



Universidad Nacional Mayor de San Marcos

Universidad del Perú. Decana de América

Facultad de Ciencias Físicas

Escuela Profesional de Ingeniería Mecánica de Fluidos

**Regionalización del modelo modificado de lluvia
estocástica Pulso Rectangular de Bartlett-Lewis para el
Perú**

MONOGRAFÍA TÉCNICA

Para optar el Título Profesional de Ingeniero Mecánico de Fluidos

AUTOR

José Augusto ZEVALLOS RUIZ

Lima, Perú

2022



Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

Usted puede distribuir, remezclar, retocar, y crear a partir del documento original de modo no comercial, siempre y cuando se dé crédito al autor del documento y se licencien las nuevas creaciones bajo las mismas condiciones. No se permite aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros a hacer cualquier cosa que permita esta licencia.

Referencia bibliográfica

Zevallos, J. (2022). *Regionalización del modelo modificado de lluvia estocástica Pulso Rectangular de Bartlett-Lewis para el Perú*. [Monografía técnica de pregrado, Universidad Nacional Mayor de San Marcos, Facultad de Ciencias Físicas, Escuela Profesional de Ingeniería Mecánica de Fluidos]. Repositorio institucional Cybertesis UNMSM.

Metadatos complementarios

Datos de autor	
Nombres y apellidos	José Augusto Zevallos Ruiz
Tipo de documento de identidad	DNI
Número de documento de identidad	46090610
URL de ORCID	https://orcid.org/0000-0002-6023-8665
Datos de asesor	
Nombres y apellidos	
Tipo de documento de identidad	
Número de documento de identidad	
URL de ORCID	
Datos del jurado	
Presidente del jurado	
Nombres y apellidos	Jorge Gastelo Villanueva
Tipo de documento	DNI
Número de documento de identidad	08434899
Miembro del jurado 1	
Nombres y apellidos	Jairo Pinedo Taquíá
Tipo de documento	DNI
Número de documento de identidad	44754057
Miembro del jurado 2	
Nombres y apellidos	Manuel Herquinio Arias
Tipo de documento	DNI
Número de documento de identidad	21288812
Miembro del jurado 3	
Nombres y apellidos	
Tipo de documento	DNI

Número de documento de identidad	
Datos de investigación	
Línea de investigación	-A.2.5.2. Recursos Hídricos
Grupo de investigación	
Agencia de financiamiento	PROPIA
Ubicación geográfica de la investigación	País: Perú Departamento: Lima Provincia: Lima Distrito: La Molina
Año o rango de años en que se realizó la investigación	2022
URL de disciplinas OCDE	Ingeniería mecánica https://purl.org/pe-repo/ocde/ford#2.03.01



Universidad Nacional Mayor de San Marcos
(Universidad del PERÚ, Decana de América)
FACULTAD DE CIENCIAS FÍSICAS

XIII CAP DE LA ESCUELA PROFESIONAL DE INGENIERÍA MECÁNICA DE FLUIDOS

ACTA DE SUSTENTACIÓN VIRTUAL DE LA MONOGRAFÍA TÉCNICA PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO MECANICO DE FLUIDOS, MODALIDAD DE TITULACIÓN M-3 – POR SUFICIENCIA PROFESIONAL

Siendo las 15:00 horas del día jueves 27 de octubre de 2022, en la Sala de Sesión Virtual de la Facultad de Ciencias Físicas, bajo la presidencia del Dr. Ing. JORGE LUIS GASTELO VILLANUEVA y con la asistencia de los miembros Mg. Ing. JAIRO PINEDO TAQUIA y el Ing. MANUEL HERQUINIO ARIAS, se dio inicio a la Sesión Pública Virtual de Sustentación de la Monografía Técnica para optar el Título Profesional de Ingeniero Mecánico de Fluidos, mediante la Modalidad de Titulación M-3 Por Suficiencia Profesional, del Bachiller:

JOSÉ AUGUSTO ZEVALLOS RUIZ

El Presidente del Jurado Examinador dio lectura del Resumen del Expediente, e invitó al Bachiller JOSÉ AUGUSTO ZEVALLOS RUIZ, a realizar la Exposición del trabajo de la Monografía Técnica titulada “REGIONALIZACIÓN DEL MODELO MODIFICADO DE LLUVIA ESTOCÁSTICA PULSO RECTANGULAR DE BARTLETT-LEWIS PARA EL PERÚ”.

Concluida la exposición del candidato y luego de las preguntas de rigor por parte del Jurado Examinador, el Presidente invitó al Bachiller a abandonar momentáneamente la sala de sesión para dar paso a la deliberación y calificación por parte del Jurado. Se procedió a promediar la nota final del curso de actualización y la nota de la sustentación para obtener la calificación final.

Al término de la deliberación del Jurado, se invitó al candidato a regresar a la sala de sesión para dar lectura a la calificación final obtenida por el Bachiller, la misma que fue:

Diecisiete (17)

El Presidente del Jurado Dr. Ing. JORGE LUIS GASTELO VILLANUEVA, a nombre de la Nación y de la Universidad Nacional Mayor de San Marcos, declaró al Bachiller JOSÉ AUGUSTO ZEVALLOS RUIZ Ingeniero Mecánico de Fluidos.

Siendo las 16.11 horas, del mismo día, se levantó la sesión.

Dr. Ing. JORGE LUIS GASTELO VILLANUEVA
PRESIDENTE DEL JURADO

Mg. Ing. JAIRO PINEDO TAQUIA
MIEMBRO DEL JURADO

Ing. MANUEL VICENTE HERQUINIO ARIAS
MIEMBRO DEL JURADO



UNMSM

Firmado digitalmente por LOZANO
BARTRA Whualkuer Enrique FAU
20148092282 soft
Motivo: Soy el autor del documento
Fecha: 05.11.2022 08:17:41 -05:00

DR. WHUALKUER ENRIQUE LOZANO BARTRA
VICEDECANO ACADÉMICO FCF

Datos de la plataforma virtual institucional del acto de sustentación:

<https://us06web.zoom.us/j/86031909483?pwd=Mkp0ZFBrays5dldNky9DNEI3UGg4UT09>

ID de reunión: 860 3190 9483

Código de acceso: 512430

Grabación archivada en el siguiente enlace:

https://drive.google.com/file/d/1PYD_wDWLbwaJZBerHdpQOTBpFEN335ay/view?usp=sharing

Anexo 1

Informe de evaluación de Originalidad

1. Facultad de Ciencias Físicas
2. Escuela/Unidad de Posgrado
Escuela Profesional de Ingeniería Mecánica de Fluidos
3. Autoridad Académica que emite el informe de originalidad
El Director de la EPIMF
4. Apellidos y nombres de la autoridad académica
Sarango Julca Douglas Donal
5. Operador del programa Informático de similitudes
Dr. Ing. Douglas Sarango Julca
6. Documento evaluado (1)
"REGIONALIZACIÓN DEL MODELO MODIFICADO DE LLUVIA ESTOCÁSTICA PULSO RECTANGULAR DE BARTLETT – LEWIS PARA EL PERÚ"
7. Autor del documento (2)
JOSÉ AUGUSTO ZEVALLOS RUIZ
8. Fecha de recepción del documento 8/10/22
9. Fecha de aplicación del programa informático de similitudes 11/10/22
10. Software utilizado
 - Turnitin (X)
 - Ithenticate
 - Otro (especificar)
11. Configuración del programa detector de similitudes
 - Excluye textos entrecomillados
 - Incluye Bibliografía
 - Excluye cadenas menores a 40 palabras
12. Porcentaje de similitudes según programa detector de similitudes³
9%
13. Fuentes originales de las similitudes encontradas⁴
14. Observaciones
Ninguna
15. Calificación de originalidad
 - Documento cumple criterios de originalidad, sin observaciones (X)
 - Documento cumple criterios de originalidad, con observaciones
 - Documento no cumple criterios de originalidad
16. Fecha del Informe 15 /11 /22



Firmado digitalmente por SARANGO
JULCA Douglas Donal FAU
20148092282 soft
Motivo: Soy el autor del documento
Fecha: 15.11.2022 22:54:14 -05:00

DR. ING. Douglas Sarango Julca
DIRECTOR (e) DE LA EPIMF

-
- 1 Otro (especificar) Monografía Técnica Modalidad de Titulación M-3
Suficiencia Profesional
 - 2 Apellidos y Nombres completos
 - 3 En letras y números
 - 4 Indicarlas en orden decreciente y su respectivo porcentaje

Contenido

Figuras y Tablas	3
Resumen	5
1. Introducción.....	6
1.1 Antecedentes.....	7
1.2. Justificación del trabajo	8
1.3. Objetivos.....	8
1.3.1. Objetivo general	8
1.3.2. Objetivos específicos.....	8
2. Zona de estudio y Datos	9
2.1. Zona de estudio.....	9
2.2. Información para el estudio	10
2.3 Limitaciones del estudio.....	11
3. Marco teórico.....	11
3.1. Modelo Modificado Pulso Rectangular de Bartlett-Lewis (MBLRP).....	11
3.1.1. Momentos estadísticos del modelo MBLRP	12
3.2. Estimadores estadísticos muestrales	13
3.3. Interpolación Distancia Inversa Ponderada (IDW)	15
3.4. Método de interpolación Kriging Ordinario (OK)	17
4. Metodología.....	21
4.1. Estadísticos de precipitación	22
4.2. Estimación de Parámetros del modelo MBLRP	25
4.3. Método Evolutivo de Recocido Simplex (AES)	26
4.4. Descripción del problema de multimodalidad y validaciones cruzadas repetitivas para la estimación de los parámetros MBLRP.	34
4.5. Interpolación espacial de los parámetros MBLRP	37
5. Resultados y Discusión.....	37
5.1. Mapas regionales de parámetros MBLRP	37
5.2. Evaluación de los resultados regionalizados	39
5.3. Evaluación de la regionalización con datos del proyecto Tocache	41
5.4. Mapas de caracterización de tormentas con el MBLRP para la zona de estudio	43
5.5. Precipitaciones simuladas.....	44
6. Conclusiones.....	45
Bibliografía.....	47

Figuras y Tablas

Figura 1 Ubicación de la zona de estudio junto con las ubicaciones de las estaciones pluviométricas utilizadas en la regionalización en color azul. Además, con flechas naranjas se indica las estaciones pluviométricas del proyecto Ochoa-Tocachi.....	9
Figura 2 Modelo modificado Pulso Rectangular de Bartlett-Lewis imagen adapta del modelo de Rodríguez Iturbe et al. (1988).....	12
Figura 3 Diagrama de interpolación espacial	15
Figura 4 Distribución espacial del parámetro μx para 6 estaciones y el punto s_0	16
Figura 5 Variograma esférico con pepita 0, rango de 5 kilómetros y umbral 0.008	19
Figura 6 Flujo de trabajo para la regionalización del modelo MBLRP	22
Figura 7 Función no lineal como un mínimo local y un mínimo global	34
Figura 8 Representación de una misma tormenta particular con diferentes juegos de parámetros A y B.....	35
Figura 9 Grupo de estaciones separadas por menos de 60 km de distancia. El valor indicado corresponde al parámetro μx obtenidos con AES.	35
Figura 10 Parámetros regionalizados del modelo MBLRP para el mes de febrero	37
Figura 11 Impacto de las validaciones cruzados en la estimación de parámetros MBLRP. Los mapas del parámetro μ después de la interacción 0 hasta 5.....	38
Figura 12 Comparación de los estadísticos observados y los simulados a partir de validación cruzada. Cada fila corresponde a un nivel de acumulación y las columnas representan un diferente tipo de estadístico de precipitación	40
Figura 13 Función de densidad acumulada (CDF) de series de precipitación simulada y observada para el acumulado de 3 horas. Los valores considerados son mayores a cero y corresponden al mes de febrero para las estaciones de la Tabla 1	42
Figura 14 Características de tormentas y celdas para el mes de febrero acorde a los parámetros del modelo MBLRP	43
Figura 15 Precipitaciones simuladas para la estación Namora. Cada grafico indica el agregado de simulación 1, 6,12 y 24 horas.	45
Figura 16 Parámetros del modelo MBLRP para el mes de enero	67
Figura 17 Parámetros del modelo MBLRP para el mes de marzo	68
Figura 18 Serie de tiempo de las precipitaciones diarias en la estación Canaveral	95
Figura 19 Serie de tiempo de las precipitaciones diarias en la estación Matucana.....	95
Figura 20 Serie de tiempo de las precipitaciones diarias en la estación Celendín	96
Figura 21 Serie de tiempo de las precipitaciones diarias en la estación Paucartambo..	96

Tabla 1 resultados del análisis de saltos y tendencias con el software trend para la estación Chulucanas	10
Tabla 2 Estaciones pluviométricas automáticas del Proyecto de Ochoa-Tocachi.....	10
Tabla 3 Datos de precipitación de una estación pluviométrica	13
Tabla 4 Proceso de cálculo de interpolación del parámetro μx para la ubicación s0. ..	16
Tabla 5 Distancias entre las 6 estaciones de la Figura 4 . Los valores están en metros. 19	19
Tabla 6 Desagregación de los valores diarios de la estación Chulucanas para el mes de febrero del año 2000	23
Tabla 7 Resultados estadísticos para agregados de 24 horas para algunas estaciones ..	24
Tabla 8 Resultados estadísticos para agregados de 3 horas para algunas estaciones	24
Tabla 9 Resultados de la optimización con AES para el cálculo de parámetros MBLRP de la estación Chulucanas.....	33
Tabla 10 Validación cruzada de los parámetros MBLRP obtenidos con AES.	36
Tabla 11 Resultados del test de KS de la validación independiente.....	41
Tabla 12 Juego de parámetros MBLRP de estación Namora de Cajamarca para el mes de febrero	43

Resumen

La necesidad de conocer las características de precipitaciones cuya duración es menor a 24 horas es vital para el dimensionamiento de obras hidráulicas en el Perú. Sin embargo, la información pluviométrica con resoluciones temporales de 1 hora disponibles en el Perú es escasa o de existir tiene registros muy cortos, calidad deficiente y una baja distribución espacial a nivel Nacional.

En este trabajo se explora la posibilidad de simular precipitaciones sub diarias (ejemplo 1 hora de duración) a nivel Nacional utilizando el modelo pulso rectangular modificado de Barlett-Lewis (MBLRP). El modelo MBLRP es un modelo estocástico que conceptualiza las tormentas como un grupo de bloques cuyas duraciones e intensidades son aleatorias entre ellas. Para poder calibrar este modelo se necesita que las series simuladas reproduzcan las características estadísticas de la precipitación medidas con pluviómetros para diferentes duraciones. Debido a que solo se cuenta con información pluviométrica de resolución diaria se requirió utilizar datos satelitales del producto TRMM para poder estimar características de precipitaciones sub diarias y así poder introducir estas características al modelo MBLRP. Además, se utilizó el método de validaciones cruzadas repetitivas para considerar la influencia de las estaciones vecinas a nivel regional.

Como principales resultados se obtuvieron mapas de los parámetros del modelo MBLRP para los meses más lluviosos del Perú, los cuales son enero, febrero y marzo. Estos mapas nos permitirán simular precipitaciones sub diarias a nivel Nacional. Además, se pudo estimar características de tormentas como el promedio de duraciones de estas y sus altura de precipitaciones.

1. Introducción

La sociedad actual se ha desarrollado en base a la gestión de los recursos hídricos, esta gestión requiere de información in situ, actual y verídica. Como no se puede retroceder en el tiempo, no se puede tener una información que atienda esta necesidad, pero si es posible producir información que se acerque a esas condiciones.

El recurso hídrico que se encuentra en la tierra es tan disperso debido a la precipitación que es la forma como se produce. La precipitación es una información de suma importancia para toda las aplicaciones de la sociedad, dentro de ello, la ingeniería y la hidrología, para el riego, para los sistemas hidro energéticos, para los sistemas de drenaje, gestiones de riesgo de inundación, así como otras más (P. S. Cowpertwait, 2006; Kossieris, Panagiotis and Makropoulos, Christos and Creaco, Enrico and Vamvakeridou-Lyroudia, Lydia and Savic, 2016). Estas aplicaciones requieren un amplio conocimiento de las características de las precipitaciones en diferentes escalas temporales.

Las características de las precipitaciones se obtienen de la información cuantificada de estas, sin embargo, es mala debido a la baja densidad de estaciones pluviométricas y registros de precipitación. La información escasa que se tiene es la mensual pero las diarias y sub diarias son más limitados, podría ser una justificación su alto costo de instalación y mantenimiento. Esta situación es aún más difícil en países en desarrollo como el nuestro donde la información es escasa e inclusive no es de libre disposición al público (Nerini et al., 2015; Yusop et al., 2014).

En nuestro país se agrava esta condición porque existe una fuerte variabilidad espacial y temporal de las precipitaciones impuestas por la topografía compleja de la cordillera de los Andes (Dinku et al., 2008; R. D. Garreaud et al., 2009; Scheel et al., 2011). Además de la presencia de los fenómenos climáticos como el fenómeno del Niño (ENSO), la Niña y los monzones del norte, etc. (Abbühl et al., 2010).

Esta realidad dificulta la inferencia confiable en estimaciones de patrones espaciales, así como también de la distribución temporal necesaria para caracterizaciones de precipitación extremas (Mantas et al., 2015). Es obvio que bajo estas condiciones se requiere de una alta densidad de estaciones pluviométricas distribuidas estratégicamente, con altísima calidad de recolección de datos (Hunziker et al., 2018).

El avance de la tecnología y la ciencia hidrológica hace posible aproximar valores como solución a la falta de información sobre todo las precipitaciones horarias mediante simulaciones estocásticas de series temporales con características similares a las presentadas por precipitaciones reales. Uno de los métodos más utilizados es el **modelo de pulso rectangular modificado de Bartlett-Lewis** (MBLRP), este método genera series de tiempo de precipitación con el supuesto de que las tormentas están conformadas por grupos de celdas con duración e intensidad aleatoria acorde a un proceso de Poisson (Kossieris et al., 2018; Ritschel et al., 2017).

En este estudio se desarrolla para el Perú una base de datos mensuales del modelo MBLRP para los meses de enero, febrero y marzo, en total se obtuvo 18 mapas para el territorio peruano, **Figura 10** y **anexo D**. Estos mapas permiten generar series temporales de precipitación sub diaria para cualquier ubicación de la zona de estudio utilizando el modelo MBLRP, utilizando el programa Hyetos.

Este trabajo tiene el propósito de regionalizar parámetros de MBLRP para la obtención de características de precipitación sub diaria como: patrones regionales, la duración de las tormentas, la separación temporal entre ellas y la altura media de precipitación por tormenta. Estas características darán una mayor comprensión de la variación espacial y temporal de las precipitaciones en el Perú, como continuación a la tesis desarrollada por Zevallos (2018) donde determina parámetros del MBLRP sin considerar la influencia regional de las estaciones sobre territorio nacional del Perú.

1.1 Antecedentes

Los parámetros calculados de las series simuladas por el modelo de pulso rectangular modificado de Bartlett-Lewis (MBLRP) han demostrado ser capaces de coincidir con estadísticas de precipitación observada desde una resolución fina (5 minutos) hasta para diferentes niveles de escalas de tiempo (24 horas). Unas muestras de aplicaciones son las simulaciones de agua residencial mencionadas en Kossieris (2016), otra es la estimación de riesgos de inundación (Wheater et al., 2005) y deslizamiento de tierras (Bathurst et al., 2005).

Anteriormente para el análisis de precipitaciones sub diarias (horarias) se ha realizado estudios en áreas localizadas como la cuenca del Vilcanota utilizando información satelital y registros de algunas estaciones pluviométricas con información horaria disponible.

Llauca et al. (2021) evaluó en la cuenca del Vilcanota para diferentes productos satelitales de precipitación, cual de estos simula mejor la escorrentías, utilizando como instrumento de comparación el modelo hidrológico GR4H. Identifica indirectamente con modelamiento hidrológico las bondades de estas alternativas de medición de precipitación sub diaria. Sin embargo, como se ha mencionado en la introducción, la disponibilidad de información pluviométrica con resolución temporal horaria es escasa a nivel nacional como para realizar este tipo de estudio para todo el Perú. Además, no se evalúa directamente la medición sino a través de una respuesta ya procesada como es la escorrentía mediante un modelo hidrológico, los cuales son optimizados considerando otros parámetros aparte de la precipitación.

Zevallos (2018) exploró la posibilidad de obtener curvas de intensidad, duración y frecuencia (IDF) a partir de simulaciones estocásticas con el modelo MBLRP. Entre sus conclusiones se menciona que los parámetros obtenidos en calibración del modelo MBLRP dependen mucho de los estadísticos que se utilizan en el método de los momentos. Agrega también que para tener una mayor confianza en las curvas IDF obtenidas a partir de simulaciones estocásticas, los resultados deben presentarse en intervalos de confianza obtenidos de los cuantiles de múltiples simulaciones estocásticas de precipitación. A pesar de ello, el trabajo solo valida el método empleado con la estación (Toquepala) ubicada en Moquegua además de no considerar una

influencia regional en la calibración del modelo MBLRP. Esto conlleva a cierta inconsistencia espacial en las curvas IDF obtenidas.

1.2. Justificación del trabajo

La variabilidad climática requiere de información sub diaria para la prevención de desastres, sequías, adecuación de estructuras de drenaje, etc. En el Perú existe bases de datos de pluviometría diaria que sirvieron recientemente para la creación de la base grillada de precipitación distribuida a nivel nacional llamada PISCO (Aybar et al., 2019). Sin embargo, cuando se requiere de información de precipitaciones con resolución temporal horario, estos no están disponibles o de existir tiene registros cortos.

Bajo este contexto, el presente trabajo amenguará esta necesidad, producto de una metodología basada en simulaciones estocásticas, información satelital y pluviométrica diaria, simulando precipitaciones sub diarias en el Perú de manera regional.

1.3. Objetivos

1.3.1. Objetivo general

- Desarrollar mapas con parámetros regionalizados del tipo MBLRP que determinen las precipitaciones sub diarias para el Perú.

1.3.2. Objetivos específicos

- Desagregar la información pluviométrica diaria a información sub diaria (3, 6, 12, 18 y 24 horas)
- Determinar los estadísticos de precipitación: promedio, varianza, auto covarianza y la probabilidad de lluvia cero para el agregado de 24 horas además de las varianzas y auto covarianzas para los agregados de 3, 6, 12 y 18 horas.
- Estimar los parámetros del modelo MBLRP con el método evolutivo de recocido simplex (AES) y refinados con validaciones cruzadas repetitivas para las estaciones pluviométricas.
- Determinar los mapas de caracterización de tormentas con el MBLRP para la zona de estudio

2. Zona de estudio y Datos

2.1. Zona de estudio

La zona de estudio tratara para el territorio nacional del Perú, el cual está ubicado entre las longitudes 68°- 82°W y las latitudes 0-18°S, **Figura 1**.

La cadena montañosa de los Andes causa que los climas sean muy variables, delimitando al Perú en tres vertientes hidrográficas (Pacífico, Amazonas y Titicaca). El clima también se ve influenciado por la corriente fría de Humboldt, la cual junto con los andes son los principales responsables de las condiciones secas de la costa con las excepciones cuando se presenta el fenómeno El Niño (ENSO). Siendo este último el causante de tormentas convectivas severas en la costa norte del país (Antico, 2009; R. D. Garreaud et al., 2009; Lavado Casimiro et al., 2012).

La influencia orográfica causada por la topografía sobre gran parte del clima peruano genera que se presenten precipitaciones convectivas, mayores a los 500 mm/año, en la vertiente oriental de los Andes por la canalización de la humedad proveniente del Amazonas (R. Garreaud, 1999). Así mismo, la Zona de Convergencia Intertropical (ITCZ) determina marcadas temporadas húmedas durante el verano austral en la mayor parte del Perú producto del transporte de masas húmedas desde el Atlántico hacia la cuenca del Amazonas (Marengo et al., 2012).




Figura 1 Ubicación de la zona de estudio junto con las ubicaciones de las estaciones pluviométricas utilizadas en la regionalización en color azul. Además, con flechas naranjas se indica las estaciones pluviométricas del proyecto Ochoa-Tocachi

2.2. Información para el estudio

2.2.1. Información pluviométrica

Para este estudio se cuenta con información de 203 pluviómetros de la red de estaciones de SENAMHI. Estos datos cuentan ya con un control de calidad previo el cual consistió en detección de quiebres y tendencias de medias **Anexo L**. En la **Tabla 1** se muestra los resultados del análisis de saltos y tendencias realizado con el software Trend para la estación Chulucanas. Se utilizó 3 test (Mann-Kendall, Regresión líneas, y el estadístico t) para evaluar la calidad de los datos.

Tabla 1 resultados del análisis de saltos y tendencias con el software trend para la estación Chulucanas

Test estadístico	Valores Críticos	Significancia			Resultados
		a=0.1	a=0.05	a=0.01	
Mann-Kendall	0.604	1.645	1.96	2.576	NS
Regresión lineal	0.728	1.653	1.972	2.602	NS
Student's t	-0.831	1.653	1.972	2.602	NS

Las estaciones pluviométricas a usar, en total 203 se muestran la denominación y ubicación en el **Anexo A**, estas estaciones se encuentran distribuidas espacialmente dentro de la zona de estudio tal como se muestra en la **Figura 1**, esta información data desde el periodo 1999-2014, a resolución temporal de un dato diario. Se seleccionó este periodo de tiempo ya que es el rango de fechas en común de registro entre el satélite TRMM 3b42 y los datos pluviométricos de SENAMHI.

Otra fuente de información pluviométrica en este caso automática son las estaciones del proyecto de Ochoa-Tocachi et al (2018) **Tabla 2**, que cuenta con precipitación de resolución horaria con periodos de entre 4 y 5 años, estas se usarán de forma independiente para la evaluación de los resultados de la regionalización del modelo MBLRP en su entorno.

Tabla 2 Estaciones pluviométricas automáticas del Proyecto de Ochoa-Tocachi

Longitud	Latitud	Estaciones
-79.45453	-4.95029	PIU_02
-79.65777	-5.04513	PIU_06
-79.85517	-4.94695	PIU_07
-77.75584	-6.35189	CHA_01
-77.3569	-9.68681	HUA_01
-76.75021	-11.45494	HMT_01

2.2.2. Información de precipitación satelital TRMM

Este trabajo operacionaliza una desagregación de datos entre la información pluviométrica e información satelital, recopilados de TRMM 3b42 versión 7 se encuentran entre los años 1999-2014. Estos datos son de resolución temporal de 3 horas y espacialmente los pixeles son de 0.25° x 0.25° https://disc.gsfc.nasa.gov/datasets/TRMM_3B42_7/summary, Huffman et al. (2007).

2.3 Limitaciones del estudio

Este estudio de circunscribe a desarrollar los parámetros del modelo MBLRP. Su aplicación se hace a través del software Hyetos. El desarrollo y el aplicativo son limitaciones por las condiciones del software. Que podrán acceder a través del link <https://www.itia.ntua.gr/en/softinfo/3>.

3. Marco teórico

3.1. Modelo Modificado Pulso Rectangular de Bartlett-Lewis (MBLRP)

El modelo MBLRP tiene la función principal de dar la forma de bloques para cuantificar la distribución temporal de las precipitaciones de este trabajo.

Esto es posible ya que las estructuras de precipitación tienen la tendencia a no ser constantes durante su desarrollo, sino que se comportan como pequeños grupos de pulsos o bloques durante su duración (tiempo de duración de la tormenta). El inicio de las tormentas y de los pulsos que las conforman se puede describir con un proceso de Poisson. El Proceso de Poisson es un modelo estocástico, describe una serie de eventos discretos, como las tormentas, donde se conoce el tiempo promedio entre tormentas, pero el tiempo exacto entre ellas es aleatorio.

Esta conceptualización de las tormentas apertura condiciones a la selección natural del modelo MBLRP para la simulación de estas tormentas (Ritschel et al., 2017).

El modelo MBLRP presentado por Rodríguez Iturbe et al. (1988) es la convolución de diferentes distribuciones estadísticas y consta de 6 parámetros independientes, ver **Figura 2**. Los seis parámetros del modelo MBLRP son λ , μ_x , κ , ϕ , α y ν . Los inicios de las tormentas en el modelo MBLRP se generan acorde a una distribución de Poisson cuyo parámetro de tasa es λ , la unida de esta tasa es $horas^{-1}$, el tiempo promedio entre las ocurrencias de las tormentas se calcula como $\frac{1}{\lambda}$ y se mide en horas; Las tormentas a su vez están compuestas por grupos de celdas, estas celdas se generan en el interior de una tormenta también con un proceso de Poisson, pero con una tasa de tiempo β $horas^{-1}$. El parámetro μ_x determina la altura promedio de las celdas y permanece constante durante el tiempo de vida estas, su unidad de medida es milímetros (mm) y obedece a una distribución exponencial. La duración de las celdas esta dado por el parámetro η , el cual obedece a una distribución gama, esta distribución gama consta de un parámetro de forma α y uno de escala $1/\nu$; El primero es adimensional mientras que ν esta en unidades de $horas^{-1}$, estos dos últimos parámetros no tienen una interpretación física clara, sin embargo, usando las propiedades de la distribución gamma se puede calcular la duración promedio de las celdas con la siguiente expresión $\frac{\alpha}{\nu}$. Por último, la duración de la tormenta es representada con el parámetro γ que obedece a una distribución exponencial y tiene unidades $horas^{-1}$. Por facilidad en el

tratamiento matemático del modelo se suele utilizar ratios adimensionales $\phi = \gamma/\eta$ y $\kappa = \beta/\eta$ como parámetros en vez de γ y β .




Figura 2 Modelo modificado Pulso Rectangular de Bartlett-Lewis imagen adapta del modelo de Rodríguez Iturbe et al. (1988)

3.1.1. Momentos estadísticos del modelo MBLRP

Para la obtención de los parámetros se parte de los momentos estadísticos que formula Rodríguez Iturbe et al. (1988) de las estadísticas de las precipitaciones sintéticamente generadas en un intervalo de acumulación T son:

$$E[Y_t^T] = \text{Valor esperado de la precipitación simulada}$$

$$\text{Var}[Y_t^T] = \text{Varianza de la precipitación simulada}$$

$$\text{Cov}[Y_t^T, Y_{t+s}^T] = \text{Auto covarianza de la precipitación simulada}$$

$$P_t^T [Y_t^T = 0] = \text{Probabilidad de periodos secos}$$

La relación de los estadísticos del modelo MBLRP en función de sus 6 parámetros $\lambda, \mu_x, \kappa, \phi, \alpha$ y ν son:

$$k_1 = \left(2\lambda\mu_c\mu^2 + \frac{\lambda\mu_c\kappa\phi\mu^2}{\phi^2 - 1} \right) \left(\frac{\nu^\alpha}{\alpha - 1} \right)$$

$$k_2 = \left(\frac{\lambda\mu_c\kappa\phi\mu^2}{\phi^2 - 1} \right) \left(\frac{\nu^\alpha}{\alpha - 1} \right)$$

$$\mu_c = 1 + \frac{\kappa}{\phi}$$

$$E[Y_t^T] = \lambda\mu_x\mu_c \frac{\nu}{\alpha - 1} T \quad (1)$$

$$\text{Var}[Y_t^T] = \frac{2\nu^{2-\alpha}T}{\alpha - 2} \left(k_1 - \frac{k_2}{\phi} \right) - \frac{2\nu^{3-\alpha}}{(\alpha - 2) - (\alpha - 3)} \left(k_1 - \frac{k_2}{\phi} \right) + \frac{2}{(\alpha - 2)(\alpha - 3)} \left[k_1(T + \nu)^{3-\alpha} - \frac{k_2}{\phi^2} (\phi T + \nu)^{3-\alpha} \right] \quad (2)$$

$$\text{Cov}[Y_t^T, Y_{t+s}^T] = \frac{k_1}{(\alpha - 2)(\alpha - 3)} \{ [T(s - 1) + \nu]^{3-\alpha} + [T(s + 1) + \nu]^{3-\alpha} - 2(Ts + \nu)^{3-\alpha} \} + \frac{k_2}{\phi^2(\alpha - 2)(\alpha - 3)} \{ 2(\phi Ts + \nu)^{3-\alpha} - [\phi T(s - 1) + \nu]^{3-\alpha} - [\phi T(s + 1) + \nu]^{3-\alpha} \} \quad (3)$$

$$P_t^T [Y_t^T = 0] = \exp \left\{ -\lambda T - \frac{\lambda\nu}{\phi(\alpha - 1)} \left[1 + \phi(\kappa + \phi) - \frac{1}{4}\phi(\kappa + \phi)(\kappa + 4\phi) + \frac{\phi(\kappa + \phi)(4\kappa^2 + 27\kappa\phi + 72\phi^2)}{72} \right] \right\} + \quad (4)$$

$$\frac{\lambda v}{(\alpha-1)(\kappa+4\phi)} \left(1 - \kappa - \phi + \frac{3}{2}\kappa\phi + \phi^2 + \frac{\kappa^2}{2} \right) + \frac{\lambda v}{(\alpha-1)(\kappa+\phi)} \left[\frac{v}{v+(\kappa+\phi)T} \right]^{\alpha-1} \frac{\kappa}{\phi} \left(1 - \kappa - \phi + \frac{3}{2}\kappa\phi + \phi^2 + \frac{\kappa^2}{2} \right) \}$$

3.2. Estimadores estadísticos muestrales

Los estimadores estadísticos muestrales sirven para caracterizar a una información de datos con el uso de medidas representativas de una muestra aleatoria. Esto se hace con el objetivo de inferir patrones estadísticos. En este estudio se utilizó 4 estimadores muestrales, los cuales son los siguientes:

$$Promedio = \frac{1}{n} \sum_{j=1}^N X_j \quad (5)$$

$$Varianza = \frac{1}{n-1} \sum_{j=1}^N (X_j - \bar{X})^2 \quad (6)$$

$$Auto\ Covarianza = \frac{1}{n-1} \sum_{j=1}^{n-\tau} (X_j - \bar{X})(X_{j+\tau} - \bar{X}) \quad (7)$$

$$Proporcion\ de\ dias\ Secos = \frac{1}{n} \sum_{j=1}^N 1_{pp \leq 0.1}(X_j) \quad (8)$$

Donde:

- N número de datos en una estación
- X_j valor muestral de precipitación de una estación j
- τ desfase temporal para el cálculo de la auto covarianza
- $1_{pp \leq 0.1}$ función indicadora de los días que presentan lluvias menores a 0.1 mm.

En la **Tabla 3** muestra una aplicación de datos de precipitación para los 20 primeros días de febrero del año 1999. Se estima el promedio, varianza, auto covarianza y la proporción de días secos ($pp = 0$) para dichos datos, con resolución temporal diaria, es decir un registro cada 24 horas.

Tabla 3 Datos de precipitación de una estación pluviométrica

fecha	Precipitación
1/02/1999	0
2/02/1999	0
3/02/1999	0
4/02/1999	0.1
5/02/1999	1
6/02/1999	0
7/02/1999	0
8/02/1999	0
9/02/1999	0

10/02/1999	3.3
11/02/1999	4.3
12/02/1999	6
13/02/1999	10.9
14/02/1999	1.8
15/02/1999	5.7
16/02/1999	17
17/02/1999	0.2
18/02/1999	0
19/02/1999	0
20/02/1999	0.3

Aplicando las fórmulas del ítem 3.2 para el cálculo de estadísticos muestrales se obtiene lo siguiente:

$$\text{Promedio de 24 horas} = \frac{1}{20} \sum_{j=1}^{20} X_j = 2.53 \text{ mm}$$

$$\text{Varianza de 24 horas} = \frac{1}{20-1} \sum_{j=1}^{20} (X_j - 2.53)^2 = 20.10 \text{ mm}^2$$

Para la auto covarianza se define el desfase temporal, τ , el cual corresponde a la unidad de la resolución temporal de la muestra. Para estos datos diarios, τ tiene el valor de un día de desfase. Por lo que la ecuación quedaría como:

$$\text{Auto Covarianza de 24 horas} = \frac{1}{19} \sum_{j=1}^{20-1} (X_j - 2.53)(X_{j+1} - 2.53) = 5.33 \text{ mm}^2$$

Para la probabilidad de días secos se tiene que cuantificar el número de días secos, dentro del periodo de la muestra y dividirlo entre el total del número de datos en dicho periodo. Consideraremos según Kim et al. (2016) las precipitaciones menores o iguales a 0.1 milímetros como precipitación 0, los resultados de este proceso para los datos de la **Tabla 3** es:

$$\text{Probabilidad de días secos 24 horas} = 50 \% = 0.5$$

Es decir que 10 días no precipito durante ese periodo.

3.3. Interpolación Distancia Inversa Ponderada (IDW)

El IDW es un método determinístico de interpolación espacial de datos (Shepard, 1968). Se procede estimando los valores en puntos desconocidos utilizando combinaciones ponderadas de un conjunto de datos vecinos a los puntos a estimar. Los valores de la ponderación suponen que los datos espacialmente más cercanos a la ubicación a estimar tienen mayor influencia en el cálculo.

Sea $g(s)$ la distribución espacial de las estaciones pluviométricas:

$$g(s) = [g(s_1), g(s_2), \dots, g(s_N)]$$

Donde, N representa el número pluviómetro disponible y s_i las coordenadas espaciales (x, y) de las N estaciones. La propiedad estimada $\hat{p}(s_0)$ en una ubicación dada por s_0 se calcula con:

$$\hat{p}(s_0) = \begin{cases} g(s_i) & \text{si } d(s_0, s_i) = 0 \text{ para los } i \\ \frac{\sum_{i=1}^N w_i g(s_i)}{\sum_{i=1}^N w_i} & \text{si } d(s_0, s_i) \neq 0 \text{ para todos los } i \end{cases} \quad (9)$$

Donde los pesos ponderados w_i y la distancia entre la ubicación de interpolación y de la observación, $d(s_0, s_i)$, se relacionan inversamente con la siguiente ecuación:

$$w_i = \frac{1}{d(s_0, s_i)^\beta}$$

Shepard (1968) señala que para valores de $\beta = 2$ han mostrado anteriormente resultados empíricos satisfactorios para el mapeo de variables espacialmente.

Así en la **Figura 3** para estimar el valor de la propiedad en *el punto a interpolar* utilizando IDW, la expresión matemática sería la siguiente:

$$\hat{p}(s_0) = \frac{\frac{1}{d_1^2} * P(s_1) + \frac{1}{d_2^2} * P(s_2) + \frac{1}{d_3^2} * P(s_3)}{\frac{1}{d_1^2} + \frac{1}{d_2^2} + \frac{1}{d_3^2}}$$

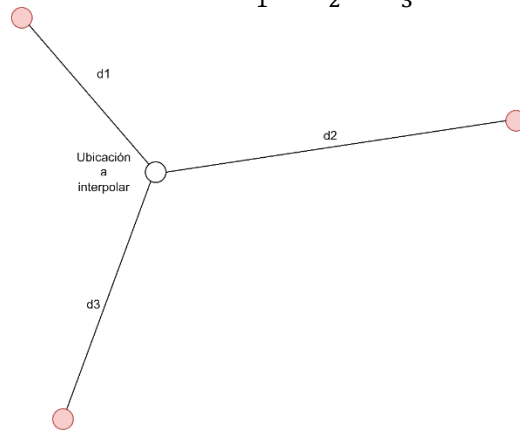


Figura 3 Diagrama de interpolación espacial

El proceso de cálculo, en la **Figura 4** muestra la distribución espacial del parámetro μ_x para las seis estaciones pluviométricas. Se desea conocer el valor interpolado de este parámetro en el punto s_0 cuya latitud y longitud son -76.692° , -11.406° . Para ello aplicaremos IDW.




Figura 4 Distribución espacial del parámetro μ_x para 6 estaciones y el punto s_0 .

En la **Tabla 4** se presenta el cálculo de los parámetros del IDW. Las primeras dos columnas son las ubicaciones de las 6 estaciones. La columna $d(s_0, s_i)$ es la distancia en metros de cada estación a la ubicación s_0 a interpolar. Los valores del parámetro μ_x de cada estación están en la cuarta columna. La columna 5 representa la influencia ponderada de cada estación hacia la ubicación s_0 . Estos pesos de la ponderación son las inversas de las distancias $d(s_0, s_i)$ elevados al cuadrado. La columna 6 se obtiene como resultado de la multiplicación entre la columna 4 y 5. Finalmente, el valor interpolado se estima como la suma total de los resultados parciales de la columna 6 entre la suma total de la columna 5.

Tabla 4 Proceso de cálculo de interpolación del parámetro μ_x para la ubicación s_0 .

x	y	$d(s_0, s_i)$	$\mu_x(s_i)$	$\frac{1}{d^2(s_0, s_i)}$	$\frac{\mu_x(s_i)}{d^2(s_0, s_i)}$
-76.61694	11.46694	10644.77	1.17	8.82526E-09	1.03256E-08
-76.70028	11.61694	23303.36	1.08	1.84146E-09	1.98878E-09
-76.50028	11.38361	21159.09	1.75	2.2336E-09	3.90881E-09
-76.80028	11.35028	13275.8	1.26	5.67386E-09	7.14906E-09
-76.75028	11.50028	12132.46	1.24	6.79364E-09	8.42411E-09
-76.61694	11.55028	17936.6	1.25	3.10828E-09	3.88535E-09
Valor interpolado $\mu_x(s_0)$					1.253

3.4. Método de interpolación Kriging Ordinario (OK)

El método de interpolación Kriging Ordinario usa el termino variograma. El variograma es una función que indica la relación espacial de una propiedad entre dos muestras. Esta relación se estima utilizando una función que muestra como las varianzas cambian a lo largo de la distancia, siendo las muestras más cercanas a un punto a estimar menos variables que las lejanas, ecuación 10. Con el uso de estas varianzas se puede medir la influencia de las estaciones vecinas al momento de realizar interpolaciones. El variograma obtenido de la muestra de datos se debe ajustar a una distribución espacial estadística teórica conocido, existen varios en este trabajo solo usaremos la distribución de variogramas esférico, ecuación 11. De manera similar a IDW, Kriging utiliza una ponderación para estimar la influencia de las estaciones vecinas a el valor de la ubicación a estimar. Sin embargo, la ponderación de Kriging no es determinista como el caso de IDW que se utiliza un factor exponencial para medir la influencia vecina.

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^N [Z(x_i + h) - Z(x_i)]^2 \quad (10)$$

Donde:

Z = propiedad

h = distancia entre dos muestras de la propiedad Z

$\gamma(h)$ = variograma experimental

N(h) = número de pares $Z(x_i + h) - Z(x_i)$

Modelo de variograma esférico

$$\gamma(h) = \begin{cases} \sigma_v^2 \left(1.5 \left(\frac{|h|}{a} \right) - 0.5 \left(\frac{|h|}{a} \right)^3 \right) & \text{si } |h| \leq a \\ \sigma_v^2 & \text{si } |h| > a \end{cases} \quad (11)$$

Donde:

$\gamma(h)$ = variograma modelo esférico

a = rango

σ_v = varianza umbral

El ajuste de variogramas esféricos fue asumiendo isotropía en el espacio y mínimos cuadrados repetitivos (Hiemstra et al., 2009).

Cuantificación de la propiedad estimada mediante Kriging.

Sigue la siguiente expresión:

$$\hat{p}(s_0) = m(u) + \sum_{i=1}^N w_i [g(s_i) - m(u)] \quad \sum_{i=1}^N w_i = 1 \quad (12)$$

Donde, $\hat{p}(s_0)$ es la propiedad estimada, $m(u)$ es el promedio de esta propiedad entre las estaciones vecinas, w son los pesos de la ponderación de kriging, y $g(s_i)$ es el valor de la propiedad en cada estación vecina. La suma de la ponderación de Kriging es forzada a 1 para que minimice la estimación de la varianza mientras se garantiza que el estimador es no sesgado.

Los pesos Kriging son estimados a partir de un sistema lineal de N+1 ecuaciones que es conocido como OK:

$$\left\{ \begin{array}{l} \sum_{i=1}^N w_i \gamma(s_i - s_j) + \psi_{s_0} = \gamma(s_j - s_0) \text{ para } j = 1, 2, 3, \dots, N \\ \sum_{i=1}^N w_i^{ok} = 1 \end{array} \right\} \quad (13)$$

Donde $\gamma(s_i - s_j)$ es el variograma entre las ubicaciones s_i y s_j , es decir la varianza de la precipitación entre estaciones vecinas, mientras que $\gamma(s_j - s_0)$ es el variograma entre la ubicación s_i y s_0 , la varianza de la propiedad entre un vecino y el punto a estimar la propiedad. Debido a que los pesos deben sumar uno, se utiliza el multiplicador de Lagrange ψ_{s_0} que tiene en cuenta la restricción mencionada. Básicamente, para minimizar una función se utiliza el criterio de derivada y lo que se busca al agregar el multiplicador de Lagrange es encontrar que la gradiente de la restricción (ψ_{s_0}) sea proporcional y paralela a la derivada de la función a minimizar. Posteriormente se iguala la diferencia de estos gradientes a cero, para luego resolver un sistema de ecuaciones que te permitan despejar los pesos w_i (Nerini et al., 2015).

Para entender la interpolación con Ok se utilizarán los datos de la **Figura 4** para estimar nuevamente el valor de μ_x en la ubicación -76.692° , -11.406° . Los cálculos para usar OK son más elaborados por lo que se realizará el paso a paso en las siguientes líneas.

Inicialmente se tiene que evaluar cómo es la variabilidad espacial del parámetro μ_x . Para ello se realiza la construcción del variograma utilizando los valores del parámetro μ_x de las seis estaciones vecinas.

Aplicando estas ecuaciones se obtiene el variograma para las seis estaciones se muestra en la **Figura 5**. Una vez estimada la varianza en función de la distancia se tiene que ajustar una distribución estadística espacial. Para esta aplicación se utilizó el modelo esférico. En la figura se muestra con líneas continuas el modelo esférico con pepita 0, rango de 5 kilómetros y un umbral de 0.008.

La interpretación de estos valores es la siguiente.

El parámetro μ_x presentaría una creciente variabilidad de 0 a 0.008 en un radio de influencia de 5 km desde una estación de medición. La influencia se puede entender con el siguiente ejemplo. Una estación tiene el valor de μ_x de 1. Si nos alejamos de esta estación 5 km el valor de μ_x tendría una variabilidad de 0.008, es decir que podría tener el valor de 1 ± 0.008 . El umbral es la variabilidad constante del parámetro μ_x para distancias mayores a 5 km. Por último, la pepita es el sesgo de variabilidad inicial y para este ejemplo se utiliza el valor de pepita 0.

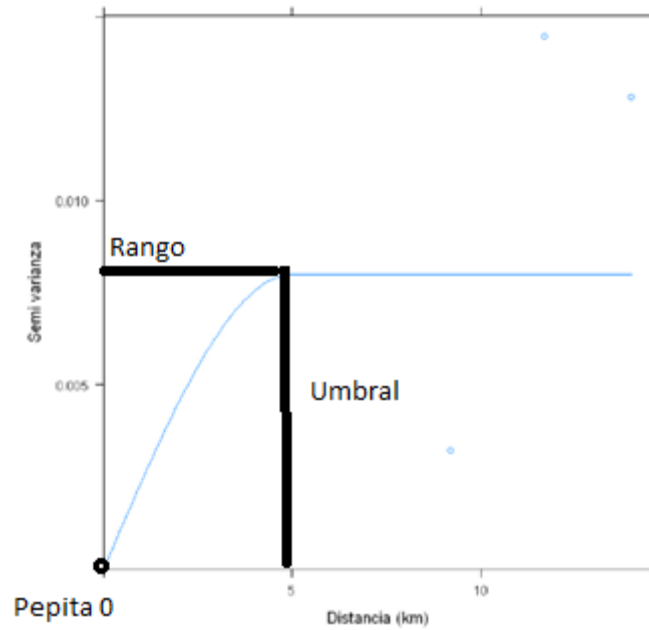


Figura 5 Variograma esférico con pepita 0, rango de 5 kilómetros y umbral 0.008

La fórmula del modelo esférico con los valores de pepita 0, rango 5km y umbral 0.008 de este cálculo es:

$$C(h) = 0.008 \left(1 - 1.5 \left(\frac{h}{5000} \right) + 0.5 \left(\frac{h}{5000} \right)^3 \right)$$

Donde h es la distancia en metros entre dos puntos donde se quiere estimar la variabilidad de la propiedad μ_x .

Las distancias entre las seis estaciones se presentan en la **Tabla 5**. Para leer esta tabla se entiende de las distancias de la siguiente manera: La distancia entre la estación 1 y la estación 2 es de 19 012 metros, por ejemplo. Estos valores luego son ingresados a el modelo esférico para medir la variabilidad del parámetro μ_x entre estaciones.

Tabla 5 Distancias entre las 6 estaciones de la Figura 4. Los valores están en metros.

	Estación 1	Estación 2	Estación 3	Estación 4	Estación 5	Estación 6
Estación 1	0	19012	15751	23852	15012	9277
Estación 2	19012	0	33921	31626	14086	11733
Estación 3	15751	33921	0	32950	30211	22499
Estación 4	23852	31626	32950	0	17567	29930
Estación 5	15012	14086	30211	17567	0	15573
Estación 6	9277	11733	22499	29930	15573	0

Al aplicar la ecuación del modelo esférico a las distancias de la **Tabla 5** y agregando la restricción de que la suma de los pesos de Kriging sea 1 en forma de columna y fila adicional, se obtiene la matriz $\gamma(s_i - s_j)$.

$$\gamma(s_i - s_j) = \begin{bmatrix} 0.008 & 0.182 & 0.095 & 0.385 & 0.080 & 0.011 & 1 \\ 0.182 & 0.008 & 1.176 & 0.944 & 0.064 & 0.032 & 1 \\ 0.095 & 1.176 & 0.008 & 1.074 & 0.818 & 0.318 & 1 \\ 0.385 & 0.944 & 1.074 & 0.008 & 0.139 & 0.794 & 1 \\ 0.080 & 0.064 & 0.818 & 0.139 & 0.008 & 0.091 & 1 \\ 0.011 & 0.032 & 0.318 & 0.794 & 0.091 & 0.008 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 0 \end{bmatrix}$$

Ahora se tiene que calcular la variabilidad del parámetro μ_x en el punto de interpolación s_0 con respecto a las demás estaciones. Para ello necesitamos aplicar la ecuación del modelo esférico a las distancias $d(s_0, s_i)$ para obtener $\gamma(s_j - s_0)$.

$$\gamma(s_j - s_0) = \begin{bmatrix} 0.02 \\ 0.36 \\ 0.26 \\ 0.05 \\ 0.05 \\ 0.04 \\ 0.15 \\ 1 \end{bmatrix}$$

Para calcular el valor de los pesos ponderados Kriging w_i , se necesita resolver el sistema de ecuaciones utilizando la siguiente expresión:

$$w = \gamma(s_i - s_j)^{-1} \gamma(s_j - s_0)$$

Obteniéndose:

$$w = \begin{bmatrix} 0.789 \\ -0.094 \\ 0.054 \\ 0.234 \\ 0.2389 \\ -0.222 \end{bmatrix}$$

El promedio del parámetro μ_x de las seis estaciones es $m(u) = 1.291$.

El residual de cada estación es:

$$R(u) = [\mu_x(s_i) - m(u)] = [-0.12, -0.24, 0.45, -0.03, -0.05, -0.04].$$

Remplazando estos cálculos en la ecuación de estimación con OK.

$$\hat{p}(s_0) = m(u) + w * R(u)$$

$$\hat{p}(s_0) = 1.291 - 0.06139 = 1.23$$

Este valor encontrado es ligeramente menor al estimado con IDW, el cual era 1.25. La primordial diferencia entre IDW y OK es la forma de estimación de los pesos ponderados que miden la influencia vecinal de las estaciones hacia el punto (s_0) donde se desea estimar los parámetros de MBLRP.

Cabe mencionar que OK requiere de mayor información para su utilización. Esto es debido al cálculo del variograma. Para este ejemplo se utilizó solo 6 estaciones y como se puede apreciar en la **Figura 5** el ajuste del modelo esférico no es el mejor. Sin embargo, al ser un ejemplo para mostrar el proceso de cálculo es útil para entender de manera general lo que se realizó con las 203 estaciones a nivel nacional.

Para la interpolación espacial de los parámetros MBLRP en una región se debe repetir el proceso descrito para todos los s_0^* que se definan dentro de dicha región.

4. Metodología

La obtención de los parámetros del modelo MBLRP se lleva a cabo canónicamente minimizando las diferencias entre las estadísticas de la precipitación observada y las generadas sintéticamente por el modelo. Esta estimación de parámetros es compleja debido a que el número de estadísticos utilizados en la función de optimización es mayor al número de parámetros a estimar (Kim et al., 2013). Asimismo, la compleja formulación de las ecuaciones de los estadísticos sintéticos (no lineales) propicia que durante la minimización se pueda obtener múltiples soluciones locales. Estas dificultades, convierten la regionalización del modelo MBLRP en una tarea difícil de realizar (Onof, C and Chandler, RE and Kakou, A and Northrop, P and Wheeler, HS and Isham, 2000).

Para solucionar estas dificultades diferentes trabajos de regionalización de parámetros se han desarrollado. Por ejemplo, Kim et al., (2013) regionalizó los parámetros de MBLRP para cada mes del año de Estados Unidos. Para el desarrollo de los mapas (72 en total), realizaron la interpolación espacial de los parámetros estimados de 3444 estaciones pluviométricas. La validación de sus mapas fue realizada mediante validaciones cruzadas y comparaciones de los estadísticos sintéticamente generados y observados. Kim et al., (2016b) sugirió reducir los espacios de búsqueda en la optimización de parámetros mediante validaciones cruzadas y limitando las diferencias entre parámetros de estaciones vecinas. Esta optimización permitió el desarrollo de mapas para la península de Corea con variaciones espaciales suaves utilizando 59 estaciones pluviométricas.

El procedimiento para la regionalización de los parámetros del modelo MBLRP sigue el flujograma de la **Figura 6**. Para realizar los cálculos se usa el lenguaje de programación R apoyado de algunas librerías del repositorio Hyetos, obteniendo resultados los parámetros del modelo MBLRP, (Hyetos <https://www.itia.ntua.gr/en/softinfo/3/>), (códigos https://github.com/JoseZevallosR/Bartlet-Lewis_Regionalization).




Figura 6 Flujo de trabajo para la regionalización del modelo MBLRP

4.1. Estadísticos de precipitación

Tal como se menciona, el procedimiento para la regionalización de los parámetros del modelo MBLRP que sigue el flujograma de la **Figura 6**, se procede de la siguiente manera: con la información satelital TRMM se desagrega la precipitación pluviométrica para cada día del periodo 1999-2014, hecho esto, se determina los estadísticos necesarios para la calibración del modelo MBLRP (ítem **4.1**). Para el cálculo de parámetros del modelo MBLRP usamos el método de los momentos y se consideró la influencia vecinal entre estaciones pluviométricas, (ítem **4.2, 4.3 y 4.4**). Los parámetros obtenidos en este cálculo son interpolados espacialmente con **Kriging** para generar los mapas regionalizados del modelo MBLRP para la zona de estudio, ítem **4.5**. Finalmente, con el resultado de los parámetros del modelo MBLRP se realiza la estimación del promedio de duración de las tormentas y sus alturas promedio de precipitación para la zona de estudio, ítem **5.4**.

Se utilizó la información satelital para desagregar los valores de precipitación diaria a mediciones de cada 3 horas ya que es la resolución temporal del satélite TRMM. Para ello, un factor de corrección multiplicativo fue calculado. Este factor se estimó como resultado de la división del valor del punto pluviométrico diario y la precipitación acumulada de 24 horas del píxel ubicado en las mismas coordenadas de la estación. A continuación, un ejemplo de desagregación:

Una vez desagregada las precipitaciones para las **203** estaciones, se procedió a calcular en total 12 estadísticos muestrales, los cuales son: promedio, varianza, auto covarianza y la probabilidad de lluvia cero para el agregado de 24 horas además de las varianzas y auto covarianzas para los agregados de 3, 6, 12 y 18 horas. Se entiende por agregado, al valor de lluvia acumulado en los intervalos de tiempo indicados. Por ejemplo, el agregado de 24 horas se refiere a la precipitación acumulada en 24 horas.

En la **Tabla 7** se muestra el resultado de los cálculos de estadísticos muestrales de agregados de 24 para algunas estaciones. El cálculo se realizó utilizando las fórmulas mencionadas en la sección **3.2** a las series de tiempo de mediciones de estas estaciones.

Tabla 7 Resultados estadísticos para agregados de 24 horas para algunas estaciones

Nombre	LONGITUD	LATITUD	Promedio 24h	Varianza 24h	Auto Covarianza 24h	P. de días secos 24h
CHULUCANAS	-80.1694	-5.1017	4.20	161.22	52.81	0.56
MASHCON	-78.4848	-7.1666	3.39	26.69	7.53	0.35
EL PORVENIR	-76.3219	-6.5931	3.78	78.67	7.93	0.55
NAMORA	-78.3389	-7.2033	4.99	45.62	18.89	0.35
SONDOR-MATARA	-78.2372	-7.2203	4.84	58.88	15.96	0.53
LA MUCHALA	-79.2164	-6.8256	2.80	70.96	18.95	0.63

En la **Tabla 8** de manera similar se aplicó las fórmulas mencionadas para las series de tiempo temporales de precipitaciones agregadas de 3 horas obtenidos de la desagregación de los datos diarios con TRMM.

Tabla 8 Resultados estadísticos para agregados de 3 horas para algunas estaciones

Nombre	LONGITU D	LATITU D	Promedio 3h	Varianza 3h	Auto Covarianza a 3h	P. de días secos 3h
CHULUCANAS	-80.1694	-5.1017	0.42	12.37	1.42	0.93
MASHCON	-78.4848	-7.1666	0.34	2.70	0.20	0.88
EL PORVENIR	-76.3219	-6.5931	0.36	5.73	0.78	0.91
NAMORA	-78.3389	-7.2033	0.48	4.46	0.58	0.87
SONDOR-MATARA	-78.2372	-7.2203	0.39	3.98	0.55	0.91
LA MUCHALA	-79.2164	-6.8256	0.31	5.04	0.75	0.93

De la misma forma se procedió a determinar los estadísticos para las otras estaciones **Anexo E.** https://github.com/JoseZevallosR/TrmmCorrection/blob/main/code/TRMM_Correction.ipynb

4.2. Estimación de Parámetros del modelo MBLRP

La no linealidad de las ecuaciones del modelo MBLRP no hacen posible una solución analítica. Adicionalmente, la máxima verosimilitud es difícil de encontrar para MBLRP (Vanhaute et al., 2012).

En este contexto usaremos el método canónico de los momentos para la estimación de los parámetros en su forma simétrica ya que es robusta y de convergencia estable (Ritschel et al., 2017). Los estadísticos se determinan mediante la formulación:

$$z(\theta, T) = \sum_{n=1}^{\kappa} w_i \left(\left[1 - \frac{\tau_i(\theta)}{T_i} \right]^2 + \left[1 - \frac{T_i}{\tau_i(\theta)} \right]^2 \right) \quad (14)$$

Donde $\theta = [\lambda, \mu_x, \kappa, \phi, \alpha, \nu]$ es el vector de parámetros del modelo MBLRP (ítem 3.1); $\tau_i(\theta)$ es i-ésimo momento estadístico del modelo MBLRP (ecuaciones 1, 2, 3 y 4 ítem 3.1.1); T_i son las estadísticas muestrales (ítem 3.2). Finalmente, w_i son los pesos asignados para cada estadístico. En nuestro estudio debido a que los estadísticos muestrales de 24 horas son mediciones en campo, se utilizó $w_i = 2$ para poder conservar su valor con mayor importancia y $w_i = 1$ para el resto de estadísticos, es decir T_i = las varianzas y auto covarianzas para los agregados de 3, 6, 12 y 18 horas, debido a que son obtenidos de la desagregación de series temporales con TRMM.

Se muestra la función objetivo considerando solo estadísticos de 24 horas de la estación Chulucanas, **Tabla 7**. De la expresión anterior se tendría 4 sumandos con sus respectivos pesos de ponderación $w_i = 1$ para i de 1 a 4.

$$z(\theta, 24) = \left(\left[1 - \frac{E[Y_t^{24}]}{4.2} \right]^2 + \left[1 - \frac{4.2}{E[Y_t^{24}]} \right]^2 \right) + \left(\left[1 - \frac{Var[Y_t^{24}]}{161.22} \right]^2 + \left[1 - \frac{161.22}{Var[Y_t^{24}]} \right]^2 \right) \\ + \left(\left[1 - \frac{Cov[Y_t^{24}, Y_{t+1}^{24}]}{52.81} \right]^2 + \left[1 - \frac{52.81}{Cov[Y_t^{24}, Y_{t+1}^{24}]} \right]^2 \right) + \left(\left[1 - \frac{P_t^{24}}{0.56} \right]^2 + \left[1 - \frac{0.56}{P_t^{24}} \right]^2 \right)$$

Donde:

Y_t^{24} es la serie temporal simulada de precipitación de 24 horas con MBLRP

Y_{t+1}^{24} es la serie temporal simulada de precipitación de 24 horas con desfase de un día

$$k_1 = \left(2\lambda\mu_c\mu^2 + \frac{\lambda\mu_c\kappa\phi\mu^2}{\phi^2 - 1} \right) \left(\frac{\nu^\alpha}{\alpha - 1} \right)$$

$$k_2 = \left(\frac{\lambda\mu_c\kappa\phi\mu^2}{\phi^2 - 1} \right) \left(\frac{\nu^\alpha}{\alpha - 1} \right)$$

$$\mu_c = 1 + \frac{\kappa}{\phi}$$

$$E[Y_t^{24}] = \lambda \mu_x \mu_c \frac{v}{\alpha - 1} 24$$

$$\begin{aligned} Var[Y_t^{24}] = & \frac{48v^{2-\alpha}}{\alpha - 2} \left(k_1 - \frac{k_2}{\phi} \right) - \frac{2v^{3-\alpha}}{(\alpha - 2) - (\alpha - 3)} \left(k_1 - \frac{k_2}{\phi} \right) \\ & + \frac{2}{(\alpha - 2)(\alpha - 3)} \left[k_1(24 + v)^{3-\alpha} - \frac{k_2}{\phi^2} (24\phi + v)^{3-\alpha} \right] \end{aligned}$$

$$\begin{aligned} Cov[Y_t^{24}, Y_{t+1}^{24}] = & \frac{k_1}{(\alpha - 2)(\alpha - 3)} \{ [v]^{3-\alpha} + [48 + v]^{3-\alpha} - 2(24\phi + v)^{3-\alpha} \} \\ & + \frac{k_2}{\phi^2(\alpha - 2)(\alpha - 3)} \{ 2(24\phi + v)^{3-\alpha} - [v]^{3-\alpha} - [48\phi + v]^{3-\alpha} \} \end{aligned}$$

P_t^{24} (precipitación cero)

$$\begin{aligned} = & \exp \left\{ -24\lambda \right. \\ & - \frac{\lambda v}{\phi(\alpha - 1)} \left[1 + \phi(\kappa + \phi) - \frac{1}{4}\phi(\kappa + \phi)(\kappa + 4\phi) \right. \\ & \left. \left. + \frac{\phi(\kappa + \phi)(4\kappa^2 + 27\kappa\phi + 72\phi^2)}{72} \right] \right. \\ & + \frac{\lambda v}{(\alpha - 1)(\kappa + 4\phi)} \left(1 - \kappa - \phi + \frac{3}{2}\kappa\phi + \phi^2 + \frac{\kappa^2}{2} \right) \\ & \left. + \frac{\lambda v}{(\alpha - 1)(\kappa + \phi)} \left[\frac{v}{v + 24(\kappa + \phi)} \right]^{\alpha-1} \frac{\kappa}{\phi} \left(1 - \kappa - \phi + \frac{3}{2}\kappa\phi + \phi^2 + \frac{\kappa^2}{2} \right) \right\} \end{aligned}$$

Minimizando esta función objetivo $Z(\theta, 24)$ se obtendría los parámetros $\theta = \{\lambda, \mu_x, \kappa, \phi, \alpha, v\}$ del modelo MBLRP para la estación Chulucanas. Sin embargo, al no considerar estadísticos sub diarios, la función objetivo no tiene información de las características de tormentas de menor duración que la diaria por lo que la calibración es deficiente para poder representar precipitaciones horarias. A pesar de ello, este ejemplo sirve para poder visualizar la complejidad de esta función para estimar los parámetros de manera analítica. Por tal razón, para minimizar la función se requiere de algoritmos computacionales de optimización heurísticos.

4.3. Método Evolutivo de Recocido Simplex (AES)

AES es un método de optimización heurística. Se basa en un esquema de búsqueda aleatoria controlada de los mejores parámetros para minimizar o maximizar una función objetivo. El algoritmo presentado por Efstratiadis y Koutsoyiannis (2002) de optimización con AES es el siguiente:

1. Se define de manera aleatoria un conjunto de parámetros aleatorios llamado $S = \{x_1, x_2, \dots, x_{n+1}\}$. De esta población P se selecciona una sub conjunto llamado simplex compuesto por $m \geq n + 1$ puntos, donde x_1 corresponde a el menor valor de la función objetivo f mientras que x_{n+1} pertenece al mayor valor de la función objetivo.
2. Del sub conjunto $\{x_3, \dots, x_{n+1}\}$ se selecciona un vértice w que es candidato a ser reemplazado. El valor de remplazo candidato es aquel que maximiza la función objetivo modificada:

$$g(x_i) = f(x_i) + uT$$

Donde u es un valor aleatorio de la distribución uniforme entre el intervalo (0,1) y T es la temperatura del sistema. La temperatura es la diferencia entre el valor máximo y mínimo de la función objetivo del sub conjunto.

3. Un nuevo punto de evaluación es generado con la siguiente formula:

$$r = g + (0.5 + u)(g - w)$$

Donde g es el centroide del sub conjunto $S - \{w\}$ y u es un valor aleatorio de la distribución uniforme.

4. Si $f(r) < f(w)$, el nuevo punto r reemplaza al valor w . Adicionalmente, si $f(r) < f(x_1)$, es decir el nuevo punto minimiza mejor que el valor x_1 , una línea de minimización es generada acorde a la siguiente ecuación:

$$x_{nuevo} = g + \phi^{[s]}(r - g)$$

Donde $\phi^{[s]} = \phi^{[s-1]} + u$, donde $\phi^{[0]} = 1$. La línea de minimización continua siempre que la función objetivo siga disminuyendo. Por otro lado, si $f(r) > f(x_1)$, el simplex se contrae de la siguiente manera:

$$x_{nuevo} = g + (0.25 + 0.5u)(r - g)$$

Si la expansión o la contracción exterior tienen éxito, x_{nuevo} reemplaza a r .

5. Si $g(r) > g(w)$, el nuevo punto de evaluación r no es aceptado, y se reduce la temperatura del sistema actual con un factor multiplicativo y el conjunto simplex es contraído con la siguiente ecuación:

$$x_{nuevo} = g - (0.25 - 0.5u)(g - w)$$

Si este punto nuevo genera un valor de la función objetivo mayor a el mayor actual, es decir, si $f(x_{nuevo}) > f(x_{n+1})$ entonces el simplex se reduce en dirección a su valor mínimo x_1 , $x'_i = 0.5(x_i + x_1)$.

6. Si $g(r) < g(w)$, el nuevo punto de evaluación r es aceptado. A continuación, se implementa un número dado de movimientos cuesta arriba de acuerdo con (4). La diferencia de los valores de funciones posteriores es una aproximación del gradiente. Siempre que el gradiente se vuelve negativo, el simplex escapa de la región de atracción del mínimo local actual y el nuevo punto reemplaza a r . De lo contrario, si cualquier intento de movimiento cuesta arriba tiene éxito, se genera un punto aleatorio en los límites de la población P y reemplaza a r de acuerdo con una probabilidad de mutación p_m . El nuevo punto se genera de la siguiente manera

$$x_{nuevo} = c + \frac{dy}{||y||}$$

Donde c es el centroide de P , d es la máxima distancia euclidiana entre los miembros de la población P hacia el centroide y y es una dirección aleatoria en el espacio de dimensiones n .

El algoritmo se detiene si la distancia relativa entre el valor actual de la función mejor f_{min} y peor f_{max} en P se vuelve menor que una tolerancia dada, ε . La temperatura inicial se fija igual a $f_{max} - f_{min}$, mientras que al inicio de cada ciclo se reevalúa para que nunca supere $\xi (f_{max} - f_{min})$, donde $\xi \geq 1$ es un parámetro de control del algoritmo.

Para resolver la optimización del ejemplo de la **sección 4.2** y así estimar los parámetros de la estación Chulucanas se minimiza la función objetivo $Z(\theta, T)$ con AES. A continuación, se muestra la implementación en lenguaje de programación R la aplicación del algoritmo descrito.

```
mean24 = 4.2 #Promedio
var24 = 161.22 #Varianza
cov24 = 52.81 #Auto Covarianza
pdr24 = 0.56 #Proporción de días Secos

fn = function (x){
  a<-x[1];l<-x[2];v<-x[3];k<-x[4];f<-x[5];mx<-x[6]

  meanMBLRPM<-function(a,l,v,k,f,mx,h=1) {
    #Promedio
    x<-(h*l*mx*v*(1+k/f))/(a-1)
    return(x)
  }
  #Varianza
  varMBLRPM<-function(a,l,v,k,f,mx,h=1) {
    A<-(2*l*(1+k/f)*(mx^2)*(v^a))/((f^2)*((f^2)-1)*(a-1)*(a-2)*(a-3))
    B<-(2*(f^2)-2+k*f)*(f^2)*((a-3)*h*(v^(2-a))-v^(3-a))+((v+h)^(3-a))
    C<-k*(f*(a-3)*h*(v^(2-a))-v^(3-a))+((v+f*h)^(3-a))
    D<-A*(B-C)
    return(D)
  }
  #Auto Covarianza
  covarMBLRPM<-function(a,l,v,k,f,mx,h=1,lag=1) {
    A<-(1*(1+k/f)*(mx^2)*(v^a))/((f^2)*((f^2)-1)*(a-1)*(a-2)*(a-3))
    B<-(2*(f^2)-2+k*f)*(f^2)*(((v+(lag+1)*h)^(3-a))-2*((v+lag*h)^(3-a)))+((v+(lag-1)*h)^(3-a))
    C<-k*((v+(lag+1)*h*f)^(3-a))-2*((v+h*lag*f)^(3-a))+((v+(lag-1)*h*f)^(3-a))
    D<-A*(B-C)
    return(D)
  }
  #Proporción de días Secos
  pdrRPBLRPM<-function(a,l,v,k,f,h=1) {
    mt<-((1+(f*(k+f))-
    (0.25*f*(k+f)*(k+4*f))+((f/72)*(k+f)*(4*(k^2)+27*k*f+72*(f^2))))*v)/(f*(a-1))
    G00<-((1-k-f+1.5*k*f+(f^2)+0.5*(k^2))*v)/(f*(a-1))
    A<-((f+(k*(v/(v+(k+f)*h)))^(a-1)))/(f+k)
    D<-exp(l*(-h-mt+G00*A))
    return(D)
  }
}
```

```

symvar<- function(a,l,v,k,f,mx,h,var){
  (1-varMBLRPM(a,l,v,k,f,mx,h)/var)^(2)+(1-
var/varMBLRPM(a,l,v,k,f,mx,h))^(2)
}
symcovar <- function(a,l,v,k,f,mx,h,cov){
  (1-covarMBLRPM(a,l,v,k,f,mx,h)/cov)^(2)+(1-
cov/covarMBLRPM(a,l,v,k,f,mx,h))^(2)
}
symmean <- function(a,l,v,k,f,mx,h,meann){
  (1-meanMBLRPM(a,l,v,k,f,mx,h)/meann)^(2)+(1-
meann/meanMBLRPM(a,l,v,k,f,mx,h))^(2)
}
sympdr <- function(a,l,v,k,f,h,pdr){
  (1-pdrRPBLRPM(a,l,v,k,f,h)/pdr)^(2)+(1-
pdr/pdrRPBLRPM(a,l,v,k,f,h))^(2)
}

w1=1;w2=1;w3=1;w4=1

S <- w1*symmean(a,l,v,k,f,mx,h=24,mean24)+
w2*symvar(a,l,v,k,f,mx,h=24,var24)+
w3*symcovar(a,l,v,k,f,mx,h=24,cov24)+w4*sympdr(a,l,v,k,f,h=24,pdr24)

if(is.infinite(S)) {S<-10^8}
if(is.na(S)) {S<-10^8}
return(S)
}

Lmin=matrix(c(0.1,0.001,0.001,0.001,0.0854,1),nrow = 6,ncol = 1)
Lmax=matrix(c(4,0.1,0.1,0.1,0.1,20),nrow=6,ncol=1)

xmin = Lmin[,1]
xmax = Lmax[,1]
xlow = Lmin[,1]
xup = Lmax[,1]

n=6
m=8
maxeval = 1500; ftol = 1e-07;
ratio = 0.99; pmut = 0.9; beta = 2; maxclimbs = 5

mvector <- 1:m
pop <- mat.or.vec(nr = m, nc = n)
for (i in 1:n) {
  pop[, i] <- xmin[i] + runif(m, 0, 1) * (xmax[i] - xmin[i])
}
fpop <- apply(pop, 1, fn)
neval <- m
iter <- 0
temperature <- max(fpop) - min(fpop)
repeat {
  iter <- iter + 1
  meanpop <- apply(pop, 2, mean)
  sdpop <- apply(pop, 2, sd)
  sn <- sample(mvector, size = n + 1)
  s <- pop[sn, ]
  fns <- fpop[sn]
}

```

```

slposition <- which.min(fns)
snlposition <- which.max(fns)
if (temperature > beta * (max(fns) - min(fns))) {
  temperature <- beta * (max(fns) - min(fns))
}
gsfunction <- fns[-slposition] + runif(n, min = 0, max = 1) *
  temperature
wposition <- which.max(gsfunction)
wposition <- sn[-slposition][wposition]
w <- s[-slposition, ] [wposition, ]
fnw <- fns[-slposition][wposition]
g <- (apply(s, 2, sum) - w)/n
r0 <- g + (0.5 + runif(1)) * (g - w)
r0 <- ifelse(r0 < xup, ifelse(xlow < r0, r0, xlow),
  xup)
fnr0 <- fn(r0)
neval <- neval + 1
if (neval >= maxeval) {
  if (fnr0 < fnw) {
    w <- r0
    pop[wposition, ] <- w
    fpop[wposition] <- fnw
  }
  gpop <- apply(pop, 2, sum)/m
  eucldist <- t(apply(pop, 1, function(x) (x - gpop)^2))
  eucldist <- apply(eucldist, 1, sum)
  eucldistpop <- sqrt(eucldist)
  ftolpop <- mean(eucldistpop)
  break
}
if (fnr0 < fnw) {
  if (fnr0 < fns[slposition]) {
    ns <- 1
    r01 <- r0
    fnr01 <- fnr0
    repeat {
      ns <- ns + runif(1, min = 0, max = 1)
      rs <- g + ns * (r0 - g)
      neval <- neval + 1
      if (any(rs > xup) || any(rs < xlow)) {
        rs <- ifelse(rs < xup, ifelse(xlow < rs,
          rs, xlow), xup)

        fnrs <- fn(rs)
        if (fnrs < fnr01) {
          w <- rs
          fnw <- fnrs
        }
        else {
          w <- r01
          fnw <- fnr01
        }
      }
      break
    }
    fnrs <- fn(rs)
    if (fnrs < fnr01) {
      if (neval >= maxeval) {
        w <- rs
        fnw <- fnrs
        break
      }
    }
    else {

```

```

        r01 <- rs
        fnr01 <- fnrs
    }
}
else {
    w <- r01
    fnw <- fnr01
    break
}
}
pop[wposition, ] <- w
fpop[wposition] <- fnw
}
else {
    r1 <- g + (0.25 + 0.5 * runif(1)) * (r0 - g)
    r1 <- ifelse(r1 < xup, ifelse(xlow < r1, r1,
                                xlow), xup)

    fnr1 <- fn(r1)
    neval <- neval + 1
    if (fnr1 < fnr0) {
        w <- r1
        fnw <- fnr1
    }
    else {
        w <- r0
        fnw <- fnr0
    }
    pop[wposition, ] <- w
    fpop[wposition] <- fnw
}
}
else {
    if (fnr0 - runif(1, min = 0, max = 1) * temperature >
        fnw + runif(1, min = 0, max = 1) * temperature) {
        temperature <- ratio * temperature
        r1 <- g - (0.25 + 0.5 * runif(1)) * (g - w)
        r1 <- ifelse(r1 < xup, ifelse(xlow < r1, r1,
                                    xlow), xup)

        fnr1 <- fn(r1)
        neval <- neval + 1
        if (fnr1 < fnw) {
            w <- r1
            fnw <- fnr1
            pop[wposition, ] <- w
            fpop[wposition] <- fnw
        }
        else {
            mcon <- 0.5 * (t(t(s[-slposition, ]) + s[slposition,
                ]))
            fmcon <- apply(mcon, 1, fn)
            neval <- neval + n
            pop[sn[-slposition], ] <- mcon
            fpop[sn[-slposition]] <- fmcon
        }
    }
}
else {
    ns <- 1
    r01 <- r0
    fnr01 <- fnr0
    for (i in 1:maxclimbs) {
        ns <- ns + runif(1)
    }
}
}
}

```

```

rs <- g + ns * (r0 - g)
neval <- neval + 1
if (any(rs > xup) || any(rs < xlow)) {
  rs <- ifelse(rs < xup, ifelse(xlow < rs,
                                rs, xlow), xup)

  fnrs <- fn(rs)
  if (fnrs < fnr01) {
    w <- rs
    fnw <- fnrs
  }
  break
}
fnrs <- fn(rs)
if (fnrs < fnr01) {
  w <- rs
  fnw <- fnrs
  break
}
}
else {
  if (neval >= maxeval) {
    break
  }
  else {
    r01 <- rs
    fnr01 <- fnrs
  }
}
}
if (fnrs < fnr01) {
  pop[wposition, ] <- w
  fpop[wposition] <- fnw
}
else {
  samplen <- sample(c(-1, 1), size = n, replace = TRUE)
  a <- ifelse(xup < meanpop + sdpop, meanpop +
              sdpop, xup)
  b <- ifelse(meanpop - sdpop < xlow, meanpop -
              sdpop, xlow)
  newpoint <- ifelse(samplen > 0, runif(n, min = meanpop +
                                       sdpop, max = a),
                    runif(n, min = b, max = meanpop -
                           sdpop))
  newpoint <- ifelse(newpoint < xup, ifelse(xlow <
                                           newpoint,
newpoint, xlow), xup)
  fnnewpoint <- fn(newpoint)
  neval <- neval + 1
  if (fnnewpoint < fnr0) {
    w <- newpoint
    fnw <- fnnewpoint
  }
  else {
    if (runif(1, min = 0, max = 1) < pmut) {
      w <- newpoint
      fnw <- fnnewpoint
    }
    else {
      w <- r0
      fnw <- fnr0
    }
  }
}
}

```

```

    }
    pop[wpopposition, ] <- w
    fpop[wpopposition] <- fnw
  }
}
}
if (neval >= maxeval) {
  break
}
gpop <- apply(pop, 2, sum)/m
eucldist <- t(apply(pop, 1, function(x) (x - gpop)^2))
eucldist <- apply(eucldist, 1, sum)
eucldistpop <- sqrt(eucldist)
ftolpop <- mean(eucldistpop)
if (ftolpop < ftol) {
  break
}
}
}
list(bestpar = pop[which.min(fpop), ], bestval = min(fpop),
     deterbestval = min(fpop), nfeval = neval, niter = iter,
     ftolpop = ftolpop, pop = pop)

```

Debido a que el algoritmo es probabilístico y que la función objetivo tiene múltiples mínimos locales al contener términos no lineales, los parámetros de MBLRP que se obtienen varían cada vez que se aplica este código. Por ejemplo, los resultados obtenidos para la estación Chulucanas en 5 intentos son mostrados en la **Tabla 9**. Como se puede apreciar, los valores son relativamente cercanos.

Tabla 9 Resultados de la optimización con AES para el cálculo de parámetros MBLRP de la estación Chulucanas

α	λ (horas ⁻¹)	ν (horas ⁻¹)	κ	ϕ	μ (mm)
1.8378	0.0300	0.1000	0.1000	0.0854	17.7723
1.8586	0.0279	0.0991	0.0997	0.0926	19.9489
1.8374	0.0300	0.1000	0.1000	0.0854	17.7567
1.8417	0.0300	0.1000	0.1000	0.0854	17.9002
1.8290	0.0310	0.1000	0.0997	0.0940	17.7455

En la siguiente sección se describe como se realizó la calibración del modelo MBLRP para las 203 estaciones disponibles.

4.4. Descripción del problema de multimodalidad y validaciones cruzadas repetitivas para la estimación de los parámetros MBLRP.

El problema de múltiples mínimo locales se puede analizar la **Figura 7**, la cual muestra una función no lineal cualquiera que describe un evento que va a tener varios mínimos (locales), pero existe un mínimo de los mínimos (mínimo global), que es el que debemos determinar. Observamos que esta función solo depende del parámetro x y tiene varios mínimos que seleccionar, mientras que para la calibración de modelo MBLRP, la función obtenida del método de los momentos depende de múltiples variables por lo que es compleja determinar los múltiples mínimos locales.

Los métodos de optimización numéricos, para obtener el mínimo global a partir de los múltiples mínimos locales, parte de un conjunto único de valores supuestos de solución aleatoria. Pero estos pueden iniciar en puntos diferentes de la trayectoria de la función (1 o 2) en la **Figura 7** por lo que las iteraciones de cálculo pueden converger a un mínimo local en vez del global.




Figura 7 Función no lineal como un mínimo local y un mínimo global

En este estudio lo descrito en el párrafo anterior se expresa como la multimodalidad asociada a la función objetivo de la estimación de parámetros que explica en el contexto del MBLRP Kim et al. (2013). El cual supone que diferentes conjuntos de parámetros A (mínimo local) y B (mínimo global) del modelo MBLRP pueden describir una misma tormenta en específico de manera correcta. En la **Figura 8**, se muestran los patrones de celdas determinados por los parámetros A y B describiendo la misma tormenta. La altura de los bloques representa cantidad de precipitación mientras que el ancho es la duración. Los parámetros de A resultan en celdas de menor duración mientras que las celdas de B son de mayor duración. Esta posible descripción de tormentas con diferentes juegos de parámetros se debe a los múltiples mínimos locales de la función objetivo del punto 4.2. Estas múltiples soluciones se denomina *multimodalidad* y ha sido detallada en la literatura científica (Gyasi-Agyei, 1999; Onof, C and Chandler, RE and Kakou, A and Northrop, P and Wheeler, HS and Isham, 2000). Por este motivo, si interpolamos espacialmente el primer juego de parámetros estimados individualmente e

independiente con AES para cada estación podría conllevar errores ya que puede que no exista una transición espacial suave entre estos.




Figura 8 Representación de una misma tormenta particular con diferentes juegos de parámetros A y B

Para reducir el efecto de multimodalidad, Kim et al. (2013) aplica un método de solución al que denomina el método de validaciones cruzadas repetitivas (VCR) para la calibración del modelo MBLRP. El método consiste en encontrar un juego inicial de parámetros para cada estación pluviométrica encontrando los mínimos de la función objetivo, mediante el método evolutivo de recocido simple (AES).

Este concepto es adaptado a este trabajo para grupos de estaciones vecinas cuando la distancia entre estaciones es menor a 60 kilómetros. Por ejemplo, en la **Figura 9** se muestra un grupo de estaciones vecinas con el valor del parámetro μ_x obtenidos con AES.




Figura 9 Grupo de estaciones separadas por menos de 60 km de distancia. El valor indicado corresponde al parámetro μ_x obtenidos con AES.

El proceso de VCR aísla una estación objetivo, para determinar mediante el método de interpolación espacial IDW los parámetros del modelo MBLRP de esta estación objetivo, en función de los parámetros de las estaciones vecinas. Los resultados obtenidos se comparan con la información de la estación aislada, si estas tienen diferencias mayores a 20 %, se procede a recalcular los parámetros de la estación objetivo usando el método AES, limitando el rango de búsqueda de parámetros en el intervalo de valores mínimos y máximos de los parámetros de las estaciones vecinas.

Por ejemplo, en la **Figura 9** se aísla la estación Pariacancha ubicada en 76.50, -11.353 (s_0), este tiene como parámetro $\mu_x = 1.89$ obtenido anteriormente con AES, ahora este parámetro es estimado mediante IDW con los de las estaciones Obrajillo, Arahua, Pallac, Huamantanga y Lachaqui. Luego se procede a comparar este valor interpolado con el valor estimado inicialmente de Pariacancha;

Se tiene la información mostrada en la **Tabla 10**: la 1ra columna se indica las estaciones vecinas, la 2da y 3ra columna su ubicación geográfica, la 4ta columna son las distancias a la estación aislada Pariacancha desde cada estación vecina, la 5ta columna es el parámetro μ_x de cada estación vecina.

Con esta información calculamos mediante la interpolación IDW el valor $\mu_x = 1.094$ para Pariacancha. Observamos que el valor obtenido por AES $\mu_x = 1.89$ y el valor obtenido con IDW $\mu_x = 1.094$, tienen una diferencia porcentual de 73%, como la diferencia es mucho mayor al 20%, se recalcula un nuevo valor para μ_x con el rango de búsqueda entre (min-max) que en este caso es [1 - 1.27]. Este proceso se realizó para las 203 estaciones pluviométricas.

Tabla 10 Validación cruzada de los parámetros MBLRP obtenidos con AES.

Estación	x	y	$d(s_0, s_i)$	$\mu_x(s_i)$	$\frac{1}{d^2(s_0, s_i)}$	$\frac{\mu_x(s_i)}{d^2(s_0, s_i)}$	
Obrajillo	-76.61694	-11.466944	15751	1	4.03084E-09	4.03084E-09	
Arahua	-76.70028	-11.616944	33921	1.16	8.69072E-10	1.00812E-09	
Pallac	-76.80028	-11.350278	32950	1	9.21041E-10	9.21041E-10	
Huamantanga	-76.75028	-11.500278	30211	1.153	1.09566E-09	1.26329E-09	
Lachaqui	-76.61694	-11.550278	22499	1.27	1.97547E-09	2.50885E-09	
				Min	1	Valor interpolado $\mu_x(s_0)$	1.094
				Max	1.27	Valor inicial estimado $\mu_x(s_0)$	1.89
						Diferencia absoluta	0.795526722
						Diferencia porcentual	72.69%

Los cálculos requieren de asistencia computacional ya que son de carácter aleatorio. El código encargado de realizar las estimaciones descritas en la sección 4.2 y 4.4 se encuentra en el **Anexo F**. https://github.com/JoseZevallosR/Bartlett-Lewis_Regionalization/blob/main/scripts/MBLRP_ESTIMACION.R

4.5. Interpolación espacial de los parámetros MBLRP

Una vez estimados los seis parámetros del MBLRP con VCR para las 203 estaciones, interpolamos espacialmente dichos parámetros con Kriging ordinario, obteniendo 18 mapas para la zona de estudio de los meses de enero, febrero y marzo, **Anexo G**.

https://github.com/JoseZevallosR/Bartlet-Lewis_Regionalization/blob/main/src/InterpolationFunctions.R

5. Resultados y Discusión

5.1. Mapas regionales de parámetros MBLRP

El mapeo anterior descrito, **Figura 10**, da como resultados los parámetros regionalizados para el mes de febrero. Los colores para cada mapa indican el rango de valores en los que se encuentran los parámetros de MBLRP. Por ejemplo, el parámetro μ (mm) tiene como valor mínimo 0.12 y máximo 7.92. En el **Anexo B** se tiene la tabla de los parámetros obtenidos de la regionalización para las 203 estaciones consideradas en este estudio.

Se puede observar que los parámetros λ y μ muestran patrones espaciales más definidos en comparación a los otros parámetros. Estos patrones se justifican coincidentemente en el texto Kim et al., (2013) donde menciona: que puede deberse a parámetros asociados a las variables físicas observables menos afectadas por la multimodalidad en la calibración del modelo.

Los patrones espaciales inferidos son delimitados de mejor manera en la costa y sierra en contraste con la selva peruana, debido a la baja densidad de estaciones pluviométricas en la vertiente del Amazonas que traen como consecuencia una distribución espacial dispersa **Figura 1**.

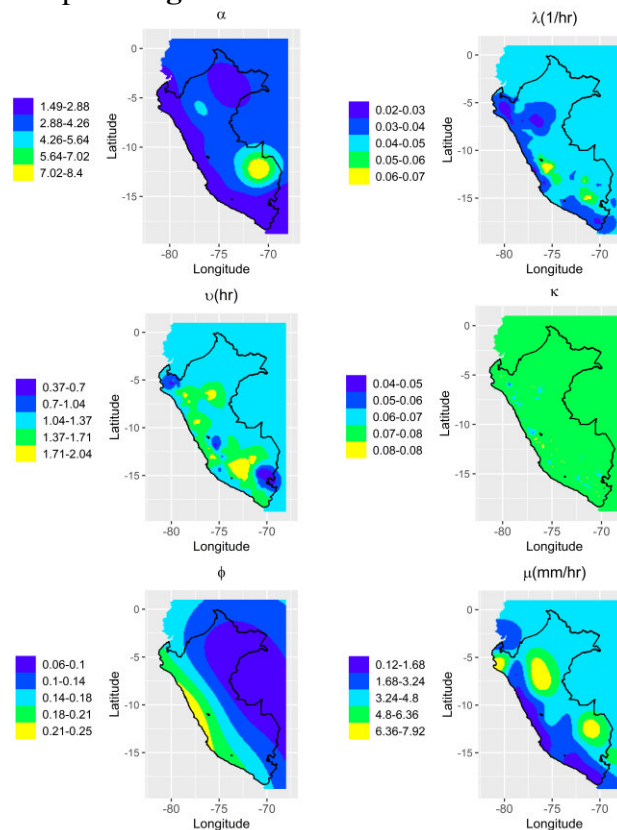


Figura 10 Parámetros regionalizados del modelo MBLRP para el mes de febrero

A pesar que la auto covarianza de las precipitaciones, presentan una gran variabilidad en la zona de estudio, los parámetros del modelo MBLRP asociados a esta estadística α y ν presentan una distribución espacial aceptable.

El parámetro α en la **Figura 10**, muestra patrones regionales similares a las vertientes de Pacifico, Amazonas y Titicaca.

El parámetro ν por su parte muestra un radio de influencia menor alrededor de las estaciones utilizadas en la regionalización, por tal motivo una posible inferencia es que se necesita mayor densidad de estaciones para mejorar su caracterización espacial.

El parámetro ϕ presenta valores similares a lo largo de franjas latitudinales en la zona de estudio.

Finalmente, $\kappa = \beta/\eta$ relación adimensional entre la tasa de generación de pulso y la duración de estos, muestra un patrón espacial casi constante en toda la zona de estudio con ligera influencia alrededor zonas aisladas. Similar al comportamiento del parámetro ν , que requiere de mayor densidad de estaciones para poder distribuir espacialmente mejor κ .

El efecto de aplicación del VCR al parámetro μ se va refinando. Esto se puede observar en la **Figura 11** por la influencia vecinal de las estaciones pluviométricas.

En la **Figura 11**, la imagen de la iteración 0 muestra los parámetros del MBLRP sin aplicación del VCR, ahora a partir de la iteración 3 los mapas subsecuentes del parámetro μ son similares sin llegar a una convergencia donde sean iguales. Esto es debido a que la calibración es mediante algoritmos estocásticos, por lo que la aleatoriedad del proceso no permite obtener mapas exactamente iguales, pero si similares en las posteriores iteraciones.




Figura 11 Impacto de las validaciones cruzados en la estimación de parámetros MBLRP. Los mapas del parámetro μ después de la interacción 0 hasta 5.

5.2. Evaluación de los resultados regionalizados

Para determinar la robustez de los mapas regionales de los parámetros MBLRP obtenidos, evaluamos por una validación cruzada siguiendo el siguiente procedimiento: Se retira una estación pluviométrica y se genera nuevamente la regionalización con las **n-1** estaciones restantes. Siendo **n** el total de estaciones disponibles. Una vez regionalizado los parámetros con las **n-1** estaciones, se procedió a obtener los 6 parámetros del modelo MBLRP en la ubicación de la estación retirada y registrarlos (**Anexo C**). Este proceso se realizó para cada una de las **n** estaciones pluviométricas. Los parámetros obtenidos de estas **n** validaciones cruzadas se utilizaron para generar estadísticos simulados con las ecuaciones 1, 2, 3 y 4. Luego estos estadísticos simulados fueron comparados con los estadísticos muestrales observados de las **n** estaciones. Idealmente, las diferencias entre estas mediciones serían mínimas o cero. Los estadísticos que se compararon son el promedio, varianza, covarianza y probabilidad de días secos. La **Figura 12** muestra los resultados de la validación cruzada para las 203 estaciones disponibles del mes de febrero. Cada columna representa un estadístico, las filas son diferentes agregados de precipitación temporal y adicionalmente se agregó la función identidad en cada gráfico para diferenciar cual estadístico es sub o sobre estimado regionalmente. El propósito de esta validación es evaluar la capacidad del método utilizado en la regionalización de los parámetros MBLRP para reproducir estadísticos de precipitaciones en zonas donde no se cuenta con información pluviométrica.

Se puede observar que en general la varianza y el promedio presentan un ajuste aceptable con ligeras dispersiones y un comportamiento simétrico en sub y sobre estimación en todos los niveles de acumulación. Los cuatro estadísticos para el acumulado de 24 horas presentan los mejores ajustes en general. Esto puede deberse a que en el proceso de calibración de MBLRP los pesos de importancia en el método de los momentos para estos estadísticos fueron mayores. La auto covarianza y la probabilidad de lluvia cero son los estadísticos que presentan mayores discrepancias, este resultado era de esperarse por la dificultad del modelo en representar temporadas secas (Cameron, David and Beven, Keith and Tawn, 2000; P. S. P. Cowpertwait & A, 1998; Onof, Christian and Wheater, 1993). Sin embargo, la importancia relativa de estos dos estadísticos en la simulación de volumen de escorrentía en una cuenca presentó valores menores a 22% (Kim & Olivera, 2012). Estos resultados son satisfactorios a nivel puntual de cada estación.

A pesar de ello debido a la baja densidad de estaciones pluviométricas en la selva peruana la interpolación con OK presenta deficiencias en la regionalización de los parámetros MBLRP. Esto es debido a que la variabilidad espacial de los parámetros MBLRP no puede ser correctamente aproximada con pocas estaciones por lo que grandes extensiones de áreas tendrían valores similares en la selva como se puede apreciar en la **Figura 10** para los 6 mapas.

La densidad de estaciones influye en la certeza de los resultados. Por esta razón la mayor confiabilidad de los mapas obtenidos es a lo largo de la cordillera de los Andes y la vertiente del Titicaca donde la densidad de estaciones es mayor **Anexo H**.
https://github.com/JoseZevallosR/Bartlett-Lewis_Regionalization/blob/main/scripts/VALIDACION_CRUZADA_DE_MBLRP.R




Figura 12 Comparación de los estadísticos observados y los simulados a partir de validación cruzada. Cada fila corresponde a un nivel de acumulación y las columnas representan un diferente tipo de estadístico de precipitación

5.3. Evaluación de la regionalización con datos del proyecto Tocache

Para la evaluación de la certeza las funciones de densidad acumulativas empíricas (CDF) que reproducen los mapas regionales del modelo MBLRP para precipitaciones acumuladas de 3 horas, se usó información meteorológica del proyecto Tocache **Figura 1**. Los resultados de las gráficas de los CDF para las estaciones de la **Tabla 2** se presentan en la **Figura 13**, muestran una similitud entre las CDFs de las series simuladas y observadas.

Alternativamente se realizó una evaluación para determinar si las series simuladas y observadas provienen de una misma distribución estadística, el test más apropiado a nuestra consideración es el de Kolmogórov-Smirnov (KS test); determinamos si los estadísticos de la máxima diferencia (**D**) entre los CDFs es significativa o no hablando estadísticamente. Se encontró que las 6 estaciones rechazan la hipótesis de pertenecer a una misma distribución. Estos resultados pueden deberse a la diversidad climática en el Perú, la dificultad de reproducir extremos por parte del modelo MBLRP (P. S. P. Cowpertwait & A, 1998) y también por el registro corto, 4-5 años, de las estaciones independientes en la validación.

Los resultados del test de KS se muestran en la **Tabla 11**. El estadístico D es la diferencia máxima entre las distribuciones acumuladas de las series observadas y las simuladas con MBLRP, el p valor es la probabilidad de que esta diferencia sea significativa. Si el p valor es mayor a 0.05 se dice que la serie simulada y observada tienen la misma distribución estadística. Que en nuestro caso los p calculados son menores que el p estadístico de 0.05.

Esta incongruencia se grafica en la **Figura 13** donde se puede apreciar que las CDF de las estaciones HUA_01 y HMT_01 para sus datos observados y simulados son muy similares. Las CDF observadas, color rojo, de las estaciones PIU_02, PIU_06, PIU_07 y CHA_01 presentan menos valores extremos que las series simuladas en esas ubicaciones (color azul). Esto puede deberse a sobre estimaciones por parte de las series simuladas o también a que se requiere mayores registros de precipitaciones en dichas ubicaciones para medir más eventos extremos en el tiempo **Anexo I**.
https://github.com/JoseZevallosR/Bartlett-Lewis_Regionalization/blob/main/scripts/VALIDACION_INDEPENDIENTE_DE_MBLRP.R

Tabla 11 Resultados del test de KS de la validación independiente

Estaciones	Estadístico D	p valor
PIU_02	0.169663	0.042000
PIU_06	0.270687	0.000000
PIU_07	0.186521	0.015927
CHA_01	0.274603	0.005273
HUA_01	0.109194	0.036799
HMT_01	0.265276	0.000103

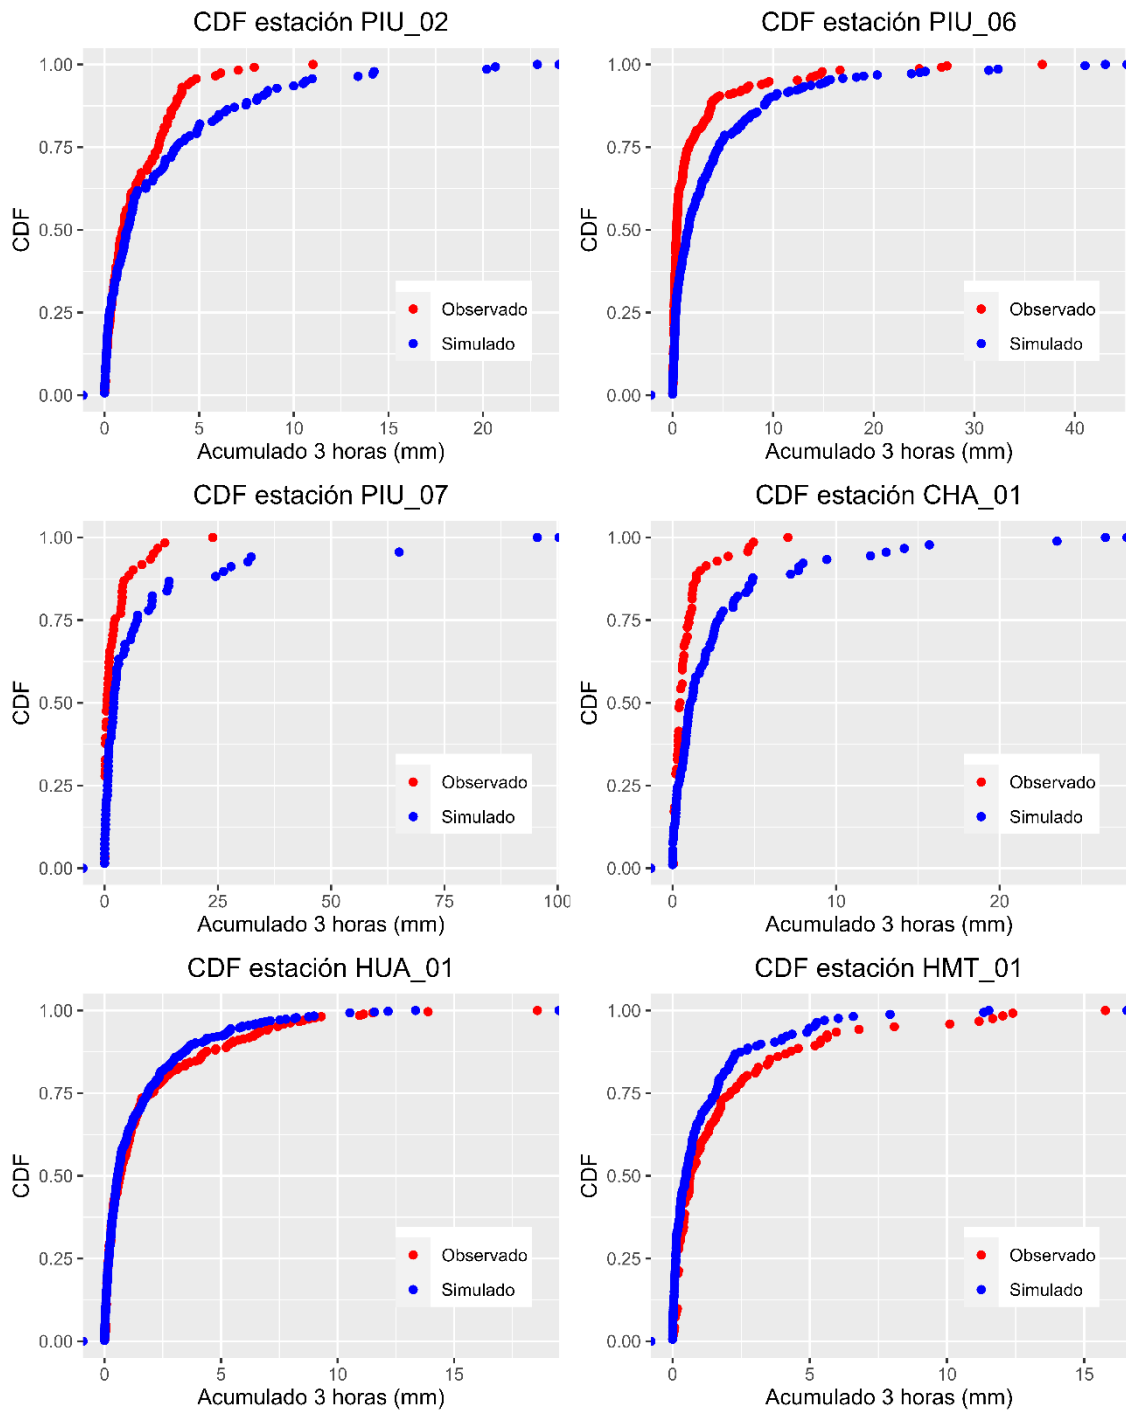


Figura 13 Función de densidad acumulada (CDF) de series de precipitación simulada y observada para el acumulado de 3 horas. Los valores considerados son mayores a cero y corresponden al mes de febrero para las estaciones de la **Tabla 2..**

5.4. Mapas de caracterización de tormentas con el MBLRP para la zona de estudio

Tal como hemos visto en el ítem 3.1, la conceptualización del MBLRP, las tormentas están conformadas por secuencias de lluvias representadas por celdas rectangulares con duraciones e intensidades aleatorias los que nos permite inferir ciertas características de precipitación en la zona de estudio.

Unas características como la altura de lluvia promedio y la duración de tormentas son calculadas utilizando las ecuaciones que propone Kim et al. (2016b) las cuales son:

$$\text{Duración promedio de tormentas} = \frac{\mu}{\phi\alpha} \quad (15)$$

$$\text{Altura promedio de precipitación por tormenta} = \frac{\mu\nu}{\alpha} \left(1 + \frac{\kappa}{\phi}\right) \quad (16)$$

En la **Tabla 12** se muestran los parámetros del modelo MBLRP para la estación Namora, ahora utilizando las ecuaciones 15 y 16 se tiene:

$$\text{Duración promedio de tormentas de Namora} = \frac{1.87}{0.085 * 2.38} = 9.24 \text{ horas}$$

$$\begin{aligned} \text{Altura promedio de precipitaciones por tormenta de Namora} \\ = 1.87 * \frac{1.551}{2.38} \left(1 + \frac{0.078}{0.085}\right) = 2.33 \text{ mm} \end{aligned}$$

Tabla 12 Juego de parámetros MBLRP de estación Namora de Cajamarca para el mes de febrero

Nombre	PROVINCIA	α	λ	ν	κ	ϕ	μ
NAMORA	CAJAMARCA	2.38	0.036	1.551	0.078	0.085	1.870

Estos cálculos se pueden realizar de manera generalizada para los mapas regionalizados de los parámetros indicados en el punto 5.4 de esta monografía.




Figura 14 Características de tormentas y celdas para el mes de febrero acorde a los parámetros del modelo MBLRP

De la **Figura 14** se infiere que el comportamiento de las tormentas en la costa es de corta duración y de baja cantidad con excepción de la costa norte para el mes de febrero. Este patrón de precipitaciones es esperado y es coherente con la descripción climática realizada de la zona de estudio en el punto **2.1** en la que se describe el efecto niño que afecta a Piura y Tumbes.

Las tormentas están en el intervalo de duración promedio entre 1 y 8 horas. Las duraciones más bajas se encuentran a lo largo de la costa con excepción de la zona del departamento de Tacna donde se aprecia precipitaciones de duración media 4-5 horas, pero de baja intensidad con un rango de 1.21 a 2.29 milímetros **Figura 14**.

La mayor cantidad de precipitación en la selva se da en un área reducida (zona amarilla) **Figura 14** imagen (b). Esto es debido a la influencia de la baja densidad de estaciones en dicha área. Por tal motivo los resultados en dicha zona deben considerarse como aproximados y con mayor incertidumbre **Anexo J**. https://github.com/JoseZevallosR/Bartlet-Lewis_Regionalization/blob/main/scripts/CARACTERISTICAS_DE_TORMENTAS.R

5.5. Precipitaciones simuladas

A lo largo del trabajo se ha mencionado la capacidad del modelo MBLRP en simular precipitaciones horarias (sub diarias). Por ejemplo, con los parámetros de la estación Namora que se muestran en la **Tabla 12** se puede generar simulaciones de precipitación para diferentes duraciones. Estas simulaciones no pertenecen a registros históricos, sin embargo, aproximan el comportamiento estadístico de la estación Namora y lo encapsulan en el concepto de precipitación del modelo MBLRP.

En la **Figura 15** se muestran las precipitaciones simuladas para la estación de Namora en diferentes acumulados de precipitación, 1,6, 12 y 24 horas. Por cada simulación se generaron 1000 datos del mes de febrero. Podemos observar que en el agregado de 1 hora se pueden apreciar las estructuras rectangulares propias del modelo MBLRP. Además, la diferencia de cantidad de precipitación entre el acumulado de 12 y 24 horas es mínima. Esto puede deberse a que las duraciones de precipitaciones en Namora en promedio son de 9 horas durante el mes de febrero.

Esta capacidad de simular precipitaciones con el modelo MBLRP representa una ventaja con respecto a la utilización de información satelital pura de TRMM. Esto es debido a que el modelo MBLRP ya está calibrado con datos de TRMM y pluviométricos, además de poder simular precipitación para diferentes acumulados según la necesidad de ingeniería que se tenga **Anexo K**.

https://github.com/JoseZevallosR/Bartlet-Lewis_Regionalization/blob/main/scripts/PRECIPITACION_SIMULADA_NAMORA.R




Figura 15 Precipitaciones simuladas para la estación Namora. Cada gráfico indica el agregado de simulación 1, 6, 12 y 24 horas.

6. Conclusiones

Los datos desagregados de la estación Chulucanas se muestran en la **Tabla 6**, estos fueron procesados usando información del satélite TRMM, determinando un factor multiplicativo de desagregación para 3, 6, 12, 18 horas que se detalla en la columna factores, este procedimiento se realizó para las 203 estaciones que involucran a la zona de estudio.

Los estadísticos calculados de las estaciones pluviométricas desagregadas se obtuvieron para los meses de enero, febrero y marzo tal como se muestra en la tabla 5 y tabla 6 para 3 y 24 horas.

El efecto de la aplicación del VCR a los parámetros de MBLRP va refinando las regiones. Esto se puede observar en la **Figura 11** por la influencia vecinal de las estaciones pluviométricas.

Los parámetros mapeados obtenidos con el método evolutivo de recocido simple (AES) refinados con validaciones cruzadas repetitivas (VCR) se muestra en la **Figura 10** para el mes de febrero, los resultados para las 203 estaciones, los meses de enero y marzo se encuentran en los anexos B y D. Los colores en cada mapa indican los rangos de valores en que se encuentra los parámetros del MBLRP, así el parámetro μ (mm) tiene como valor mínimo 0.12 y máximo 7.92 para febrero.

Se puede observar que los parámetros λ y μ muestran patrones espaciales más definidos en comparación a los otros parámetros (κ , ϕ , α , ν). Estos patrones se justifican coincidentemente en el texto Kim et al., (2013) donde menciona: que puede deberse a parámetros asociados a las variables físicas observables menos afectadas por la multimodalidad en la calibración del modelo.

Los patrones espaciales inferidos son delimitados de mejor manera en la costa y sierra en contraste con la selva peruana, debido a la baja densidad de estaciones pluviométricas en la vertiente del Amazonas que traen como consecuencia una distribución espacial dispersa **Figura 1**.

La auto covarianza de precipitaciones presenta una gran variabilidad (**Anexo XX columna xx**) en la zona de estudio sin embargo los parámetros de MBLRP asociados a esta estadística α y ν presentan una distribución espacial aceptable.

El resultado en las vertientes Pacífico, Amazonas y Titicaca muestran patrones regionales similares para el parámetro α , **Figura 10**.

La magnitud reducida de estaciones pluviométricas en la zona de estudio, se evidencia en el parámetro ν y κ , donde los patrones espaciales son constantes efecto de un radio de influencia menor alrededor de las estaciones.

El parámetro ϕ presenta valores similares a lo largo de franjas latitudinales en la zona de estudio.

Al realizar para las estaciones del proyecto Ochoa-Tocachi una evaluación y determinar si las distribuciones estadísticas de las series simuladas y observadas son las mismas usando el test de Kolmogórov-Smirnov, arrojaron que los parámetros estadísticos, p valor son menores a 0.05, rechazando la hipótesis que las distribuciones son del mismo origen. Estos resultados pueden deberse a la diversidad climática en el Perú, la dificultad de reproducir extremos por parte del modelo MBRLP (P. S. P. Cowpertwait & A, 1998) y también por el registro corto, 4-5 años, de las estaciones independientes en la validación.

Las tormentas del mes de febrero, en la costa, son de corta duración y de baja cantidad excepto la costa norte **Figura 14**, coherente con la descripción climática de la zona de estudio (ítem 2.1) influenciada por el efecto de El Niño. Las tormentas están en el intervalo de duración promedio entre 1 y 8 horas. Las duraciones más bajas se encuentran a lo largo de la costa con excepción de la zona del departamento de Tacna donde se aprecia precipitaciones de duración media 4-5 horas, pero de baja intensidad con un rango de 1.21 a 2.29 milímetros **Figura 14**.

Bibliografía

- Abbühl, L. M., Norton, K. P., Schlunegger, F., Kracht, O., Aldahan, A., & Possnert, G. (2010). El Niño forcing on 10Be-based surface denudation rates in the northwestern Peruvian Andes? *Geomorphology*, 123(3–4), 257–268. <https://doi.org/10.1016/j.geomorph.2010.07.017>
- Antico. (2009). Ocean circulation: Thermohaline circulation. *Encyclopedia of Atmospheric Sciences*, 4(December 2007), 1549-1555. <https://doi.org/10.1002/joc>
- Aybar, C., Fernández, C., Huerta, A., Lavado, W., & Vega, F. (2019). ce pt t. *Hydrological Sciences Journal*, 0(0), 1. <https://doi.org/10.1080/02626667.2019.1649411>
- Bathurst, J. C., Moretti, G., El-Hames, A., Moaven-Hashemi, A., & Burton, A. (2005). Scenario modelling of basin-scale, shallow landslide sediment yield, Valsassina, Italian Southern Alps. *Natural Hazards and Earth System Science*, 5(2), 189–202. <https://doi.org/10.5194/nhess-5-189-2005>
- Cameron, David and Beven, Keith and Tawn, J. (2000). Modelling extreme rainfalls using a modified random pulse Bartlett--Lewis stochastic rainfall model (with uncertainty). *Advances in Water Resources*, 24, 203–211.
- Cowpertwait, P. S. (2006). A spatial-temporal point process model of rainfall for the Thames catchment, UK. *Journal of Hydrology*, 330(3–4), 586–595. <https://doi.org/10.1016/j.jhydrol.2006.04.043>
- Cowpertwait, P. S. P., & A, P. R. S. L. (1998). *A Poisson-cluster model of rainfall : some high-order moments and extreme values A Poisson-cluster model of rainfall : high-order*. 885–898. <https://doi.org/10.1098/rspa.1998.0191>
- Dinku, T., Chidzambwa, S., Ceccato, P., Connor, S. J., & Ropelewski, C. F. (2008). Validation of high-resolution satellite rainfall products over complex terrain. *International Journal of Remote Sensing*, 29(14), 4097–4110. <https://doi.org/10.1080/01431160701772526>
- Efstratiadis, A., & Koutsoyiannis, D. (2002). An evolutionary annealing-simplex algorithm for global optimisation of water resource systems Overview of nonlinear optimisation algorithms. *Proceedings of the Fifth International Conference on Hydroinformatics*, 3.
- Garreaud, R. (1999). Multiscale Analysis of the Summertime Precipitation over the Central Andes. *Monthly Weather Review*, 127(5), 901–921. [https://doi.org/10.1175/1520-0493\(1999\)127<0901:MAOTSP>2.0.CO;2](https://doi.org/10.1175/1520-0493(1999)127<0901:MAOTSP>2.0.CO;2)
- Garreaud, R. D., Vuille, M., Compagnucci, R., & Marengo, J. (2009). Present-day South American climate. *Palaeogeography, Palaeoclimatology, Palaeoecology*, 281(3–4), 180–195. <https://doi.org/10.1016/j.palaeo.2007.10.032>
- Gyasi-Agyei, Y. (1999). Identification of regional parameters of a stochastic model for rainfall disaggregation. *Journal of Hydrology*, 223(3–4), 148–163. [https://doi.org/10.1016/S0022-1694\(99\)00114-6](https://doi.org/10.1016/S0022-1694(99)00114-6)
- Hiemstra, P. H., Pebesma, E. J., Twenhöfel, C. J. W., & Heuvelink, G. B. M. (2009). Real-time automatic interpolation of ambient gamma dose rates from the Dutch radioactivity monitoring network. *Computers and Geosciences*, 35(8), 1711–1721. <https://doi.org/10.1016/j.cageo.2008.10.011>
- Huffman, G. J., Adler, R. F., Bolvin, D. T., Gu, G., Nelkin, E. J., Bowman, K. P., Hong, Y., Stocker, E. F., & Wolff, D. B. (2007). The TRMM Multisatellite Precipitation Analysis (TMPA): Quasi-global, multiyear, combined-sensor precipitation estimates at fine scales. *Journal of Hydrometeorology*, 8(1), 38–55. <https://doi.org/10.1175/JHM560.1>
- Hunziker, S., Brönnimann, S., Calle, J., Moreno, I., Andrade, M., Ticona, L., Huerta,

- A., & Lavado-Casimiro, W. (2018). Effects of undetected data quality issues on climatological analyses. *Climate of the Past*, *14*(1), 1–20. <https://doi.org/10.5194/cp-14-1-2018>
- Kim, D., Kwon, H. H., Lee, S. O., & Kim, S. (2016a). Regionalization of the Modified Bartlett–Lewis rectangular pulse stochastic rainfall model across the Korean Peninsula. *Journal of Hydro-Environment Research*, *11*, 123–137. <https://doi.org/10.1016/j.jher.2014.10.004>
- Kim, D., Kwon, H. H., Lee, S. O., & Kim, S. (2016b). Regionalization of the Modified Bartlett–Lewis rectangular pulse stochastic rainfall model across the Korean Peninsula. *Journal of Hydro-Environment Research*, *11*, 123–137. <https://doi.org/10.1016/j.jher.2014.10.004>
- Kim, D., & Olivera, F. (2012). Relative Importance of the Different Rainfall Statistics in the Calibration of Stochastic Rainfall Generation Models. *Journal of Hydrologic Engineering*, *17*(3), 368–376. [https://doi.org/10.1061/\(asce\)he.1943-5584.0000453](https://doi.org/10.1061/(asce)he.1943-5584.0000453)
- Kim, D., Olivera, F., Cho, H., & Socolofsky, S. A. (2013). Regionalization of the modified bartlett-lewis rectangular pulse stochastic rainfall model. *Terrestrial, Atmospheric and Oceanic Sciences*, *24*(3), 421–436. [https://doi.org/10.3319/TAO.2012.11.12.01\(Hy\)](https://doi.org/10.3319/TAO.2012.11.12.01(Hy))
- Kossieris, Panagiotis and Makropoulos, Christos and Creaco, Enrico and Vamvakeridou-Lyroudia, Lydia and Savic, D. A. (2016). Assessing the applicability of the bartlett-lewis model in simulating residential water demands. *Procedia Engineering*, *154*, 123–131. <https://doi.org/10.1016/j.proeng.2016.07.429>
- Kossieris, P., Makropoulos, C., Onof, C., & Koutsoyiannis, D. (2018). A rainfall disaggregation scheme for sub-hourly time scales: Coupling a Bartlett-Lewis based model with adjusting procedures. *Journal of Hydrology*, *556*, 980–992. <https://doi.org/10.1016/j.jhydrol.2016.07.015>
- Lavado Casimiro, W. S., Ronchail, J., Labat, D., Espinoza, J. C., & Guyot, J. L. (2012). Basin-scale analysis of rainfall and runoff in Peru (1969–2004): Pacific, Titicaca and Amazonas drainages. *Hydrological Sciences Journal*, *57*(4), 625–642. <https://doi.org/10.1080/02626667.2012.672985>
- Llauca, H., Lavado-casimiro, W., León, K., Jimenez, J., Traverso, K., & Rau, P. (2021). Assessing near real-time satellite precipitation products for flood simulations at sub-daily scales in a sparsely gauged watershed in Peruvian andes. *Remote Sensing*, *13*(4), 1–18. <https://doi.org/10.3390/rs13040826>
- Mantas, V. M., Liu, Z., Caro, C., & Pereira, A. J. S. C. (2015). Validation of TRMM multi-satellite precipitation analysis (TMPA) products in the Peruvian Andes. *Atmospheric Research*, *163*, 132–145. <https://doi.org/10.1016/j.atmosres.2014.11.012>
- Marengo, J. A., Liebmann, B., Grimm, A. M., Misra, V., Silva Dias, P. L., Cavalcanti, I. F. A., Carvalho, L. M. V., Berbery, E. H., Ambrizzi, T., Vera, C. S., Saulo, A. C., Nogues-Paegle, J., Zipser, E., Seth, A., & Alves, L. M. (2012). Recent developments on the South American monsoon system. *International Journal of Climatology*, *32*(1), 1–21. <https://doi.org/10.1002/joc.2254>
- Nerini, D., Zulkafli, Z., Wang, L.-P., Onof, C., Buytaert, W., Lavado-Casimiro, W., & Guyot, J.-L. (2015). A Comparative Analysis of TRMM–Rain Gauge Data Merging Techniques at the Daily Time Scale for Distributed Rainfall–Runoff Modeling Applications. *Journal of Hydrometeorology*, *16*(5), 2153–2168. <https://doi.org/10.1175/JHM-D-14-0197.1>
- Ochoa-Tocachi, B. F., Buytaert, W., Antiporta, J., Acosta, L., Bardales, J. D., Célleri, R., Crespo, P., Fuentes, P., Gil-Ríos, J., Gualpa, M., Llerena, C., Olaya, D., Pardo,

- P., Rojas, G., Villacís, M., Villazón, M., Viñas, P., & De Bièvre, B. (2018). Data Descriptor: High-resolution hydrometeorological data from a network of headwater catchments in the tropical Andes. *Scientific Data*, 5, 1–16. <https://doi.org/10.1038/sdata.2018.80>
- Onof, C and Chandler, RE and Kakou, A and Northrop, P and Wheeler, HS and Isham, V. (2000). Rainfall modelling using Poisson-cluster processes: a review of developments. *Stochastic Environmental Research and Risk Assessment*, 14(6), 0384–0411. <https://doi.org/10.1007/s004770000043>
- Onof, Christian and Wheeler, H. S. (1993). Modelling of British rainfall using a random parameter Bartlett-Lewis rectangular pulse model. *Journal of Hydrology*, 149(1–4), 67–95. [https://doi.org/10.1016/0022-1694\(93\)90100-N](https://doi.org/10.1016/0022-1694(93)90100-N)
- Ritschel, C., Rust, H. W., & Ulbrich, U. (2017). Precipitation extremes on multiple time scales – Bartlett–Lewis Rectangular Pulse Model and Intensity–Duration–Frequency curves. *Hydrology and Earth System Sciences Discussions*, 2013(April), 1–20. <https://doi.org/10.5194/hess-2017-207>
- Rodriguez-Iturbe, Ignacio and Cox, David Roxbee and Isham, V. (1988). A point process model for rainfall: further developments. *Proceedings of the Royal Society of London. A. Mathematical and Physical Sciences*, 417(1853), 283–298. <https://doi.org/10.1098/rspa.1988.0061>
- Scheel, M. L. M., Rohrer, M., Huggel, C., Santos Villar, D., Silvestre, E., & Huffman, G. J. (2011). Evaluation of TRMM Multi-satellite Precipitation Analysis (TMPA) performance in the Central Andes region and its dependency on spatial and temporal resolution. *Hydrology and Earth System Sciences*, 15(8), 2649–2663. <https://doi.org/10.5194/hess-15-2649-2011>
- Shepard, D. (1968). A two-dimensional interpolation function for irregularly-spaced data. *23rd ACM National Conference*, 517–524. <https://doi.org/10.1145/800186.810616>
- Vanhoute, W. J., Vandenberghe, S., Scheerlinck, K., De Baets, B., & Verhoest, N. E. C. (2012). Calibration of the modified Bartlett-Lewis model using global optimization techniques and alternative objective functions. *Hydrology and Earth System Sciences*, 16(3), 873–891. <https://doi.org/10.5194/hess-16-873-2012>
- Wheater, H. S., Chandler, R. E., Onof, C. J., Isham, V. S., Bellone, E., Yang, C., Lekkas, D., Lourmas, G., & Segond, M. L. (2005). Spatial-temporal rainfall modelling for flood risk estimation. *Stochastic Environmental Research and Risk Assessment*, 19(6), 403–416. <https://doi.org/10.1007/s00477-005-0011-8>
- Yusop, Z., Nasir, H., & Yusof, F. (2014). Disaggregation of daily rainfall data using Bartlett Lewis Rectangular Pulse model: a case study in central Peninsular Malaysia. *Environmental Earth Sciences*, 71(8), 3627–3640. <https://doi.org/10.1007/s12665-013-2755-7>
- Zevallos, J. A. (2018). *Estimación de curvas de intensidad-duración-frecuencia de precipitaciones para el Perú usando precipitaciones horarias simuladas con el modelo de pulso rectangular de Bartlett-Lewis*. Lima: Repositorio Digital de Tesis y Trabajos de Investigación PUCP.

Anexo A

Cuadro de las 203 estaciones convencionales utilizadas

Nombre	LONGITUD	LATITUD	ALTITUD	DEPARTAMENTO	PROVINCIA
CHULUCANAS	-80.16944	-5.101667	89	PIURA	MORROPON
MASHCON	-78.4848	-7.166611	2662	CAJAMARCA	CAJAMARCA
EL PORVENIR	-76.32194	-6.593056	223	SAN MARTIN	SAN MARTIN
NAMORA	-78.33889	-7.203333	2760	CAJAMARCA	CAJAMARCA
SONDOR-MATARA	-78.23722	-7.220278	2908	CAJAMARCA	SAN MARCOS
LA MUCHALA	-79.21639	-6.825556	1707	CAJAMARCA	CHOTA
CONTUMAZA	-78.83028	-7.355833	2542	CAJAMARCA	CONTUMAZA
GRANJA PORCON	-78.62667	-7.033889	3149	CAJAMARCA	CAJAMARCA
CHOTA	-78.61694	-6.766944	2468	CAJAMARCA	CHOTA
CELENDIN	-78.11833	-6.864167	2602	CAJAMARCA	CELENDIN
CAJABAMBA	-78.05056	-7.626944	2625	CAJAMARCA	CAJABAMBA
HUAMACHUCO	-78.05083	-7.830278	3186	LA LIBERTAD	SANCHEZ CARRION
RIOJA	-77.16694	-6.046667	823	SAN MARTIN	RIOJA
LLAPA	-78.83028	-6.999722	2951	CAJAMARCA	SAN MIGUEL
JESUS	-78.38944	-7.237222	2564	CAJAMARCA	CAJAMARCA
MAGDALENA	-78.66056	-7.254167	1307	CAJAMARCA	CAJAMARCA
MONTE GRANDE	-79.15322	-7.225028	431	CAJAMARCA	CONTUMAZA
SANTIAGO ANTUNEZ DE MAYOLO	-77.52486	-9.516528	3079	ANCASH	HUARAZ
RECUAY	-77.45403	-9.729472	3431	ANCASH	RECUAY
CHAVIN	-77.17553	-9.586333	3140	ANCASH	HUARI
SANTA ANA	-75.22111	-12.004444	3293	JUNIN	HUANCAYO
RICRAN	-75.4794	-11.7831	3674	JUNIN	JAUIJA
PAMPAS	-74.86611	-12.393056	3250	HUANCAVELICA	TAYACAJA
CAJATAMBO	-76.98975	-10.477858	3432	LIMA	CAJATAMBO
OYON	-76.76694	-10.666944	3652	LIMA	OYON
PICOY	-76.73361	-10.916944	2903	LIMA	OYON
OBRAJILLO	-76.61694	-11.466944	2696	LIMA	CANTA
MATUCANA	-76.37828	-11.839389	2417	LIMA	HUAROCHIRI
TARMA	-75.69028	-11.396944	3025	JUNIN	TARMA
COMAS	-75.1292	-11.7486	3603	JUNIN	CONCEPCION
CERRO DE PASCO	-76.25417	-10.694444	4357	PASCO	PASCO
GRANJA KAYRA	-71.87528	-13.556944	3214	CUSCO	CUSCO
HUAROCHIRI	-76.23361	-12.133611	3120	LIMA	HUAROCHIRI
HUAYAO	-75.33889	-12.033611	3321	JUNIN	CHUPACA
YAUYOS	-75.91061	-12.492056	2285	LIMA	YAUYOS
PAUCARBAMBA	-74.53594	-12.555667	3380	HUANCAVELICA	CHURCAMP
HUANCAPI	-74.0705	-13.7504	3117	AYACUCHO	VICTOR FAJARDO
MACHU PICCHU	-72.54583	-13.166944	2399	CUSCO	URUBAMBA

URUBAMBA	-72.12524	-13.303589	2850	CUSCO	URUBAMBA
ANTA ANCAHURO	-72.21583	-13.468333	3324	CUSCO	ANTA
PARURO	-71.84472	-13.7675	3070	CUSCO	PARURO
ACOMAYO	-71.68361	-13.916944	3212	CUSCO	ACOMAYO
PAUCARTAMBO	-71.59056	-13.324444	2905	CUSCO	PAUCARTAMBO
CCATCCA	-71.56028	-13.61	3681	CUSCO	QUISPICANCHI
ENAFER	-70.01806	-15.823333	3812	PUNO	PUNO
PAUZA	-73.35583	-15.288056	2489	AYACUCHO	PAUCAR DEL SARA SARA
COTAHUASI	-72.89389	-15.211111	2683	AREQUIPA	LA UNION
CHUQUIBAMBA	-72.64861	-15.838056	2859	AREQUIPA	CONDESUYOS
LA ANGOSTURA	-71.64944	-15.179722	4258	AREQUIPA	CAYLLOMA
SIBAYO	-71.45306	-15.485556	3816	AREQUIPA	CAYLLOMA
LLALLY	-70.89806	-14.948889	3985	PUNO	MELGAR
PAMPAHUTA	-70.6775	-15.491389	4316	PUNO	LAMPA
CHUQUIBAMBILLA	-70.72833	-14.796389	3918	PUNO	MELGAR
IMATA	-71.08778	-15.836667	4475	AREQUIPA	CAYLLOMA
AYAVIRI	-70.59278	-14.881111	3930	PUNO	MELGAR
PROGRESO	-70.35556	-14.694722	3925	PUNO	AZANGARO
CABANILLAS	-70.34639	-15.6393	3885	PUNO	SAN ROMAN
ARAPA	-70.11861	-15.135556	3837	PUNO	AZANGARO
HUANCANE	-69.7625	-15.203333	3842	PUNO	HUANCANE
HUARAYA MOHO	-69.49139	-15.389722	3836	PUNO	MOHO
CAPACHICA	-69.8443	-15.6158	3822	PUNO	PUNO
PAUCARAY	-73.64389	-14.050833	3232	AYACUCHO	SUCRE
CABANACONDE	-71.96861	-15.618611	3333	AREQUIPA	CAYLLOMA
SALAMANCA	-72.83361	-15.500278	3203	AREQUIPA	CONDESUYOS
CAICAY	-71.69548	-13.597756	3117	CUSCO	PAUCARTAMBO
TAMBOBAMBA	-72.16694	-13.933611	3279	APURIMAC	COTABAMBAS
POMACANCHI	-71.57278	-14.028056	3690	CUSCO	ACOMAYO
ISLA TAQUILE	-69.69472	-15.779444	3837	PUNO	PUNO
MAÑAZO	-70.33889	-15.813333	3931	PUNO	PUNO
SANTA ROSA	-70.79639	-14.626944	3957	PUNO	MELGAR
CHIGUATA	-71.40028	-16.400278	2902	AREQUIPA	AREQUIPA
UBINAS	-70.85667	-16.3825	3381	MOQUEGUA	GENERAL SANCHEZ CERRO
CHUAPALCA ALTERNATIVA ALTA	-69.64361	-17.305	4185	TACNA	TARATA
CARUMAS	-70.69444	-16.813056	3055	MOQUEGUA	MARISCAL NIETO
CANDARAVE	-70.25389	-17.271111	3410	TACNA	CANDARAVE
ILAVE	-69.64361	-16.084722	3874	PUNO	EL COLLAO
LARAQUERI	-70.06778	-16.1525	3928	PUNO	PUNO
SAN ALEJANDRO	-75.20333	-8.830278	207	UCAYALI	PADRE ABAD
COSPAN	-78.54222	-7.440556	2300	CAJAMARCA	CAJAMARCA
ALAO	-76.73	-6.518889	421	SAN MARTIN	EL DORADO

PONGO DE CAYNARACHI	-76.30028	-6.333611	187	SAN MARTIN	LAMAS
RUNATULLO	-75.05083	-11.593056	3473	JUNIN	CONCEPCION
SALCABAMBA	-74.78583	-12.199444	3005	HUANCAVELICA	TAYACAJA
CHALLABAMBA	-71.64722	-13.2175	2803	CUSCO	PAUCARTAMBO
HUANCA	-71.87861	-16.030833	3065	AREQUIPA	CAYLLOMA
PACAYZAPA	-76.77806	-6.256111	913	SAN MARTIN	LAMAS
JEPELACIO	-76.93361	-6.050278	1057	SAN MARTIN	MOYOBAMBA
SAN PEDRO	-80.03389	-5.084722	236	PIURA	MORROPON
MALVAS	-77.65028	-9.933611	3009	ANCASH	HUARMEY
PARIACOTO	-77.89003	-9.559667	1312	ANCASH	HUARAZ
ARAHUAY	-76.70028	-11.616944	2504	LIMA	CANTA
SAN MATEO DE OTAO	-76.53164	-11.845083	3506	LIMA	HUAROCHIRI
AMBAR	-77.28361	-10.750278	2076	LIMA	HUAURA
SAN PEDRO DE PILAS	-76.21694	-12.450278	2690	LIMA	YAUYOS
LANGA	-76.42	-12.1325	2863	LIMA	HUAROCHIRI
HUACHOS	-75.54222	-13.220278	2736	HUANCAVELICA	CASTROVIRREYNA
HUAC-HUAS	-74.9406	-14.1319	3180	AYACUCHO	LUCANAS
SAPILICA	-79.99972	-4.796389	1450	PIURA	AYABACA
EL VIRREY	-79.96722	-5.580833	206	LAMBAYEQUE	LAMBAYEQUE
HACIENDA BIGOTE	-79.79639	-5.338889	205	PIURA	MORROPON
CHALACO	-79.83	-5.033889	2290	PIURA	MORROPON
CORRAL DEL MEDIO	-79.88361	-5.316944	207	PIURA	MORROPON
SONDORILLO	-79.40667	-5.338889	1702	PIURA	HUANCABAMBA
SALLIQUE	-79.31694	-5.766944	1804	CAJAMARCA	JAEN
CHONTALI	-79.06694	-5.966944	1626.5	CAJAMARCA	JAEN
CALLANCAS	-78.49139	-7.779444	1501	LA LIBERTAD	OTUZCO
CUEVA BLANCA	-79.4045	-6.1313	3300	LAMBAYEQUE	FERREÑAFE
TOCMOCHE	-79.35583	-6.406667	1399	CAJAMARCA	CHOTA
HACIENDA PUCARA	-79.1342	-6.0419	1012	CAJAMARCA	JAEN
UDIMA	-79.08444	-6.813056	2466	CAJAMARCA	SANTA CRUZ
LIVES	-79.03389	-7.084722	1932	CAJAMARCA	SAN MIGUEL
PUCHACA	-79.46694	-6.350278	345	LAMBAYEQUE	FERREÑAFE
SAN BENITO	-78.93083	-7.407778	1317	CAJAMARCA	CONTUMAZA
PUENTE CHILETE	-78.8376	-7.2242	854	CAJAMARCA	CONTUMAZA
EL TAMBO	-78.75506	-7.850306	688	LA LIBERTAD	GRAN CHIMÁs
CHUGUR	-78.74556	-6.677778	2748	CAJAMARCA	HUALGAYOC
DOS DE MAYO (J. OLAYA)	-76.40667	-7.406667	285	SAN MARTIN	BELLAVISTA
SORITOR	-77.08444	-6.135278	852	SAN MARTIN	MOYOBAMBA
CHOTANO LAJAS	-78.74861	-6.56	2148.2	CAJAMARCA	CHOTA
JEPELACIO	-76.915	-6.101389	1057	SAN MARTIN	MOYOBAMBA
CAMPANILLA	-76.68361	-7.433611	316	SAN MARTIN	MARISCAL CACERES

SAN PABLO	-76.57611	-6.813056	270	SAN MARTIN	BELLAVISTA
CUÑUMBUQUE	-76.50833	-6.508333	230	SAN MARTIN	LAMAS
NUEVO LIMA	-76.47417	-7.118333	255	SAN MARTIN	BELLAVISTA
SAN ANTONIO	-76.42361	-6.423611	467	SAN MARTIN	SAN MARTIN
SHANUSI	-76.25389	-6.067778	154	LORETO	ALTO AMAZONAS
PILLUANA	-76.28056	-6.778611	207	SAN MARTIN	PICOTA
CHAZUTA	-76.0983	-6.5689	183	SAN MARTIN	SAN MARTIN
PELEJO	-75.79	-6.215833	141	SAN MARTIN	SAN MARTIN
SHAMBOYACU	-76.16694	-7.000278	306	SAN MARTIN	PICOTA
HUANGACOCOA	-78.06833	-7.937222	3770	LA LIBERTAD	SANCHEZ CARRION
LA ENCAÑADA	-78.32194	-7.118611	2980	CAJAMARCA	CAJAMARCA
BIAVO	-76.49139	-7.253889	263	SAN MARTIN	BELLAVISTA
CACHICADAN	-78.1525	-8.101667	2892	LA LIBERTAD	SANTIAGO DE CHUCO
MOLLEPATA	-77.95556	-8.194722	2708	LA LIBERTAD	SANTIAGO DE CHUCO
HUACAMARCANGA	-78.28778	-8.101667	3902	LA LIBERTAD	SANTIAGO DE CHUCO
AGUAYTIA	-75.51417	-9.029722	316	UCAYALI	PADRE ABAD
OCROS	-77.40028	-10.400278	3249	ANCASH	OCROS
PAMPA LIBRE	-76.96694	-10.866944	1756	LIMA	HUAURA
PARIACANCHA	-76.50028	-11.383611	3842	LIMA	CANTA
PACCHO	-76.93361	-10.950278	3208	LIMA	HUAURA
ANDAJES	-76.90028	-10.783611	2707	LIMA	OYON
SANTA CRUZ	-76.63361	-11.200278	3583	LIMA	HUARAL
PALLAC	-76.80028	-11.350278	2367	LIMA	HUARAL
HUAMANTANGA	-76.75028	-11.500278	3392	LIMA	CANTA
PARQUIN	-76.71694	-10.966944	3571	LIMA	HUAURA
LACHAQUI	-76.61694	-11.550278	3670	LIMA	CANTA
CARAMPOMA	-76.51556	-11.655306	3424	LIMA	HUAROCHIRI
SAN JOSE DE PARAC	-76.25839	-11.800806	3829	LIMA	HUAROCHIRI
RICRAN	-75.52528	-11.542222	3674	JUNIN	JAUIJA
YAURICOCHA	-75.72292	-12.316667	4578	LIMA	YAUYOS
SANTA ANA	-75.16667	-12	3293	JUNIN	HUANCAYO
HUANCAVELICA	-74.96694	-12.783611	3717	HUANCAVELICA	HUANCAVELICA
LIRCAY	-74.71694	-12.983611	3303	HUANCAVELICA	ANGARAES
MILLOC	-76.35028	-11.571556	4391	LIMA	HUAROCHIRI
ANTIOQUIA	-76.50028	-12.083611	1516	LIMA	HUAROCHIRI
SAN LAZARO DE ESCOMARCA	-76.35028	-12.183611	3758	LIMA	HUAROCHIRI
AYAVIRI	-76.13361	-12.383611	3224	LIMA	YAUYOS
TANTA	-76.01694	-12.116944	4323	LIMA	YAUYOS
CARANIA	-75.87242	-12.344667	3840	LIMA	YAUYOS
HUANGASCAR	-75.83394	-12.898833	2500	LIMA	YAUYOS
VILCA	-75.82636	-12.114944	3832	LIMA	YAUYOS

SAN JUAN DE CASTROVIRREYNA	-75.64389	-13.203333	1856	HUANCAVELICA	CASTROVIRREYNA
SAN PEDRO DE HUACARPANA	-75.65028	-13.050278	3794	ICA	CHINCHA
CUSICANCHA	-75.305	-13.491389	3263	HUANCAVELICA	HUAYTARA
TAMBO	-75.27111	-13.694722	3145	HUANCAVELICA	HUAYTARA
SANTIAGO DE CHOCORVOS	-75.25417	-13.83	2600	HUANCAVELICA	HUAYTARA
HUANCALPI	-75.23722	-12.542222	3846	HUANCAVELICA	HUANCAVELICA
CHOCLOCOCHA	-75.03361	-13.100278	4547	HUANCAVELICA	CASTROVIRREYNA
VILCASHUAMAN	-73.94889	-13.643611	3518	AYACUCHO	VILCAS-HUAMAN
CHILCAYOC	-73.71694	-13.866944	3395	AYACUCHO	SUCRE
COLQUEPATA	-71.67333	-13.363333	3696	CUSCO	PAUCARTAMBO
CORDOVA	-75.16944	-14.033889	3199	HUANCAVELICA	HUAYTARA
LLAUTA	-74.93194	-14.237222	2569	AYACUCHO	LUCANAS
CHICHAS	-72.91658	-15.544722	2161	AREQUIPA	CONDESUYOS
ANDAHUA	-72.34917	-15.493611	3562	AREQUIPA	CASTILLA
ORCOPAMPA	-72.33889	-15.260833	3812	AREQUIPA	CASTILLA
AYO	-72.27028	-15.679167	1947	AREQUIPA	CASTILLA
CHOCO	-72.11694	-15.566944	2432	AREQUIPA	CASTILLA
HUAMBO	-72.10028	-15.733611	3312	AREQUIPA	CAYLLOMA
MADRIGAL	-71.81167	-15.616583	3273	AREQUIPA	CAYLLOMA
TISCO	-71.45028	-15.350278	4195	AREQUIPA	CAYLLOMA
PORPERA	-71.31694	-15.350278	4396	AREQUIPA	CAYLLOMA
CRUCERO ALTO	-70.91694	-15.766944	4521	PUNO	LAMPA
PUCARA	-70.33361	-15.033611	3877	PUNO	LAMPA
TARACO	-69.96694	-15.300278	3829	PUNO	HUANCANE
PUTINA	-69.86803	-14.914889	3861	PUNO	SAN ANTONIO DE PUTINA
PUENTE CARRETERA AZANGARO	-70.18361	-14.916944	3853	PUNO	AZANGARO
ISLA SOTO	-69.49139	-15.559167	3830	PUNO	MOHO
PAMPA DE ARRIEROS	-71.58917	-16.063333	3701	AREQUIPA	AREQUIPA
PILLONES	-71.21668	-15.981225	4432	AREQUIPA	CAYLLOMA
LAS SALINAS	-71.14833	-16.318056	4349	AREQUIPA	AREQUIPA
CALACOA	-70.6828	-16.7349	3421	MOQUEGUA	MARISCAL NIETO
PAMPA UMALZO (TITIJONES)	-70.42356	-16.875	4245	MOQUEGUA	MARISCAL NIETO
ICHUÑA	-70.53725	-16.14075	3874	MOQUEGUA	GENERAL SANCHEZ CERRO
CAIRANI	-70.33889	-17.288056	3386	TACNA	CANDARAVE
SUSAPAYA	-70.13278	-17.350833	3468	TACNA	TARATA
VILACOTA	-70.05028	-17.116944	4390	TACNA	TARATA
TALABAYA	-69.99972	-17.559167	3409	TACNA	TARATA
CAPAZO	-69.81306	-17.237222	4423	PUNO	EL COLLAO

PAUCARANI	-69.77944	-17.525	4625	TACNA	TACNA
CANAL UCHUSUMA	-69.62628	-17.579861	4260	TACNA	TACNA
LA FRONTERA	-69.46759	-17.393589	4067	TACNA	TARATA

Anexo B

Tabla de parámetros regionalizados

Nombre	LONGITUD	LATITUD	α	λ	ν	κ	ϕ	μ
CHULUCANAS	-80.169	-5.102	1.95	0.0225	0.723	0.0894	0.0854	4.51
EL PORVENIR	-76.322	-6.593	4.28	0.0283	1.3995	0.0517	0.0854	8.38
SAN PABLO	-78.847	-7.085	1.96	0.0366	1.3024	0.059	0.0854	1.89
NAMORA	-78.339	-7.203	2.38	0.0361	1.5506	0.0779	0.0854	1.87
SONDOR-MATARA	-78.237	-7.220	2.38	0.0288	2.1721	0.063	0.0854	1.63
LA MUCHALA	-79.216	-6.826	2.07	0.03	1.0469	0.0794	0.3697	2.95
CONTUMAZA	-78.830	-7.356	1.96	0.0351	1.6051	0.0573	0.0854	1.56
GRANJA PORCON	-78.627	-7.034	2.52	0.0452	1.6751	0.065	0.0854	2.63
CHOTA	-78.617	-6.767	2.45	0.0381	1.7497	0.0523	0.0854	1.7
CELENDIN	-78.118	-6.864	2.22	0.0294	1.4529	0.0731	0.0854	1.87
CAJABAMBA	-78.051	-7.627	2.54	0.0375	1.5082	0.0695	0.0854	2.12
HUAMACHUCO	-78.051	-7.830	2.57	0.0486	1.5082	0.0613	0.0854	1.89
RIOJA	-77.167	-6.047	4.40	0.0331	1.3482	0.076	0.0854	8.03
LLAPA	-78.830	-7.000	2.27	0.0415	1.6223	0.0787	0.0854	1.7
JESUS	-78.389	-7.237	2.62	0.0342	1.5506	0.0698	0.0854	1.87
MAGDALENA	-78.661	-7.254	2.44	0.0332	1.4529	0.0668	0.1629	1.87
MONTE GRANDE	-79.153	-7.225	3.17	0.03	1.0469	0.0585	0.0854	1.7
SANTIAGO ANTUNEZ DE MAYOLO	-77.525	-9.517	2.71	0.0433	2.0922	0.0634	0.0854	1.47
RECUAY	-77.454	-9.729	2.59	0.0436	1.4877	0.0697	0.0854	1.61
SANTA ANA	-75.221	-12.004	3.36	0.0583	0.8487	0.0894	0.0854	3.26
RICRAN	-75.479	-11.783	3.36	0.0708	0.3992	0.0591	0.0854	5.17
PAMPAS	-74.866	-12.393	2.88	0.0465	1.299	0.0613	0.3264	2.07
CAJATAMBO	-76.990	-10.478	2.29	0.0477	1.7669	0.0638	0.0861	1.14
OYON	-76.767	-10.667	2.67	0.0475	1.3825	0.0558	0.0854	1.54
PICOY	-76.734	-10.917	2.51	0.0434	1.4789	0.0606	0.0854	1.29
OBRAJILLO	-76.617	-11.467	2.42	0.0385	1.4248	0.0865	0.0854	1.17
MATUCANA	-76.378	-11.839	2.36	0.0355	1.5522	0.0698	0.1187	1.14
COMAS	-75.129	-11.749	3.68	0.0812	0.6974	0.081	0.0854	3.89
CERRO DE PASCO	-76.254	-10.694	2.80	0.0614	1.3233	0.0666	0.0854	1.71
GRANJA KAYRA	-71.875	-13.557	4.49	0.0496	1.5653	0.0815	0.1256	4.09
HUAROCHIRI	-76.234	-12.134	2.14	0.0442	1.8235	0.0717	0.0854	1.07
HUAYAO	-75.339	-12.034	3.36	0.0628	0.3992	0.072	0.0854	6.9
YAUYOS	-75.911	-12.492	1.95	0.0341	1.4515	0.0782	0.1103	1
PAUCARBAMBA	-74.536	-12.556	2.88	0.0623	1.8667	0.0823	0.0854	1.67
HUANCAPI	-74.071	-13.750	3.12	0.0475	1.896	0.0868	0.0854	2.13
URUBAMBA	-72.125	-13.304	4.33	0.0422	1.5476	0.0589	0.1198	4.09
ANTA ANCACHURO	-72.216	-13.468	4.09	0.0476	2.1099	0.069	0.1086	4.09
PARURO	-71.845	-13.768	4.18	0.0472	1.618	0.0644	0.1278	5
ACOMAYO	-71.684	-13.917	4.28	0.0527	1.618	0.0707	0.1198	4.09
PAUCARTAMBO	-71.591	-13.324	7.98	0.0519	1.8311	0.0748	0.1198	6.38

CCATCCA	-71.560	-13.610	7.25	0.046	2.0663	0.0667	0.1019	5.82
ENAFER	-70.018	-15.823	2.69	0.0593	0.5844	0.064	0.0854	3.96
COTAHUASI	-72.894	-15.211	2.32	0.0363	1.9781	0.068	0.0854	1.17
CHUQUIBAMBA	-72.649	-15.838	2.13	0.0347	1.807	0.0647	0.108	1.11
LA ANGOSTURA	-71.649	-15.180	3.24	0.0693	1.46	0.0696	0.0854	2.9
SIBAYO	-71.453	-15.486	2.77	0.0462	1.6175	0.0876	0.0854	2.18
LLALLY	-70.898	-14.949	2.54	0.0647	0.4977	0.0645	0.0854	4.17
PAMPAHUTA	-70.678	-15.491	2.61	0.0539	1.0064	0.0822	0.0854	2.65
CHUQUIBAMBILLA	-70.728	-14.796	2.73	0.0546	0.4272	0.0619	0.0854	5.31
IMATA	-71.088	-15.837	2.57	0.0477	0.9343	0.0592	0.0854	3.02
AYAVIRI	-70.593	-14.881	2.44	0.0583	0.4219	0.0691	0.0854	4.32
PROGRESO	-70.356	-14.695	2.57	0.0442	0.4603	0.061	0.0854	4.34
CABANILLAS	-70.346	-15.639	3.14	0.0467	0.9391	0.0687	0.0854	3.96
ARAPA	-70.119	-15.136	2.24	0.0466	0.3372	0.0547	0.0854	3.71
HUANCANE	-69.763	-15.203	2.48	0.0466	0.3372	0.0769	0.0854	4.62
HUARAYA MOHO	-69.491	-15.390	2.13	0.0457	0.3372	0.066	0.0868	4.64
CAPACHICA	-69.844	-15.616	2.96	0.0507	0.525	0.0566	0.0854	4.62
PAUCARAY	-73.644	-14.051	3.76	0.0487	1.8725	0.0665	0.0854	3.24
CABANACONDE	-71.969	-15.619	2.47	0.0466	1.487	0.0811	0.0854	1.88
SALAMANCA	-72.834	-15.500	2.31	0.0442	1.2875	0.0641	0.0854	1.33
CAICAY	-71.695	-13.598	4.55	0.0468	1.905	0.0671	0.1086	3.81
TAMBOBAMBA	-72.167	-13.934	4.49	0.0556	2.0613	0.0789	0.1086	4.09
POMACANCHI	-71.573	-14.028	4.07	0.0631	1.618	0.0792	0.0854	3.33
ISLA TAQUILE	-69.695	-15.779	2.39	0.0539	0.5844	0.0811	0.0854	3.96
MAÑAZO	-70.339	-15.813	2.90	0.0496	0.9572	0.0637	0.0854	3.54
SANTA ROSA	-70.796	-14.627	2.62	0.0601	0.4603	0.0716	0.0854	4.32
CHIGUATA	-71.400	-16.400	2.29	0.033	1.3525	0.0605	0.0854	1.54
UBINAS	-70.857	-16.383	2.92	0.0315	1.4582	0.0717	0.0882	2.72
CHUAPALCA ALTERNATIVA ALTA	-69.644	-17.305	2.54	0.0426	1.3769	0.0635	0.0854	1.95
CARUMAS	-70.694	-16.813	2.07	0.0432	1.4735	0.0709	0.0854	1.35
CANDARAVE	-70.254	-17.271	2.12	0.0273	1.9023	0.0874	0.0854	1
ILAVE	-69.644	-16.085	2.78	0.0491	0.5844	0.0897	0.0854	3.96
LARAQUERI	-70.068	-16.153	2.73	0.0518	0.9572	0.075	0.0854	3.09
COSPAN	-78.542	-7.441	2.30	0.0451	1.8294	0.0762	0.0854	1.96
ALAO	-76.730	-6.519	4.85	0.0224	1.3995	0.0711	0.0854	8.38
PONGO DE CAYNARACHI	-76.300	-6.334	4.02	0.0512	2.1783	0.0551	0.0854	8.2
RUNATULLO	-75.051	-11.593	3.68	0.0652	0.9383	0.085	0.0854	3.89
SALCABAMBA	-74.786	-12.199	2.88	0.0472	1.3006	0.0829	0.0867	2.17
CHALLABAMBA	-71.647	-13.218	9.39	0.0785	1.9451	0.077	0.6368	8.51
HUANCA	-71.879	-16.031	2.17	0.0353	1.4052	0.058	2.0673	1.31
PACAYZAPA	-76.778	-6.256	4.68	0.0306	1.3482	0.0884	0.0854	6.33
JEPELACIO	-76.934	-6.050	4.26	0.0386	1.3482	0.0761	0.0854	6.36
SAN PEDRO	-80.034	-5.085	1.90	0.0306	0.723	0.0668	0.1293	4.41
MALVAS	-77.650	-9.934	2.08	0.0429	1.5172	0.0798	0.0854	1.14

PARIACOTO	-77.890	-9.560	2.35	0.0384	1.4603	0.0576	2.0244	1.2
ARAHUAY	-76.700	-11.617	2.26	0.0325	1.8911	0.0815	0.0885	1.08
SAN MATEO DE OTAO	-76.532	-11.845	1.96	0.0395	1.3042	0.0809	0.1187	1.29
AMBAR	-77.284	-10.750	2.05	0.0375	1.3048	0.0494	2.1021	1.21
SAN PEDRO DE PILAS	-76.217	-12.450	2.13	0.0392	1.4806	0.054	0.1187	1.09
LANGA	-76.420	-12.133	2.16	0.0374	1.3718	0.0627	0.1193	1.25
HUACHOS	-75.542	-13.220	2.34	0.0358	1.8843	0.0787	0.0854	1.43
HUAC-HUAS	-74.941	-14.132	1.98	0.0574	1.0461	0.0698	0.0854	2.11
SAPILLICA	-80.000	-4.796	2.34	0.0365	0.723	0.085	0.0854	4.41
EL VIRREY	-79.967	-5.581	2.36	0.0151	0.723	0.0622	0.0854	8.84
HACIENDA BIGOTE	-79.796	-5.339	1.94	0.0322	0.5487	0.0783	0.0854	6.01
CHALACO	-79.830	-5.034	2.59	0.0322	1.38	0.0824	0.1384	5.22
CORRAL DEL MEDIO	-79.884	-5.317	1.88	0.0319	0.227	0.0667	0.091	11.5
SONDORILLO	-79.407	-5.339	2.60	0.0322	0.7213	0.0655	1.9125	5.05
SALLIQUE	-79.317	-5.767	2.09	0.0322	0.5918	0.0733	0.1448	3.57
CHONTALI	-79.067	-5.967	2.11	0.0525	1.394	0.0663	0.155	2.1
CALLANCAS	-78.491	-7.779	1.95	0.0393	0.98	0.0565	0.0854	1.74
CUEVA BLANCA	-79.405	-6.131	2.51	0.038	1.7662	0.0778	0.155	2
TOCMOCHE	-79.356	-6.407	1.82	0.034	1.7762	0.0763	0.1448	2
HACIENDA PUCARA	-79.134	-6.042	2.84	0.0302	1.6244	0.0575	0.155	2.57
UDIMA	-79.084	-6.813	1.88	0.0333	0.9347	0.0797	0.0854	3.18
LIVES	-79.034	-7.085	2.06	0.0358	1.0469	0.0791	0.0854	1.7
PUCHACA	-79.467	-6.350	2.14	0.0274	1.394	0.0572	0.2815	2.39
SAN BENITO	-78.931	-7.408	2.07	0.0346	1.4731	0.0581	0.0854	1.79
PUENTE CHILETE	-78.838	-7.224	2.13	0.03	1.0469	0.0604	0.2019	1.7
EL TAMBO	-78.755	-7.850	2.02	0.035	1.4731	0.0599	0.0854	1.65
CHUGUR	-78.746	-6.678	2.41	0.0447	1.7544	0.0765	0.0854	2.61
DOS DE MAYO (J. OLAYA)	-76.407	-7.407	3.21	0.0248	0.9863	0.0522	0.0854	7.93
SORITOR	-77.084	-6.135	5.29	0.0396	1.823	0.0844	0.0854	6.48
CHOTANO LAJAS	-78.749	-6.560	2.34	0.0322	1.8456	0.0617	0.0854	1.74
JEPELACIO	-76.915	-6.101	4.69	0.0323	1.3482	0.0645	0.0854	8.21
CAMPANILLA	-76.684	-7.434	3.13	0.0367	1.2167	0.0603	0.087	8.92
SAN PABLO	-76.576	-6.813	5.10	0.0284	1.695	0.0644	0.0937	7.73
CUÑUMBUQUE	-76.508	-6.508	4.08	0.0213	1.3995	0.0877	0.0854	5.5
NUEVO LIMA	-76.474	-7.118	3.53	0.0219	0.9863	0.0872	0.0854	7.07
SAN ANTONIO	-76.424	-6.424	5.06	0.0312	1.896	0.0614	0.1104	9.33
SHANUSI	-76.254	-6.068	2.91	0.0342	1.4767	0.0606	0.0854	6.47
PILLUANA	-76.281	-6.779	4.43	0.0283	1.3995	0.0536	0.0987	7.04
CHAZUTA	-76.098	-6.569	3.41	0.0342	1.7291	0.0559	0.1156	6.47
PELEJO	-75.790	-6.216	4.15	0.0323	1.8507	0.0607	0.0854	7.64
SHAMBOYACU	-76.167	-7.000	5.92	0.0294	2.0766	0.0844	0.1737	8.2
HUANGACOCCHA	-78.068	-7.937	2.40	0.0439	1.5082	0.0646	0.0854	2.12
LA ENCAÑADA	-78.322	-7.119	2.83	0.0338	1.5506	0.083	0.0854	2.2
BIAVO	-76.491	-7.254	3.23	0.0231	0.9863	0.0551	0.0854	7.93

CACHICADAN	-78.153	-8.102	2.18	0.038	1.2535	0.07	0.0854	2.12
MOLLEPATA	-77.956	-8.195	3.22	0.0392	1.5082	0.085	0.0854	2.12
HUACAMARCANGA	-78.288	-8.102	1.95	0.0439	1.1401	0.0511	0.0854	2.12
OCROS	-77.400	-10.400	1.85	0.0356	1.328	0.0532	0.1153	1
PAMPA LIBRE	-76.967	-10.867	2.65	0.0356	1.3925	0.0494	2.1211	1.16
PARIACANCHA	-76.500	-11.384	3.05	0.055	1.4025	0.0843	0.0854	1.75
PACCHO	-76.934	-10.950	2.33	0.0524	1.9803	0.054	0.0854	1.24
ANDAJES	-76.900	-10.784	2.43	0.0377	1.6476	0.0515	0.0854	1.42
SANTA CRUZ	-76.634	-11.200	2.27	0.0452	1.3804	0.0806	0.0854	1.26
PALLAC	-76.800	-11.350	2.51	0.038	1.5747	0.0667	0.0854	1.26
HUAMANTANGA	-76.750	-11.500	2.23	0.0381	1.4381	0.0874	0.0854	1.24
PARQUIN	-76.717	-10.967	2.53	0.0535	1.3765	0.0686	0.0854	1.68
LACHAQUI	-76.617	-11.550	2.21	0.0401	1.621	0.074	0.0857	1.25
CARAMPOMA	-76.516	-11.655	2.28	0.043	1.3782	0.0713	0.0854	1.26
SAN JOSE DE PARAC	-76.258	-11.801	2.55	0.0709	1.3042	0.0872	0.1187	1.25
RICRAN	-75.525	-11.542	3.36	0.0583	0.8515	0.0631	0.0854	3.55
YAUICOCHA	-75.723	-12.317	2.44	0.0829	1.5791	0.0704	0.1103	1.19
SANTA ANA	-75.167	-12.000	2.85	0.0558	0.8932	0.0698	0.0854	3.04
HUANCAVELICA	-74.967	-12.784	2.88	0.0527	1.4347	0.0744	0.0913	2.44
LIRCAY	-74.717	-12.984	2.30	0.0682	0.4928	0.0846	0.0854	2.21
MILLOC	-76.350	-11.572	2.53	0.06	1.4205	0.0766	0.0854	1.53
ANTIOQUIA	-76.500	-12.084	2.26	0.0326	1.3042	0.0619	2.0267	1
SAN LAZARO DE ESCOMARCA	-76.350	-12.184	1.75	0.03	1.7764	0.0857	0.0854	1.06
AYAVIRI	-76.134	-12.384	2.21	0.0632	1.3925	0.0829	0.1187	1.31
TANTA	-76.017	-12.117	2.65	0.0509	1.8534	0.0881	0.0855	1.73
CARANIA	-75.872	-12.345	2.44	0.051	1.9164	0.0887	0.1187	1.07
HUANGASCAR	-75.834	-12.899	2.42	0.0316	1.7431	0.064	0.0854	1.14
VILCA	-75.826	-12.115	2.76	0.0611	1.4894	0.0877	0.0854	1.45
SAN JUAN DE CASTROVIRREYNA	-75.644	-13.203	2.31	0.0293	1.5083	0.0803	0.0987	1.18
SAN PEDRO DE HUACARPANA	-75.650	-13.050	2.22	0.0422	2.0398	0.0645	0.0854	1.1
CUSICANCHA	-75.305	-13.491	2.15	0.039	1.4	0.0736	0.0854	1.31
TAMBO	-75.271	-13.695	2.00	0.0315	1.9964	0.0564	0.0855	1.2
SANTIAGO DE CHOCORVOS	-75.254	-13.830	2.24	0.0426	1.3561	0.0589	0.1627	1.38
HUANCALPI	-75.237	-12.542	3.04	0.0499	0.9171	0.0732	0.0854	3.04
CHOCLOCOCHA	-75.034	-13.100	3.99	0.0541	1.8381	0.0871	0.0854	3.49
VILCASHUAMAN	-73.949	-13.644	3.57	0.0448	1.5061	0.0811	0.0854	3.39
CHILCAYOC	-73.717	-13.867	3.03	0.0557	1.8946	0.0843	0.0854	1.91
COLQUEPATA	-71.673	-13.363	4.98	0.0553	1.6813	0.0577	0.1198	4.4
CORDOVA	-75.169	-14.034	1.97	0.0448	1.3597	0.0644	0.0854	1.58
LLAUTA	-74.932	-14.237	2.18	0.0427	0.8022	0.0885	0.0854	1.67
CHICHAS	-72.917	-15.545	2.13	0.0347	0.9773	0.0775	0.0959	1.27
ANDAHUA	-72.349	-15.494	2.43	0.038	1.9319	0.0518	0.0965	1.56

ORCOPAMPA	-72.339	-15.261	2.56	0.0408	1.8343	0.0573	0.0854	1.5
AYO	-72.270	-15.679	2.08	0.0353	1.4299	0.058	1.9191	1.24
CHOCO	-72.117	-15.567	2.42	0.0366	1.5601	0.0708	0.0854	1.38
HUAMBO	-72.100	-15.734	2.37	0.0438	1.4299	0.0866	0.0969	1.36
MADRIGAL	-71.812	-15.617	2.58	0.0414	1.8341	0.0736	0.0854	1.74
TISCO	-71.450	-15.350	2.85	0.0574	1.4601	0.0852	0.0854	2.38
PORPERA	-71.317	-15.350	3.03	0.0564	1.4903	0.0733	0.1043	3.09
CRUCERO ALTO	-70.917	-15.767	2.77	0.0544	0.9572	0.0732	0.0854	2.71
PUCARA	-70.334	-15.034	2.59	0.0575	0.4603	0.0517	0.0854	3.56
TARACO	-69.967	-15.300	2.88	0.0428	0.525	0.0538	0.0854	3.96
PUTINA	-69.868	-14.915	2.55	0.0543	0.3914	0.0675	0.0854	4.62
PUENTE CARRETERA AZANGARO	-70.184	-14.917	2.50	0.0571	0.3372	0.0726	0.0854	3.93
ISLA SOTO	-69.491	-15.559	2.39	0.0431	0.4363	0.0779	0.0854	5.83
PAMPA DE ARRIEROS	-71.589	-16.063	2.11	0.0367	1.4052	0.0565	0.2114	1.53
PILLONES	-71.217	-15.981	2.94	0.0389	1.8282	0.0776	0.0854	1.86
LAS SALINAS	-71.148	-16.318	2.53	0.0422	1.2639	0.0604	0.0883	1.7
CALACOA	-70.683	-16.735	1.88	0.044	1.4714	0.0803	0.0854	1.12
PAMPA UMALZO (TITIJONES)	-70.424	-16.875	2.46	0.0351	1.6495	0.0892	0.0854	1.19
ICHUÑA	-70.537	-16.141	2.44	0.0463	0.7387	0.0893	0.0854	2.71
CAIRANI	-70.339	-17.288	2.17	0.0226	1.7544	0.0696	0.0857	1
SUSAPAYA	-70.133	-17.351	2.11	0.0312	1.2675	0.072	0.1028	1.98
VILACOTA	-70.050	-17.117	2.37	0.04	1.1267	0.0759	0.0854	1.98
TALABAYA	-70.000	-17.559	2.10	0.0328	1.3249	0.0635	0.0854	1.4
CAPAZO	-69.813	-17.237	2.08	0.0315	1.5029	0.062	0.0854	1.42
PAUCARANI	-69.779	-17.525	2.40	0.0349	1.6495	0.0739	0.0854	1.35
CANAL UCHUSUMA	-69.626	-17.580	2.15	0.032	1.0927	0.0713	0.0854	1.95
LA FRONTERA	-69.468	-17.394	2.28	0.0346	1.1267	0.0636	0.0854	1.98

Anexo C

Tabla de parámetros por estación obtenidos a través de validaciones cruzadas

Nombre	LONGITUD	LATITUD	α	λ	ν	κ	ϕ	μ
CHULUCANAS	-80.169	-5.102	2.014	0.036	0.968	0.073	0.261	3.670
EL PORVENIR	-76.322	-6.593	4.623	0.035	1.598	0.065	0.105	7.786
SAN PABLO	-78.847	-7.085	2.344	0.039	1.374	0.063	0.356	2.174
NAMORA	-78.339	-7.203	2.515	0.035	1.488	0.071	0.092	1.998
SONDOR-MATARA	-78.237	-7.220	2.442	0.037	1.399	0.076	0.093	2.058
LA MUCHALA	-79.216	-6.826	2.215	0.037	1.476	0.064	0.182	2.483
CONTUMAZA	-78.830	-7.356	2.256	0.035	1.394	0.057	0.537	1.964
GRANJA PORCON	-78.627	-7.034	2.341	0.037	1.388	0.066	0.228	2.132
CHOTA	-78.617	-6.767	2.407	0.039	1.441	0.073	0.102	2.506
CELENDIN	-78.118	-6.864	2.656	0.037	1.446	0.066	0.215	2.909
CAJABAMBA	-78.051	-7.627	2.509	0.040	1.484	0.066	0.141	2.276
HUAMACHUCO	-78.051	-7.830	2.458	0.039	1.850	0.071	0.096	1.900
RIOJA	-77.167	-6.047	4.583	0.037	1.558	0.072	0.102	6.754
LLAPA	-78.830	-7.000	2.155	0.037	1.193	0.073	0.142	2.204
JESUS	-78.389	-7.237	2.421	0.036	1.571	0.080	0.113	1.914
MAGDALENA	-78.661	-7.254	2.314	0.037	1.486	0.060	0.110	2.058
MONTE GRANDE	-79.153	-7.225	2.222	0.037	1.304	0.069	0.343	2.509
SANTIAGO ANTUNEZ DE MAYOLO	-77.525	-9.517	2.542	0.042	1.408	0.069	0.387	1.968
RECUAY	-77.454	-9.729	2.500	0.042	1.632	0.065	0.284	1.768
SANTA ANA	-75.221	-12.004	4.274	0.061	1.361	0.082	0.087	3.914
RICRAN	-75.479	-11.783	2.826	0.056	1.245	0.072	0.120	3.315
PAMPAS	-74.866	-12.393	2.900	0.055	1.336	0.069	0.098	2.442
CAJATAMBO	-76.990	-10.478	2.477	0.043	1.312	0.071	0.276	1.669
OYON	-76.767	-10.667	2.470	0.043	1.374	0.073	0.292	1.567
PICOY	-76.734	-10.917	2.532	0.050	1.297	0.080	0.152	1.702
OBRAJILLO	-76.617	-11.467	2.328	0.044	1.465	0.075	0.109	1.415
MATUCANA	-76.378	-11.839	2.409	0.049	1.550	0.071	0.218	1.380
COMAS	-75.129	-11.749	3.087	0.053	1.002	0.074	0.134	3.921
CERRO DE PASCO	-76.254	-10.694	2.551	0.045	1.418	0.070	0.271	1.939
GRANJA KAYRA	-71.875	-13.557	4.232	0.057	1.336	0.066	0.130	4.318
HUAROCHIRI	-76.234	-12.134	2.341	0.048	1.596	0.062	0.281	1.639
HUAYAO	-75.339	-12.034	3.544	0.055	1.678	0.070	0.095	2.202

YAUUYOS	-75.911	-12.492	2.528	0.051	1.653	0.072	0.131	1.531
PAUCARBAMBA	-74.536	-12.556	2.702	0.052	1.191	0.075	0.124	3.636
HUANCAPI	-74.071	-13.750	3.615	0.046	1.744	0.081	0.112	2.917
URUBAMBA	-72.125	-13.304	4.692	0.052	1.833	0.076	0.161	4.318
ANTA ANCACHURO	-72.216	-13.468	4.703	0.047	1.710	0.072	0.145	4.200
PARURO	-71.845	-13.768	4.611	0.054	1.674	0.069	0.124	4.253
ACOMAYO	-71.684	-13.917	4.560	0.053	1.710	0.075	0.137	4.509
PAUCARTAMBO	-71.591	-13.324	5.331	0.063	1.534	0.062	0.273	5.003
CCATCCA	-71.560	-13.610	3.844	0.052	1.339	0.071	0.126	3.459
ENAFER	-70.018	-15.823	2.548	0.051	0.783	0.069	0.107	3.179
COTAHUASI	-72.894	-15.211	2.512	0.043	1.319	0.069	0.183	1.925
CHUQUIBAMBA	-72.649	-15.838	2.477	0.042	1.385	0.067	0.337	1.893
LA ANGOSTURA	-71.649	-15.180	2.753	0.050	1.310	0.068	0.160	2.825
SIBAYO	-71.453	-15.486	2.582	0.058	1.016	0.069	0.140	4.929
LLALLY	-70.898	-14.949	3.142	0.050	0.961	0.068	0.115	4.356
PAMPAHUTA	-70.678	-15.491	2.719	0.051	0.994	0.075	0.092	3.479
CHUQUIBAMBILLA	-70.728	-14.796	2.533	0.059	0.516	0.072	0.109	5.074
IMATA	-71.088	-15.837	2.657	0.048	1.118	0.065	0.097	3.267
AYAVIRI	-70.593	-14.881	2.743	0.052	0.500	0.074	0.105	6.713
PROGRESO	-70.356	-14.695	2.542	0.057	0.554	0.063	0.105	6.003
CABANILLAS	-70.346	-15.639	3.076	0.051	1.180	0.067	0.102	3.389
ARAPA	-70.119	-15.136	3.130	0.043	0.654	0.073	0.096	5.827
HUANCANE	-69.763	-15.203	3.355	0.045	0.877	0.071	0.092	4.369
HUARAYA MOHO	-69.491	-15.390	2.363	0.055	0.472	0.064	0.240	5.122
CAPACHICA	-69.844	-15.616	2.553	0.050	0.637	0.073	0.097	3.964
PAUCARAY	-73.644	-14.051	3.090	0.051	1.746	0.073	0.114	2.271
CABANACONDE	-71.969	-15.619	2.460	0.044	1.500	0.069	0.271	1.738
SALAMANCA	-72.834	-15.500	2.308	0.033	1.298	0.077	0.098	1.416
CAICAY	-71.695	-13.598	5.273	0.052	1.357	0.066	0.093	5.986
TAMBOBAMBA	-72.167	-13.934	3.987	0.050	1.577	0.075	0.134	3.840
POMACANCHI	-71.573	-14.028	4.349	0.052	1.671	0.073	0.133	3.925
ISLA TAQUILE	-69.695	-15.779	2.497	0.052	0.617	0.075	0.114	4.518
MAÑAZO	-70.339	-15.813	2.486	0.054	0.699	0.072	0.100	3.856
SANTA ROSA	-70.796	-14.627	2.866	0.053	0.783	0.067	0.105	4.273
CHIGUATA	-71.400	-16.400	2.535	0.043	1.247	0.065	0.380	2.341
UBINAS	-70.857	-16.383	2.507	0.044	1.243	0.069	0.124	2.264

CHUAPALCA									
ALTERNATIVA									
ALTA									
	-69.644	-17.305	2.258	0.034	1.765	0.070	0.095	1.454	
CARUMAS	-70.694	-16.813	1.983	0.046	1.409	0.056	0.087	1.361	
CANDARAVE	-70.254	-17.271	2.182	0.033	1.366	0.069	0.186	1.491	
ILAVE	-69.644	-16.085	2.491	0.051	0.837	0.065	0.112	3.544	
LARAQUERI	-70.068	-16.153	2.623	0.049	0.903	0.073	0.100	3.396	
COSPAN	-78.542	-7.441	2.396	0.035	1.469	0.066	0.113	2.091	
ALAO	-76.730	-6.519	4.320	0.031	1.478	0.072	0.107	7.394	
PONGO DE									
CAYNARACHI	-76.300	-6.334	4.533	0.031	1.628	0.077	0.100	7.191	
RUNATULLO	-75.051	-11.593	3.988	0.063	1.524	0.070	0.110	2.768	
SALCABAMBA									
	-74.786	-12.199	3.215	0.055	0.993	0.065	0.096	3.674	
CHALLABAMBA									
	-71.647	-13.218	6.751	0.053	1.632	0.063	0.088	5.533	
HUANCA	-71.879	-16.031	2.499	0.045	1.256	0.067	0.119	2.254	
PACAYZAPA	-76.778	-6.256	3.717	0.033	1.135	0.065	0.100	8.343	
JEPELACIO	-76.934	-6.050	4.005	0.034	1.129	0.063	0.092	7.812	
SAN PEDRO	-80.034	-5.085	2.228	0.036	1.012	0.069	0.179	4.114	
MALVAS	-77.650	-9.934	2.525	0.042	1.407	0.069	0.387	1.912	
PARIACOTO	-77.890	-9.560	2.582	0.042	1.562	0.065	0.131	2.010	
ARAHUAY	-76.700	-11.617	2.321	0.042	1.579	0.070	0.097	1.327	
SAN MATEO DE									
OTAO	-76.532	-11.845	2.316	0.042	1.382	0.068	0.097	1.382	
AMBAR	-77.284	-10.750	2.467	0.043	1.409	0.072	0.317	1.703	
SAN PEDRO DE									
PILAS	-76.217	-12.450	2.282	0.052	1.392	0.071	0.092	1.544	
LANGA	-76.420	-12.133	1.961	0.035	1.360	0.063	0.091	1.183	
HUACHOS	-75.542	-13.220	2.332	0.039	1.447	0.068	0.148	1.511	
HUAC-HUAS	-74.941	-14.132	2.336	0.041	1.410	0.071	0.090	1.525	
SAPILLICA	-80.000	-4.796	2.146	0.041	0.967	0.069	0.195	3.871	
EL VIRREY	-79.967	-5.581	2.196	0.034	1.058	0.068	0.201	3.680	
HACIENDA BIGOTE									
	-79.796	-5.339	2.068	0.037	0.963	0.059	0.269	4.096	
CHALACO	-79.830	-5.034	2.123	0.030	0.960	0.080	0.092	4.370	
CORRAL DEL									
MEDIO	-79.884	-5.317	2.055	0.041	0.914	0.058	0.336	4.477	
SONDORILLO	-79.407	-5.339	2.155	0.044	0.804	0.073	0.195	3.849	
SALLIQUE	-79.317	-5.767	2.455	0.035	1.269	0.056	0.129	2.784	
CHONTALI	-79.067	-5.967	2.827	0.029	1.326	0.073	0.139	2.947	
CALLANCAS	-78.491	-7.779	2.394	0.038	1.575	0.072	0.132	2.099	
CUEVA BLANCA									
	-79.405	-6.131	2.345	0.031	1.513	0.067	0.162	2.342	
TOCMOCHE	-79.356	-6.407	2.280	0.034	1.277	0.065	0.776	2.623	

HACIENDA PUCARA	-79.134	-6.042	2.171	0.043	1.418	0.061	0.152	2.043
UDIMA	-79.084	-6.813	2.262	0.036	1.355	0.073	0.473	2.507
LIVES	-79.034	-7.085	2.287	0.035	1.350	0.062	0.376	2.083
PUCHACA	-79.467	-6.350	2.327	0.033	1.758	0.070	0.157	2.490
SAN BENITO	-78.931	-7.408	2.222	0.036	1.407	0.068	0.344	1.908
PUENTE CHILETE	-78.838	-7.224	2.250	0.037	1.365	0.067	0.106	2.047
EL TAMBO	-78.755	-7.850	2.386	0.036	1.441	0.069	0.232	2.243
CHUGUR	-78.746	-6.678	2.355	0.036	1.173	0.069	0.161	2.516
DOS DE MAYO (J. OLAYA)	-76.407	-7.407	3.267	0.032	0.946	0.068	0.102	8.408
SORITOR	-77.084	-6.135	2.669	0.041	0.486	0.075	0.125	10.253
CHOTANO LAJAS	-78.749	-6.560	2.424	0.041	1.686	0.069	0.115	2.447
JEPELACIO	-76.915	-6.101	4.012	0.038	1.175	0.081	0.091	7.000
CAMPANILLA	-76.684	-7.434	4.052	0.026	1.646	0.076	0.115	6.517
SAN PABLO	-76.576	-6.813	4.213	0.027	1.588	0.069	0.100	6.708
CUÑUMBUQUE	-76.508	-6.508	4.494	0.032	1.569	0.065	0.118	8.141
NUEVO LIMA	-76.474	-7.118	4.082	0.025	1.576	0.067	0.105	6.936
SAN ANTONIO	-76.424	-6.424	4.377	0.028	1.539	0.078	0.092	7.667
SHANUSI	-76.254	-6.068	3.872	0.035	1.601	0.069	0.118	7.558
PILLUANA	-76.281	-6.779	4.325	0.029	1.616	0.074	0.120	7.578
CHAZUTA	-76.098	-6.569	4.792	0.029	1.730	0.071	0.099	8.031
PELEJO	-75.790	-6.216	4.314	0.033	1.688	0.071	0.111	7.343
SHAMBOYACU	-76.167	-7.000	4.237	0.028	1.727	0.072	0.104	6.374
HUANGACOCHA	-78.068	-7.937	2.584	0.042	1.364	0.074	0.099	2.345
LA ENCAÑADA	-78.322	-7.119	2.386	0.036	1.627	0.072	0.114	1.866
BIAVO	-76.491	-7.254	3.462	0.025	1.191	0.070	0.096	8.442
CACHICADAN	-78.153	-8.102	2.623	0.040	1.633	0.073	0.184	2.437
MOLLEPATA	-77.956	-8.195	2.381	0.042	1.259	0.075	0.131	3.464
HUACAMARCANGA	-78.288	-8.102	2.369	0.038	1.652	0.068	0.119	1.966
OCROS	-77.400	-10.400	2.510	0.043	1.467	0.070	0.241	1.672
PAMPA LIBRE	-76.967	-10.867	2.426	0.045	1.551	0.079	0.149	1.447
PARIACANCHA	-76.500	-11.384	2.416	0.043	1.624	0.075	0.137	1.462
PACCHO	-76.934	-10.950	2.397	0.038	1.182	0.074	1.053	1.404
ANDAJES	-76.900	-10.784	2.531	0.043	1.483	0.065	0.182	1.299

SANTA CRUZ	-76.634	-11.200	2.511	0.046	1.402	0.071	0.160	1.556
PALLAC	-76.800	-11.350	2.386	0.043	1.550	0.066	0.135	1.368
HUAMANTANGA								
	-76.750	-11.500	2.340	0.041	1.477	0.077	0.117	1.326
PARQUIN	-76.717	-10.967	2.544	0.043	1.316	0.085	0.099	1.408
LACHAQUI	-76.617	-11.550	2.361	0.041	1.514	0.072	0.097	1.294
CARAMPOMA								
	-76.516	-11.655	2.307	0.045	1.333	0.071	0.105	1.506
SAN JOSE DE PARAC	-76.258	-11.801	2.361	0.041	1.496	0.065	0.098	1.420
RICRAN	-75.525	-11.542	3.280	0.057	1.256	0.068	0.116	2.440
YAURICOCHA	-75.723	-12.317	2.622	0.048	1.616	0.074	0.114	1.940
SANTA ANA	-75.167	-12.000	3.239	0.056	0.543	0.083	0.091	5.893
HUANCAVELICA								
	-74.967	-12.784	2.755	0.054	1.038	0.068	0.111	3.193
LIRCAY	-74.717	-12.984	3.082	0.049	1.439	0.072	0.126	2.923
MILLOC	-76.350	-11.572	2.435	0.046	1.370	0.072	0.166	1.586
ANTIOQUIA	-76.500	-12.084	2.217	0.040	1.327	0.070	0.090	1.459
SAN LAZARO DE ESCOMARCA								
	-76.350	-12.184	2.217	0.040	1.431	0.070	0.094	1.298
AYAVIRI	-76.134	-12.384	2.321	0.042	1.654	0.066	0.146	1.306
TANTA	-76.017	-12.117	2.407	0.051	1.435	0.068	0.145	1.723
CARANIA	-75.872	-12.345	2.362	0.054	1.455	0.065	0.093	1.682
HUANGASCAR								
	-75.834	-12.899	2.451	0.044	1.556	0.077	0.098	1.632
VILCA	-75.826	-12.115	2.508	0.053	1.476	0.070	0.100	2.143
SAN JUAN DE CASTROVIRREYNA								
	-75.644	-13.203	2.366	0.041	1.621	0.066	0.096	1.632
SAN PEDRO DE HUACARPANA								
	-75.650	-13.050	2.527	0.037	1.646	0.076	0.096	1.588
CUSICANCHA	-75.305	-13.491	2.429	0.042	1.373	0.068	0.108	2.007
TAMBO	-75.271	-13.695	2.260	0.046	0.875	0.068	0.095	2.369
SANTIAGO DE CHOCORVOS								
	-75.254	-13.830	2.216	0.038	1.686	0.077	0.102	1.541
HUANCALPI	-75.237	-12.542	2.734	0.052	1.317	0.067	0.118	2.693
CHOCLOCOCHA								
	-75.034	-13.100	2.921	0.051	1.505	0.071	0.146	2.151
VILCASHUAMAN								
	-73.949	-13.644	3.059	0.049	1.735	0.076	0.102	2.373
CHILCAYOC	-73.717	-13.867	3.040	0.050	1.111	0.068	0.125	4.156

COLQUEPATA	-71.673	-13.363	4.483	0.067	0.721	0.063	0.199	10.360
CORDOVA	-75.169	-14.034	2.368	0.043	1.337	0.067	0.096	1.850
LLAUTA	-74.932	-14.237	2.185	0.046	1.418	0.080	0.100	1.921
CHICHAS	-72.917	-15.545	2.440	0.042	1.577	0.076	0.131	1.403
ANDAHUA	-72.349	-15.494	2.503	0.040	1.595	0.066	0.556	2.003
ORCOPAMPA	-72.339	-15.261	2.581	0.042	1.546	0.064	0.149	2.052
AYO	-72.270	-15.679	2.478	0.042	1.353	0.077	0.140	1.823
CHOCO	-72.117	-15.567	2.381	0.044	1.444	0.064	0.417	1.724
HUAMBO	-72.100	-15.734	2.351	0.043	1.402	0.066	0.475	1.680
MADRIGAL	-71.812	-15.617	2.740	0.048	1.457	0.070	0.155	2.273
TISCO	-71.450	-15.350	3.255	0.052	1.534	0.071	0.141	3.208
PORPERA	-71.317	-15.350	2.761	0.053	1.303	0.080	0.121	2.594
CRUCERO ALTO	-70.917	-15.767	2.593	0.049	0.917	0.065	0.124	3.222
PUCARA	-70.334	-15.034	2.657	0.049	0.627	0.073	0.099	4.067
TARACO	-69.967	-15.300	2.540	0.049	0.583	0.071	0.100	3.963
PUTINA	-69.868	-14.915	2.734	0.048	0.639	0.071	0.096	4.027
PUENTE CARRETERA AZANGARO	-70.184	-14.917	3.627	0.045	1.177	0.068	0.126	3.733
ISLA SOTO	-69.491	-15.559	2.456	0.052	0.527	0.060	0.095	5.151
PAMPA DE ARRIROS	-71.589	-16.063	2.535	0.045	1.254	0.068	0.451	2.819
PILLONES	-71.217	-15.981	2.646	0.046	1.312	0.074	0.147	2.422
LAS SALINAS	-71.148	-16.318	2.489	0.042	1.369	0.070	0.103	1.967
CALACOA	-70.683	-16.735	2.243	0.041	1.816	0.072	0.094	1.463
PAMPA UMALZO (TITIJONES)	-70.424	-16.875	2.266	0.041	1.332	0.073	0.119	1.891
ICHUÑA	-70.537	-16.141	2.709	0.047	1.089	0.068	0.115	3.385
CAIRANI	-70.339	-17.288	2.141	0.032	1.308	0.078	0.142	1.527
SUSAPAYA	-70.133	-17.351	2.260	0.033	1.659	0.071	0.099	1.414
VILACOTA	-70.050	-17.117	2.261	0.035	1.605	0.072	0.104	1.592
TALABAYA	-70.000	-17.559	2.267	0.035	1.435	0.069	0.094	1.666
CAPAZO	-69.813	-17.237	2.354	0.037	1.531	0.079	0.097	1.637
PAUCARANI	-69.779	-17.525	2.245	0.035	1.373	0.074	0.089	1.662
CANAL UCHUSUMA	-69.626	-17.580	2.330	0.037	1.421	0.072	0.093	1.648
LA FRONTERA	-69.468	-17.394	2.373	0.038	1.391	0.071	0.095	1.846

Anexo D

La **Figura 16** y **Figura 17** muestran los mapas regionales de los parámetros de MBLRP para los meses de enero y marzo.




Figura 16 Parámetros del modelo MBLRP para el mes de enero




Figura 17 Parámetros del modelo MBLRP para el mes de marzo

Anexo E

Condigo en Python para la desagregación diaria de precipitación y estadísticos muestrales

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt

from scipy.stats import skew
from matplotlib import inline
plt.style.use('ggplot')

def proportiondry(x):
    def mayorque(y):
        return y>0.1
    drydays=len(x)-np.sum(x.apply(mayorque))
    return float(drydays)/len(x)

def autocovariance(Xi, k=1):
    N = np.size(Xi)
    Xs = np.average(Xi)
    autoCov = 0
    for i in np.arange(0, N-k):
        autoCov += ((Xi[i+k])-Xs)*(Xi[i]-Xs)
    return (1.0/(N-1))*autoCov

def estadisticosprec(x):
    result=[]
    a=x.dropna()
    #si se tiene menor a 10 años no contar
    if len(a)==0:
        return [None]
    result.append(np.mean(a))
    result.append(np.var(a))
    result.append(autocovariance(a))
    result.append(proportiondry(a))
    return result

#crea una tabla de los estadisticos extraidos una vez usado la fucion
estadisticosprec
def
crearTablaEst(location,x,names=['x','y','meanlh','varlh','autocovlh','
dryperiodlh']):

    val=x.transpose()
    val.reset_index(drop=True, inplace=True)
    pos=location#posiciones.loc[final_station,:]
    pos.reset_index(drop=True, inplace=True)
    df=pd.concat([pos, pd.DataFrame(np.matrix(val))], axis=1)

    df.columns=names

    return df
```

```

def factores(a,b):
    if a==0.0 or b==0.0:
        return a
    else:
        return float(a)/b

def csv_trmm(file,month,month_hourly_date):
    month_sat_hourly=pd.read_csv(file)
    rng = month_hourly_date #bug generator
    month_hourly_date=rng[np.in1d(rng.month, month)]
    location=month_sat_hourly.iloc[:,0:2]
    location.columns=['x','y']
    month_sat_hourly=month_sat_hourly.iloc[:,
2:month_sat_hourly.shape[1]].transpose() # possible bug
    month_sat_hourly=month_sat_hourly.set_index(month_hourly_date)
    return (month_sat_hourly,location,month_hourly_date)

def common_period(dates,month,obs,daily_sat):
    daily_dates=dates[np.in1d(dates.month, month)]
    month_sat_daily=daily_sat.loc[daily_dates]
    month_obs_daily=obs.loc[daily_dates]

    return (month_sat_daily,month_obs_daily,daily_dates)

def
filter_months_complete(percentaje,month_obs_daily,month_sat_daily,gaug
e_loc,month_sat_hourly):
    idx=[]
    n=percentaje*month_obs_daily.shape[0]

    for x in month_obs_daily.columns:
        if month_obs_daily[x].count()> n:
            idx.append(x)

    gauge_loc=gauge_loc.iloc[idx,:]
    month_sat_daily=month_sat_daily.iloc[:,idx]
    month_obs_daily=month_obs_daily.iloc[:,idx]
    month_sat_hourly=month_sat_hourly.iloc[:,idx]

    return
(gauge_loc,month_sat_daily,month_obs_daily,month_sat_hourly)

def
bias_correction(month_sat_daily,month_obs_daily,month_dates,month_sat_
hourly,daily_dates):
    BIASM=[]
    for i in range(0,month_sat_daily.shape[0]):#filas
        BIAS=[]
        for j in range(0,month_sat_daily.shape[1]):#columnas

BIAS.append(factores(month_obs_daily.iloc[i,j],month_sat_daily.iloc[i,
j]))
        BIASM.append(BIAS)

    correcionM=[]
    bugM=[]
    k=0 #lleva la contabilidad de las fechas diarias

```

```

for i in range(0,month_sat_hourly.shape[0]):
    correcion=[]
    bug=[]
    for j in range(0,month_sat_hourly.shape[1]):
        if month_dates[i].date()==daily_dates[k].date():

            bug.append(BIASM[k][j])

correcion.append(month_sat_hourly.iloc[i,j]*BIASM[k][j])
    k=k
    else:
        k=k+1

correcion.append(month_sat_hourly.iloc[i,j]*BIASM[k][j])

    bugM.append(bug)
    correcionM.append(correcion)

    month_sat_hourly_corrected=pd.DataFrame(correcionM)

month_sat_hourly_corrected=month_sat_hourly_corrected.set_index(month_
dates)

    return month_sat_hourly_corrected

def
stats_month(month_sat_hourly_corrected,month_obs_daily,location,month)
:

DATA3=month_sat_hourly_corrected.groupby(pd.Grouper(freq='3h')).agg(np
.sum)
    EST3=DATA3.loc[np.in1d(DATA3.index.month,
month)].dropna().apply(estadisticosprec, axis=0)

DATA6=month_sat_hourly_corrected.groupby(pd.Grouper(freq='6h')).agg(np
.sum)
    EST6=DATA6.loc[np.in1d(DATA6.index.month,
month)].dropna().apply(estadisticosprec, axis=0)

DATA12=month_sat_hourly_corrected.groupby(pd.Grouper(freq='12h')).agg(
np.sum)
    EST12=DATA12.loc[np.in1d(DATA12.index.month,
month)].dropna().apply(estadisticosprec, axis=0)

DATA18=month_sat_hourly_corrected.groupby(pd.Grouper(freq='18h')).agg(
np.sum)
    EST18=DATA18.loc[np.in1d(DATA18.index.month,
month)].dropna().apply(estadisticosprec, axis=0)
    EST24=month_obs_daily.apply(estadisticosprec, axis=0)

    names=['stattion','x','y']
    agregados=[24,3,6,12,18]
    ESTS=[EST24,EST3,EST6,EST12,EST18]
    result=[]
    for i,stat in enumerate(ESTS):
        names=['x','y']

```

```
names=names+['mean{}'.format(agregados[i]),'var{}'.format(agregados[i])
,'autocov{}'.format(agregados[i]),'dryperiod{}'.format(agregados[i])]
result.append(crearTablaEst(location,stat, names))
```

```
df=pd.concat(result,axis=1)
df=df.loc[:,~df.columns.duplicated()]
return df
```

```
rng = pd.date_range('1981-01-01','2016-12-31', freq='d')
obs=pd.read_csv('D:/Proyectos_GitHub/TrmmCorrection/data/RAIN_GAUGE.csv')
obs_daily=obs.iloc[:,3:13152].transpose()
obs_daily=obs_daily.set_index(rng)
```

#Estadisticos de Enero

```
rng=pd.date_range('1998-01-01 00:00:00','2014-12-31 21:00:00',
freq='3H')
jan_sat_hourly,posiciones,jan_hourly_date=csv_trmm(file='D:/Proyectos_GitHub/TrmmCorrection/data/TRMM_NATIONAL_ENE.csv',month=1,month_hourly_date=rng)
jan_sat_daily=jan_sat_hourly.groupby(pd.Grouper(freq='24h')).agg(np.sum)
```

```
#todos los datos diarios dentro del rango de tiempo del TRMM
rng=pd.date_range('1998-01-01','2014-12-31', freq='d')
jan_sat_daily,jan_obs_daily,daily_dates=common_period(rng,1,obs_daily,jan_sat_daily)
posiciones,jan_sat_daily,jan_obs_daily,jan_sat_hourly=filter_months_complete(0.8,jan_obs_daily,jan_sat_daily,posiciones,jan_sat_hourly)
```

```
jan_sat_hourly_corrected=bias_correction(jan_sat_daily,jan_obs_daily,jan_hourly_date,jan_sat_hourly,daily_dates)
```

```
jan_stats=stats_month(jan_sat_hourly_corrected,jan_obs_daily,posiciones,month=1)
jan_stats[jan_stats.iloc[:,2:]<0]=np.NaN
jan_stats=jan_stats.dropna()
```

#Estadisticos de Febrero

```
rng=pd.date_range('1999-02-01 00:00:00','2015-02-28 21:00:00',
freq='3H')
feb_sat_hourly,posiciones,feb_hourly_date=csv_trmm(file='D:/Proyectos_GitHub/TrmmCorrection/data/TRMM_NATIONAL_FEB.csv',month=2,month_hourly_date=rng)
feb_sat_daily=feb_sat_hourly.groupby(pd.Grouper(freq='24h')).agg(np.sum)
```

```
#todos los datos diarios dentro del rango de tiempo del TRMM
rng=pd.date_range('1999-02-01','2015-02-28', freq='d')
feb_sat_daily,feb_obs_daily,daily_dates=common_period(rng,2,obs_daily,feb_sat_daily)
posiciones,feb_sat_daily,feb_obs_daily,feb_sat_hourly=filter_months_complete(0.8,feb_obs_daily,feb_sat_daily,posiciones,feb_sat_hourly)
feb_sat_hourly_corrected=bias_correction(feb_sat_daily,feb_obs_daily,feb_hourly_date,feb_sat_hourly,daily_dates)
feb_stats=stats_month(feb_sat_hourly_corrected,feb_obs_daily,posiciones,month=2)
```


#Estadísticos de Marzo

```
rng=pd.date_range('1998-01-01 00:00:00','2014-12-31 21:00:00',
freq='3H')
mar_sat_hourly, posiciones, mar_hourly_date=csv_trmm(file='D:/Proyectos_
GitHub/TrmmCorrection/data/TRMM_NATIONAL_MAR.csv',month=3,month_hourly
_date=rng)
mar_sat_daily=mar_sat_hourly.groupby(pd.Grouper(freq='24h')).agg(np.su
m)
rng=pd.date_range('1998-01-01','2014-12-31', freq='d')
mar_sat_daily, mar_obs_daily, daily_dates=common_period(rng,3,obs_daily,
mar_sat_daily)
posiciones, mar_sat_daily, mar_obs_daily, mar_sat_hourly=filter_months_co
mplete(0.8,mar_obs_daily,mar_sat_daily,posiciones,mar_sat_hourly)
mar_sat_hourly_corrected=bias_correction(mar_sat_daily,mar_obs_daily,m
ar_hourly_date,mar_sat_hourly,daily_dates)

mar_stats=stats_month(mar_sat_hourly_corrected,mar_obs_daily,posicione
s,month=3)
mar_stats[mar_stats.iloc[:,2:]<0]=np.NaN
mar_stats=mar_stats.dropna()
```


Anexo F

Código programado en R para la estimación de parámetros del modelo MBLRP de manera regional.

```
library(extRemes)
library(raster)
library("HyetosMinute")
library(geosphere)
library(foreach)
library(doParallel)

#####
###Model Statistics#####
#####
#Mean
meanMBLRPM<-function(a,l,v,k,f,mx,h=1) {
  x<-(h*l*mx*v*(1+k/f))/(a-1)
  return(x)
}
#Variance
varMBLRPM<-function(a,l,v,k,f,mx,h=1) {
  A<-(2*l*(1+k/f)*(mx^2)*(v^a))/((f^2)*((f^2)-1)*(a-1)*(a-2)*(a-3))
  B<-(2*(f^2)-2+k*f)*(f^2)*((a-3)*h*(v^(2-a))-(v^(3-a))+((v+h)^(3-a)))
  C<-k*(f*(a-3)*h*(v^(2-a))-(v^(3-a))+((v+f*h)^(3-a)))
  D<-A*(B-C)
  return(D)
}
#Covariance
covarMBLRPM<-function(a,l,v,k,f,mx,h=1,lag=1) {
  A<-(l*(1+k/f)*(mx^2)*(v^a))/((f^2)*((f^2)-1)*(a-1)*(a-2)*(a-3))
  B<-(2*(f^2)-2+k*f)*(f^2)*(((v+(lag+1)*h)^(3-a))-2*((v+lag*h)^(3-a)))+((v+(lag-1)*h)^(3-a)))
  C<-k*(((v+(lag+1)*h*f)^(3-a))-2*((v+h*lag*f)^(3-a)))+((v+(lag-1)*h*f)^(3-a)))
  D<-A*(B-C)
  return(D)
}
#Dry probabilities
#pdrRPBLRP<-function(a,l,v,k,f,h=1) {
#  mt<-((1+(f*(k+f)))-
#(0.25*f*(k+f)*(k+4*f))+((f/72)*(k+f)*(4*(k^2)+27*k*f+72*(f^2))))*v)/(f
*(a-1))
#  G00<-((1-k-f+1.5*k*f+(f^2)+0.5*(k^2))*v)/(f*(a-1))
#  A<-(f+(k*(v/(v+(k+f)*h))^(a-1)))/(f+k)
#  D<-exp(l*(-h-mt+G00*A))
#  return(D)
#}

#####
#####Optimization Function#####
#####

MBLRPM=function(mean24,var24,cov24lag1,pdr24,var3,cov3lag1,var6,var12,
var18,Lmin,Lmax) {
  #####
  ###Model Statistics#####
  #####
  #Mean
```

```

meanMBLRPM<-function(a, l, v, k, f, mx, h=1) {
  x<-(h*l*mx*v*(1+k/f))/(a-1)
  return(x)
}
#Variance
varMBLRPM<-function(a, l, v, k, f, mx, h=1) {
  A<-(2*l*(1+k/f)*(mx^2)*(v^a))/((f^2)*((f^2)-1)*(a-1)*(a-2)*(a-3))
  B<-(2*(f^2)-2+k*f)*(f^2)*((a-3)*h*(v^(2-a))-(v^(3-a))+((v+h)^(3-
a)))
  C<-k*(f*(a-3)*h*(v^(2-a))-(v^(3-a))+((v+f*h)^(3-a)))
  D<-A*(B-C)
  return(D)
}
#Covariance
covarMBLRPM<-function(a, l, v, k, f, mx, h=1, lag=1) {
  A<-(1*(1+k/f)*(mx^2)*(v^a))/((f^2)*((f^2)-1)*(a-1)*(a-2)*(a-3))
  B<-(2*(f^2)-2+k*f)*(f^2)*(((v+(lag+1)*h)^(3-a))-2*((v+lag*h)^(3-
a))+((v+(lag-1)*h)^(3-a)))
  C<-k*(((v+(lag+1)*h*f)^(3-a))-2*((v+h*lag*f)^(3-a))+((v+(lag-
1)*h*f)^(3-a)))
  D<-A*(B-C)
  return(D)
}
#Dry probabilities
#pdrRPBLRPM<-function(a, l, v, k, f, h=1) {
# mt<-((1+(f*(k+f)))-
(0.25*f*(k+f)*(k+4*f))+((f/72)*(k+f)*(4*(k^2)+27*k*f+72*(f^2))))*v)/(f
*(a-1))
# G00<-((1-k-f+1.5*k*f+(f^2)+0.5*(k^2))*v)/(f*(a-1))
# A<-(f+(k*(v/(v+(k+f)*h))^(a-1)))/(f+k)
# D<-exp(l*(-h-mt+G00*A))
# return(D)
#}
symvar<- function(a, l, v, k, f, mx, h, var) {
  (1-varMBLRPM(a, l, v, k, f, mx, h)/var)^(2)+(1-
var/varMBLRPM(a, l, v, k, f, mx, h))^2)
}
symcovar <- function(a, l, v, k, f, mx, h, cov) {
  (1-covarMBLRPM(a, l, v, k, f, mx, h)/cov)^(2)+(1-
cov/covarMBLRPM(a, l, v, k, f, mx, h))^2)
}
symmean <- function(a, l, v, k, f, mx, h, meann) {
  (1-meanMBLRPM(a, l, v, k, f, mx, h)/meann)^(2)+(1-
meann/meanMBLRPM(a, l, v, k, f, mx, h))^2)
}
sympdr <- function(a, l, v, k, f, h, pdr) {
  (1-pdrRPBLRPM(a, l, v, k, f, h)/pdr)^(2)+(1-
pdr/pdrRPBLRPM(a, l, v, k, f, h))^2)
}
#Objective function
fopt <- function(x) {
  a<-x[1];l<-x[2];v<-x[3];k<-x[4];f<-x[5];mx<-x[6]

  w1=1;w2=1;w3=1;w4=1;w5=1;w6=1;

  S3<-
w2*symvar(a, l, v, k, f, mx, h=3, var3)+w3*symcovar(a, l, v, k, f, mx, h=3, cov3lag1
)

  S6<-w2*symvar(a, l, v, k, f, mx, h=6, var6)

```

```

S12<-w2*symvar(a,l,v,k,f,mx,h=12,var12)

S18<-w2*symvar(a,l,v,k,f,mx,h=18,var18)

w1=5;w2=5;w3=5;w4=5

S24 <- w1*symmean(a,l,v,k,f,mx,h=24,mean24)+
w2*symvar(a,l,v,k,f,mx,h=24,var24)+
w3*symcovar(a,l,v,k,f,mx,h=24,cov24lag1)+w4*sympdr(a,l,v,k,f,h=24,pdr2
4)

S<-S24+S3+S6+S12+S18

if(is.infinite(S)) {S<-10^8}
if(is.na(S)) {S<-10^8}
return(S)
}

# set the interior and exterior parameters bounds
xmin <- Lmin
xmax <- Lmax
xlow <- Lmin
xup <- c(50,20,runif(1,min = 1.8, max = 2.2),runif(1,min = 0.05, max
= 0.09),runif(1,min = 1.8, max = 2.2),runif(1,min = 8, max = 12))

modecal <-
eas(n=6,m=30,xmin,xmax,xlow,xup,fn=fopt,maxeval=5000,ftol=1.e-
10,ratio=0.99,pmut=0.95, beta=2,maxclimbs=5)
modecal
a<-modecal$bestpar[[1]];
l<-modecal$bestpar[[2]];
v<-modecal$bestpar[[3]];
k<-modecal$bestpar[[4]];
f<-modecal$bestpar[[5]];
mx<-modecal$bestpar[[6]]
# In order to use the derived parameters in the functions of HyetosR
# as well as in the classic version of Hyetos,please be sure that
# for parameters mx and sx the length units are millimeters (mm)
# and for parameters l, v, mx and sx the time units are days (d).
# For this reason, make the following unit conversions:

#checar
#l<-l*24
#v<-v/24
#mx<-mx*24

# parameter set for implementation in HyetosR functions
par <- c(a=a,l=l,v=v,k=k,f=f,mx=mx)

par
}

nearpoints=function(mdist,radio=60000){
#Return the index of the closest gauge station to each station
#mdist = matrix of distance in meters
#radio is the maximum distance allowed among station
distance=list()

```

```

for (i in 1:dim(mdist)[1]){
  values=sort(mdist[i,])
  values=tail(values, -1)

  condition=values[values<radio]
  near=numeric(length(condition))

  for (j in 1:length(condition)){
    near[j]=which(mdist[i,]==condition[j])[1]
  }

  if (length(near)>1){
    distance[[i]]=near
  }else{
    if (is.na(near)){
      distance[[i]]=0
    }else{
      distance[[i]]=near
    }
  }
}
distance
}

#####
####Functions for filtering data #
####before regionalization#####
#####

kickOutliers=function(data) {
  #delete neighbors based on variance outliers
  data_help=data
  coordinates(data_help) <- ~x+y
  proj4string(data_help)='+proj=longlat +datum=WGS84 +no_defs
+ellps=WGS84 +towgs84=0,0,0'
  mdist <- distm(data_help,fun = distHaversine)
  neighbors=nearpoints(mdist)
  outlier=c()
  for (station in 1:dim(data)[1]){
    sub=data[c(station,neighbors[[station]],)]
    outvals=which(sub$var24 %in% boxplot(sub$var24)$out)
    outlier=c(outlier,outvals)
  }

  idx=unique(outlier)
  data[-idx,]
}

filter_Neighbors=function(data,min_n=3,radio=60000) {
  #Return the statins with at least n neighbors
  #data= location of the stations
  #min_n= number of minumun neighbors required
  n_old=dim(data)[1]
  n_new=n_old*2

  while (n_old-n_new!=0){
    n_old=dim(data)[1]
    data_help=data
    coordinates(data_help) <- ~x+y

```

```

    proj4string(data_help)='+proj=longlat +datum=WGS84 +no_defs
+ellps=WGS84 +towgs84=0,0,0'
    mdist <- distm(data_help,fun = distHaversine)
    neighbors=nearpoints(mdist,radio=radio)
    data=data[lengths(neighbors)>=min_n,]
    n_new=dim(data)[1]
  }
  data
}

#####
#Cross Validations using Inverse Distance Weigth
#####
idwCV=function(data,parameter='a',power=2){
  x=data
  coordinates(x) <- ~x+y
  proj4string(x)='+proj=longlat +datum=WGS84 +no_defs +ellps=WGS84
+towgs84=0,0,0'
  mdist <- distm(x) #the answer is in meters

  crossValidated=numeric()
  for (i in 1:dim(data)[1]){
    info=data[[parameter]][-i]
    denominador=sum((1/mdist[i,-i])^power)
    crossValidated[i]=sum(info/mdist[i,-i]^power/denominador)
  }

rr=cbind(data[c('x','y')], 'var1.pred'=crossValidated, 'observed'=data[[
parameter]])
  rr$residual=rr$observed-rr[['var1.pred']]
  rr
}

#####
#####Repetitive Cross Validation##
#####

repetitiveCV=function(times=1,data,Stats,Lmin,Lmax,fun=MBLRPM){
  #data contains the intial parameter estimation
  #stats is the rainfall statistics

  #Estaciones cambiantes de intervalos

  parameters=data[,3:8]
  data_help=data
  coordinates(data_help) <- ~x+y
  proj4string(data_help)='+proj=longlat +datum=WGS84 +no_defs
+ellps=WGS84 +towgs84=0,0,0'

  mdist <- distm(data_help,fun = distHaversine)
  vecinos=nearpoints(mdist)

  range=clusterIDX(data)
  old_error=rep(100,length(range))
  current_error=numeric(length(range))
  for (iter in 1:times){
    print(paste("Number of cross validation
iteration",as.character(iter)))

```

```

k_cluster=1
for (station in range){
  print(paste('cluster
:',as.character(k_cluster),'/',as.character(length(range))))
  mistakes=c()
  for (k in 1:6){#parameters, 6 in total
    x <- idwCV(data[c(station,vecinos[[station]]),],parameter=
c('a','l','v','k','f','mx')[k],power=2)
    #Checking region error
    sub=x[c('x','y','varl.pred','observed','residual')]
    sub$porcentaje=abs(sub$residual)*100/sub$observed
    sub$residual=NULL
    sub$location=c(station,vecinos[[station]])

    #median(sub$porcentaje)
    good_neighbors=subset(sub,sub$porcentaje<30)
    wrong_neighbors=subset(sub,sub$porcentaje>=30)

    if (dim(wrong_neighbors)[1]!=0 & dim(good_neighbors)[1]!=0 ){
      for (fix_id in wrong_neighbors$location){
        Lmin[k,fix_id]=min(good_neighbors$varl.pred)
        Lmax[k,fix_id]=max(good_neighbors$varl.pred)

        mistakes=c(mistakes,fix_id) #add the wrong stations
      }
    }
  }
  n_parameters=length(mistakes)
  mistakes=unique(mistakes)

  if (length(mistakes)==0){
    current_error[k_cluster]=0
    print('No parameters to correct')
  }else{

current_error[k_cluster]=round(n_parameters*100/(6*length(sub$location
)),2)

    if(old_error[k_cluster]<current_error[k_cluster]){
      print('Using old parameter with lower error')
      print(paste("Incorrect parameters in the
cluster:",as.character(n_parameters),'/',as.character(6*length(sub$loc
ation)), ' (' ,as.character(old_error[k_cluster]),'%)''))
      parameters[mistakes,]=old_parameters[mistakes,]
      old_error[k_cluster]=old_error[k_cluster]
    }else{

      print(paste("Incorrect parameters in the
cluster:",as.character(n_parameters),'/',as.character(6*length(sub$loc
ation)), ' (' ,as.character(current_error[k_cluster]),'%)''))
      n.cores <- parallel::detectCores() - 1
      #create the cluster
      my.cluster <- parallel::makeCluster(
        n.cores,
        type = "PSOCK"
      )
      #register it to be used by %dopar%
      doParallel::registerDoParallel(cl = my.cluster)

      parameters[mistakes,]=t(matrix(foreach(
        i=mistakes,
        .combine = 'c',

```

```

    .packages = "HyetosMinute"
  ) %dopar% {
    momentos=Stats[i,]

    mean24 = momentos$mean24
    var24 = momentos$var24
    cov24lag1 =momentos$autocov24
    pdr24=momentos$dryperiod24
    var3=momentos$var3
    cov3lag1=momentos$autocov3
    var6=momentos$var6
    var12=momentos$var12
    var18=momentos$var18

par=fun(mean24,var24,cov24lag1,pdr24,var3,cov3lag1,var6,var12,var18,Lm
in[,i],Lmax[,i])

    return(par)
  },nrow = 6,ncol = length(mistakes))
parallel::stopCluster(cl = my.cluster) #closing the cluster

    old_error[k_cluster]=current_error[k_cluster]
  }
}

    k_cluster=k_cluster+1 #counting clusters
  }
#parameters=cbind(Stats[,1:2],parameters)

names(parameters)=c('a','l','v','k','f','mx')#c('x','y','a','l','v','k
','f','mx')
    old_parameters=data[,3:8]

    data[,3:8]=parameters#check

    #write.table(data,paste0("D:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/CV_parameters/iteraciones/",'parameters_i
ter_',as.character(iter),'.csv'),sep = ', ',row.names = F)
  }

  data
}

#####
##### Run Function#####
#####
run=function(rain_stats,path,iterations=5,fun=MBLRPM,FILE_NAME) {
  #rain_stats: contains the rainfall statistics
  #path: where to save the results
  #Maskshape: Shape form of the final results

  n=dim(rain_stats)[1]

  #Maximum and minimum search parameters space
  Lmin=matrix(c(0.1,0.001,0.001,0.001,0.0854,1),nrow = 6,ncol = n)
  Lmax=matrix(c(4,0.1,0.1,0.1,0.1,20),nrow=6,ncol=n)

```

```

#print('Calculating the initial parameters ...')
#Initial parameters
parameters0=matrix(data=NA,nrow =n,ncol = 6)

n.cores <- parallel::detectCores() - 1
#create the cluster
my.cluster <- parallel::makeCluster(
  n.cores,
  type = "PSOCK"
)
#register it to be used by %dopar%
doParallel::registerDoParallel(cl = my.cluster)

parameters0=t(matrix(foreach(
  i=1:n,
  .combine = 'c',
  .packages = "HyetosMinute"
) %dopar% {

  momentos=rain_stats[i,]

  mean24 = momentos$mean24
  var24 = momentos$var24
  cov24lag1 =momentos$autocov24
  pdr24=momentos$dryperiod24
  var3=momentos$var3
  cov3lag1=momentos$autocov3
  var6=momentos$var6
  var12=momentos$var12
  var18=momentos$var18

par=fun(mean24,var24,cov24lag1,pdr24,var3,cov3lag1,var6,var12,var18,Lm
in[,i],Lmax[,i])

  return(par)

},nrow = 6,ncol = n))

parallel::stopCluster(cl = my.cluster) #closing the cluster

parameters=cbind(rain_stats[,1:2],parameters0)
names(parameters)=c('x','y','a','l','v','k','f','mx')

print('Reptitive Cross Validations ...')
CV_parameters=repetitiveCV(times =
iterations,parameters,rain_stats,Lmin = Lmin ,Lmax = Lmax)
#saving the initial parameters
write.table(CV_parameters,paste0(path,FILE_NAME),sep = ', ',row.names
= F)
CV_parameters
}

#####
SimStats= function(parameters){

  stats=matrix(data=NA,nrow = dim(parameters)[1],ncol = 16)
  for (i in 1:dim(parameters)[1]){

```



```

par=parameters[i,]
par[2]<-par[2]*24
par[3]<-par[3]/24
par[6]=par[6]*24

est=numeric(16)
iter=0
for (j in c(24,3,6,12)){
  m=meanMBLRPM(par[1],par[2],par[3],par[4],par[5],par[6],h=j/24)
  v=varMBLRPM(par[1],par[2],par[3],par[4],par[5],par[6],h=j/24)

cov=covarMBLRPM(par[1],par[2],par[3],par[4],par[5],par[6],h=j/24)
pdr=pdrRPBLRPM(par[1],par[2],par[3],par[4],par[5],h=j/24)
est[(1+iter*4):(4+iter*4)]=c(m,v,cov,pdr)
  iter=iter+1
}

stats[i,]=as.numeric(est)
}
stats
}

clusterIDX=function(data){
  #return cluster index
  #data contains the intial parameter estimation
  #stats is the rainfall statistics
  drop_range=function(x,vector){
    for (element in vector){
      x=x[x!=element]
    }
    x
  }
  #Estaciones cambiantes de intervalos
  range=1:dim(data)[1]

  data_help=data
  coordinates(data_help) <- ~x+y
  proj4string(data_help)='+proj=longlat +datum=WGS84 +no_defs
+ellps=WGS84 +towgs84=0,0,0'

  mdist <- distm(data_help,fun = distHaversine)
  vecinos=nearpoints(mdist)

  idx=c()
  while (length(range)!=0){
    station=range[1]
    range=drop_range(range,c(station,vecinos[[station]]))
    idx=c(idx,station)
  }#ends parameter iteration
  idx
}

precp_sim=function(par,n,tyscale=24){
  #par are the MBLR parameters
  #n is the number of days

  a=par[1]
  l=par[2]*24
  v=par[3]/24

```

```

k=par[4]
f=par[5]
mx=par[6]*24

tt=SequentialSimul(Length=n,BLpar=list(lambda=l,phi=f,kappa=k
, alpha=a,v=v,mx=mx,sxmx=1),CellIntensityProp=list(Weibull=FALSE,
iota=NA),TimeScale=tscale,ExportSynthData=list(exp=TRUE,FileContent=c(
"AllDays"),DaysPerSeason=31,
file="SynthRPBLM.txt"),ImportHistData=list(imp=F,file="HistHourlyData.
txt",
ImpDataTimeScale=1,na.values="NA",FileContent=c("AllDays"),DaysPerSeas
on=31,DailyValues=TRUE),
PlotTs=FALSE,Statistics=list(print=TRUE,plot=FALSE),RandSeed=NULL
)[[1]]
  as.numeric(tt)
}

points_wgs84=function(data){
  coordinates(data) <- ~x+y
  proj4string(data)='+proj=longlat +datum=WGS84 +no_defs +ellps=WGS84
+towgs84=0,0,0'
  data
}

nonzero=function(obs){
  "cumulative distribution of none zero values"
  idx=obs>0
  #ecdf(obs[idx])
  obs[idx]
}

coords_correction=function(mapa){
  #rotation of trmm to correct positioning
  flip(flip(t(mapa), 1),2)
}

```

Anexo G

Código desarrollado en lenguaje de programación R para la interpolación de parámetros del modelo MBLRP

```
library(raster)
library(gstat)
library(ggplot2)
library(gridExtra)
library(tmap)
library(RColorBrewer)

autofitVariogramPISCop <- function (formula, input_data, model =
c("Sph", "Exp", "Gau",
"Ste"), kappa = c(0.05, seq(0.2, 2, 0.1), 5, 10), fix.values = c(NA,
NA, NA), verbose = FALSE, GLS.model = NA, start_vals = c(NA,
NA, NA), miscFitOptions = list(), boundaries, ...)
{
  if ("alpha" %in% names(list(...)))
    warning("Anisotropic variogram model fitting not supported, see
the documentation of autofitVariogram for more details.")
  miscFitOptionsDefaults = list(merge.small.bins = TRUE, min.np.bin =
5)
  miscFitOptions = modifyList(miscFitOptionsDefaults, miscFitOptions)
  longlat = !is.projected(input_data)
  if (is.na(longlat))
    longlat = FALSE
  diagonal = spDists(t(bbox(input_data)), longlat = longlat)[1,
2]

  if (!missing(boundaries))
    boundaries = boundaries
  else {
    boundaries = c(2, 4, 6, 9, 12, 15, 25, 35, 50, 65, 80,
100) * diagonal * 0.35/100
  }
  if (!is(GLS.model, "variogramModel")) {
    experimental_variogram = variogram(formula, input_data,
boundaries = boundaries, ...)
  }
  else {
    if (verbose)
      cat("Calculating GLS sample variogram\n")
    g = gstat(NULL, "bla", formula, input_data, model = GLS.model,
set = list(gls = 1))
    experimental_variogram = variogram(g, boundaries = boundaries,
...)
  }
  if (miscFitOptions[["merge.small.bins"]]) {
    if (verbose)
      cat("Checking if any bins have less than 5 points, merging bins
when necessary...\n\n")
    while (TRUE) {
      if (length(experimental_variogram$np[experimental_variogram$np <
miscFitOptions[["min.np.bin"]]]) == 0 | length(boundaries) ==
1)

```

```

    break
    boundaries = boundaries[2:length(boundaries)]
    if (!is(GLS.model, "variogramModel")) {
      experimental_variogram = variogram(formula,
                                         input_data, boundaries =
boundaries, ...)
    }
    else {
      experimental_variogram = variogram(g, boundaries = boundaries,
                                         ...)
    }
  }
}
if (is.na(start_vals[1])) {
  initial_nugget = min(experimental_variogram$gamma)
}
else {
  initial_nugget = start_vals[1]
}
if (is.na(start_vals[2])) {
  initial_range = 0.1 * diagonal
}
else {
  initial_range = start_vals[2]
}
if (is.na(start_vals[3])) {
  initial_sill = mean(c(max(experimental_variogram$gamma),
                          median(experimental_variogram$gamma)))
}
else {
  initial_sill = start_vals[3]
}
if (!is.na(fix.values[1])) {
  fit_nugget = FALSE
  initial_nugget = fix.values[1]
}
else fit_nugget = TRUE
if (!is.na(fix.values[2])) {
  fit_range = FALSE
  initial_range = fix.values[2]
}
else fit_range = TRUE
if (!is.na(fix.values[3])) {
  fit_sill = FALSE
  initial_sill = fix.values[3]
}
else fit_sill = TRUE
getModel = function(psill, model, range, kappa, nugget,
                    fit_range, fit_sill, fit_nugget, verbose) {
  if (verbose)
    debug.level = 1
  else debug.level = 0
  if (model == "Pow") {
    warning("Using the power model is at your own risk, read the
docs of autofitVariogram for more details.")
    if (is.na(start_vals[1]))
      nugget = 0
    if (is.na(start_vals[2]))
      range = 1
    if (is.na(start_vals[3]))
      sill = 1
  }
}

```

```

    }
    obj = try(fit.variogram(experimental_variogram, model = vgm(psill
= psill,
                                                    model
= model, range = range, nugget = nugget, kappa = kappa),
            fit.ranges = c(fit_range), fit.sills =
c(fit_nugget,
fit_sill), debug.level = 0), TRUE)
    if ("try-error" %in% class(obj)) {
        warning("An error has occurred during variogram fitting.
Used:\n",
                "\tnugget:\t", nugget, "\n\tmodel:\t", model,
                "\n\tpsill:\t", psill, "\n\trange:\t", range,
                "\n\tkappa:\t", ifelse(kappa == 0, NA, kappa),
                "\n as initial guess. This particular variogram fit is
not taken into account. \nGstat error:\n",
                obj)
        return(NULL)
    }
    else return(obj)
}
test_models = model
SSerr_list = c()
vgm_list = list()
counter = 1
for (m in test_models) {
    if (m != "Mat" && m != "Ste") {
        model_fit = getModel(initial_sill - initial_nugget,
m, initial_range, kappa = 0,
initial_nugget,
                                fit_range, fit_sill, fit_nugget, verbose =
verbose)
        if (!is.null(model_fit)) {
            vgm_list[[counter]] = model_fit
            SSerr_list = c(SSerr_list, attr(model_fit, "SSerr"))
        }
        counter = counter + 1
    }
    else {
        for (k in kappa) {
            model_fit = getModel(initial_sill - initial_nugget,
m, initial_range, k, initial_nugget,
fit_range,
                                fit_sill, fit_nugget, verbose = verbose)
            if (!is.null(model_fit)) {
                vgm_list[[counter]] = model_fit
                SSerr_list = c(SSerr_list, attr(model_fit,
"SSerr"))
            }
            counter = counter + 1
        }
    }
}
strange_entries = sapply(vgm_list, function(v) any(c(v$psill,
v$range) < 0) |
is.null(v))
if (any(strange_entries)) {
    if (verbose) {
        print(vgm_list[strange_entries])
        cat("^^^ ABOVE MODELS WERE REMOVED ^^^\n\n")
    }
}

```

```

    }
    warning("Some models were removed for being either NULL or having
a negative sill/range/nugget, \n\tset verbose == TRUE for more
information")
    SSerr_list = SSerr_list[!strange_entries]
    vgm_list = vgm_list[!strange_entries]
  }
  if (verbose) {
    cat("Selected:\n")
    print(vgm_list[[which.min(SSerr_list)]]
    cat("\nTested models, best first:\n")
    tested = data.frame(`Tested models` = sapply(vgm_list,
function(x)
as.character(x[2, 1])), kappa = sapply(vgm_list,
function(x) as.character(x[2, 4])), SSerror = SSerr_list)
    tested = tested[order(tested$SSerror), ]
    print(tested)
  }
  result = list(exp_var = experimental_variogram, var_model =
vgm_list[[which.min(SSerr_list)]],
               sserr = min(SSerr_list))
  class(result) = c("autofitVariogram", "list")
  return(result)
}

# obs_point_data: spatialpointsdataframe (columnas OBS y MODEL)
# model_grid_data: grid para interpolar

OK_interpolation <- function(data_points,
                             model_grid_data, var=formula('mx~1'))
{
  # getting residuals

  # variogram autofit
  variogram_fit <- autofitVariogramPISCOp(var, data_points, model =
c("Sph", "Exp", "Gau", "Ste"))

  # ok

  gs <- gstat::gstat(formula = var, data = data_points,
                    model = variogram_fit$var_model)

  kp <- raster::predict(gs, model_grid_data)
  round(raster::brick(kp)[["var1.pred"]], 3)
}

mapas_mes = function(path_to_file, grd, month='feb'){
  parameters = read.csv(path_to_file)

  data=parameters
  coordinates(data) <- ~x+y
  proj4string(data)=crs(grd)

  formulas=c(formula('a~1'), formula('l~1'), formula('v~1'), formula('k~1')
, formula('f~1'), formula('mx~1'))

```

```
for (k in 1:6){
  mapa=OK_interpolation(data_points = data,model_grid_data = grd,var
=formulas[[k]] )
  proj4string(mapa)=crs (grd)

  writeRaster (mapa,paste0 ('D:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/CV_maps/', 'parametros_',as.character(k), '
_',month, '.tif'), overwrite=TRUE)
}
}
```

Anexo H

Código de programación en lenguaje R para la realización de la validación cruzada de los mapas regionales del modelo MBLRP

```
#Importing the regionalization functionality
source('D:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/src/RMBLRP.R')
#Mixed stats from gauge stations and corrected TRMM
gauge_stats=read.csv('D:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/data/feb_gauge_stat.csv')
gauge_stats=kickOutliers(gauge_stats)
gauge_stats=filter_Neighbors(gauge_stats)

n=dim(gauge_stats)[1]
print(n)
write.table(gauge_stats,'D:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/data/gauge_stats_feb_filtered.csv',sep =
',',row.names = F)

validation_parameters=read.csv('D:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/CV_validation/CrossValidationParameters2.
csv',sep=',')[,-c(1,2)]

print(dim(validation_parameters)[1])
gauge_help=gauge_stats
coordinates(gauge_help) <- ~x+y
proj4string(gauge_help)='+proj=longlat +datum=WGS84 +no_defs
+ellps=WGS84 +towgs84=0,0,0'
mdist=dism(gauge_help)

try(for (i in 1:n){

  stats=gauge_stats[-i,]
  station=gauge_stats[i,]
  print(paste('Cross Validation: ',as.character(i)))
  CV_parameters=try(run(stats,path="D:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/CV_validation/",iterations=4,FILE_NAME='p
arameters_feb.csv'))
  for (j in 1:6){
    info=CV_parameters[[c('a','l','v','k','f','mx')[j]]]
    denominador=sum((1/mdist[i,-i])^2)
    validation_parameters[i,j]=sum(info/mdist[i,-i]^2/denominador)
  }
  validation_file=cbind(gauge_stats[,c(1,2)],validation_parameters)
  write.table(validation_file,'D:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/CV_validation/CrossValidationParameters2.
csv',sep=',',row.names = F)
})
```


Anexo I

Código de programación en lenguaje R para realizar la evaluación independiente.

```
source('D:/Proyectos_GitHub/Bartlet-Lewis_Regionalization/src/RMBLRP.R')
source('D:/Proyectos_GitHub/Bartlet-Lewis_Regionalization/src/plotHelpers.R')

inde_gauge=read.csv("D:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/data/ValidacionIndependiente/Validation_points/independent_g
auges.csv",sep = ';')
names(inde_gauge)=c('x','y','gauge')
gauge_loc=points_wgs84(inde_gauge)
cv_maps=stack(list.files("D:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/CV_maps/feb/",full.names = T,pattern = '.tif'))
gauge_par <-data.frame(raster::extract(cv_maps, gauge_loc))
names(gauge_par)=c('a','l','v','k','f','mx')

setwd("D:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/data/ValidacionIndependiente/Validation_points/")

plot11=plot_cdf('FEB_PIU_02_3hr.csv',gauge_par[2,],'PIU_02')
plot12=plot_cdf('FEB_PIU_06_3hr.csv',gauge_par[3,],'PIU_06')
plot21=plot_cdf('FEB_PIU_07_3hr.csv',gauge_par[4,],'PIU_07')
plot22=plot_cdf('FEB_CHA_01_3hr.csv',gauge_par[5,],'CHA_01')
plot31=plot_cdf('FEB_HUA_01_3hr.csv',gauge_par[7,],'HUA_01')
plot32=plot_cdf('FEB_HMT_01_3hr.csv',gauge_par[8,],'HMT_01')

figure=grid.arrange(arrangeGrob(plot11,plot12,plot21,plot22,plot31,plot32,nrow = 3))
ggsave("D:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/img/independent_cdf.png",figure,dpi=1200,units
'cm',width =20 ,height =25 )

plot11=plot_cdf('FEB_PIU_02_3hr.csv',gauge_par[2,],'PIU_02',language = 'Spanish')
plot12=plot_cdf('FEB_PIU_06_3hr.csv',gauge_par[3,],'PIU_06',language = 'Spanish')
plot21=plot_cdf('FEB_PIU_07_3hr.csv',gauge_par[4,],'PIU_07',language = 'Spanish')
plot22=plot_cdf('FEB_CHA_01_3hr.csv',gauge_par[5,],'CHA_01',language = 'Spanish')
#plot_cdf('FEB_CHA_02_3hr.csv',gauge_par[6,])
plot31=plot_cdf('FEB_HUA_01_3hr.csv',gauge_par[7,],'HUA_01',language
'Spanish')
plot32=plot_cdf('FEB_HMT_01_3hr.csv',gauge_par[8,],'HMT_01',language
'Spanish')

figure=grid.arrange(arrangeGrob(plot11,plot12,plot21,plot22,plot31,plot32,nrow = 3))
```

```
ggsave("D:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/img/cdf_independiente.png",figure,dpi=1200,units =
'cm',width =20 ,height =25 )
```

```
inde_gauge=read.csv("D:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/data/ValidacionIndependiente/Validation_points/independent_g
auges.csv",sep = ';')
names(inde_gauge)=c('x','y','gauge')
gauge_loc=points_wgs84(inde_gauge)
cv_maps=stack(list.files("D:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/CV_maps/feb/",full.names = T,pattern = '.tif'))
gauge_par <-data.frame(raster::extract(cv_maps, gauge_loc))
names(gauge_par)=c('a','l','v','k','f','mx')
```

```
setwd("D:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/data/ValidacionIndependiente/Validation_points/")
```

```
files=c('FEB_PIU_02_3hr.csv','FEB_PIU_06_3hr.csv',
'FEB_PIU_07_3hr.csv','FEB_CHA_01_3hr.csv',
'FEB_HUA_01_3hr.csv','FEB_HMT_01_3hr.csv')
```

```
pars=c(2,3,4,5,7,8)
```

```
p_valor=numeric()
d_stat= numeric()
for (i in 1:length(files)){
  file=files[i]
  par=gauge_par[pars[i],]
  obs=data.frame(obs=nonzero(read.csv(file,sep = ',')$Rainfall.mm))
  sim=data.frame(sim=nonzero(precip_sim(as.numeric(par),dim(obs)[1],tscale = 3)))
  f=ks.test(sim$sim, obs$obs)
  p_valor[i]=f$p.value
  d_stat[i]=f$statistic
}
```

```
archi=data.frame(files,d_stat,p_valor)
write.table(archi,'archi.csv',row.names = FALSE,sep = ',')
```

Anexo J

Código de programación en lenguaje R para el cálculo de características de tormentas.

```
library(raster)

a=raster('d:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/CV_maps/feb/parametros_1_feb.tif')
v=raster('d:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/CV_maps/feb/parametros_3_feb.tif')
fi=raster('d:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/CV_maps/feb/parametros_5_feb.tif')
k=raster('d:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/CV_maps/feb/parametros_4_feb.tif')
l=raster('d:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/CV_maps/feb/parametros_2_feb.tif')
mu=raster('d:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/CV_maps/feb/parametros_6_feb.tif')

average_rain_cell_duration=v/a
average_number_cell_per_storn=1+k/fi
average_storm_duration=v/(fi*a)#
average_rainfall_deph_storm=mu*(v/a)*(1+k/fi)

writeRaster(average_rain_cell_duration,'d:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/storm_characteristics/average_rain_cell_d
uration.tif',overwrite=T)
writeRaster(average_storm_duration,'d:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/storm_characteristics/average_storm_durat
ion.tif',overwrite=T)
writeRaster(average_rainfall_deph_storm,'d:/Proyectos_GitHub/Bartlet-
Lewis_Regionalization/output/storm_characteristics/average_rainfall_de
ph_storm.tif',overwrite=T)
writeRaster(average_number_cell_per_storn,'d:/Proyectos_GitHub/Bartlet
-
Lewis_Regionalization/output/storm_characteristics/average_number_cell
_per_storn.tif',overwrite=T)
```

Anexo K

Código para simular precipitaciones indicando los parámetros del modelo MBLRP. En este ejemplo se utilizó los parámetros de la estación Namora.

```
source('D:/Proyectos_GitHub/Bartlett-
Lewis_Regionalization/src/RMBLRP.R')
source('D:/Proyectos_GitHub/Bartlett-
Lewis_Regionalization/src/plotHelpers.R')
library(ggplot2)

par=c(2.38,0.036,1.551,0.078,0.085,1.870)

estacion1=data.frame(x=1:1000,pp=precip_sim(as.numeric(par),1000,tscale
= 1))
estacion3=data.frame(x=1:1000,pp=precip_sim(as.numeric(par),1000,tscale
= 6))
estacion5=data.frame(x=1:1000,pp=precip_sim(as.numeric(par),1000,tscale
= 12))
estacion8=data.frame(x=1:1000,pp=precip_sim(as.numeric(par),1000,tscale
= 24))

agg1=ggplot(data=estacion1,aes(x=x,y=pp))+geom_line()+ylab('Precipitac
i h (mm)') +xlab(element_blank())

agg3=ggplot(data=estacion3,aes(x=x,y=pp))+geom_line()+ylab('Precipitac
i h (mm)') +xlab(element_blank())

agg5=ggplot(data=estacion5,aes(x=x,y=pp))+geom_line()+ylab('Precipitac
i 2h (mm)') +xlab(element_blank())

agg8=ggplot(data=estacion8,aes(x=x,y=pp))+geom_line()+ylab('Precipitac
i 4h (mm)') +xlab(element_blank())

dev.new()
grid.arrange(arrangeGrob(agg1,agg3,agg5,agg8,nrow = 4))
```

Anexo L

Los datos utilizados en este trabajo fueron procesados con un control de calidad previo a su uso. El análisis consistió en detección de quiebres y tendencias de medias. A continuación, se presenta gráficos de las series temporales de algunas estaciones para inspección visual de la calidad de los datos utilizados.

Los Gráficos de datos pluviométricos para el mes de febrero de las estaciones Cañaverál, Matucana, Celendín y Paucartambo se muestran en la parte inferior. Se puede apreciar que las series cuentan con pocos datos faltantes a lo largo de 1999 y 2014. Además, se aprecia la estacionalidad de las series, esto es debido a que los datos utilizados no presentan quiebres de media o de desviación estándar.




Figura 18 Serie de tiempo de las precipitaciones diarias en la estación Cañaverál




Figura 19 Serie de tiempo de las precipitaciones diarias en la estación Matucana




Figura 20 Serie de tiempo de las precipitaciones diarias en la estación Celendín




Figura 21 Serie de tiempo de las precipitaciones diarias en la estación Paucartambo