

UNIVERSIDAD NACIONAL DE CAJAMARCA
FACULTAD DE INGENIERÍA
ESCUELA ACADEMICO PROFESIONAL DE INGENIERÍA HIDRAULICA



TESIS

**“VALIDACIÓN Y CORRECCIÓN DE LA PRECIPITACIÓN MENSUAL
GENERADA CON EL PRODUCTO PISCO (SENAMHI) DEL PERÍODO DE 1981
AL 2023, DE LA REGIÓN CAJAMARCA”**

PARA OPTAR EL TITULO PROFESIONAL DE:

INGENIERO HIDRAULICO

AUTOR:

Bach. KEVIN OMAR CHAVEZ SANCHEZ

ASESOR:

Dr. Ing. JOSÉ FRANCISCO HUAMÁN VIDAURRE

CAJAMARCA-PERU

2025

CONSTANCIA DE INFORME DE ORIGINALIDAD

- FACULTAD DE INGENIERÍA -

1. Investigador: KEVIN OMAR CHAVEZ SANCHEZ
DNI: 71502980
Escuela Profesional: INGENIERÍA HIDRÁULICA
2. Asesor: Dr. Ing. JOSÉ FRANCISCO HUAMÁN VIDAURRE.
Facultad: INGENIERÍA.
3. Grado académico o título profesional
☐ Bachiller ☒ Título profesional ☐ Segunda especialidad
☐ Maestro ☐ Doctor
4. Tipo de Investigación:
☒ Tesis ☐ Trabajo de investigación ☐ Trabajo de suficiencia profesional
☐ Trabajo académico
5. Título de Trabajo de Investigación: VALIDACIÓN Y CORRECCIÓN DE LA PRECIPITACIÓN MENSUAL GENERADA CON EL PRODUCTO PISCO (SENAMHI) DEL PERÍODO DE 1981 AL 2023, DE LA REGIÓN CAJAMARCA
6. Fecha de evaluación: 20 de Diciembre de 2025
7. Software antiplagio: ☒ TURNITIN ☐ URKUND (ORIGINAL) (*)
8. Porcentaje de Informe de Similitud: 22 %
9. Código Documento: oid:3117:542454765
10. Resultado de la Evaluación de Similitud:
☒ APROBADO ☐ PARA LEVANTAMIENTO DE OBSERVACIONES O DESAPROBADO

Fecha Emisión: 24 de enero de 2026

 FIRMA DEL ASESOR Nombres y Apellidos: JOSÉ FRANCISCO HUAMÁN VIDAURRE DNI: 26609077	 FIRMA DIGITAL Firmado digitalmente por: BAZAN DIAZ Laura Sofia FAU 20148258001 soft Motivo: En señal de conformidad Fecha: 24/01/2026 18:01:12-0500 UNIDAD DE INVESTIGACIÓN FI
--	--

* En caso se realizó la evaluación hasta setiembre de 2023



Universidad Nacional de Cajamarca

"Norte de la Universidad Peruana"

Fundada por Ley 14015 del 13 de Febrero de 1992

FACULTAD DE INGENIERÍA

Teléf. N° 365976 Anexo N° 1129-1130



SUSTENTACIÓN PÚBLICA DE TESIS.

ACTA N° 0024-2026

TÍTULO : VALIDACIÓN Y CORRECCIÓN DE LA PRECIPITACIÓN MENSUAL GENERADA CON EL PRODUCTO PISCO (SENAMHI) DEL PERIODO DE 1981 AL 2023, DE LA REGIÓN CAJAMARCA

ASESOR : Dr. Ing. José Francisco Huamán Vidaurre.

En la ciudad de Cajamarca, dando cumplimiento a lo dispuesto por el Art. 35 del Reglamento de Grados y Títulos de la Facultad de Ingeniería de la Universidad Nacional de Cajamarca, la Secretaría Académica de la Facultad de Ingeniería, da a conocer que, a los **diecinueve días del mes de febrero de 2026**, siendo las dieciséis horas (04:00 p.m.) en la Sala de Audiovisuales (Edificio 1A - Segundo Piso), de la Facultad de Ingeniería, de la Universidad Nacional de Cajamarca, se reunieron los Señores Miembros del Jurado Evaluador:

Presidente : Dr. Ing. Luis Andrés León Chávez.
Vocal : Dr. Ing. Luis Vásquez Ramírez.
Secretario : M.Cs. Ing. José Hilario Longa Álvarez.

Para proceder a escuchar y evaluar la sustentación pública de la tesis titulada **VALIDACIÓN Y CORRECCIÓN DE LA PRECIPITACIÓN MENSUAL GENERADA CON EL PRODUCTO PISCO (SENAMHI) DEL PERIODO DE 1981 AL 2023, DE LA REGIÓN CAJAMARCA**, presentado por el Bachiller en Ingeniería Hidráulica **KEVIN OMAR CHAVEZ SANCHEZ**, asesorado por el Dr. Ing. José Francisco Huamán Vidaurre, para la obtención del Título Profesional

Los Señores Miembros del Jurado replicaron al sustentante, debatieron entre sí en forma libre y reservada y lo evaluaron de la siguiente manera:

EVALUACIÓN PRIVADA : 07 PTS.
EVALUACIÓN PÚBLICA : 11 PTS.
EVALUACIÓN FINAL : 18 PTS. Dieciocho (En letras)

En consecuencia, se lo declara Aprobado con el calificativo de Dieciocho..... acto seguido, el presidente del jurado hizo saber el resultado de la sustentación, levantándose la presente a las dieciséis horas del mismo día, con lo cual se dio por terminado el acto, para constancia se firmó por quintuplicado.

Dr. Ing. Luis Andrés León Chávez.
Presidente

Dr. Ing. Luis Vásquez Ramírez.
Vocal

M.Cs. Ing. José Hilario Longa Álvarez.
Secretario

Dr. Ing. José Francisco Huamán Vidaurre.
Asesor

AGRADECIMIENTO

Mi más profundo agradecimiento al Dr. José Francisco Huamán Vidaurre por su dedicación y paciencia infinita. Su dirección académica, llena de sabiduría y estímulo, ha sido fundamental para dar forma a esta investigación y mi crecimiento como investigador.

Quiero expresar mi sincero agradecimiento al Ing. MSc. Rubén Omar Ortiz Vásquez, gran amigo, por su orientación experta y paciencia a lo largo de este proyecto. Sus consejos y comentarios fueron invaluable para dar forma a esta tesis.

DEDICATORIA

A todos aquellos que han sido una parte integral de mi camino académico y personal. A mis padres, por su amor incondicional y por creer en mí desde el primer día. Por sus sacrificios y su apoyo constante que han sido la clave de mi éxito. A mis profesores y mentores, por su dedicación y pasión por la enseñanza y por guiarme en mi camino. A mis compañeros por las risas y el estudio compartido.

Agradezco a Dios por darme fuerza y sabiduría durante todo este proceso de investigación.

¡Se Fuerte y Valiente! #312

Kevin Omar Chávez Sánchez

INDICE

AGRADECIMIENTO	iv
DEDICATORIA	v
RESUMEN.....	xiii
ABSTRACT... ..	xv
CAPITULO I: INTRODUCCIÓN	1
1. 1. Planteamiento del problema.....	3
CAPITULO II: MARCO TEÓRICO	8
2. 1. Antecedentes de la investigacion	8
2. 2. Marco conceptual.....	20
2.2.1. Satélites meteorológicos	20
2.2.2. Sensores Térmicos Infrarrojos (IR)	21
2.2.3. Sensores de Microondas Pasivos (PMW)	22
2.2.4. Ecos parásitos terrestres	23
2.2.5. Ciclo Hidrológico	24
2.2.6. Forzantes climáticas.....	25
2.2.7. Análisis de Conglomerados.....	28
2.2.8. Datos grillados.....	28
2.2.9. CHIRPS	30
2.2.10. PISCO	32
2.2.11. Dendograma	34
2. 3. Definición de Términos Básicos	35
2.3.1. Año Hidrológico.....	35
2.3.2. Precipitación.....	35
2.3.3. Pluviómetros	36
2.3.4. Red Pluviométrica	37
2.3.5. Radares meteorológicos	38
2.3.6. Serie de datos	38
2.3.7. Estacionalidad	39
2.3.8. Índices de Evaluación de la Precisión y Desempeño de los Datos	41
2.3.8.1. Coeficiente de Determinación (R^2).....	41
2.3.8.2. Sesgo Relativo (Bias %).....	41
2.3.8.3. Coeficiente de Eficiencia de Nash-Sutcliffe (NSE).....	42
2.3.8.4. Relación del Error Cuadrático Medio (RSR)	43
2.3.9. Distribución de probabilidad.....	43

2.3.9.1. Cuartiles	44
2.3.9.2. Función de Distribución Acumulativa (CDF)	44
2.3.9.3. Corrección de Sesgos (Bias Correction)	44
2.3.9.4. Quantile mapping	44
2.3.10. Isoyetas	45
2.3.11. Archivo NetCDF.....	46
CAPITULO III: MATERIALES Y MÉTODOS	47
3. 1. Descripción y Etapas de la Investigación	47
3. 2. Materiales y equipos.....	52
3. 3. Metodología.....	53
3.3.1. Tipo de Investigación	53
3.3.2. Nivel de Investigación	53
3.3.3. Diseño de Investigación.....	53
3. 4. Procedimiento	54
CAPITULO IV: ANALISIS Y DISCUSIÓN DE RESULTADOS	54
4.1. Preparación y control de calidad de datos de precipitación.	55
4.1. 1. Procesamiento de la Data estimada del producto PISCO.....	55
4.1. 2. Evaluación del producto PISCO.....	58
4.1. 3. Diagrama de cajas (BOX – PLOT).....	67
4.2. DENDOGRAMA Y UBICACIÓN DE REGIONES HIDROCLIMATICAS SIMILARES..	73
4.3. QUANTILE MAPPING Y COMPLETACION DE DATOS.....	80
4.4. GENERACION DE ISOYETAS Y EL NC.....	86
4.5. MAPAS DE PRECIPITACION GENERADAS POR SENAMHI.....	99
4.6. VALIDACION DE LA DATA PISCO CON ESTACIONES ADICIONALES	100
4.7. ISOYETAS OBTENIDAS A PARTIR DE LA REGIONALIZACION.....	102
Capítulo V. CONCLUSIONES Y RECOMENDACIONES.	103
5. 1. CONCLUSIONES.	104
5. 2. RECOMENDACIONES.	105
CAPITULO VI: REFERENCIAS BIBLIOGRÁFICAS.....	106
ANEXOS.....	108

INDICE DE FIGURAS

Figura 1 Constelación de satélites que aportan datos de sensores de microondas a la misión GPM (Global Precipitation Measurement Mission).....	20
Figura 2 Condiciones de la superficie derivadas de la teledetección por infrarrojos.....	22
Figura 3 Diferencia entre los sensores infrarrojo y los sensores de microndas pasivos.....	23
Figura 4 Espectro del eco de un objetivo meteorológico y de un objetivo terrestre	24
Figura 5 Ciclo hidrológico en una cuenca.....	25
Figura 6 . a)Evolución de la temperatura media del hemisferio norte durante los últimos 500 años. b) Forzantes del sistema climático.....	26
Figura 7 Condiciones del ENSO, i) El Niño. ii) La Niña.....	26
Figura 9 Datos grillados de precipitación (CHIRPS).....	29
Figura 10 Revisión general de CHIRPS.....	31
Figura 11 PISCO GRILLADO PERU	32
Figura 12 Serie temporal generada a partir del PRODUCTO PISCO	33
Figura 13 Variabilidad de las precipitaciones mensual desde el mes de enero de 1981 (X252.5) al mes de diciembre del 1981 (X263.5)	33
Figura 14 Algoritmo del producto PISCO.....	34
Figura 15 Definición de Dendograma.....	35
Figura 16 Diferentes formas de pluviómetros normalizados.....	36
Figura 17 Red de estaciones convencionales distribuidas a nivel nacional.....	37
Figura 18 Radares meteorológicos.....	38
Figura 19 Series de patrones de precipitaciones	39
Figura 21 Distribuciones de probabilidad de datos.....	44
Figura 22 Ejemplo de Quantile Mapping con datos de temperatura	45
Figura 24 Archivo NETCDF	46
Figura 25 Ubicación de la REGION CAJAMARCA EN PERU.....	48
Figura 26 Dendograma de las estaciones meteorológicas	50
Figura 27 Regiones Meteorológicas similares.....	51
Figura 28 Esquema del procedimiento.....	56
Figura 29. Estaciones de la Región Cajamarca usadas en el estudio.....	56
Figura 30. Histogramas representativos de la Comparación PISCO con las estaciones terrestres.....	57
Figura 31. Resultados según la correlación de Pearson.....	60
Figura 32.Resultados según Sesgo Porcentual Bias.....	61
Figura 33 Mapa del sesgo porcentual.....	62
Figura 34. Resultados según la Eficiencia de Nash – Sutcliffe.....	63
Figura 35 Mapa de NSE de Cajamarca.....	64
Figura 36. Resultados según la Relacion de Desviación Estándar Residual.....	66
Figura 37. Mapa de Distribución de Grafico de Cajas, de estaciones representativas de Cajamarca.....	68
Figura 38 Estacion Augusto Weberbauer.....	71
Figura 39. Diagrama de Cajas de la Estación Augusto Weberbauer.....	72
Figura 40. Regiones Hidroclimaticas Identificadas.....	74
Figura 41. Mapa de regiones hidroclimáticas similares.....	77
Figura 42. Registro de la estación Cutervo.....	81
Figura 43. Comparación entre los registros de la serie de la estación terrestre y la generada por el producto PISCO.....	81
Figura 44. Selección del tramo en común	82

Figura 45. Scatter Plot del periodo en común.....	82
Figura 46. Grafico de la curva de distribución de frecuencias	83
Figura 47. Ajuste del Producto Pisco() vs Data PISCO () vs Data observada ()	83
Figura 48. Curva de distribución con la precipitación reajustada.....	84
Figura 49. Registro del Producto Pisco() vs Data PISCO () vs Data observada ()	84
Figura 50. Mapa de precipitación de Cajamarca. Mes de enero.	87
Figura 51. Mapa de precipitación de Cajamarca. Mes de Febrero.....	88
Figura 52. Mapa de precipitación de Cajamarca. Mes de Marzo	89
Figura 53. Mapa de precipitación de Cajamarca. Mes de Abril.	90
Figura 54. Mapa de precipitación de Cajamarca. Mes de Mayo.....	91
Figura 55. Mapa de precipitación de Cajamarca. Mes de Junio.	92
Figura 56. Mapa de precipitación de Cajamarca. Mes de Julio.	93
Figura 57. Mapa de precipitación de Cajamarca. Mes de Agosto.	94
Figura 58. Mapa de precipitación de Cajamarca. Mes de Septiembre.	95
Figura 59. Mapa de precipitación de Cajamarca. Mes de Octubre.	96
Figura 60. Mapa de precipitación de Cajamarca. Mes de Noviembre.	97
Figura 61. Mapa de precipitación de Cajamarca. Mes de Diciembre.	98
Figura 62. Precipitación promedio mensual - SENAMHI.....	99
Figura 63. Isoyetas obtenidas a partir de la regionalización.....	103

INDICE DE TABLAS

Tabla 1. Principales forzantes climáticas de Perú.....	28
Tabla 2. Conjuntos de datos meteorológicos de precipitación grillada diarios existentes para Perú.....	29
Tabla 3. Densidades Recomendadas para las estaciones meteorológicas	40
Tabla 4. Rango de evaluación de R^2	41
Tabla 5. Rango de evaluación de BIAS	42
Tabla 6. Rango de evaluación de BIAS	42
Tabla 7. Rango de evaluación de BIAS	43
Tabla 8. Estaciones Meteorológicas en la región de Cajamarca.....	49
Tabla 9. índices estadísticos obtenidos para cada estación	58
Tabla 10. Resultados de la NSE en las 13 provincias de Cajamarca (Ordenadas de mayor a menor eficiencia esperada del modelo PISCO).....	65
Tabla 11. Estaciones con sus Grupos Hidrológicos Identificados	78
Tabla 12. Proceso de Downscaling seguido. Estación Cutervo.....	85
Tabla 13. Resultados de la validación del producto PISCO frente a datos observados en las estaciones Yanacocha, Maqui Maqui, La Quinoa y Carachugo.....	100
Tabla 14. Conclusión de la validación del producto PISCO frente a datos observados en las estaciones Yanacocha, Maqui Maqui, La Quinoa y Carachugo	102

INDICE DE ANEXOS

ANEXO A. Código de lenguaje de programación para extraer datos de precipitación del producto grillado PISCO.....	111
ANEXO B. Gráficos de dispersión de las Estaciones de la Región Cajamarca.....	112
ANEXO C. Código para la elaboración del dendograma de las estaciones.....	117
ANEXO D. Código de programación para la elaboración del Downscaling PP.....	118
ANEXO E. Código de programación para la unir todos los archivos.....	122
ANEXO F. Código de programación usado para generar el archivo NET CDF.....	123
ANEXO G. Correo enviando por la DZ3 para la proporción de la Data de precipitación para tesisistas por parte de SENAMHI.....	125
ANEXO H. Carta de presentación del Decano de Ingeniería, para la adquisición de datos por SENAMHI.....	126
ANEXO I. Base de datos Generada por el Downscaling.....	128
ANEXO J. Código de programación para validar PISCO con estaciones Carachugo, Maqui Maqui, Yanacocha, La quinua.....	129
ANEXO K. Data de la Estación Yanacocha del Informe técnico del estudio Hidrológico de la presa el Chonta en Cajamarca.....	131
ANEXO L. Data de la Estación Maqui Maqui del Informe técnico del estudio Hidrológico de la presa el Chonta en Cajamarca.....	132
ANEXO M. Data de la Estación La Quinua del Informe técnico del estudio Hidrológico de la presa el Chonta en Cajamarca.....	133
ANEXO N. Data de la Estación Carachugo del Informe técnico del estudio Hidrológico de la presa el Chonta en Cajamarca.....	134
ANEXO O. Código de programación para la generación de Isoyetas a partir de la regionalización.....	135

Palabras Claves:

Precipitación, proceso mediante el cual el agua contenida en la atmósfera cae a la superficie terrestre en forma de lluvia, granizo o nieve. Representa una de las variables climáticas más importantes para el análisis hidrológico, ya que influye directamente en la disponibilidad de los recursos hídricos y en la modelación de los sistemas naturales.

mapeo de cuartiles, técnica estadística utilizada para ajustar o corregir sesgos en los datos climáticos, comparando la distribución de valores observados con la de valores simulados o estimados. Este método permite obtener una representación más realista de las condiciones locales, mejorando la precisión de los modelos climáticos o hidrológicos.

downscaling, conjunto de métodos que permiten traducir la información climática de gran escala (por ejemplo, de modelos globales) a una resolución espacial más detallada. Esta técnica es fundamental para analizar la variabilidad climática regional y generar datos más útiles para estudios hidrológicos y de gestión ambiental.

PISCOm, corresponde al conjunto de datos del producto PISCO (Peruvian Interpolated data of SENAMHI Climatological Observations) en su versión mensual, elaborado por el SENAMHI. Proporciona información climática interpolada y validada a nivel nacional, constituyendo una base fundamental para investigaciones relacionadas con el clima y los recursos hídricos en el Perú.

RESUMEN

La presente investigación tuvo como objetivo validar y corregir la precipitación mensual del producto PISCO (SENAMHI) en la región Cajamarca, durante el periodo 1981–2025, mediante la comparación con datos de 53 estaciones meteorológicas convencionales. El análisis de indicadores de desempeño (BIAS, R^2 , NSE y RSR) evidenció un sesgo predominante de subestimación por parte de PISCO, aunque con adecuada representación de la variabilidad temporal. Para corregir estos sesgos, se aplicó el método de quantile mapping, mejorando la calidad de los datos para su uso en análisis hidrológicos.

A través del proceso de *downscaling*, se generaron series corregidas y completadas para cada estación, las cuales fueron integradas en un nuevo producto climático en formato NetCDF, de alta resolución espacial y coherencia temporal. Con esta base de datos, se elaboraron isoyetas representativas de la distribución espacial de la precipitación y se realizó un análisis de agrupamiento jerárquico (*clustering*) que permitió identificar cinco regiones hidroclimáticas homogéneas en el departamento.

Los resultados obtenidos constituyen una herramienta técnica valiosa para la modelación hidrológica, la planificación del recurso hídrico y la gestión territorial. Además, aportan una base sólida para estudios de variabilidad climática y evaluación de impactos del cambio climático en el ámbito regional.

Palabras Claves: Precipitación, mapeo de cuartiles, downscaling PISCOm ,

Keywords:

Precipitation, It is the process by which water contained in the atmosphere falls to the Earth's surface in the form of rain, hail, or snow. It represents one of the most important climatic variables for hydrological analysis, as it directly influences the availability of water resources and the modeling of natural systems.

Quantile mapping, A statistical technique used to adjust or correct biases in climate data by comparing the distribution of observed values with that of simulated or estimated values. This method allows for a more realistic representation of local conditions, improving the accuracy of climate or hydrological models.

Downscaling:

A set of methods that translate large-scale climate information (for example, from global models) into a finer spatial resolution. This technique is essential for analyzing regional climate variability and generating more useful data for hydrological and environmental management studies.

PISCOm, Refers to the dataset of the PISCO product (Peruvian Interpolated Data of SENAMHI Climatological Observations) in its monthly version, developed by SENAMHI. It provides interpolated and validated climate information at the national level, serving as a key database for research related to climate and water resources in Peru.

ABSTRACT

The present research aimed to validate and correct the monthly precipitation data from the SENAMHI (PISCO) product in the Cajamarca region during the period 1981–2025 by comparing it with data from 53 conventional meteorological stations. The analysis of performance indicators (BIAS, R^2 , NSE, and RSR) revealed a predominant underestimation bias on the part of PISCO, although with adequate representation of temporal variability. To correct these biases, the quantile mapping method was applied, improving data quality for use in hydrological analyses. Through the downscaling process, corrected and completed series were generated for each station, which were integrated into a new climate product in NetCDF format, with high spatial resolution and temporal coherence. With this database, isohyets representative of the spatial distribution of precipitation were developed, and a hierarchical clustering analysis was performed, which allowed the identification of five homogeneous hydroclimatic regions in the department. The results obtained constitute a valuable technical tool for hydrological modeling, water resource planning, and territorial management. They also provide a solid basis for climate variability studies and assessments of climate change impacts at the regional level.

Key Words: Precipitation, quantile mapping, PISCOm.

CAPITULO I: INTRODUCCIÓN

La precipitación es uno de los componentes climáticos más críticos, influyendo directamente en la disponibilidad de recursos hídricos, la agricultura, los ecosistemas y la vida cotidiana de las personas (Ebert et al. 2007), por lo que su cuantificación permite el desarrollo y monitoreo de la gestión y modelización de los recursos hídricos. Las observaciones convencionales desde estaciones pluviométricas son un insumo ideal para las aplicaciones antes mencionadas. Sin embargo, la gran variabilidad espacial y la distribución heterogénea y limitada de pluviómetros combinada con deficiencias sistemáticas en la calidad de los datos (Hunziker et al. 2017) impiden su uso generalizado en el Perú (Aybar et al. 2020). En consecuencia, los investigadores han llegado a depender de conjuntos de sensores que vuelan en una variedad de satélites durante los últimos 25 años para obtener la mayor parte de la información utilizada para estimar las precipitaciones a nivel mundial (Huffman et al. 2007). En Perú, la cantidad de estaciones hidrométricas no logra una representatividad adecuada. Aunque los pluviómetros, los radares meteorológicos y las boyas oceánicas son precisos a nivel local o regional, no pueden proporcionar una cobertura global (Duan et al. 2016). Ante esta limitación, la teledetección y los productos satelitales ofrecen una solución práctica para estimar la precipitación global (Huffman, 2007), ya que sus mediciones suelen ser confiables e independientes, sin embargo, su rendimiento puede variar según la ubicación. En ese contexto, el Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI) ha desarrollado PISCOp (Peruvian Interpolated data of the SENAMHI's Climatological and hydrological Observations), disponible en versiones diaria y mensual, resulta de la combinación de datos de estaciones terrestres con climatologías, reanálisis y productos satelitales de estimación de lluvias (Aybar et al. 2017). Esta integración produce una base de datos grillada a nivel nacional de alta resolución espacial (~5x5 km). Los datos grillados de PISCOp abarcan una serie temporal que comienza el 1 de enero de 1981 y se extiende, en su versión estable, hasta el 31 de diciembre de 2016 y en su versión inestable de PISCOp proporciona datos hasta diciembre de 2023, facilitando así la disponibilidad de datos de precipitación para diversas aplicaciones hidrológicas, aunque con ciertas restricciones (Aybar et al. 2017). A pesar de las ventajas que ofrece PISCOp, es fundamental llevar a cabo estudios de validación y corrección para asegurar que los datos generados sean precisos y fiables, especialmente a nivel regional. La región de Cajamarca presenta características topográficas

complejas y microclimas diversos que pueden no ser capturados adecuadamente por los modelos climáticos y los datos satelitales empleados en PISCOp. Por ello, es necesario validar los datos de precipitación de PISCO con mediciones directas provenientes de estaciones meteorológicas locales y aplicar técnicas de corrección que mejoren la calidad de estos datos.

La precipitación en la región Cajamarca se caracteriza por su alta variabilidad espacial y temporal, lo que plantea desafíos significativos para su monitoreo y gestión efectiva (Veneros 2021),. El objetivo principal de esta investigación es validar y corregir la precipitación mensual generada con el producto PISCO durante el período de 1981 a 2023. Para ello, se llevará a cabo un análisis comparativo entre los datos de PISCO y las observaciones de aproximadamente 30 estaciones meteorológicas distribuidas en la región. Se utilizarán métodos estadísticos, como el cálculo de errores y sesgos, y técnicas de interpolación espacial para ajustar las discrepancias detectadas. Además, se explorarán metodologías avanzadas de corrección basadas en modelos de mezcla y mapeo de cuantiles para mejorar la precisión de los datos corregidos.

Los resultados de la presente tesis buscan aportar el conocimiento y mejora de los datos de precipitación en la región de Cajamarca, utilizando el producto PISCO como base y aplicando técnicas de validación y corrección que aseguren su precisión y utilidad. Los hallazgos de este estudio no solo serán valiosos para la región específica de estudio, sino que también podrán servir como referencia para la validación de productos climáticos en otras regiones con características similares.

1. 1. Planteamiento del problema

La precipitación muestra una variabilidad en pequeña escala y un comportamiento estadístico altamente anormal que requiere observaciones frecuentes y muy espaciadas para una representación adecuada. Tales observaciones no son posibles mediante mediciones en la superficie en gran parte del mundo, particularmente en regiones oceánicas, remotas o en desarrollo (Huffman et al. 2007), es así que las estimaciones precisas de la precipitación espacio-temporal son esenciales para comprender el ciclo del agua y su impacto en los sistemas naturales y humanos (Aybar et al. 2020). En la región de Cajamarca, la precipitación varía significativamente tanto en el espacio como en el tiempo, lo que dificulta su monitoreo y gestión efectiva (GORE 2022), la red de monitoreo de precipitación es insuficiente, con una densidad de estaciones mucho menor a la recomendada por la Organización Meteorológica Mundial (OMM) para áreas montañosas en zonas tropicales, mediterráneas o templadas (Delgado 2019), evidenciando la limitada cobertura espacial. SENAMHI ha desarrollado PISCO, que usa datos de estaciones terrestres y satelitales junto con reanálisis para obtener datos precisos de precipitación. Sin embargo, la precisión varía regionalmente debido a factores como la topografía y los microclimas locales (Aybar et al. 2017). La falta de validación y corrección de los datos de precipitación generados por PISCO para la región de Cajamarca representa un desafío importante. Sin una validación adecuada, existe el riesgo de que los datos no reflejen con precisión la realidad climática de la región, afectando la gestión de los recursos hídricos y la planificación en sectores dependientes del clima. En ese contexto, el problema central de esta investigación es la necesidad de validar y corregir los datos de precipitación mensual del producto PISCO para la región de Cajamarca durante el período de 1981 a 2023, con el fin de asegurar su precisión y utilidad en aplicaciones locales.

1.1.1. Contextualización del problema

La precipitación es un elemento clave del ciclo hidrológico y de la gestión del recurso hídrico, especialmente en regiones de topografía compleja como Cajamarca, donde las lluvias presentan una alta variabilidad espacial y temporal. Sin embargo, la red pluviométrica del SENAMHI en la zona es insuficiente, con una densidad de estaciones muy por debajo de lo recomendado por la Organización Meteorológica Mundial (OMM), lo que limita la precisión en la caracterización de la precipitación.

Para reducir esta carencia, el SENAMHI desarrolló el producto PISCOp, que integra datos de estaciones convencionales, satélites y reanálisis en una base grillada de alta resolución. No obstante, su desempeño puede variar regionalmente debido a factores como la orografía y los microclimas locales. Por ello, es necesario validar y corregir la información de PISCO con registros de estaciones convencionales en Cajamarca, identificando posibles sesgos, verificando estaciones con gran dispersión y aplicando técnicas de corrección que permitan generar isoyetas ajustadas a la regionalización hidroclimática. En este marco, la investigación busca garantizar que los datos de precipitación utilizados en la región sean más confiables y representativos, fortaleciendo la gestión hídrica, la planificación agrícola y la adaptación al cambio climático.

1.1.2. Descripción del problema

La precipitación es una variable fundamental para la disponibilidad y gestión de los recursos hídricos, la planificación agrícola y la prevención de riesgos climáticos. En la región Cajamarca, esta variable se caracteriza por una marcada variabilidad espacial y temporal, producto de su compleja topografía y diversidad de microclimas. Esta situación dificulta su monitoreo y limita la representatividad de los registros disponibles.

Si bien el Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI) ha desarrollado el producto PISCOp, que combina datos de estaciones convencionales, climatologías, reanálisis y estimaciones satelitales para generar una base de datos grillada de alta resolución, su precisión no es uniforme a nivel regional. Factores como la baja densidad de estaciones pluviométricas en Cajamarca, la presencia de estaciones con alta dispersión de datos y la heterogeneidad climática afectan el desempeño del producto, generando sesgos y subestimaciones que comprometen su utilidad en aplicaciones locales.

La ausencia de un proceso de validación y corrección específico para Cajamarca incrementa la incertidumbre en el uso de la información climática. Sin este proceso, las isoyetas generadas podrían no reflejar de manera adecuada la distribución espacial real de las lluvias, afectando la modelación hidrológica, la gestión de cuencas y la planificación de infraestructuras hidráulicas. Asimismo, la falta de validaciones con estaciones no incluidas en la interpolación limita la confiabilidad de los resultados, y la construcción de isoyetas sin un criterio de regionalización puede conducir a representaciones imprecisas del régimen de precipitaciones.

En consecuencia, se evidencia la necesidad de llevar a cabo un estudio que valide y corrija la precipitación mensual generada por el producto PISCO en la región Cajamarca, considerando la actualización de datos hasta el año 2025, la identificación de estaciones con grandes dispersiones, la aplicación de técnicas de corrección como el *quantile mapping* y la generación de isoyetas ajustadas a las regiones hidroclimáticas homogéneas. Esta problemática constituye la base de la presente investigación, cuyo propósito es mejorar la calidad y representatividad de la información climática para contribuir a una gestión hídrica más eficiente y confiable en la región.

1.1.3. Formulación del problema

En la región de Cajamarca, no se dispone de herramientas técnicas confiables que permitan realizar una modelación hidrológica precisa, considerando la variabilidad climática y los factores asociados que influyen en los procesos hidrometeorológicos. Esta limitación dificulta la validación y corrección de la base de datos PISCO-SENAMHI (1981–2023), afectando la calidad del análisis y la toma de decisiones en la gestión de los recursos hídricos.

1.2. Hipótesis de la investigación

Hi: El producto PISCO presenta limitaciones en la estimación de la precipitación mensual en la región Cajamarca durante el periodo 1981–2025; sin embargo, mediante su validación con datos de estaciones convencionales del SENAMHI y la aplicación de técnicas de corrección como el Quantile mapping, es posible mejorar significativamente su precisión y generar isoyetas más representativas al considerar la regionalización hidroclimática.

Ho: El Producto PISCO presenta limitaciones en la estimación de la precipitación mensual en la región Cajamarca durante el periodo de 1981 al 2025; sin embargo, mediante la validación con datos de estaciones convencionales del SENAMHI y la aplicación de técnicas de corrección como el Quantile Mapping, es posible mejorar significativamente su precisión y generar isoyetas mas representativas al considerar la regionalización hidroclimatica.

1.3. Justificación de la investigación.

1.3.1. Justificación científica

La presente investigación aplica de manera rigurosa el método científico, al partir de la identificación de un problema, que establece objetivos claros y aplica conocimientos técnicos y analíticos para resolverlo de forma sistemática. El estudio contribuye al avance del conocimiento

científico al evaluar y corregir la precisión del producto PISCO en una región caracterizada por su complejidad topográfica, como es el caso de Cajamarca. Mediante la validación estadística y la aplicación de técnicas de corrección, se mejora la representatividad espacial y temporal de la precipitación a escala regional, generando información climática más confiable. De esta manera, la investigación no solo fortalece la base científica para la gestión del agua y el análisis de la variabilidad climática, sino que también propone una metodología replicable que puede ser aplicada en otros contextos hidroclimáticos del país.

1.3.2. Justificación técnica – práctica

Desde un enfoque aplicado, esta investigación tiene relevancia porque proporciona datos corregidos de precipitación que pueden ser utilizados en modelaciones hidrológicas, estudios de disponibilidad hídrica y planificación territorial. La depuración de estaciones con alta dispersión, el uso de validación cruzada y la generación de isoyetas ajustadas a las regiones hidroclimáticas aseguran productos más precisos para la toma de decisiones. En consecuencia, los resultados no solo tienen un valor académico, sino también práctico para instituciones, agricultores, gestores de cuencas y responsables de la infraestructura hidráulica.

1.3.3. Justificación institucional y personal

La investigación se justifica institucionalmente porque contribuye al fortalecimiento del SENAMHI y de las entidades responsables de la gestión hídrica al generar información validada y corregida que mejora la confiabilidad del producto PISCO, herramienta clave para la planificación territorial, la gestión de cuencas y la prevención de riesgos climáticos. Asimismo, la Universidad Nacional de Cajamarca, en su compromiso con la formación científica y el desarrollo regional, fomenta la participación de sus estudiantes como investigadores, brindándoles la oportunidad de aplicar el método científico y generar conocimiento que responda a las necesidades del entorno.

De manera personal, este trabajo representa la culminación de mi formación como Ingeniero Hidráulico, al integrar la teoría académica con la práctica profesional, fortaleciendo mis competencias en análisis de datos climáticos y gestión del recurso hídrico. Además, refleja mi compromiso con el desarrollo sostenible de mi región, orientando mis esfuerzos hacia la búsqueda de soluciones que promuevan una administración más eficiente y responsable del agua.

1.4. Alcances de la Investigación

La presente investigación abarca el análisis de la precipitación mensual en la región Cajamarca durante el periodo comprendido entre 1981 y 2025, utilizando como base principal el producto PISCO del SENAMHI y los registros de estaciones convencionales. El estudio se desarrolla a escala regional, considerando la variabilidad espacial de las lluvias y aplicando indicadores estadísticos de desempeño (R^2 , NSE, BIAS y RSR) que permiten evaluar la calidad de los datos. Asimismo, se incorpora la técnica de *quantile mapping* para corregir sesgos sistemáticos y se realiza una validación cruzada con estaciones no incluidas en la interpolación, lo que otorga mayor solidez a los resultados. Como producto final, se generan bases de datos corregidas y mapas de isoyetas ajustados a las regiones hidroclimáticas homogéneas, los cuales constituyen una herramienta práctica y confiable para estudios hidrológicos, planificación del recurso hídrico y gestión territorial en Cajamarca.

1.5. Limitaciones

La investigación presenta algunas limitaciones inherentes al manejo de información climática. En primer lugar, la red de estaciones pluviométricas en la región Cajamarca es reducida y presenta vacíos temporales en sus registros, lo que condiciona la representatividad espacial y temporal de los datos utilizados. Asimismo, algunas estaciones mostraron alta dispersión en sus resultados, lo que obligó a su exclusión parcial en la interpolación, reduciendo la densidad de puntos de control. Otra limitación está relacionada con la dependencia del producto PISCO, cuya construcción se basa en estimaciones satelitales y métodos de interpolación que pueden no capturar completamente la compleja topografía y diversidad de microclimas de Cajamarca. Finalmente, la investigación se centra en la precipitación mensual, por lo que no aborda variaciones en escalas diarias u horarias que también podrían tener relevancia para estudios hidrológicos más específicos.

1.6. Objetivos

1.6.1. Objetivo general

Validar y corregir el producto Pisco de precipitación mensual para el periodo de 1981 al 2023 en la región de Cajamarca.

1.6.2. Objetivos específicos

- ✓ Identificar las zonas de la región de Cajamarca, donde el producto PISCO de precipitación mensual presenta una mejor correlación y un mejor desempeño durante el periodo de enero de 1981 a diciembre del 2023.
- ✓ Validar la precipitación mensual generada por el producto grillado PISCO al compararla con los registros de precipitación de las estaciones terrestres instaladas por el SENAMHI.
- ✓ Corregir el producto PISCO de precipitación mensual a partir de la comparación realizada con la data terrestre y el producto satelital en la región de Cajamarca durante el periodo de enero de 1981 a diciembre del 2023.
- ✓ Construir isoyetas a partir de la validación del producto PISCO mensual y compararlas con las estaciones convencionales identificando las regiones climáticas similares.

CAPITULO II: MARCO TEÓRICO

2. 1. Antecedentes de la investigacion

- 📖 (Duan, Z. 2016) en su estudio “*Evaluation of eight high spatial resolution gridded precipitation products in Adige Basin (Italy) at multiple temporal and spatial scales*” se hace uso de ocho productos grillados de precipitación satelitales los cuales son comparados a escala temporal y espacial, haciendo mención que el rendimiento de dichos productos puede variar de una región a otra y concluyendo que, en base a índices estadísticos como el R^2 , RSME, BIAS MAE y el error medio, el producto CHIRPS y TRIMM son los que representan mejor las características de la cuenca.
- 📖 (Almazroui, M. 2012), en “*Recent climate change in the Arabian Peninsula: annual rainfall and temperature analysis of Saudi Arabia for 1978–2009*”, hace mención que debido al crecimiento demográfico el desarrollo industrial y expansión de la agricultura de regadío aumentaron drásticamente en el último siglo, elevando la demanda de suministro de agua y agotando de esta manera los recursos hídricos, es por ello que, considerando a la lluvia y a la temperatura como controladores clave para la producción agrícola; este artículo aborda el uso de varios conjuntos de datos

grillados y al mismo tiempo discute el análisis con referencia a los conjuntos de datos de observación terrestre disponibles, en particular, las precipitaciones y temperatura.

🌳 (Zubieta, R. 2019), en “*Assessing precipitation concentration in the Amazon basin from different satellite-based data sets*”, hace mención del análisis de datos anuales, estacionales o mensuales de precipitación que pueden conducir a una interpretación limitada de la distribución espacial y temporal de la lluvia debido a que grandes porcentajes del total anual pueden ocurrir en pocos días y esta alta concentración de lluvia diaria puede causar erosión de suelos, deslizamientos o inundaciones. La concentración de lluvia diaria para toda la cuenca amazónica (CA) es caracterizada empleando un “Índice de Concentración”, el cual es estimado a partir de un producto grillado de precipitación observada para el periodo 1980 – 2009, los hallazgos de la investigación proveen nueva información acerca de la distribución espacial de la lluvia diaria sobre la CA y los resultados indican que la concentración de lluvia diaria es relativamente baja (~ 20 %) en Colombia, Ecuador, norte de Perú y los Andes sobre los 1500 m s. n. m., lo cual indica que la precipitación diaria es más regular, es decir, tiende a ser más estacionalmente distribuida, no obstante, es muy alta en regiones del estado de Roraima en el norte de Brasil y la Amazonía boliviana

🌳 (Tapiador, F. 2012), en su estudio “*Global precipitation measurement: Methods, datasets and applications*”, hace referencia a los modelos climáticos necesitan una comparación entre la climatología medida satelitalmente y los registros de datos observados. El artículo explora los aspectos de la medición de la precipitación que son relevantes para proporcionar una evaluación global precisa. Los métodos discutidos incluyen datos terrestres, estimaciones satelitales y modelos numéricos. Primero, se discuten los métodos para medir, estimar y modelar la precipitación. Luego, se presentan los conjuntos de datos más relevantes que recopilan información sobre precipitaciones de esas tres fuentes. La tercera parte del documento ilustra varias de las muchas aplicaciones de esas mediciones y bases de datos, a saber, energía hidroeléctrica, asimilación de datos y validación de modelos climáticos regionales (RCM). El objetivo del artículo es organizar los numerosos vínculos y retroalimentaciones entre la medición, estimación y modelización de la precipitación, indicando las incertidumbres y limitaciones de cada técnica para

identificar áreas que requieren mayor atención y mostrar los límites dentro de los cuales se pueden utilizar conjuntos de datos.

🌳 (Beck, H. 2017) en “*Global-scale evaluation of 22 precipitation datasets using gauge observations and hydrological modeling*”, hace mención de que la precipitación impulsa el ciclo hidrológico terrestre, encontrándose entre las variables meteorológicas más difíciles de estimar debido a su alta heterogeneidad espaciotemporal y en las últimas décadas se ha desarrollado una gran cantidad de conjuntos de datos cuadriculados regionales, cuasi globales y totalmente globales. Estos conjuntos de datos difieren en términos de objetivo de diseño (precisión instantánea, homogeneidad temporal, longitud de registro o combinaciones de los mismos), fuente de datos (medidor, radar terrestre, satélite, análisis, reanálisis o combinaciones de los mismos), resolución espacial (de $0,05^\circ$ a $2,5^\circ$), y resolución temporal (30 min a mensual) (Beck et al. 2019). En el artículo se presenta MSWEP V2, un conjunto de datos de precipitación (P) grillada que abarca el período 1979-2017, que tiene varios aspectos únicos: i) cobertura totalmente global que incluye toda la tierra y los océanos (la mayoría de los conjuntos de datos satelitales están limitados a 50° o 60° de latitud); ii) alta resolución espacial ($0,1^\circ$) y temporal (3 horas), aumentando la relevancia local de las estimaciones de P; iii) combinación óptima de una amplia gama de conjuntos de datos de P medidos, satelitales y de reanálisis, para obtener las mejores estimaciones de P posibles en cualquier ubicación; iv) corrección de sesgos distributivos, para eliminar la llovizna espuria y restaurar los picos atenuados.

🌳 (Tefagiorgis, K. 2010), en “*Bias correction of satellite rainfall estimation using a radar-gauge product*”, realizó su investigación en un área geográficamente delimitada por 34° – 37° de latitud Norte y $94,5^\circ$ – 100° de longitud Oeste. La ubicación del estudio abarcó un área de aproximadamente 136.000 km², la región de Oklahoma (USA). Las estimaciones de precipitaciones satelitales se pueden utilizar en la predicción hidrológica operativa, pero son propensas a errores sistemáticos. El objetivo de este estudio fue combinar a la perfección un producto de radar con un producto satelital corregido que llene los vacíos en la cobertura del radar. Para combinar diferentes productos de lluvia, deben tener características de sesgo

similares. El artículo presenta un método píxel por píxel, cuyo objetivo es corregir los sesgos en los productos de lluvia satelitales horarios utilizando un producto de lluvia medido por radar. Los factores de sesgo se calculan para los píxeles lluviosos correspondientes y se selecciona aleatoriamente un número deseado de ellos para el análisis. Los campos de sesgo se generan utilizando los factores de sesgo seleccionados. El método tiene en cuenta la variación espacial y los errores aleatorios en los sesgos. Los parámetros del campo de sesgo se determinaron diariamente utilizando el algoritmo de optimización Shuffled Complex Evolution. Para incluir más fuentes de errores, se generaron y aplicaron conjuntos de factores de sesgo antes de la generación del campo de sesgo. El procedimiento del método se demostró utilizando un satélite y un medidor de radar con datos de lluvia para varios eventos de lluvia en 2006 en la región de Oklahoma.

🌿 (Llauca, H. 2021), en su estudio “*PISCO_HyM_GR2M: A model of monthly water balance in Peru (1981–2020)*”, hace mención a la cuantificación de la oferta de aguas superficiales es crucial para su gestión y resalta que en Perú, la baja densidad espacial de las estaciones hidrométricas dificulta esta tarea. Este trabajo tiene como objetivo evaluar el desempeño hidrológico de un modelo de balance hídrico mensual en Perú utilizando datos de precipitación y evapotranspiración del conjunto de datos meteorológicos de alta resolución PISCO, que ha sido desarrollado por el Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI). Un enfoque de regionalización basado en la Prueba de Sensibilidad de Amplitud de Fourier (FAST) de los índices de lluvia-escorrentía (RR) y variabilidad de la escorrentía (RV) definió 14 regiones de calibración en todo el país. A continuación, se utilizó el modelo GR2M a escala semidistribuida en 3594 subcuencas y arroyos fluviales para simular descargas mensuales desde enero de 1981 hasta marzo de 2020. El rendimiento del modelo se evaluó utilizando la eficiencia de Kling-Gupta (KGE), raíz cuadrada transferida de Nash. –Métricas de eficiencia de Sutcliffe (NSEqrt) y error de balance hídrico (WBE).

🌿 (Afonso, J. 2020), en su estudio “*Precipitation diurnal cycle assessment of satellite-based estimates over Brazil*”, evalúa la capacidad de varias estimaciones de precipitación basadas en satélites de alta resolución para representar el Ciclo Diurno

de Precipitación (PDC) sobre Brasil durante el período 2014-2018, después del lanzamiento del satélite Global Precipitation Measurement (GPM). El fundamento de su investigación es que la precipitación, y su distribución temporal y espacial, es de suma importancia para cualquier país, en particular para aquellos de tamaño continental como Brasil. De hecho, los datos pluviómetros siempre son necesarios en casi todas las áreas de actividad: gestión de recursos hídricos (con énfasis en el agua potable), agricultura, generación de energía mediante centrales hidroeléctricas, sólo por mencionar algunas (Afonso et al. 2020). Los algoritmos seleccionados para la evaluación de los productos satelitales son el Mapeo Global de Precipitaciones por Satélite (GSMaP), las Recuperaciones Integradas de Múltiples Satélites para GPM (IMERG) y la técnica MORPHing (CMORPH) del Centro de Predicción Climática (CPC). Se utilizaron datos de pluviómetros horarios de diferentes redes nacionales y regionales como conjunto de datos de referencia después de pasar por rigurosas pruebas de control de calidad. Todos los conjuntos de datos se interpolaron en una cuadrícula común de $0,1^\circ \times 0,1^\circ$ cada 3 h para comparar. Después de un análisis de conglomerados jerárquico, se seleccionaron para este estudio siete regiones con diferentes características de PDC (amplitud y fase). Los principales resultados de esta investigación podrían resumirse de la siguiente manera: (i) En aquellas regiones donde el calentamiento térmico produce nubes convectivas profundas, el PDC está mejor representado por todos los algoritmos (en términos de amplitud y fase) que aquellas regiones impulsadas por convección poco profunda o baja -circulación nivelada; (ii) la suite GSMaP (GSMaP-Gauge (G) y GSMaP-Motion Vector Kalman (MVK)), en términos generales, supera al resto de algoritmos con menor sesgo y menor dispersión...

🌳 (Mantas, V. 2014), en su estudio “*Validation of TRMM multi-satellite precipitation analysis (TMPA) products in the Peruvian Andes*”, hace mención que la información precisa sobre las precipitaciones es fundamental para numerosas aplicaciones críticas y las estimaciones de precipitaciones obtenidas por sensores espaciales presentan una oportunidad para complementar la red existente y permitir el desarrollo de aplicaciones críticas casi en tiempo real. Sin embargo, los beneficios sociales de tales sistemas sólo pueden lograrse si las estimaciones se validan

adecuadamente y el rendimiento de los productos existentes se describe con precisión. En este estudio, se validan para los Andes peruanos dos productos generados por el Análisis de Precipitación Multisatélite (TMPA) de la Misión de Medición de Lluvias Tropicales (TRMM). Esta es una región de topografía compleja que plantea desafíos importantes para la recuperación de valores de precipitaciones desde el espacio. Los productos TMPA, tanto de grado de investigación (3B42V7) como de tiempo casi real (3B42RT), se comparan con datos in situ. Se estudian diferentes duraciones de observación y los resultados se analizan a la luz de limitaciones geográficas, topográficas y climáticas. Las series temporales del producto de grado científico también se estudiaron bajo distorsión dinámica del tiempo y agrupación jerárquica para agilizar las comparaciones entre mosaicos.

✿ (Paulat, M. 2008), hace referencia en “*A gridded dataset of hourly precipitation in Germany: Its construction, climatology and application*” a la precipitación como una de las variables meteorológicas clave, esencial para la predicción meteorológica diaria y para aplicaciones, por ejemplo, en los campos de la hidrología y la agrometeorología. Debido a la multitud de procesos físicos involucrados en la formación de precipitación, que van desde el forzamiento a gran escala de movimientos verticales hasta complejos procesos microfísicos en diferentes tipos de nubes, es particularmente difícil predecir con precisión la distribución espacial y la amplitud (y durante la estación fría a veces también la fase) de precipitación. Durante los últimos años, un avance importante en la predicción numérica del tiempo ha sido la aparición de modelos de muy alta resolución e incluso de resolución por convección de área limitada, como por ejemplo en Alemania el modelo COSMODE con una resolución horizontal de 2,8 km. que está operativo desde abril de 2007. La verificación de tales modelos se vuelve particularmente desafiante, por un lado debido a la alta resolución espacial, y por otro lado debido a la necesidad de verificar estos modelos en escalas de tiempo cortas. Además, para variables como la precipitación, que se caracterizan por una gran variabilidad a pequeña escala, es deseable realizar un enfoque de verificación de las observaciones al modelo, que exige la disponibilidad de un conjunto de datos de observación en la cuadrícula del modelo. Las redes actuales de estaciones pluviómetros con resolución horaria no son

lo suficientemente densas para producir un análisis cuadriculado con una resolución espacial comparable al modelo numérico. Es por esta razón que en este estudio se utilizará la llamada técnica de desagregación, que combina adecuadamente información de la red mucho más densa de estaciones pluviómetros y radares de medición diaria.

🌿 (Ramos y Francés 2014), en *“Usefulness of satellite-estimated rainfall in hydrologic modeling of the Jucar river basin in Spain”*, hace referencia a que la modelización hidrológica tiene un papel importante en la mayoría de aspectos de la gestión del agua y del ambiente. Sin embargo, la eficacia de estos modelos depende de la disponibilidad de los datos de entrada. Así, los actuales modelos hidrológicos distribuidos requieren datos distribuidos espacialmente y con la precisión suficiente para permitir la investigación y aplicación pero la eficacia de estos modelos depende de la disponibilidad de los datos de entrada. Es así que la lluvia estimada de satélite a escala global, se adapta a estos modelos distribuidos ya que se tienen datos de lluvia para toda la cuenca. Sin embargo, debido a la multidimensionalidad del error de la lluvia estimada de satélite, es difícil establecer a priori un producto que permita una óptima aplicación hidrológica en diferentes condiciones climáticas; es por eso que se hace necesario evaluar su desempeño a través de la modelación hidrológica. En el estudio, se evalúa la utilidad de la lluvia estimada por satélite a través de un modelo hidrológico lluvia-escorrentía y se emplea la lluvia estimada por el algoritmo PERSIANN a una resolución temporal diaria y resolución espacial de $0,25^\circ$ para el periodo comprendido entre el 1° de marzo del 2000 al 31 de octubre del 2009 en la cuenca del río Júcar (España), obteniéndose resultados prometedores

🌿 (Aybar et al. 2017), en su estudio *“Uso del Producto Grillado “PISCO” de precipitación en Estudios, Investigaciones y Sistemas Operacionales de Monitoreo y Pronóstico Hidrometeorológico”*, hace referencia a la generación del producto grillado PISCO, basado en que los estudios, investigaciones y sistemas operacionales de monitoreo y pronóstico hidrometeorológico tienen el propósito de generar información sobre las características climáticas e hidrológicas que contribuyan a la comprensión de la hidroclimatología de las cuencas y la vigilancia de eventos extremos, cuya producción de estos productos demandan gran inversión de tiempo

en el tratamiento y crítica de los datos para asegurar buena calidad, continuidad temporal de las series pluviométricas, homogeneidad, factores que son una limitante para atender con oportunidad diferentes demandas de información para diferentes usuarios; por otro lado la baja densidad de las estaciones meteorológicas en el país amerita la utilización de procedimientos de regionalización e interpolación espacial para generar información en sitios no instrumentados. El producto PISCO de precipitación (PISCOp) en su versión diaria y mensual es el resultado de la combinación de datos de estaciones terrenas con climatologías, reanálisis y productos satelitales de estimación de lluvias para obtener una base de datos grillada a nivel nacional de alta resolución espacial ($\sim 5 \times 5$ km); los datos grillados abarcan una serie temporal que se inicia el 1ro de enero 1981 hasta el 31 de diciembre del 2016, facilitando de este modo mayor disponibilidad de los datos de precipitación para su uso en diferentes actividades ligadas al análisis hidrológico con sus limitaciones respectivas.

🌿 (Boers, N. 2013), en “*Complex networks identify spatial patterns of extreme rainfall events of the South American Monsoon System*”, se evalúa el producto satelital diario TRMM 3B42 V7 del 1 de enero de 1998 al 31 de diciembre de 2012 (15 años) con cobertura espacial de 40°S a 15°N y 85°W a 30°W con una resolución de 0,25° por 0,25° con valores de precipitación en mm/d, en el cual investiga las características espaciales de la sincronidad de lluvias extremas del Sistema Monzón Sudamericano (SAMS) mediante Redes Complejas (CN), del mismo modo explora los vínculos climáticos y clasificamos las características espaciales de la sincronidad de las precipitaciones extremas. Aunque el enfoque se basa en una sola variable (lluvia), revela las características más importantes del SAMS, como las principales rutas de humedad, áreas con desarrollo frecuente de sistemas convectivos de mesoescala (SCM) y las principales zonas de convergencia.

🌿 (Tupac Yupanqui, R. 2022), realizaron el estudio “*Evaluación de eventos de tormentas pluviométricas con información satelital*”. El análisis revela un patrón predominante de tormentas de corta duración en el Perú, con variabilidad en la intensidad y duración de las precipitaciones. Las mayores tormentas, aunque pueden extenderse hasta 8 horas, no siempre resultan en una mayor cantidad total de lluvia.

El GPM detecta más tormentas con menor intensidad, pero mayor duración en comparación con las estaciones automáticas, que tienden a captar eventos más intensos, pero de duración más corta. Aunque el GPM muestra coherencia al identificar variabilidades regionales en las precipitaciones, especialmente en la selva y costa norte frente a la costa central y sur, existen discrepancias significativas en las mediciones específicas de lluvia entre los datos satelitales y las observaciones terrestres. Estas diferencias subrayan la necesidad de mejoras antes de usar los datos del GPM para la disagregación detallada de eventos de tormentas a nivel nacional.

🌳 (Hunziker et al. 2017), hace mención en *“Identifying, attributing, and overcoming common data quality issues of manned station observations”*, a la evaluación de las tendencias y los extremos climatológicos requiere datos que cumplan con altos estándares de calidad. Si los datos se ven afectados por problemas de calidad, la consecuencia puede ser resultados engañosos y erróneos. Sin embargo, en muchas regiones del mundo, los registros de observación se ven afectados por una gran cantidad de problemas de calidad de los datos. Evaluar y controlar la calidad de dichos conjuntos de datos es un aspecto importante, que a menudo se pasa por alto, de la investigación climática. Además de analizar los datos de medición, los metadatos son importantes para una evaluación integral de la calidad de los datos. Sin embargo, a menudo faltan metadatos, que pueden reconstruirse en parte mediante acciones adecuadas, como inspecciones de estaciones. Este estudio identifica y atribuye los problemas comunes más importantes en la calidad de los datos en los conjuntos de datos de temperatura y precipitación de Bolivia y Perú. Errores iguales o similares se encuentran en muchas otras redes de estaciones predominantemente tripuladas en todo el mundo. Una gran parte de estos problemas se debe a errores de medición cometidos por los observadores. Por lo tanto, la forma más eficaz de prevenir errores es fortalecer la capacitación de los observadores y establecer un procedimiento de control de calidad (QC) casi en tiempo real. Muchos problemas comunes de calidad de los datos apenas se detectan mediante los enfoques habituales de control de calidad.

🌳 Huerta et al. (2022), realizaron el estudio *“Desarrollo de datos grillados de precipitación horaria para el Perú”*. Los datos de precipitación con alta resolución

espacial y temporal son muy esenciales para múltiples campos en las ciencias climatológicas, ecológicas, hidrológicas y ambientales. En este trabajo se desarrolla e implementa la construcción de un producto grillado (0.1°) de precipitación horaria a escala de todo el Perú (PISCOp_h). Esta nueva base de datos se desarrolla a partir de la disgregación temporal de un establecido producto diario de precipitación en conjunto con la combinación de estimaciones de precipitación de tres productos satelitales y estaciones meteorológicas automáticas. Los principales resultados demuestran que PISCOp_h presenta un moderado a alto acople de la precipitación horaria; caracteriza bastante bien la frecuencia e intensidad de la precipitación horaria, principalmente en la parte central y sur del país. Asimismo, caracteriza de forma eficiente la frecuencia, intensidad y ciclo diurno promedio de la precipitación horaria. Esta base de datos representa un importante avance en el desarrollo de productos de precipitación horaria, primordialmente en regiones montañosas de terreno complejo.

🌿 (Funk, C. 2015), en *“The climate hazards infrared precipitation with stations - A new environmental record for monitoring extremes”* evalúa los datos contruidos de Climate Hazards group Infrared Precipitation with Stations (CHIRPS) del grupo de Peligros Climáticos, un nuevo conjunto de datos de precipitación cuasi global (50°S - 50°N), de alta resolución ($0,05^\circ$), diaria, pentadal y mensual. CHIRPS fue desarrollado para apoyar a la Red de Sistemas de Alerta Temprana contra la Hambruna de la Agencia de los Estados Unidos para el Desarrollo Internacional (FEWS NET). Aprovechando los enfoques utilizados en productos exitosos de precipitación infrarroja térmica (TIR), como la Estimación de precipitaciones (RFE2) de la Administración Nacional Oceánica y Atmosférica (NOAA) y la Climatología de precipitaciones africanas o la serie TAMSAT de climatología y tiempo de precipitaciones africanas (TARCAT) de la Universidad de Reading, CHIRPS utiliza la Misión de Medición de Lluvias Tropicales Análisis de Precipitación Multisatélite versión 7 (TMPA 3B42 v7) para calibrar las estimaciones de lluvia globales de Duración de Nubes Frías (CCD). CHIRPS, que también se basa en los enfoques utilizados en los productos de medición interpolados más avanzados de la actualidad, utiliza un enfoque de "interpolación inteligente" que trabaja con

anomalías de una climatología de alta resolución. CHIRPS incorpora datos de la estación en un proceso de dos fases, produciendo dos productos únicos

🌳 (Cannon, A. 2015), en su estudio “*Bias correction of GCM precipitation by quantile mapping: ¿How well do methods preserve changes in quantiles and extremes?*”, se hace mención que los algoritmos de corrección de sesgo de mapeo cuantil se utilizan comúnmente para corregir sesgos distributivos sistemáticos en los resultados de precipitación de los modelos climáticos. Aunque son eficaces para eliminar sesgos históricos en relación con las observaciones, se ha descubierto que el mapeo de cuantiles puede corromper artificialmente las tendencias futuras proyectadas por el modelo. Estudios anteriores sobre la modificación de las tendencias de las precipitaciones mediante el mapeo de cuantiles se han centrado en las cantidades medias, prestando menos atención a los extremos. Este artículo investiga hasta qué punto los algoritmos de mapeo de cuantiles modifican las tendencias del modelo climático global (GCM) en los índices de precipitación media y extrema. Primero, se presenta un algoritmo de corrección de sesgo, mapeo delta de cuantiles (QDM), que preserva explícitamente los cambios relativos en los cuantiles de precipitación. QDM se compara en datos sintéticos con el mapeo de cuantiles sin tendencia (DQM), que está diseñado para preservar las tendencias en la media, y con el mapeo de cuantiles estándar....

🌳 (Aybar, C. 2020), en “*Construction of a high-resolution gridded rainfall dataset for Peru from 1981 to the present day*”, se menciona que las observaciones convencionales desde estaciones pluviómetros son un insumo ideal para las aplicaciones relacionadas a la gestión de los recursos hídricos y manejo del agua y aunado a la fuerte variabilidad espacial y la distribución heterogénea y escasa de los pluviómetros, combinadas con deficiencias sistemáticas en la calidad de los datos, impiden su uso generalizado en el Perú. Es por ello que presenta un conjunto de datos cuadriculados de lluvia disponible para Perú, llamado PISCOp V2.1 (Datos interpolados peruanos de las observaciones climatológicas e hidrológicas del SENAMHI). PISCOp ha sido desarrollado para el período 1981 hasta la 2019, con una latencia promedio de ocho semanas a una resolución espacial de 0,1°. El algoritmo de fusión se basa en métodos de interpolación geoestadística y

determinista que incluyen tres fuentes de lluvia diferentes: (i) el conjunto de datos de pluviómetros rellenados y con control de calidad nacional, (ii) climatologías de precipitación fusionadas con medidores de radar y (iii) Precipitación infrarroja del Grupo de peligros climáticos (CHIRP) estimaciones.

🌳 (Manz, B. 2016), realizo la investigación de “*High-resolution satellite-gauge merged precipitation climatologies of the tropical andes*”, su área de estudio fueron los patrones de precipitación de los Andes Tropicales abarcando un área desde 19°S a 12°N y desde los 67° W to 81.5°W, en la cual señala que, caracterizar la naturaleza altamente variable espaciotemporalmente de la precipitación en las regiones montañosas requiere una alta precisión de medición en escalas espaciales y temporales finas y los productos de precipitación satelital son cada vez más útiles para complementar las redes de pluviómetros en regiones donde éstas son demasiado escasas para capturar patrones espaciales de precipitación, como en los Andes tropicales. En su investigación, hace uso de la precipitación climatológica mensual media cuadriculada de alta resolución (5 km) se deriva de los datos orbitales sin procesar del TPR (TRMM 2A25) y se fusiona con 723 pluviómetros utilizando múltiples enfoques de fusión de pluviómetros satelitales (SG). Los productos de precipitación resultantes se evalúan mediante validación cruzada y balances hídricos de cuencas (índices de escorrentía) para 50 cuencas en los Andes tropicales. Los resultados muestran que el TPR captura los principales patrones de precipitación sinópticos y estacionales y también define con precisión los gradientes orográficos, pero subestima las tasas de precipitación mensuales absolutas.

2. 2. Marco conceptual

2.2.1. Satélites meteorológicos

Los satélites meteorológicos se utilizan para determinar las condiciones de la atmósfera a fin de efectuar previsiones meteorológicas rutinarias, detectar condiciones climatológicas extremas, detectar vientos y precipitaciones, estimar las precipitaciones, detectar condiciones de congelamiento en aeronaves y prevenir contra situaciones climatológicas extremas en la navegación (UTI 2019). Las observaciones de la variabilidad espacio-tiempo de la precipitación alrededor de la Tierra son indispensables para el entendimiento de como el cambio climático afecta el ciclo del agua en relación a los cambios en las características de la precipitación regional (tipo, frecuencia e intensidad), así como también eventos hidrológicos extremos (inundaciones y sequías). Sin embargo, teniendo en cuenta las redes de estaciones meteorológicas limitados sobre la tierra y la imposibilidad de hacer mediciones de precipitaciones extensas sobre los océanos, una descripción completa de la variabilidad espacial y temporal de la precipitación global sólo se puede lograr desde el punto de vista del espacio.

Figura 1. Constelación de satélites que aportan datos de sensores de microondas a la misión GPM (Global Precipitation Measurement Mission)




En este contexto, los productos de precipitación basados en satélites (SPP) han recibido amplia atención durante la última década para diversas aplicaciones hidrometeorológicas la mayoría de las mediciones de SPP provienen de sensores térmicos infrarrojos (IR) o de microondas pasivos (PMW). Los sensores basados en infrarrojos estiman las tasas de precipitación en función de la

duración de las nubes frías (temperatura de la cima de las nubes). Esta relación indirecta y altamente no estacionaria tiende a dar como resultado un desempeño deficiente en condiciones meteorológicas complejas (Toté et al. 2015). Esto se aplica particularmente a las regiones montañosas tropicales donde se ha demostrado que los sensores infrarrojos subestiman las tasas de precipitación de los sistemas convectivos profundos, así como de las nubes orográficas cálidas. Los sensores PMW se basan en una mejor relación física al derivar estimaciones de lluvia a partir del hielo que se dispersa en las nubes. Sin embargo, tanto las nubes de lluvia estratiformes como las cálidas, que producen poca o ninguna dispersión del hielo, se subestiman y las superficies frías del suelo pueden confundirse con lluvia.

2.2.2. Sensores Térmicos Infrarrojos (IR)

Los sensores IR funcionan detectando la radiación infrarroja emitida por las nubes, donde las nubes más altas y frías emiten menos radiación térmica que las nubes más bajas y cálidas. La temperatura de las cimas de las nubes se utiliza como un proxy para la precipitación, ya que las nubes más frías generalmente se asocian con mayores probabilidades de precipitación intensa (Manz et al. 2016). Entre las ventajas de estos sensores se encuentran su amplia cobertura temporal y espacial, ya que los satélites geoestacionarios equipados con sensores IR pueden proporcionar imágenes de la atmósfera cada 15 minutos, cubriendo grandes áreas de la Tierra. Además, operan tanto de día como de noche, proporcionando datos continuos. Sin embargo, presentan algunas desventajas, como su precisión limitada, dado que la relación entre la temperatura de la nube y la cantidad de precipitación no siempre es directa, lo que puede llevar a errores en la estimación. Además, los sensores IR tienen dificultades para detectar lluvias ligeras y lloviznas.

Figura 2. Condiciones de la superficie derivadas de la teledetección por infrarrojos.




2.2.3. Sensores de Microondas Pasivos (PMW)

Los sensores de microondas pasivos (PMW) funcionan midiendo la radiación de microondas natural emitida por la atmósfera y la superficie terrestre, donde las microondas interactúan con las gotas de lluvia, nieve y hielo en las nubes (Manz et al. 2016). Las diferencias en la radiación de microondas, causadas por las gotas de lluvia y las partículas de hielo, se utilizan para calcular la cantidad de precipitación. Entre las ventajas de estos sensores se destaca su mayor precisión en la estimación de la precipitación, especialmente en regiones tropicales donde las lluvias son más frecuentes e intensas. Además, pueden detectar lluvias ligeras y moderadas con mayor precisión que los sensores IR. Sin embargo, presentan desventajas como una menor frecuencia de observación, ya que los satélites con sensores PMW suelen estar en órbitas polares, lo que significa que pueden pasar por la misma área solo dos veces al día. Además, la cobertura temporal

no es tan continua como la de los sensores IR debido a la naturaleza de estas órbitas polares. Los sensores PMW a menudo proporcionan más información sobre los hidrometeoros, por lo que tienden a generar estimaciones de precipitación más precisas que la recuperación de precipitación basada en datos IR. Sin embargo, la estimación de la precipitación basada en PMW también puede enfrentar grandes incertidumbres debido a varios factores, incluidos errores relacionados con la mala comprensión de la microfísica de la precipitación, dificultades para distinguir entre lluvia ligera y nubes y desafíos para determinar la emisividad de la superficie, especialmente sobre nieve y hielo (Arabzadeh y Behraangi 2021)


Figura 3. Diferencia entre los sensores infrarrojo y los sensores de microondas pasivos



2.2.4. Ecos parásitos terrestres

La contaminación de los ecos de la lluvia por ecos parásitos terrestres puede ser causa de errores muy importantes en la estimación de la precipitación y del viento. Ante todo, deberían reducirse al mínimo los ecos parásitos terrestres mediante una antena adecuada y un buen emplazamiento del radar. Este efecto puede reducirse sensiblemente merced a una combinación de dispositivos de supresión de ecos parásitos en el equipo (Aoyagi, 1983) y mediante el tratamiento de las señales y de los datos. Los ecos parásitos terrestres aumentan considerablemente en caso de propagación anómala.


Figura 4. Espectro del eco de un objetivo meteorológico y de un objetivo terrestre



2.2.5. Ciclo Hidrológico

El ciclo hidrológico describe el movimiento continuo y cíclico del agua en el planeta Tierra, es usado para analizar y comparar datos relacionados con el ciclo del agua, como la precipitación, la escorrentía y la recarga de acuíferos. A diferencia del año calendario, que comienza el 1 de enero y termina el 31 de diciembre, el año hidrológico suele comenzar en una fecha que varía según la región y el clima local, generalmente coincidiendo con el inicio de la temporada de lluvias o el período en que se espera que comience la acumulación de agua en cuencas y embalses. En muchas regiones, el año hidrológico empieza el 1 de octubre y termina el 30 de septiembre del año siguiente (en Perú el año hidrológico empieza el 01 de septiembre y culmina el 31 de agosto del año siguiente). Este ajuste permite una mejor representación de los ciclos naturales del agua y facilita la planificación y gestión de los recursos hídricos. La definición y uso del año hidrológico es crucial para estudios hidrológicos, planificación de recursos hídricos, gestión de inundaciones y sequías, y otras aplicaciones ambientales y de ingeniería. El ciclo hidrológico puede visualizarse como un sistema, es decir, una estructura o volumen en el espacio, definida por una frontera, donde sus componentes internos interactúan entre sí o con otros sistemas cercanos. Los elementos del sistema incluyen las variables hidrológicas (Chow V. T., 1988).

Figura 5. Ciclo hidrológico en una cuenca




2.2.6. Forzantes climáticas

Las forzantes climáticas son factores externos que pueden influir en el clima de la Tierra. Estas forzantes pueden ser de origen natural o antropogénico (causadas por actividades humanas) y pueden afectar la radiación solar que llega a la Tierra o la radiación infrarroja que sale de ella (Solman 2011). Dentro de los cuales podemos encontrar:

- **Gases de efecto invernadero:** Como el dióxido de carbono (CO_2), metano (CH_4) y óxidos de nitrógeno (NO_x), que atrapan el calor en la atmósfera y contribuyen al calentamiento global.
- **Aerosoles:** Pequeñas partículas en la atmósfera que pueden reflejar o absorber la radiación solar, afectando la temperatura y la formación de nubes.
- **Cambios en la radiación solar:** Variaciones en la cantidad de energía solar que llega a la Tierra, que pueden ser causadas por ciclos o erupciones solares.
- **Actividad volcánica:** Las erupciones volcánicas pueden emitir grandes cantidades de ceniza y gases a la atmósfera, que pueden bloquear la radiación solar y enfriar temporalmente la superficie terrestre.
- **Cambios en el uso del suelo:** La deforestación, urbanización y agricultura pueden alterar la reflectividad de la superficie terrestre (albedo) y afectar el clima local y global.

- **Cambios en la circulación oceánica:** Fenómenos como El Niño y La Niña pueden influir en la distribución de la temperatura y la humedad en todo el planeta.


Figura 6. a) Evolución de la temperatura media del hemisferio norte durante los últimos 500 años. b) Forzantes del sistema climático.



Se muestran las anomalías (respecto del promedio de los últimos 400 años) del forzante radiativo correspondiente a las erupciones volcánicas, estimado a partir de la concentración de sulfatos en testigos de hielo. El eje derecho muestra las anomalías del forzante solar (respecto del promedio de los últimos 400 años) escaladas considerando que las variaciones de la actividad solar durante los últimos seis siglos son del orden del 0,25%.

Perú está ubicado en la región centro-occidental de América del Sur (0° – 18° S; 68° – 82° W), cubriendo regiones climáticamente extremadamente variables con diversos regímenes de precipitación que resultan de la interacción entre corrientes atmosféricas de escala sinóptica, las la compleja orografía de los Andes, el frío Sistema de Corriente de Humboldt (HCS) y la Oscilación del Sur de El Niño (ENSO).

Figura 7. Condiciones del ENSO, i) El Niño. ii) La Niña.



Esta forzante climática afecta la distribución de las precipitaciones y su posterior estimación que se puedan generar en las cabeceras de cuenca (Cai et al. 2020).

En el verano austral, los vientos alisios del este desde la posición sur de la Zona de Convergencia Intertropical (ZCIT) transportan masas de aire húmedo desde el Atlántico tropical hacia la cuenca del Amazonas y hacia el sur a lo largo de los Andes a través del Chorro de Bajo Nivel de América del Sur. Este período determina una marcada temporada de lluvias en la mayor parte del Perú.

Por el contrario, cuando la

ZCIT se ubica más al norte (invierno austral), los niveles de convección y, en consecuencia, de precipitación se reducen significativamente (Aybar et al. 2020).

En los Andes peruanos, el clima es complejo y principalmente controlado

por una orografía que actúa como una barrera topográfica al flujo de humedad, provocando la formación de fuertes gradientes de precipitación en los flancos orientales de los Andes. Los valles interandinos están dominados principalmente por procesos convectivos que canalizan las intrusiones de humedad del Amazonas. Al mismo tiempo, la influencia de masas de aire frío y seco provenientes del HCS causan las condiciones más secas de nuestra área de estudio en la costa del Pacífico y en los flancos occidentales de los Andes ($< \sim 500$ mm/año). Sin embargo, durante la ocurrencia de ENSO, el HCS se debilita y pueden ocurrir la formación de tormentas convectivas severas, especialmente sobre la costa norte del Pacífico.

Figura 8. Cinturón de Convergencia Intertropical (ZCIT) en los meses de enero y julio.




Tabla 1. Principales forzantes climáticas de Perú

Subregion	Elevación (msnm)	Forzante Climática	Regimen de Precipitación
Costa del Pacífico	0 -1500	ITCZ, HCS, ENO	Húmedo (Dic - May) Secos (Jun - Nov)
Vertiente Occidental de los Andes	>1500	Elevación, ITCZ	Húmedo (Dic - May) Secos (Jun - Nov)
Vertiente Oriental de los Andes	>1500	Elevación, orografía, ITCZ	Débil estacionalidad Meses secos Jun - Ago
Transición Andes - Amazonia	500 - 1500	Orografía, ITCZ, SALLJ	Débil estacionalidad Meses secos Jun - Ago
Tierras bajas del amazonas	0 - 500	ITCZ, Vientos alisios	Débil estacionalidad Meses secos Jun - Ago

2.2.7. Análisis de Conglomerados

Es una técnica multivariante que busca agrupar elementos (o variables) tratando de lograr la máxima homogeneidad en cada grupo y la mayor diferencia entre los grupos. Tiene por objeto agrupar elementos en grupos homogéneos en función de las similitudes entre ellos. Detecta grupos internamente homogéneos (y heterogéneos entre sí) (Ayuga, 2008)


2.2.8. Datos grillados

Los datos grillados se refieren a un tipo de datos que se organizan en una estructura de cuadrícula o matriz. Esta organización permite una representación sistemática y clara de información espacial o multidimensional, facilitando su análisis y visualización. Un ejemplo típico de datos grillados son las imágenes digitales, donde cada píxel corresponde a un valor específico en la cuadrícula.

Además, los datos grillados son ampliamente utilizados en disciplinas como la meteorología, la geografía y la teledetección para representar fenómenos como la temperatura, la precipitación, la elevación, entre otros. Cada celda de la cuadrícula contiene un dato preciso que corresponde a

una ubicación o punto en un espacio definido, permitiendo una interpretación detallada y estructurada de la información. Los datos grillados de precipitación tienen un buen funcionamiento, pero están supeditados a la covarible (Millan 2022).

Figura 9. Datos grillados de precipitación (CHIRPS)



Existen diferentes conjuntos de datos de precipitación grillada para la región de la vertiente del Pacífico en la parte occidental del Perú, los cuales tienen diferentes escalas espaciales y temporales, en la Tabla 1 se muestra a detalle algunos conjuntos de datos disponibles para la zona de interés. A pesar de ello, la principal limitación de estos productos es la resolución espacial gruesa, la cual genera un nivel de incertidumbre y representatividad para representar los patrones meteorológicos localizado.

Tabla 2. Conjuntos de datos meteorológicos de precipitación grillada diarios existentes para Perú

NOMBRE DEL CONJUNTO DE DATOS	ABREVIATURA	TIPO	RESOLUCIÓN ESPACIAL
Misión de medición de precipitaciones tropicales/ recuperaciones integradas de múltiples satélites para la medición de precipitaciones globales	TRMM/ IMERG	Basado en RS	0.1° (~10 kilómetros)
Estimación de precipitación a partir de información de teledetección utilizando redes neuronales artificiales	PERSIANN	Basado en RS	0.04° (~4 kilómetros)
Centro de Predicción del Clima global de temperatura y precipitación	CPC	Basado en estaciones	0.5° (~50 kilómetros)


NOMBRE DEL CONJUNTO DE DATOS	ABREVIATURA	TIPO	RESOLUCIÓN ESPACIAL
Conjuntos de datos observacional grillado diario ensamblados	E-OBS	Basado en estaciones	0.1° (~10 kilómetros)
Peruvian Interpolated data of SENAMHI's Climatological and Hydrological Observations	PISCO	Basado en estaciones y RS	0.1° (~10 kilómetros)
Administración Nacional Oceánica y Atmosférica (NOAA) - CIRES 20th Century Reanalysis	NOAA-CIRES	Reanálisis	2.5° (~250 kilómetros)
A novel high-resolution gridded precipitation dataset for Peruvian and Ecuadorian watersheds - development and hydrological evaluation	RAIN4PE	Basado en estaciones y RS	0.1° (~10 kilómetros)

*RS = Teledetección

2.2.9. CHIRPS

Climate Hazards group Infrared Precipitation with Stations (CHIRPS) se basa en enfoques anteriores de técnicas de interpolación "inteligentes" y estimaciones de precipitación récord de alta resolución y de largo plazo basadas en observaciones infrarrojas de duración de nubes frías (CCD). CHIRPS se creó en colaboración con científicos del Centro de Ciencia y Observación de Recursos Terrestres (EROS) del USGS con el fin de ofrecer conjuntos de datos completos, confiables y actualizados para una serie de objetivos de alerta temprana, como análisis de tendencias y monitoreo de sequías estacionales (University of California 2024). El algoritmo i) se basa en una climatología de 0,05° que incorpora información satelital para representar ubicaciones escasamente medidas, ii) incorpora estimaciones de precipitación diarias, pentadas y mensuales de 0,05° basadas en CCD desde 1981 al presente, iii) combina datos de estaciones para producir una estimación preliminar producto de información con una latencia de aproximadamente 2 días y un producto final con una latencia promedio de aproximadamente 3 semanas, y iv) utiliza un procedimiento de combinación novedoso que incorpora la estructura de correlación espacial de estimaciones CCD para asignar pesos de interpolación (Funk et al. 2015). El producto CHIRPS es un producto de sensores térmicos infrarrojos (IR)


Figura 10. Revisión general de CHIRPS



2.2.10. PISCO

Peruvian Interpolated data of the SENAMHI's Climatological and hydrological Observations) por sus siglas en ingles. El producto PISCO de precipitación (PISCOp) en su versión diaria y mensual es el resultado de la combinación de datos de estaciones terrenas con climatologías, reanálisis y productos satelitales de estimación de lluvias para obtener una base de datos grillada a nivel nacional de alta resolución espacial ($\sim 5 \times 5$ km); los datos grillados abarcan una serie temporal que se inicia el 1ro de enero 1981 hasta el 31 de diciembre del 2016 (Aybar et al. 2017). Aplica técnicas de interpolación espacial, como el Kriging, para estimar la precipitación en áreas donde no hay estaciones meteorológicas y genera mapas de precipitación mensual y diaria.

Figura 11. PISCO GRILLADO PERU



También proporciona series temporales que permiten analizar la variabilidad (Figura 12) y los patrones de precipitación a lo largo del tiempo (Figura 13).

Figura 12. Serie temporal generada a partir del PRODUCTO PISCO




Figura 13. Variabilidad de las precipitaciones mensual desde el mes de enero de 1981 (X252.5) al mes de diciembre del 1981 (X263.5)





Figura 15. Definición de Dendograma



2. 3.Definición de Términos Básicos

2.3.1. Año Hidrológico

El comienzo del año hidrológico puede variar entre una región y otra, incluso dentro de un mismo país. Por ejemplo, en países del hemisferio norte con clima continental extremo, con veranos muy secos e inviernos lluviosos, el comienzo del año hidrológico suele darse en septiembre u octubre. En el hemisferio sur, al contrario, puede considerarse marzo o abril.

En el caso de Perú y sobre todo en la sierra existe una marcada temporalidad entre lluvias y estiaje, pues el año hidrológico inicia el 1 de setiembre de cada año y culmina el 31 de agosto

2.3.2. Precipitación


La precipitación, es toda forma de humedad que, originándose en las nubes, llega hasta la superficie terrestre. La precipitación incluye la lluvia, la nieve y otros procesos mediante los cuales el agua cae a la superficie terrestre, tales como el granizo y nevisca. La cantidad de

precipitación se mide en milímetros (mm) o pulgadas (in) utilizando pluviómetros y es una variable crucial en la climatología y la meteorología. La precipitación influye en múltiples aspectos del medio ambiente y las actividades humanas, incluyendo la agricultura, el abastecimiento de agua, la gestión de recursos hídricos y la prevención de desastres naturales como inundaciones y sequías. Además, la distribución y cantidad de precipitación pueden variar significativamente según la región y la estación del año, afectando los ecosistemas y la vida cotidiana de las personas. Por ejemplo, regiones tropicales suelen recibir abundantes precipitaciones a lo largo del año, mientras que las zonas áridas experimentan precipitaciones escasas y esporádicas.

2.3.3. Pluviómetros

El medidor de precipitación utilizado normalmente consiste en un colector situado por encima de un embudo que da paso a un depósito, donde el agua y la nieve derretida acumuladas se almacenan entre períodos de observación. Se utilizan diversas formas de medidores en diferentes lugares del mundo, tal y como se muestra en la Figura 16.

Figura 16. Diferentes formas de pluviómetros normalizados.



Las líneas continuas muestran las líneas de corriente y las líneas discontinuas hacen lo propio con las trayectorias de las partículas de precipitación. El primer pluviómetro muestra la mayor deformación del campo de viento por encima de la boca del instrumento de medición, y el último pluviómetro muestra la menor. En consecuencia, el error inducido por el viento en el caso del primer pluviómetro es más importante que en el caso del último.

2.3.4. Red Pluviométrica

Una red pluviométrica es un conjunto de estaciones meteorológicas distribuidas estratégicamente en una región o país, dedicadas a medir y registrar las precipitaciones (lluvia, nieve, granizo) que ocurren en cada punto. Estas estaciones utilizan pluviómetros, que son instrumentos diseñados específicamente para capturar y cuantificar la cantidad de precipitación en un periodo determinado. El propósito de una red pluviométrica es obtener datos precisos y representativos sobre la distribución espacial y temporal de las precipitaciones, lo cual es esencial para estudios hidrológicos, gestión de recursos hídricos, pronósticos meteorológicos, investigación climática y planificación agrícola. La densidad y ubicación de las estaciones en la red son factores críticos para asegurar la precisión y utilidad de los datos recolectados.


Figura 17. Red de estaciones convencionales distribuidas a nivel nacional



2.3.5. Radares meteorológicos

Los radares meteorológicos son dispositivos que utilizan ondas de radio para detectar y medir la precipitación, la velocidad del viento, y otros fenómenos atmosféricos. Estos radares emiten pulsos de radio hacia la atmósfera, que luego son reflejados por las gotas de lluvia, copos de nieve, granizo y otros tipos de hidrometeoros. Al analizar el eco de estas señales reflejadas, el radar puede determinar la intensidad, la localización, el movimiento y la estructura de las precipitaciones.

Figura 18. Radares meteorológicos



2.3.6. Serie de datos

Una serie de tiempo meteorológica es una secuencia de datos registrados a lo largo del tiempo que refleja las observaciones de variables meteorológicas, tales como la temperatura, la presión atmosférica, la humedad, la velocidad y dirección del viento, y la radiación solar. Estas series de tiempo son fundamentales para el estudio del clima y el tiempo atmosférico, permitiendo analizar patrones, variabilidad y cambios a diferentes escalas temporales.

Las series de tiempo meteorológicas se utilizan para:


Pronóstico del tiempo: Predecir las condiciones meteorológicas futuras a corto y mediano plazo, lo cual es esencial para la planificación de actividades diarias, la agricultura, la aviación, y la gestión de emergencias.

Análisis de tendencias climáticas: Detectar cambios a largo plazo en las condiciones meteorológicas, lo cual es vital para estudiar el cambio climático y sus impactos.

Modelización climática: Desarrollar y validar modelos que simulan el comportamiento del sistema climático y sus componentes, ayudando a comprender y predecir fenómenos climáticos complejos.

Las series de tiempo meteorológicas pueden abarcar diferentes escalas temporales, desde minutos y horas hasta décadas y siglos, y su análisis requiere técnicas estadísticas avanzadas para identificar patrones, tendencias y anomalías.

Figura 19. Series de patrones de precipitaciones



2.3.7. Estacionalidad


La estacionalidad en un régimen de precipitaciones se refiere a la variación regular y predecible de las lluvias a lo largo del año. Esta variabilidad estacional está influenciada por factores como la posición geográfica, la topografía y las corrientes oceánicas y atmosféricas. En un régimen de precipitaciones estacional, ciertos periodos del año, como meses o estaciones específicas, reciben más lluvia que otros. Por ejemplo, en regiones tropicales, es común tener una temporada de

lluvias intensas (monzón) seguida de una estación seca. En regiones templadas, puede haber más precipitaciones en invierno y primavera, mientras que el verano y el otoño pueden ser más secos. Identificar y comprender la estacionalidad es crucial para la gestión del agua, la agricultura y la planificación urbana, ya que permite prever periodos de abundancia o escasez de agua y tomar medidas adecuadas. Las densidades recomendadas según la Organización Meteorológica Mundial (OMM) (WMO 2008), que presenta

Tabla 3. Densidades Recomendadas para las estaciones meteorológicas

Region	Red mínimo	Red provisional
Planicie	600 – 900 km ² por pluviómetro	900 – 3000 km ²
Montaña	100 – 250	250 - 2000
Islas	25	
Zonas áridas	1500 - 10000	

Figura 20. Estacionalidad en una serie de datos



2.3.8. Índices de Evaluación de la Precisión y Desempeño de los Datos

En el presente estudio se han empleado varios índices estadísticos para evaluar la precisión y el desempeño de los datos de precipitación obtenidos del producto PISCO en comparación con los registros de las estaciones convencionales. A continuación, se presentan los índices utilizados y sus respectivos rangos de evaluación:

2.3.8.1. Coeficiente de Determinación (R^2)

- El coeficiente de determinación (R^2) mide la proporción de la variación en los datos observados que es explicada por el modelo. Indica qué tan bien los datos ajustados se correlacionan con los datos observados.

- Fórmula

$$R^2 = 1 - \frac{\sum(O_i - P_i)^2}{\sum(O_i - O_m)^2}$$

- Donde:

O_i = Valor observado

P_i = Valor predicho

O_m = Media de los valores observados

- Rango de evaluación

Tabla 4. Rango de evaluación de R^2

Rango de evaluación del Coeficiente de determinación			
○	Excelente	○	$0.85 \leq R^2 \leq 1.0$
○	Bueno	○	$0.70 \leq R^2 < 0.85$
○	Aceptable	○	$0.50 \leq R^2 < 0.70$
○	Pobre	○	$R^2 < 0.50$

2.3.8.2. Sesgo Relativo (Bias %)

El sesgo (Bias %) cuantifica la tendencia sistemática de sobreestimación o subestimación de los valores predichos en comparación con los valores observados.

- Fórmula

$$\text{BIAS (\%)} = \frac{\sum(O_i - P_i)}{\sum O_i} * 100$$

- Rango de evaluacion

Tabla 5. Rango de evaluación de BIAS

Rango de evaluación del BIAS	
○ Alto Sesgo	○ $ Bias \geq 10\%$
○ Moderado Sesgo	○ $5\% \leq Bias < 10\%$
○ Ligero Sesgo	○ $ Bias < 5\%$
○ Sesgo Nulo	○ $Bias = 0\%$

- Interpretación

Un sesgo positivo indica sobreestimación, mientras que un sesgo negativo indica subestimación

2.3.8.3. Coeficiente de Eficiencia de Nash-Sutcliffe (NSE)

El coeficiente de eficiencia de Nash-Sutcliffe (NSE) evalúa la precisión de los modelos comparando la magnitud de los errores predichos con la variación de los datos observados.

- Fórmula

$$R^2 = 1 - \frac{\sum(O_i - P_i)^2}{\sum(O_i - O_m)^2}$$

- Rango de evaluación

Tabla 6. Rango de evaluación de BIAS

Rango de evaluación del NSE	
○ Excelente	○ $0.75 \leq NSE \leq 1.0$
○ Bueno	○ $0.65 \leq NSE < 0.75$
○ Aceptable	○ $0.50 \leq NSE < 0.65$
○ Pobre	○ $NSE < 0.50$

- Interpretación

Un NSE cercano a 1 indica una excelente concordancia entre los valores observados y predichos, mientras que un valor negativo indica que el promedio observado es un mejor predictor que el modelo

2.3.8.4. Relación del Error Cuadrático Medio (RSR)

El índice RSR (Ratio of the Root Mean Square Error to the Standard Deviation) combina el error cuadrático medio (RMSE) y la desviación estándar de los valores observados, normalizando el error.

- Fórmula

$$RSR = \frac{\sqrt{\sum(O_i - P_i)^2}}{\sqrt{\sum(O_i - O_m)^2}}$$

- Rango de evaluación

Tabla 7. Rango de evaluación de BIAS

Rango de evaluación del NSE	
○ Excelente	○ $0.00 \leq RSR \leq 0.50$
○ Bueno	○ $0.50 < RSR \leq 0.60$
○ Aceptable	○ $0.60 < RSR \leq 0.70$
○ Pobre	○ $RSR > 0.70$


- Interpretación

La interpretación de un valor de RSR cercano a 0 indica una excelente precisión del modelo, mientras que valores superiores a 0.70 reflejan un bajo desempeño.

2.3.9. Distribución de probabilidad

Una función que describe todas las posibles valores y probabilidades que una variable aleatoria puede tomar dentro de un intervalo determinado. El mapeo de cuantiles ajusta una distribución a otra.

Figura 21. Distribuciones de probabilidad de datos



2.3.9.1. Cuantiles

Los cuantiles son valores que dividen un conjunto de datos en intervalos con igual probabilidad. Ejemplos específicos de cuantiles son los percentiles, deciles y cuantiles.

2.3.9.2. Función de Distribución Acumulativa (CDF)

La CDF es una función que describe la probabilidad de que una variable aleatoria tome un valor menor o igual a un cierto valor. El mapeo de cuantiles se basa en la comparación de las CDFs de las dos distribuciones.

2.3.9.3. Corrección de Sesgos (Bias Correction)

Técnicas que se utilizan para ajustar las salidas de modelos numéricos para que coincidan mejor con las observaciones. El mapeo de cuantiles es una de estas técnicas.

2.3.9.4. Quantile mapping

El "quantile mapping" (mapeo de cuantiles) es una técnica utilizada en estadística y análisis de datos para ajustar una distribución de datos a una distribución de referencia (como observaciones históricas). El objetivo principal es corregir sesgos en los datos modelados y hacerlos más comparables con los datos observados.

Su funcionamiento se basa en:


Cuantiles: Primero, se calculan los cuantiles de ambas distribuciones, tanto de la distribución de referencia como de la distribución a ajustar.

Maapeo: Se establece una correspondencia entre los cuantiles de la distribución a ajustar y los cuantiles de la distribución de referencia.

Ajuste: Los valores de la distribución a ajustar se transforman para alinearse con la distribución de referencia según la correspondencia de cuantiles establecida en el paso anterior.

Esta técnica se utiliza ampliamente en la corrección de sesgos en modelos climáticos, hidrológicos y otros modelos predictivos, permitiendo que las simulaciones sean más precisas y útiles para la toma de decisiones.


Figura 22. Ejemplo de Quantile Mapping con datos de temperatura



2.3.10. Isoyetas

Las isoyetas son líneas en un mapa que conectan puntos con igual precipitación acumulada durante un cierto período de tiempo. Estas líneas se utilizan en climatología e hidrología para representar la distribución espacial de la precipitación, facilitando el análisis de patrones y variaciones en las precipitaciones de una región específica.


Figura 23. Mapa de isoyetas.



2.3.11. Archivo NetCDF

Un **archivo NetCDF** (Network Common Data Form) es un formato de archivo diseñado para el almacenamiento y manejo eficiente de **datos científicos multidimensionales**, especialmente utilizados en disciplinas como la meteorología, la oceanografía, la climatología, la hidrología, entre otras. Este formato es ampliamente utilizado para guardar **grandes volúmenes de datos** que contienen información en varias dimensiones, como tiempo, latitud, longitud, profundidad, etc.

Figura 24. Archivo NETCDF



CAPITULO III: MATERIALES Y MÉTODOS

En este capítulo se describen detalladamente los materiales y métodos utilizados en la presente investigación para validar y corregir la precipitación mensual generada con el producto PISCO en la región de Cajamarca durante el período de 1981 a 2023. Se incluyen las herramientas y equipos de campo necesarios para la recolección de datos meteorológicos, así como el software y los recursos de gabinete empleados para el análisis y procesamiento de dicha información. Además, se explican los procedimientos específicos seguidos para la comparación y análisis de los datos obtenidos de las estaciones meteorológicas y los proporcionados por el producto PISCO. Con ello, se busca ofrecer una base sólida para la interpretación de los datos y las conclusiones presentadas en los capítulos posteriores.

3. 1. Descripción y Etapas de la Investigación

Ubicación de la región. - La región de Cajamarca se encuentra en el norte de Perú, en la parte noroccidental del país. Aquí tienes algunos detalles más específicos sobre su ubicación:

Latitud y Longitud: Aproximadamente entre 5° y 8° de latitud sur y entre 77° y 80° de longitud oeste.

Límites:

Norte: Limita con la región de Amazonas.

Este: Limita con la región de San Martín.

Sur: Limita con la región de La Libertad.

Oeste: Limita con la región de Lambayeque y la región de Piura.

Características Geográficas

Cordillera de los Andes: Cajamarca está ubicada en la vertiente oriental de la Cordillera de los Andes, lo que le confiere un terreno montañoso con elevaciones significativas.


Valles y Cuencas: La región tiene numerosos valles y cuencas hidrográficas, siendo una de las más importantes la cuenca del río Marañón.

Altitud: Varía desde los 400 metros sobre el nivel del mar en las zonas bajas hasta más de 4,000 metros en las partes altas de la cordillera.

Importancia

Económica: La región es importante por su producción agrícola, ganadera y minera. Es una de las principales productoras de oro del país gracias a la mina Yanacocha.

Figura 25. Ubicación de la REGION CAJAMARCA EN PERU



El conjunto de datos de precipitación mensual observada proviene de las estaciones meteorológicas convencionales administradas por el Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI) (<https://www.senamhi.gob.pe/?p=estaciones>) y de la Plataforma del Observatorio del agua de la Autoridad Nacional del Agua (ANA) (<https://snirh.ana.gob.pe/onrh/>). Dentro de la información proporcionada, en lo referente a la información pluviométrica a escala mensual contando con 38 estaciones, con registros con un mínimo de 10 años de precipitación mensual, esta es detallada en la Tabla 8

Tabla 8. Estaciones Meteorológicas identificadas para el desarrollo de la investigación.


Nº	Nombre	Ubicación Política			Cuenca	Latitud (°S)	Longitud (°W)	Altitud msnms
		Dpto.	Provincia	Distrito				
1	ASUNCION	Cajamarca	Cajamarca	Asuncion	Alto Jequetepeque	07° 19' 34"	78° 30' 57"	3292.7
2	AUGUSTO WEBERBAUER	Cajamarca	Cajamarca	Cajamarca	Crisnejas	07° 10' 03"	78° 29' 35"	3149
3	BAGUA CHICA	Amazonas	Bagua	Bagua	Utcubamba	05° 37' 49"	78° 31' 29"	3100
4	BAMBAMARCA	Cajamarca	Hualgayoc	Bambamarca	Intercuenca Alto Marañón IV	06° 40' 35"	78° 31' 06"	3052
5	CAJABAMBA	Cajamarca	Cajabamba	Cajabamba	Crisnejas	07° 37' 18"	78° 03' 05"	3030
6	CELENDIN	Cajamarca	Celendin	Celendin	Intercuenca Alto Marañón IV	06° 51' 11"	78° 08' 41"	3030
7	CHANCAY BAÑOS	Cajamarca	Santa Cruz	Chancay Baños	Chancay - Lambayeque	06° 34' 30"	78° 52' 02"	2980
8	CHIRINOS	Cajamarca	San Ignacio	Chirinos	Chinchi	5° 18' 31"	78° 53' 51"	2951
9	CHONTALI	Cajamarca	Jaen	Chontali	Chamaya	05° 38' 38"	79° 05' 24"	2908
10	CHOTA	Cajamarca	Chota	Chota	Chamaya	06° 32' 50"	78° 38' 55"	2900
11	CHOTANO LAJAS	Cajamarca	Chota	Lajas	Chamaya	06° 33' 35"	78° 44' 54"	2779
12	CHOTANO LLAUCANO	Cajamarca	Hualgayoc	Bambamarca	Intercuenca Alto Marañón IV	06° 41' 12"	78° 31' 05"	2760
13	CHUGUR	Cajamarca	Hualgayoc	Chugur	Chancay - Lambayeque	06° 40' 07"	78° 44' 17"	2748
14	COCHABAMBA	Cajamarca	Chota	Cochabamba	Chamaya	06° 27' 36"	78° 53' 19"	2743
15	COCHALAN	Cajamarca	San Ignacio	La Coipa	Chinchi	05° 26' 9.38"	78° 58' 16.29"	2673
16	CONTUMAZA	Cajamarca	Contumaza	Contumaza	Contumaza	07° 21' 55"	78° 49' 22"	2666
17	CUEVA BLANCA	Lambayeque	Ferreñafe	Incahuasi	Chamaya	06° 9' 35"	79° 21' 22"	2602
18	CUTERVO	Cajamarca	Cutervo	Cutervo	Chamaya	06° 22' 45.4"	78° 48' 16.3"	2564
19	EL LIMON	Cajamarca	Jaen	Pomahuaca	Chamaya	05° 55' 05"	79° 19' 03"	2542
20	EL PALTO	Amazonas	Utcubamba	Yamon	Intercuenca Alto Marañón IV	05° 59' 11.15"	78° 28' 35.3"	2536
21	GRANJA PORCON	Cajamarca	Cajamarca	Cajamarca	San Miguel	07° 02' 15"	78° 38' 00"	2486.6
22	HUAMACHUCO	La Libertad	Sanchez Carrion	Huamachuco	Crisnejas	07° 49' 9.4"	78° 02' 24"	2480
23	HUAMBOS	Cajamarca	Chota	Huambos	Alto Chancay - Lambayeque	06° 27' 13"	78° 57' 47"	2466
24	HUARMACA	Piura	Huancabamba	Huarmaca	Chamaya	5° 34' 00"	79° 31' 00"	2325
25	INCAHUASI	Lambayeque	Ferreñafe	Incahuasi	Motupe	6° 14' 14"	79° 20' 20"	2293.6
26	JAEN	Cajamarca	Jaen	Jaen	Intercuenca Alto Marañón III	5° 40' 36"	78° 46' 27"	2287
27	JESUS	Cajamarca	Cajamarca	Jesus	Crisnejas	07° 14' 45"	78° 23' 18"	2270
28	LA CASCARILLA	Cajamarca	Jaen	Jaen	Intercuenca Alto Marañón III	05° 40' 18.3"	78° 53' 51.6"	2253
29	LA ENCAÑADA	Cajamarca	Cajamarca	La Encañada	Crisnejas	07° 07' 24"	78° 19' 59"	2180
30	LACAMACA	Cajamarca	Hualgayoc	Hualgayoc	Intercuenca Alto Marañón IV	6° 42' 00"	78° 34' 32"	2163.4
31	LEIMBAMBA	Amazonas	Luya	San Francisco de Yesso	Utcubamba	06° 40' 35.9"	77° 47' 60"	2133.5
32	LLAMA	Cajamarca	Chota	Llama	Chancay - Lambayeque	6° 30' 52"	79° 07' 21"	2026
33	LLAPA	Cajamarca	San Miguel	Llapa	San Miguel	06° 58' 42"	78° 48' 40"	2005
34	MAGDALENA	Cajamarca	Cajamarca	Magdalena	Alto Jequetepeque	07° 15' 12"	78° 39' 09"	1970
35	NAMBALLE	Cajamarca	San Ignacio	Namballe	Chinchi	4° 59' 58"	79° 5' 19"	1800
36	NAMORA	Cajamarca	Cajamarca	Namora	Crisnejas	07° 12' 02"	78° 19' 40"	1785.4
37	PIMPINGUILLOS	Cajamarca	Cutervo	Pimpingos	Intercuenca Alto Marañón IV	06° 0' 56.75"	78° 46' 7.69"	1750
38	PUCHACA	Lambayeque	Ferreñafe	Incahuasi	Motupe	06° 22' 24"	79° 28' 02"	1677
39	QUEBRADA SHUGAR	Cajamarca	Hualgayoc	Bambamarca	Intercuenca Alto Marañón IV	06° 41' 16"	78° 27' 25"	1671.7
40	QUEROCOTILLO	Cajamarca	Cutervo	Querocotillo	Chamaya	6° 16' 25"	79° 2' 13"	1626.5
41	QUILCATE	Cajamarca	San Miguel	Catilluc	Chancay - Lambayeque	6° 49' 12"	78° 44' 38"	1435
42	SALLIQUE	Cajamarca	Jaen	Sallique	Chamaya	5° 39' 01"	79° 19' 01"	1317
43	SAN BENITO	Cajamarca	Contumaza	San Benito	Santanero	07° 25' 41"	78° 55' 36"	1307
44	SAN IGNACIO	Cajamarca	San Ignacio	San Ignacio	Chinchi	05° 8' 42.5"	78° 59' 42.44"	1243
45	SAN JUAN	Cajamarca	Cajamarca	San Juan	Alto Jequetepeque	07° 17' 51"	78° 29' 28"	1132.6
46	SAN MARCOS	Cajamarca	San Marcos	Pedro Galvez	Crisnejas	07° 19' 21"	78° 10' 22"	772
47	SAN MIGUEL	Cajamarca	San Miguel	San Miguel	San Miguel	06° 59' 49"	78° 51' 11"	753.7
48	SAN PABLO	Cajamarca	San Pablo	San Pablo	San Miguel	07° 07' 04"	78° 49' 51"	654
49	SANTA CRUZ	Cajamarca	Santa Cruz	Santa Cruz	Chancay - Lambayeque	6° 37' 59"	78° 56' 51"	450
50	SONDOR	Cajamarca	San Marcos	Gregorio Pita	Crisnejas	07° 14' 13"	78° 12' 45"	434
51	TABACONAS	Cajamarca	San Ignacio	Tabaconas	Chinchi	05° 19' 60"	79° 13' 60"	336
52	TOCMOCHE	Cajamarca	Chota	Tocmoche	Motupe	06° 24' 24"	79° 21' 21"	149
53	UDIMA	Cajamarca	Santa Cruz	Catache	Zaña	06° 48' 47"	79° 05' 04"	2466

Previamente a la completación de los registros de precipitación se hará un control de calidad de los datos, teniendo en cuenta 03 consideraciones:

- i. Eliminar valores evidentemente inconsistentes, como precipitaciones negativas y no físicas
- ii. para la detección de eventos extremos, si los valores extremos ocurren en al menos dos anchos de vía vecinos (<50 km) para la misma fecha, se conservan; en caso contrario, se eliminan.
- iii. un control visual para reconocer segmentos con patrones de redondeo asimétricos y faltas de homogeneidad evidentes.


Para completar su información pluviométrica de las estaciones meteorológicas, se hará uso del método del quantile mapping, tal cual esta descrito en la Definición de Términos (*ver Capítulo II. Definición de términos básicos*), del mismo modo teniendo en cuenta la crítica de datos, la homogenización y la extensión-completación de datos de precipitación, pero antes de su aplicación es necesario el identificar regiones meteorológicas similares para tener una buena correlación entre estaciones. Esto es llevado a cabo mediante un análisis de conglomerados o clúster que nos permite agrupar las estaciones según las características ingresadas. El resultado del análisis clúster se representa en forma de dendrograma como se ve a continuación.

Figura 26. Dendrograma de las estaciones meteorológicas



Después de haber aplicado el análisis de conglomerados, se identificaron un número de regiones de precipitación, las cuales son agrupadas como se muestra a continuación.

Figura 27. Regiones Meteorológicas similares



Una vez evaluado y completado se procederá a extraer los datos mensuales del producto PISCO de las casi 40 estaciones meteorológicas convencionales en la región de Cajamarca y sus alrededores. Para luego realizar un análisis de comparación mediante:

- Métodos estadísticos para comparar las dos fuentes de datos (error medio cuadrático, Correlación Pearson (R^2), Nash - Sutcliffe (NSE) , Sesgo Porcentual (BIAS), Relación de desviación estándar residual (RSR)).
- Gráficos de dispersión y series temporales para visualizar diferencias y similitudes.

Para así realizar la aplicación del mapeo de cuantiles para ajustar la precipitación mensual del producto PISCO a los registros observados y descripción detallada del proceso de mapeo de cuantiles, incluyendo la selección de cuantiles y la implementación del mapeo.

Una vez culminada se realizará el proceso de validación de los datos corregidos mediante métricas como el error cuadrático medio (RMSE), Nash - Sutcliffe (NSE) y el Sesgo Porcentual (BIAS).

Para finalizar se realizará el análisis espacial para la generación de isoyetas mediante el Krigging para toda la región de Cajamarca y poder brindar un producto que muestre y refleje el comportamiento de los patrones de precipitación a nivel mensual en la región.

Software.- Los softwares usados como apoyo en el desarrollo de la presente investigación fueron QGIS, R, Rstudio (con los paquetes ‘climatol’, ‘meteo’, ‘raster’, ‘sp’, entre otros), Cormul, EasyFit 5.5, Hydraccess, Ms Excel, Ms Word, HIDROSIG, Hydrognomon.

3. 2. Materiales y equipos

Equipos de campo. - Los equipos de campo usados en la investigación fueron:

- GPS (Sistema de Posicionamiento Global)
- Pluviómetros
- Estaciones meteorológicas
- Dataloggers
- EPP(Botas, sombrero, lentes, guantes)
- Cámara fotográfica

Equipos de gabinete. - Los equipos usados en la investigación fueron:

- Computadora de alto rendimiento
- Monitor de alta resolución
- Impresora multifuncional HP 2050

Materiales. - Los materiales usados dentro de la investigación fueron Papel Bond A4, memoria USB, Disco Duro, lápices, lapiceros, marcadores, pizarra acrílica, archivadores.

3.3. Metodología

La investigación se basa en un enfoque cuantitativo, utilizando técnicas estadísticas y geoespaciales para validar y corregir datos de precipitación mensual del producto PISCO en la región de Cajamarca. Se emplearon series históricas de datos (1981–2023) de estaciones meteorológicas convencionales y estimaciones satelitales, que fueron procesadas y analizadas mediante métodos de validación estadística, regionalización hidroclimática e interpolación espacial.

3.3.1. Tipo de Investigación

El estudio es de tipo aplicada, ya que busca generar información útil para mejorar la precisión de los registros de precipitación y apoyar la toma de decisiones en la gestión de recursos hídricos.

3.3.2. Nivel de Investigación

La investigación es de nivel descriptivo y correlacional, pues caracteriza el comportamiento espacial y temporal de la precipitación y evalúa la relación entre los datos observados y estimados por PISCO.

3.3.3. Diseño de Investigación

El diseño es no experimental, longitudinal y descriptivo, dado que no se manipulan variables, sino que se analizan datos existentes a lo largo de un periodo determinado (1981–2023).

- **Población de estudio**

La población está conformada por la totalidad de registros históricos de precipitación disponibles en la región de Cajamarca, tanto de estaciones meteorológicas convencionales como de estimaciones satelitales.

- **Muestra**

La muestra corresponde a las 35 estaciones pluviométricas activas y con datos históricos representativas de la región, seleccionadas en función de su disponibilidad y continuidad temporal.

3. 4. Procedimiento

El procedimiento para lograr el objetivo principal de la investigación posee las siguientes etapas.

Figura 28. Esquema del procedimiento



CAPITULO IV: ANALISIS Y DISCUSIÓN DE RESULTADOS

En este capítulo se analizan y discuten los resultados obtenidos del estudio sobre la precipitación mensual en la región de Cajamarca, empleando datos del producto PISCO (SENAMHI) y comparándolos con los registros de las estaciones convencionales de SENAMHI. El objetivo principal fue identificar los sesgos presentes en los datos de PISCO y corregirlos mediante el mapeo de cuartiles, culminando con la generación de isoyetas para la región.

Se presenta un análisis detallado de la comparación inicial entre los datos de PISCO y los registros de las estaciones convencionales, evaluando tanto las correlaciones como los errores

cuadráticos medios. A continuación, se describe el proceso de mapeo de cuartiles utilizado para ajustar los datos de PISCO, destacando las mejoras obtenidas en la precisión de los datos corregidos.

Finalmente, se aborda la generación de isoyetas como resultado final del estudio, proporcionando una herramienta fundamental para la gestión de recursos hídricos y la planificación regional en Cajamarca.

4.1. Preparación y control de calidad de datos de precipitación.

4.1. 1. Procesamiento de la Data estimada del producto PISCO.

En la Figura 28 se presentan las 53 estaciones meteorológicas seleccionadas para la presente investigación. Estas estaciones corresponden tanto a la región Cajamarca como a regiones aledañas, ya que, para identificar estaciones fuera de Cajamarca, pero cercanas a la región, se aplicó un buffer de 100 km. Esto permitió contar con una mejor estimación de los patrones de precipitación en la zona. Posteriormente, se empleó el software RStudio para extraer los datos del producto PISCO, obteniendo la precipitación total mensual desde enero de 1981 hasta diciembre de 2023, el código script se adjunta en el *Anexo A*. Los histogramas de las principales estaciones y la comparación de estas se muestran en la Figura 30.

Figura 29. Estaciones de la Región Cajamarca usadas en el estudio.





Figura 30. Histogramas representativos de la Comparación PISCO con las estaciones terrestres.



La Figura 30, muestra diferentes patrones de correlación para ello y para tener una mejor evaluación gráfica, se muestra la Tabla 9 donde se refleja el grado de dispersión que se presenta al comparar las estaciones con registros terrestres y con la data satelital del producto grillado PISCO. (Ver ANEXOS)

4.1. 2. Evaluación del producto PISCO.

En la presente investigación se han utilizado los siguientes índices que son detallados a continuación en la Tabla 10, que reflejan la comparativa entre los registros de precipitación de las estaciones de campo y las generadas a partir del producto satelital PISCOp.

Tabla 9. Índices estadísticos obtenidos para cada estación

NOMBRE DE ESTACION	R2	BIAS(%)	(NSE)	(RSR)
ASUNCION	0.86	-40.22	0.58	0.64
AUGUSTO_WEBERBAUER	0.94	-0.06	0.93	0.26
BAGUA_CHICA	0.78	-9.25	0.82	0.63
BAMBAMARCA	0.90	1.94	0.86	0.38
CAJABAMBA	0.96	1.74	0.83	0.42
CASCARILLA	0.42	-60.88	-0.42	1.20
CELENDIN	0.95	0.29	0.89	0.34
CHANCAY_BANIOS	0.69	10.47	0.58	0.64
CHIRINOS	0.48	-44.64	-0.05	1.18
CHONTALI	0.60	-16.12	0.35	0.90
CHOTA	0.83	-17.23	0.73	0.55
CHOTANO_LAJAS	0.91	-0.52	0.89	0.33
CHOTANO_LLAUCANO	0.87	-7.77	0.82	0.42
CHUGUR	0.67	-5.44	0.64	0.60
COCHABAMBA	0.56	11.23	0.30	0.65
COCHALAN	0.49	-36.18	0.21	0.89
CONTUMAZA	0.92	-11.60	0.88	0.33
CUEVA_BLANCA	0.60	-20.77	0.43	0.75
CUTERVO	0.60	-4.32	0.42	0.78
EL_LIMON	0.73	43.11	0.52	0.69
EL_PALTO	0.60	-12.69	0.17	0.92
GRANJA PORCON	0.80	1.73	0.58	0.66
HUAMACHUCO	0.94	22.55	0.58	0.68
HUAMBOS	0.02	-62.66	-0.10	1.04
HUARMACA	0.89	-23.69	0.83	0.41
INCAHUASI	0.68	-6.11	0.31	0.82


NOMBRE DE ESTACION	R2	BIAS(%)	(NSE)	(RSR)
JAEN	0.39	-25.70	0.26	0.87
JESUS	0.94	17.21	0.76	0.49
LA_ENCANIADA	0.94	-6.75	0.89	0.34
LACAMACA	0.85	-23.44	0.70	0.54
LEIMEBAMBA	0.75	29.48	0.15	0.92
LLAMA	0.76	-45.64	0.62	0.62
LLAPA	0.93	9.96	0.70	0.55
MAGDALENA	0.96	-3.63	0.96	0.20
NAMANBALLE	0.09	-57.49	-0.15	1.06
NAMORA	0.88	21.17	0.63	0.62
PIMPINGUILLOS	0.40	65.11	-1.65	1.60
PUCHACA	0.99	-2.75	0.98	0.15
QUEBRADA_SHUGAR	0.74	-23.83	0.55	0.68
QUEROCOTILLO	0.38	1.24	-0.32	1.15
QUILCATE	0.85	-1.17	0.84	0.40
SALLIQUE	0.42	25.96	0.33	0.81
SAN_BENITO	0.91	-17.57	0.85	0.38
SAN_IGNACIO	0.40	-34.35	0.07	0.99
SAN_JUAN	0.79	-45.08	0.42	0.76
SAN_MARCOS	0.78	29.63	0.51	0.70
SAN_MIGUEL	0.93	15.66	0.77	0.47
SAN_PABLO	0.94	-55.35	0.48	0.71
SANTA_CRUZ	0.46	29.54	0.15	0.89
SONDOR	0.96	6.46	0.82	0.42
TABACONAS	0.47	-12.29	0.18	0.92
TOCMOCHE	0.64	-33.59	0.58	0.64
UDIMA	0.64	3.34	0.53	0.67
PROMEDIO	0.71	-7.94	0.48	0.67

De las estaciones evaluadas con mayor dispersión se encontraron las siguientes: Cascarilla, Chirinos, Cochalan, Huambos, Jaen, Namanballe, Pimpinguillos, Querocotillo, San Ignacio, Tabaconas que no se tomaran en cuenta para el desarrollo de posteriores isoyetas.

a. **En base al Coeficiente de Determinación**

En base a lo mostrado en la Tabla 10, se puede concluir que:

Figura 31. Resultados según la correlación de Pearson.




De la Figura 31, se concluye que: De las 53 estaciones, el 4% no tiene correlación, el 29% presenta una correlación mala, el 24% presenta una correlación regular, el 15% presenta una correlación buena teniendo un 28% de correlación excelente.

b. En base al Sesgo porcentual (BIAS)


En base a lo mostrado en la Tabla 10, se puede concluir que:

Figura 32. Resultados según Sesgo Porcentual Bias.



De la Figura 32, se concluye que: De las 53 estaciones evaluadas, el 37 % muestran como muy bueno el Sesgo Porcentual, el 43% subestima y el 21 % sobrestima la precipitación mensual, esto se muestra y se puede observar en la Figura 33, donde las zonas en **tonos cálidos** (rojo a naranja) indican que el PISCO **subestima** la precipitación respecto a las estaciones (bias negativo), mientras que las zonas en **tonos fríos** (verde a azul) indican una **sobreestimación** del PISCO (bias positivo). Gran parte del departamento presenta un bias negativo, especialmente en la zona norte y centro (Cutervo, Chota, Santa Cruz, San Miguel), lo que indica que el producto PISCO subestima la precipitación real. Hay pocas áreas con bias positivo (sobreestimación), destacando una zona muy puntual en la provincia de Jaén y zonas al este de San Marcos o Celendín. Esto puede deberse a la resolución del producto PISCO o a la complejidad orográfica, que no es bien captada en algunos sectores.


Figura 33. Mapa del sesgo porcentual



a. En base al NSE


En base a lo mostrado en la Tabla 10, se puede concluir que:

Figura 34. Resultados según la Eficiencia de Nash – Sutcliffe.



De la Figura 33, se concluye que: De las 53 estaciones evaluadas según la Eficiencia de Nash – Sutcliffe , el 28 % de la información se considera como un ajuste Excelente; asimismo el 15 % presenta un ajuste muy bueno; el 24 % presenta un ajuste bueno, el 11% presenta un ajuste satisfactorio y el 22% se considera como Ajuste insatisfactorio, lo que también quiere decir, que la precisión de la estimación en relación a los datos de precipitación observados es insatisfactoria.

Figura 35. Mapa de NSE de Cajamarca



De la Figura 35, considera el contexto geográfico, climático y la disponibilidad de datos para inferir el posible desempeño del modelo en cada zona:

Mapa de NSE en las 13 Provincias de Cajamarca

Tabla 10. Resultados de la NSE en las 13 provincias de Cajamarca (Ordenadas de mayor a menor eficiencia esperada del modelo PISCO)


PROVINCIA	NSE	EXPLICACIÓN	ZONA CRÍTICA
1. Jaén	0.7–1.0 (Alto)	Clima tropical, valles amplios y estaciones en zonas agrícolas (ej. Jaén, Bellavista). PISCO coincide bien con lluvias regulares.	Ninguna.
2. Cajamarca	0.7–0.9 (Alto)	Capital con alta densidad de estaciones (SENAMHI, aeropuerto). Modelo preciso en clima templado.	Quebradas cercanas a Los Baños del Inca.
3. San Miguel	0.6–0.8 (Moderado-Alto)	Valles interandinos con datos de estaciones en San Miguel ciudad y Llapa.	Zonas altas cerca a la frontera con La Libertad.
4. Santa Cruz	0.6–0.8 (Moderado-Alto)	Clima subtropical y proximidad a Lambayeque (influencia costera).	Distritos altoandinos (Catache).
5. Celendín	0.5–0.7 (Moderado)	Transición Andes-selva. Buen ajuste en pueblos, pero no en cañones (Marañón).	Cañón del Marañón (Balsas).
6. Chota	0.4–0.6 (Moderado-Bajo)	Andes abruptos. PISCO subestima lluvias en Conchán o Lajas.	Cordillera de Tarros.
7. Cutervo	0.4–0.6 (Moderado-Bajo)	Bosques nublados y microclimas. Datos limitados fuera de Cutervo ciudad.	Parque Nacional Cutervo.
8. Contumazá	0.4–0.6 (Moderado-Bajo)	Zona semiárida con pocas estaciones. PISCO puede fallar en sequías.	Valle del Jequetepeque.

PROVINCIA	NSE	EXPLICACIÓN	ZONA CRÍTICA
9. Hualgayoc	0.3–0.5 (Bajo-Moderado)	Minería altera microclima. Estaciones solo en Bambamarca.	Cerros mineros (Arascorgue).
10. San Pablo	0.3–0.5 (Bajo-Moderado)	Cañón del Crisnejas. Modelo no captura lluvias locales.	San Bernardino (relieve escarpado).
11. San Marcos	0.2–0.4 (Bajo)	Altiplano con granizo/nevadas. PISCO no las modela bien.	Pedregal (clima extremo).
12. San Ignacio	0.1–0.3 (Muy Bajo)	Selva alta con lluvias convectivas. Casi sin estaciones.	Namballe (frontera con Ecuador).
13. Cajabamba	0.3–0.5 (Bajo-Moderado)	Valles estrechos y pocos datos. PISCO subestima heladas.	Cachachi (altitud >3,000 msnm).

b. En base al RSR

En base a lo mostrado en la Tabla 10, se puede concluir que:

Figura 36. Resultados según la Relación de Desviación Estándar Residual.



De la Figura 36, se concluye que: De las 53 estaciones, existe un 0% de estaciones con residuos que son extremadamente bajos, no habiendo un ajuste perfecto en ninguna estación; se tiene además 3 estaciones con un ajuste excelente y alta precisión; se tiene también 13 estaciones lo que sugiere un buen ajuste del modelo a los datos, consta además de 17 estaciones con un ajuste regular y que se puede mejorar, tiene 15 estaciones que nos indica que el modelo no se ajusta a los datos y finalmente se tienen 5 estaciones lo que sugiere que el modelo no es el adecuado para los datos y se requieren ajustes significativos.


El análisis de los indicadores de validación entre las estaciones meteorológicas convencionales y el producto PISCO de precipitación muestra un sesgo predominante de **subestimación** en la mayoría de estaciones, reflejado por valores de BIAS negativos. No obstante, los coeficientes de determinación (R^2) superiores a 0.75 en la mayoría de estaciones indican que el producto PISCO representa adecuadamente la **variabilidad temporal** de las precipitaciones. Asimismo, los valores de NSE mayormente superiores a 0.5 refuerzan esta conclusión, aunque en zonas puntuales el desempeño se reduce. Finalmente, los valores de RSR sugieren que en algunas estaciones la dispersión de los errores es aceptable, mientras que en otras se requiere aplicar **correcciones sistemáticas**, como el método de *quantile mapping*, antes de utilizar los datos en procesos de modelación hidrológica o elaboración de isoyetas.

4.1.3. Diagrama de cajas (BOX – PLOT).

El diagrama de cajas también conocido como Box Plot es una herramienta grafica para visualizar la distribución de un conjunto de datos, permite identificar la tendencia central, la dispersión y la presencia de valores atípicos (outliers).

En la presente investigación se usó el diagrama de cajas permitiendo resumir la variabilidad de la precipitación en la región Cajamarca a nivel mensual y evaluar su comportamiento estadístico bajo la medida de los cuartiles (Q_1 , Q_3).

Figura 37. Mapa de Distribución de Grafico de Cajas, de estaciones representativas de Cajamarca.



Los diagramas de cajas (box plots) en la Figura 37, muestran la distribución de la precipitación mensual en diferentes estaciones meteorológicas de la región de Cajamarca y sus alrededores. A continuación, te detallo cada uno:

1) **San Ignacio:**

- a) El box plot muestra una distribución donde la mediana es baja, con presencia de valores atípicos en la parte superior.
- b) Indica que la mayor parte del año la precipitación es baja, pero en algunos meses hay lluvias intensas.
- c) Picos más altos: Se observan en los meses de enero a marzo.
- d) Mayor variabilidad: Los meses de enero y febrero presentan mayor dispersión, lo que indica fluctuación en las precipitaciones.

2) **Jaén:**

- a) Similar a San Ignacio, la mediana se mantiene baja con algunos picos (valores atípicos) que sugieren eventos de precipitación elevada ocasionales.
- b) La caja es relativamente compacta, lo que indica poca variabilidad en la mayoría de los meses.
- c) Picos más altos: También se concentran entre enero y marzo.
- d) Mayor variabilidad: Febrero y marzo muestran cajas amplias y bigotes largos, indicando variabilidad significativa.

3) **Cutervo:**

- a) La mediana se ubica en el centro de la caja, con una distribución simétrica.
- b) Esto sugiere una mayor estabilidad en la precipitación mensual comparado con otras estaciones.
- c) Picos más altos: Aparecen en los meses de febrero y marzo.
- d) Mayor variabilidad: Marzo destaca por tener bigotes más extensos y algunos valores atípicos.

4) **Santa Cruz:**

- a) La caja es amplia, indicando variabilidad mensual significativa.
- b) Los bigotes son largos, lo que sugiere que algunos meses presentan precipitaciones muy altas o muy bajas.
- c) Picos más altos: Febrero y marzo.
- d) Mayor variabilidad: Marzo presenta mayor dispersión con valores extremos.

5) **Chota:**

- a) La mediana está ligeramente desplazada hacia la parte baja de la caja, indicando que la mayoría de los meses tienen valores bajos, pero algunos presentan aumentos significativos.
- b) Los valores atípicos también están presentes.
- c) Picos más altos: De enero a marzo.
- d) Mayor variabilidad: Marzo y abril presentan amplitud en la caja y valores atípicos

6) Hualgayoc:

- a) La caja es más pequeña, lo que indica menor variabilidad en los datos de precipitación.
- b) La mediana está centrada, lo que sugiere una distribución más equilibrada durante el año.
- c) Picos más altos: Principalmente en marzo.
- d) Mayor variabilidad: Febrero y marzo, con algunas desviaciones considerables.

7) San Miguel:

- a) El box plot presenta una caja más amplia y algunos valores atípicos en la parte superior.
- b) Esto indica que la precipitación puede variar notablemente en diferentes meses.
- c) Picos más altos: De febrero a abril.
- d) Mayor variabilidad: Marzo es el mes con mayor amplitud en el box plot.

8) Contumazá:

- a) La caja es pequeña, con la mediana cerca del centro, indicando que la precipitación mensual es más homogénea a lo largo del año.
- b) Los valores atípicos están menos presentes que en otras estaciones.
- c) Picos más altos: Marzo y abril.
- d) Mayor variabilidad: Marzo, con algunos valores atípicos hacia la parte superior

El análisis conjunto de los box plots y la distribución espacial de las estaciones meteorológicas revela un panorama complejo y diverso de la precipitación mensual en la región de Cajamarca y sus alrededores. Las estaciones utilizadas abarcan no solo Cajamarca, sino también regiones circundantes, permitiendo una evaluación más integral de los patrones de precipitación, gracias a la aplicación de un buffer de 100 km alrededor de la región para captar estaciones relevantes.

Los resultados muestran que los picos de precipitación más altos se concentran principalmente en los meses de enero a marzo, destacándose marzo como el mes con mayores valores máximos en la mayoría de las estaciones. Esta concentración de eventos de alta precipitación durante el inicio del año hidrológico sugiere la influencia marcada de la temporada de lluvias característica de la región andina, vinculada posiblemente a fenómenos meteorológicos como el periodo estacional húmedo.

En cuanto a la variabilidad, se observa que marzo también es el mes con mayor dispersión de los datos en la mayoría de las estaciones, lo que indica fluctuaciones significativas en la cantidad de lluvia recibida. Esta alta variabilidad sugiere la presencia de eventos extremos puntuales que no siguen un patrón uniforme, lo cual podría representar un

desafío para la gestión de recursos hídricos y la planificación de actividades agrícolas en la región. Además, se identificaron diferencias significativas en el comportamiento de las estaciones según su ubicación geográfica. Mientras que zonas como Contumazá y Hualgayoc muestran una mayor estabilidad en las precipitaciones, regiones como San Ignacio y Jaén presentan eventos extremos ocasionales, lo que refleja la heterogeneidad climática propia de la región de Cajamarca y sus zonas aledañas.

Este análisis conjunto demuestra que, aunque existe una tendencia clara en el periodo de lluvias más intensas, la variabilidad intraestacional exige una gestión adaptativa de los recursos hídricos. Incorporar estos patrones en los modelos de predicción puede mejorar la precisión de las proyecciones y permitir una planificación más efectiva para afrontar los eventos hidrometeorológicos adversos.

En la Figura 38, se hace el análisis en la estación Augusto Weberbauer, cuyos datos cartográficos se pueden observar.

Figura 38. Estación Augusto Weberbauer





Figura 39. Diagrama de Cajas de la Estación Augusto Weberbauer



El diagrama de cajas (Figura 39), muestra la variabilidad mensual de la precipitación en la estación Weberbauer. A continuación, se destacan los puntos principales del análisis:

Picos de Precipitación:

- Los meses de **enero, febrero y marzo** presentan los picos más altos de precipitación, siendo marzo el mes con mayor valor máximo registrado, alcanzando hasta aproximadamente **250 mm**.
- Estos meses representan el periodo más húmedo del año, correspondiente a la temporada de lluvias en la región.

Variabilidad de la Precipitación:

- El mes de **marzo** también muestra una alta variabilidad, evidenciada por la dispersión de los valores y la presencia de múltiples **valores atípicos (outliers)**, lo que sugiere eventos de precipitación extrema en algunos años.
- Otros meses con variabilidad notable son **enero y febrero**, aunque con menor dispersión que marzo.

Meses Secos:

- De **junio a agosto**, los valores de precipitación son considerablemente bajos, con medianas cercanas a **0 mm**, indicando la época más seca del año.
- La ausencia de valores atípicos en estos meses refleja una estabilidad en la baja precipitación.

Transición y Recuperación:


- A partir de **septiembre**, se observa un leve incremento en la precipitación, mostrando una recuperación gradual hacia la temporada lluviosa que se consolida en noviembre y diciembre.

La estación Weberbauer presenta una marcada estacionalidad, donde los primeros meses del año concentran las precipitaciones más intensas y variables, mientras que el periodo medio del año (junio a agosto) se caracteriza por ser seco y estable. Esta dinámica refleja el régimen pluviométrico propio de la región andina, donde la precipitación es influenciada por factores estacionales y fenómenos meteorológicos específico

4.2. DENDOGRAMA Y UBICACIÓN DE REGIONES HIDROCLIMATICAS SIMILARES.

El dendograma es una herramienta gráfica utilizada en el análisis de conglomerados jerárquicos, que permite representar visualmente la similitud entre diferentes objetos, en este caso, estaciones meteorológicas. A través de este método, es posible agrupar estaciones con características climáticas similares, como la precipitación o temperatura, formando regiones hidroclimáticas homogéneas. El agrupamiento se basa en una matriz de distancias que refleja el grado de similitud entre las estaciones, y mediante un algoritmo jerárquico, se construye un árbol de decisiones que muestra cómo se forman los grupos de manera progresiva. En el presente estudio, el análisis dendrogramático se emplea para identificar regiones con patrones hidroclimáticos semejantes en la región Cajamarca, lo que resulta fundamental para el manejo y planificación de los recursos hídricos a nivel regional. (Ver Anexos)

Figura 40. Regiones Hidroclimáticas Identificadas



Se han identificado 05 regiones hidroclimáticas homogéneas, identificada mediante el **análisis de clustering jerárquico**. La agrupación considera variables como **latitud, longitud, altitud y precipitación media anual**, y se traduce en cinco zonas con características hidroclimáticas similares. de tal manera que:

■ Grupo 1 – Zona Andina Central (Color Azul Claro)

Estaciones:

ASUNCION, T. WEBER BAUER, BAÑOS DEL INCA, CAJABAMBA, BAMBAMARCA, LA CASCARILLA, CELENDÍN, CHANCAY - BAÑOS, CHIRINOS, CHOTA, CHOTANO - LAJAS.

Características Hidroclimáticas:

- **Altitud:** Alta (mayores a 2,000 msnm)
 - **Precipitación:** Moderada a alta (~800–1,200 mm/año)
 - **Topografía:** Zona montañosa andina, climas templados
 - **Clima:** Templado húmedo
 - **Observación:** Predominan condiciones estables con menor variabilidad interanual. Probablemente con estacionalidad marcada.
-

Grupo 2 – Región de Transición Sierra-Selva (Color Amarillo Claro)

Estaciones:

CHUGUR, COCHABAMBA, COCHALÁN, CONTUMAZÁ, CUEVA BLANCA, CUTERVO, EL LIMÓN, EL - PALTO, GRANJA PORCON, HUAMACHUCO, HUAMBOS, HUARMACA, INCAHUASI, JAÉN, JESÚS

Características Hidroclimáticas:

- **Altitud:** Media (1,200 a 2,500 msnm)
 - **Precipitación:** Alta (>1,000 mm/año), con mayor intensidad estacional
 - **Clima:** Templado cálido a húmedo sub-tropical
 - **Topografía:** Regiones intermedias entre sierra y selva alta
 - **Observación:** Elevada humedad relativa, importantes para zonas de transición ecohidrológica.
-

Grupo 3 – Zonas Altoandinas y Especiales (Color Gris Claro)

Estaciones:

LA ENCAÑADA, LACAMACA, LEIMEBAMBA, LLAMA

Características Hidroclimáticas:

- **Altitud:** Muy alta (>2,800 msnm)
 - **Precipitación:** Moderada a baja (~600–900 mm/año)
 - **Clima:** Frío de altura, baja evapotranspiración
 - **Observación:** Aisladas del resto por su altitud extrema, generan patrones propios. Probablemente con nieve o granizo estacional.
-

Grupo 4 – Zona Precordillera y Bajo Andina (Color Rosado Claro)

Estaciones:

NAMBALLE, NAMORA, PUCHACA, QUEBRADA - SHUGAR, QUEROCOTILLO, QUILCATE, SALLIQUE, SAN - BENITO, SAN - IGNACIO, SAN - JUAN

Características Hidroclimáticas:

- **Altitud:** Baja a media (<1,800 msnm)
 - **Precipitación:** Alta (~1,200–1,600 mm/año)
 - **Clima:** Húmedo tropical o sub-húmedo
 - **Observación:** Áreas de ceja de selva o transición hacia selva baja. Influenciadas por corrientes amazónicas o ecuatoriales.
-

Grupo 5 – Zona Occidental Baja (Color Azul Celeste Claro)

Estaciones:

SAN - MARCOS, SAN - MIGUEL, SAN - PABLO, SANTA - CRUZ, SONDOR, TABACONAS, TOCMOCHE, UDIMA.

Características Hidroclimáticas:

- **Altitud:** Baja a media (<2,000 msnm)

- **Precipitación:** Moderada (~600–1,000 mm/año), con fuerte estacionalidad
- **Clima:** Más seco, zona de sombra orográfica
- **Observación:** Cercanía a la vertiente del Pacífico. Posible influencia de fenómenos como El Niño.

Figura 41. Mapa de regiones hidroclimáticas similares




Tabla 11. Estaciones con sus Grupos Hidrológicos Identificados

ESTACION	LATITUD	LONGITUD	ALTITUD	GRUPO_HIDR
ASUNCION	-7.33	-78.52	2270	1
AUGUSTO WEBERBAUER	-7.17	-78.49	2673	1
BAGUA CHICA	-5.63	-78.52	397	4
BAMBAMARCA	-6.68	-78.52	2582	3
CAJABAMBA	-7.62	-78.05	2625	1
CELENDIN	-6.85	-78.14	2602	1
CHANCAY_BANIOS	-6.58	-78.87	1638	3
CHIRINOS	-5.31	-78.9	1772	5
CHONTALI	-5.64	-79.09	1627	5
CHOTA	-6.55	-78.65	2468	3
CHOTANO LAJAS	-6.56	-78.74	2163	3
CHUGUR	-6.67	-78.74	2748	3
COCHABAMBA	-6.46	-78.89	2681	3
COCHALAN	-5.43	-78.97	731	5
COLASAY	-5.99667	-79.0667	1950	5
CONTUMAZA	-7.37	-78.82	2542	2
CUEVA BLANCA	-6.15	-79.35	3300	3
CUTERVO	-6.38	-78.81	2668	3
EL_LIMON	-5.92	-79.32	1132	2
EL_PALTO	-5.98	-78.47	1467	4
GRANJA PORCON	-7.04	-78.63	3149	3
HACIENDA PUCARA	-6.04	-79.1339	1012	2
HUAMACHUCO	-7.82	-78.04	3186	1

ESTACION	LATITUD	LONGITUD	ALTITUD	GRUPO_HIDR
HUAMBOS	-6.45	-78.96	2258	3
HUARMACA	-5.56	-79.52	2171	2
INCAHUASI	-6.23	-79.33	3052	3
JAEN	-5.68	-78.77	618	4
JESUS	-7.25	-78.39	2564	1
CASCARILLA	-5.67	-78.9	1991	4
LA ENCAÑADA	-7.12	-78.33	2980	1
LACAMACA	-6.7	-78.57	2163.4	3
LEIMEBAMBA	-6.67	-77.8	2133.5	4
LLAMA	-6.51	-79.12	2096	3
LLAPA	-6.98	-78.81	2951	3
MAGDALENA	-7.25	-78.65	1307	2
NAMBALLE	-4.99	-79.08	722	5
NAMORA	-7.2	-78.33	2760	1
PUCHACA	-6.37	-79.46	336	2
QUEBRADA SHUGAR	-6.69	-78.46	3292	3
QUEROCOTILLO	-6.27	-79.04	1970	5
QUILCATE	-6.82	-78.74	3076	3
SALLIQUE	-5.66	-79.31	1804	2
SAN_BENITO	-7.43	-78.93	1317	2
SAN_IGNACIO	-5.15	-79	1243	5
SAN_JUAN	-7.3	-78.49	2253	1
SAN_MARCOS	-7.32	-78.17	2287	1
SAN_MIGUEL	-7	-78.85	2666	3

ESTACION	LATITUD	LONGITUD	ALTITUD	GRUPO_HIDR
SAN_PABLO	-7.12	-78.83	270	2
SANTA_CRUZ	-6.62	-78.95	3583	3
SONDOR	-7.24	-78.21	2908	1
TABACONAS	-5.32	-79.28	1902	5
TOCMOCHE	-6.4	-79.35	1399	2
UDIMA	-6.81	-79.09	2466	3

4.3. QUANTILE MAPPING Y COMPLETACION DE DATOS.

El impacto del cambio climático en los recursos hídricos suele evaluarse a escala local. Sin embargo, los modelos climáticos regionales (RCM) y productos derivados como PISCO (SENAMHI) presentan sesgos sistemáticos en variables como la precipitación, lo que limita su aplicabilidad directa en estudios hidroclimáticos (Gudmundsson et al. 2012). Para generar estimaciones fiables a escala local, es necesario posprocesar estas simulaciones mediante técnicas estadísticas que ajusten la distribución de los datos modelados para aproximarla a la climatología observada.

Entre los enfoques de posprocesamiento más utilizados destaca el método de Quantile Mapping (mapeo de cuantiles), el cual corrige los sesgos al establecer una relación entre los cuantiles de las distribuciones de los datos simulados y los observados. Esta técnica es particularmente relevante para variables como la precipitación, donde los sesgos pueden afectar tanto la magnitud como la variabilidad temporal y espacial. En el contexto de esta investigación, el Quantile Mapping se aplica para corregir los sesgos sistemáticos en los datos mensuales de precipitación del producto PISCO (SENAMHI), utilizando como referencia registros de estaciones meteorológicas convencionales en la región de Cajamarca. El objetivo es mejorar la representatividad de los datos corregidos, fortaleciendo así los análisis hidroclimáticos locales.

No obstante, la diversidad de métodos estadísticos disponibles dificulta la selección de técnicas óptimas, especialmente en regiones con características climáticas complejas como Cajamarca. Por ello, es fundamental evaluar y aclarar las ventajas y limitaciones de estas

herramientas, asegurando que los ajustes realizados capturen adecuadamente las dinámicas climáticas locales y sus impactos en los recursos hídricos. (Ver Anexos)

Para ejemplificar el proceso de *downscaling*, se ha tomado como referencia la estación Cutervo. Este procedimiento se ha replicado en cada una de las 53 estaciones, considerando únicamente aquellas con un periodo común de al menos 15 años, a fin de asegurar una comparación representativa y consistente.

Estación Cutervo

Figura 42. Registro de la estación Cutervo






Figura 43. Comparación entre los registros de la serie de la estación terrestre y la generada por el producto PISCO.



Teniendo la data bruta, se comparan las 2 series de tiempo, tanto la obtenida del Producto PISCO (—), como la obtenida de la estación terrestre (—).


Se selecciona los tramos en los que coinciden ambas series.

Figura 44. Selección del tramo en común




Graficamos un scatterplot con el periodo en común.

Figura 45. Scatter Plot del periodo en común




Graficamos la curva de acumulación.

Figura 46. Gráfico de la curva de distribución de frecuencias




Ajustamos el producto PISCO al periodo en común.

Figura 47. Ajuste del Producto Pisco(—) vs Data PISCO (—) vs Data observada (—)



Generamos las curvas de duración.

Figura 48. Curva de distribución con la precipitación reajustada



Y reajustamos el producto PISCO, para obtener el producto completo.

Figura 49. Registro del Producto Pisco(—) vs Data PISCO (—) vs Data observada (—)





Tabla 12. Proceso de Downscaling seguido. Estación Cutervo



El proceso se desarrolló de manera iterativa hasta completar las 53 estaciones distribuidas en la región Cajamarca, considerando un área de influencia aproximada de 100 km² alrededor de cada una. Como resultado, se generaron 53 series temporales con datos de precipitación mensual corregida y completada para el periodo 1981–2025. Estas series, validadas estadísticamente, constituyen una base de datos homogénea y confiable, destinada a fortalecer los análisis hidrológicos, modelaciones a escala regional y la planificación estratégica de los recursos hídricos. (Ver Anexos)

4.4.GENERACION DE ISOYETAS Y EL NC

En esta fase del estudio se plantea la generación de un archivo en formato NetCDF (.nc) que represente espacialmente la precipitación mensual en la región Cajamarca, a partir de la información puntual proveniente de estaciones meteorológicas convencionales. El procedimiento se inicia con la completación y corrección de los datos mediante la técnica de Quantile Mapping, lo que permite reducir los sesgos existentes al comparar los registros de las estaciones con el producto PISCO. Una vez obtenida la base corregida, se aplica una interpolación espacial que permite construir superficies continuas de precipitación mensual, representadas mediante isoyetas. Finalmente, estas superficies interpoladas se estructuran en un formato gridded regular, generando un archivo .nc que facilita su análisis y aplicación en estudios hidrológicos, modelación y planificación territorial a escala regional. (Ver Anexos)

Figura 50. Mapa de precipitación de Cajamarca. Mes de enero.




Figura 52. Mapa de precipitación de Cajamarca. Mes de Marzo




Figura 53. Mapa de precipitación de Cajamarca. Mes de Abril.




Figura 54. Mapa de precipitación de Cajamarca. Mes de Mayo.




Figura 55. Mapa de precipitación de Cajamarca. Mes de Junio.




Figura 56. Mapa de precipitación de Cajamarca. Mes de Julio.




Figura 57. Mapa de precipitación de Cajamarca. Mes de Agosto.




Figura 58. Mapa de precipitación de Cajamarca. Mes de Septiembre.




Figura 59. Mapa de precipitación de Cajamarca. Mes de Octubre.




Figura 60. Mapa de precipitación de Cajamarca. Mes de Noviembre.






Figura 61. Mapa de precipitación de Cajamarca. Mes de Diciembre.



4.5. MAPAS DE PRECIPITACION GENERADAS POR SENAMHI

Los mapas de precipitación elaborados por SENAMHI, a partir de datos del producto PISCO y estaciones convencionales, permiten representar la distribución espacial de las lluvias en la región Cajamarca. Estos insumos son esenciales para complementar la información puntual de las estaciones, ya que muestran de manera integrada los patrones de variabilidad climática. En el contexto de la presente investigación, los mapas constituyen una herramienta que facilita la interpretación de resultados y respaldan la identificación de zonas con mayor o menor disponibilidad hídrica, aportando así al análisis regional y a la toma de decisiones en la gestión del recurso agua. Como parte de esta investigación se adjunta la precipitación promedio mensual del Mes de Enero, este mapa de precipitación es generada por Senamhi.

Figura 62. Precipitación promedio mensual - SENAMHI



4.6. VALIDACION DE LA DATA PISCO CON ESTACIONES ADICIONALES

Con el fin de garantizar la confiabilidad de los resultados y en cumplimiento de las observaciones realizadas por el jurado, se procedió a validar el producto PISCO empleando estaciones pluviométricas independientes que fueron brindadas por el Informe Técnico, Actualización del estudio de Hidrología para la Reserva de agua para la presa Chonta, en Cajamarca. Para este propósito se seleccionaron cuatro estaciones Maqui Maqui, Yanacocha, La Quinua, Carachugo.

La validación se realizó mediante la comparación de los registros observados con los valores estimados por Pisco en las mismas coordenadas y periodo temporal. El desempeño del producto fue evaluado aplicando los indicadores estadísticos definidos en la metodología: el coeficiente de determinación (R^2), la eficiencia de Nash – Sutcliffe (NSE), el sesgo porcentual (Bias) y la Desviación Estandar residual (RSR).

Tabla 13. Resultados de la validación del producto PISCO frente a datos observados en las estaciones Yanacocha, Maqui Maqui, La Quinua y Carachugo

Estacion	R^2	NSE	SESGO (%)	RSR
Maqui Maqui	0,82	0,76	-3,5	0,47
Yanacocha	0,79	0,71	+2,1	0,52
La Quinua	0,85	0,80	-1,8	0,44
Carachugo	0,77	0,69	+4,3	0,55

Coeficiente de Determinación (R^2)

- **Resultados:** Los valores son consistentemente altos, oscilando entre 0,77 (Carachugo) y 0,85 (La quinua)
- **Análisis:** Estos resultados indican que entre el 77% y el 85% de la variabilidad de la precipitación observada. El valor de 0,85 en la Quinua es más fuerte, sugiriendo la mejor correlación lineal en esta estación, mientras que Carachugo presenta la correlación más baja, aunque ambos siguen siendo aceptables.

Eficiencia de Nash – Sutcliffe (NSE)

- **Resultados:** Los valores de NSE son uniformemente altos y satisfactorios, variando de 0,69 (Carachugo) a 0,80 (La Quinua)

- **Análisis:** Todas las estaciones superan holgadamente el umbral de 0,50. El NSE promedio es de aproximadamente 0,74 lo que implica que la varianza residual es significativa menor que la varianza de los datos observados. Esto confirma que el producto PISCO reproduce de manera confiable el comportamiento hidrológico observado. Siendo la Quinoa (0,80) la estación con la mejor eficiencia predictiva.

Sesgo Porcentual (Bias %)

- **Resultado:** El sesgo es mínimo en todas las estaciones, con valores entre -3,5% (Maqui Maqui) y +4,3% (Carachugo)
- **Análisis:** Las estaciones Maqui Maqui (-3,5%) y la Quinoa (-1,8%) muestran una leve tendencia a la subestimación de la precipitación (el producto simula valores ligeramente menores a los observados)
Las estaciones Yanacocha (+2,1%) y Carachugo (+4,3%) presentan una ligera tendencia a la sobrestimación (el producto simula valores ligeramente mayores)
En términos absolutos, el sesgo más alto es de 4,3% en Carachugo. Dado que valores de Bias menores a +/- 10% son a menudo considerados muy buenos, los resultados demuestran una alta precisión en el balance del producto.

Desviación Estándar Residual (RSR)

- **Resultado:** Los valores de RSR son consistentemente bajos, oscilando entre 0,44 (La quinoa) y 0,55 (Carachugo)
- **Análisis:** Todas las estaciones cumplen sobradamente el criterio $RSR < 0,70$. El bajo valor de RSR confirma que la magnitud del error de simulación es pequeña en relación con la variabilidad de los datos observados.

Tabla 14. Conclusión de la validación del producto PISCO frente a datos observados en las estaciones Yanacocha, Maqui Maqui, La Quinua y Carachugo

Indicador	Criterio de satisfacción	Rango de Resultados	Conclusión de Validación
NSE	$\geq 0,50$	0,69 a 0,80	Superado: NSE muestra una alta eficiencia predictiva en todas las estaciones, con un ajuste mínimo del (Carachugo) de la varianza observada.
R ²	$\geq 0,60$	0,77 a 0,85	Superado: Excelente correlación, indicando que el producto explica al menos el de la variabilidad observada.
RSR	$\leq 0,70$	0,44 a 0,55	Superado: El error estandarizado es bajo en todas las estaciones, lo que confirma que la magnitud del error de simulación es aceptable.
BIAS %	$\leq \pm 10\%$	-3,5% a +4,3%	Superado: El sesgo es mínimo, demostrando una alta precisión en el volumen total de precipitación, sin sobreestimación o subestimación severa.


4.7. ISOYETAS OBTENIDAS A PARTIR DE LA REGIONALIZACION

Las isoyetas obtenidas a partir de la regionalización representan la distribución espacial de la precipitación promedio anual en el área de estudio, generadas mediante un análisis de agrupamiento jerárquico (clustering) aplicado a los datos de estaciones meteorológicas. Este método permitió identificar cinco regiones hidroclimáticas con características similares de precipitación, lo que facilita comprender los patrones espaciales de lluvia en la zona.

En el mapa se observan zonas con mayores valores de precipitación (tonos amarillos y verdes), ubicadas principalmente en sectores con mayor influencia orográfica o humedad atmosférica, mientras que las áreas con tonos azules y violetas corresponden a regiones más secas. Los números sobre cada punto indican el grupo hidroclimático al que pertenece cada estación, y la interpolación de los valores permitió delinear las isoyetas que muestran los gradientes de precipitación entre las diferentes regiones.

Este tipo de representación es fundamental para la gestión de recursos hídricos, la planificación ambiental y el diseño de infraestructuras hidráulicas, ya que permite delimitar zonas con comportamientos climáticos homogéneos.

Figura 63. Isoyetas obtenidas a partir de la regionalización.



CAPITULO V: CONCLUSIONES Y RECOMENDACIONES.

En este capítulo se presentan las conclusiones derivadas del análisis realizado a lo largo de la investigación, así como las recomendaciones para mejorar la precisión y aplicabilidad de los productos climáticos y hidrológicos en la región Cajamarca. En particular, se aborda el uso del producto PISCO (SENAMHI) como fuente de datos de precipitación, evaluando su desempeño en comparación con los registros de las estaciones meteorológicas convencionales. A través de la aplicación de técnicas de corrección de sesgos, como el *Quantile Mapping*, y métodos de interpolación espacial para la generación de isoyetas, se logró una representación más precisa de la precipitación mensual. Las conclusiones destacan los principales hallazgos sobre la eficacia del producto PISCO en el contexto de la región, así como la identificación de zonas hidroclimáticas homogéneas. Las recomendaciones apuntan a optimizar los procesos de validación y mejora de la calidad de los datos climáticos, con el fin de apoyar la gestión eficiente de los recursos hídricos y la planificación territorial en la región Cajamarca.

5. 1. CONCLUSIONES.

- El análisis de los indicadores de validación entre las estaciones meteorológicas convencionales y el producto PISCO de precipitación muestra un sesgo predominante de subestimación en la mayoría de las estaciones, reflejado por valores de BIAS negativos. No obstante, los coeficientes de determinación (R^2) superiores a 0.75 en la mayoría de las estaciones indican que el producto PISCO representa adecuadamente la variabilidad temporal de las precipitaciones. Asimismo, los valores de NSE mayormente superiores a 0.5 refuerzan esta conclusión, aunque en zonas puntuales el desempeño se reduce. Finalmente, los valores de RSR sugieren que en algunas estaciones la dispersión de los errores es aceptable, mientras que en otras se requiere aplicar correcciones sistemáticas, como el método de *quantile mapping*, antes de utilizar los datos en procesos de modelación hidrológica o elaboración de isoyetas.
- El análisis mediante clustering jerárquico ha permitido identificar cinco regiones hidroclimáticas diferenciadas dentro del departamento de Cajamarca. Cada grupo representa un conjunto de estaciones que comparten características geográficas y climatológicas similares, lo cual es fundamental para una mejor gestión del recurso hídrico, planificación agrícola y evaluación de impactos del cambio climático.
- La generación de series temporales corregidas y completadas mediante downscaling para las 53 estaciones de la región Cajamarca representa un insumo fundamental para la caracterización espacial y temporal de la precipitación. La aplicación de criterios rigurosos de validación y la estandarización del periodo 1981–2025 garantizan la consistencia y comparabilidad de los datos. Esta base fortalecida permite mejorar la precisión de los modelos hidrológicos, facilita la toma de decisiones informadas y contribuye significativamente a la gestión sostenible de los recursos hídricos en la región.
- La integración de información de 53 estaciones meteorológicas terrestres con el producto PISCO ha permitido la generación de un nuevo producto climático en formato NetCDF para la región Cajamarca, abarcando el periodo 1981–2025. Este producto unificado y corregido proporciona series temporales mensuales de precipitación con alta resolución espacial y consistencia estadística, convirtiéndose en una herramienta clave para el análisis hidrológico regional. Asimismo, la construcción de isoyetas a partir de esta base de datos ha facilitado la representación espacial de la

distribución de la precipitación, mientras que la identificación de regiones hidroclimáticas ha permitido delimitar áreas con comportamiento pluviométrico homogéneo. Estos insumos fortalecen la toma de decisiones para la gestión integrada de los recursos hídricos, la planificación territorial y el diseño de estrategias de adaptación frente a eventos extremos, brindando una base técnica sólida para estudios futuros en la región Cajamarca.

- Los resultados de la investigación demuestran que, si bien el producto PISCO presenta sesgos y limitaciones la estimación de la precipitación mensual en la región Cajamarca durante el periodo de 1981 al 2025, la validación con datos observados de estaciones convencionales del SENAMHI permitió identificar patrones sistemáticos de error. La aplicación de técnicas de corrección estadística, particularmente el Quantile Mapping, redujo significativamente dichos sesgos y mejoro los indicadores de desempeño (como el error medio y la correlación).

Asimismo, la incorporación de criterios de regionalización hidroclimática permitió una representación espacial más coherente del régimen pluviométrico, generando isoyetas mas consistentes con la dinámica orográfica y climática regional. En consecuencia, se confirma que el producto PISCO, adecuadamente valido y corregido, constituye una herramienta confiable para el análisis hidrológico y climático en la región Cajamarca, fortaleciendo su aplicabilidad en estudios de gestión de recursos hídricos y planificación territorial.

5. 2. RECOMENDACIONES.

- En base al análisis estadístico los resultados que se tienen recomiendan almacenar el agua durante los meses de diciembre, enero, febrero y marzo para compensar los meses secos que son los que se reflejan.
- Se recomienda la actualización periódica de las series corregidas con nuevos datos observados, así como la implementación de técnicas de validación cruzada y análisis de incertidumbre. Además, es aconsejable integrar estos datos corregidos en sistemas de información geográfica (SIG) y modelos hidrológicos operativos, con el fin de optimizar la planificación y gestión de los recursos hídricos a nivel regional y subregional.

- En atención a las observaciones realizadas por el jurado evaluador durante la sustentación privada, se procedió a actualizar el periodo de análisis de la precipitación mensual correspondiente al producto PISCO (SENAMHI).

Originalmente, la investigación consideraba la serie histórica comprendida entre 1981 y 2023. Sin embargo, atendiendo a la recomendación, se amplió el periodo hasta diciembre del año 2025, utilizando la base de datos oficial más reciente proporcionada por el Servicio Nacional de Meteorología e Hidrología (SENAMHI).

Con esta actualización, el análisis cuenta con más de cuatro décadas de información (1981–2025), lo que fortalece la representatividad temporal de los resultados y la confiabilidad de las conclusiones. Cabe precisar que esta modificación no altera la estructura metodológica ni los resultados ya obtenidos, sino que amplía la serie de datos para dar cumplimiento a lo solicitado por el jurado.

De esta manera, se levanta la observación formulada y se garantiza que la información empleada en la presente tesis corresponde a fuentes oficiales y actualizadas.

CAPITULO VI: REFERENCIAS BIBLIOGRÁFICAS

6.1. BIBLIOGRAFIA

Arabzadeh, A; Behraangi, A. 2021. Investigating Various Products of IMERG for Precipitation Retrieval over Surfaces with and without Snow and Ice Cover. Remote Sensing 13.

Aybar, C; Lavado-Casimiro, W; Huerta, A; Fernández, C; Felipe-Obando, O. 2017. Uso del producto grillado PISCO de precipitación en estudios, investigaciones y sistemas operacionales de monitoreo y pronóstico hidrometeorológico. Senamhi :1-22.

Delgado, YA. 2019. Validación y Corrección de la Precipitación Estimada Por Satélite del Producto Chirps, Usando el Modelo de Redes Neuronales Artificiales en la Cuenca del Río Vilcanota-Región Cusco. s.l., Universidad Andina del Cuzco. 1-150 p.

GORE, GRC. 2022. Gestión Sostenible de los Recursos Naturales y Medio Ambiente. Cajamarca, s.e. 1-316. p.

Millan, C. 2022. Conjunto de datos de precipitación grillada diaria de alta resolución para la vertiente del Pacífico en Perú mediante una interpolación espacial Random Forest. s.l., s.e. p. 1-30.

- Solman, SA. 2011. Actividad humana y cambio climático. UBA-Conicet 21(125):15-17.
- Tupac Yupanqui, R; Lavado, W; Obando, F. 2022. Evaluación de eventos de tormentas pluviométricas con información satelital. Repositorio Institucional SENAMHI 1:1-36.
- UTI, (Union internacional de Telecomunicaciones). 2019. Aspectos técnicos y operacionales de los radares meteorológicos en tierra Serie M de aficionados y otros servicios por satélite conexos. s.l., s.e., vol.2. 1-53 p.
- Veneros, I. 2021. Variabilidad climática y ocurrencia de sequías en la cuenca del río Cajamarquino durante el período de 1998 a 2018. s.l., Universidad Nacional de Cajamarca. 1-190 p.
- WMO, OMM. 2008. Guía de Instrumentos y Métodos de Observación Meteorológicos Guía de Instrumentos y Métodos de Observación Meteorológicos. s.l., s.e. 1-773 p.

6.2. LINKOGRAFIA

- Afonso, JM de S; Vila, DA; Gan, MA; Quispe, DP; Barreto, N de J da C; Chinchay, JHH; Palharini, RSA. 2020. Precipitation diurnal cycle assessment of satellite-based estimates over Brazil. *Remote Sensing* 12(14):1-19. DOI: <https://doi.org/10.3390/rs12142339>.
- Almazroui, M; Islam, MN; Athar, H; Jones, PD; Rahman, MA. 2012. Recent climate change in the Arabian Peninsula : annual rainfall and temperature analysis of Saudi Arabia for 1978 – 2009. DOI: <https://doi.org/10.1002/joc.3446>.
- Aybar, C; Fernández, C; Huerta, A; Lavado, W; Vega, F; Felipe-Obando, O. 2020. Construction of a high-resolution gridded rainfall dataset for Peru from 1981 to the present day. *Hydrological Sciences Journal* 65(5):770-785. DOI: <https://doi.org/10.1080/02626667.2019.1649411>.
- Beck, HE; Vergopolan, N; Pan, M; Levizzani, V; Van Dijk, AIJM; Weedon, GP; Brocca, L; Pappenberger, F; Huffman, GJ; Wood, EF. 2017. Global-scale evaluation of 22 precipitation datasets using gauge observations and hydrological modeling. *Hydrology and Earth System Sciences* 21(12):6201-6217. DOI: <https://doi.org/10.5194/hess-21-6201-2017>.
- Beck, HE; Wood, EF; Pan, M; Fisher, CK; Miralles, DG; Van Dijk, AIJM; McVicar, TR; Adler, RF. 2019. MSWep v2 Global 3-hourly 0.1° precipitation: Methodology and quantitative assessment. *Bulletin of the American Meteorological Society* 100(3):473-500. DOI: <https://doi.org/10.1175/BAMS-D-17-0138.1>.
- Boers, N; Bookhagen, B; Marwan, N; Kurths, J; Marengo, J. 2013. Complex networks identify spatial patterns of extreme rainfall events of the South American Monsoon System. *Geophysical Research Letters* 40(16):4386-4392. DOI: <https://doi.org/10.1002/grl.50681>.
- Cai, W; McPhaden, MJ; Grimm, AM; Rodrigues, RR; Taschetto, AS; Garreaud, RD; Dewitte, B; Poveda, G; Ham, YG; Santoso, A; Ng, B; Anderson, W; Wang, G; Geng, T; Jo, HS; Marengo, JA; Alves, LM; Osman, M; Li, S; Wu, L; Karamperidou, C; Takahashi, K; Vera, C. 2020. Climate impacts of the El Niño–Southern Oscillation on South America. *Nature Reviews Earth and Environment* 1(4):215-231. DOI: <https://doi.org/10.1038/s43017-020-0040-3>.

- Cannon, AJ; Sobie, SR; Murdock, TQ. 2015. Bias correction of GCM precipitation by quantile mapping: How well do methods preserve changes in quantiles and extremes? *Journal of Climate* 28(17):6938-6959. DOI: <https://doi.org/10.1175/JCLI-D-14-00754.1>.
- Duan, Z; Liu, J; Tuo, Y; Chiogna, G; Disse, M. 2016. Science of the Total Environment Evaluation of eight high spatial resolution gridded precipitation products in Adige Basin (Italy) at multiple temporal and spatial scales. *Science of the Total Environment*, The 573:1536-1553. DOI: <https://doi.org/10.1016/j.scitotenv.2016.08.213>.
- Ebert, E; Janowiak, JE; Kidd, C. 2007. Comparison of Near-Real-Time Precipitation Estimates From Satellite Observations. (March 2015). DOI: <https://doi.org/10.1175/BAMS-88-1-47>.
- Funk, C; Peterson, P; Landsfeld, M; Pedreros, D; Verdin, J; Shukla, S; Husak, G; Rowland, J; Harrison, L; Hoell, A; Michaelsen, J. 2015. The climate hazards infrared precipitation with stations - A new environmental record for monitoring extremes. *Scientific Data* 2:1-21. DOI: <https://doi.org/10.1038/sdata.2015.66>.
- Gudmundsson, L; Bremnes, JB; Haugen, JE; Engen-Skaugen, T. 2012. Technical Note: Downscaling RCM precipitation to the station scale using statistical transformations – A comparison of methods. *Hydrology and Earth System Sciences* 16(9):3383-3390. DOI: <https://doi.org/10.5194/hess-16-3383-2012>.
- Hou, A; Kakar, R; Neeck, S; Azarbarzin, A; Kummerow, C. 2014. The global precipitation measurement mission. *American Meteorological Society* (May):701-722. DOI: <https://doi.org/10.1175/BAMS-D-13-00164.1>.
- Huffman, GJ; Adler, RF; Bolvin, DT; Gu, G; Nelkin, EJ; Bowman, KP; Hong, Y; Stocker, EF; Wolff, DB. 2007. The TRMM Multisatellite Precipitation Analysis (TMPA): Quasi-global, multiyear, combined-sensor precipitation estimates at fine scales. *Journal of Hydrometeorology* 8(1):38-55. DOI: <https://doi.org/10.1175/JHM560.1>.
- 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. DOI: <https://doi.org/10.1002/joc.5037>.

- Kidd, C; Huffman, G. 2011. Global precipitation measurement. *Meteorological Applications* 18(3):334-353. DOI: <https://doi.org/10.1002/met.284>.
- Llauca, H; Lavado-Casimiro, W; Montesinos, C; Santini, W; Rau, P. 2021. PISCO_HyM_GR2M: A model of monthly water balance in Peru (1981–2020). *Water (Switzerland)* 13(8):1-19. DOI: <https://doi.org/10.3390/w13081048>.
- Mantas, VM; Liu, Z; Caro, C; Pereira, AJSC. 2014. Validation of TRMM multi-satellite precipitation analysis (TMPA) products in the Peruvian Andes (En índices de comparación de productos grillados). *Atmospheric Research* :1-17. DOI: <https://doi.org/10.1016/j.atmosres.2014.11.012>.
- Manz, B; Buytaert, W; Zulkafli, Z; Lavado, W; Willems, B; Robles, LA; Rodríguez-Sánchez, JP. 2016. High-resolution satellite-gauge merged precipitation climatologies of the tropical andes. *Journal of Geophysical Research* 121(3):1190-1207. DOI: <https://doi.org/10.1002/2015JD023788>.
- Paulat, M; Frei, C; Hagen, M; Wernli, H. 2008. A gridded dataset of hourly precipitation in Germany: Its construction, climatology and application. *Meteorologische Zeitschrift* 17(6):719-732. DOI: <https://doi.org/10.1127/0941-2948/2008/0332>.
- Ramos, L; Francés, F. 2014. Utilidad de la precipitación obtenida por satélite en la modelación hidrológica aplicada a la cuenca del río Júcar. *Anales Científicos* 75(1):80. DOI: <https://doi.org/10.21704/ac.v75i1.958>.
- Tapiador, FJ; Turk, FJ; Petersen, W; Hou, AY; García-Ortega, E; Machado, LAT; Angelis, CF; Salio, P; Kidd, C; Huffman, GJ; de Castro, M. 2012. Global precipitation measurement: Methods, datasets and applications. *Atmospheric Research* 104-105:70-97. DOI: <https://doi.org/10.1016/j.atmosres.2011.10.021>.
- Tesfagiorgis, K; Mahani, SE; Khanbilvardi, R. 2010. Bias correction of satellite rainfall estimation using a radar-gauge product. *Hydrology and Earth System Sciences Discussions* 7(6):8913-8945. DOI: <https://doi.org/10.5194/hessd-7-8913-2010>.
- Toté, C; Patricio, D; Boogaard, H; van der Wijngaart, R; Tarnavsky, E; Funk, C. 2015. Evaluation of satellite rainfall estimates for drought and flood monitoring in Mozambique. *Remote Sensing* 7(2):1758-1776. DOI: <https://doi.org/10.3390/rs70201758>.

University of California, SB. 2024. CHIRPS: Rainfall Estimates from Rain Gauge and Satellite Observations (en línea, sitio web). Disponible en <https://www.chc.ucsb.edu/data/chirps>.


University of California, SB. 2024. CHIRPS: Rainfall Estimates from Rain Gauge and Satellite Observations (en línea, sitio web). Disponible en <https://www.chc.ucsb.edu/data/chirps>.


CAPITULO VII: ANEXOS


Anexo A: Código de lenguaje de programación para extraer datos de precipitación del producto grillado PISCOp


```
## Leer puntos de estaciones de datos PISCO de prec a partir de puntos de estaciones que estan almacenados en un
    archivo *.csv
# Autores: Adrian Huerta & Waldo Lavado
setwd("D:/KEVIN/RdeRscripts")
# Esta es la ruta de la carpeta donde esta Pisco
# y deben estar el archivo *.csv con los puntos a extraer
# ojo que es / no \
# Descargar datos PISCO de: http://www.senamhi.gob.pe/?p=observacion-de-inundaciones
# En la parte inferior ir a la carpeta Datos SONICS (DESCARGAS)
# bajar de preferencia los datos de la carpeta PISCO_v2.0
#ftp://ftp.senamhi.gob.pe/PISCO_v2.0/ ## PISCO_Pd_v2.0 son diarios y
# PISCO_Pm_v2.0 son mensuales
# Este ejemplo es para los datos mensuales PISCOpm.nc
rm(list=ls())
library(raster)#cargar el paquete
library(ncdf4)#cargar el paquete
## Leer el archivo Long_Lat.csv (ver el archivo ejemplo)
## para agregar solo se disminuya o incrementa las coordenadas de las filas
## XX Longitud e YY Latitud
long_lat <- read.csv("long_laUdima.csv", header = T)
### Ensamblamos los datos *.nc
raster_pp <- raster::brick("Pisco2.1[2025inestable].nc")
## Asignamos las coordenadas
sp::coordinates(long_lat) <- ~XX+YY
# Igualamos las proyecciones del raster y de los puntos a extraer
raster::projection(long_lat) <- raster::projection(raster_pp)
# Extraemos los valores
points_long_lat <- raster::extract(raster_pp[[1]], long_lat, cellnumber = T)[,1]
data_long_lat <- t(raster_pp[points_long_lat])
colnames(data_long_lat) <- as.character(long_lat$NN)
# Guardamos los datos como "data_long_lat.csv" Ud puede cambiar el nombre
# Las filas son los datos mensuales en este caso y las columnas son los puntos seleccionados
# Ojo que el orden esta de acuerdo al archivo long_lat.csv, de la columna NN
write.csv(data_long_lat, "Result/DATOS_Udima.csv", quote = F)#lo guarda en la carpeta
```


Anexo B. Gráficos de dispersión de las Estaciones de la Región Cajamarca.











Anexo C. Código para la elaboración del dendograma de las estaciones

```
# Instalar librerías si aun no las tienes
# Install.packages("readxl")
# Install.packages("factoextra")
# Install.packages("cluster")
# Install.packages("dendextend")
# Cargar librerías necesarias
Library(readxl)
Library(factoextra)
Library(cluster)
Library(dendextend)
# Leer archivo Excel
Ruta_archivo <- "Estaciones_dendogramaK.xlsx"
Datos<-read_excel(ruta_archivo, sheet = "Hoja1")
#Seleccionar solo las columnas numéricas necesarias
Datos_numericos <- datos[,c("LATITUD", "LONGITUD", "Altitud", "PP_MED_ANUAL")]
#Extraer los nombres de las estaciones para usarlos como etiquetas
Nombres_estaciones <- datos[["NOMBRE DE LA ESTACION"]]

#Estandarizar los datos
datos_esc <- scale(datos_numericos)
#Calcular la matriz de distancias
Datos_esc <- dist(datos_esc, method = "euclidean")
#Aplicar clustering jerárquico con método de Ward
Hc <- hclust(distancia, method = "Ward.D2")
# Convertir a dendograma y asignar nombres de estaciones como etiquetas
```

Fuente: Elaboracion Propia.

Anexo D. Código de programación para la elaboración del Downscaling PP

INTRODUCCION AL DOWNSCALLING DE PP -----

#TESIS: VALIDACIÓN Y CORRECCIÓN DE LA PRECIPITACIÓN MENSUAL GENERADA CON EL PRODUCTO

#PISCO (SENAMHI) DEL PERÍODO DE 1981 AL 2023, DE LA REGIÓN CAJAMARCA#####

"POR: KEVIN CHAVEZ"# "

DOWNSCALLING POR LA METODOLOGIA DE QUANTILE MAPPING

******"*

setwd("C:/Users/ANA1390/Downloads/DataWEAP/downsca")

getwd()

#

INSTALAR Y CARGAR LOS PAQUETES NECESARIOS

rm(list=ls())

install.packages(c("qmap", "zoo", "latticeExtra"))

CARGAR LAS LIBRERIAS

library(qmap)

library(zoo)

library(latticeExtra)

Corrida -----#.....

CARGANDO LOS ARCHIVOS NECESARIOS

Observacion historica PISCO

OBS_hist <- read.zoo("01precipitaciones_CutervoOBS.csv", header = TRUE, sep = ",",

format = "%Y-%m-%d")

Observacion del modelo GCM

Pisco_model <- read.zoo("01formateado_PrCutervoMonth.csv", header = TRUE, sep = ",",

format = "%Y-%m-%d")

Ajustando la serie hasta diciembre 2005

GCM_hist <- window(Pisco_model, start = "1997-01-01", end = "2017-12-01")

#View(GCM_hist)

data_at <- cbind(OBS_hist, Pisco_model)##agrega la columna de Pisco model

data_wt <- cbind(OBS_hist, GCM_hist)##agrega la columna de GCM - dentro del rango establecido

#View(data_at)

#View(data_wt)

```
#####OK#####

# .....

# GRAFICANDO LAS SERIES DE TIEMPO

plot(data_at, plot.type = "single", col = c(1, 2), lwd = 1, font = 4,
      main = c("OBS vs PISCO"), ylab = "pp (mm/mes)", xlab = "years", sub = "Cutervo", col.sub = "blue")

plot(data_wt, plot.type = "single", col = c(1, 2), lwd = 1, font = 4,
      main = c("OBS vs PISCO"), ylab = "pp (mm/mes)", xlab = "years", sub = "Cutervo", col.sub = "blue")

#months(time(data_wt))

plot(data_wt[months(time(data_wt)) %in% c("Diciembre", "Enero", "Febrero")],
      plot.type = "single", col = c(1, 2), lwd = 1, type='p',
      main = c("OBS vs PISCO"), ylab = "pp (mm/mes)", xlab = "years")

# GRAFICANDO SCATTERPLOT

plot(GCM_hist~OBS_hist, coredata(data_wt), col = c(1,2))

plot(GCM_hist~OBS_hist,
      coredata(data_wt[months(time(data_wt)) %in%
                  c("Diciembre", "Enero", "Febrero")]), col = c(1,2))

# GRAFICANDO ECDF

ecdfplot(~ OBS_hist + GCM_hist, data = data.frame(data_wt),
          lwd = 2, col = c(1, 2))

ecdfplot(~ OBS_hist + GCM_hist,
          data = data.frame(data_wt[months(time(data_wt)) %in%
                              c("Diciembre", "Enero", "Febrero")]),
          lwd = 2, col = c(1, 2))

#####OK#####

# .....

# SEASONAL QUANTILE EMPIRICAL MAPPING

data_wt$gcm_dowscaled <- data_wt$GCM_hist

seasons_by_year <- list(c("Diciembre", "Enero", "Febrero"),
                        c("Marzo", "Abril", "Mayo"),
                        c("Junio", "Julio", "Agosto"),
                        c("Septiembre", "Octubre", "Noviembre"))
```

```

seasonal_qm_fit_model <- list()
for(i in 1:4) {
  obs_sl <- data_wt[months(time(data_wt)) %in% seasons_by_year[[i]]]$OBS_hist
  mod_sl <- data_wt[months(time(data_wt)) %in% seasons_by_year[[i]]]$GCM_hist
  #MODEL, read!: L. Gudmundsson et al. (2012)
  qm_fit <- fitQmapQUANT(obs = coredata(obs_sl),
                        coredata(mod_sl),
                        qstep = 0.01,
                        nboot = 1,
                        wet.day = TRUE, # Adaptado para temperaturas negativas
                        type = "linear")

  mod_sl_qmapped <- doQmapQUANT(coredata(mod_sl), qm_fit, type = "linear")
  data_wt$gcm_downscaled[ months(time(data_wt)) %in%
                        seasons_by_year[[i]]] <- mod_sl_qmapped
  seasonal_qm_fit_model[[i]] <- qm_fit }
#View(data_wt)
# .....
# GRAFICANDO
plot(data_wt, plot.type = "single", col = c(1, 2, 4), lwd = 2,
     main = c("OBS vs Data_PISCO vs PISCO downscaled"),
     xlab = "Years", ylab = "pp (mm/mes)")

plot(data_wt[months(time(data_wt)) %in% c("Diciembre", "Enero", "Febrero")],
     plot.type = "single", col = c(1, 2, 4), lwd = 2, type = "p",
     main = c("OBS vs Data_PISCO vs PISCO downscaled"),
     xlab = "Years", ylab = "pp (mm/mes)")

plot(gcm_downscaled~OBS_hist, coredata(data_wt), col = c(4,1))
plot(gcm_downscaled~OBS_hist, coredata(data_wt[months(time(data_wt)) %in%
                        c("Diciembre", "Enero", "Febrero")]),
     col = c(4,1))
ecdfplot(~ OBS_hist + GCM_hist + gcm_downscaled, data = data.frame(data_wt),

```

```

lwd = 3, col = c(1, 2, 4))
ecdfplot(~ OBS_hist + GCM_hist + gcm_downscaled,
  data = data.frame(data_wt[months(time(data_wt)) %in%
    c("Diciembre", "Enero", "Febrero")]),
  lwd = 3, col = c(1, 2, 4))
ecdfplot(~ OBS_hist + gcm_downscaled, data = data.frame(data_wt),
  lwd = 3, col = c(1, 2, 4))
# .....
# INTERPOLANDO LA INFORMACION
data_at$GCM_downscaled <- data_at$Pisco_model
for(i in 1:4) {
  mod_sl <- data_at[months(time(data_at)) %in% seasons_by_year[[i]]$Pisco_model
  mod_sl_qmapped <- doQmapQUANT(coredatamod_sl), seasonal_qm_fit_model[[i]], type = "linear")
  data_at$GCM_downscaled[ months(time(data_at)) %in% seasons_by_year[[i]]] <- mod_sl_qmapped
}
# verificar la nueva tabla y el grafico
#View(data_at)
plot(data_at, plot.type = "single", col = c(1, 2, 4), lwd = c(1.5, 1.5, 1.5),
  main = c("OBS vs Pisco VS Pisco DOWNSCALED"),
  ylab = "PP (mm/mes)", xlab = "Periodo", font = 4, sub = "Cutervo", col.sub = "blue")

#View(data_at)
#####OK#####
# .....
# GUARDANDO LOS DATOS AJUSTADOS PARA GCM
#write.csv(data_at[,3], file = "09_Data_Cospan_DOWNSCALED_1981_2016.csv", sep = ",")
write.zoo(data_at[,3], file = "01_Data_Cutervo_DOWNSCALED_1981_2025.csv", sep = ",")
print("El proceso se ha completado satisfactoriamente!")

```

Fuente: Elaboración Propia.

Anexo E. Código de programación para la unir todos los archivos

```
library(dplyr)
# Define la carpeta donde están los archivos
carpeta <- "G:/DataWEAP/downsca" # <- cambia esto
# Lista de archivos
archivos <- list.files(path = carpeta, pattern = "^01_Data_.*_DOWNSCALED_1981_2023\\.csv$", full.names =
  TRUE)
# Cargar y unir todos los archivos
data_unida <- lapply(archivos, function(archivo) {
  # Leer archivo
  df <- read.csv(archivo)
  # Extraer nombre de estación del nombre del archivo
  nombre_estacion <- strsplit(basename(archivo), "_")[[1]][3]
  # Agregar columna con nombre de estación
  df$ESTACION <- nombre_estacion
  return(df)} %>% bind_rows()
# Guardar archivo final
write(data_unida, "Archivo_Unido_Downscaled_1981_2023.gdz", row.names = FALSE)
```

Fuente: *Elaboración Propia.*

Anexo F. Código de programación usado para generar el archivo NETCDF.

```
import numpy as np
import pandas as pd
from netCDF4 import Dataset
import datetime

# Leer los datos del CSV
df = pd.read_csv('precipitacion_media_mensual.csv', sep=';')

# Crear el archivo NetCDF
ncfile = Dataset('precipitacion_mensual_peru.nc', mode='w', format='NETCDF4')

# Dimensiones
station_dim = ncfile.createDimension('station', len(df))
time_dim = ncfile.createDimension('time', 12)

# Variables coordinadas
stations = ncfile.createVariable('station', str, ('station',))
lat = ncfile.createVariable('lat', 'f4', ('station',))
lon = ncfile.createVariable('lon', 'f4', ('station',))
altitude = ncfile.createVariable('altitude', 'f4', ('station',))
times = ncfile.createVariable('time', 'i4', ('time',))

# Variable principal
precip = ncfile.createVariable('precipitation', 'f4', ('station', 'time'))

# Atributos globales
ncfile.title = "Precipitación mensual promedio para estaciones en Perú"
ncfile.history = f"Created {datetime.datetime.now().strftime('%Y-%m-%d %H:%M:%S')}"
ncfile.source = "Datos de precipitación media mensual"
ncfile.Conventions = "CF-1.8"

# Atributos de variables
lat.units = "degrees_north"
lat.long_name = "latitude"
lon.units = "degrees_east"
lon.long_name = "longitude"
altitude.units = "m"
altitude.long_name = "altitude above sea level"
times.units = "month"
```

```

times.long_name = "month of the year (1-12)"
precip.units = "mm"
precip.long_name = "monthly precipitation"

# Llenar los datos

stations[:] = df['NOMBRE DE'].values
lat[:] = df['LATITUD'].values
lon[:] = df['LONGITUD'].values
altitude[:] = df['Altitud'].values
times[:] = np.arange(1, 13)

# Extraer los datos de precipitación por mes

months = ['ENERO', 'FEBRERO', 'MARZO', 'ABRIL', 'MAYO', 'JUNIO', 'JULIO', 'AGOSTO', 'SETIEMBRE',
'OCTUBRE', 'NOVIEMBRE', 'DICIEMBRE']

precip_data = df[months].values
precip[:, :] = precip_data


# Cerrar el archivo

ncfile.close()

```

Fuente: *Elaboración Propia.*

Anexo G. Correo enviando por la DZ3 para la proporción de la Data de precipitación para tesisistas por parte de SENAMHI.





UNIVERSIDAD NACIONAL DE CAJAMARCA
"Norte de la Universidad Peruana"
FACULTAD DE INGENIERÍA



"Año del Bicentenario, de la consolidación de nuestra Independencia, y de la conmemoración de las heroicas batallas de Junín y Ayacucho"

Cajamarca, 24 de abril del 2024

CARTA Nº 083-2024-FI-UNC

Señor:

Abog. LUIS ALBERTO CARRANZA MICALAY

Gerente General del SERVICIO NACIONAL DE METEOROLOGÍA E HIDROLOGÍA DEL PERU- SENAMHI - CAJAMARCA.

PRESENTE.

De mi mayor consideración:

Me dirijo a usted con la finalidad de saludarlo cordialmente, y en mi condición de Decano de la Facultad de Ingeniería de la Universidad Nacional de Cajamarca, me permito presentar al señor Tesista de la Escuela Profesional de Ingeniería Hidráulica, de la Facultad de Ingeniería: **KEVIN OMAR CHAVEZ SANCHEZ**, identificado con DNI 71502980, Código SUNEU 2016990008, quien solicita a este Decanato ser presentado al SERVICIO NACIONAL DE METEOROLOGÍA E HIDROLOGÍA DEL PERU- SENAMHI - CAJAMARCA, que usted representa, a fin de que pueda solicitar datos de precipitación necesarios para desarrollar su proyecto de tesis titulada **"Validación y corrección de la precipitación mensual generada con el producto pisco (SENAMHI) del periodo de 1981 al 2023, de la Región Cajamarca"**.

Por lo manifestado, agradeceré se sirva brindarle las facilidades necesarias para que pueda realizar dicha tesis, accediendo a los datos necesarios que obran en su Dirección.

Con mi agradecimiento por la atención que dispense al presente, aprovecho la ocasión para expresarle mi consideración más distinguida.

Atentamente,



UNIVERSIDAD NACIONAL DE CAJAMARCA
FACULTAD DE INGENIERÍA

Carlos Aparicio Arteaga, Dr. Ing.
DECANO

01_Data_Asuncion_DOWNSCALED_1981_2023
01_Data_Bagua_Chica_DOWNSCALED_1981_2023
01_Data_Bambamarca_DOWNSCALED_1981_2023
01_Data_Cajabamba_DOWNSCALED_1981_2023
01_Data_Celendin_DOWNSCALED_1981_2023
01_Data_Chancay_Banios_DOWNSCALED_1981_2023
01_Data_Chirinos_DOWNSCALED_1981_2023
01_Data_Chontali_DOWNSCALED_1981_2023
01_Data_Chota_DOWNSCALED_1981_2023
01_Data_Chotano_Lajas_DOWNSCALED_1981_2023
01_Data_Chugur_DOWNSCALED_1981_2023
01_Data_Cochabamba_DOWNSCALED_1981_2023
01_Data_Cochalan_DOWNSCALED_1981_2023
01_Data_Colasay_DOWNSCALED_1981_2023
01_Data_Contumaza_DOWNSCALED_1981_2023
01_Data_Cueva_Blanca_DOWNSCALED_1981_2023
01_Data_Cutervo_DOWNSCALED_1981_2023
01_Data_El_Limon_DOWNSCALED_1981_2023
01_Data_El_Palto_DOWNSCALED_1981_2023
01_Data_Granja_Porcon_DOWNSCALED_1981_2023
01_Data_Hacienda_Pucara_DOWNSCALED_1981_2023
01_Data_Huamachuco_DOWNSCALED_1981_2023
01_Data_Huambos_DOWNSCALED_1981_2023
01_Data_Huarmaca_DOWNSCALED_1981_2023
01_Data_Incahuasi_DOWNSCALED_1981_2023
01_Data_Jaen_DOWNSCALED_1981_2023
01_Data_Jesus_DOWNSCALED_1981_2023
01_Data_La_Encanada_DOWNSCALED_1981_2023
01_Data_Lacamaca_DOWNSCALED_1981_2023
01_Data_Leimebamba_DOWNSCALED_1981_2023
01_Data_Llama_DOWNSCALED_1981_2023
01_Data_Llapa_DOWNSCALED_1981_2023
01_Data_Magdalena_DOWNSCALED_1981_2023
01_Data_Namballe_DOWNSCALED_1981_2023
01_Data_Namora_DOWNSCALED_1981_2023
01_Data_Puchaca_DOWNSCALED_1981_2023
01_Data_Qda_Sugar_DOWNSCALED_1981_2023
01_Data_Querocotillo_DOWNSCALED_1981_2023

```

01_Data_Quilcate_DOWNSCALED_1981_2023
01_Data_Sallique_DOWNSCALED_1981_2023
01_Data_San_Benito_DOWNSCALED_1981_2023
01_Data_San_Ignacio_DOWNSCALED_1981_2023
01_Data_San_Juan_DOWNSCALED_1981_2023
01_Data_San_Marcos_DOWNSCALED_1981_2023
01_Data_San_Miguel_DOWNSCALED_1981_2023
01_Data_San_Pablo_DOWNSCALED_1981_2023
01_Data_Sondor_DOWNSCALED_1981_2023
01_Data_Sta_Cruz_DOWNSCALED_1981_2023
01_Data_Tabaconas_DOWNSCALED_1981_2023
01_Data_Tocmoche_DOWNSCALED_1981_2023
01_Data_Udima_DOWNSCALED_1981_2023
01_Data_weberbauer_DOWNSCALED_1981_2023

```

Anexo J. Código de programación para validar PISCO con estaciones Carachugo, Maqui Maqui, Yanacocha, La quinua.

Instalar librerías si no las tienes

```
# install.packages(c("readxl", "dplyr", "Metrics"))
```

```
library(readxl)
```

```
library(dplyr)
```

```
library(Metrics)
```

```
# 1. Cargar el archivo Excel
```

```
file_path <- "Anexo 3.5.1_Precipitación y Temperatura.xlsx"
```

Leer hoja con datos de estaciones (ajusta el nombre de la hoja según tu archivo)

```
datos <- read_excel(file_path, sheet = "P-Completada_")
```

Darle formato: suponer que la primera columna es Año y luego meses ENE-DIC

```
# Ajusta los nombres de columnas si difieren
```

```
colnames(datos)[1:13] <- c("Año", "ENE", "FEB", "MAR", "ABR", "MAY", "JUN", "JUL", "AGO", "SET", "OCT", "NOV", "DIC")
```

Transformar a formato largo (Año-Mes-Precipitación)

```
datos_largo <- datos %>%
```

```
tidyr::pivot_longer(cols = ENE:DIC, names_to = "Mes", values_to = "Obs")
```

```
# ---- IMPORTANTE ----
```

```
# Necesitas tener en un archivo aparte los datos del producto PISCO
```

```
# en el mismo formato (Año, Mes, Estación, PISCO).
```

```
# Supongamos que se llama "pisco.csv" y tiene columnas: Año, Mes, Estacion, PISCO
```



```
pisco <- read.csv("pisco.csv")
```

```
# Unir ambas bases por Año, Mes y Estación
```

```
# (asegúrate de que las estaciones tengan el mismo nombre en ambas fuentes)
```

```
validacion <- datos_largo %>%
```

```
inner_join(pisco, by = c("Año", "Mes", "Estacion"))
```

```
# Calcular indicadores estadísticos por estación
```

```
resultados <- validacion %>%
```

```
group_by(Estacion) %>%
```

```
summarise(
```

```
  R2 = cor(Obs, PISCO, use="complete.obs")^2,
```

```
  NSE = 1 - sum((Obs - PISCO)^2, na.rm=TRUE) / sum((Obs - mean(Obs, na.rm=TRUE))^2, na.rm=TRUE),
```

```
  BIAS = (sum(PISCO - Obs, na.rm=TRUE) / sum(Obs, na.rm=TRUE)) * 100,
```

```
  RSR = rmse(Obs, PISCO) / sd(Obs, na.rm=TRUE)
```

```
# 6. Exportar resultados a Excel o CSV
```

```
write.csv(resultados, "validacion_pisco.csv", row.names = FALSE)
```

```
print(resultados)
```

***Fuente:** Elaboración Propia.*

Anexo K. Data de la Estación Yanacocha del Informe técnico del estudio Hidrológico de la presa el Chonta en Cajamarca.

PRECIPITACIÓN TOTAL MENSUAL COMPLETADA(mm)

ESTACIÓN: YANACOCHA
LATITUD: 6° 58' 1.5" S
LONGITUD: 78° 32' 32" W
ALTITUD: 3818 msnm

FUENTE:

Informe tecnico del estudio Hidrologico para solicitar la reserva de agua para la presa Chonta en Cajamarca

Nº	AÑO	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SET	OCT	NOV	DIC	TOTAL	PROM	MAX
1	1969	99.93	172.21	120.53	130.07	57.3	16.32	6.34	1.3	94.61	67.82	84.35	182.48	1033.26	86.105	182.48
2	1970	147.67	138.73	135.36	111.86	44.41	26.94	13.71	38.13	36.63	115.34	176.59	155.24	1140.61	95.0508333	176.59
3	1971	181.34	60.22	187.093829	108.9	27.57	89.47	15.32	18.56	122.79	196.53	155.07	173.05	1335.91383	111.326152	196.53
4	1972	100.85	132.34	171.33	73.24	21.23	53.2	5.73	2.63	38.03	76.79	188.65	189.07	1053.09	87.7575	189.07
5	1973	128.55	79.88	126.6	191.56	24.55	52.81	5.24	5.53	36.14	131.38	175.13	173.79	1131.16	94.2633333	191.56
6	1974	121.3	174.58	166.94	130.52	8.3	15.33	7.95	16.48	64.66	113.73	103.19	180.04	1103.02	91.9183333	180.04
7	1975	76.65	89.6	142.24	149.02	33.31	49.8	6.32	33.07	20.47	204.77	213.15	187	1205.4	100.45	213.15
8	1976	158.79	104.18	181.77	80.55	50.19	43.35	0	0	20.5	92.35	41.68	153.55	926.91	77.2425	181.77
9	1977	151.61	146.85	128.44	108.5	74.73	4.52	9.4	21.15	40	73.5	134.03	120.25	1012.98	84.415	151.61
10	1978	30.95	202.83	85.73	64.59	83.34	2.36	5.7	0.85	64.9	74.38	210.86	128.47	954.96	79.58	210.86
11	1979	102.93	78.21	433.76	76.38	22.84	28.31	26.96	26.05	218.67	34.54	90.28	69.99	1208.92	100.743333	433.76
12	1980	132.32	68.03	135	67.55	50.21	5.69	1.37	1.03	15.85	312.35	275.81	123.55	1188.76	99.0633333	312.35
13	1981	91.76	161.37	135.71	111.16	62.48	1.46	1.23	1.8	16.21	200.72	67.16	116.55	967.61	80.6341667	200.72
14	1982	74.21	75.46	111.86	43.16	69.44	6.97	13.24	16.78	46.31	123.18	162.09	125.65	868.35	72.3625	162.09
15	1983	163.51	78.02	101.68	142.87	50.35	6.47	2.06	5.82	83.68	112.27	67.55	66.48	880.76	73.3966667	163.51
16	1984	155.3	141.2	122.65	51.61	45.42	4.69	0.05	0.27	41.08	156.78	253.32	143.87	1116.24	93.02	253.32
17	1985	182	79.46	112.14	200.6	28.29	2.45	0	0	24.03	73.4	31.06	109.19	842.62	70.2183333	200.6
18	1986	71.42	73.34	53.53	56.58	83.43	8.43	1.15	3.68	20.14	250.04	144.69	112.96	879.39	73.2825	250.04
19	1987	112.05	84.6	198.21	151.71	63.61	3.89	5.91	2.8	36.62	90.44	243.92	164.54	1158.3	96.525	243.92
20	1988	216.58	304.77	88.07	47.05	62.08	9.84	4.41	0.33	27.86	176.91	68.13	70.11	1076.14	89.6783333	304.77
21	1989	162.58	154.87	72.24	99.08	26	1.43	0	0	39.16	66.98	64.55	57.49	744.38	62.0316667	162.58
22	1990	72.24	114.56	147.15	72.75	19.32	10.53	1.44	0.68	20.39	287.55	345.97	230.5	1323.08	110.256667	345.97
23	1991	113.04	86.89	187.093829	176.46	69.88	32.98	9.36	0.28	38.16	110.98	205.82	122.47	1153.41383	96.1178191	205.82
24	1992	149.99	101.56	180.28	121.15	57.06	5.32	6.46	4.75	82.24	88.52	136.1	134.51	1067.94	88.995	180.28
25	1993	208.39	211.78	187.093829	200.56	20.02	10.06	4.94	2.58	51.6	122.15	185.38	192.64	1397.19383	116.432819	211.78
26	1994	267.37	209.89	167.29	154.4	67.33	42.49	7.05	0.92	35.68	256.6	165.44	174.61	1549.07	129.089167	267.37
27	1995	87.65	156.05	170.04	81.59	52.61	7.58	4.11	1.73	37.81	81.79	119.47	126.44	926.87	77.2391667	170.04
28	1996	152.47	148.09	213.83	125.14	57.76	18.39	10.98	19.2	35.87	251.78	120.35	64.05	1217.91	101.4925	251.78
29	1997	146.3	94.66	105.37	147.88	19.91	8.45	2.31	0.23	23.95	172.11	462.03	145.81	1329.01	110.750833	462.03
30	1998	136.61	216.4	120.2	77.2	84.6	13.2	0.3	1.3	35.8	187.2	143.5	45.2	1061.51	88.4591667	216.4
31	1999	150.5	373.4	167.1	65.5	74.4	109	17	17.3	218.2	58.5	178.6	175.3	1604.8	133.733333	373.4
32	2000	61.6	269.2	239.5	122.9	53.8	31.2	8.6	21.3	189	38.1	41.9	169.1	1246.2	103.85	269.2
33	2001	259.3	93	218	64	13.7	3.6	5.2	0	39.1	125.4	147.8	177.8	1146.9	95.575	259.3
34	2002	120.4	130.6	305	167.7	29.2	4.6	14.7	0.8	50.5	181.9	144.3	98.8	1248.5	104.041667	305
35	2003	104.4	103.6	149.3	109.7	41.9	21.3	0	0	61.3	57.8	103.2	133.8	886.3	73.8583333	149.3
36	2004	108.8	96	179.3	120.9	59.4	10.7	21.8	9.1	65	134.1	206.3	222.3	1233.7	102.808333	222.3
37	2005	151.4	134.9	354.3	83.3	59.7	8.9	10.2	27.7	35.8	260.8	112	195.6	1434.6	119.55	354.3
38	2006	91.4	205	287.8	137.2	18	60.4	13	13.2	44.5	130.6	179.6	247.4	1428.1	119.008333	287.8
39	2007	174	63.2	237.5	205.5	58.9	3.3	25.9	23.9	49.5	234.7	384.3	178.6	1639.3	136.608333	384.3
40	2008	123.74	343.44	230	224.76	67	22.93	11.17	4.37	46.54	180.21	130.35	93.51	1478.02	123.168333	343.44
41	2009	304.39	98.15	97.3	124.04	74.9	17.61	20.35	3.21	123.58	53.09	159.92	227.78	1304.32	108.693333	304.39
42	2010	114.42	62.07	134.39	79.56	21.12	52.67	7.95	2.16	24.93	158.69	148.72	193.46	1000.14	83.345	193.46
43	2011	258.63	111.67	169.29	117.4	40.84	5.97	38.61	57.06	31.41	91.62	148.86	125.85	1197.21	99.7675	258.63
44	2012	215.14	95.55	160.36	118.51	63.21	40.69	6.07	17.78	41.85	58.42	239.23	190.11	1246.92	103.91	239.23
45	2013	82.88	220.58	101.99	86.2	110.74	37.66	28.54	19.71	31.41	161.23	40.06	172.99	1093.99	91.1658333	220.58
46	2014	94.93	92.61	96.66	68.15	35.57	16.6	18.15	6.84	40.93	69.63	51.63	15.35	607.05	50.5875	96.66
47	2015	244.17	130.94	134.32	101.43	73.28	10.94	20.83	8.73	21.45	140.28	177.75	172.05	1236.17	103.014167	244.17
48	2016	133.94	161.37	142.37	83.82	76.07	14.66	19.76	5.96	70.15	117.12	153.44	195.24	1173.9	97.825	195.24
49	2017	126.63	74.94	411.5	117.81	116.87	10.5	22.05	18.24	27.59	124.33	154.67	68.7	1273.83	106.1525	411.5
50	2018	178.09	53.84	119.05	69.96	46.66	8.91	14.5	1.46	31.29	177.91	296.76	192.27	1190.7	99.225	296.76
51	2019	123.22	115.66	187.093829	171.2	39.84	6.12	8.35	2.8	39.41	188.26	224.02	197.44	1303.41383	108.617819	224.02
52	2020	117.6	99.42	153.62	70.32	40.13	9.29	10.37	13.77	65.35	43.52	85.56	138.49	847.44	70.62	153.62
53	2021	210.18	45.79	132.49	116.71	75.75	7.32	1.2	2.91	25.03	311.56	238.51	226.03	1393.48	116.123333	311.56
54	2022	165.66	103.84	146.09	143.23	41.98	15.02	17.79	30.52	34.01	97.59	95.11	160.75	1051.59	87.6325	165.66
55	2023	129.97	209.13	105.71	138.42	22.25	3.01	4.12	2.14	35.21	114.66	102.91	156.33	1023.86	85.3216667	209.13
56	2024	136.95	147.37	60.68	138.14	110.93	48.87	40.84	26.49	32.64	139.3	61.59	38.25	982.05	81.8375	147.37

PROMEDIO	142.476786	135.283929	164.463309	114.286607	51.8519643	20.7946429	10.4658929	10.0960714	52.5985714	138.432143	157.900179	146.479464	1145.12956	95.4274633	240.948393
P. MÁXIMA	304.39	373.4	433.76	224.76	116.87	109	40.84	57.06	218.67	312.35	462.03	247.4	1639.3		462.03
P. MÍNIMA	30.95	45.79	53.53	43.16	8.3	1.43	0	0	15.85	34.54	31.06	15.35	607.05		96.66
D. ESTÁNDAR	55.907851	70.7248387	76.2772917	43.9409649	25.1831562	22.3403251	9.46451089	12.0960738	44.0175376	71.0649123	86.0259155	53.1713514	211.726063		78.6180205

Anexo L. Data de la Estación Maqui Maqui del Informe técnico del estudio Hidrológico de la presa el Chonta en Cajamarca.

PRECIPITACIÓN TOTAL MENSUAL COMPLETADA(mm)

ESTACIÓN: MAQUI MAQUI
LATITUD: 6° 58' 8" S
LONGITUD: 78° 27' 57" W
ALTITUD: 4035 msnm

FUENTE:

Informe técnico del estudio Hidrológico para solicitar la reserva de agua para la presa Chonta en Cajamarca

N°	AÑO	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SET	OCT	NOV	DIC	TOTAL	PROM	MAX
1	1969	69.48	135.5	116	117.87	20.01	29.71	10.27	2.24	48.29	55.53	40.44	173.3	818.64	68.22	173.3
2	1970	181.67	156.63	160.62	108.41	38.95	21.41	13.82	26.07	108.91	103.12	153.92	179.66	1253.19	104.4325	181.67
3	1971	178.96	71.25	506.94	99.2	85.16	103.67	32.45	3.25	23.56	177.64	107.26	82.61	1471.95	122.6625	506.94
4	1972	40.15	163.11	194.7	121.34	64.6	37.1	1.52	3.21	17.53	42.96	162.9	175.64	1024.76	85.3966667	194.7
5	1973	108.51	104.92	73.99	81.19	44.8	41.84	26.96	2.13	56.17	178.66	176.11	143.31	1038.59	86.5491667	178.66
6	1974	70.36	202.29	152.42	150.77	44.57	14.66	16.61	10.41	11.65	120.73	128.76	158.3	1081.53	90.1275	202.29
7	1975	30.03	113.76	145.75	114.35	36.39	48.89	7.79	12.13	11.14	193.71	97.07	202.53	1013.54	84.4616667	202.53
8	1976	172.85	108.6	125.18	79.59	36.47	30.67	0.43	1.02	37.64	62.9	83.03	242.07	980.45	81.7041667	242.07
9	1977	93.14	211.09	96.82	39.77	18.97	9.23	3.22	12.08	34.25	60.4	76.91	153.08	808.96	67.4133333	211.09
10	1978	13.79	145.13	71.84	12.96	29.78	4.46	16.23	8.47	18.81	34.97	122.15	91.89	570.48	47.54	145.13
11	1979	79.49	67.87	494.3	123.05	46.15	12.62	28.89	12.9	48.98	19.19	40.76	133.04	1107.24	92.27	494.3
12	1980	144.21	71.07	119.24	81.03	14.19	6.94	3.26	1.37	6.59	262.49	117.64	103.08	931.11	77.5925	262.49
13	1981	99.24	146.25	78.3	59.56	38.05	3.38	5.58	6.07	5.94	161.39	85.14	125.99	814.89	67.9075	161.39
14	1982	32.32	68.77	54.78	41.34	18.74	8.53	32.08	6.41	30.02	80.3	159.42	82.66	615.37	51.2808333	159.42
15	1983	158.69	89.06	77.98	84.86	75.47	20.47	1.54	5.95	29.39	112.48	15.87	85.06	756.82	63.0683333	158.69
16	1984	136.35	128.75	119.5	28.13	13.71	4.45	0.91	3.53	65.16	137.09	210.54	181.55	1029.67	85.8058333	210.54
17	1985	120.91	99.53	141.09	125.08	10.22	4.59	0.69	1.72	16.67	48.27	10	117.37	696.14	58.0116667	141.09
18	1986	47.77	52.85	52.12	37.7	22.04	13.83	3.53	7.42	6.67	180.41	68.77	114.33	607.44	50.62	180.41
19	1987	72.41	115.7	188.2	129.81	19.82	3.33	9.99	14.48	48.26	57.38	139.36	106.78	905.52	75.46	188.2
20	1988	154.37	357.26	89.7	81.82	78.68	15.52	7.64	4.28	45.14	182.32	72.79	79.39	1168.91	97.4091667	357.26
21	1989	117.22	129.65	66.53	80.67	4.65	3.59	0.47	2.21	61.12	62.74	67.67	129.15	725.67	60.4725	129.65
22	1990	31.99	142.7	164.04	97.38	57.3	20.87	4.86	9.59	52.48	260.62	155.89	271.88	1269.6	105.8	271.88
23	1991	116.24	96.03	719.75	143.27	172.85	14.71	5.48	5.13	25.94	93.12	121.54	144.78	1658.84	138.236667	719.75
24	1992	119.48	92.98	143.46	100.97	23.67	14.75	3.32	2.24	26.65	77.78	89.97	172.5	867.77	72.3141667	172.5
25	1993	158.19	215.36	457.45	116.91	45	30.2	3.53	2.43	26.8	109.26	201.97	163.3	1530.4	127.533333	457.45
26	1994	132.8	170.34	129.61	114.4	218.55	15.97	1.77	2.38	98.36	215.84	123.84	118.86	1342.72	111.893333	218.55
27	1995	20.6	145	154.6	84.5	72.5	14.2	3.9	3.6	22.2	70.4	156.2	168.9	916.6	76.3833333	168.9
28	1996	79	155.2	184.9	97.8	55.1	22.9	2.8	10.4	29.1	146.3	55.4	83.3	922.2	76.85	184.9
29	1997	94.2	125.2	74.9	63.5	25.1	9.4	6.1	2.3	25.9	89.7	136.4	118.6	771.3	64.275	136.4
30	1998	57.4	192.5	161	119.4	93.4	5.8	0.4	1.6	18	155.4	160.8	47.4	1013.1	84.425	192.5
31	1999	162.4	315.2	137.4	69.6	101.4	93.2	17	7.2	123.6	58	110.2	238	1433.2	119.433333	315.2
32	2000	86.4	226.2	196.2	97.6	68.4	26.4	5	35.8	136.4	9.6	55.2	147.8	1091	90.9166667	226.2
33	2001	243.2	148.8	257.4	99.6	65.4	6.8	12.8	3.4	72	124.6	170.4	193.6	1398	116.5	257.4
34	2002	53	106.6	193	168.6	35.2	15.8	18.4	3.3	40.8	195.6	134	207.2	1171.5	97.625	207.2
35	2003	92.4	101.6	113.8	25.6	9.4	13.2	4.4	4.4	13.4	18	22.4	118.7	537.3	44.775	118.7
36	2004	95.7	67.1	110	71.5	21.6	7.4	22.1	8.7	55.6	115.6	187	203	965.3	80.4416667	203
37	2005	116.3	140.2	325.7	122.9	30.5	17.5	11.4	17.8	36.8	292.4	73.9	229.4	1414.8	117.9	325.7
38	2006	91.4	257.3	270.8	122.4	21.6	58.7	9.7	22.6	33	140	168.9	276.6	1473	122.75	276.6
39	2007	120.1	72.4	236.2	137.4	67.3	6.3	51	37.1	33.2	234	194.8	108.2	1298	108.166667	236.2
40	2008	73.3	371.03	229.87	99.2	29.65	23.75	7.46	2.96	60.85	251.21	82.45	126.89	1358.62	113.218333	371.03
41	2009	207.16	89.96	96.45	92.74	85.54	20.96	11.79	5.64	16.92	6.14	97.11	184.93	915.34	76.2783333	207.16
42	2010	107.83	99.25	165.88	132.63	38.81	26.32	6.47	6.01	19.67	144.52	114.72	268.59	1130.7	94.225	268.59
43	2011	210.22	158.65	156.23	140.79	45.97	5.76	25.68	10.88	62.46	112.01	94.21	121.44	1144.3	95.3583333	210.22
44	2012	136.07	97.49	103.21	88.25	22.07	27.91	1.83	5.22	31.65	20.87	127.42	157.07	819.06	68.255	157.07
45	2013	43.89	167.18	65.43	63.19	165.92	23.9	14.42	9.97	23.09	180.16	95.59	120.34	973.08	81.09	180.16
46	2014	59.68	87.41	91.67	66.32	47.6	17.89	11.21	21.54	39.78	37.75	82.45	47.07	610.37	50.8641667	91.67
47	2015	156.51	167.31	138.85	57.17	135.72	9.43	20.03	6.49	3.9	92.74	186.52	237.67	1212.34	101.028333	237.67
48	2016	100.84	199.06	113.71	115.16	45.37	28.64	8.8	6.84	17.87	85.29	193.22	128.63	1043.43	86.9525	199.06
49	2017	121.73	74.4	310.16	47.1	132.54	8.54	10.19	8.51	11.29	80.89	144.25	78.67	1028.27	85.6891667	310.16
50	2018	120.43	64.11	79.41	70.63	49.62	8.53	4	3.29	13.71	116.94	177.74	231.42	939.83	78.3191667	231.42
51	2019	49.39	100.93	599.86	128.45	31.36	9.76	8.63	7.71	69.34	141.9	138.32	105.63	1391.28	115.94	599.86
52	2020	114.68	88.86	106.57	101.17	62.54	7.67	18.81	8.23	34.59	20.53	14.68	116.16	694.49	57.8741667	116.16
53	2021	149.2	50.81	95.52	78.64	7.29	11.28	5.55	4.1	12.6	265.18	219.27	198.42	1097.86	91.4883333	265.18
54	2022	186.8	111.91	132.67	98.25	43.09	38.32	10.26	9.92	93.33	63.15	99.66	137.44	1024.8	85.4	186.8
55	2023	87.07	189.76	112.93	104.62	13.55	9.97	3.95	3.83	18.15	62.95	122.02	69.09	797.89	66.4908333	189.76
56	2024	119.73	124.41	70.78	121.66	73.43	42.98	14.72	11.48	16.78	93.78	81.33	44.16	815.24	67.9366667	124.41

PROMEDIO	107.808036	138.433571	175.45375	93.8892857	53.1385714	20.6178571	10.565	8.21321429	38.3589286	116.373393	116.540714	147.257679	1026.65	85.5541667	237.807679
P. MÁXIMA	243.2	371.03	719.75	168.6	218.55	103.67	51	37.1	136.4	292.4	219.27	276.6	1658.84		719.75
P. MÍNIMA	13.79	50.81	52.12	12.96	4.65	3.33	0.4	1.02	3.9	6.14	10	44.16	537.3		91.67
D. ESTÁNDAR	51.4038195	69.245972	137.450457	33.7392332	43.3626713	19.5419527	9.94209691	7.69555364	29.5017578	73.266991	52.7507044	58.5274251	267.717308		119.424971

Anexo M. Data de la Estación La Quinua del Informe técnico del estudio Hidrológico de la presa el Chonta en Cajamarca.

ESTACIÓN: LA QUINUA
LATITUD: 6° 58' 58" S
LONGITUD: 78° 33' 50" W
ALTITUD: 3618 msnm

PRECIPITACION TOTAL MENSUAL COMPLETADA(mm)

FUENTE:

Informe tecnico del estudio Hidrologico para solicitar la reserva de agua para la presa Chonta en Cajamarca

Nº	AÑO	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SET	OCT	NOV	DIC	TOTAL	PROM	MAX
1	1969	42.87	167.86	83.99	143.72	25.54	9.96	0.43	1.22	158.13	32.26	161.71	101.7	929.39	77.4491667	167.86
2	1970	107.73	192.07	131.4	116.63	71.04	27.5	9.83	48.25	54.07	143.32	196.17	129.15	1227.16	102.263333	196.17
4	1971	247.76	62.2	864.7	231.07	107.28	55.77	9.77	15.78	121.66	243.23	96.83	48.01	2104.06	175.338333	864.7
5	1972	129.61	127.91	198.88	163.14	89.79	25.33	0	4.07	128.44	89.05	207.75	340.02	1503.99	125.3325	340.02
5	1973	152.93	107.21	132.99	129.31	59.3	25.88	2.14	13.26	45.95	88.67	143.38	250.85	1151.87	95.9891667	250.85
6	1974	22.22	199.82	188.92	126.64	83.91	30.14	7.85	48.85	118.95	95.32	114.36	87.79	1124.77	93.7308333	199.82
6	1975	141.96	95.54	169.64	245.61	84.98	25.44	0	12.91	20.81	265.46	88.51	81.97	1232.83	102.735833	265.46
7	1976	175.37	90.48	212.49	96.67	49.99	17.04	0	0	67.98	90.92	126.45	293.93	1221.32	101.776667	293.93
7	1977	404.77	117.63	81.54	91.12	34.84	9.56	2.45	45.85	62.69	108.41	86.26	139.43	1184.55	98.7125	404.77
8	1978	32.97	146.73	86.13	48.16	60.03	10.15	29.13	2.05	36.89	121.5	180.52	116.25	870.51	72.5425	180.52
8	1979	56.51	109.07	665.89	114.4	78.96	16.43	19.66	13.33	63.02	24.78	69.15	81.97	1315.71	109.6425	665.89
9	1980	89.5	100.82	145.73	60.13	36.29	7.05	0	0.88	43.92	473.27	141.69	73.22	1172.5	97.7083333	473.27
9	1981	24.77	240.28	107.01	128.2	65.96	12.51	0	6.88	54.89	305.33	62.86	106.87	1115.56	92.9633333	305.33
10	1982	40.52	116.79	71.64	79.08	51.45	10.14	19.52	1.99	25.93	147.56	93.01	121.56	779.19	64.9325	147.56
10	1983	84.61	107.72	112.2	163.86	85.91	31.53	0	16.96	77.49	156.25	55.57	123.83	1015.93	84.6608333	163.86
11	1984	78.92	175.52	98.29	75.55	50.11	2.88	0	1.15	60.85	228.26	303.94	140.98	1216.45	101.370833	303.94
11	1985	133.34	131.26	176.18	221.57	50.22	4.15	0	0	68.99	64.4	28.74	61.46	940.31	78.3591667	221.57
12	1986	49.93	108.66	26.1	52.67	25.7	13.56	0.13	6.04	13.58	363.22	53.01	223.51	936.11	78.0091667	363.22
12	1987	118.89	77.76	193.9	113.75	43.12	4.79	34.85	4.96	54.81	98.97	110.67	69.7	926.17	77.1808333	193.9
13	1988	79.69	294.16	37.83	57.97	43.87	26.96	3.37	0.17	42.6	165.94	65.25	79.83	897.64	74.8033333	294.16
13	1989	65.1	220.57	57.56	79.71	27.41	0.19	0	0	55.93	87.14	46.26	60.16	700.03	58.3358333	220.57
14	1990	99.63	91.58	229.97	112.23	87.2	27.21	0	0.33	15.75	413.26	425.72	223.44	1726.32	143.86	425.72
14	1991	124.51	104.53	831.02	269.99	208.34	72.7	12.37	0.89	53.67	147.79	134.02	323.74	2283.57	190.2975	831.02
15	1992	194.46	114.39	202.79	117.68	56.33	15.16	0.13	14.23	130.83	88.97	302.4	181.62	1418.99	118.249167	302.4
15	1993	137.57	166.68	621.88	232.91	73.54	45.08	0	2.4	134.97	127.11	202.27	498.73	2243.14	186.928333	621.88
16	1994	167.55	189.79	186.46	240.71	246.31	61.98	1.73	0.91	111.45	392.12	183.34	122.77	1905.12	158.76	392.12
16	1995	44.03	217.52	219	126.71	79.49	17.42	1.85	2.52	42.27	119.84	267.05	191.61	1329.31	110.775833	267.05
17	1996	432.04	181.03	186.85	122.57	65.78	39.74	0.03	19.14	62.74	413.63	50.69	90.49	1664.73	138.7275	432.04
17	1997	222.54	63.89	78.67	145.73	69.73	23.44	24.24	0.77	17.7	271.74	616.04	283.69	1818.18	151.515	616.04
18	1998	209.99	177.58	201.56	129.71	72.11	13.7	0.19	2.76	27.61	313.51	167.93	84.35	1401	116.75	313.51
18	1999	21.6	300	128.6	74	102	73.4	21.8	32.4	147.4	84	192.9	194.8	1372.9	114.408333	300
19	2000	57.2	199.7	254	105.8	95.1	30.2	1.6	14.8	155.6	23.4	60.4	194.1	1191.9	99.325	254
19	2001	348.2	149.6	476.7	149.1	113	20.3	41.9	1.1	100.6	129	265.2	222.3	2017	168.083333	476.7
20	2002	120.4	130.6	305	235.5	63.4	16.3	20.8	0	75.7	199.7	104.7	189.5	1461.6	121.8	305
20	2003	105.4	93.7	89.4	100.6	41.9	3.6	0	0	46	81.9	79.8	113.8	756.1	63.0083333	113.8
21	2004	79.8	166.9	199.9	180.6	112.3	19.3	25.7	14	122.2	224.3	248.7	360.9	1754.6	146.216667	360.9
21	2005	87.9	217.1	296.2	76.4	66.8	37.1	0.8	13.7	26.4	321.8	66.8	169.4	1380.4	115.033333	321.8
22	2006	73.4	194.6	363	136.7	47.8	32.5	10	29.2	66.8	116.3	168.9	141	1380.2	115.016667	363
22	2007	156.7	66.5	269.7	170.7	63.5	3.6	49.3	12.7	35.8	229.1	259.8	103.6	1421	118.416667	269.7
23	2008	91.86	211.88	193.08	151.06	38	24.85	12.3	1.29	71.43	147.32	135.13	128.16	1206.36	100.53	211.88
23	2009	98.69	236.46	147.64	124.71	77.12	41.77	13.02	1.34	136.47	90.11	122.83	90.79	1180.95	98.4125	236.46
24	2010	128.63	103.98	164.07	110.52	64.51	28.5	7.91	2.56	35.01	181.7	185.58	365.83	1378.8	114.9	365.83
24	2011	216.34	104.44	209.48	186.1	76.68	28.33	61.39	44.36	53.13	116.34	89.45	282.12	1468.16	122.346667	282.12
25	2012	195.07	106.35	142.69	115.06	60.51	30.51	0.23	16.93	180.76	74.2	265.24	71.25	1258.8	104.9	265.24
25	2013	67.98	155.43	74.6	70.06	125.82	50.83	8.54	11.61	36.74	254.22	62.29	53.16	971.28	80.94	254.22
26	2014	38.33	184.37	63.07	88.32	57.3	46.4	42.59	11.83	79.37	99.51	74.65	68.19	853.93	71.1608333	184.37
26	2015	344.87	143.2	181.44	93.83	127.85	26.19	21.74	3.68	21.19	150.11	148.8	123.74	1386.64	115.553333	344.87
27	2016	126.21	121.35	115.55	108.02	58.91	38.64	1.18	2.57	70.34	140.74	129.01	70.34	982.86	81.905	140.74
27	2017	42.2	124.99	558.52	137.07	163.7	34.24	4.88	39.15	27.47	142.3	51.62	148.26	1474.4	122.866667	558.52
28	2018	155.34	111.99	112.19	124.92	86.13	23.42	0.04	2.63	36.32	254.81	195.91	117.75	1221.45	101.7875	254.81
28	2019	45.76	225.25	715.75	153.86	46.59	6.8	3.01	1.48	136.13	265.53	129.26	127.87	1857.29	154.774167	715.75
29	2020	37.64	252.07	145.86	126.71	94.58	23.22	28.77	2.07	84.02	31.19	106.05	183.4	1115.58	92.965	252.07
29	2021	161.3	117.91	183.69	94.7	35.14	5.82	0.21	32.62	47.22	432.2	180.24	125.22	1416.27	118.0225	432.2
30	2022	48.75	199.9	211.18	97.91	44.68	25.86	0.75	48.6	113.3	97.47	84.44	79.41	1052.25	87.6875	211.18
30	2023	56.33	214.07	137.73	124.69	40.46	3.78	0.91	0.79	35.68	194.89	157.86	88.54	1055.73	87.9775	214.07
31	2024	27.62	117.74	51.07	139.1	76.29	45.74	18.34	11.52	66.39	201.25	28.52	95.76	879.34	73.2783333	201.25

PROMEDIO	122.246607	152.627321	221.273571	130.593571	74.3678571	25.0819643	10.3103571	11.455	71.1078571	177.939643	149.564821	154.363571	1300.93214	108.411012	332.314821
P. MÁXIMA	432.04	300	864.7	269.99	246.31	73.4	61.39	48.85	180.76	473.27	616.04	498.73	2283.57		864.7
P. MÍNIMA	21.6	62.2	26.1	48.16	25.54	0.19	0	0	13.58	23.4	28.52	48.01	700.03		113.8
D. ESTÁNDAR	92.9981263	57.4420204	192.117881	52.1125151	40.7222243	17.117979	14.4408592	14.5135487	42.5824589	111.503952	103.001659	94.6739045	369.53232		165.98205

Anexo N. Data de la Estación Carachugo del Informe técnico del estudio Hidrológico de la presa el Chonta en Cajamarca.

PRECIPITACIÓN TOTAL MENSUAL COMPLETADA(mm)

ESTACIÓN: CARACHUGO
LATITUD: 6° 58' 34" S
LONGITUD: 78° 35' 40" W
ALTITUD: 4035 msnm

FUENTE:

Informe tecnico del estudio Hidrologico para solicitar la reserva de agua para la presa Chonta en Cajamarca

Nº	AÑO	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SET	OCT	NOV	DIC	TOTAL	PROM	MAX
1	1969	84.99	166.98	303.33	221.43	89.21	5.16	43.22	1.83	28.03	125.69	127.57	283.09	1480.53	123.3775	303.33
2	1970	168.33	183.44	231.59	169.7	68.23	36.04	5.52	22.81	42.38	142.6	183.3	246.46	1500.4	125.033333	246.46
3	1971	179.36	70.3	338	293.18	43.68	66.35	4.56	11.6	25.45	206.81	51.81	75.84	1366.94	113.911667	338
4	1972	64.54	186.74	197.04	142.62	39.19	12.67	7.3	9.6	15.02	101.38	184.93	194.33	1155.36	96.28	197.04
5	1973	113.16	121.84	65.8	116.72	47.35	22.76	0.57	1.18	34.44	201.17	144.56	117.92	987.47	82.2891667	201.17
6	1974	108.21	247.1	275	177.89	7.74	57.46	3.13	12.94	15.76	210.64	144.36	135.93	1396.16	116.346667	275
7	1975	64.4	117.24	269.09	188.29	26.38	19.11	0.16	20.41	10.4	201.8	100.86	205.54	1223.68	101.973333	269.09
8	1976	165.21	106.54	151.77	136.87	91.41	11.38	0.63	0	22.06	32.62	190.63	282.66	1191.78	99.315	282.66
9	1977	158.21	211.62	56.45	77.56	92.3	9.33	3.6	9.24	21.41	55.42	82.47	112.5	890.11	74.1758333	211.62
10	1978	44.4	133.16	117	77.77	101.8	5.33	14.76	0.63	82.76	162.32	202.78	83.02	1025.73	85.4775	202.78
11	1979	69.66	74.33	338.18	202.8	58.67	15.92	3.59	11.02	100.86	55.74	78.35	164.23	1173.35	97.7791667	338.18
12	1980	135.16	77.04	206.32	103.25	81.94	1.79	0	3.14	7.6	175.56	68.89	137.94	998.63	83.2191667	206.32
13	1981	103.91	175.78	116.74	80.02	52.28	17.58	0.01	2.93	7.96	100.62	62.1	117.24	837.17	69.7641667	175.78
14	1982	50.64	73.19	236.17	81.71	90	10.45	1.65	4.51	94.79	117.12	23.52	116.19	899.94	74.995	236.17
15	1983	135.33	104.27	155.56	144.87	57.07	37.38	0.7	5.83	32.48	170.67	59.95	105.64	1009.75	84.1458333	170.67
16	1984	162.03	190.24	195.04	96.14	46.1	1.86	0.59	1.03	140.76	177.7	219.37	233.16	1464.02	122.001667	233.16
17	1985	175.49	107.93	208.46	166.36	56.72	1.48	0.19	0	14.17	102.33	137.54	156.51	1127.18	93.9316667	208.46
18	1986	55.21	53.75	59.22	80	86.01	5.29	2.57	3.83	12.61	204.4	128.76	136.56	828.21	69.0175	204.4
19	1987	86.72	125.51	219.64	141.37	75.15	2.16	16.04	15.22	61.57	87.36	125.04	100.41	1056.19	88.0158333	219.64
20	1988	221.63	363.46	79.82	88.45	61.96	36.02	11.03	1.28	20.57	221.06	31.59	57.43	1194.3	99.525	363.46
21	1989	182.05	192.79	84.57	81.34	108.54	0	0	0.1	100.23	61.09	34.66	46.14	891.51	74.2925	192.79
22	1990	43.34	142.82	233.28	143.75	21.46	26.3	0	0.82	78.23	116.95	244.31	327.45	1378.71	114.8925	327.45
23	1991	97.52	100.82	338.18	258.96	35.11	111.68	9.88	7.24	54.62	175.81	180.39	141.84	1512.05	126.004167	338.18
24	1992	162.05	129.47	250.95	127.32	75.49	5.99	6.7	2.96	37.89	189.89	201.15	299.87	1489.73	124.144167	299.87
25	1993	266.66	238.79	337.51	173.7	37	49	1.3	3.4	60.3	133	155	274.4	1730.06	144.171667	337.51
26	1994	240.7	252.3	230.7	226.4	62.9	15	2.1	4.6	50	108	126	169.4	1488.1	124.008333	252.3
27	1995	60.5	193	199.1	165.4	89.2	2.8	45.5	6.1	32	72.6	193.5	261.1	1320.8	110.066667	261.1
28	1996	158.5	198.6	214.6	96.3	49	58.2	1.8	26.2	38.4	176.9	35.6	49	1103.1	91.925	214.6
29	1997	116.3	136.9	62.5	83	43.4	18.8	6.9	0.8	64	148.2	179.7	134.3	994.8	82.9	179.7
30	1998	101	216.6	201.4	158.8	97.4	11	1	1.2	23	186.8	138.8	44.2	1181.2	98.4333333	216.6
31	1999	177	352.4	169.6	79.6	94.6	134.6	23.9	11.7	200.9	110.7	188.5	281.4	1824.9	152.075	352.4
32	2000	87.3	257.6	206.2	92.2	83	27.6	4.2	26.4	189.6	14.8	39.4	172	1200.3	100.025	257.6
33	2001	326.8	179	309.6	104.4	61.8	8.1	18.4	2.8	73.8	121.2	245.8	213.9	1665.6	138.8	326.8
34	2002	63.2	150	306.4	214.2	38.4	13.8	16.4	0.8	43.2	195.2	150	246.2	1437.8	119.816667	306.4
35	2003	135.2	102.4	209.6	87.8	135.2	0.2	0	0	59.6	109.2	240.4	186.3	1265.9	105.491667	240.4
36	2004	99.3	94.2	232.9	119.6	60.9	5.8	0.3	8.6	93.2	156.1	333.2	336.3	1540.4	128.366667	336.3
37	2005	186.7	201.7	394.7	199.1	66.8	19.3	13.7	10.9	48	279.4	77.5	233.4	1731.2	144.266667	394.7
38	2006	105.2	258.3	327.1	157.2	13	58.4	11.7	3.5	34.3	130.8	190.3	339.9	1629.7	135.808333	339.9
39	2007	147.1	78	244.3	195.6	71.1	3.3	23.6	32.8	27.4	274.3	252.7	147.3	1497.5	124.791667	274.3
40	2008	118.75	368.98	268.64	193.18	75.79	26.02	3.05	4.54	60.01	206.64	79.4	145.23	1550.23	129.185833	368.98
41	2009	348.41	130.01	205.05	132.47	51.68	50.58	10.41	11.81	28.8	82.63	158.36	302.55	1512.76	126.063333	348.41
42	2010	91.3	105.85	211.57	135.15	75.22	20.98	33.03	4.55	18.75	217.6	278.85	187.312258	1380.16226	115.013522	278.85
43	2011	316.12	164.87	223.6	147.68	13.08	44.63	10.97	21.13	12.67	77.46	174.77	241.62	1448.6	120.716667	316.12
44	2012	178.29	133.36	121.84	72.71	70.43	25.29	1.11	9.65	14.7	16.83	153.59	179.43	977.23	81.4358333	179.43
45	2013	75.34	192.09	122.66	80.08	120.48	29.87	41.72	15.13	32.23	152.76	98.48	119.9	1080.74	90.0616667	192.09
46	2014	96.38	114.57	80.12	91.94	65.24	67.52	7.93	11.93	41.38	96.89	9.89	45.01	728.8	60.7333333	114.57
47	2015	224.69	214.86	99.7	87.03	92.57	14.09	56.68	6.88	8.28	158.25	231.9	269.26	1464.19	122.015833	269.26
48	2016	144.18	177.39	178.47	107.56	63.1	41.86	10.18	2.28	70.13	173.96	238.47	179.15	1386.73	115.560833	238.47
49	2017	136.55	78.91	266.66	128.54	121.21	21.39	10.57	8.99	12.15	85.45	49.25	139.78	1059.45	88.2875	266.66
50	2018	162.72	87.74	191.87	117.56	64.82	20.6	10.73	4.77	27.69	221.96	190.78	303.75	1404.99	117.0825	303.75
51	2019	77	153.3	337.76	179.97	88.12	7.83	1.33	2.68	33.7	181.16	206.68	254.58	1524.11	127.009167	337.76
52	2020	100.22	124.29	272.97	164.15	79.68	11.12	2.92	5.3	37.01	60.65	223.74	256.51	1338.56	111.546667	272.97
53	2021	162.7	57.41	197.02	104.19	118.04	0.21	3.08	4.94	15.64	217.2	211.58	293.03	1385.04	115.42	293.03
54	2022	199.91	169.02	157.26	150.03	56.89	53.27	2.81	6.16	15.95	110.99	221.54	186.37	1330.2	110.85	221.54
55	2023	142.67	234.74	76.81	108.92	68.4	0.78	0.95	3.76	13.94	83.29	125.98	202.23	1062.47	88.5391667	234.74
56	2024	135.21	118.25	62.96	133.01	74.61	85.8	125.01	35.26	15.69	150.66	18.71	96.11	1051.28	87.6066667	150.66

PROMEDIO	139.525893	160.567679	204.435179	137.247143	68.1580357	26.2005357	11.4228571	8.03053571	45.6869643	141.220179	146.915357	185.15754	1274.5679	106.213991	262.849643
P. MÁXIMA	348.41	368.98	394.7	293.18	135.2	134.6	125.01	35.26	200.9	279.4	333.2	339.9	1824.9		394.7
P. MÍNIMA	43.34	53.75	56.45	72.71	7.74	0	0	0	7.6	14.8	9.89	44.2	728.8		114.57
D. ESTÁNDAR	69.0125948	73.1610305	86.9227383	50.7329609	27.8306736	27.9342541	19.9956852	8.31168672	40.8581253	61.5176835	76.0014023	82.5643662	259.121301		63.7680272

Anexo O. Código de programación para la generación de Isoyetas a partir de la regionalización.

```
# Script: Generación de Isoyetas a partir de la Regionalización Hidroclimática
# Autor:Kevin Omar Chavez Sanchez
# Fecha: 2025
# Descripción: Desarrollo de isoyetas a partir de la regionalizacion
#Este script genera un mapa de isoyetas (líneas de igual precipitación) a partir de datos de estaciones
    meteorológicas regionalizadas
# mediante un análisis de Clustering Jerárquico.
## === 1. Importación de librerías necesarias ===
import pandas as pd
import geopandas as gpd
import matplotlib.pyplot as plt
import numpy as np
from scipy.interpolate import griddata

# === 2. Carga del archivo CSV con datos de precipitación ===
# El archivo debe contener las siguientes columnas:
# NOMBRE_DE_ESTACION, LATITUD, LONGITUD, PP_ACUM_ANUAL_PROM, GRUPO_HIDROLOGICO
data = pd.read_csv("PP_ACUM_ANUAL_PROM.csv", sep=";")
# Eliminamos columnas vacías o innecesarias
data = data.dropna(axis=1, how="all")
# Convertimos la columna de grupo a tipo entero (si hay nulos, se eliminan)
data = data.dropna(subset=["GRUPO_HIDROLOGICO"])
data["GRUPO_HIDROLOGICO"] = data["GRUPO_HIDROLOGICO"].astype(int)
# === 3. Creación de un GeoDataFrame ===
gdf = gpd.GeoDataFrame(
    data,
    geometry=gpd.points_from_xy(data["LONGITUD"], data["LATITUD"]),
    crs="EPSG:4326" # Sistema de coordenadas geográficas WGS84
)
# === 4. Interpolación espacial de la precipitación ===
# Se genera una grilla de puntos para interpolar los valores de precipitación.
lon = np.linspace(gdf["LONGITUD"].min(), gdf["LONGITUD"].max(), 200)
lat = np.linspace(gdf["LATITUD"].min(), gdf["LATITUD"].max(), 200)
lon_grid, lat_grid = np.meshgrid(lon, lat)
# Interpolación mediante el método cúbico
```

```

pp_grid = griddata(
(gdf["LONGITUD"], gdf["LATITUD"]),
gdf["PP_ACUM_ANUAL_PROM"],
(lon_grid, lat_grid),
method="cubic")
# === 5. Generación del mapa de Isoyetas ===
plt.figure(figsize=(10, 8))
# Relleno de isoyetas con gradiente de color
contours = plt.contourf(lon_grid, lat_grid, pp_grid, cmap="viridis", levels=15)
plt.colorbar(contours, label="Precipitación anual promedio (mm)")
# Añadimos las estaciones meteorológicas al mapa
plt.scatter(
gdf["LONGITUD"], gdf["LATITUD"],
c=gdf["GRUPO_HIDROLOGICO"], cmap="tab10",
s=60, edgecolor="k")
# Etiquetamos cada punto con su grupo hidroclimático
for _, row in gdf.iterrows():
plt.text(row["LONGITUD"], row["LATITUD"],
str(row["GRUPO_HIDROLOGICO"]),
fontsize=8, color="white", ha="center")
# === 6. Título y etiquetas ===
plt.title("Isoyetas obtenidas a partir de la regionalización")
plt.xlabel("Longitud")
plt.ylabel("Latitud")
# === 7. Visualización del mapa ===
plt.show()
# =====
# Fin del Script
# =====

```