NDVI se obtiene de un amplio espectro de satélites (por ejemplo, MODIS, Landsat, etc.). Se formuló como una relación entre la resta en la reflectancia roja del NIR y la adición de estas dos reflectancias. El NDVI está diseñado para monitorizar la biomasa activa fotosintética y hace uso del fuerte contraste entre la alta reflectancia en el espectro NIR y la baja reflectancia en el espectro Rojo ([Schultz et al., 2016](#)).

$$NDVI = (NIR_{b4} - RED_{b3}) / (NIR_{b4} + RED_{b3})$$

Dónde, para Landsat: NIR es la reflectancia del infrarrojo cercano de la banda 4 para TM/ETM+, la banda 5 para OLI. RED es la reflectancia del espectro visible, banda 3 para TM/ETM+, banda 4 para OLI. El rango de valores del NDVI está entre -1 a 1.

➤ **EVI - Enhanced Vegetation Index**

EVI fue desarrollado para optimizar la señal de vegetación con una sensibilidad mejorada en regiones de biomasa alta y una reducción de las influencias de la atmósfera ([Zoungrana et al., 2015](#)).

$$EVI = (G) \frac{NIR_{b4} - RED_{b3}}{NIR_{b4} + C_1 * RED_{b3} - C_2 * B_{b1} + L}$$

Dónde, para Landsat: NIR es la reflectancia del infrarrojo cercano de la banda 4 para TM/ETM+, la banda 5 para OLI. RED es la reflectancia del espectro visible, banda 3 para TM/ETM+, banda 4 para OLI. B es la reflectancia azul b1 para

TM/ETM+, b2 para OLI. G es el factor de ganancia. C1, C2 son los coeficientes del término de resistencia a aerosoles, que utiliza la banda azul para corregir las influencias de aerosoles en la banda roja y L funciona como el factor de ajuste del suelo. El rango de valores del EVI está entre -1 a 1.

#### ➤ **SAVI**

El SAVI se estableció para mejorar la sensibilidad del NDVI al fondo del suelo. El rango de L es de 0 a 1. En aplicaciones prácticas, los valores de L se determinan de acuerdo con las condiciones ambientales específicas. Cuando el grado de cobertura de la vegetación es alto, el valor de L se acerca a 1, lo que demuestra que el fondo del suelo no tiene ningún efecto sobre la extracción de la información de la vegetación. Este tipo de condiciones ideales rara vez se encuentra en entornos naturales y puede ser aplicable solo en el caso de una gran cobertura de dosel. El valor de L es alrededor de 0.5 en la mayoría de las condiciones ambientales comunes. Cuando está cerca de 0, el valor de SAVI es igual al NDVI (She et al., 2015).

$$SAVI = (1 + L) \frac{(NIR_{b4} - RED_{b3})}{(NIR_{b4} + RED_{b3} + L)}$$

Dónde: NIR es la reflectancia del infrarrojo cercano de la banda 4 para TM/ETM+, la banda 5 para OLI. RED es la reflectancia del espectro visible, banda 3 para TM/ETM+, banda 4 para OLI. L funciona como el factor de ajuste del suelo.

#### ➤ **Datos de NDVI y EVI mejorados por el algoritmo BOKU**

Es una plataforma de servicio de datos disponible gratuitamente para ejecutar operaciones de preprocesamiento como suavizado de datos, subconfiguración espacial y temporal, mosaico y reproyección de series de tiempo de índices de vegetación (NDVI y EVI). Los conjuntos de datos suavizados y llenado de huecos se derivan utilizando el filtro Whittaker-Vondrak (Vuolo et al., 2012). En el método Whittaker-Vondrak, se considera que la curva más probable es el mejor compromiso con respecto a la "fidelidad"

y la "suavidad" evaluadas mediante modelamiento numérico, sirven para depurar datos anómalos y que sean lo más idénticos a los originales ([Huang Kun-yi & Zhou Xiong, 1981](#)).

#### **2.1.11. Modelo de elevación digital - DEM**

##### **➤ TanDEM – X**

El objetivo de la misión TanDEM-X era producir un DEM global con una resolución espacial de 12 m, a partir de interferometría de radar (InSAR) con dos satélites (TerraSAR-X y TanDEM-X) en una órbita controlada con una línea base de 250-500 m. El proyecto logró imágenes completas de la Tierra al menos dos veces, con cobertura adicional en áreas de topografía compleja, incluyendo el reposicionamiento de las órbitas para evitar la sombra del radar en terrenos montañosos. El requisito de precisión absoluta para el producto TanDEM-X es <10 m horizontal y vertical, mientras que la precisión vertical relativa (incertidumbre en altura entre dos puntos en un  $1^\circ \times 1^\circ$  área) es de 2 m para áreas con pendiente  $\leq 20\%$  y 4 m cuando la pendiente es  $> 20\%$  ([Grohmann, 2018](#); [Krieger et al., 2013](#)).

##### **➤ SRTM**

La Misión de Topografía por Radar Shuttle fue una cooperación entre la NASA, la Agencia Nacional de Inteligencia Geoespacial de los Estados Unidos (NGA), el Departamento de Defensa de los Estados Unidos (DoD), DLR y la Agencia Espacial Italiana (ASI, Italia). Los requisitos de precisión de la misión, <20 m de error de geolocalización y <16 m de error vertical. Se han lanzado tres versiones oficiales de SRTM. El objetivo de la última versión oficial (V3 o "SRTM Plus") era la eliminación completa de los vacíos, que se llenaron principalmente con datos de ASTER GDEM. En 2014, se publicaron públicamente datos globales de SRTM V3 con resolución de  $\sim 30$  m en el ecuador ([Grohmann, 2018](#); [Farr et al., 2007](#)).

➤ **ASTER GDEM**

El sensor ASTER (Radiómetro avanzado de emisión y reflexión térmica en el espacio) se lanzó en diciembre de 1999 a bordo del satélite Terra, con la capacidad de generar imágenes estereoscópicas a lo largo de la pista en la longitud de onda infrarroja cercana. ASTER GDEM V.1 se produjo procesando automáticamente todo el archivo ASTER. ASTER GDEM V.2 se lanzó en 2011 y mejora la primera versión de los algoritmos de procesamiento, la inclusión de escenas adquiridas entre 2008 y 2011, una mejor georreferenciación de datos y un aumento de resolución espacial efectiva de 120 m a 70 m. Con una confianza del 95%, ASTER GDEM tiene una precisión estimada de 30 m horizontal y 20 m vertical ([Grohmann, 2018; Yamaguchi et al., 1998](#)).

➤ **ALOS WORLD 3D**

El sensor PRISM (Instrumento Pancromático de Teledetección para Mapeo Estéreo) se lanzó en enero de 2006 a bordo del satélite ALOS (Satélite Avanzado de Observación de la Tierra), con la capacidad de generar un triplete de imágenes pancromáticas estereoscópicas a lo largo de la pista (0.52–0.77  $\mu\text{m}$ ) a nadir (NDR), hacia adelante (FWD) y hacia atrás (BWD), con resolución de 2.5 m. En sus cinco años de operación, ALOS produjo aproximadamente 6.5 millones de escenas que cubren todo el mundo. Se utilizó un proceso automatizado de todas las escenas con menos del 30% de cobertura de nubes (alrededor de 3 millones de escenas) para generar un DEM global con una resolución de 5 m. Aunque el conjunto de datos de 5 m se distribuye comercialmente, una versión de resolución de 30 m (AW3D30) está disponible gratuitamente y se utilizó en este estudio. Las precisiones se informan solo para el conjunto de datos de 5 m como un RMSE de 5 m para horizontal y vertical ([Grohmann, 2018; Shimada et al., 2010](#)).

➤ **MERIT DEM**

DEM global de alta precisión con una resolución de 3° (~ 90 m en el ecuador) al eliminar los componentes de error principales de los DEM

existentes. Como el sesgo absoluto, el ruido de banda, el ruido de moteado y el sesgo de altura de árbol, utilizando múltiples conjuntos de datos de satélite y técnicas de filtrado. Después de la eliminación del error, las áreas de terreno mapeadas tienen una precisión vertical de  $\pm 2$  m ([Yamazaki et al., 2017](#)).

#### **2.1.12. Influencia de los ENSO en los regímenes de precipitación**

Durante El Niño (o La Niña), la región experimenta anomalías negativas (positivas) en las precipitaciones, siendo más fuertes durante diciembre-febrero y más débiles durante marzo-mayo. Además, las anomalías en las precipitaciones muestran que la señal ENSO exhibe una propagación en forma de onda en el oeste, siendo más fuerte sobre los Andes occidentales ([Poveda et al., 2011](#)). En los andes del Perú durante los ENSO, las precipitaciones aumentan, ya que un estudio hecho por [Morera et al., \(2017\)](#) mostró que durante los eventos del Niño, el rendimiento de sedimentos suspendidos en los ríos aumenta de 82% a 97% durante los meses de enero a abril debido al incremento de las tasas de precipitación.

Durante los años normales, la precipitación media anual en los Andes occidentales peruanos es generalmente baja y muestra un gradiente latitudinal ( $\sim 1000$  mm/año en el norte a  $\sim 400$  mm/año en el sur). El año hidrológico comienza en septiembre y termina en agosto en todas las cuencas hidrográficas y no cambia con la latitud. La expansión estacional de los vientos ecuatoriales del este transporta la humedad del Atlántico a los Andes y hace que se produzca precipitación principalmente durante el verano austral (enero-marzo). En promedio, el 90% de la precipitación anual cae de octubre a abril, con un pico en febrero y marzo. El resto del año (mayo a septiembre) es seco, con menos de 50–100 mm de precipitación. En los tiempos que hay ENSO, una pronunciada extensión hacia el este del Pacífico occidental se calienta y desarrolla convección atmosférica, lo que aumenta la humedad atmosférica y aumenta en gran medida la lluvia en el Pacífico oriental ecuatorial, generalmente frío y

seco. En Perú, la precipitación diaria es más frecuente y más fuerte durante los años ENSO que durante los años normales. El efecto más pronunciado del ENSO sobre la precipitación ocurre en el norte de Perú, que experimenta un monzón impulsado por el viento del este en las montañas y eventos de precipitación intensa intermitentes del oeste en la costa del Pacífico. En consecuencia, se producen inundaciones catastróficas en la región ecuatorial oriental de Ecuador y el norte de Perú ([Chiang et al., 2000](#); [Daniels & Veblen, 2000](#); [Morera et al., 2017](#); [Vicente-Serrano et al., 2017](#)).

## **2.2. Conceptos básicos**

### **2.2.1. Ráster**

Una imagen raster o de píxeles es una estructura o archivo de datos que representa una cuadrícula rectangular de píxeles o puntos de colores, llamada matriz, que se puede mostrar en una pantalla, papel u otro dispositivo de representación.

### **2.2.2. Remuestreo**

Remuestrear es cambiar el tamaño de píxel de una imagen (agregando o restando píxeles). Esta acción se realiza principalmente para su visualización en pantalla. El remuestreo siempre reduce la calidad de la imagen

### **2.2.3. Filtro Gaussiano**

El valor de cada punto es el resultado de la media con diferentes pesos de los valores vecinos a cada lado de dicho punto. Este tipo de filtro también tiene un problema de desenfoque de bordes, pero no es tan pronunciado como en el caso del promedio simple.



#### **2.2.4. Filtro por dilatación gaussiana**

La dilatación morfológica produce el efecto expandirse o expandirse en regiones de la imagen.

#### **2.2.5. Filtro por erosión gaussiana**

La acción de erosión produce un efecto de adelgazamiento en el área de la imagen y se considera que es el efecto opuesto a la dilatación.

#### **2.2.6. Kernel**

Un kernel o máscara de convolución puede entenderse como una matriz de coeficientes que, cuando se aplica a un píxel objetivo (considerando el píxel como un punto  $(x, y)$  del plano), logra una transformación, un cambio en el píxel objetivo así como en sus vecinos (entender la transformación como una imagen  $G(x, y)$  sobre cada uno de ellos).

#### **2.2.7. Regresión lineal múltiple**

La regresión lineal múltiple puede producir un modelo lineal en el que el valor de la variable dependiente o de respuesta ( $Y$ ) se determina a partir de un conjunto de variables independientes denominadas predictores ( $X_1, X_2, X_3...$ ). Es una extensión de la regresión lineal simple, por lo que es fundamental comprender esta última. Los modelos de regresión multivariable se pueden utilizar para predecir el valor de una variable dependiente o para evaluar el grado de influencia que los predictores tienen sobre ella (los siguientes factores deben analizarse sistemáticamente. Tenga cuidado de no malinterpretar la relación causa-efecto).

## **CAPÍTULO III**

### **METODOLOGÍA**

#### **3.1. Área de estudio**

El área de estudio se ubica en el sector norte de los Andes peruanos y está delimitada por un polígono que va de los 79°07' a 76°20' W y entre 09°19' y 10°19' S, que incluye la Cordillera Blanca, el Parque Nacional Huascarán, la cuenca del río Santa, la cuenca del río Pativilca, la cuenca del río Marañón y la zona costera (Figura 1). Esta región se caracteriza por un clima complejo, controlado principalmente por los Andes. La orografía actúa como barrera topográfica al flujo de humedad, lo que provoca la formación de fuertes gradientes de precipitación en los flancos orientales de la cordillera, lo que da lugar a un promedio anual de más de 900 mm (durante el verano). Por su parte, en las zonas situadas por encima de los 4500 m.s.n.m. en la vertiente

occidental, la media anual es de 600 mm, que es menor que en la vertiente oriental debido a los flujos de viento de este a oeste, lo que hace que las descargas se produzcan primero y en mayor proporción en esa zona.




Figura 2. Localización del área de estudio usando un modelo de elevación digital de 30 m. Los rangos de elevación se muestran en la leyenda, se muestran también las estaciones meteorológicas para el modelamiento y para la validación.

### **3.2. Diseño de la investigación.**

#### **3.2.1. Universo o población.**

La población es el ámbito de la cordillera Blanca, espacio delimitado por el polígono que va de los 79°07' a 76°20' W y entre 09°19' y 10°19' S. Figura 2.

#### **3.2.2. Diseño y caracterización de la muestra.**

Se han realizado análisis estadísticos para la validación de los productos espacializados de precipitación, así como también para la preparación y homogenización de los datos de las estaciones in situ. Se han aplicado técnicas y metodologías dentro del campo de la teledetección.

### **3.3. Materiales y equipos**

#### **3.3.1. Insumos**

- Productos satelitales de precipitación CHIRPS, PISCO, GPM y PERSIANN.
- Índices de vegetación NDVI.
- Modelos de elevación digital SRTM.
- Datos de precipitación registrada en las estaciones meteorológicas (2012-2020).

#### **3.3.2. Equipos**

- Work Station con procesador windows 64 bits

#### **3.3.3. Software**

- ArcMap 10.4.1
- Jupyter Notebook
- Lenguaje de programación Python 3

### 3.4. Metodología

#### 3.4.1. Búsqueda de productos satelitales

Existen diversas misiones satelitales para la medición de la precipitación, las más usadas y que se han empleado en este estudio, se describen a continuación:

##### a. Precipitación

- **CHIRPS: Climate Hazards Group InfraRed Precipitation with Station Data**

Resolución temporal: diaria, pentadal y mensual (1981 – actualidad)

Resolución espacial: 0.05°.

Disponible en: <https://data.chc.ucsb.edu/products/CHIRPS-2.0/>

- **GPM: Global Precipitation Measurement**

Resolución temporal: diaria y mensual (2014 – 2017)

Resolución espacial: 0.1°.

Disponible en: <https://climatedataguide.ucar.edu/climate-data/gpm-global-precipitation-measurement-mission>

- **PERSIANN: Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks**

Resolución temporal: horaria, diaria, mensual y anual (2000 – actualidad)

Resolución espacial: 0.25°.

Disponible en: <https://chrsdata.eng.uci.edu/>

- **PISCO: Peruvian Interpolate data of the SENAMHI's Climatological and hydrological Observations**

Resolución temporal: diaria y mensual (1981 – 2016)

Resolución espacial: 0.3°.

Disponible en: <http://iridl.ldeo.columbia.edu/>

#### **b. Vegetación**

- **NDVI: MODIS a través del algoritmo BOKU.**

Resolución temporal: semanal (2002 – actualidad)

Resolución espacial: 250 m.

Disponible en:

<http://ivfl-info.boku.ac.at/satellite-data-processing/dataprocess-global>

#### **c. Modelos de elevación digital**

- **SRTM**

Resolución espacial: 30 m.

Disponible en:

<https://search.earthdata.nasa.gov/search?q=srtm>

### **3.4.2. Descarga de los productos satelitales**

La descarga de datos se realiza a través de los portales anteriormente mencionados, también puede hacerse a través de plataformas como Google Earth Engine o de manera automática a través de scripts (Utilizando Python) que permitan realizar búsquedas por fechas y nombre del producto en las plataformas de los datos raster.

### **3.4.3. Procesamiento de los productos de precipitación**

Los productos de precipitación, al poseer distinta resolución espacial, tienen también distinto tamaño, en sus dimensiones de columnas y filas de píxeles, por lo que fue necesario llevarlos a una misma extensión y resolución *Tabla 2*. Para ello, se aplicó un ajuste y anclaje de los productos en función de un raster guía con la extensión apropiada para el modelamiento.

Tabla 2. Extensión de los diferentes productos satelitales según la resolución del modelo a obtener.

| Resolución espacial |         | Columnas y filas | Extensión geográfica       |
|---------------------|---------|------------------|----------------------------|
| 0.005°              | ~ 500 m | 574 x 746        | [7.2, 74.07, 76.20, 10.93] |
| 0.01°               | ~ 1 km  | 287 x 373        | [7.2, 79.07, 76.20, 10.93] |
| 0.02°               | ~ 2 km  | 143 x 186        | [7.2, 79.07, 76.21, 10.92] |
| 0.03°               | ~ 3 km  | 096 x 124        | [7.2, 79.07, 76.19, 10.92] |
| 0.04°               | ~ 4 km  | 072 x 093        | [7.2, 79.07, 76.19, 10.92] |

En primer lugar, se remuestrearon todos los productos satelitales a una misma resolución estándar de 500 m, 1 km, 2 km y 4 km, empleando el método *Bilinear* con un kernel de 4x4. Luego se realizó un corte a cada raster empleando las extensiones establecidas en la *Tabla 2*. A cada producto obtenido de este preprocesamiento se le nombró teniendo en cuenta la fecha (formato YY-MM-DD) de su obtención y el producto al cual pertenece (Por ejemplo: 2012-01-01\_CHIRPS).

Finalmente, se creó un conjunto de rangos para los datos mediante la indexación por fecha, siguiendo el formato YY-MM-DD, y el procedimiento se realizó de manera automática en un script diseñado en Python que genera un reporte en consola de las imágenes perdidas (fechas sin datos). Con la indexación, todos los datos de precipitación fueron remuestreados a una escala mensual.

#### 3.4.4. Procesamiento de datos in situ de precipitación

Se recopiló información meteorológica de precipitación de 38 estaciones distribuidas dentro del área de estudio. Se realizó un primer análisis para evaluar el comportamiento de la serie de datos y comparándola con datos de otras estaciones cercanas. Aquellas que no reflejaban un comportamiento esperado, presentaban vacíos de información prolongados o cambios en la serie temporal fueron descartadas. Teniendo en cuenta este análisis, se decidió

descartar un total de 5 estaciones, cuyos códigos son PE109014, 'PE109019, PE109040, PE110018 y PE110040. Es así como solo se incluyeron 33 estaciones (Tabla 3) dentro del modelamiento.

Tabla 3. Lista de estaciones escogidas para el modelamiento.

| Item | Estación             | Código   | Longitud (°) | Latitud (°) | Altitud (msnm) |
|------|----------------------|----------|--------------|-------------|----------------|
| 1    | EMA01_Ocros          | EMANC001 | -77.40       | -10.41      | 3254           |
| 2    | EMA02_Chacas         | EMANC002 | -77.48       | -9.16       | 4038           |
| 3    | EMA03_Chiquian       | EMANC003 | -77.15       | -10.15      | 3406           |
| 4    | EMA04_Casma          | EMANC004 | -78.24       | -9.48       | 127            |
| 5    | EMA05_Shilla         | EMANC005 | -77.62       | -9.23       | 3056           |
| 6    | EMA06_Corongo        | EMANC006 | -77.90       | -8.57       | 3157           |
| 7    | EMA07_San Nicolas    | EMANC007 | -77.18       | -8.98       | 2781           |
| 8    | EMA08_Cañasbamba     | EMANC008 | -77.77       | -9.10       | 2290           |
| 9    | EMA09_Purhuay        | EMANC009 | -77.21       | -9.31       | 3478           |
| 10   | EMA10_Shancayan      | EMANC010 | -77.52       | -9.52       | 3072           |
| 11   | EMA11_Huarmey        | EMANC011 | -78.14       | -10.06      | 10             |
| 12   | EMA12_Pomabamba      | EMANC012 | -77.47       | -8.81       | 2941           |
| 13   | EMA13_Pastoruri      | EMANC013 | -77.30       | -9.89       | 4161           |
| 14   | EMA14_Nepeña         | EMANC014 | -78.37       | -9.18       | 115            |
| 15   | EMA15_Tingua         | EMANC015 | -77.69       | -9.22       | 2497           |
| 16   | EMA16_Quillcayhuanca | EMANC016 | -77.42       | -9.50       | 3819           |
| 17   | EM_Morder            | EMANC018 | -77.65       | -8.96       | 4900           |
| 18   | EM_Dos Cruces        | EMANC023 | -77.06       | -9.56       | 4493           |
| 19   | EM_Ayash             | EMANC024 | -77.02       | -9.52       | 3805           |
| 20   | EM_Antamina          | EMANC026 | -77.09       | -9.56       | 4035           |
| 21   | Huangacocha          | PE107092 | -78.67       | -7.94       | 3595           |
| 22   | Salpo                | PE108001 | -78.61       | -8.01       | 3285           |
| 23   | Cachicadan           | PE108045 | -78.15       | -8.09       | 2760           |
| 24   | Huacamarcanga        | PE108048 | -78.29       | -8.12       | 3883           |
| 25   | Mollepata            | PE108046 | -77.95       | -8.19       | 2590           |
| 26   | Sihuas               | PE108047 | -77.65       | -8.57       | 2716           |
| 27   | Pomabamba            | PE108017 | -77.47       | -8.78       | 3000           |
| 28   | Huaraz               | PE109001 | -77.52       | -9.52       | 3023           |
| 29   | UNASAM               | PE109009 | -77.52       | -9.52       | 3079           |
| 30   | Chacchan             | PE109045 | -77.78       | -9.54       | 2285           |
| 31   | Cajamarquilla        | PE109046 | -77.74       | -9.63       | 3028           |
| 32   | Pira                 | PE109048 | -77.71       | -9.59       | 3625           |
| 33   | San lorenzo          | PE109013 | -77.37       | -9.75       | 3850           |



Una vez establecidas las estaciones, se inspeccionó el contenido de datos nulos y vacíos (NaN-Not a Number). Para discriminar los datos vacíos se reemplazaron todos los valores por -99.9, los valores nulos se reemplazaron por 0.0001, ya que estos podrían confundirse con datos NaN codificados con 0. En cuanto a los datos anómalos, estos fueron eliminados empleando un algoritmo basado en el valor medio y la desviación estándar de los valores de precipitación, según la ecuación (1) establecida por [Zhang et al. \(2018\)](#).

$$Lim = \bar{x} + 3.S$$

Donde *Lim* es el límite,  $\bar{x}$  es la media de los valores y *S* es la desviación estándar. Como límite se toma la suma de la media más tres veces la desviación estándar. Los valores límite dependen de la cantidad de precipitación que registre la estación, y así los rangos límite variaron entre 100 y 400 mm/mes (Figura 3).




Figura 3. Serie temporal de la precipitación (2012-2020) donde la línea azul y la línea roja indican el límite determinado por el filtro.

Con estos límites se ajustaron todos los datos y se eliminaron ciertas desviaciones o anomalías que podrían generar un sesgo al relacionarlos con los raster de precipitación y afectar al rendimiento final del modelo. Con este suavizado de datos, algunas series quedaron incompletas y en un análisis adicional, se pudo apreciar que algunas estaciones no contaban con datos continuos para el período de estudio (2012-2020). Por ello, se optó por analizar una relación entre los diferentes productos de precipitación junto a los datos de las estaciones. La finalidad fue encontrar al producto que tenía una mayor correlación con los datos in situ, y de este análisis se determinó que los productos GPM son aquellos que mejor se ajustan a los datos de precipitación, ya que la mayoría de ellos se usan en la modelización para poder espacializar la precipitación (*Figura 4*) por su alta correlación con los datos in situ.




Figura 4. Frecuencia de uso de los distintos productos raster en el modelo de precipitación.

Con esta información, las series temporales sin datos se completaron con los datos GPM mejorados (*Figura 5*), se completaron las series eliminadas

por el filtro de control de calidad (color rojo) y se rellenaron las series incompletas (color negro punteado).




Figura 5. Datos completados con los productos GPM (línea negra), datos originales (línea azul oscuro) y la línea celeste indica la data depurada.

Finalmente, a los datos obtenidos se les sacó la suma acumulada de precipitación por cada mes del año. También, para cada mes se extrajeron los valores que le correspondían de los distintos productos satelitales (PERSIANN, CHRS, GPM y CHIRPS), para lo que se empleó el método de extracción punto-rejilla.

### 3.4.5. Procesamiento de datos de NDVI

Para el análisis de NDVI como proxy para estimar la precipitación, se emplearon los conjuntos de datos mejorados de cobertura vegetal NDVI y EVI de la plataforma BOKU (Vuolo et al., 2012). Estos datos tienen la ventaja de haber sido filtrados y uniformizados a escala temporal, pero, sin embargo, en una primera prueba se determinó que los datos BOKU EVI alteraban la predicción de la precipitación por la presencia de algunos valores atípicos. Por ello, se decidió emplear solo los datos BOKU NDVI que fueron nuevamente filtrados para poder amortiguar el efecto de subestimación producto de zonas permanentes sin vegetación (glaciares) y de sobreestimación en zonas con permanente vegetación (cultivos agrícolas). Sin embargo, antes de realizar este

proceso, fue necesario la aplicación de un filtro gaussiano para suavizar los datos y eliminar aquellos que están fuera de rango. Este filtro se aplicó a través de la siguiente condición:

$$\begin{cases} Si\ RI_a < 0 \rightarrow no\ es\ RI \\ Si\ RI_a \geq 0 \rightarrow es\ RI \end{cases}$$

Donde  $RI$  es el raster inicial o de entrada y  $RI_a$  es el raster gaussiano.

### ***Filtro de NDVI para zonas glaciares***

Este procedimiento se realizó para minimizar el efecto del NDVI (en zonas glaciares) en el gradiente altitudinal de precipitación puesto que, al tener valores muy bajos de NDVI en entornos cercanos a glaciares, se puede subestimar los valores reales de precipitación. Para ello, se ubicaron las zonas glaciares y se enmascararon y, con esta máscara, se aplicó un filtro a cada producto de NDVI empleando un filtro por dilatación que utilizó un kernel tipo cruz con una matriz de 31 píxeles. Así se generó un nuevo raster que cumplía la siguiente condición:

$$NR \begin{cases} Si\ RI_a < 500 \rightarrow es\ 0 \\ Si\ RI_a \geq 500 \rightarrow es\ 250 \end{cases}$$

donde  $NR$  es el nuevo raster generado, que además debe de cumplir con la condición de que  $NR > 100$  es  $RI_a$  sino es raster de media.




Figura 6. A: Raster con sus valores normales de NDVI y B: valores corregidos de NDVI en zonas glaciares aplicando el filtro de dilatación.

### ***Filtro de NDVI para zonas agrícolas***

Otro aspecto que se consideró antes de emplear el NDVI como un proxy para la precipitación, fueron las zonas agrícolas, ya que estas zonas presentan cobertura vegetal durante gran parte del año, lo cual puede generar sobreestimaciones de la precipitación en la zona costera (la cual se caracteriza por permanecer seca). Para poder aminorar el ruido generado por estas áreas, se aplicó un filtro por erosión de un kernel rectangular de 20 píxeles como matriz, lo cual genera que un píxel en la imagen original (ya sea 1 o 0) se considera 1 solo si todos los píxeles bajo el núcleo son 1, de lo contrario se erosiona (se hace cero).

Seguidamente a este proceso se aplicó una condición de la forma:

$$IMG\_A \begin{cases} Si RI_a < 1500 \rightarrow es RI_a \\ Si RI_a \geq 1500 \rightarrow es dst1 \end{cases}$$

donde  $IMG\_A$  es el nuevo raster generado y  $RI\_a$  es el raster gaussiano.

Después se aplicó un filtro gaussiano de 20 píxeles como matriz.

Con el resultado (*IMG\_B*) se realizó una segunda condición para generar el raster NDVI:

$$NDVI \begin{cases} Si RI_a < 1500 \rightarrow es RI_a \\ Si RI_a \geq 1500 \rightarrow es dst1 \end{cases}$$

Después se aplicó un filtro de media tipo rectangular de 10 píxeles como matriz, al cual se le realizó una diferencia en valor absoluto entre el raster NDVI y el raster gaussiano (*RI\_a*) para generar el producto final (*Figura 7*).




Figura 7. C: valores originales de NDVI en la zona costa y D: valores corregidos de NDVI con el filtro de erosión.

Obtenida la imagen filtrada, se procedió a cambiar la resolución de todas las imágenes de NDVI (500 m, 1 km, 2 km, 3 km y 4 km), empleando el método *Bilinear* con un kernel de 4 por 4, luego se homogenizó la extensión del raster empleando los valores descritos en la *Tabla 2*. Posteriormente, estos datos se mensualizaron para todo un año manteniendo su formato de fecha (YY-MM).

### ***Análisis del desfase entre el NDVI y la precipitación***

Con las imágenes mensualizadas se realizó una regionalización basada en los valores de NDVI en base a los rangos establecidos por la variación existente en la desviación estándar ( $0 < 20000 - 58000 <$ ). También se aplicó un filtro de media empleando un kernel de 20 píxeles, luego se extrajeron los valores de NDVI con el método de extracción *punto-grilla*. Se encontró que el desfase (lag) entre el máximo de precipitación y NDVI ocurre en aproximadamente 47 días (*Figura 8*). Por ello, los datos de NDVI se desplazaron este período de tiempo para que se considerara a manera de un efecto inmediato al momento de introducir esta variable dentro del modelo para estimar la precipitación.




Figura 8. A: desfase entre la precipitación máxima y el pico del NDVI (línea discontinua) y la corrección del NDVI (desplazada). B: gráfico de cajas que muestra los días de retraso entre el NDVI y la precipitación.

#### **3.4.6. Procesamiento del modelo de elevación digital (DEM)**

El DEM fue remuestreado a las resoluciones espaciales de trabajo (500 m, 1 km, 2 km, 3 km y 4 km). Al igual que los demás productos raster, se extrajeron los valores de altitud empleando el método punto-rejilla.

#### **3.4.7. Regionalización del área de estudio**

En el análisis del NDVI se observó que había una distribución espacial bastante marcada. La *figura 9* muestra que, en la zona costera, los valores del

NDVI son muy bajos (Región 1) debido a la escasa precipitación y a zonas desérticas muy extendidas, mientras que en la zona media del área de estudio (Región 2), el NDVI es muy variable debido a la presencia de los valles que centran la mayor cantidad de vegetación y las laderas con escasa vegetación debido a la fuerte pendiente o a la altitud. Finalmente, en el este, los valores de NDVI son más altos por la presencia de la selva Amazónica (Región 3) que concentra una gran variedad de vegetación en toda la superficie. En base a este comportamiento, se decidió regionalizar el área de estudio en 3 regiones para ajustar más el modelo y mejorar su predicción, ya que el comportamiento del NDVI será distinto y esto puede generar ciertos errores al modelizar la precipitación. Este procedimiento se realizó con la finalidad de obtener un valor de precipitación más acertado y acorde a cada región dentro del área de estudio.

La regionalización basada en el NDVI también contribuyó al descarte de algunas estaciones meteorológicas que no mostraban un comportamiento esperado para cada región, por lo que se realizó un segundo filtrado de los datos de las estaciones, identificando que las estaciones EMANC012, EMANC011 y PE110039 no presentaban datos coherentes con la región en la que se encuentran. También descartaron las estaciones EMANC014 y EMANC004 por estar muy cercanas a la zona costera de la región 1 y, finalmente, las estaciones EMANC012 y EMANC015, se excluyeron por presentar condiciones atípicas en la precipitación diaria.






Figura 9. Regionalización realizada en base al análisis de los datos de NDVI.

### 3.4.8. Construcción del modelo para espacializar la precipitación

El desarrollo del modelo se realizó en el lenguaje de programación Python y se emplearon distintas librerías (*Tabla 4*) para poder construir y ejecutar el modelo.

Tabla 4. Listado de librerías empleadas en el modelo.

| Librerías  | Abreviatura | Uso                                                    |
|------------|-------------|--------------------------------------------------------|
| Pandas     | pd          | Análisis estadístico de datos                          |
| Matplotlib | plt         | Construcción de gráficas                               |
| Numpy      | np          | Trabajo con matrices y arreglos                        |
| Os         | ---         | Herramientas para procesamiento de datos geoespaciales |
| Geopandas  | gpd         | Estadística aplicada a datos geoespaciales             |

| Librerías      | Abreviatura | Uso                                      |
|----------------|-------------|------------------------------------------|
| Datetime       | ---         | Formato de fechas                        |
| Statmodels.api | sm          | Estimación de modelos estadísticos       |
| Rasterio       | ---         | Lectura y escritura de datos tipo matriz |
| SKlearn        | ---         | Entrenamiento de modelo                  |

El modelo se construyó para cargar los datos mensuales de las estaciones meteorológicas, datos extraídos a través del método punto-rejilla de cada producto satelital de precipitación. Asimismo, se cargan los datos de NDVI, para poder realizar un primer diagnóstico que determina los coeficientes de correlación y determinación, a fin de obtener los mejores productos de precipitación para poder estimar la precipitación en toda el área de estudio. Las variables elegidas para el modelo entonces se introducen en una ecuación basada en una regresión lineal múltiple de la forma:

$$HiP - RI_i = a_i * dNDVI_i + b_i * DEM + c_i * P_{PP_i} + residuo$$

Donde  $HiP - RI_i$  es la acumulación insitu de la precipitación por mes  $i$ ,  $dNDVI_i$  es el valor del NDVI desplazado para el mes  $i$ ,  $DEM$  es el valor altitudinal del dato *punto-rejilla*,  $P_{PP_i}$  es el valor mensual extraído de los raster de precipitación (PERSIANN, PERSIANN CHRS, PISCO, GPM y CHIRPS) que mejor correlación mostró con la precipitación medida in situ para el mes  $i$  y los valores de  $a_i$ ,  $b_i$ ,  $c_i$  y  $d_i$  son las constantes de cada variable.

Este proceso se realizó para las distintas resoluciones espaciales (500 m, 1 km, 2 km, 3 km y 4 km) y así observar el comportamiento de los distintos productos satelitales, así como la eficacia del modelo al estimar la precipitación comparándola con los datos in situ. Esta comparación se realizó empleando el coeficiente de determinación ( $R^2$ ) estimado con respecto a los datos de precipitación in situ, suponiendo que aquel con valor más cercano a 1 sería el modelo que podía estimar un valor más real de la precipitación. Sin embargo, para evitar que existan grandes cambios en el comportamiento espacial de la

precipitación, se realizó un filtrado final que consistía en probar diferentes kernels de suavizado hasta obtener aquel que representaba una mayor coherencia espacial de la precipitación pero que no añadía un mayor sesgo entre los datos estimados y los observados en las estaciones meteorológicas.




Figura 10. Prueba de distintos filtros para obtener el producto final de precipitación.

Siguiendo ese criterio, se estableció que el mejor filtro es aquel que emplea un kernel de 30, ya que muestra una clara relación de la precipitación con el gradiente altitudinal y no se pierde en mayor medida la precisión de los valores estimados por el modelo.

### 3.4.9. Diagrama de flujo para espacializar la precipitación




Figura 11. Diagrama de flujo para la modelización de la precipitación.

## **CAPÍTULO IV**

### **RESULTADOS**

#### **4.1. Análisis de productos satelitales de precipitación.**

Se procesaron todos los productos de precipitación PERSIANN, GPM y CHIRPS para los años 2012 a 2020. Todos los raster obtenidos cuentan con la misma resolución espacial, cantidad de filas y columnas. A continuación, se muestran 3 productos originales que corresponden a los datos originales del 01 de enero de 2012.




Figura 12. Productos originales CHIRPS, PERSIANN y GPM antes de la modelización de la precipitación.

El análisis de los productos satelitales de precipitación mostró que el mejor comportamiento en relación a los datos de estaciones meteorológicas, fueron los productos GPM ya que tienen los mejores valores de  $R^2$  (entre 0.1 y 0.9) para la mayoría de fechas dentro del período de estudio (*Figura 13*), seguido por los productos PERSIANN y CHIRPS que muestran valores bajos en la mayoría de casos. Sin embargo, en casi todos los productos se puede observar que los valores de  $R^2$  varían según las fechas, siendo mayores durante la temporada húmeda y bajando durante el inicio de la temporada seca (mayo-agosto) puesto que los productos satelitales suelen sobreestimar la precipitación en zonas con escasa precipitación o durante la temporada de estío.

#### 4.2. Modelo de espacialización de la precipitación

En un primer análisis del modelo de precipitación, se compararon los valores del coeficiente de determinación de los distintos productos, el modelo y los datos de precipitación in situ.




Figura 13. Comparación de los coeficientes de determinación de los distintos productos de precipitación y el modelo.

Los resultados muestran que durante el período de estudio se logró estimar los valores de precipitación con el mejor  $R^2$  (Figura 13, línea azul oscura) durante todos los años. Los valores del coeficiente de determinación del modelo varían entre 0.1 (relación más baja) y por encima de 0.8 (con una relación muy alta), mientras que la mayoría de productos obtiene coeficientes máximos de 0.6 e inferiores a este valor. En cuanto al análisis por resolución espacial, se pueden apreciar comportamientos similares entre los distintos productos obtenidos a diferente resolución espacial, siendo el modelo de 2 km el que presenta mejores valores de  $R^2$  con respecto a los demás (Figura 14). También, se puede apreciar que el descenso de los valores del coeficiente de determinación obedece a que la modelización parte de los productos satelitales originales y esto puede generar ciertos sesgos al predecir la precipitación para una zona compleja como el área de estudio. Sin embargo, los valores estimados a través del modelo son mejores a los datos satelitales originales.




Figura 14. Comparación de los coeficientes del modelo a diferente resolución espacial.

Esto podemos comprobarlo en la *Figura 15* donde se aprecia que el modelo tiene un mejor comportamiento y representación de la precipitación a una resolución de 2 km con un  $R^2 = 0.63$  y un RSME = 53.1, mientras que a una resolución de 500 m y 3 km, el modelo se hace un poco más inestable con un  $R^2 = 0.6$  y RSME = 55.3, sin embargo, estos valores no varían en gran medida y su diferencia es baja.




Figura 15. Comparación estadística entre los valores de precipitación obtenidos y los valores observados.

También, se corroboraron los datos de precipitación obtenidos espacialmente y de acuerdo con la fecha de análisis. Por ejemplo, en febrero del 2012, 2013 y 2014 se puede apreciar una mayor precipitación en las partes altas de la cuenca. Mientras que en el mes de agosto, se aprecia escasa o nula precipitación en estas mismas áreas (*Figura 16*). La coherencia espacial se aprecia también en el sector oeste del área de estudio, que coincide con la costa peruana, donde los valores de precipitación a lo largo del año son muy bajos, mientras que en la parte oriental se muestran altos niveles de precipitación (cerca de los 300 mm/mes) durante la época de lluvias con un descenso en esos valores durante la época seca (210 a 240 mm/mes).






Figura 16. Rejilla final obtenida del modelo de precipitación en la cuenca del río Santa.

#### 4.3. Validación del modelo de precipitación

El modelo fue comparado espacialmente con otros métodos de interpolación (IDW y kriging) y también con un producto en rejilla de precipitación elaborado para todo el Perú. En la *Figura 17*, se puede apreciar que los valores de precipitación obtenidos con los métodos convencionales de precipitación, no presentan una buena coherencia espacial de la precipitación debido a que los valores en toda el área de estudio son casi uniformes y existen pequeños puntos de concentración en los lugares donde se ubican las estaciones meteorológicas empleadas para la interpolación. En cuanto al producto de rejilla (PISCO), se observa una cierta coherencia espacial con el modelo, sin embargo, en el perfil B-B' se aprecia que los valores de PISCO son cercanos a cero en el sector occidental ( $-79$  a  $-78^\circ$ ). Estos valores pueden estar subestimados debido a que en este sector se encuentra la cordillera Negra y donde la ocurrencia de precipitaciones es mayor con respecto a la zona de costa. Del mismo modo, al igual que los otros métodos de interpolación, se pueden apreciar ciertos núcleos de

precipitaciones elevadas en algunas áreas (*Figura 17*). Tomando como referencia la latitud, los valores de precipitación decrecen levemente conforme nos vamos alejando de la línea ecuatorial (perfil A-A'), siendo el modelo y PISCO los que mejor representan este comportamiento.




Figura 17. Comparación espacial de la precipitación obtenida por el modelo, dos métodos de interpolación y un modelo de rejilla.

En un análisis más estadístico (*Figura 18*), se puede apreciar que el modelo alcanza un mejor valor en el coeficiente de determinación ( $R^2=0.62$ ), en comparación con los otros métodos y modelos. También se aprecia un mejor valor del RMSE = 54, siendo mucho menor que los otros y más cercano al valor de 50 que se ha considerado como aceptable para este estudio. Cabe mencionar que esta comparación se realizó con el total de estaciones meteorológicas, y también es necesario precisar que la razón de que los valores de  $R^2$  y RMSE no sean más ajustados se debe a la alta complejidad del área de estudio y al efecto de otras variables que actúan de una manera más local. Sin embargo, siendo este modelo de mayor resolución, los resultados obtenidos son aceptables.




Figura 18. Coeficiente de determinación y error cuadrático medio de los datos obtenidos del modelo, métodos de interpolación y PISCO.

El  $R^2$  medio basado en las cantidades de precipitación por temporada en todas las estaciones varía entre 0.39 (estación húmeda) y 0.61 (estación seca). La Figura 19 muestra que la predicción es mejor durante la estación en la que suele haber grandes cantidades de precipitación ( $RMSE < 50\%$ ), mientras que el  $RMSE$  aumenta durante la estación seca ( $RMSE = 75$ ), disminuyendo así la predicción del modelo durante estos meses, que suelen ser de junio a agosto. Sin embargo, los datos durante la estación seca se ajustan mejor a una línea recta ( $R^2 = 0.61$ ), mientras que los valores de la estación húmeda se encuentran con una mayor dispersión debido a la gran variabilidad espacial de la precipitación que existe en la zona de estudio. Para corroborar lo anterior, también se realizó un análisis mensual para un año hidrológico, observando en este análisis que los meses con mejor predicción corresponden a enero, febrero y marzo. Sin embargo, la predicción del modelo disminuye en los demás meses a medida que aumenta el  $RMSE$  ( $>50\%$ , ver Anexo 3).




Figura 19. Comparación de la precipitación durante la temporada seca (A) y húmeda (B).

#### 4.4. Relación del ENSO y la precipitación (HIP-RI)

Para la estimación de los eventos Niño y Niña se suelen usar diferentes regiones (Figura 20A) donde se realizan mediciones de temperatura superficial del mar (TSS), y en ellas se ha realizado un análisis estadístico preliminar de correlación para poder determinar las regiones que podrían utilizarse para un análisis más detallado. Las regiones 1+2 y 3.4 fueron las que proporcionaban mejores resultados. Específicamente, en las zonas de costa y montaña (áreas 1+2) (Figura 20B), se obtuvieron los valores promedios acumulados de precipitación que posteriormente se compararon con el promedio de tres meses consecutivos de la TSS de las regiones del ENSO.




Figura 20. A: Regiones de medición de temperatura superficial del mar para determinar los eventos Niño y Niña. B: Sectores dentro del ámbito de estudio y el departamento de Ancash. La costa en color celeste y las montañas en color morado.

### Análisis en la costa

En la Figura 21 podemos apreciar que la precipitación en la costa del área de estudio (departamento de Ancash) y el ENSO1+2 presentan un comportamiento similar, ya que sus valores mínimos y máximos suelen coincidir en función al tiempo.

Los incrementos de la temperatura generados por el Niño generan mayores precipitaciones en la costa, contrariamente a las montañas donde el régimen es más seco. En eventos Niña se invierte la situación, teniendo mayores precipitaciones en las montañas y siendo más seco en la costa.

Por otro lado, el ENSO3.4 representa mejor los efectos del fenómeno de la Niña, ya que las precipitaciones suelen disminuir producto del flujo del viento hacia Australia e Indonesia. Sin embargo, se puede observar que el ENSO se va desplazando a medida que nos alejamos de la costa y nos dirigimos hacia el océano, ya que los picos de esta variable y la precipitación se van distanciando (Figura 21A).

Para poder hacerlo coincidir gráficamente desplazamos los valores del ENSO1+2 en 2 meses y los valores del ENSO3.4 en 4 meses, de tal forma que los extremos (picos) puedan coincidir con los extremos de la temperatura (Figura 21B).




Figura 21. Relación entre los ENSO y la precipitación (HIP-RI) en la costa peruana. A: datos originales del ENSO, B: datos del ENSO desplazado.

Además del desplazamiento se probó suprimiendo los valores correspondientes a los años Niño y Niña, usando el coeficiente de determinación ( $R^2$ ) y la eficiencia de Nash-Sutcliffe (NSE). La correlación entre el ENSO3.4 y la precipitación en la costa fue nula, dando valores de coeficiente de determinación negativos que prácticamente son cero y valores bajos entre positivo y negativo de la eficiencia de Nash-Sutcliffe, esto nos indica que no se evidencia alguna correlación estadística como se muestra en la Figura 22.




Figura 22. Correlación entre ENSO3.4 y la precipitación (HIP-RI) en la costa. A: Data original. B: Data desplazada en 4 meses. C: Datos desplazados y quitando los eventos Niño y Niña.

La correlación entre el ENSO1+2 y la precipitación en la costa muestra valores que alcanzan el 0.37 de coeficiente de determinación ( $R^2$ ) y 0.38 de eficiencia de Nash-Sutcliffe (NSE), como se muestra en la Figura 23.




Figura 23. Correlación entre el ENSO1+2 y la precipitación (HIP-RI) en la costa. A: Data original. B: Data desplazada en 4 meses. C: Datos desplazados y quitando los eventos Niño y Niña.

### Análisis en las montañas

Similar al caso anterior se puede observar un desfase entre los valores de precipitación y del ENSO, mientras que realizando el ajuste del desplazamiento podemos observar que el ENSO1+2 presenta un comportamiento similar que la precipitación, como se muestra en la Figura 24.




Figura 24. Relación entre los ENSO y la precipitación (HIP-RI) en las montañas. A: datos originales del ENSO, B: datos del ENSO desplazado.

Siguiendo los mismos pasos que en la costa, se desplazaron y quitaron los valores correspondientes a los años Niño y Niña. Estadísticamente los valores de la correlación entre el ENSO3.4 y la precipitación en las montañas fue nula, dando valores de coeficiente de determinación negativos que prácticamente son cero y valores bajos negativos de la eficiencia de Nash-Sutcliffe, lo cual nos indica que no se evidencia ninguna correlación estadística, como se muestra en la Figura 25.




Figura 25. Correlación el ENSO3.4 y la precipitación (HIP-RI) en las montañas. A: Data original. B: Data desplazada en 4 meses. C: Datos desplazados y quitando los eventos Niño y Niña.

Los resultados de correlación quitando los datos correspondientes a eventos Niño y Niña, para el ENSO1+2 muestran una mejora significativa en la correlación, alcanzando valores de 0.6303 para el coeficiente de determinación ( $R^2$ ) y 0.6328 para la eficiencia de Nash-Sutcliffe (NSE), como se muestra en la Figura 25. Esto nos muestra que para la zona de montañas sería una excelente variable predictora al momento de aplicar espacializaciones de precipitación.






Figura 26. Correlación el ENSO en la zona 1+2 y la precipitación (HIP-RI) en las montañas. A: Data original. B: Data desplazada en 4 meses. C: Datos desplazados y quitando los eventos Niño y Niña.

## CAPITULO V

### CONCLUSIONES Y RECOMENDACIONES

#### 5.1. Conclusiones

- Se determinó la distribución espacial y temporal de la precipitación a partir de distintas variables predictoras y mediciones in situ de estaciones meteorológicas con resoluciones espaciales de 500 m, 1 km, 2 km, 3 km y 4 km desde 2012 a 2020. La precisión del modelo alcanza un  $R^2$  de 0.62 con un RMSE de 54, mostrando una mejor predicción en comparación con otros métodos de interpolación y productos de rejilla con una resolución espacial más gruesa.
- Se adecuó y procesó los productos satelitales de tres productos de precipitación (CHIRPS, PERSIANN y GPM), de los cuales los productos GPM representan una mejor correlación con los datos de precipitación in situ. También, se procesó el NDVI-BOKU de tal manera que se obtuvo un retardo entre el pico de NDVI y la precipitación de 47 días y se filtraron para evitar los efectos de sobreestimación (zonas agrícolas) o subestimación (áreas glaciares, lagunas y áreas urbanas) de valores precipitación por efectos del NDVI.
- Se construyó un modelo basado en variables predictoras para la espacialización de la precipitación en toda el área de estudio, y que era capaz de realizar un análisis inicial entre los valores de precipitación in situ y los satelitales, para escoger los mejores productos para cada fecha. Además, se lograron ajustar los coeficientes de todas las variables predictoras para aumentar la confianza en la predicción realizando una estimación basada en la regionalización basada en el NDVI y que varía mensualmente para cada estimación.

- Se obtuvieron los valores de precipitación para los meses de octubre, noviembre, diciembre, enero, febrero y marzo (época húmeda) y para los meses de abril, mayo, junio, julio, agosto y septiembre; la precisión de los valores obtenidos durante la temporada húmeda (RMSE=46.1) es cercana a la obtenida durante la época seca (RMSE=75.1), mientras que el mes de enero presenta el mejor ajuste (RMSE=37.1).

## 5.2. Recomendaciones y trabajos futuros

- La temperatura superficial del mar del ENSO en la zona 1+2 podría utilizarse como variable predictora de la precipitación en zonas de montañas en años que son normales. Según las comparaciones generales y preliminares de este estudio se logró encontrar una relación entre los eventos ENSO y la precipitación, por lo que se recomienda y sugiere realizar mayores estudios en este aspecto.
- Considerar otras variables predictoras como la temperatura y la dirección del viento, así como la cobertura del suelo, podrían mejorar las predicciones de la precipitación de una manera más local y podrían aumentar el ajuste de los valores obtenidos.

## REFERENCIAS BIBLIOGRÁFICAS

- Aceituno, P. (1988). On the functioning of the Southern Oscillation in the South American Sector. Part I: Surface climate. *American Meteorological Society*, 116, 505–524.
- Alzate, D., Araujo, G. A., Rojas, E., Gómez, D., & Matínez, F. E. (2018). Regnie interpolation for rain and temperature in the andean, caribbean and pacific regions of Colombia. *Colombia Forestal*, 21(1), 102–118. <https://doi.org/10.14483/2256201X.11601>
- Ashouri, H., Hsu, K. L., Sorooshian, S., Braithwaite, D. K., Knapp, K. R., Cecil, L. D., Nelson, B. R., & Prat, O. P. (2015). PERSIANN-CDR: Daily precipitation climate data record from multisatellite observations for hydrological and climate studies. *Bulletin of the American Meteorological Society*, 96(1), 69–83. <https://doi.org/10.1175/BAMS-D-13-00068.1>

- Aybar, C., Lavado, W., Huerta, A., Fernández, C., Vega, F., Sabino, E., & Felipe, O. (2017). Uso del Producto Grillado “PISCO” de precipitación en Estudios, Investigaciones y Sistemas Operacionales de Monitoreo y Pronóstico Hidrometeorológico. In *Nota Técnica 001 SENAMHI-DHI-2017* (pp. 1–22). SENAMHI.
- Barrett, E. C., & Beaumont, M. J. (1994). *Satellite rainfall monitoring : An overview Satellite Rainfall Monitoring : An Overview*. 7257(June). <https://doi.org/10.1080/02757259409532257>
- Barrie, L. A. (1991). Snow Formation and Processes in the Atmosphere that Influence its Chemical Composition. *Seasonal Snowpacks*, 1–20. [https://doi.org/10.1007/978-3-642-75112-7\\_1](https://doi.org/10.1007/978-3-642-75112-7_1)
- Bell, T. L., Abdullah, A., Martin, R. L., & North, G. R. (1990). Sampling errors for satellite-derived tropical rainfall: Monte Carlo study using a space-time stochastic model. *Journal of Geophysical Research*, 95(D3), 2195–2205. <https://doi.org/10.1029/JD095iD03p02195>
- Chiang, J. C. H., Cane, M. A., & Orlove, B. S. (2000). Forecasting Andean rainfall and crop yield from the influence of El Niño on Pleiades visibility. *Nature*, 403(January), 68–71.
- Collier, C. G. (2000). Precipitation. In *Remote Sensing in Hydrology and Water Management* (pp. 111–132).
- Condom, T., Rau, P., & Espinoza, J. C. (2011). Correction of TRMM 3B43 monthly precipitation data over the mountainous areas of Peru during the period 1998-2007. *Hydrological Processes*, 25(12), 1924–1933. <https://doi.org/10.1002/hyp.7949>
- Daniels, L. D., & Veblen, T. T. (2000). ENSO effects on temperature and precipitation of the Patagonian-Andean region: Implications for biogeography. *Physical Geography*, 21(3), 223–243. <https://doi.org/10.1080/02723646.2000.10642707>
- de Vos, L. W., Leijnse, H., Overeem, A., & Uijlenhoet, R. (2019). Quality control for crowdsourced personal weather stations to enable operational rainfall monitoring. *Geophysical Research Letters*, 46(15), 8820–8829. <https://doi.org/10.1029/2019GL083731>
- Elliott, R. L., Brock, F. V., Stone, M. L., & Harp, S. L. (1994). Configurations decisions for an automated weather station network. *Applied Engineering in Agriculture*, 10(1), 45–51.
- Farr, T. G., Rosen, P. A., Caro, E., Crippen, R., Duren, R., Hensley, S., Kobrick, M., Paller, M., Rodriguez, E., Roth, L., Seal, D., Shaffer, S., Shimada, J., Umland, J., Werner, M., Oskin, M., Burbank, D., & Alsdorf, D. (2007). The Shuttle Radar Topography Mission. *Reviews of*

- Geophysics*, 45(2), RG2004. <https://doi.org/10.1029/2005RG000183>
- Fick, S. E., & Hijmans, R. J. (2017). WorldClim 2: new 1-km spatial resolution climate surfaces for global land areas. *International Journal of Climatology*, 37(12), 4302–4315. <https://doi.org/10.1002/joc.5086>
- Froidurot, S., Zin, I., Hingray, B., & Gautheron, A. (2014). Sensitivity of precipitation phase over the swiss alps to different meteorological variables. *Journal of Hydrometeorology*, 15(2), 685–696. <https://doi.org/10.1175/JHM-D-13-073.1>
- Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., Husak, G., Rowland, J., Harrison, L., Hoell, A., & Michaelson, J. (2015). The climate hazards infrared precipitation with stations - A new environmental record for monitoring extremes. *Scientific Data*, 2, 1–21. <https://doi.org/10.1038/sdata.2015.66>
- Garreaud, R., Vuille, M., & Clement, A. C. (2003). The climate of the Altiplano: Observed current conditions and mechanisms of past changes. *Palaeogeography, Palaeoclimatology, Palaeoecology*, 194(1–3), 5–22. [https://doi.org/10.1016/S0031-0182\(03\)00269-4](https://doi.org/10.1016/S0031-0182(03)00269-4)
- Georganos, S., Abdi, A. M., Tenenbaum, D. E., & Kalogirou, S. (2017). Examining the NDVI-rainfall relationship in the semi-arid Sahel using geographically weighted regression. *Journal of Arid Environments*, 146, 64–74. <https://doi.org/10.1016/j.jaridenv.2017.06.004>
- Grohmann, C. H. (2018). Evaluation of TanDEM-X DEMs on selected Brazilian sites: Comparison with SRTM, ASTER GDEM and ALOS AW3D30. *Remote Sensing of Environment*, 212, 121–133. <https://doi.org/10.1016/j.rse.2018.04.043>
- Groisman, P., & Legates, D. (1994). The accuracy of United States precipitation data. *Bulletin of the American Meteorological Society*, 75(2), 215–227. [https://doi.org/10.1175/1520-0477\(1994\)0752.0.CO;2](https://doi.org/10.1175/1520-0477(1994)0752.0.CO;2)
- Huang Kun-yi, & Zhou Xiong. (1981). The whittaker-vondrak method of data smoothing as a numerical filter. *Chinese Astronomy and Astrophysics*, 5(4), 449–454. [https://doi.org/10.1016/0275-1062\(81\)90011-4](https://doi.org/10.1016/0275-1062(81)90011-4)
- Huffman, G. J., Adler, R. F., Arkin, P., Chang, A., Ferraro, R., Gruber, A., Janowiak, J., McNab, A., Rudolf, B., & Schneider, U. (1997). The Global Precipitation Climatology Project (GPCP) Combined Precipitation Dataset. *Bulletin of the American Meteorological Society*, 78(1), 5–20. [https://doi.org/10.1175/1520-0477\(1997\)078<0005:TGPCPG>2.0.CO;2](https://doi.org/10.1175/1520-0477(1997)078<0005:TGPCPG>2.0.CO;2)

- Huffman, G. J., Adler, R. F., Bolvin, D. T., Gu, G., Nelkin, E. J., Bowman, K. P., Hong, Y., Stocker, E. F., & Wolff, D. B. (2007). The TRMM Multisatellite Precipitation Analysis (TMPA): Quasi-global, multiyear, combined-sensor precipitation estimates at fine scales. *Journal of Hydrometeorology*, 8(1), 38–55. <https://doi.org/10.1175/JHM560.1>
- Huffman, G. J., Adler, R. F., Bolvin, D. T., & Nelkin, E. J. (2010). The TRMM Multi-Satellite Precipitation Analysis (TMPA). In *Satellite Rainfall Applications for Surface Hydrology* (pp. 3–22). Springer Netherlands. [https://doi.org/10.1007/978-90-481-2915-7\\_1](https://doi.org/10.1007/978-90-481-2915-7_1)
- Hunink, J. E., Immerzeel, W. W., & Droogers, P. (2014). A High-resolution precipitation 2-step mapping procedure (HiP2P): development and application to a tropical mountainous area. *Remote Sensing of Environment*, 140, 179–188. <https://doi.org/10.1016/j.rse.2013.08.036>
- Hunziker, S., Gubler, S., Calle, J., Moreno, I., Andrade, M., Velarde, F., Ticona, L., Carrasco, G., Castellón, Y., Oria, C., Croci-Maspoli, M., Konzelmann, T., Rohrer, M., & Brönnimann, S. (2017). Identifying, attributing, and overcoming common data quality issues of manned station observations. *International Journal of Climatology*, 37(11), 4131–4145. <https://doi.org/10.1002/joc.5037>
- Kidd, C. (2001). Satellite rainfall climatology: A review. *International Journal of Climatology*, 21(9), 1041–1066. <https://doi.org/10.1002/joc.635>
- Krieger, G., Zink, M., Bachmann, M., Bräutigam, B., Schulze, D., Martone, M., Rizzoli, P., Steinbrecher, U., Walter Antony, J., De Zan, F., Hajnsek, I., Papathanassiou, K., Kugler, F., Rodriguez Cassola, M., Younis, M., Baumgartner, S., López-Dekker, P., Prats, P., & Moreira, A. (2013). TanDEM-X: A radar interferometer with two formation-flying satellites. *Acta Astronautica*, 89, 83–98. <https://doi.org/10.1016/j.actaastro.2013.03.008>
- Lassegues, P. (2018). Daily and climatological fields of precipitation over the western Alps with a high density network for the period of 1990–2012. *Theoretical and Applied Climatology*, 131(1–2). <https://doi.org/10.1007/s00704-016-1954-z>
- Lavado Casimiro, W. S., Ronchail, J., Labat, D., Espinoza, J. C., & Guyot, J. L. (2012). Analyse de la pluie et de l'écoulement au Pérou (1969–2004) : Bassins versants du Pacifique, du Lac Titicaca et de l'Amazone. *Hydrological Sciences Journal*, 57(4), 625–642. <https://doi.org/10.1080/02626667.2012.672985>
- Lloyd, C., Gash, J., Shuttleworth, W., & Marques, A. (1988). The measurement and modelling of rainfall interception by amazonian rain forest. *Agricultural and Forest Meteorology*,

43(1), 277–294.

- Marcos Martín, C. (2018). Satélites meteorológicos. *Física Del Caos En La Predicción Meteorológica*, 83–102. <https://doi.org/10.31978/014-18-009-x.07>
- Martin, D. W., & Scherer, W. D. (1973). Review of Satellite Rainfall Estimation Methods. *Bulletin of the American Meteorological Society*, 29, 661–675.
- Morera, S. B., Condom, T., Crave, A., Steer, P., & Guyot, J. L. (2017). The impact of extreme El Niño events on modern sediment transport along the western Peruvian Andes (1968–2012). *Scientific Reports*, 7(1), 1–14. <https://doi.org/10.1038/s41598-017-12220-x>
- Mourre, L., Condom, T., Junquas, C., Lebel, T., E. Sicart, J., Figueroa, R., & Cochachin, A. (2016). Spatio-temporal assessment of WRF, TRMM and in situ precipitation data in a tropical mountain environment (Cordillera Blanca, Peru). *Hydrology and Earth System Sciences*, 20(1), 125–141. <https://doi.org/10.5194/hess-20-125-2016>
- Organizacion Meteorológica Mundial. (2010). Guía red de estaciones de observación en superficie del smoc (GSN) y de la red de estaciones de observación en altitud del smoc (GUAN). *Gcos - 144*, 144, 36.
- Organización Meteorológica Mundial. (2011). Guía de prácticas hidrológicas. In Presidente de la Junta de publicaciones (Ed.), *OMM (OMM)*. <https://doi.org/OMM-Nº 168>
- Organización Meteorológica Mundial. (2017). *Guía de Instrumentos y Métodos de Observación Meteorológicos*. OMM.
- Poveda, G., Álvarez, D. M., & Rueda, Ó. A. (2011). Hydro-climatic variability over the Andes of Colombia associated with ENSO: A review of climatic processes and their impact on one of the Earth's most important biodiversity hotspots. *Climate Dynamics*, 36(11–12), 2233–2249. <https://doi.org/10.1007/s00382-010-0931-y>
- Rauthe, M., Steiner, H., Riediger, U., Mazurkiewicz, A., & Gratzki, A. (2013). A Central European precipitation climatology - Part I: Generation and validation of a high-resolution gridded daily data set (HYRAS). *Meteorologische Zeitschrift*, 22(3), 235–256. <https://doi.org/10.1127/0941-2948/2013/0436>
- Schneider, U., Becker, A., Finger, P., Meyer-Christoffer, A., Ziese, M., & Rudolf, B. (2014). GPCC's new land surface precipitation climatology based on quality-controlled in situ data and its role in quantifying the global water cycle. *Theoretical and Applied Climatology*, 115(1–2), 15–40. <https://doi.org/10.1007/s00704-013-0860-x>
- Schultz, M., Clevers, J. G. P. W., Carter, S., Verbesselt, J., Avitabile, V., Quang, H. V., & Herold,

- M. (2016). Performance of vegetation indices from Landsat time series in deforestation monitoring. *International Journal of Applied Earth Observation and Geoinformation*, 52(May 2012), 318–327. <https://doi.org/10.1016/j.jag.2016.06.020>
- Schwarb, M., Acuña, D., Konzelmann, T., Rohrer, M., Salzmann, N., Serpa Lopez, B., & Silvestre, E. (2011). A data portal for regional climatic trend analysis in a Peruvian High Andes region. *Advances in Science and Research*, 6(1), 219–226. <https://doi.org/10.5194/asr-6-219-2011>
- She, X., Zhang, L., Cen, Y., Wu, T., Huang, C., & Baig, M. H. A. (2015). Comparison of the continuity of vegetation indices derived from Landsat 8 OLI and Landsat 7 ETM+ data among different vegetation types. *Remote Sensing*, 7(10), 13485–13506. <https://doi.org/10.3390/rs71013485>
- Shimada, M., Tadono, T., & Rosenqvist, A. (2010). Advanced land observing satellite (ALOS) and monitoring global environmental change. *Proceedings of the IEEE*, 98(5), 780–799. <https://doi.org/10.1109/JPROC.2009.2033724>
- Shukla, J. B., Sundar, S., Misra, A. K., & Naresh, R. (2008). Modelling the removal of gaseous pollutants and particulate matters from the atmosphere of a city by rain: Effect of cloud density. *Environmental Modeling and Assessment*, 13(2), 255–263. <https://doi.org/10.1007/s10666-007-9085-7>
- Simpson, J., Adler, R. F., & North, G. R. (1988). A Proposed Tropical Rainfall Measuring Mission (TRMM) Satellite. *Bulletin of the American Meteorological Society*, 69(3), 278–295. [https://doi.org/10.1175/1520-0477\(1988\)069<0278:aptrmm>2.0.co;2](https://doi.org/10.1175/1520-0477(1988)069<0278:aptrmm>2.0.co;2)
- Smith, E. A., Asrar, G., Furuhashi, Y., Ginati, A., Mugnai, A., Nakamura, K., Adler, R. F., Chou, M. D., Desbois, M., Durning, J. F., Entin, J. K., Einaudi, F., Ferraro, R. R., Guzzi, R., Houser, P. R., Hwang, P. H., Iguchi, T., Joe, P., Kakar, R., ... Zhang, W. (2007). International global precipitation measurement (GPM) program and mission: An overview. *Advances in Global Change Research*, 28, 611–653. [https://doi.org/10.1007/978-1-4020-5835-6\\_48](https://doi.org/10.1007/978-1-4020-5835-6_48)
- Vicente-Serrano, S. M., Aguilar, E., Martínez, R., Martín-Hernández, N., Azorin-Molina, C., Sanchez-Lorenzo, A., El Kenawy, A., Tomás-Burguera, M., Moran-Tejeda, E., López-Moreno, J. I., Revuelto, J., Beguería, S., Nieto, J. J., Drumond, A., Gimeno, L., & Nieto, R. (2017). The complex influence of ENSO on droughts in Ecuador. *Climate Dynamics*, 48(1–2), 405–427. <https://doi.org/10.1007/s00382-016-3082-y>
- Villavicencio, E., Medina, K., Loarte, E. y León, H. (2021). Improved of precipitation and



- temperature satellite dataset in areas with scarce weather stations data: case study in Ancash, Peru [Manuscrito enviado para publicación]. *Earth System Science Data*.
- Vuolo, F., Mattiuzzi, M., Klisch, A., & Atzberger, C. (2012). Data service platform for MODIS Vegetation Indices time series processing at BOKU Vienna: current status and future perspectives. *Earth Resources and Environmental Remote Sensing/GIS Applications III*, 8538(October), 85380A. <https://doi.org/10.1117/12.974857>
- Willmott, C. J., Rowe, C. M., & Philpot, W. D. (1985). Small-scale climate maps: A sensitivity analysis of some common assumptions associated with grid-point interpolation and contouring. *American Cartographer*, 12(1), 5–16. <https://doi.org/10.1559/152304085783914686>
- Wilson, L., Lettenmaier, D., & Skillingstad, E. (1992). A hierarchical stochastic model of large-scale atmospheric circulation patterns and multiple station daily precipitation. *Geophysical Research*, 97(91), 2791–2809.
- WMO, W. M. O., & UNESCO, U. N. E. and S. O. (1998). International Glossary of Hydrology. In *IHP/OHP-Berichte* (Issue 12). [http://www.wmo.int/pages/prog/hwrr/publications/international\\_glossary/385\\_IGH\\_2012.pdf](http://www.wmo.int/pages/prog/hwrr/publications/international_glossary/385_IGH_2012.pdf)
- Xie, P., & Arkin, P. A. (1997). Global Precipitation: A 17-Year Monthly Analysis Based on Gauge Observations, Satellite Estimates, and Numerical Model Outputs. *Bulletin of the American Meteorological Society*, 78(11), 2539–2558. [https://doi.org/10.1175/1520-0477\(1997\)078<2539:GPAYMA>2.0.CO;2](https://doi.org/10.1175/1520-0477(1997)078<2539:GPAYMA>2.0.CO;2)
- Yamaguchi, Y., Kahle, A. B., Tsu, H., Kawakami, T., & Pniel, M. (1998). Overview of advanced spaceborne thermal emission and reflection radiometer (ASTER). *IEEE Transactions on Geoscience and Remote Sensing*, 36(4), 1062–1071. <https://doi.org/10.1109/36.700991>
- Yamazaki, D., Ikeshima, D., Tawatari, R., Yamaguchi, T., O’Loughlin, F., Neal, J. C., Sampson, C. C., Kanae, S., & Bates, P. D. (2017). A high-accuracy map of global terrain elevations. *Geophysical Research Letters*, 44(11), 5844–5853. <https://doi.org/10.1002/2017GL072874>
- Zhang, X., Feng, Y., & Chan, R. (2018). Introduction to RClimDex. *Climate Research Division Environment Canada*, 1–26.
- Zhao, C., Yao, S., Zhang, S., Han, H., Zhao, Q., & Yi, S. (2015). Validation of the Accuracy of Different Precipitation Datasets over Tianshan Mountainous Area. *Advances in*

*Meteorology*, 2015. <https://doi.org/10.1155/2015/617382>

Zoungrana, B. J. B., Conrad, C., Amekudzi, L. K., Thiel, M., & Dapola Da, E. (2015). Land use/cover response to rainfall variability: A comparing analysis between NDVI and EVI in the southwest of Burkina Faso. *Climate*, 3(1), 63–77. <https://doi.org/10.3390/cli3010063>

## ANEXOS

### Anexo 1. Ejemplos de descarga de productos satelitales.



Figura A1. Portal web de descargar de datos PERSIANN.

Una vez ubicados en el portal “CHRS Data Portal”, nos dirigimos a la parte inferior de la pantalla. En *Dataset* seleccionaremos el tipo de producto (PERSIANN, PERSIANN-CCS o PERSIANN CDR). En *Time Step* elegimos la resolución temporal (Horario, diario, mensual o anual), *Domain* determinará nuestra zona de estudio (límites políticos, polígono del área de interés, países, subcuencas, etc.).

Una vez establecidos estos parámetros, lo siguiente es preparar la información a descargar. Para ello, en la misma parte inferior elegiremos la pestaña de *Download*.

Elegimos el período de información que deseamos descargar, luego la extensión de archivo que deseamos en *Format* y en *Compression* elegimos ZIP.




Figura A2. Selección de fechas de descargar de datos.

Damos clic en la opción *Download* y se nos abrirá una ventana que nos solicitará nuestro correo, con el cual podremos acceder a la descarga de los archivos.




Figura A3. Registro de e-mail donde se enviará el enlace para descargar los archivos.

Después de unos minutos el enlace para la descarga de datos llegará al correo que hemos consignado y así obtendremos los datos de precipitación.

CHRS CCS data request asistente2.investigacionZvxZzW is ready by http |

CHRS CCS data request <no-reply@uci.edu>  
para mí ▾  
Your requested data from CHRS is ready  
follow the http link below to retrieve the data:  
[CCS.country.daily.20200101-20200131](http://CCS.country.daily.20200101-20200131)

16:5

Figura A4. E-mail con el enlace para descargar los archivos.

La descarga de los productos de precipitación CHIRPS pueden realizarse desde la página del distribuidor o desde un gestor de descargas como es el caso del aplicativo web Climate Engine de la Universidad de Idaho (<https://app.climateengine.org/climateEngine>). Este repositorio de información fue realizado y construido por Huntington et al. (2017) y fue diseñado para el mapeo de anomalías y valores bajo demanda, análisis de series de tiempo y resúmenes estadísticos para generar resultados descargables en formato GeoTIFF y resultados de series de tiempo en formato .csv o .xlsx.

La descarga de datos puede realizarse desde períodos cortos de 15 días, hasta toda la información almacenada desde el inicio de la medición. Los datos de CHIRPS, están constituidos de dos maneras: los datos diarios y los pentadales o cada 5 días.

A continuación, se detallan los pasos para la descarga y adquisición de los archivos.




Figura A5. Portal web de descargar de datos CHIRP y CHIRPS.

En cuanto a los productos de NDVI y EVI, se descargan desde el gestor de descargas de la misma University of Natural Resources and Life Sciences de Vienna. El método de descarga se realiza de la siguiente manera:

The image shows a web portal interface for downloading satellite data. It is divided into five numbered sections:

- Select product:** A list of four product options with checkboxes. The first three are unchecked, and the fourth, "MODIS EVI 16-Day Global 250m raw", is checked.
- Select sensor:** A dropdown menu showing "Combined Terra & Aqua".
- Select region of interest:** A map of South America with a black rectangle highlighting a region in Peru. The rectangle's corners are marked with 'L' (Left) and 'R' (Right). Below the map, there are input fields for ULC Lat, ULC Lng, LRC Lat, and LRC Lng.
- Select dates of start and end:** Two input fields for "Start date" and "End date". The "Start date" field contains "2012-01-01".
- Filtering parameters:** Two input fields for "Lambda" (set to 6000) and "Number of iterations" (set to 2).
- File output parameters:** Three dropdown menus for "Temporal resolution" (set to 7-days), "File type" (set to GeoTIFF (.tif)), and "Projection (EPSG code)" (set to 4326).

Figura A6. Portal web de descargar de productos NDVI y EVI. 1) tipo de producto, 2) selección de área de interés, 3) período, 4) filtros y 5) resolución temporal y espacial.



Anexo 2. Lista de productos satelitales que miden precipitación, NDVI y DEM a nivel mundial.

| Nombre del producto de precipitación | Página oficial del producto                                                                                                                                                                               | Fuente                 |
|--------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------|
| Reanálisis de la agencia NCEP-NCAR   | <a href="https://psl.noaa.gov/data/gridded/tables/precipitation.html">https://psl.noaa.gov/data/gridded/tables/precipitation.html</a>                                                                     | Xie y Arkin, 1997      |
| Conjunto de datos GPCC               | <a href="https://psl.noaa.gov/data/gridded/data.gpcc.html">https://psl.noaa.gov/data/gridded/data.gpcc.html</a>                                                                                           | Schneider et al., 2014 |
| Datos TRMM/GPM                       | <a href="https://disc.gsfc.nasa.gov/information?page=1&amp;project=TRMM,GPM&amp;keywords=precipitation">https://disc.gsfc.nasa.gov/information?page=1&amp;project=TRMM,GPM&amp;keywords=precipitation</a> | Huffman et al., 2010   |
| Datos CHIRPS                         | <a href="https://earlywarning.usgs.gov/fews/datadownloads/Global/CHIRPS%202.0">https://earlywarning.usgs.gov/fews/datadownloads/Global/CHIRPS%202.0</a>                                                   | Funk et al., 2015      |
| PERSIANN                             | <a href="https://chrsdata.eng.uci.edu/">https://chrsdata.eng.uci.edu/</a>                                                                                                                                 | Ashouri et al., 2015   |
| Índice de Precipitación Global (GPI) | <a href="http://research.jisao.washington.edu/data_sets/gpi/">http://research.jisao.washington.edu/data_sets/gpi/</a>                                                                                     |                        |
| PISCOp                               | <a href="http://iridl.ldeo.columbia.edu/SOURCES/.SENAMHI/.HSR/.PISCO/index.html?Set-Language=es">http://iridl.ldeo.columbia.edu/SOURCES/.SENAMHI/.HSR/.PISCO/index.html?Set-Language=es</a>               | Aybar et al., 2017     |

| Nombre del producto raster | Página oficial del producto                                                                                                                                     | Fuente                |
|----------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------|
| NDVI Algoritmo BOKU        | <a href="http://ivfl-info.boku.ac.at/satellite-data-processing/dataprocess-global">http://ivfl-info.boku.ac.at/satellite-data-processing/dataprocess-global</a> | Vuolo et al., 2012    |
| EVI Algoritmo BOKU         | <a href="http://ivfl-info.boku.ac.at/satellite-data-processing/dataprocess-global">http://ivfl-info.boku.ac.at/satellite-data-processing/dataprocess-global</a> | Vuolo et al., 2012    |
| MERIT DEM                  | <a href="http://hydro.iis.u-tokyo.ac.jp/~yamada/MERIT_DEM/">http://hydro.iis.u-tokyo.ac.jp/~yamada/MERIT_DEM/</a>                                               | Yamazaki et al., 2017 |

Anexo 3. Comparación de la precipitación estimada con el modelo a nivel mensual para un año hidrológico.




Figura B1. Correlación entre de las precipitaciones estimada y modelada a nivel mensual en un año hidrológico.