

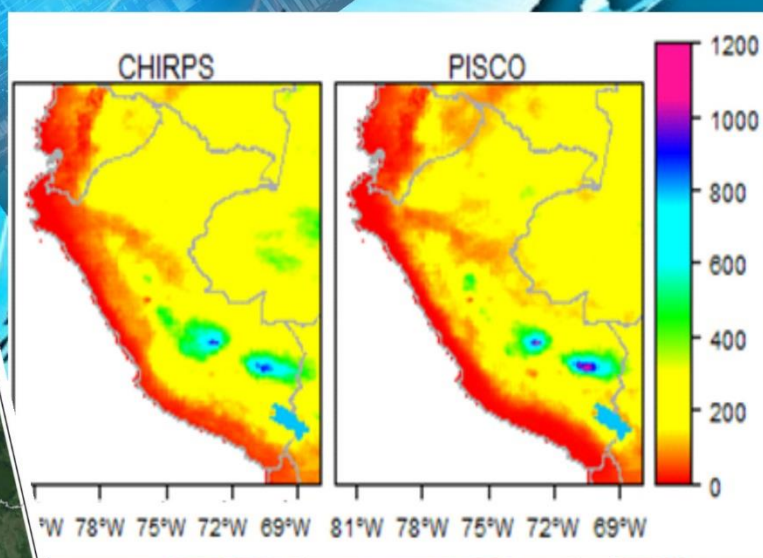
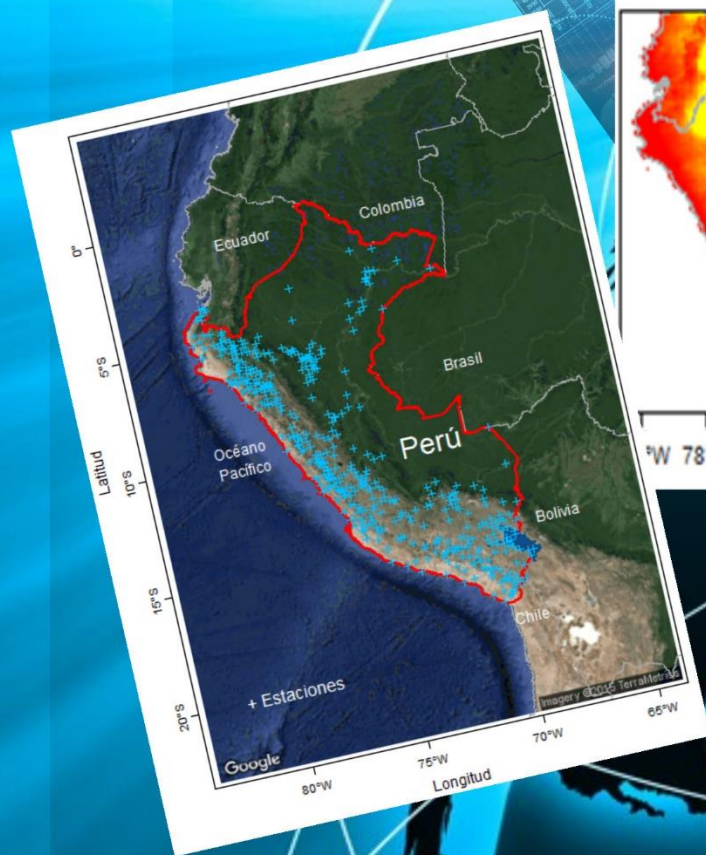


PERÚ

Ministerio del Ambiente

Servicio Nacional de Meteorología e Hidrología del Perú - SENAMHI

# GENERACIÓN DE BASE DE DATOS DE PRECIPITACIÓN MENSUAL GRILLADA DE ALTA RESOLUCIÓN A NIVEL NACIONAL 1981 -2013



2015





PERSONAL DIRECTIVO

**Ing. Amelia Díaz Pabló**  
*Presidente Ejecutivo del SENAMHI*

**Ing. Esequiel Villegas Paredes**  
*Director Científico del SENAMHI*

**Ing. Oscar G. Felipe Ovando**  
*Director de Hidrología y Recursos Hídricos del SENAMHI*

**PhD. Waldo Lavado Casimiro**  
*Director de Hidrología Aplicada del SENAMHI*

REVISOR DEL ESTUDIO

**PhD. Waldo Lavado Casimiro**  
*Director de Hidrología Aplicada del SENAMHI*

RESPONSABLE DEL ESTUDIO

**Ing. MSc. CARLOS ANTONIO FERNÁNDEZ PALOMINO**  
*Especialista en Hidrología del SENAMHI*

Lima-Perú  
Diciembre 2015

---

## ÍNDICE

	Pág.
I. INTRODUCCIÓN.....	5
II. OBJETIVOS .....	6
2.1 Objetivo general.....	6
2.2 Objetivos específicos.....	6
III. MARCO TEORICO .....	6
3.1 Introducción a análisis espacial de precipitación.....	6
3.2 Estadística espacial .....	6
3.3 Enfoques para la espacialización de la precipitación .....	7
3.3.1 Métodos deterministas:.....	7
3.3.2 Métodos estocásticos: .....	7
3.4 Métodos a evaluar .....	8
3.4.1 Método de ponderación inverso a la distancia (inverse-distance weighting-IDW).....	8
3.4.2 Kriging con Deriva Externa (KED) .....	8
IV. MATERIALES Y METODOLOGÍA.....	14
4.1 Zona de estudio.....	14
4.1.1 Ubicación .....	14
4.1.2 Extensión .....	14
4.1.3 Contexto general del Perú .....	15
4.2 Información utilizada.....	21
4.2.1 Precipitación mensual pluviométrica periodo 1981 -2013.....	21
4.2.2 Precipitación mensual estimada por satélite – CHIRPS.....	23
4.2.3 De las herramientas de análisis.....	23
4.3 Metodología.....	23
4.3.1 Control de calidad de los datos de precipitación.....	23
4.3.2 Evaluación y validación de los datos de CHIRPS .....	24
4.3.3 Combinación entre precipitación pluviométrica y CHIRPS a través de Kriging con Deriva Externa .....	24
V. RESULTADOS.....	27
5.1 Control de calidad de los datos de precipitación .....	27
5.2 Evaluación y validación de los datos de CHIRPS .....	27
5.3 Combinación entre precipitación pluviométrica y CHIRPS a través de Kriging con Deriva Externa .....	32
5.3.1 Relación de precipitación versus CHIRPS.....	32
5.3.2 Análisis estructural .....	33
5.3.3 Validación cruzada .....	35
5.3.4 Interpolación espacial.....	37

5.4 Evaluación de los productos grillados CHIRPS y PISCO versus datos de precipitación pluviométrica.....	39
5.5 Generación de mapas climáticos .....	40
VI. CONCLUSIONES .....	42
VII. BIBLIOGRAFIA .....	43

## ÍNDICE DE FIGURAS

Figura 1: Comportamiento típico de un semivariograma acotado con una representación de los parámetros básicos. SEMEXP corresponde al semivariograma experimental y MODELO al ajuste de un modelo teórico (Giraldo, 2002).....	12
Figura 2: Comparación de los modelos exponencial, esférico y Gaussiano. La línea punteada vertical representa el rango en el caso del modelo esférico y el rango efectivo en el de los modelos exponencial y gaussiano. Este tiene un valor de 210, respecto a una escala simulada entre 0 y 300. El valor de la meseta es 30 y el de la pepita 0. El 95% de la meseta es igual a 28.5.....	13
Figura 3: Esquema de validación cruzada dejando uno fuera .....	14
Figura 4: Mapa de ubicación del área de estudio.....	16
Figura 5: clasificación climática del Perú utilizando la Clasificación de Thornthwaite (basado en SENAMHI, 2005. Véase la Cuadro 1).....	17
Figura 6: Modelo digital de elevación (DEM en m s.n.m.) y los tres sistemas de drenaje de cuencas: la del Pacífico, el Lago Titicaca y Amazonas (Atlántico).....	20
Figura 7: Climatología de la precipitación media anual [mm] del periodo 1950-2000 (Hijmans et al., 2005) .....	20
Figura 8: Climatología de la temperatura media anual [°C] del periodo 1950-2000 (Hijmans et al., 2005) .....	21
Figura 9: Número de estaciones con dato disponibles por mes de la base original de datos de precipitación .....	22
Figura 10: Distribución espacial de las estaciones utilizadas .....	22
Figura 11: Metodología empleada para el control de calidad de datos mensuales de precipitación en la investigación.....	23
Figura 12: Diagrama de flujo de la metodología para la interpolación espacial. ....	26
Figura 13: Número de estaciones por mes de la base original (línea azul) y de la base con control de calidad (línea roja) .....	27
Figura 14: Distribución espacial de la cantidad de datos (a), altitud (b) y precipitación promedio mensual (c) luego del control de calidad de dato.....	28
Figura 15: Distribución espacial de la correlación (1ra fila) y el bias en porcentaje (2da fila) entre la precipitación mensual observada y CHIRPS. Validación en toda la serie de tiempo del periodo 1981-2013 (a y d), periodo lluvioso [Oct-Mar] (b y e) y el periodo seco [Abr-Set] (c y f). En el mapa de correlación, los triángulos corresponden a correlaciones significativas y en el mapa de bias, círculos rojos (azules) corresponden a sobreestimación (subestimación) .....	30
Figura 16: Similar a la Figura 15 pero validación en el periodo 1981 – 1998 (a y c) y en el periodo 1999 – 2013 (b y d) .....	31
Figura 17: Gráfica de relación de precipitación pluviométrica mensual versus precipitación estimada por satélite CHIRPS para los meses de año 2013 .....	32
Figura 18: Gráfica de relación de precipitación pluviométrica mensual versus precipitación estimada por satélite CHIRPS para el periodo de análisis.....	33
Figura 19: Ajuste del semivariograma residual por el mejor modelo teórico para cada mes .....	34
Figura 20: Izquierda, frecuencia de modelos teóricos ajustados para cada mes en el periodo de 1981-2013 y derecha, porcentaje de modelo de semivariograma teórico ajustado al semivariograma experimental de los residuales en el periodo de 1981-2013.....	35

Figura 21: Validación cruzada dejando uno fuera (LOOCV): arriba LOOCV para IDW, abajo LOOCV para KED. NASH para a,f) toda la serie (1981-2013), b,g) periodo húmedo [Oct-Mar], c,h) periodo seco (Abr-Set), d,i) periodo 1981-1997 e,j) periodo 1998-2013.....	36
Figura 22: mapas de la precipitación mensual grillado (mm) por la técnica de interpolación KED (denominado producto PISCO-precipitación) para los meses del año 2013. ....	37
Figura 23: Comparación de los patrones espaciales de la precipitación mensual grillado (mm) por la técnica de interpolación: Izquierda (IDW), medio (producto CHIRPS) derecha KED (denominado producto PISCO-precipitación) para el mes de diciembre 2013 .....	38
Figura 24: Comparación de los patrones espaciales de la precipitación promedio multianual del periodo 1981 al 2013, generado a partir de datos grillados mensuales.....	38
Figura 25: Relación entre los productos de precipitación mensual grillado (CHIRPS y PISCO) versus los datos pluviométricos. Línea azul (rosado) muestra la relación lineal entre CHIRPS y observado (PISCO y observado), línea gris muestra la relación óptima y en cada ventana se muestra los coeficientes de determinación entre los productos grillados y observados.....	39
Figura 26: Valores de los coeficientes de determinación resultado de la relación espacial entre los productos de precipitación mensual grillado (CHIRPS y PISCO) versus los datos pluviométricos para los meses analizados (periodo 1981 – 2013).....	40
Figura 27: Mapas de climatología de precipitación en mm [1981 – 2010]. ....	41

## ÍNDICE DE TABLAS

Tabla 1: Características del sistema climático.....	17
---	----

## I. INTRODUCCIÓN

En los últimos años se está incrementando la demanda por productos grillados de las variables hidroclimáticas de alta calidad, resolución espacial y temporal; por parte de diferentes disciplinas y sectores, incluyendo la hidrología, agricultura y salud. La precipitación es una de las variables climatológicas más importantes para los estudios como son las caracterizaciones hidroclimatológicas y riesgos (las inundaciones y sequías). Además de que los datos de precipitación son uno de los principales variables forzantes para comprender los procesos hidrológicos. En ese contexto el SENAMHI a través de la Dirección General de Hidrología y Recursos Hídricos ha comenzado a enfocarse en diversos proyectos de investigación considerando como una de ellas la interpolación de variables hidroclimáticas siguiendo los siguientes objetivos: Adquisición de conocimiento a través de revisión de literaturas, talleres de capacitación, revisión general de productos actuales y determinación de cuál de los métodos de interpolación es la adecuada para la interpolación de variables hidroclimáticas (precipitación, temperatura, evapotranspiración, etc.). Por lo que producto de este esfuerzo SENAMHI a través de la Dirección General de Hidrología y Recursos Hídricos ha comenzado a producir el producto PISCO (Peruvian Interpolated data of the SENAMHI's Climatological and hydrological Observations). PISCO, presentará una serie de datos hidroclimáticos a una resolución espacial de 0.05° y nuestro objetivo es llegar a tener escalas temporales diarias y mensuales de las variables de precipitación, temperatura máxima y mínima, evapotranspiración y caudales.

En el presente estudio presentamos la generación de una base de datos de precipitación mensual grillada de alta resolución espacial (0.05°) a nivel nacional, para el periodo de enero de 1981 hasta diciembre del 2013. La interpolación de la precipitación es generada mediante la aplicación del método geoestadístico denominado Kriging con Deriva Externa (KED) usando como covariable el producto de precipitación estimado por satélite denominado CHIRPS.

Finalmente el producto de PISCO-precipitación y los diferentes productos derivados a partir de ella están disponibles para los usuarios en formato GeoTIFF y NetCDF (Network Common Data Form) en el siguiente sitio web:

- i) <http://www.senamhi.gob.pe/serviciosclimaticos/sequia/?p=indices>
- ii) [http://ons.snirh.gob.pe/Peru/maproom/Monitoring/Meteorological/Precipitation\\_SENAMHI.html.es](http://ons.snirh.gob.pe/Peru/maproom/Monitoring/Meteorological/Precipitation_SENAMHI.html.es)

## II. OBJETIVOS

### 2.1 Objetivo general

Generar una base de datos de precipitación mensual grillada de alta resolución espacial (0.05°) a nivel nacional, para el periodo de enero de 1981 hasta diciembre del 2013.

### 2.2 Objetivos específicos

- Describir y evaluar los productos de precipitación observada y de satélite
- Realizar la combinación (“merging”) entre los datos de precipitación observada y CHIRPS a través de la técnica de interpolación de Kriging con Deriva Externa (KED)
- Generar base de datos de precipitación mensual grillada

## III. MARCO TEORICO

En esta sección se describe breve y únicamente los principales conceptos de estadística espacial que han de aplicarse en este estudio.

### 3.1 Introducción a análisis espacial de precipitación

Mapas de precipitación tienen una amplia gama de aplicaciones, tales como la gestión de los recursos hídricos y la simulación hidrológica. Sin embargo para obtener información continua espacialmente de la precipitación mensual, la cobertura de la red de estaciones es limitada. Por estas razones, en especial, en áreas de alto relieve topográfico como es el caso del territorio Peruano, es insuficiente utilizar únicamente los datos de las estaciones meteorológicas para caracterizar la cantidad y la distribución espacial de la precipitación sobre un área de estudio a gran escala. Para mejorar las estimaciones regionales de precipitación las técnicas geoestadísticas multivariadas son una alternativa que ampliamente están siendo utilizados para la caracterización espacial de la precipitación utilizando la información de superficie disponible (Feki et al., 2012). En otros estudios, se ha incorporado la información de productos de precipitación de satélite y en conjunción con mediciones provenientes de pluviómetros se han utilizado para describir la precipitación (Creutin et al., 1988). En este estudio considerando que el sensoramiento remoto es una de las formas de obtener mejor la información de los patrones espaciales de precipitación y que los registros de datos observados de precipitación son medidas precisas de precipitación; Nosotros aprovechamos estos beneficios mutuos para realizar la combinación de los dos tipos de información mediante la técnica de interpolación geoestadística denominado Kriging con Deriva Externa (KED) y así obtener el producto denominado PISCO-precipitación.

### 3.2 Estadística espacial

La estadística espacial, denominada también *Geoestadística* es la rama de la estadística que estudia procesos aleatorios con índices espaciales (Cressie, 1991).



Generalmente los modelos estadísticos toman en cuenta variables aleatorios independientes, en casos más reales se toman en cuenta la dependencia estadística. En el caso de series temporales mientras los datos estén más próximos puede existir una correlación, lo mismo sucede con datos espaciales donde la dependencia puede estar en todas las direcciones.

### **3.3 Enfoques para la espacialización de la precipitación**

Diferentes técnicas se han utilizado para los propósitos de espacialización de la precipitación, a partir de datos obtenidos en las redes de medición, lo cual implica casi siempre llevar a cabo las tareas de análisis exploratorio de datos, descripción y predicción del comportamiento espacial de una o varias variables sobre el dominio de estudio.

Para realizar las estimaciones se recurre al uso de algoritmos de interpolación espacial, los cuales, en general, utilizan información discreta de una variable de interés para obtener superficies continuas. Puede decirse que estos se clasifican en dos categorías, los métodos deterministas y los métodos estocásticos (Isaaks y Srivastava, 1989).

#### **3.3.1 Métodos deterministas:**

Diferentes autores (Isaaks and Srivastava, 1989; Burrough and McDonnell, 1998) presentan una revisión completa de los diversos métodos deterministas clásicos para generar superficies continuas de variables espaciales a partir de valores medidos puntualmente, como por ejemplo el vecino cercano, el método lineal, el método del inverso de la distancia elevada a un exponente, los splines, la interpolación cúbica y bicúbica, etc. A pesar de que la mayoría de dichos métodos no pueden cuantificar la incertidumbre de interpolación, muchos autores manifiestan que éstos tienen la gran ventaja de ser algoritmos muy sencillos que pueden ser fácilmente implementados.

#### **3.3.2 Métodos estocásticos:**

El desarrollo de la geoestadística en la década de los sesenta surgió de la necesidad de generar una metodología para evaluar y estimar la disponibilidad de reservas en los depósitos mineros. Debido a su facilidad para analizar y extraer patrones de comportamiento de variables distribuidas en el espacio ha sido adoptada como herramienta para el análisis de la variabilidad espacial de los procesos físicos en diversos campos de las ciencias, como por ejemplo la hidrogeología, la hidrología superficial, la meteorología, la ciencia del suelo, la investigación de yacimientos minerales, entre tantos (Journel and Huijbregts, 1989; Gómez-Hernández, 1996; Goovaerts, 1997). Como uno de sus campos fundamentales de desarrollo, la geoestadística ha generado diversos métodos de estimación, los cuales se conocen como modelos estocásticos de interpolación o krigeado. En ellos, la variable que se desea estimar tiene intrínseca dos componentes: (i) una componente determinista que varía uniformemente en el espacio y (ii) una componente aleatoria. La componente determinista permite hacer una afirmación acerca del rango probable de valores a los que pueden pertenecer

los correspondientes a las zonas no conocidas, mientras que la componente aleatoria es el causante de que no puedan hacerse predicciones con total certidumbre (Gómez-Hernández, 1996; Burrough and McDonnell, 1998). Una de las mayores contribuciones de la geoestadística en la estimación de campos espaciales ha sido el direccionamiento del problema de la estimación de variables hacia la integración de distintos tipos de datos, proponiendo para dicho fin una serie de algoritmos capaces de relacionar de forma sistemática la información obtenida a partir de distintas fuentes. En general, la información secundaria proviene de mediciones indirectas que pueden dar indicio de la distribución espacial de la variable principal.

### 3.4 Métodos a evaluar

En este estudio evaluamos el enfoque estocástico (KED) frente al enfoque determinista (Método de ponderación inverso a la distancia), para conocer el valor añadido en la caracterización espacial de la precipitación por la técnica de interpolación geoestadística KED el cual incorpora como un variable predictor a la precipitación estimada por satélite (CHIRPS).

#### 3.4.1 Método de ponderación inverso a la distancia (inverse-distance weighting-IDW)

Este algoritmo calcula los valores de las celdas por medio de una composición ponderada de los datos de la muestra, el modelo sugiere que el resultado predicho reduce su incidencia en la medida en que aumenta la separación entre el punto a evaluar y los puntos de su entorno. Es así como se acepta que los puntos más cercanos al centroide poseen un mayor peso en el cálculo del valor definitivo de la celda, su modelo matemático (Slocum, 1999):

$$Z = \left( \sum \left( \frac{Z_i}{d_i^n} \right) \right) / \sum \left( \frac{1}{d_i^n} \right) \quad (1)$$

Donde  $Z$  es el valor a interpolar,  $Z_i$  son los valores de los puntos vecinos,  $d_i$  Distancia entre los puntos vecinos y el punto de la celda a predecir,  $n$  Es la potencia a la cual se eleva la distancia, oscila entre 0.5 a 4. Para este estudio, el parámetro de potencia se fija para que sea igual a dos.

#### 3.4.2 Kriging con Deriva Externa (KED)

Tveito et al., (2008), señala que la familia kriging, también conocido como métodos geoestadísticos, se basa en la idea de que los valores medidos en lugares cercanos tienden a estar más relacionada que los valores medidos en otros lugares.

Similar a IDW, Kriging también utiliza una ponderación, sin embargo, como un método probabilístico, Kriging depende de las relaciones espaciales y estadísticos para predecir puntos no medidos (Johnston et al., 2001). Funciones de semivariograma empíricos proporcionan medios para cuantificar la autocorrelación

espacial de los conjuntos de datos que luego se incluyen en el modelo espacial (Goovaerts, 1997).

Ecuación de Kriging se basa en la predicción espacial lineal óptima, donde la media desconocida del proceso al azar se estima a través del mejor estimador lineal insesgado. El estimador es "insesgado" porque la media de error es 0; "lineal", ya que los valores estimados son combinaciones lineales ponderadas de los datos disponibles, y "mejor" porque el estimador tiene como objetivo minimizar la varianza de los errores (Cressie, 1990).

Kriging con deriva externa permite la predicción de una variable  $Z$ , conocido sólo en un pequeño conjunto de puntos de la zona de estudio, a través de otra variable  $Y$  exhaustivamente conocido en la misma zona. Elegimos para modelar  $Z$  con una función aleatoria  $Z(s)$  e  $Y$  como una variable determinista  $Y(s)$  con  $s$  un punto particular de un campo  $S$ . Las dos cantidades se asume que son linealmente relacionadas (ecuación 2):

$$E[Z(s)] = a_0 + b_1 Y(s) \quad (2)$$

Examinamos el caso de una función  $Z(s)$  aleatoria, cuya predicción se desea mejorar introduciendo la función de forma  $Y(s)$  que provee detalle a una escala más pequeña que la distancia promedio de la muestra para  $Z(s)$ . El estimador de  $Z^{*KED}(s_0)$  en la posición  $s_0$  es una combinación lineal de los valores de la muestra  $Z(s_i)$  en la ubicación  $s_i$  ( $i = 1, \dots, n$ ):

$$Z^{*KED}(s_0) = \sum_{i=1}^n \lambda_i^{KED} Z(s_i) \text{ con } \sum_{i=1}^n \lambda_i = 1 \quad (3)$$

Buscamos para un predictor insesgado, que es uno con un error de predicción que se espera que sea cero,  $E[Z^*(s_0) - Z(s_0)] = 0$ , de modo que:

$$E[Z^*(s_0)] = E[Z(s_0)] \quad (4)$$

Esta igualdad puede ser desarrollado en:

$$E[Z^*(s_0)] = \sum_i^n \lambda_i E[Z(s_0)] = a_0 + b_1 \sum_i^n \lambda_i Y(s_i) = a_0 + b_1 Y(s_0) \quad (5)$$

Esta ecuación implica que las ponderaciones deben ser en promedio consistente con una interpolación exacta de  $Y(s)$ :

$$Y(s_0) = \sum_{i=1}^n \lambda_i Y(s_i) \quad (6)$$

La función objetivo (O) para minimizar en este caso consiste en la predicción de la varianza,  $\sigma_E^2(s_0)$ , y dos restricciones:

$$O = \sigma_E^2(s_0) - \mu_1 \left( \sum_{i=1}^n \lambda_i - 1 \right) - \mu_2 \left( \sum_{i=1}^n \lambda_i Y(s_i) - Y(s_0) \right) \quad (7)$$

Donde  $\mu_1$  y  $\mu_2$  son parámetros de Lagrange, y la predicción de la varianza es:

$$\sigma_E^2(s_0) = \text{var} \left[ Z^*(s_0) - Z(s_0) \right] = \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j C(s_i - s_j) - 2 \sum_{i=1}^n \lambda_i C(s_i - s_0) + C(0) \quad (8)$$

Con  $C$  la función covariancia de  $Z$ .

El mínimo de esta función cuadrática se encuentra estableciendo las derivadas parciales de la función objetivo  $O(\lambda_1, \mu_1, \mu_2)$  a cero, lo que lleva al sistema de ecuaciones:

$$\sum_{j=1}^n \lambda_j C(s_i - s_j) - \mu_1 - \mu_2 Y(s_i) = C(s_i - s_0) \text{ para } i = 1, \dots, n \quad (9)$$

$$\sum_{j=1}^n \lambda_j = 1 \quad (10)$$

$$\sum_{j=1}^n \lambda_j Y(s_j) = Y(s_0) \quad (11)$$

Con la mínima predicción de la varianza:

$$\sigma_K^2 = C(0) - \sum_{i=1}^n \lambda_i C(s_i - s_0) + \mu_1 + \mu_2 Y(s_0) \quad (12)$$

La mezcla de una función aleatoria estacionaria de segundo orden con una función media no estacionaria puede parecer sorprendente. Sin embargo, estacionariedad es un concepto que depende de la escala (Wackernagel, 1994). Los datos pueden sugerir la estacionalidad de los datos muy espaciados en  $Z(s)$ , mientras que su aspecto no estacionario cuando inspecciona el fino detalle prevista por una función  $Y(s)$ . Por lo tanto KED consiste en la incorporación en el sistema de Kriging condiciones de universalidad suplementarios sobre una o varias variables de deriva externo  $Y_i(s) i = 1, \dots, M$  medida exhaustivamente en el dominio espacial.

La función  $Y_i(s)$  necesita ser conocido en todas las ubicaciones  $s_i$  de la muestras  $Z(s_i)$ , así como en los nodos de la red de estimación. En este método, se supone una relación lineal entre la variable de interés y las variables auxiliares en los puntos de observación de la variable de interés. Esta asunción es muy importante en la predicción utilizando el método KED. Por lo tanto, si una función no lineal describe mejor las relaciones entre las dos variables, esta función debe ser primero utilizada para transformar los datos de la variable auxiliar. Los datos transformados se podrían utilizar entonces como deriva externa.

### 3.4.2.1 Análisis Estructural

El análisis estructural es una de las etapas fundamentales de todo estudio geoestadístico. Tiene como objetivo la caracterización de la estructura espacial del fenómeno estudiado.

El enfoque de geoestadística se basa en la teoría de las variables regionalizadas (Matheron, 1970). Se supone que las muestras espaciales se consideran como la realización de un proceso espacial aleatoria. Esto permite el uso de un poderoso instrumento estadístico para la estimación espacial denominado *semivariograma* (Feki and Slimani, 2006).

Si,  $z^\alpha(s_i)$  representa realizaciones de las variable aleatoria  $Z^\alpha(s_i)$  en los puntos particulares  $s_i$  dentro de un campo de  $S$ . La hipótesis intrínseca (Chauvet, 1999) asume que, para una variable aleatoria  $Z(s_i)$ : (i) el valor esperado de  $Z(s_i)$  no depende de la posición  $s_i$ , y (ii) la varianza de  $[Z(s_i) - Z(s_i + h)]$  no depende de la posición  $s_i$  en  $S$  para cualquier vector de separación  $h$ .

Entonces la función del semivariograma da una medida de la correlación espacial de una variable (es) aleatoria, como una función de la distancia de separación. El semivariograma experimental fue estimado por la función:

$$\gamma_\alpha(h) = \frac{1}{2n(h)} \sum_{i=1}^{n(h)} [Z^\alpha(s_i + h) - Z^\alpha(s_i)] \quad (13)$$

Donde  $\gamma_\alpha$  es la semivarianza de  $Z^\alpha$  en la distancia de separación  $h$ ; y  $n(h)$  es el número de pares de puntos en un intervalo de distancia  $(h + \Delta h)$ .

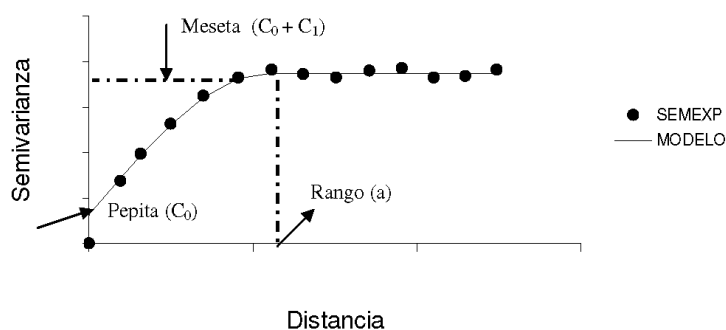
Para poder realizar la predicción del valor es necesario ajustar el semivariograma empírico a un semivariograma experimental para cuantificar el grado y escala de variación espacial. Por ello se hace necesario el ajuste de modelos que generalicen lo observado en el semivariograma experimental a cualquier distancia.

Existen diversos modelos teóricos de semivarianza que pueden ajustarse al semivariograma experimental. En Samper and Carrera, (1990) se presenta una discusión respecto a las características y condiciones que éstos deben cumplir. Warrick et al., (1986) menciona que en general dichos modelos pueden dividirse en no acotados (lineal, logarítmico, potencial) y acotados (esférico, exponencial, gaussiano). Los del segundo grupo garantizan que la covarianza de los incrementos es finita, por lo cual son ampliamente usados cuando hay evidencia de que presentan buen ajuste. Todos estos modelos tienen tres parámetros comunes (Figura 1) que son descritos a continuación:

**Efecto Pepita:** Denominado *nugget* en inglés, se denota por  $C_0$  y representa una discontinuidad puntual del semivariograma en el origen (Figura 1). Puede ser debido a errores de medición en la variable o a la escala de la misma.

**Rango:** muestra la distancia donde la separación entre puntos indica una autocorrelación significativa. Indica la amplitud del radio de búsqueda de los vecinos locales.

**Meseta:** Denominado *sill* en inglés, máxima semivarianza hallada entre un par de puntos, que es encargada de encontrar la incertidumbre en el momento de la interpolación.



**Figura 1:** Comportamiento típico de un semivariograma acotado con una representación de los parámetros básicos. SEMEXP corresponde al semivariograma experimental y MODELO al ajuste de un modelo teórico (Giraldo, 2002)

En este estudio se evalúa el ajuste del variograma experimental por los modelos teóricos: esférico (SPH), exponencial (EXP) y Gaussiano (GAU) por ser de mayor aplicación con variables de precipitación.

**Modelo Esférico:** En este modelo se muestra una disminución progresiva de la autocorrelación espacial (así como un aumento en la semivarianza) hasta cierta distancia, después de la cual la autocorrelación es cero. Su expresión matemática es la siguiente:

$$\gamma(h) = \begin{cases} C_0 + C_1 \left( \frac{3}{2} \left( \frac{h}{a} \right) - \frac{1}{2} \left( \frac{h}{a} \right)^3 \right) & h \leq a \\ C_0 + C_1 & h > a \end{cases} \quad (14)$$

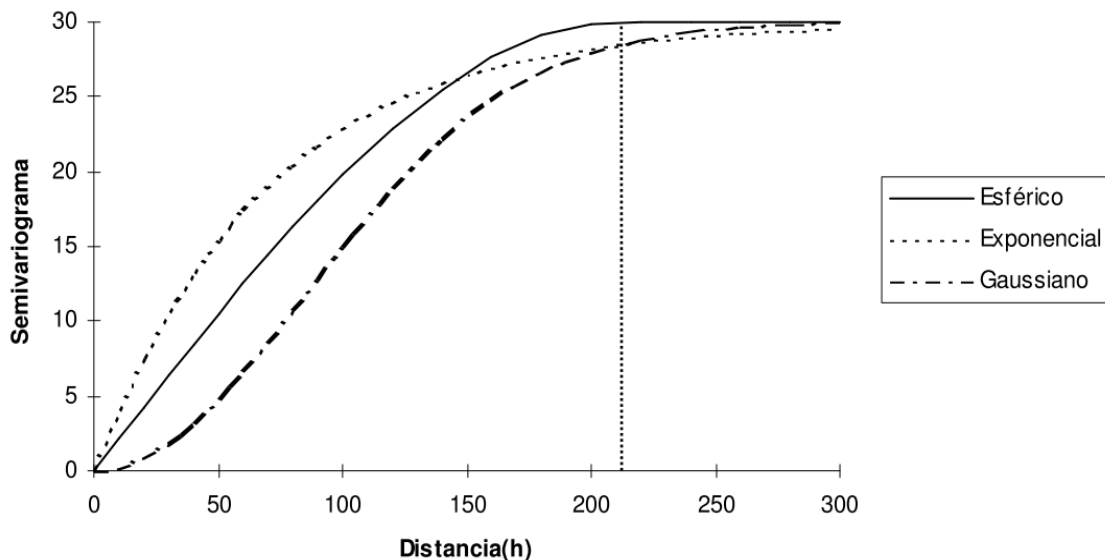
En donde  $C_1$  representa la meseta,  $a$  el rango y  $h$  la distancia.

**Modelo Exponencial:** Este modelo se aplica cuando la dependencia espacial tiene un crecimiento exponencial respecto a la distancia entre las observaciones. Su expresión matemática es la siguiente:

$$\gamma(h) = C_0 + C_1 \left( 1 - \exp\left(\frac{-3h}{a}\right) \right) \quad (15)$$

**Modelo Gaussiano:** Al igual que en el modelo exponencial, la dependencia espacial se desvanece solo en una distancia que tiende a infinito. El principal distintivo de este modelo es su forma parabólica cerca al origen (Figura 2). Su expresión matemática es:

$$\gamma(h) = C_0 + C_1 \left( 1 - \exp\left(\frac{-h^2}{a^2}\right) \right) \quad (16)$$



**Figura 2:** Comparación de los modelos exponencial, esférico y Gaussiano. La línea punteada vertical representa el rango en el caso del modelo esférico y el rango efectivo en el de los modelos exponencial y gaussiano. Este tiene un valor de 210, respecto a una escala simulada entre 0 y 300. El valor de la meseta es 30 y el de la pepita 0. El 95% de la meseta es igual a 28.5.

### 3.4.2.2 Evaluación de la eficiencia de la técnica de interpolación

En este estudio evaluamos la eficiencia de la técnica de interpolación a través de la validación cruzada dejando uno fuera o Leave-one-out cross-validation (LOOCV)

**Validación cruzada dejando uno fuera:** Para evaluar la bondad de ajuste o la eficiencia de la técnica de interpolación, el más empleado es la validación cruzada dejando uno fuera (Figura 3), que consiste en excluir la observación (dato de prueba) de uno de los N puntos muestrales y con los N-1 valores restantes (Datos de entrenamiento) se predice el valor de la variable en estudio en la ubicación del punto que se excluyó (Dato de prueba); vía Kriging o ponderación de la distancia inversa. Este procedimiento se realiza en forma secuencial con cada uno de los puntos de datos de prueba y así se obtiene un conjunto de N datos o valores estimados con el cual se determina medidas de precisión como la raíz del error cuadrático medio (RECM), el coeficiente de determinación  $R^2$  y el coeficiente de eficiencia NASH.

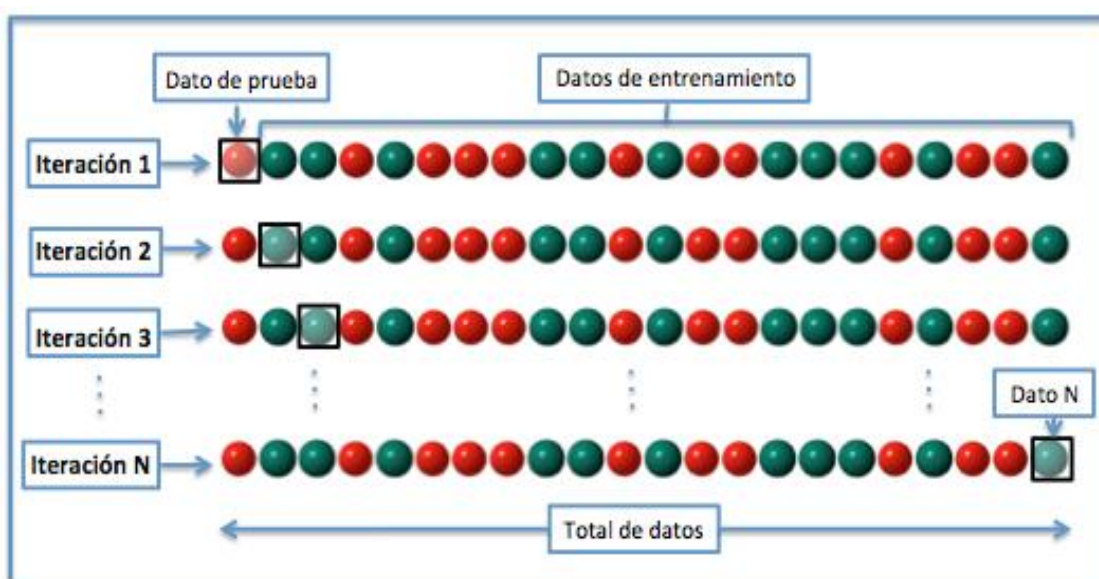


Figura 3: Esquema de validación cruzada dejando uno fuera.

## IV. MATERIALES Y METODOLOGÍA

### 4.1 Zona de estudio

#### 4.1.1 Ubicación

El territorio peruano se localiza en el hemisferio Sur, en el sector centro occidental de América del Sur con sus costas bañadas por las aguas del Océano Pacífico, extendiéndose al continente Antártico por factores geográficos, ecológicos y por antecedentes históricos. Este territorio está comprendido dentro de la zona intertropical del hemisferio Sur, esto es entre los dos principales paralelos que son: la Línea Ecuatorial y el Trópico de Capricornio.

#### 4.1.2 Extensión

La superficie continental del territorio peruano se extiende entre los meridianos  $68^{\circ} 39' 27''$  de longitud Este (Boca del Río Health o Abuyama en el Departamento de Madre de Dios) y  $81^{\circ} 19' 34,5''$  longitud Oeste (Punta Balcón, en el Departamento de



Piura); y entre los paralelos 0° 01' 48" (Thalweg en el río Putumayo, Departamento de Loreto) y 18° 21' 03" (Pascana del Hueso, en el Departamento de Tacna).

Limita al Norte con Ecuador, en una extensión de 1 529 km de frontera, y con Colombia, en 1 506 km de frontera; al Sur con Chile, en una extensión de 169 km de frontera; al Este con Brasil, con una frontera de 2 822 km y Bolivia, en una extensión de 1 047 km de frontera, y al Oeste sus costas son bañadas por el Océano Pacífico, a lo largo de 3 080 km (

Figura 4).

#### **4.1.3 Contexto general del Perú**

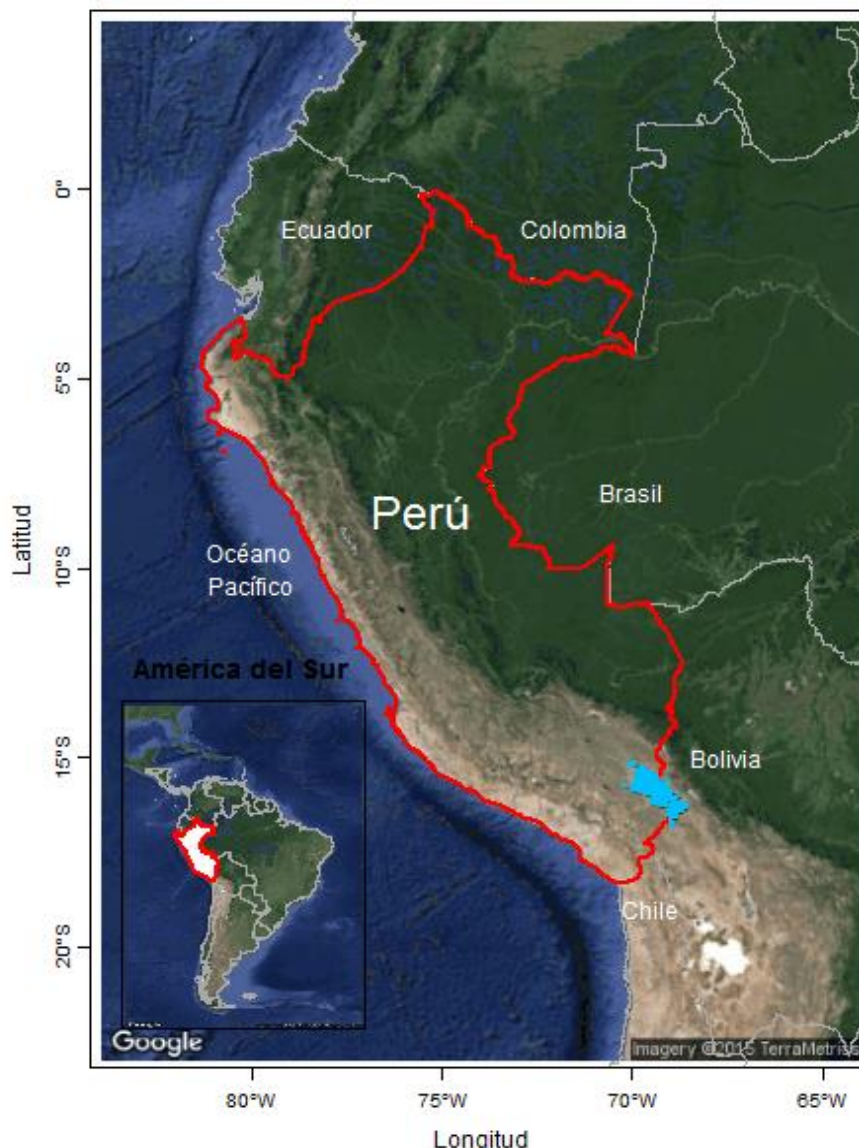
El Perú con una superficie de 1.285.220 km<sup>2</sup> es un país caracterizado por diversas unidades fisiográficas (

Figura 4) y el clima (Figura 5). Pulgar, (1941) propuso agrupar las diferencias altitudinales en 8 regiones homogéneas: Chala o Costa (0-500 msnm), Yunga (500 a 2.300 msnm), el quechua (2300 a 3500 msnm), Suni o Jalca (3.500 a 4000 msnm), Puna (4000-4800 msnm), Janca o Cordillera (4800-6768 msnm), Rupa Rupa o Selva Alta (400 a 1000 msnm) y Omagua o Selva Baja (80-400 msnm). Esta clasificación fue tomada por el SENAMHI (2005), utilizando la clasificación climática de Thornthwaite (Thornthwaite, 1948), destacando así 27 zonas climáticas diferentes en el Perú (véase la Figura 5 y en la Tabla 1). Las características de estas zonas climáticas se describen a continuación:

#### **Clima Semi-Cálido Muy Seco (Desértico-Árido-Sub Tropical)**

Este tipo de clima constituye uno de los aspectos climáticos más notables del Perú, comprende casi toda la región de la costa, desde Piura hasta Tacna y desde el litoral del Pacífico hasta el nivel aproximado de 2 000 msnm, representa el 14% de la superficie total del país.

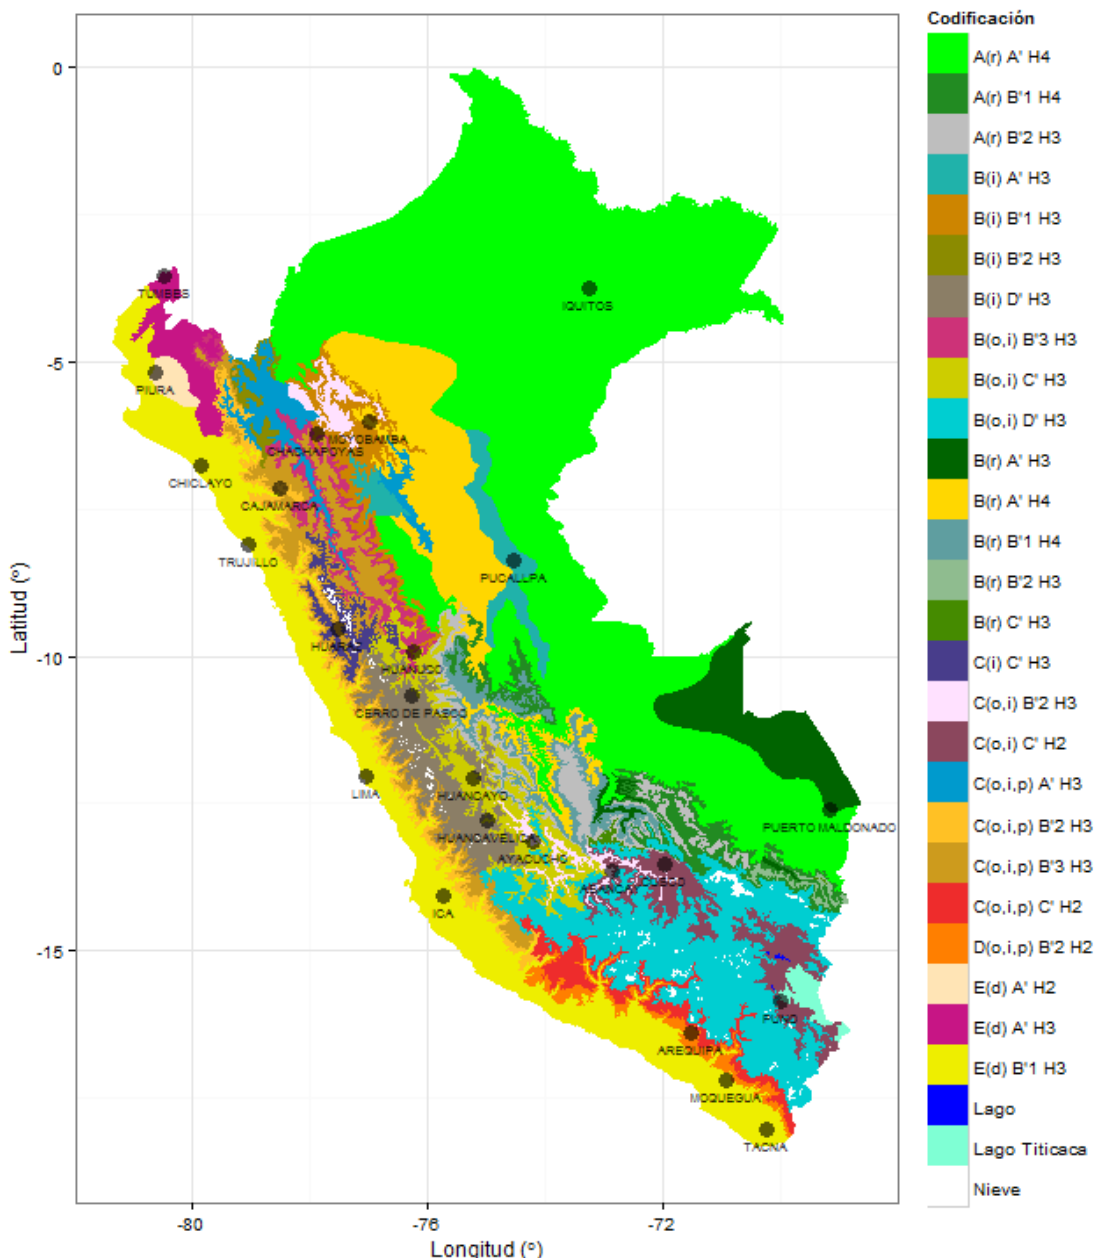
Se caracteriza por presentar precipitación promedio anual de 150 mm y temperatura media anuales de 18 a 19 °C, decreciendo en los niveles más elevados de la región.



**Figura 4:** Mapa de ubicación del área de estudio.

### **Clima Cálido Muy Seco (Desértico o Árido Tropical)**

Comprende el sector septentrional de la región costera, que incluye gran parte de los Departamentos de Tumbes y Piura, entre el litoral marino y la costa aproximada de 1 000 msnm. Representa menos del 3,0% (35 mil km<sup>2</sup>) de la superficie territorial del país. Se caracteriza por ser muy seco, con más precipitación media anual (alrededor de 200 mm) y cálido, con una temperatura promedio anual de 24 °C, sin cambio térmico invernal definido.



**Figura 5:** Clasificación climática del Perú utilizando la Clasificación de Thornthwaite (basado en SENAMHI, 2005. Véase la Tabla 1)

### Clima Templado Sub-Húmedo (De Estepa y Valles Interandinos Bajos)

Este clima es propio de la región de la sierra, correspondiendo a los valles interandinos bajos e intermedios, situados entre los mil y 3 mil msnm.

Las temperaturas sobrepasan los 20°C y la precipitación anual se encuentra por debajo de los 500 mm aunque en las partes más elevadas, húmedas y orientales, pueden alcanzar y sobrepasar los 1200 mm.

**Tabla 1:** Características del sistema climático.

Precipitación Efectiva		Temperatura Eficiente	
Símbolo	Carácter del Clima	Símbolo	Carácter del Clima
A	Muy lluvioso	A'	Cálido
B	Lluvioso	B'1	Semicalido
C	Semiseco	B'2	Templado
D	Semiarido	B'3	Semifrío
E	Arido	C'	Frío
		D'	Semifrigido
		E'	Frígido
		F'	Polar

Distribución de la Precipitación a Través del Año		Humedad Relativa	
Símbolo	Significado	Símbolo	Característica Climática
r	Precipitación abundante en todas las estaciones del año	H1	Muy Seco
i	Con invierno seco	H2	Seco
p	Con primavera seca	H3	Húmedo
v	Con verano seco	H4	Muy Húmedo
o	Con otoño seco		
d	Deficiencia de precipitación en todas las estaciones del año		

### **Clima Frío o Boreal (De los Valles Mesoandinos)**

Este tipo climático de la región de la sierra, se extiende entre los 3 000 y 4 000 msnm. Se caracteriza por sus precipitaciones anuales promedio de 700 mm y sus temperaturas medias anuales de 12 °C presentan veranos lluviosos e inviernos secos con fuertes heladas.

### **Clima Frígido (De Tundra)**

Este tipo de clima, conocido como clima de Puna, corresponden a los sectores altitudinales de la región andina comprendido entre los 4 000 y 5 000 msnm. Cubre alrededor de 13,0% del territorio peruano (170 000 km<sup>2</sup>). Se caracteriza por presentar precipitaciones promedio de 700 mm anuales y temperaturas promedio anuales de 6 °C. Comprende las colinas, mesetas y cumbres andinas. Los veranos son siempre lluviosos y nubosos; y los inviernos (junio-agosto), son rigurosos y secos.

### **Clima de Nieve (Gélido)**

Este clima corresponde al de nieve perpetua de muy alta montaña, con temperaturas medias durante todos los meses del año por debajo del punto de congelación (0 °C). Se distribuye en los sectores altitudinales que sobrepasan los 5 mil msnm y que están representados mayormente por las grandes masas de nieve y hielo de las altas cumbres de los Andes Peruanos.

### **Clima Semi-Cálido Muy Húmedo (Sub-Tropical muy Húmedo)**

Este tipo de clima predomina en la selva alta o contra fuertes orientales andinos boscosos. Se caracteriza por ser muy húmedo, con precipitaciones por encima de los 2 mil mm y con bolsones pluviales que sobrepasan los 5000 mm, como en la zona de Quincenal.

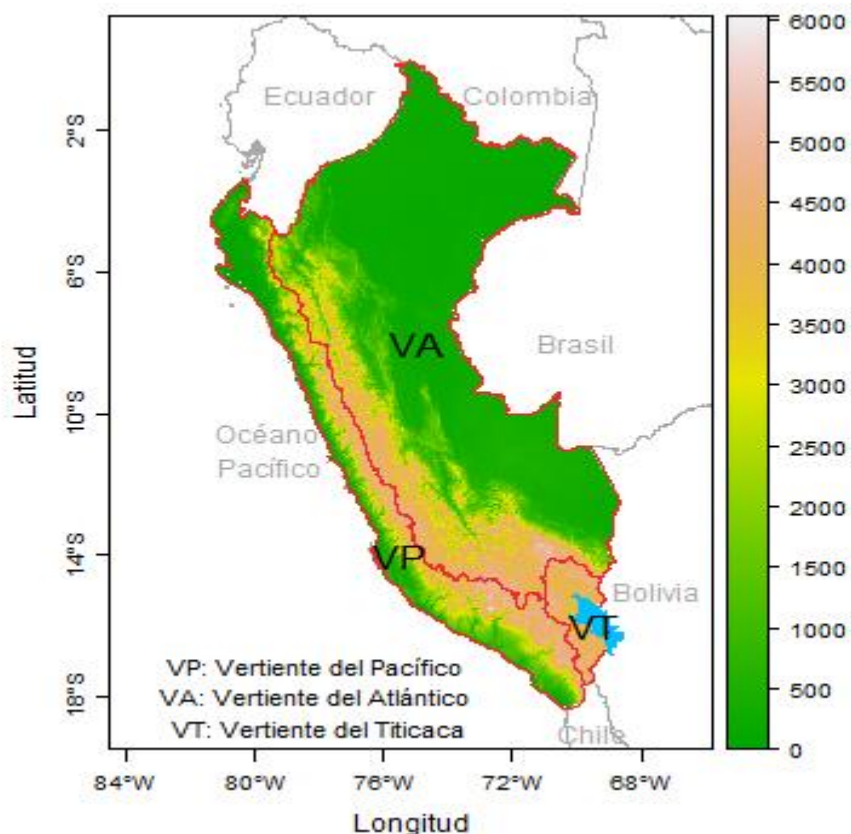
Las temperaturas están por debajo de 22 °C en su mayor extensión. Temperaturas más elevadas se registran en los fondos de los valles y en la transición a la llanura amazónica.

### **Clima Cálido Húmedo (Tropical Húmedo)**

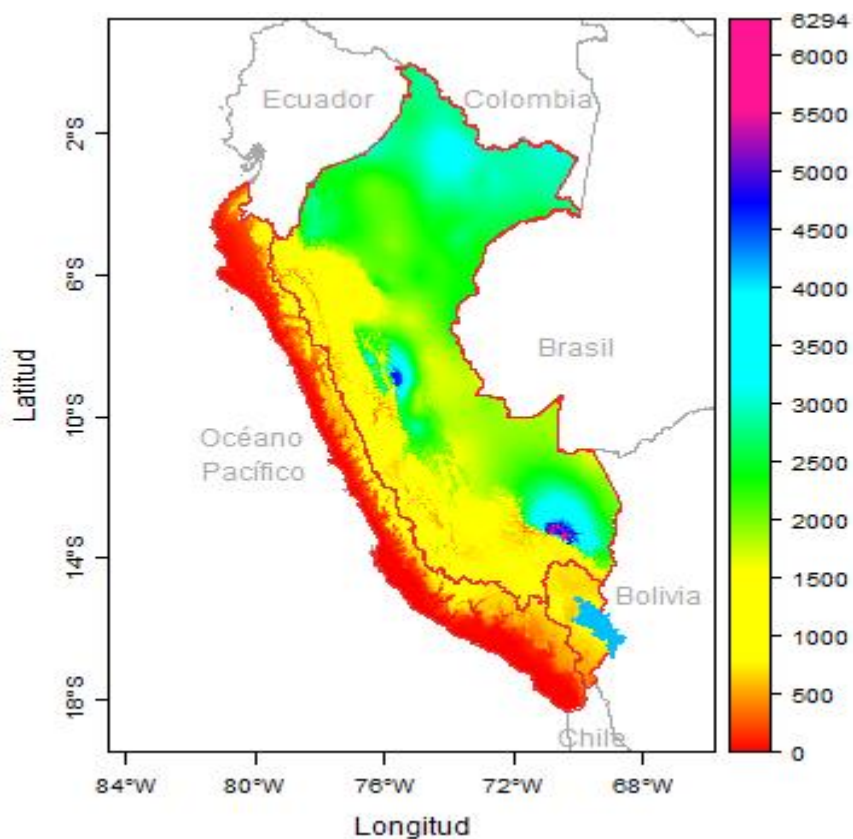
Este clima corresponde a las llanuras amazónicas peruanas y se caracterizan por presentar precipitaciones promedios anuales de 2000 mm y temperaturas de 25 °C a más, sin cambio térmico invernal bien definido. El área se encuentra bajo la influencia de este tipo climático y comprende alrededor de 43,0% de la superficie territorial del país.

En conclusión, la presencia de los Andes y el Altiplano divide a los sistemas de drenaje en tres cuencas: la del Pacífico, el Lago Titicaca y Amazonas (Atlántico) (Figura 6). De acuerdo con un informe de la UNESCO, (2006), la distribución media anual de balance de agua (escorrentía) para el período 1969 a 1999, calculado como la diferencia entre la precipitación y la evapotranspiración es 16,4 mm en la vertiente del Pacífico, 129.8 mm en la cuenca del Lago Titicaca y 2696.5 mm en la vertiente amazónica. Por lo tanto, la escorrentía estimada por la UNESCO, (2006) está en oposición a la distribución de la población de Perú, donde se encuentran las mayores ciudades (Lima, Arequipa y Piura) en la vertiente del Pacífico.

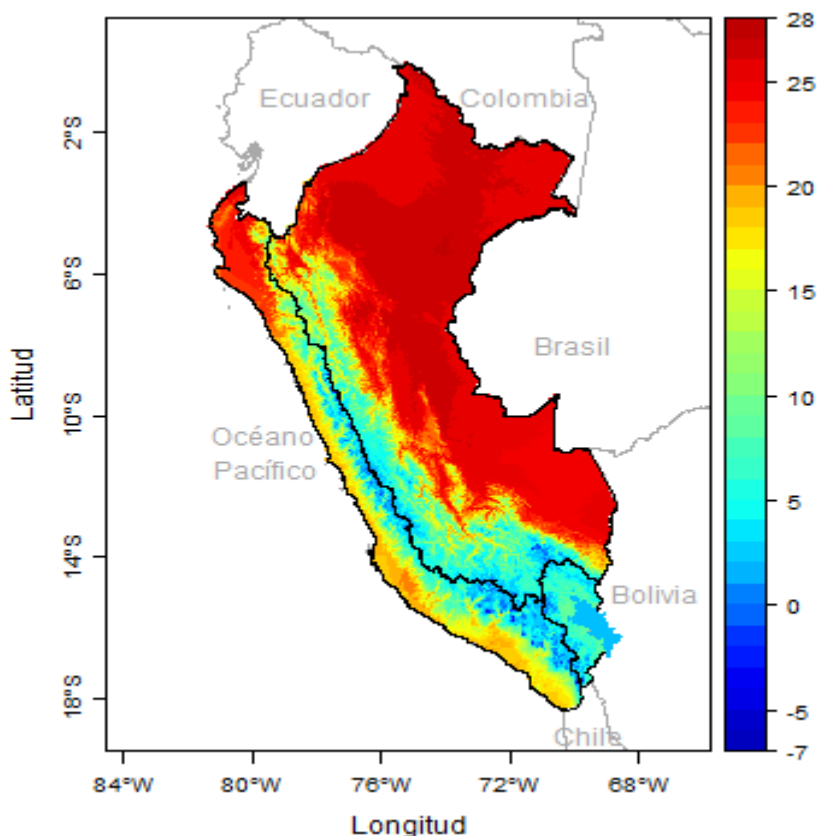
En la Figura 7 y Figura 8 se muestra la caracterización espacial de los patrones espaciales de la climatología de la precipitación anual y temperatura media de acuerdo a los datos globales de clima (WorldClim – Global Climate Data, Hijmans et al., 2005), donde WorldClim es un conjunto de datos climáticos globales grillados a una resolución espacial de aproximadamente de 1 kilómetro cuadrado correspondiente al periodo 1950 – 2000, con las limitaciones de que esta base de datos tiene incertidumbre en áreas de montaña como los Andes Peruanos debido que para su generación fueron utilizadas limitada cantidad de estaciones a nivel del Perú. Sin embargo como una primera aproximación de los patrones espaciales de precipitación y temperatura nos permite caracterizar y conocer la variabilidad espacial de estas variables en el Perú. Así altas tasas de precipitación media anual (> 1500 mm) se tiene en la vertiente de la Amazonía donde se aprecia también las regiones de extrema precipitación (denominados hotspot, Espinoza et al., 2015) lo cual es el caso donde está ubicado las estaciones pluviométricas de Quincemil y San Gabán (70.75° W, 13.22° S). Las tasas aproximadamente entre 400 a 1500 se tienen a lo largo de la cordillera de los Andes y las tasas más bajas de precipitación media anual se tienen a lo largo de la costa peruana.



**Figura 6:** Modelo digital de elevación (DEM en m.s.n.m.) y los tres sistemas de drenaje de cuencas: la del Pacífico, el Lago Titicaca y Amazonas (Atlántico).



**Figura 7:** Climatología de la precipitación media anual [mm] del periodo 1950-2000 (Hijmans et al., 2005).



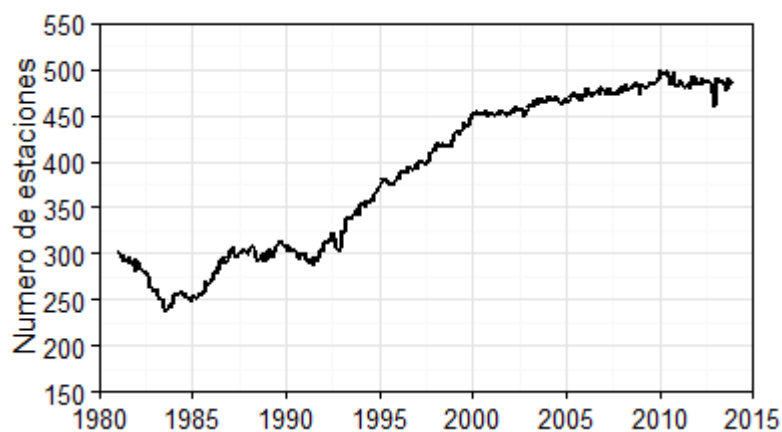
**Figura 8:** Climatología de la temperatura media anual [°C] del periodo 1950-2000 (Hijmans et al., 2005).

## 4.2 Información utilizada

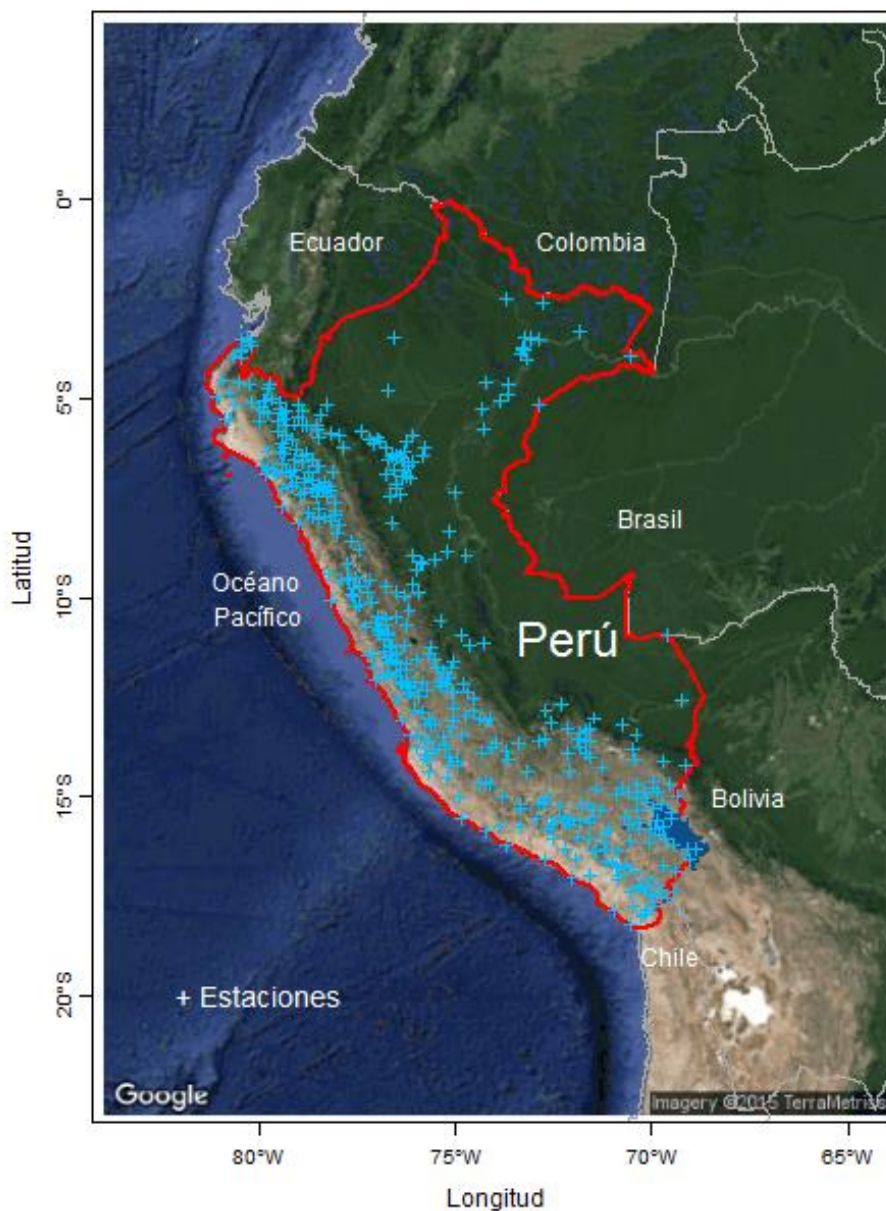
Para la generación de PISCO – precipitación se utilizaron datos que consistieron en: i) una base de precipitación pluviométrica de todo el Perú y ii) datos de precipitación estimada por satélite del producto CHIRPS a escala mensual.

### 4.2.1 Precipitación mensual pluviométrica periodo 1981 -2013

Los datos de precipitación pluviométrica mensual (observados) fueron obtenidos del Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI). Los datos comprenden solo la variable precipitación en el periodo enero de 1981 hasta diciembre de 2013. La distribución espacial de las estaciones analizadas (529 estaciones) es mostrada en la Figura 10. Las estaciones no se encuentran completamente distribuidas en todo el territorio, donde se observa que la mayor densidad de las estaciones se encuentra en la vertiente del Pacífico y a lo largo de los Andes, mientras tanto esto se observa baja densidad de estaciones en selva peruana. Otra de las características de las estaciones es también muchas de ellas han sufrido diversos cambios en su operatividad, es decir, el número de estaciones de servicio han cambiado a lo largo de los años (Figura 9). De acuerdo a la Figura 9 se aprecia un incremento de estaciones a partir de 1984, con una leve disminución en 1992 para luego seguir incrementado hasta llegar a un valor constante (480 estaciones aproximadamente) desde 2007.



**Figura 9:** Número de estaciones con dato disponibles por mes de la base original de datos de precipitación



**Figura 10:** Distribución espacial de las estaciones utilizadas



#### 4.2.2 Precipitación mensual estimada por satélite – CHIRPS

El producto CHIRPS (Climate Hazards Group InfraRed Precipitation with Stations) desarrollado por la USGS (U.S. Geological Survey) y el grupo de riesgos climáticos de la universidad de California, Santa Bárbara es un producto nuevo puesto a la disposición desde 2014. En una primera etapa se genera el producto de la precipitación llamado CHIRP (Climate Hazards Group InfraRed Precipitation); combinando datos de la climatología global de la precipitación (0.05° de resolución), observaciones del satélite geoestacionario infrarrojo (IR) calibrados con datos de TRMM 3B42 y los campos de las precipitaciones del modelo atmosférico de la NOAA-CFSv2 (Climate Forecast System version 2), en un segundo procedimiento, combinando el CHIRP con la precipitación observada in situ se genera el producto CHIRPS a una resolución espacial de 0.05° cubriendo 50°S-50°N y resolución temporal mínima de diario que está disponible desde 1981. Descripción detallada del algoritmo se encuentra en Peterson et al., (2013) y Funk et al., (2014).

El producto de precipitación mensual estimada por satélite del producto CHIRPS se ha utilizado como la variable predictor para estimar la precipitación mensual del producto PISCO.

#### 4.2.3 De las herramientas de análisis

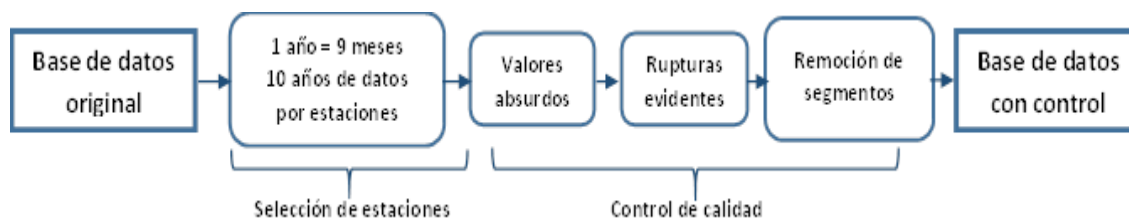
Para el procesamiento de los datos espaciales se utilizaron:

- Programa R, para sistematizar la interpolación; es un lenguaje y entorno de programación para el análisis estadístico y gráfico de libre distribución. Se utilizó principalmente el paquete Gstat, que es un paquete para el modelado geoestadístico espacial y espacio-temporal, la predicción y simulación (Pebesma, 2004).

### 4.3 Metodología

#### 4.3.1 Control de calidad de los datos de precipitación

En esta sección se describe la metodología empleada para el control de calidad de los datos de precipitación mensual para identificar los diferentes errores en el registro. El esquema de la metodología se aprecia en la Figura 11.



**Figura 11:** Metodología empleada para el control de calidad de datos mensuales de precipitación en la investigación

Antes de iniciar el proceso de control de datos fue necesario establecer un mínimo de registro de datos para las series temporales, debido a la obligación de usar la máxima cantidad de datos (tanto a escala temporal como espacial) para el proceso

de interpolación. Se estableció que un mínimo de 10 años de datos (con al menos 9 datos mensuales por año) sea considerado como una serie larga.

Las estaciones que fueron posteriormente seleccionadas pasaron por el filtro de control de calidad. Cada dato de precipitación mensual ha sido cuidadosamente examinado, especialmente, para encontrar valores absurdos de precipitación (valores irreales) y rupturas (en las series temporales) por inspección visual. Algunas estaciones presentaron segmentos inconsistentes en sus series temporales de precipitación, debido a que este problema está más relacionado al análisis de homogeneidad, no se realizó ninguna corrección de los datos de precipitación mensual. A pesar de eso, se decidió eliminar tales segmentos ya que incrementaría el error en el proceso de interpolación. Esta remoción así como los demás procesos del control de calidad fueron realizados usando datos de estaciones vecinas.

#### **4.3.2 Evaluación y validación de los datos de CHIRPS**

Debido a que la precipitación estimada por satélite está sujeta a diversos errores, es necesario caracterizarlos. Hay diferentes enfoques para caracterizar los errores de estimación de las precipitaciones. Quintero et al., (2012) indican dos categorías: (i) métodos que analizan por separado los diferentes fuentes de error y su interacción (Berenguer and Zawadzki, 2008; Germann et al., 2009) y (ii) métodos basados en la comparación con una “precipitación de referencia” para inferir las características de los errores. El primer enfoque proporciona más información acerca de los propios errores, pero requiere el estudio de la interacción entre las fuentes error para obtener la estimación del error total. El segundo enfoque proporciona una estimación directa de los errores, pero también es afectada por los errores en la precipitación de referencia.

En este estudio la evaluación se basa en la comparación de precipitación mensual estimada por satélite (CHIRPS) con una “precipitación de referencia” que es la información de pluviómetros. La comparación se realiza de punto (precipitación pluviométrica) a pixel (CHIRPS) para el periodo de 1981 a 2013. Donde para evaluar y tener una visión más detallada del error acudimos a las medidas estadísticas para variables continuas como el coeficiente de correlación ( $r$ ) para cuantificar el grado de dependencia y el bias para cuantificar si el producto de satélite sobrestima u subestima la precipitación mensual.

#### **4.3.3 Combinación entre precipitación pluviométrica y CHIRPS a través de Kriging con Deriva Externa**

Considerando que el sensoramiento remoto es una de las formas de obtener mejor información de los patrones espaciales de la precipitación y que los registros de precipitación observada son medidas precisas de precipitación; Nosotros aprovechamos estos beneficios mutuos para realizar la combinación de los dos tipos de información mediante la técnica de interpolación geoestadística denominado Kriging con Deriva Externa (KED) y así obtener el producto denominado PISCO-precipitación. Donde KED es un método que permite la incorporación de una variable externa que es linealmente correlacionada a la variable predictada (Webster and Oliver, 2007).

Una complicación en la aplicación de KED en el presente estudio fue que los datos de precipitación observada (PO) no cumplieron con la asunción de la estacionariedad de segundo orden (distribución gaussiana), donde esta asunción generalmente no se cumple en variables como la precipitación debido que estos datos presentan asimetría o sesgos positivos y muestran largas variancias en áreas de alta versus baja precipitación. Como parcial solución para cumplir con la asunción nosotros transformamos por logaritmos a los datos de precipitación observada y de satélite con la finalidad de estabilizar las variancias de acuerdo a Oliver and Webster, (2014). Luego aplicamos KED en el espacio transformado y finalmente los resultados obtenidos de KED re transformamos para obtener el producto de precipitación corregida (PISCO – Precipitación).

En nuestra aplicación de KED para cada precipitación mensual, la deriva o tendencia está dado por la precipitación estimada por satélite CHIRPS. Donde la manera como se introduce la variable auxiliar en el procedimiento de predicción de KED es descrita en el siguiente procedimiento.

- Se realiza una regresión lineal basado en *mínimos cuadrados ordinarios* (MCO) entre CHIRPS versus PO para los estaciones disponibles en un mes específico y luego se estima la deriva en función a la ecuación de la regresión sobre una grilla regular de 5 kilómetros (resolución espacial de CHIRPS)
- Los residuales son obtenidos en cada ubicación de las estaciones terrenas (lo cual es la diferencia entre la cantidad de precipitación observada – PO y la estimada por la regresión)
- Se modeliza el semivariograma para los residuales y un modelo teórico es ajustada.
- Se evalúa el método de combinación (KED) y finalmente se estima la precipitación corregida en las grillas de CHIRPS.

KED como otros métodos geoestadísticos utiliza los semivariogramas como una herramienta para caracterizar la dependencia espacial en las variables de interés (Ly et al., 2011). Por la cual el modelamiento de semivariogramas es muy importante. La manera de ajustar modelos teóricos de semivariograma al semivariograma experimental se realiza a través de procedimientos manuales (Nalder and Wein, 1998 and Haberlandt, 2007); sin embargo este procedimiento no es un enfoque apropiado porque esto depende de la habilidad del modelador en este campo, además que el procedimiento manual no es tan viable para trabajar con muchos datos espaciotemporales.

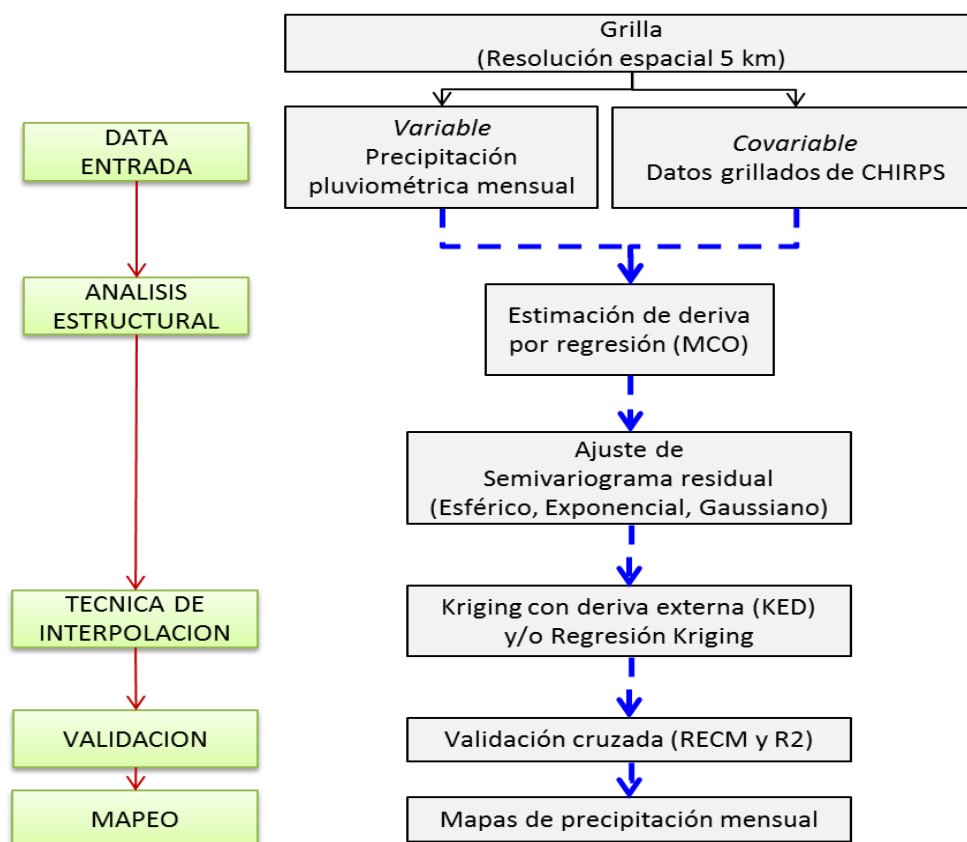
Así, en este estudio realizamos un procedimiento automatizado para ajustar el mejor modelo teórico al semivariograma experimental de acuerdo a Oliver and Webster, (2014), evaluándose para ello tres modelos teóricos (exponencial, esférico, y gaussiano) los cuales son los más utilizados para modelizar la dependencia espacial de la variable precipitación. Para este propósito construimos el semivariograma experimental estableciendo un retraso (Lag) o intervalos de distancias a 15 km para todos los meses, luego el ajuste por cada modelo teórico para cada mes es llevada a cabo utilizando la aproximación de *mínimos cuadrados ponderados* (weighted least squares approximation) (Cressie, 1985; McBratney and Webster, 1986) y luego seleccionamos como el mejor modelo teórico aquello que

presenta el valor más bajo del estadístico denominado *sumas de cuadrados residuales* (Residual Sum of Squares - RSS). Finalmente los coeficientes del mejor modelo teórico (efecto pepita–nugget, meseta–partial sill, y rango–range) fueron utilizados en el procedimiento de KED para estimar los valores en sitios sin medición.

Adicionalmente, a través de la validación cruzada dejando uno (LOOCV) se ha realizado una comparación de la eficiencia de KED frente al método IDW. Con la finalidad de conocer el valor añadido por el variable predictor CHIRPS en la caracterización espacial de la precipitación mensual. Para ello a partir de la validación cruzada se han estimado las medidas de precisión como la medida de eficiencia el coeficiente de NASH para conocer la capacidad de cada técnica en explicar la variabilidad de los datos espaciales.

Finalmente se genera mapas de precipitación mensual para el territorio peruano y los correspondientes mapas de confiabilidad, esta última es en base al rango o radio de influencia de las estaciones caracterizado por el rango con alta dependencia espacial del semivariograma de cada mes.

A continuación en la Figura 12 se muestra el esquema metodológico de manera resumida de la combinación entre precipitación pluviométrica y CHIRPS a través de Kriging con Deriva Externa realizada en este estudio.

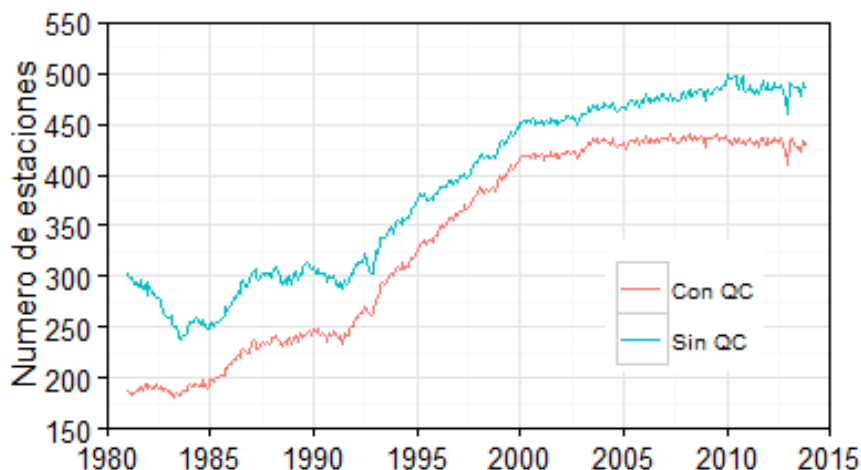


**Figura 12:** Diagrama de flujo de la metodología para la interpolación espacial.

## V. RESULTADOS

### 5.1 Control de calidad de los datos de precipitación

Luego del control de calidad, la base de datos original se redujo de 529 a 448 estaciones así como también disminuyó la cantidad de estaciones disponibles en el tiempo siendo la menor disposición de estaciones en los primeros años (180 estaciones) (Figura 13).



**Figura 13:** Número de estaciones por mes de la base original (línea azul) y de la base con control de calidad (línea roja)

Las estaciones con series temporales más largas prácticamente se encuentran distribuidas en toda el área del país, pero principalmente se encuentran dentro de la región de los Andes (Figura 14a y Figura 14b); solo muy pocas estaciones tienen menos de 10 años de datos. Los mayores valores de precipitación se dan generalmente en la vertiente del Atlántico (superando los 4000 mm) y los menores valores (valores menor a 50mm) en casi toda la costa del Perú (Figura 14c)

### 5.2 Evaluación y validación de los datos de CHIRPS

Antes del proceso de interpolación fue necesario evaluar cuan bueno es el CHIRPS estimando los valores de precipitación mensual. Para tal razón se realizó la validación usando los siguientes estadísticos: coeficiente de correlación de Pearson y el bias.

Los resultados del proceso de validación se dividen en dos puntos (Figura 15 y Figura 16), el primero de estos se basa en el análisis de toda la serie temporal diferenciando por periodos lluviosos (meses de octubre, noviembre, diciembre, enero, febrero y marzo) y periodos secos (meses de abril, mayo, junio, julio, agosto y setiembre). El otro punto se enfocó en analizar la validación según el periodo de registro, estos periodos corresponden a 1981 – 1998 y 1999 y 2013.

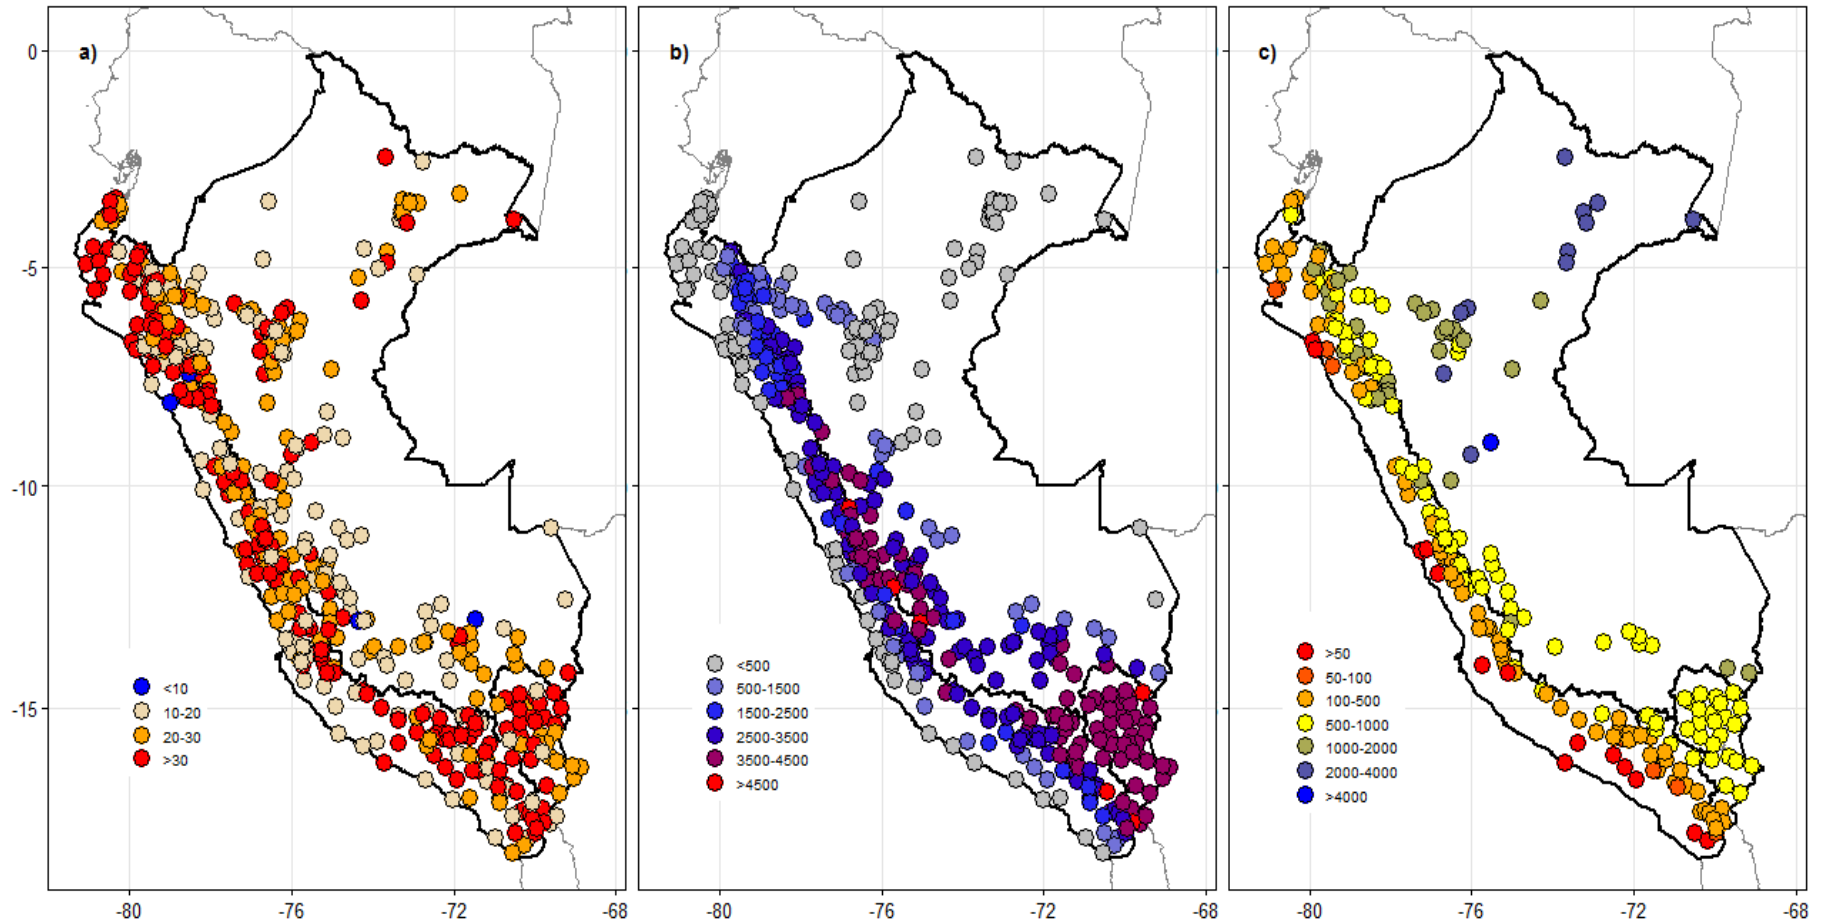


Figura 14: Distribución espacial de la cantidad de datos (a), altitud (b) y precipitación promedio mensual (c) luego del control de calidad de dato

### Validación según periodos secos y húmedos:

De acuerdo a la Figura 15 **Error! No se encuentra el origen de la referencia.abc**, se aprecia prácticamente que todas las estaciones presentan una correlación significativa positiva con los datos del CHIRPS en toda la serie histórica y en el periodo lluvioso. La cantidad de estaciones que presentan correlación significativa positiva disminuyen en el periodo seco. Las estaciones que no presentan correlación fueron aquellas posicionadas en el territorio costero del país. Por otro lado, el error del CHIRPS con respecto al valor observado (Figura 15def) presentan en todos los periodos sobreestimación (subestimaciones) al sur (norte) del país. Ligeras subestimaciones y sobreestimaciones se presentaron al centro del país. Menos del 50% de error se presentó en la cuenca del lago Titicaca. Los mayores errores se dieron en el periodo seco que en el periodo lluvioso y en toda la serie.

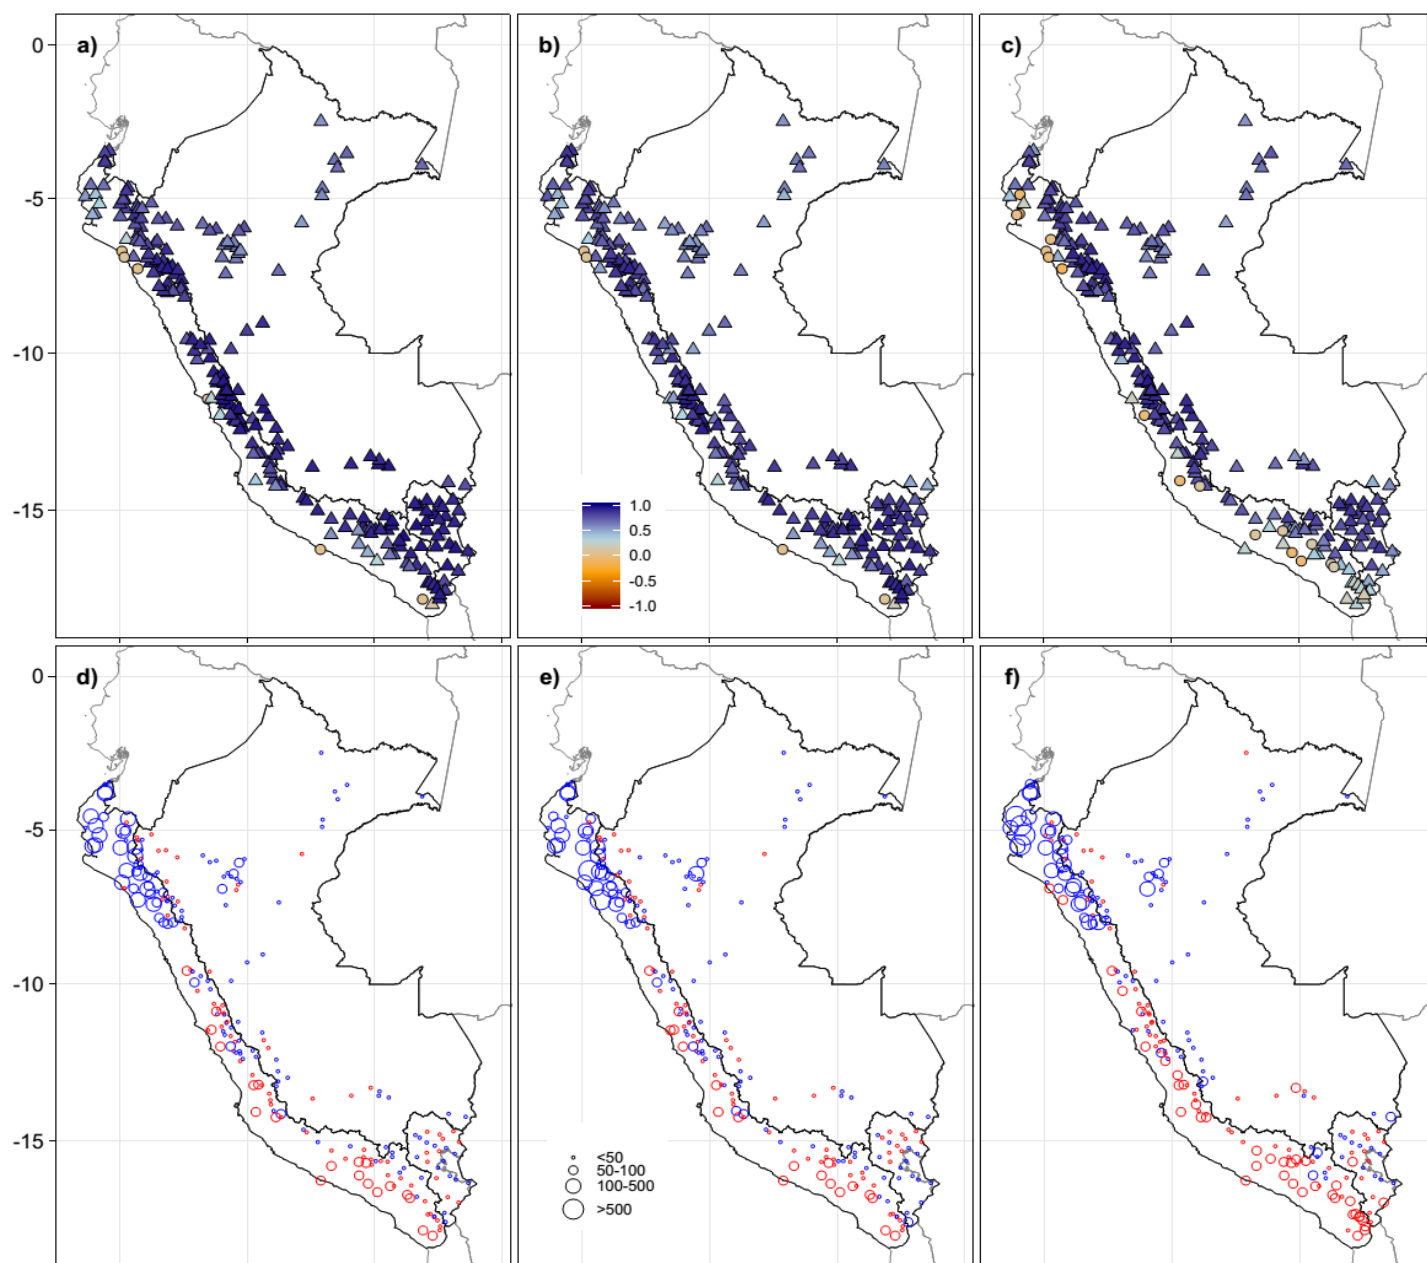
Estos resultados evidencian que el CHIRPS detecta la variabilidad de la precipitación mensual en casi todas las estaciones del país, pero con subestimaciones y sobreestimaciones que se aprecian claramente en la vertiente del pacífico cerca a la costa. La exactitud de estimación del CHIRPS depende a su vez del periodo hidrológico, menor estimación de precipitación se da en el periodo seco que en el periodo lluvioso. Por lo tanto se hace necesario ajustar el CHIRPS para su uso en el territorio peruano.

### Validación según periodos de mayor y menor registro de datos:

Se dividió la serie temporal observada y CHIRPS en periodos de 1981 – 1997 y 1998 – 2013 para comparar los resultados de validación diferenciando periodos de registro. Esto con énfasis en contrastar con otros productos satelitales como el TRMM que inicia a partir del año 1998.

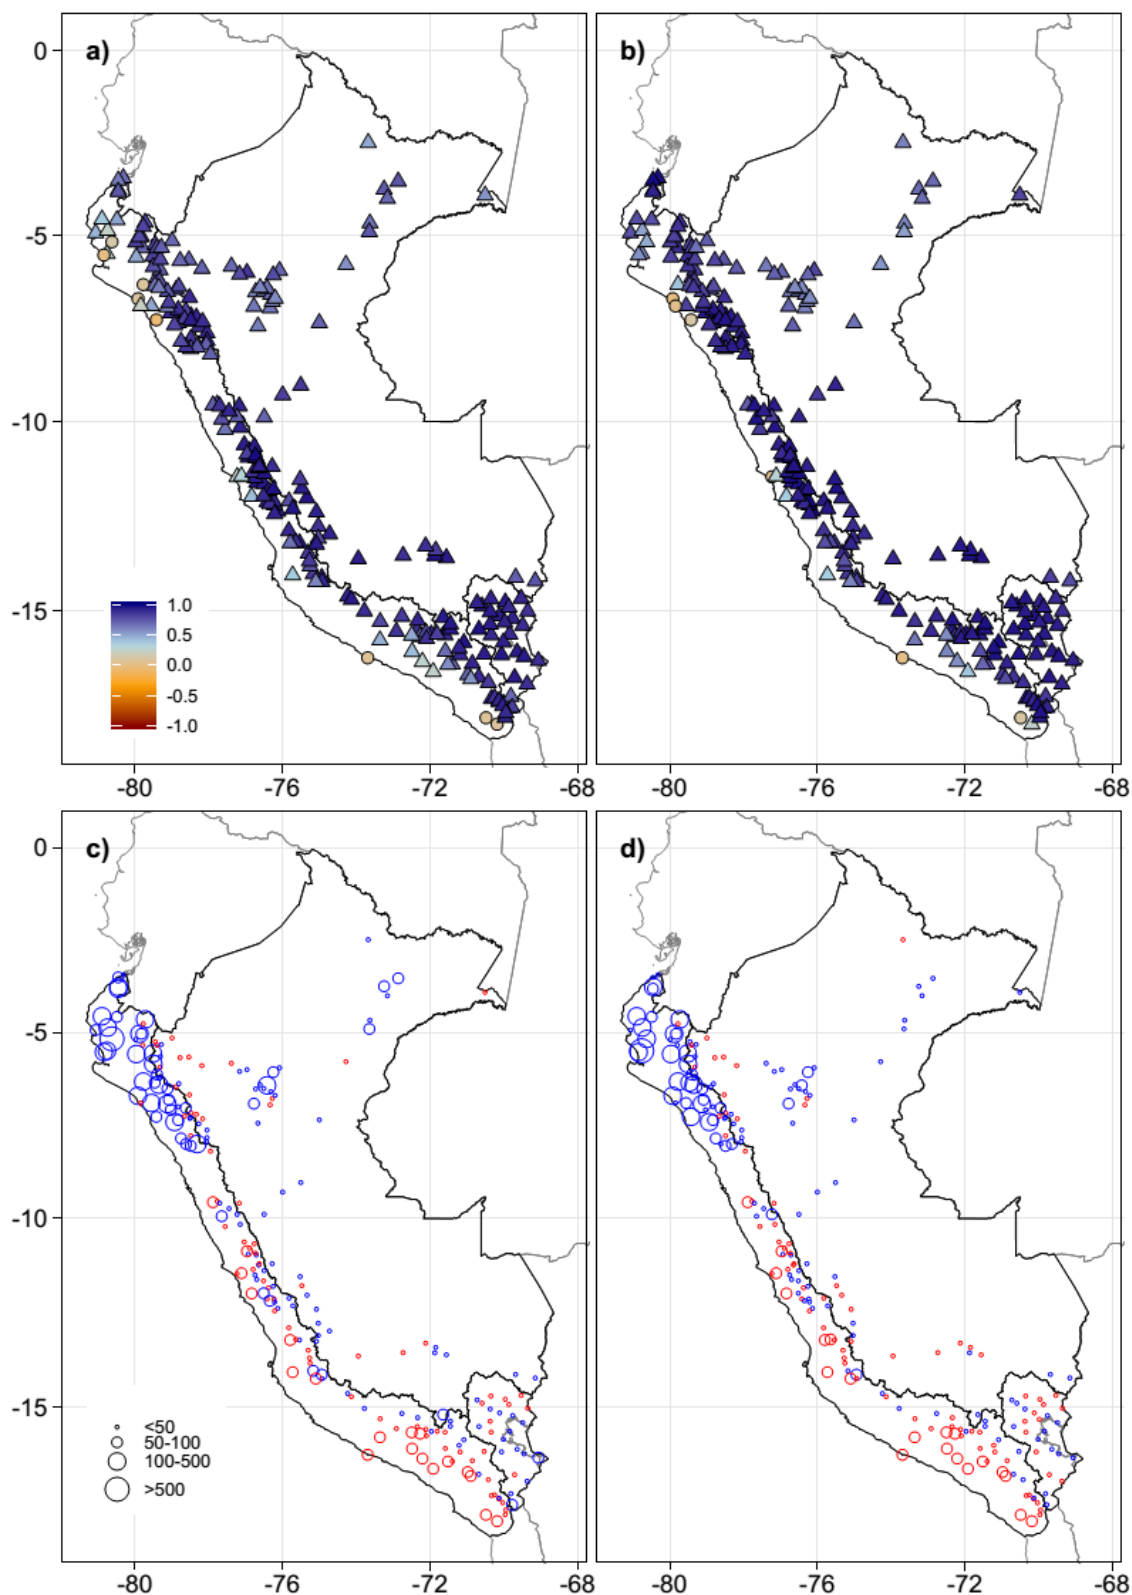
Los dos periodos (Figura 16ab) presentaron gran cantidad de estaciones con alta correlación significativa y al igual que en la anterior sección solo algunas estaciones ubicadas en la parte costa no presentaron un semejante comportamiento. Se debe resaltar que en el periodo 1981 – 1998, se encontró una menor detección de la variabilidad por parte del CHIRPS debido a una mayor cantidad de estaciones sin relación significativa. A pesar de la disminución de la estimación de la variabilidad de la precipitación observada en 1981 – 1998, los errores (Figura 16 **Error! No se encuentra el origen de la referencia.cd**) tienden a ser completamente iguales. No se ve una clara señal de mayor (o menor) sobreestimación y subestimación en los dos periodos analizados. Ambos periodos tuvieron sobreestimación (subestimación) al sur (norte) de la vertiente del pacífico en estaciones cercanas a la costa. La parte central de la vertiente del pacífico y del Lago Titicaca presentó una mayor cantidad de subestimaciones y la menor cantidad de errores respectivamente. Solo al norte de la vertiente del Atlántico se aprecia una disminución de los errores en 1999 – 2013.

De la validación se infiere entonces que el CHIRPS estima prácticamente la variabilidad de precipitación de todo el Perú, solo algunos errores se presenta en aquellas estaciones ubicadas en la costa. Los valores estimados no son tan exactos ya que se evidenció altos porcentajes de sobrestimaciones (subestimaciones) al sur (norte) de la vertiente del pacífico. Estos resultados varían dependiendo del periodo hidrológico y temporal.



**Figura 15:** Distribución espacial de la correlación (1ra fila) y el bias en porcentaje (2da fila) entre la precipitación mensual observada y CHIRPS. Validación en toda la serie de tiempo del periodo 1981-2013 (a y d), periodo lluvioso [Oct-Mar] (b y e) y el periodo seco [Abr-Set] (c y f). En el mapa de correlación, los triángulos corresponden a correlaciones significativas y en el mapa de bias, círculos rojos (azules) corresponden a sobreestimación (subestimación)



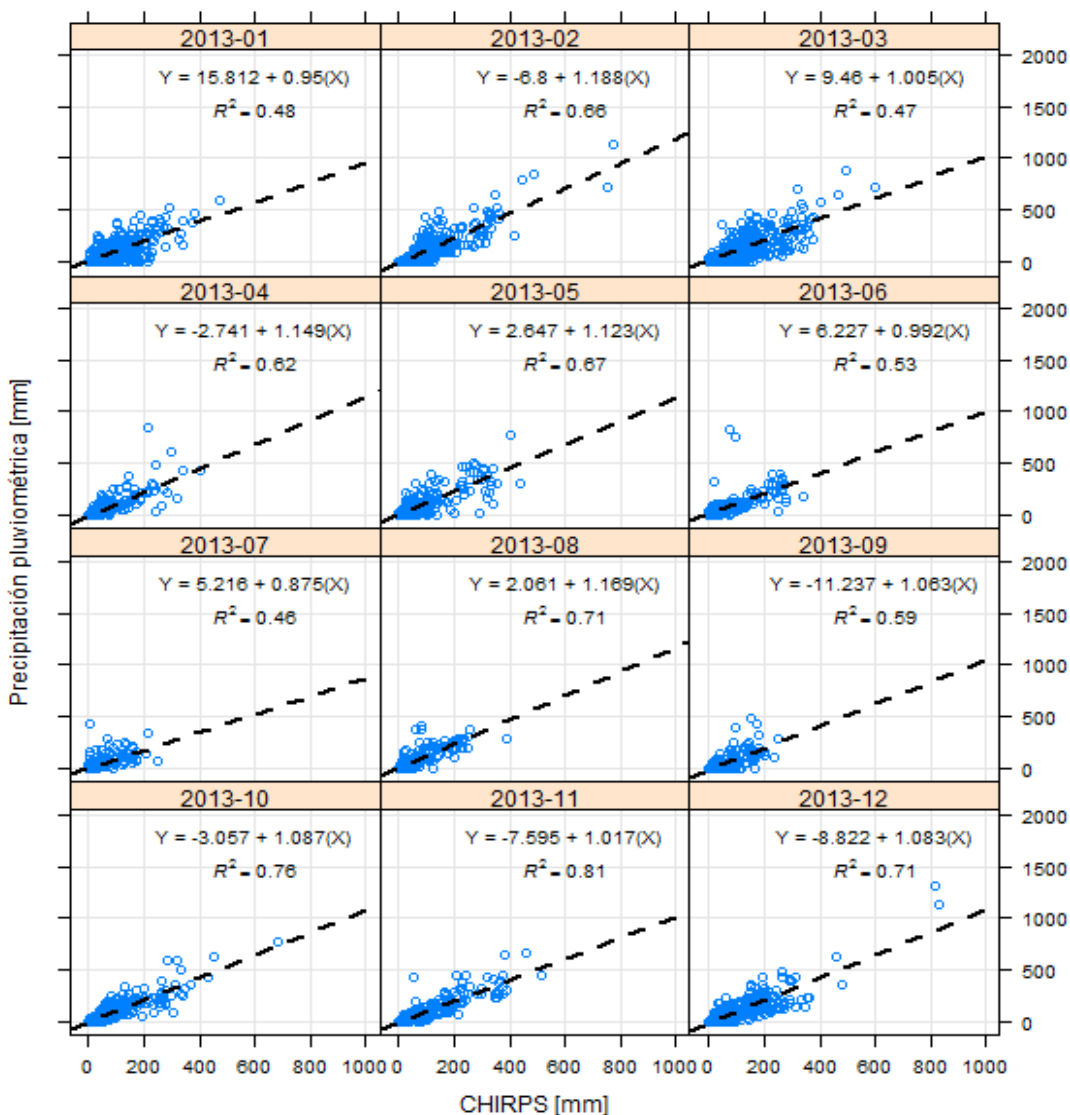


**Figura 16:** Similar a la Figura 15 pero validación en el periodo 1981 – 1998 (a y c) y en el periodo 1999 – 2013 (b y d)

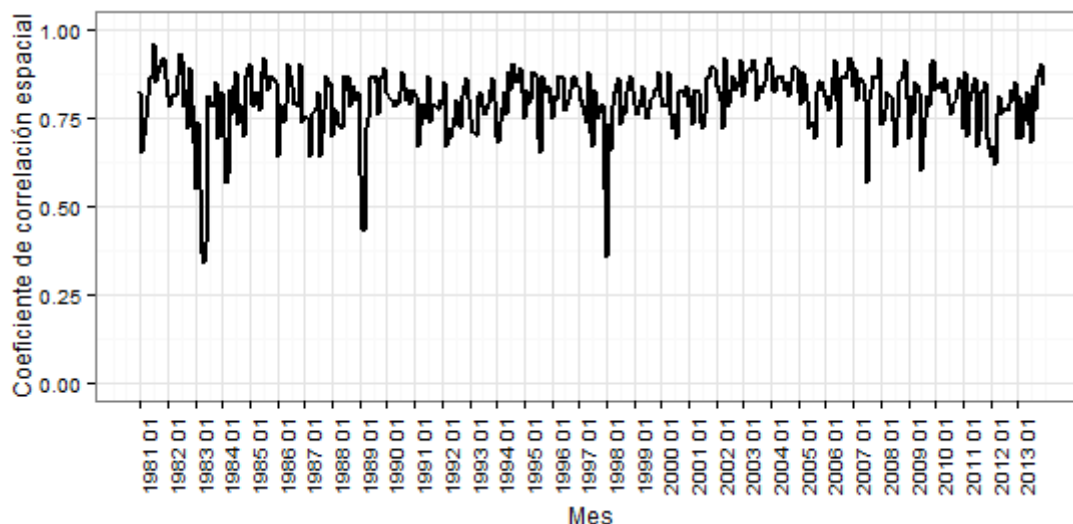
### 5.3 Combinación entre precipitación pluviométrica y CHIRPS a través de Kriging con Deriva Externa

#### 5.3.1 Relación de precipitación versus CHIRPS

Se ha determinado la correlación espacial entre la precipitación pluviométrica mensual versus la precipitación estimada por satélite CHIRPS para cada mes analizado y en este estudio se muestra esta relación a manera de ejemplo (Figura 17) para los meses del año 2013, donde se puede apreciar los respectivos valores de correlación y ecuación de relación lineal entre estas variables. Asimismo en la Figura 18 se muestra la correlación espacial para todos los meses donde claramente se tiene buenos valores de coeficiente de correlación espacial (promedio 0.8) y con excepción que en algunos años como 1983 y 1998 se encuentran valores de correlación menores a 0.5, el cual nos indica que en los meses de estos dos años el producto CHIRPS no es eficiente para caracterizar la variabilidad espacial de la precipitación pluviométrica.



**Figura 17:** Gráfica de relación de precipitación pluviométrica mensual versus precipitación estimada por satélite CHIRPS para los meses de año 2013



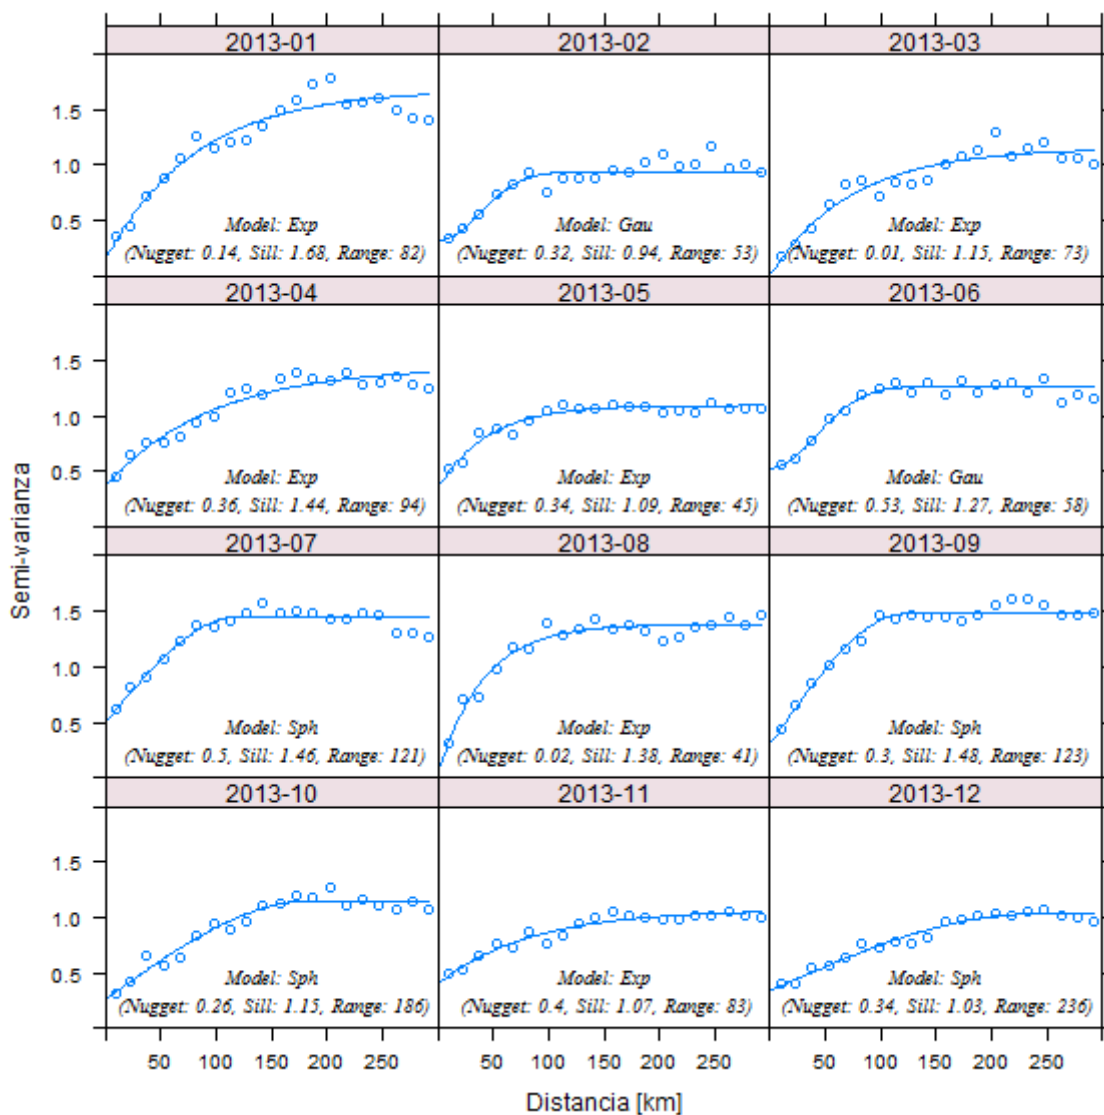
**Figura 18:** Gráfica de relación de precipitación pluviométrica mensual versus precipitación estimada por satélite CHIRPS para el periodo de análisis

### 5.3.2 Análisis estructural

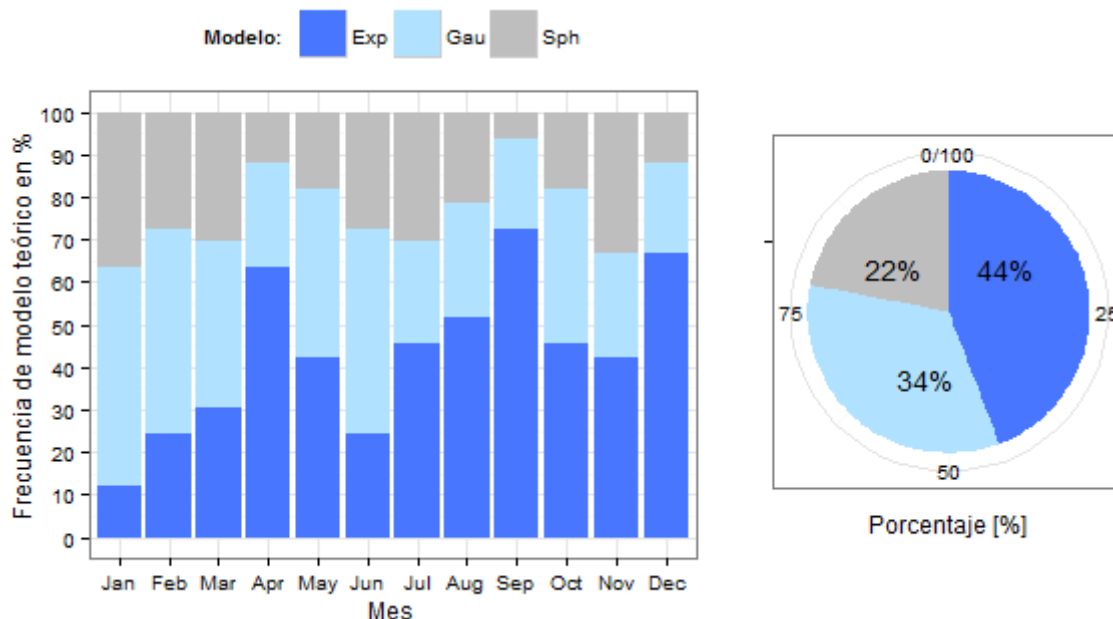
La principal etapa para la interpolación de datos a través de técnicas geoestadísticas y en este caso particular de KED es el modelamiento de semivariogramas residuales de la deriva (deriva es la fracción explicada por la covariable estimada mediante una regresión lineal entre la precipitación pluviométrica y la precipitación estimada por satélite CHIRPS). Por lo que en esta sección se muestran los resultados del análisis estructural es decir el modelamiento de la dependencia espacial de la precipitación a través de los semivariogramas residuales. En la Figura 19 se muestra a manera de ejemplo el ajuste del mejor modelo teórico para cada uno de los meses del año 2013, donde claramente podemos apreciar que cada mes es ajustado independientemente por un modelo teórico, donde se observa que la semivarianza se incrementa a medida que aumenta la distancia entre estaciones, hasta un valor casi constante (meseta), a una distancia conocida como rango (variable para cada mes) de dependencia espacial. Las estaciones separadas por unas distancias menores (mayores) al rango están (no están) relacionadas espacialmente, esto significa que en la interpolación realizada en una celda no conocida, intervienen todas las estaciones vecinas que se encuentran dentro de un área de forma circular definida por el rango y asimismo los valores interpolados serán más confiables en aquellos sitios cercanos y ubicados dentro del área de influencia de las estaciones pluviométricas analizadas la cual está definida por el rango.

En la Figura 20 (izquierda) se muestra la frecuencia de los modelos de semivariogramas teóricos ajustados para cada mes en el periodo de 1981-2013, donde se puede apreciar que no existe una clara predominancia de un modelo teórico para cada mes, dándonos a conocer que el proceso físico de la variabilidad espacial de la precipitación es independiente para cada mes. Sin embargo encontramos que el modelo teórico que es más frecuente (Figura 20 derecha) en este estudio es el modelo exponencial - Exp (en 44% de los meses) seguida por el modelo Gaussiano – Gau (34%) y esférico (22%).

**Nota:** Cabe señalar que en este estudio para regionalizar la precipitación se ha trabajado con los valores de precipitación transformados por el logaritmo natural para así evitar valores negativos en la interpolación debida a la alta asimetría de los datos. Luego de la interpolación los valores estimados a escala logarítmica fueron re transformados para obtener los valores reales.



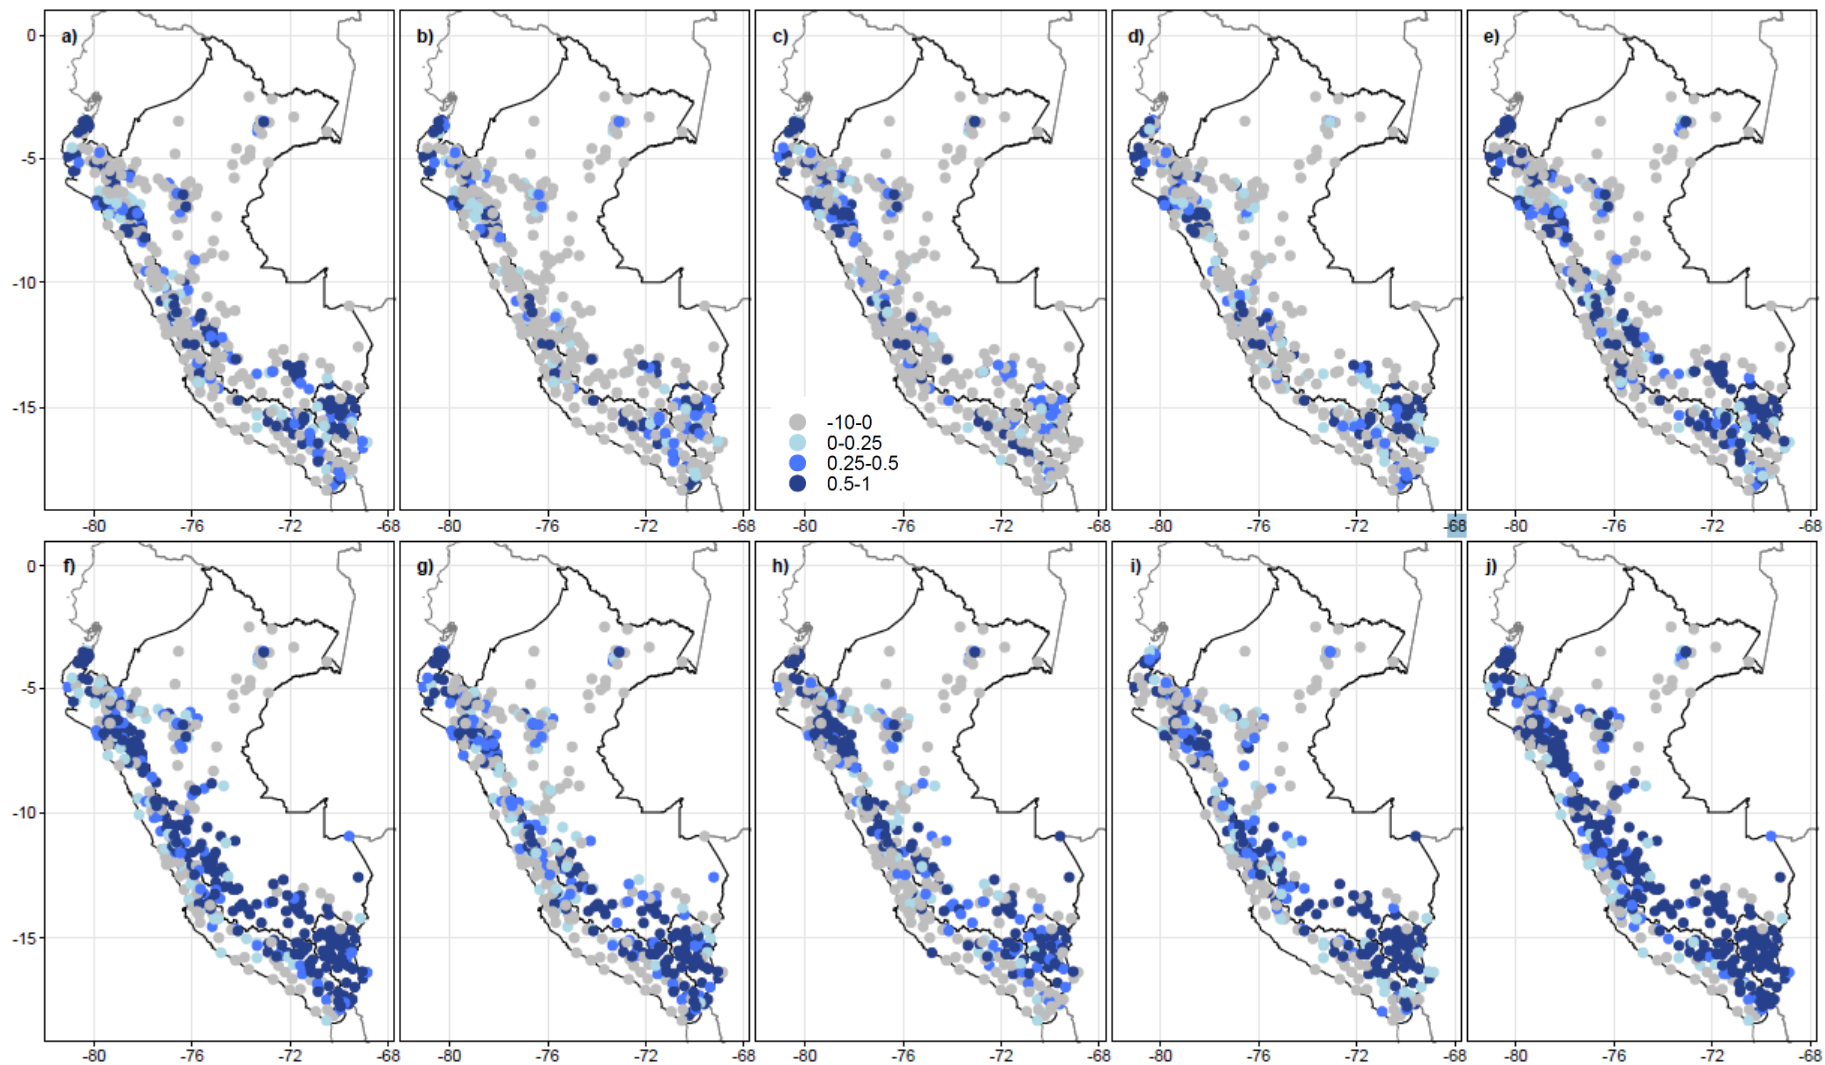
**Figura 19:** Ajuste del semivariograma residual por el mejor modelo teórico para cada mes



**Figura 20:** Izquierda, frecuencia de modelos teóricos ajustados para cada mes en el periodo de 1981-2013 y derecha, porcentaje de modelo de semivariograma teórico ajustado al semivariograma experimental de los residuales en el periodo de 1981-2013

### 5.3.3 Validación cruzada

En este capítulo se muestra el performance de cada técnica (IDW y KED) en caracterizar los datos espaciales de precipitación. Figura 21 muestra la distribución espacial de la medida estadística llamado coeficiente de NASH en el área de estudio, la cual revela que la técnica de interpolación KED que incorpora una variable auxiliar (CHIRPS) en general es más eficiente que IDW la cual es una técnica más sencilla que únicamente hace uso una variable (precipitación pluviométrica) para espacializar la precipitación. La Figura 21f muestra el coeficiente de NASH para el periodo de análisis 1981-2013 donde se aprecia que se tiene buen performance de KED ( $NASH > 0.5$ ) a lo largo de los Andes del Perú, mientras se puede apreciar bajas eficiencias ( $NASH < 0.5$ ) a los largo de la franja de la costa peruana donde las magnitudes de precipitación son muy bajas y en el norte de la Amazonía Peruana la cual es caracterizada por altas magnitudes de precipitación y baja densidad de estaciones. Los mismos patrones espaciales de la medida de eficiencia NASH se presentan para los periodos de los meses húmedos y secos siendo (Figura 21h). Mientras tanto en la Figura 21i,j claramente podemos apreciar que los valores de NASH más altos se tiene para el periodo de 1998-2013 que a comparación del periodo 1981-1997, esta diferencia de los patrones de la eficiencia en estos dos periodos es importante la cual esta probablemente relacionado a dos factores más importantes i) la densidad de estaciones en el último periodo 1998-2013 es mayor que en el periodo 1981-1997 y ii) probable influencia de los datos de precipitación satelital del producto TRMM 3B42 (disponibles desde enero 1998 en adelante) y son utilizados en la generación del producto CHIRPS ya que esta última hace uso de los valores de observaciones del satélite geostacionario infrarrojo (IR) calibrados con datos de TRMM 3B42 en la generación de CHIRPS.

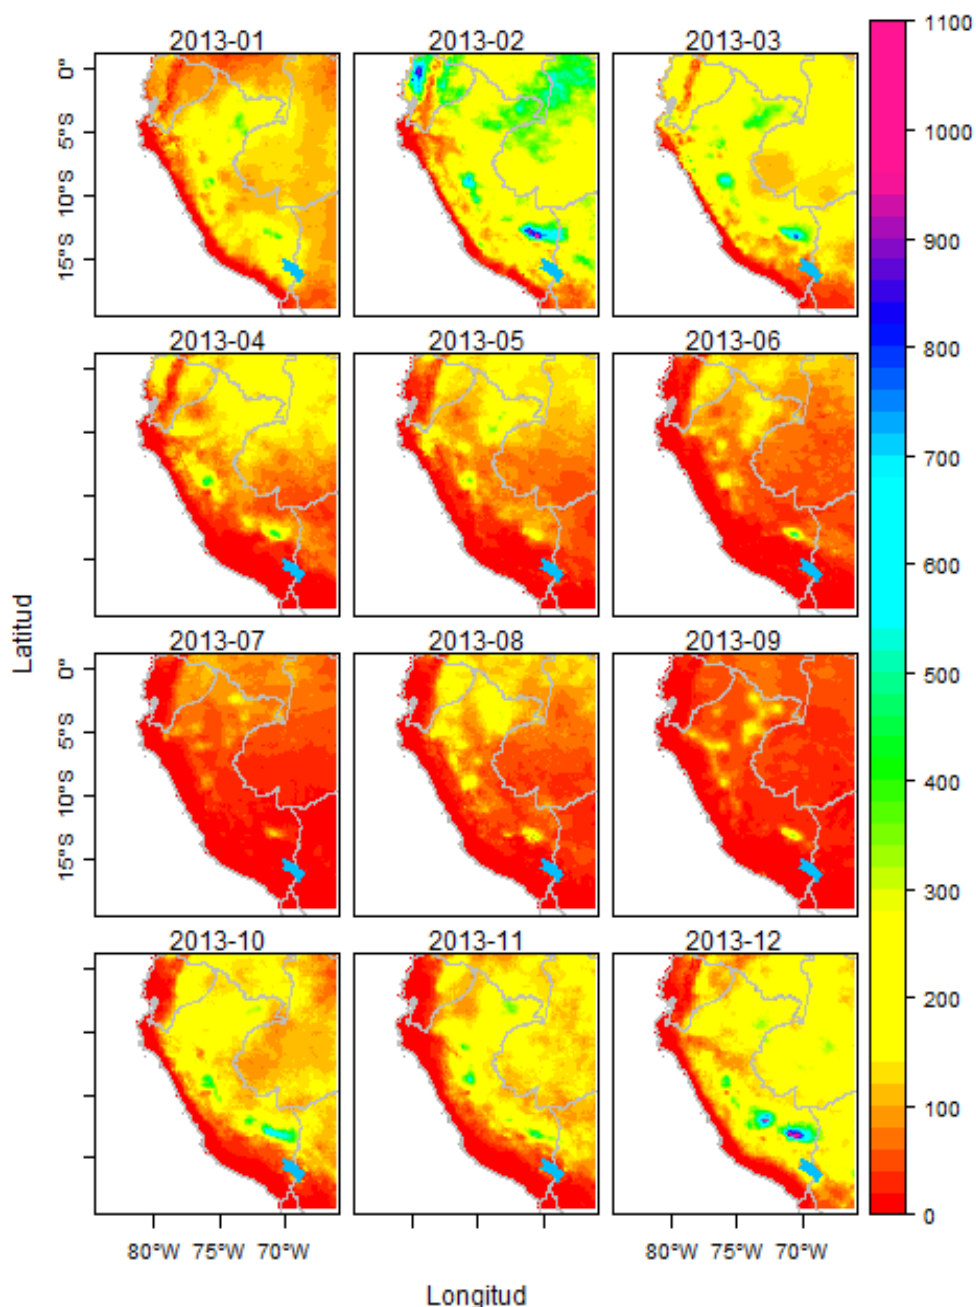


**Figura 21:** Validación cruzada dejando uno fuera (LOOCV): arriba LOOCV para IDW, abajo LOOCV para KED. NASH para a,f) toda la serie (1981-2013), b,g) periodo húmedo [Oct-Mar], c,h) periodo seco (Abr-Set), d,i) periodo 1981-1997 e,j) periodo 1998-2013

### 5.3.4 Interpolación espacial

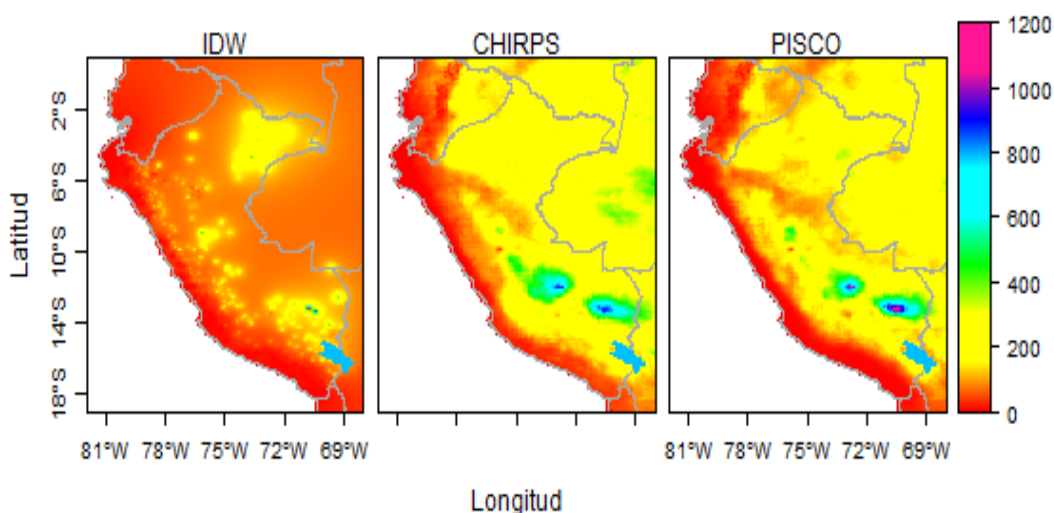
En esta sección se muestra los resultados de la combinación (“merging”) entre los datos de precipitación pluviométrica observada y CHIRPS a través de la técnica de interpolación de Kriging con Deriva Externa (KED). En la Figura 22 a manera de ejemplo se muestra los mapas de la precipitación mensual grillada denominado PISCO-Precipitación para los meses del año 2013.

La base de datos completa de precipitación mensual grillado [periodo 1981 – 2013] denominado PISCO-Precipitación esta libremente disponible para los usuarios ver la sección de introducción o conclusiones para mayor referencia.

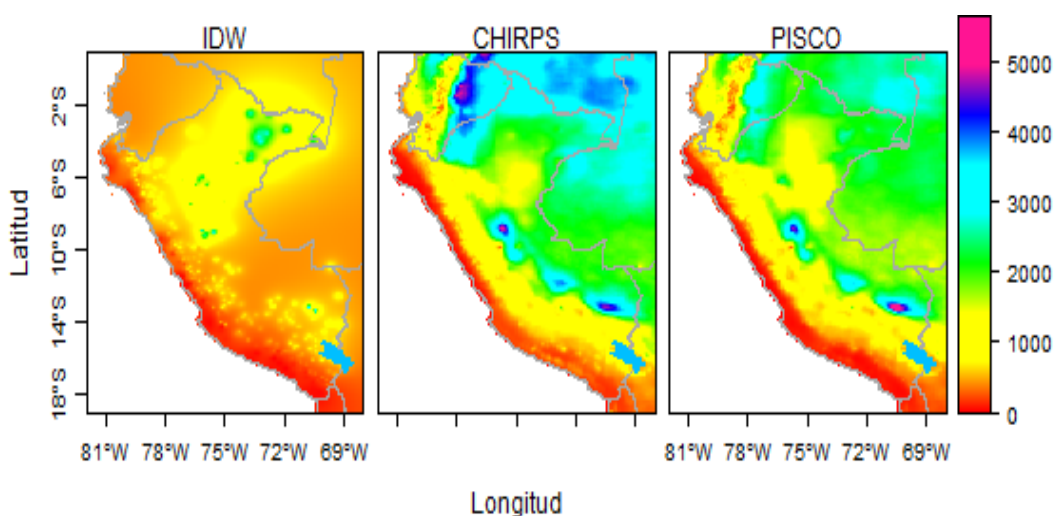


**Figura 22:** mapas de la precipitación mensual grillado (mm) por la técnica de interpolación KED (denominado producto PISCO-precipitación) para los meses del año 2013.

La Figura 23 muestra los patrones espaciales de precipitación para el mes de diciembre del 2013 para el producto CHIRPS y los datos interpolados por IDW y KED (PISCO). Esta figura nos muestra que la técnica de interpolación IDW no caracteriza la variabilidad espacial de la precipitación siendo los valores estimados confiables únicamente para los sitios de medición donde podemos apreciar que la magnitud máxima de precipitación (1200 mm) se presenta en la estación Quincemil ( $70.75^{\circ}$  W,  $13.22^{\circ}$  S) y en esta misma ubicación el producto CHIRPS subestima la precipitación observada en 25%, mientras tanto el producto pisco subestima en 8%, quiere decir que el producto PISCO corrige considerablemente los sesgos que existían entre los datos de precipitación pluviométrica y el CHIRPS, a su vez el producto PISCO recoge la información de los patrones espaciales del satélite lo cual no es vista en una técnica sencilla como es el IDW. En Figura 23 también se puede apreciar claramente que el producto CHIRPS sobrestima la magnitud de la precipitación a lo largo de la costa peruana, mientras el producto PISCO corrige esta sobrestimación. Estas características se mantienen incluso en los patrones de precipitación promedio multianual mostrado en la Figura 24.



**Figura 23:** Comparación de los patrones espaciales de la precipitación mensual grillado (mm) por la técnica de interpolación: Izquierda (IDW), medio (producto CHIRPS) derecha KED (denominado producto PISCO-precipitación) para el mes de diciembre 2013

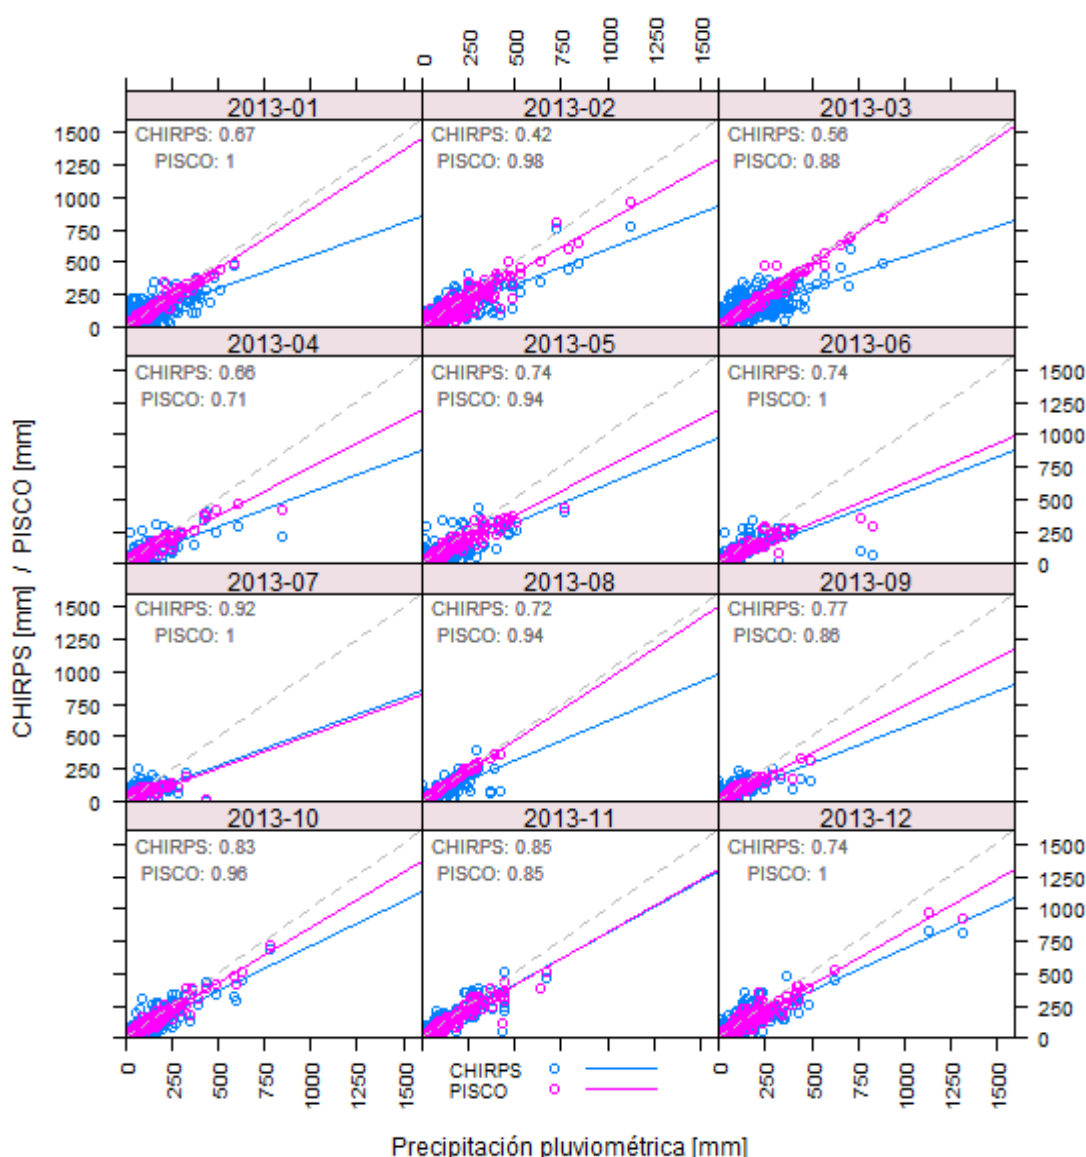


**Figura 24:** Comparación de los patrones espaciales de la precipitación promedio multianual del periodo 1981 al 2013, generado a partir de datos grillados mensuales



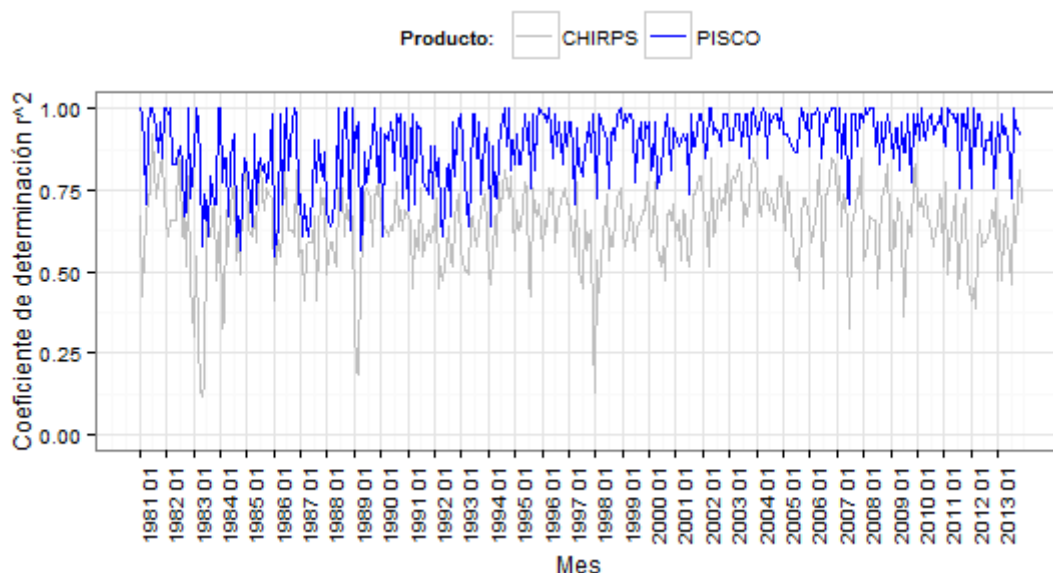
### 5.4 Evaluación de los productos grillados CHIRPS y PISCO versus datos de precipitación pluviométrica

En la Figura 25 se muestra la relación espacial y los coeficientes de determinación entre los datos grillados (CHIRPS y PISCO) versus los datos de precipitación pluviométrica para los meses del año 2013. Donde podemos apreciar claramente que el producto PISCO presenta menores sesgos con los datos observados y que la varianza explicada por PISCO es mayor en todo los meses. Estas mismas características se ha obtenido para todos los meses, así en la Figura 26 se muestra el coeficiente de determinación que nos caracteriza la varianza explicada de la variabilidad espacial de precipitación mensual por cada producto para cada mes analizado, obteniéndose claramente que el producto PISCO en cada mes analizado explica mejor la variabilidad espacial de la precipitación pluviométrica mensual.



**Figura 25:** Relación entre los productos de precipitación mensual grillado (CHIRPS y PISCO) versus los datos pluviométricos. Línea azul (rosado) muestra la relación lineal entre CHIRPS y observado (PISCO y observado), línea gris muestra la relación óptima y en cada ventana se muestra los coeficientes de determinación entre los productos grillados y observados.

Así mismo, observamos que en los meses de los años 1983, 1989, 1997 y 1998 donde el producto CHIRPS tiene baja capacidad de caracterizar la variabilidad espacial de precipitación observada (coeficiente de determinación < 0.5) fueron corregidas por PISCO (coeficiente de determinación > 0.5).



**Figura 26:** Valores de los coeficientes de determinación resultado de la relación espacial entre los productos de precipitación mensual grillado (CHIRPS y PISCO) versus los datos pluviométricos para los meses analizados (periodo 1981 – 2013).

### 5.5 Generación de mapas climáticos

Los datos grillados de precipitación mensual (PISCO) finalmente pueden ser utilizados por los usuarios de múltiples disciplinas. Como resultado de ello en la siguiente Figura 27 se muestra los mapas climáticos de precipitación para cada mes para el periodo 1981 – 2013.

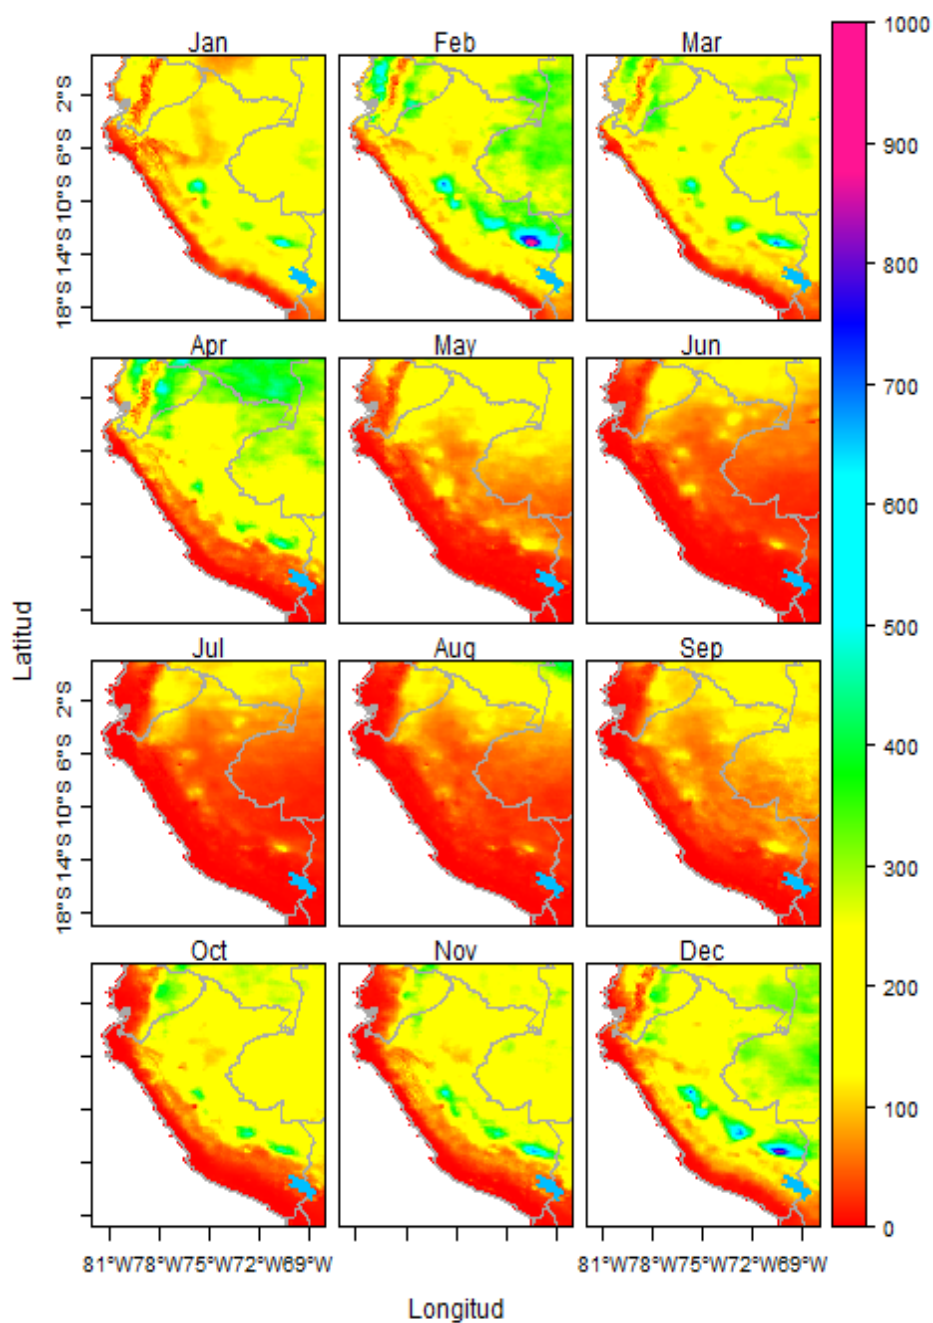


Figura 27: Mapas de climatología de precipitación en mm [1981 – 2010].

## VI. CONCLUSIONES

En base al estudio realizado se tiene las siguientes conclusiones:

- Se ha evaluado el producto de precipitación estimada por satélite (CHIRPS) con respecto a los datos de precipitación pluviométrica observada, encontrándose que la precipitación mensual del producto CHIRPS sobrestiman las magnitudes de la precipitación observada a lo largo del sur de la vertiente del pacífico (departamentos de Arequipa, Moquegua, Tacna) mientras tanto encontramos que subestima a norte de la vertiente del pacífico y en el norte de la Amazonía Peruana. Sin embargo estos sesgos de sobrestimación y subestimación son corregidos por el producto PISCO-Precipitación.
- Se ha generado una base de datos de precipitación mensual grillada de alta resolución espacial (0.05°) a nivel nacional, para el periodo de enero de 1981 hasta diciembre del 2013, mediante la combinación (“merging”) entre los datos de precipitación pluviométrica observada y CHIRPS a través de la técnica de interpolación de Kriging con Deriva Externa (KED), donde:
- Se ha modelado los semivariogramas residuales para cada mes, encontrándose que cada mes es caracterizado independientemente por un modelo teórico de semivariograma. Sin embargo el modelo teórico más frecuente resultado ser el modelo exponencial (en 44% de lo meses analizados del periodo 1981 - 2013) seguida por Gaussiano (34) y Esférico (22%).
- A nivel de validación cruzada dejando uno fuera (LOOCV) se encontró que la técnica de interpolación Kriging con Deriva Externa (KED) que incorpora la información de los patrones espaciales de precipitación estimada por satélite (CHIRPS) es más eficiente (basado en coeficiente de NASH) en caracterizar la variabilidad espacial de la precipitación en comparación a una técnica de interpolación más sencilla como es el método de ponderación inverso a la distancia (inverse-distance weighting-IDW).
- Se ha realizado una post evaluación de los datos grillados (CHIRPS y PISCO) con respecto a los datos de precipitación pluviométrica observada donde se ha encontrado claramente que el producto PISCO (coeficiente de determinación promedio = 0.88) explica mejor la variabilidad espacial de la precipitación observada frente a CHIRPS (coeficiente de determinación promedio = 0.63).
- Finalmente el producto PISCO-precipitación nos permitió generar la climatología de la precipitación mensual a nivel nacional y será una herramienta útil en múltiples estudios como son las caracterizaciones hidroclimatológicas, riesgos (inundaciones y sequías) y para comprender los procesos hidrológicos en las cuencas hidrológicas del Perú.
- El producto de PISCO-precipitación está libremente disponible para los usuarios en formato GeoTIFF y NetCDF (Network Common Data Form) en el siguiente sitio web:
  - i) <http://www.senamhi.gob.pe/serviciosclimaticos/sequia/?p=indices>
  - ii) [http://ons.snirh.gob.pe/Peru/maproom/Monitoring/Meteorological/Precipitation\\_SENAMHI.html.es](http://ons.snirh.gob.pe/Peru/maproom/Monitoring/Meteorological/Precipitation_SENAMHI.html.es)

## VII. BIBLIOGRAFIA

- Berenguer, M., Zawadzki, I., 2008. A Study of the Error Covariance Matrix of Radar Rainfall Estimates in Stratiform Rain. *Weather Forecast.* 23, 1085–1101. doi:10.1175/2008WAF2222134.1
- Burrough, P.A., McDonnell, R.A., 1998. Principles of Geographical Information Systems. *Econ. Geogr.* 75, 422. doi:10.2307/144481
- Chauvet, P., 1999. Aide mémoire de Géostatistique linéaire. Paris: Les presses de l'école des mines de Paris.
- Cressie, N., 1991. *Statistics for Spatial Data.* New York.
- Cressie, N., 1990. The origins of kriging. *Math. Geol.* 22, 239–252. doi:10.1007/BF00889887
- Cressie, N., 1985. Fitting variogram models by weighted least squares. *J. Int. Assoc. Math. Geol.* 17, 563–586. doi:10.1007/BF01032109
- Creutin, J.D., Delrieu, G., Lebel, T., 1988. Rain Measurement by Raingage-Radar Combination: A Geostatistical Approach. *J. Atmos. Ocean. Technol.* 5, 102–115. doi:doi:10.1175/1520-0426(1988)005<0102:RMBRRC>2.0.CO;2
- Espinoza, J.C., Chavez, S., Ronchail, J., Junquas, C., Takahashi, K., Lavado, W., 2015. Rainfall hotspots over the southern tropical Andes: Spatial distribution, rainfall intensity, and relations with large-scale atmospheric circulation. *Water Resour. Res.* n/a–n/a. doi:10.1002/2014WR016273
- Feki, H., Slimani, M., 2006. Analyse structurale de la pluviométrie en Tunisie. In: WATMED 3, Troisième conférence internationale sur les ressources en eau dans le bassin méditerranéen, Liban.
- Feki, H., Slimani, M., Cudennec, C., 2012. Incorporating elevation in rainfall interpolation in Tunisia using geostatistical methods. *Hydrol. Sci. J.* 57, 1294–1314. doi:10.1080/02626667.2012.710334
- Funk, C.C., Peterson, P.J., Landsfeld, M.F., Pedreros, D.H., Verdin, J.P., Rowland, J.D., Romero, B.E., Husak, G.J., Michaelsen, J.C., Verdin, A.P., 2014. A Quasi-Global Precipitation Time Series for Drought Monitoring. *U.S. Geol. Surv. Data Ser.* 832, 4. doi:http://dx.doi.org/110.3133/ds832
- Germann, U., Berenguer, M., Sempere-Torres, D., Zappa, M., 2009. REAL-Ensemble radar precipitation estimation for hydrology in a mountainous region. *Q. J. R. Meteorol. Soc.* 135, 445–456. doi:10.1002/qj.375
- Giraldo, R., 2002. *Introducción a la geoestadística: Teoría y aplicación.* Departamento de Estadística, Universidad Nacional de Colombia.
- Gómez-Hernández, J.J., 1996. "Geostatistics and hydrology: an overview." *Second Jt. Conf. Exhib. Geogr. Inf.* 1, 457–466.
- Goovaerts, P., 1997. Geostatistics for natural resources evaluation, *Geostatistics for*

natural resources evaluation.

- Haberlandt, U., 2007. Geostatistical interpolation of hourly precipitation from rain gauges and radar for a large-scale extreme rainfall event. *J. Hydrol.* 332, 144–157. doi:10.1016/j.jhydrol.2006.06.028
- Hijmans, R.J., Cameron, S.E., Parra, J.L., Jones, P.G., Jarvis, A., 2005. Very high resolution interpolated climate surfaces for global land areas. *Int. J. Climatol.* 25, 1965–1978. doi:10.1002/joc.1276
- Isaaks, E.H., Srivastava, R.M., 1989. *An Introduction to Applied Geostatistics*. New York.
- Johnston, K., Ver Hoef, J.M., Krivoruchko, K., Lucas, N., 2001. “Using ArcGIS Geostatistical Analyst,” ESRI, Red- lands.
- Journel, A.G., Huijbregts, C., 1989. *Minning Geostatistics*. Reimpresión de la quinta edición (1991) publicada en 2003. New Jersey.
- Ly, S., Charles, C., Degré, a., 2011. Geostatistical interpolation of daily rainfall at catchment scale: The use of several variogram models in the Ourthe and Ambleve catchments, Belgium. *Hydrol. Earth Syst. Sci.* 15, 2259–2274. doi:10.5194/hess-15-2259-2011
- Matheron, G., 1970. *La théorie des variables régionalisées et ses applications*. Fontainebleau: Ecole Nationale Supérieure des Mines de Paris, Cahiers du centre de morphologie mathématique, fascicule 5.
- McBratney, A.B., Webster, R., 1986. Choosing functions for semi-variograms of soil properties and fitting them to sampling estimates. *J. Soil Sci.* 37, 617–639. doi:10.1111/j.1365-2389.1986.tb00392.x
- Nalder, I.A., Wein, R.W., 1998. Spatial interpolation of climatic Normals: test of a new method in the Canadian boreal forest. *Agric. For. Meteorol.* 92, 211–225. doi:10.1016/S0168-1923(98)00102-6
- Oliver, M.A., Webster, R., 2014. A tutorial guide to geostatistics: Computing and modelling variograms and kriging. *Catena* 113, 56–69. doi:10.1016/j.catena.2013.09.006
- Pebesma, E.J., 2004. Multivariable geostatistics in S: The gstat package. *Comput. Geosci.* 30, 683–691. doi:10.1016/j.cageo.2004.03.012
- Peterson, P., Funk, C.C., Husak, G.J., Pedreros, D.H., Landsfeld, M., Verdin, J.P., Shukla, S., 2013. The Climate Hazards group InfraRed Precipitation (CHIRP) with Stations (CHIRPS): Development and Validation. AGU Fall Meet. Abstr. 1417.
- Pulgar, V.J., 1941. *Geografía del Perú : las ocho regiones naturales del Perú* Lima : Edit. Universo.
- Quintero, F., Sempere-Torres, D., Berenguer, M., Baltas, E., 2012. A scenario-incorporating analysis of the propagation of uncertainty to flash flood simulations.

- J. Hydrol. 460-461, 90–102. doi:10.1016/j.jhydrol.2012.06.045
- Samper, F.J., Carrera, J., 1990. Geoestadística. Aplicaciones a la hidrogeología subterránea. Centro Internacional de Métodos Numéricos en Ingeniería. Universitat Politècnica de Catalunya. Barcelona.
- SENAMHI, 2005. Mapa Climático del Perú, Servicio Nacional de Meteorología e Hidrología, Lima, Perú.
- Slocum, T.A., 1999. Chapter 8: Interpolation methods for smooth continuous phenomena. In Thematic Cartography and Visualization. New Jersey.
- Thornthwaite, C.W., 1948. An approach toward a rational classification of climate. Geogr. Rev. 38, 55–94.
- Tveito, O., Wegehenkel, M., Van der Wel, F., Dobesch, H., 2008. "The Use of Geographic Information Systems in Climatology and Meteorology: COST 719," Luxemburg: COST Action719.
- UNESCO, 2006. Balance hídrico superficial del Perú a nivel multianual. Documentos Técnicos del PHI-LAC, N°1.
- Wackernagel, H., 1994. Cokriging versus kriging in regionalized multivariate data analysis. Geoderma 62, 83–92. doi:10.1016/0016-7061(94)90029-9
- Warrick, A., Myers, D., Nielsen, D., 1986. Geostatistical Methods Applied to Soil Science. Methods of Soil Analysis. Part 1. Physical and Mineralogical Methods. Agron. Monogr. 9, 53 – 81.
- Webster, R., Oliver, M.A., 2007. Geostatistics for Environmental Scientists, 2nd Edition. England.