

# Optimización de una red de monitoreo de precipitación usando modelos Geoestadísticos: caso de estudio en la cuenca del río Paute, Ecuador

Contreras Juan<sup>1,2</sup>, Ballari Daniela<sup>1,2,3</sup>, Samaniego Esteban<sup>1,2</sup>

1 Facultad de Ingeniería/Universidad de Cuenca  
Avenida 12 de Abril s/n, 10150  
Cuenca/Azuay/Ecuador  
juanjosecs91@gmail.com

2 Departamento de Recursos Hídricos y Ciencias Ambientales/ Universidad de Cuenca  
Víctor Manuel Albornoz y los Cerezos/Azuay/Ecuador  
esteban.samaniego@ucuenca.edu.ec

3 IERSE/Facultad de Ciencia y Tecnología/Universidad del Azuay  
Avenida 24 de Mayo 7-77 y Hernán Malo, 10150 Cuenca /Azuay/Ecuador  
dballari@uazuay.edu.ec

## RESUMEN

En regiones de montaña como los Andes, la densidad de la red de pluviómetros es pobre y a menudo dispersa. Por lo tanto, es incapaz de proporcionar una adecuada estimación de la precipitación, por lo que la densificación de estas redes constituye un tema de gran relevancia para una adecuada gestión ambiental y de los recursos hídricos. El presente estudio tiene como objetivo identificar el diseño óptimo para extender la red de pluviómetros existente en una cuenca de montaña en el sur del Ecuador (Cuenca del Río Paute) mediante el uso de modelos geoestadísticos. Imágenes satelitales de precipitación TRMM 3B43 e imágenes MODIS de distintas variables atmosféricas, así como variables topográficas derivadas de un Modelo Digital de Elevación (DEM), fueron utilizadas como información auxiliar para definir distintos modelos de regresión para la optimización de la red por medio de Kriging Universal (KU). Con el mejor modelo de regresión la red fue densificada, reduciendo la Varianza Media de Kriging Universal (VMKU) como función objetivo por medio del algoritmo de optimización Spatial Simulated Annealing (SSA). Con el propósito de comparar los resultados, Kriging Ordinario (KO) también fue utilizado. La red fue densificada sobre 63 puntos (42 añadidos). Con KU se obtuvo una varianza media 18% menor a KO. La varianza entre la red actual y propuesta se redujo en un 55% y un 64% con KO y KU, respectivamente. La red de diseño obtenida en el estudio permite captar adecuadamente la variabilidad espacial de la precipitación en relación a la red actual y puede ser usada como guía para la densificación paulatina de estas redes en la región.

Palabras clave: **Red de pluviómetros, modelos geoestadísticos, kriging universal, imágenes satelitales, Spatial Simulated Annealing.**

## ABSTRACT

*In mountain regions like the Andes, the density of the rain gauge network is poor and often dispersed. This situation affects the ability to provide an adequate estimation of precipitation. Therefore, the densification of these networks is an issue of great relevance for an adequate management of environment and water resources. The present study aims to identify the optimal design to extend the existing rain gauge network in a mountain basin of southern Ecuador (Paute River basin) through the use of geostatistical models. Precipitation satellite images TRMM 3B43 and MODIS images of different atmospheric variables,*

as well as topographic variables derived from a Digital Elevation Model (DEM), were used as auxiliary information to define different regression models for network optimization using Universal Kriging (KU). With the best regression model the network was densified, reducing the Mean Universal Kriging Variance (VMKU) as an objective function by means of the Spatial Simulated Annealing (SSA) optimization algorithm. In order to compare the results, Ordinary Kriging (KO) was also used. The network was densified over 63 points (42 added). With KU a mean variance 18% lower than KO was found. The variance between the current and proposed network was reduced by 55% and 64% with KO and KU, respectively. The design network obtained in the study allows to adequately capture the spatial variability of precipitation in relation to the current network and can be used as a guide for the gradual densification of these networks in the region.

**Keywords:** Rain gauge network, geostatistical models, universal kriging, satellite images, Spatial Simulated Annealing.

## I. INTRODUCCIÓN

La precipitación es el componente más importante del ciclo hidrológico y tiene un papel fundamental en diferentes actividades socioeconómicas. Por lo tanto, un conocimiento exacto de la variabilidad espacial y temporal de la precipitación es esencial para muchos campos científicos y de gestión como la hidrología, meteorología, ecología, modelación climática, planificación de riego, control y prevención de inundaciones y la gestión de los recursos hídricos (Celleri et al., 2007; Padrón et al., 2015; Shaghaghian & Abedini, 2013; Tapiador et al., 2012).

Para capturar y cuantificar la variabilidad espacial y temporal de la precipitación, pluviómetros son comúnmente instalados en un área determinada o una cuenca (Adhikary et al., 2014). Estas mediciones son posteriormente extrapoladas para obtener estimaciones promedio de la precipitación sobre un área. A pesar de los adelantos en la teledetección remota por medio de imágenes satelitales y radares meteorológicos para capturar la variabilidad de la precipitación, los pluviómetros siguen siendo la fuente más precisa de información (Michaelides et al., 2009; Tapiador et al., 2012). En regiones de montaña como los Andes, la densidad de estas redes es pobre y a menudo dispersa y, por lo tanto, incapaz de proporcionar una adecuada estimación de la precipitación. Estas estimaciones sólo mejorarán si, con el tiempo, se aumenta la densidad de la red de pluviómetros (Celleri et al., 2007; Ochoa et al., 2014). Por esto, especial atención es requerida en el diseño y densificación de estas redes.

Uno de los métodos más utilizados en el diseño y optimización de redes de pluviómetros es el método de reducción de la varianza por medio de técnicas de Kriging (Cheng et al., 2008). La principal ventaja de kriging sobre los métodos de interpolación más sencillos es que las características escasamente muestreadas de la variable objetivo pueden ser complementadas por atributos secundarios que son muestreados más densamente (Goovaerts, 2000). El creciente interés por las herramientas geoestadísticas se basa en la disponibilidad de datos secundarios o auxiliares (ej. medidas indirectas de sensores remotos) que podrían utilizarse para producir modelos espaciales/temporales fiables de diversas variables ambientales (Hengl et al., 2012).

La mayoría de estudios de diseño y optimización de redes de precipitación se han enfocado en el uso de Kriging Ordinario (ej.: Adhikary et al., 2014; Chebbi et al., 2013; Chebbi et al., 2011; Feki et al., 2016; Pardo-Igúzquiza 1998); sin embargo, pocos estudios que utilicen métodos con variables auxiliares han sido reportados. Por ejemplo, Feki and Slimani (2015) compararon tres algoritmos geoestadísticos diferentes, como kriging con deriva externa, kriging de regresión y cokriging, que integran la elevación como variable secundaria con el objetivo de encontrar procedimientos eficientes para la optimización de la

red de precipitación. Ellos encontraron que el kriging de regresión fue el mejor modelo. Por otra parte Ge et al. (2014) diseñaron una red de monitoreo ecohidrológico mediante un muestreo multicriterio con el uso de cokriging universal. Ellos diseñaron la red para el monitoreo simultáneo de la precipitación, temperatura y humedad del suelo definiendo variogramas para cada variable mediante información satelital y variables auxiliares derivadas de un modelo digital de elevación. Encontraron que, comparado con un diseño de muestreo que no tiene en cuenta la correlación multivariada y la tendencia espacial, el método de muestreo utilizado redujo la varianza del error de predicción y fue eficiente en capturar la variación espacial de las variables objetivo.

En regiones poco monitoreadas como los Andes en Ecuador, conocer la estructura espacial de la precipitación por medio de mediciones in-situ es muy difícil debido a la poca densidad de pluviómetros y a una distribución dispersa de los mismos. La incorporación de variables auxiliares o explicativas con una cobertura espacial continua relacionadas con la precipitación sin duda es una alternativa fiable para un diseño más preciso de estas redes. Campozaño et al. (2016) ha reportado la gran utilidad de imágenes satelitales de nubosidad para identificar procesos de generación y el estudio espacio-temporal de la precipitación en terrenos complejos, como los Andes. Hasta el momento no existen estudios relacionados que utilicen información auxiliar a partir de productos satelitales de variables atmosféricas en la optimización de redes de precipitación. De esta manera, el objetivo de este estudio es densificar la red de precipitación existente en una cuenca Andina en el sur del Ecuador, la Cuenca del río Paute, mediante el uso de información auxiliar de variables atmosféricas además de variables topográficas y geográficas relacionadas con la variabilidad de la precipitación por medio de Kriging Universal. Con el propósito de comparar y resaltar la ventaja de utilizar variables auxiliares en la densificación de la red, Kriging Ordinario fue utilizado.

## II. MÉTODO

### ÁREA DE ESTUDIO

El área de estudio es la cuenca del río Paute (Figura 1). La cuenca del Paute está ubicada entre la cordillera oriental y occidental de los Andes en Ecuador y tiene un área de 6.481 km<sup>2</sup>. Su rango de elevación varía de 442 a 4.415 m.s.n.m. y alrededor del 40% de la cuenca está cubierta por páramo. El patrón climático en la región de estudio está influenciado por el régimen costero del Pacífico desde el oeste, y las masas de aire del Atlántico continental y tropical del este (Vuille et al., 2000). La cuenca se caracteriza por una alta variación espacial y temporal de la precipitación que puede clasificarse en tres regímenes pluviales, subregiones con un patrón de precipitación

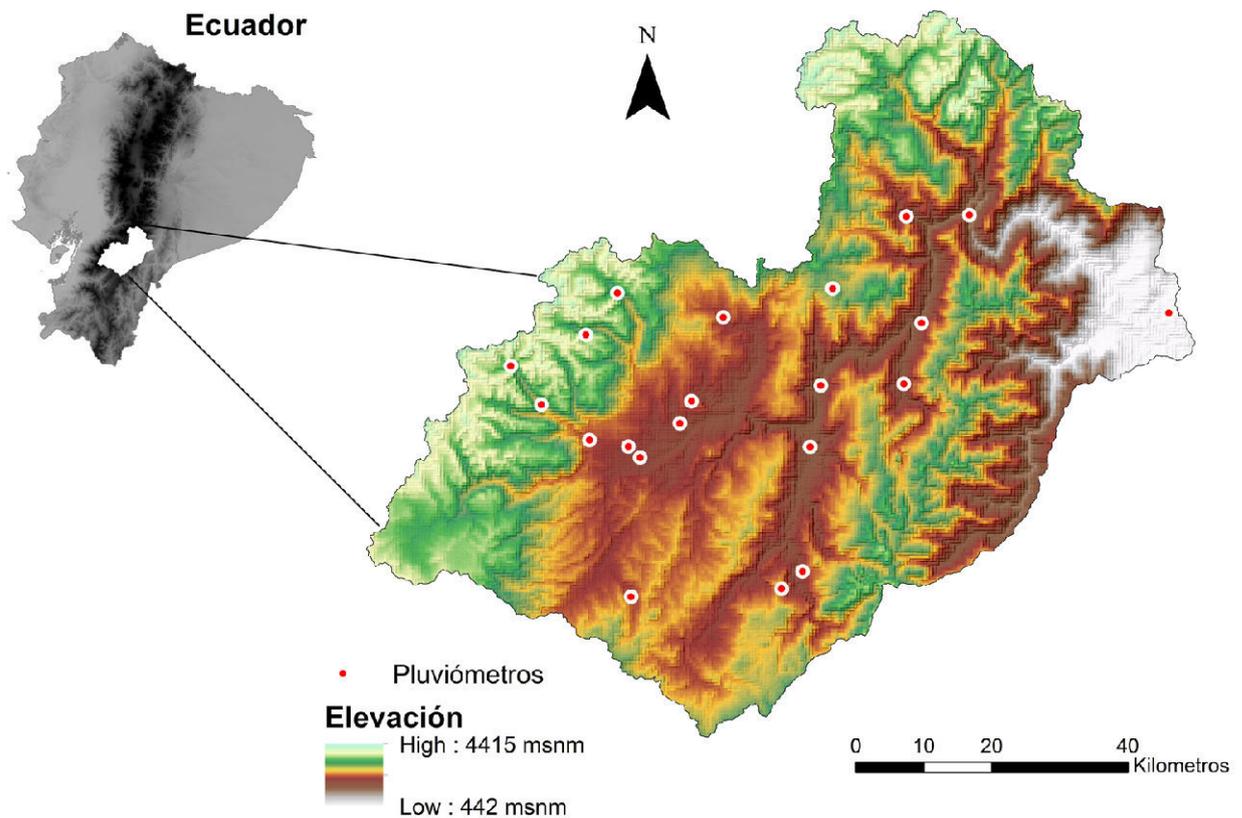


Figura 1. Ubicación del área de estudio y de la red de monitoreo de precipitación del INAMHI.

uni-, bi- y trimodal (Campozano et al., 2016; Celleri et al., 2007). La cuenca del río Paute alimenta varias centrales hidroeléctricas, Amaluza (1075 MW), El Labrado y Chanlud (38,4MW), Mazar (162,6 MW) y Sopladora (500 MW), generando alrededor del 40% de la producción hidroeléctrica del Ecuador. Además, varias ciudades de la región dependen directamente de los diversos servicios ecohidrológicos de la cuenca.

La Cuenca del Río Paute es una de las cuencas más monitoreadas de Ecuador debido a su importancia en la producción de energía hidroeléctrica. Actualmente, varias instituciones públicas a nivel nacional y local entre ellas principalmente el Instituto Nacional de Meteorología e Hidrología (INAMHI) y la Empresa de Telecomunicaciones Agua Potable y Alcantarillado de la ciudad de Cuenca (ETAPA EP) cuentan con redes de monitoreo de precipitación en la región. Estas redes, sin embargo, se encuentran dispersas de manera desigual por todo el territorio por lo que no existe una representación completa de la precipitación en toda la cuenca.

Para este estudio, la densificación de la red de monitoreo se realizó tomando en cuenta la red de pluviómetros existentes del INAMHI (Figura 1) debido a que es la red más extensa y de mayor antigüedad de la región, contando con 21 pluviómetros en la cuenca.

#### DATOS

##### *Datos satelitales de precipitación*

Debido a que el número de pluviómetros en la región es limitado, no es posible obtener una representación completa de la variabilidad espacial de la precipitación, por lo que los datos de precipitación obtenidos de imágenes satelitales con una cobertura espacial y temporal continua fueron utilizados. Los

datos de precipitación fueron obtenidos de la de la Misión de Observación de Precipitación Tropical (Tropical Rainfall Measuring Mission - TRMM), un proyecto conjunto lanzado por la NASA y la agencia espacial Japonesa JAXA diseñado para el monitoreo y estudio de la precipitación en zonas tropicales (1997-2015). TRMM estuvo compuesto por varios instrumentos de medición de precipitación, tales como el Radar de Lluvia (PR), el Generador de Imágenes por Microondas TRMM (TMI) y el Escáner de Radiación Visible e Infrarrojo (VIRS). La información de estos instrumentos se procesan con algoritmos de recuperación para generar estimaciones de precipitación a una escala cuasi-global (Condom et al. 2010). La precipitación es obtenida a una resolución espacial de 0.25° (aproximadamente 27 x 27 km a latitud de 0°) para áreas 50°N-50°S por medio del TRMM Análisis de Precipitación Multi-Satélite (TMPA), que fue diseñado para combinar estimaciones de precipitación de varios sistemas de satélites, así como de datos de precipitación en tierra cuando estos estuvieran disponibles (Huffman et al., 2007).

Para el estudio, datos mensuales de precipitación TRMM 3B43 durante el período Enero 2001 a Diciembre 2011 (120 imágenes) fueron descargados de la plataforma Giovanni de la NASA (<https://giovanni.sci.gsfc.nasa.gov/giovanni/>) y geo referenciados para el área de estudio. Las imágenes satelitales TRMM fueron reescaladas a una resolución de 5 km con el método de vecinos más cercanos (Mahmud et al., 2015). Este cambio de resolución espacial se justifica por el uso posterior de variables auxiliares de mejor resolución espacial. Posteriormente, las imágenes satelitales fueron promediadas mensualmente durante el período de estudio para finalmente obtener la precipitación anual en el área acumulando los 12 conjuntos de datos mensuales. En la Tabla I se presentan los estadísticos de la precipitación anual durante el período de estudio.

**TABLA I**  
**ESTADÍSTICA DESCRIPTIVA DE LA PRECIPITACIÓN PROMEDIO ANUAL EN LA CUENCA DEL RÍO PAUTE CAPTADA POR LA IMAGEN TRMM.**

PROMEDIO	MÁXIMA	MÍNIMA	MEDIANA	DESVIACIÓN ESTÁNDAR
1127.1 mm	1735.4 mm	709.9 mm	1095.7 mm	235.8 mm

*Variables auxiliares*

Con el objetivo de representar de mejor manera los patrones espaciales de la precipitación en el área de estudio, variables geográficas, topográficas, y atmosféricas relacionadas con la precipitación a una resolución más fina fueron utilizadas en el estudio para el diseño de la red de pluviómetros. A continuación se detallan los diferentes productos satelitales utilizados.

- Variables geográficas: Latitud y longitud.
- Variables topográficas: Datos de un Modelo Digital de Elevación (DEM) fueron obtenidos del proyecto Shuttle Radar Topography Mission (SRTM), patrocinado por la Agencia Nacional de Inteligencia Geoespacial (NGA) y la NASA. El DEM fue descargado a una resolución espacial de 90 m de la página web <http://www2.jpl.nasa.gov/srtm/dataproduct.htm> y posteriormente reescalado a una resolución de 5 km mediante el método de vecinos más cercanos (Bostan et al., 2012). Parámetros topográficos como la elevación, el aspecto y la pendiente fueron derivados del DEM (Fig. 2a-c).
- Variables atmosféricas: Varios productos satelitales MODIS

(MOD06\_L2 y MOD\_08) fueron descargados a una resolución de 5 km para obtener mediciones mensuales de varios parámetros atmosféricos. La fracción de nubes (FN), la temperatura en la parte superior de las nubes (TSN) y el vapor de agua en la atmósfera (VAA) fueron considerados para el análisis (Fig. 2d-f). Las imágenes fueron descargadas de la página web <https://modis.gsfc.nasa.gov/data/dataproduct/>.

Al igual que las imágenes de precipitación, las imágenes satelitales de todas las variables auxiliares antes mencionadas a excepción de las variables topográficas fueron descargadas a una resolución mensual durante Enero 2001 - Diciembre 2011. Estas imágenes fueron promediadas mensualmente durante el período de estudio. Posteriormente, una imagen a escala anual de cada variable fue obtenida promediando los 12 conjuntos de datos mensuales. En la Figura 2 se muestra el mapa de las variables auxiliares utilizadas en el estudio.

MÉTODOS

*Análisis de regresión*

Con el objetivo de definir relaciones entre la precipitación y las diferentes variables ambientales, modelos de regresión lineal simple fueron establecidos entre la imagen anual de precipitación TRMM y cada una de las variables auxiliares a una resolución de 5 km. Las variables con una correlación mayor a 0.3 y un valor de significancia del 95% ( $p < 0.05$ ) fueron posteriormente analizadas para definir y evaluar modelos de regresión lineal múltiple como modelos de predicción para la red de diseño. El análisis de regresión simple y múltiple fue realizado en R.

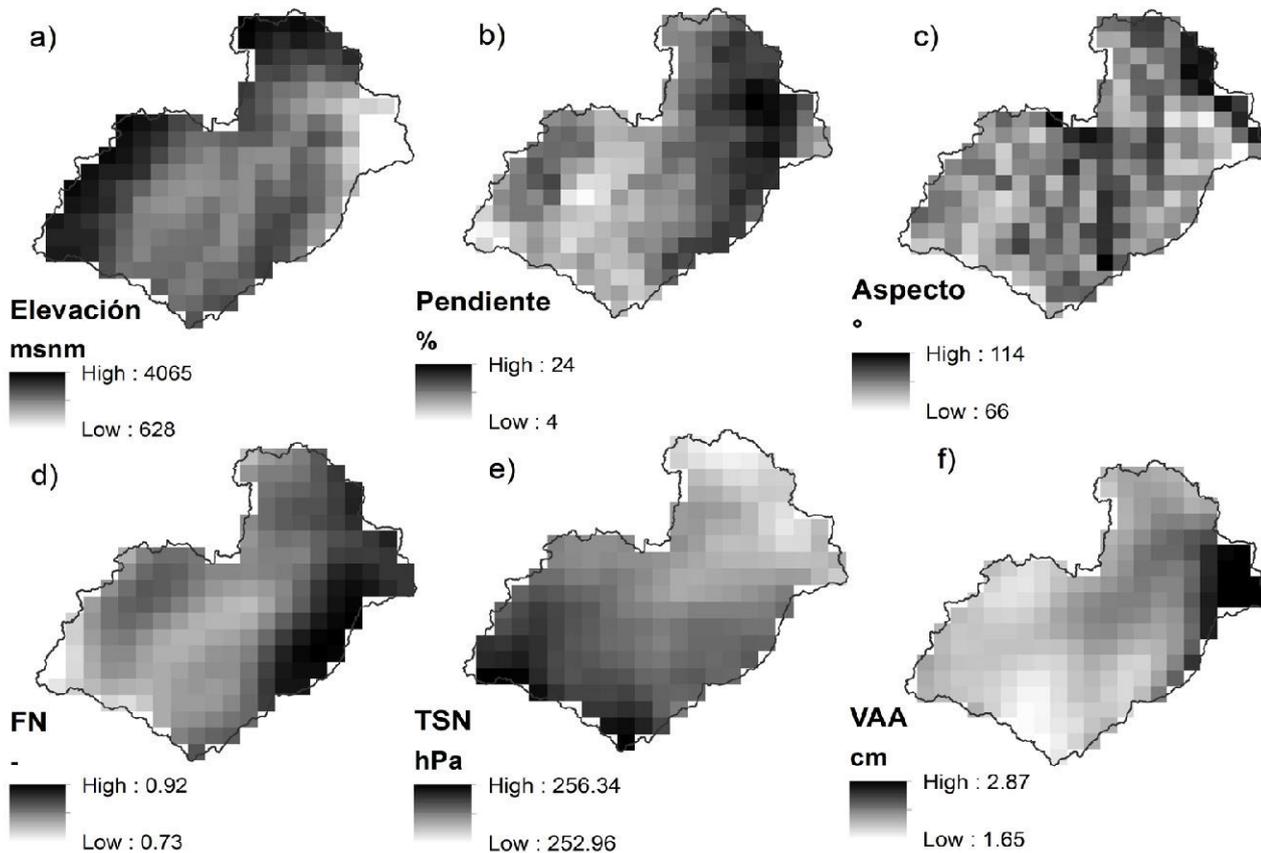


Figura 2. Mapa de las variables auxiliares utilizadas en el estudio a una resolución de 5 km x 5 km: a) elevación, b) pendiente, c) aspecto, d) FN: fracción de nubes, e) TSN: temperatura superior en las nubes y f) VAA: vapor de agua en la atmósfera.

## MUESTREO ESPACIAL

### Técnicas de interpolación

El muestreo espacial aquí utilizado se basa en dos métodos de interpolación geoestadísticos que no son nuevos y que se han descrito con frecuencia en la literatura. Por lo tanto, aquí se realiza una breve descripción de los mismos. El lector puede referirse a Hengl (2009) para más información.

### Kriging Ordinario (KO)

Las estimaciones de Kriging Ordinario son una media ponderada de las observaciones, con pesos derivados del grado de correlación espacial. La estimación KO es un promedio ponderado lineal de las  $n$  observaciones disponibles definidas como:

$$\hat{Z}(s) = \sum_{i=1}^n \lambda_i z(s_i) \quad (1)$$

donde  $Z(s)$  es la estimación de KO en la posición  $s$ ,  $\lambda_i$  son los pesos de KO, y  $s_i$  son los lugares de observación. En KO, los pesos se obtienen de tal manera que la varianza de error de predicción se minimiza sujeto a la imparcialidad (es decir, los pesos de kriging se limitan a sumar a uno). La varianza del error de predicción ( $\sigma_{KO}^2$ ) se define en la Ec. (2) como:

$$\sigma_{KO}^2(s_0) = E \left[ \left( \hat{Z}(s_0) - (s_0) \right)^2 \right] \quad (2)$$

donde  $E$  es la esperanza matemática.

### Kriging Universal (KU)

En KU, la distribución espacial de la variable objetivo se describe mediante la suma de una tendencia determinista, modelada por una regresión lineal sobre covariables, y la realización de un residuo estocástico, espacialmente autocorrelacionado. La predicción de KU es dada por la siguiente ecuación:

$$\hat{Z}(s) = \sum_{j=0}^n B_j x_j(s) + \varepsilon(s) \quad (3)$$

donde  $Z(s)$  es la variable ambiental objetivo,  $s \equiv (s_1, s_2)'$  es una coordenada espacial bidimensional, donde las  $x_j(s)$  son covariables (observe que  $x_0(s) \equiv 1$  para todo  $s$ ), donde  $B_j$  son coeficientes de regresión, y donde  $\varepsilon(s)$  es un residuo normalmente distribuido con media cero y varianza constante  $c(0)$ . El residual  $\varepsilon$  está posiblemente autocorrelacionado espacialmente, cuantificado mediante una función de auto covarianza o un variograma.

En notación de matriz la ecuación (Ec. 3) se puede reescribir como:

$$\hat{Z}(s) = x'(s)\beta + \varepsilon(s) \quad (4)$$

donde  $x$  y  $\beta$  son vectores de columna de  $m+1$  covariables y  $m+1$  coeficientes de regresión, respectivamente. La predicción de KU en una posición no observada  $s_0$  de  $n$  observaciones  $z(s_i)$  está dada por:

$$\hat{Z}(s_0) = (c_0 + X(X'C^{-1}X)^{-1}(x_0 - X'C^{-1}c_0))'C^{-1}z \quad (5)$$

donde  $X$  es la matriz  $n \times (m+1)$  de covariables en los lugares de observación,  $x_0$  es el vector de covariables en la localización de predicción,  $C$  es la matriz de varianza-covarianza  $n \times n$  de los  $n$  residuos,  $c_0$  es el vector de covarianzas entre los residuos en las posiciones de observación y predicción, y donde  $z$  es el vector de observaciones  $z(s_i)$ .  $C$  y  $c_0$  se derivan del variograma de  $\varepsilon$ .

La varianza del error de predicción universal (varianza de KU) en  $s_0$  está dada por:

$$\sigma^2(s_0) = c(0) - c_0'C^{-1}c_0 + (x_0 - X'C^{-1}c_0)'(x_0 - X'C^{-1}c_0) \quad (6)$$

La varianza de kriging universal incorpora tanto la varianza del error de predicción del residuo como la varianza del error de estimación de la tendencia. Mediante la minimización del promedio espacial (o suma) de la varianza de kriging universal en los puntos, se obtiene automáticamente el equilibrio correcto entre la optimización del patrón de muestra en el espacio geográfico y de atributos (Brus & Heuvelink, 2007).

### Análisis de variograma

Un requerimiento importante para aplicar técnicas de kriging es conocer la estructura espacial de la variable objetivo, la cual es definida por el variograma o semivariograma. De esta manera los semivariogramas (experimental y ajustado) de los modelos de regresión múltiple para KU y otro para KO fueron definidos a partir de las imágenes satelitales a una resolución de 5 km (Figura 2) por medio de la librería "gstat" en R (Pebesma, 2004). Los modelos de variograma exponencial, gaussiano y esférico fueron evaluados debido a que son los más utilizados en hidrología (Adhikary et al., 2014).

### Función objetivo

El diseño de la red de pluviómetros requiere buscar una combinación entre todas las estaciones de medición que minimice la varianza de estimación y/o maximice el contenido de información de los datos observados. Esto se logra mediante el posicionamiento óptimo de estaciones redundantes o adicionales. En este estudio, la reducción de las Varianzas Medias de Kriging Ordinario (VMKO) (Ec. 2) y de Kriging Universal (VMKU) (Ec. 6) fueron consideradas como funciones objetivos como un indicador para lograr la red óptima. El principio subyacente es que el posicionamiento óptimo de estaciones adicionales en zonas de alta varianza reducirá el error de kriging en la red y por lo tanto mejorará el rendimiento de la red. Aplicando este principio repetidamente, se puede llegar a una combinación óptima entre las estaciones existentes y adicionales que producen un alto rendimiento de la red, encontrando así la red de pluviómetros óptima.

### Optimización del muestreo

Para la optimización Spatial Simulated Annealing (SSA) fue usado en este estudio. SSA es un algoritmo que usa ligeras perturbaciones de diseños previos y una técnica de búsqueda aleatoria para resolver problemas de optimización espacial (Chebbi et al., 2011; Ge et al., 2014; Melles et al., 2011; Pardo-Igúzquiza, 1998). Este algoritmo combinatorio iterativo tiene cinco pasos (Baume et al., 2011):

1. Comenzar con un diseño inicial arbitrario y calcular la función objetivo seleccionada (VMKO o VMKU);
2. Calcular un nuevo diseño candidato del diseño actual por perturbaciones aleatorias de las ubicaciones de uno o varios sitios de medición;
3. Evaluar el nuevo diseño candidato con la función objetivo;
4. Aceptar el nuevo diseño cuando la función objetivo ha mejorado, o aceptar el mismo con alguna probabilidad cuando la función objetivo se ha deteriorado (esto asegura que el algoritmo escape de óptimos locales);
5. Detener cuando se ha alcanzado un número grande de iteraciones o cuando no se han aceptado nuevos diseños de candidatos para un número dado de veces.

Varios parámetros del algoritmo SSA deben ser definidos antes del proceso de optimización. La probabilidad inicial de aceptar diseños empeorados fue establecida en 0.2 ( $p < 20\%$ ) para evitar la selección de óptimos locales. Otro parámetro a ser configurado es el 'cooling schedule', que hace referencia a la tasa con que  $p$  disminuye a cero. Para el estudio,  $p$  fue configurado a una función de disminución exponencial de acuerdo al número de iteraciones. Todos los parámetros del algoritmo fueron configurados según estudios previos realizados por Brus and Heuvelink (2007) y Melles et al. (2011). Las simulaciones se realizaron mediante el uso de la función optimizeNetwork del paquete "IntamapInteractive" disponible en R.

#### Implementación de la red densificada

**Selección del modelo de variograma:** Para la densificación de la red un modelo de variograma fue seleccionado entre los diferentes modelos de regresión múltiple definidos. El modelo de variograma utilizado fue el que menor semivarianza presentó en el análisis realizado por medio del semivariograma experimental.

**Selección del número de estaciones:** Para determinar el número óptimo de pluviómetros requerido en la cuenca del Paute, se investigó la relación entre el número de puntos de muestreo y el correspondiente valor de la función objetivo por medio de KO (considerando el peor escenario de optimización, sin variables auxiliares). Este análisis se lo realizó optimizando la red agregando puntos de monitoreo de 10 en 10 partiendo de la red actual hasta llegar a los 120 puntos por medio de SSA. La optimización de cada muestra fue realizada sobre 1000 iteraciones considerando toda el área de la cuenca. El número óptimo se estableció cuando VMKO se estabilizó a pesar del aumento de pluviómetros.

**Restricciones por accesibilidad:** Un aspecto importante a considerar al realizar el diseño de la red es tener en cuenta las limitaciones de acceso para realizar monitoreo ambiental en regiones montañosas y de difícil acceso. Por esta razón y con el fin de facilitar la instalación, el mantenimiento y la recolección de datos de los equipos se estableció un buffer de 1 km alrededor de las vías para delimitar posibles lugares dónde se podrían ubicar los nuevos puntos de monitoreo (Figura 3). Bajo estas consideraciones se determinó que aproximadamente el 61% del área de la cuenca cuenta con zonas de fácil acceso (cercanas a vías) sobre las cuales se realizó la densificación de la red (Figura 3).

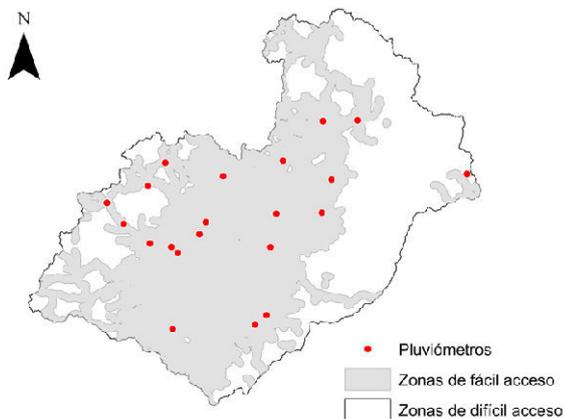


Figura 3. Zonas accesibles para la instalación de nuevos puntos de monitoreo de precipitación. Una vez definidos los puntos anteriores la red de monitoreo fue optimizada sobre 10000 iteraciones.

### III. RESULTADOS

#### ANÁLISIS DE REGRESIÓN

Los resultados del análisis de regresión se presentan en la Tabla II y muestran el porcentaje de varianza en la precipitación que es explicado por cada variable ( $R^2$ ). En general, las variables geográficas y atmosféricas tuvieron resultados similares y este fue mejor que las variables topográficas. Los coeficientes de determinación ( $R^2$ ) de las variables geográficas variaron de 0.511 a 0.015, las variables atmosféricas variaron de 0.514 a 0.067 y las variables topográficas variaron entre 0.444 y 0.04. Se encontraron mayores valores de  $R^2$  para la FN, la longitud y la elevación, mientras que los menores valores fueron encontrados para la latitud, el aspecto y la TSN. Todas las variables pasaron la prueba de significancia a excepción de la latitud y el aspecto.

TABLA II  
RESULTADOS DEL ANÁLISIS DE REGRESIÓN SIMPLE ENTRE LA PRECIPITACIÓN ANUAL Y LAS VARIABLES AUXILIARES EN LA CUENCA DEL RÍO PAUTE.

VARIABLES		$R^2$
Geográficas	Longitud	0.511*
	Latitud	0.0145
Topográficas	Elevación	0.444*
	Pendiente	0.341*
	Aspecto	0.0049
Atmosféricas	FN	0.514*
	VAA	0.357*
	TSN	0.067*

Nota: \* indica que la variable tiene un nivel de significancia de  $p < 0.05$ ; las variables en cursiva fueron excluidas del análisis multivariado.

Con las variables topográficas y atmosféricas que presentaron un valor de  $R^2$  mayor a 0.3 (Tabla II) se realizó un análisis de regresión entre estos dos conjuntos de variables auxiliares con el fin de establecer de mejor manera las relaciones entre la precipitación y más de una variable auxiliar (multicolinealidad). Las correlaciones que se muestran en la Tabla III indican que existe una mayor correlación entre la elevación y el VAA, la FN y la pendiente, y entre la FN y el VAA. De esta manera, 3 modelos de regresión múltiple fueron establecidos con la precipitación: precipitación + elevación + VAA + longitud ( $R^2 = 0.571$ ), precipitación + FN + pendiente + longitud ( $R^2 = 0.547$ ), y precipitación + FN + VAA + longitud ( $R^2 = 0.568$ ). La longitud ( $R^2 = 0.51$ ,  $p < 0.05$ ) fue incluida en los 3 modelos de regresión múltiple debido a que en estudios previos se ha evidenciado que las variables geográficas tienen una influencia importante en la variabilidad de la precipitación en la zona de estudio (Buytaert et al., 2006).

#### ANÁLISIS DE VARIOGRAMA

En la Figura 4 se muestra el variograma experimental de cada modelo y en la Tabla IV sus respectivos parámetros. En la Figura 4 se observa una disminución clara de la semivarianza al usar los diferentes modelos que incluyen variables auxiliares. Lo que a priori indica una mejora en la reducción de la varianza al aplicar estos modelos sobre KO. La Tabla IV indica que los modelos de regresión múltiple se ajustan a un modelo exponencial y que todos los parámetros de los diferentes modelos varían. Con el propósito de usar el mejor modelo de predicción, KU3 (precipitación + VAA + FN + longitud) fue seleccionado para la densificación de la red debido a que presentó una menor semivarianza en el variograma experimental en comparación a los otros modelos como se observa en la Figura 4.

**TABLA III**  
VALORES DE R<sup>2</sup> ENTRE LAS VARIABLES TOPOGRÁFICAS Y ATMOSFÉRICAS EN LA CUENCA DEL RÍO PAUTE.

	ELEVACIÓN	PENDIENTE	FN	VAA
Elevación	1			
Pendiente	0.03	1		
FN	0.12	<b>0.53</b>	1	
VAA	<b>0.54</b>	0.25	<b>0.31</b>	1

Nota: las relaciones entre las variables en negrita y cursiva fueron utilizadas para establecer modelos de regresión múltiple con la precipitación. Todas las relaciones obtuvieron un valor de p < 0.05.

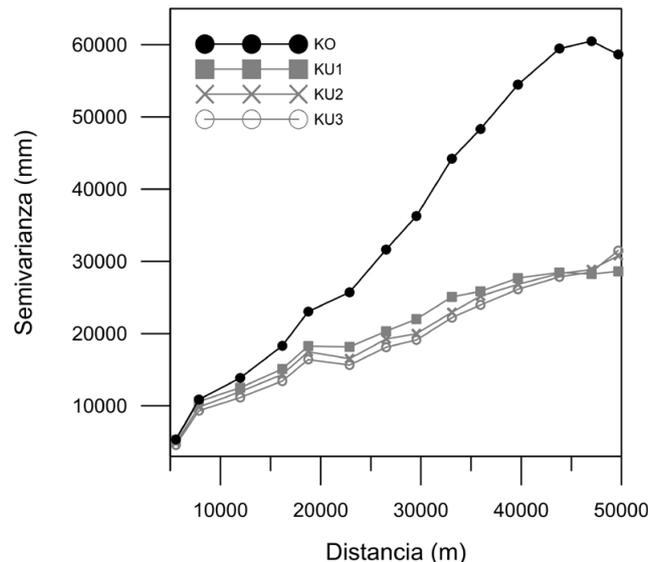


Figura 4. Semivariograma experimental de los diferentes modelos de regresión derivados de las imágenes satelitales.

**TABLA IV**  
PARÁMETROS DE LOS MODELOS DE REGRESIÓN MÚLTIPLE AJUSTADOS AL VARIOGRAMA EXPERIMENTAL.

VARIABLES	CÓDIGO	MODELO	NUGGET	SILL	RANGE
Precipitación	KO	Gausiano	5059	62145	33213
Precipitación+ elevación+ VAA+longitud	KU1	Exponencial	0	35028	27736
Precipitación+ pendiente+FN +longitud	KU2	Exponencial	0	35732	30964
Precipitación+ VAA+FN+ longitud	KU3	Exponencial	157	37727	36609

**DISEÑO DE LA RED DENSIFICADA DE PRECIPITACIÓN**

En la Figura 5 se observa el valor de la VMKO para varios conjuntos de pluviómetros. Se encontró que la varianza disminuye con el aumento en el número de puntos. Cuando el número de puntos alcanzó los 60 aproximadamente, la disminución en la varianza media del error de predicción de KO no disminuyó substancialmente. De esta manera, se estableció un equilibrio entre el número de pluviómetros requeridos y la función objetivo. El total de pluviómetros requeridos cumple con las recomendaciones establecidas por la Organización Meteorológica Mundial (WMO) donde en regiones de montaña se requiere un pluviómetro por cada 100 km<sup>2</sup> aproximadamente para una adecuada captura de la variabilidad espacial de la precipitación (WMO, 1994, 2008).

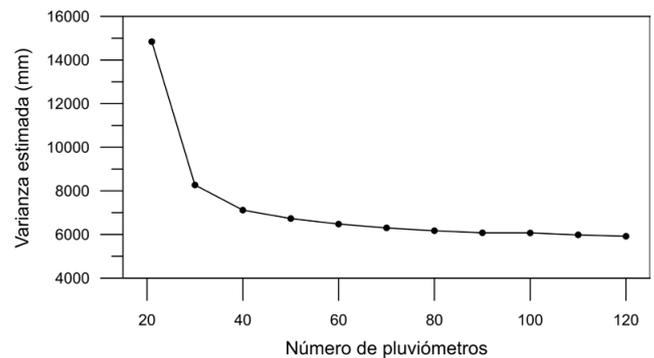


Figura 5. Balance entre la función objetivo (VMKO) y el número de pluviómetros.

Con el objetivo de densificar la red en dos fases, se estableció un número total de 63 pluviómetros requeridos en el área de estudio de los cuales 42 fueron añadidos a la red existente de 21. La densificación de la red se realizó: a) duplicando la red existente, es decir añadiendo 21 puntos a la red actual y b) triplicando la red existente añadiendo 21 puntos más a la red identificada en a. En la Figura 6 se muestra la ubicación de los nuevos puntos de muestreo obtenidos mediante la optimización con KO y KU. Se puede observar que tanto la red de muestreo identificada mediante la disminución de la varianza de KO y KU muestran un patrón similar con una distribución de los sitios por todo el territorio priorizando la cercanía a la red de vías; sin embargo, algunos de los sitios identificados con KO tendieron a localizarse en los bordes de la cuenca no así con KU.

En la Tabla V se muestra el valor de la varianza media de la red resultante optimizada con KO y KU para los 21 y 42 puntos. Tanto al duplicar como al triplicar la red, la menor varianza media fue obtenida con KU, este valor fue 4% menor al obtenido con KO al densificar los primeros 21 puntos y 18% menor al densificar con los 42 puntos. La red resultante redujo significativamente la varianza de la red actual en un 55% y 64% con KO y KU, respectivamente.

**TABLA V**  
VARIANZA MEDIA OBTENIDA AL DENSIFICAR LA RED CON KO Y KU.

RED	VMKO	VMKU
Duplicada	7289.3	7054.9
Triplicada	6655.1	5421.8

**IV. CONCLUSIONES**

En regiones donde no se cuenta con información completa de la estructura espacial de la variabilidad de la precipitación, el uso de información auxiliar derivada de imágenes satelitales resulta una opción viable y confiable para el diseño y optimización de redes de monitoreo de precipitación. Con el propósito de identificar nuevos sitios de monitoreo para la precipitación en una cuenca Andina del sur del Ecuador, imágenes satelitales de variables atmosféricas y topográficas fueron empleadas para la densificación de la red mediante kriging universal.

El análisis de regresión simple y multivariado entre la imagen de precipitación y las distintas variables auxiliares mostraron mayores correlaciones entre la precipitación y la longitud, la FN y la elevación. Estos resultados concuerdan con Buytaert et al. (2006) y Campozano et al. (2016) quienes han reportado una influencia de las variables geográficas, la elevación

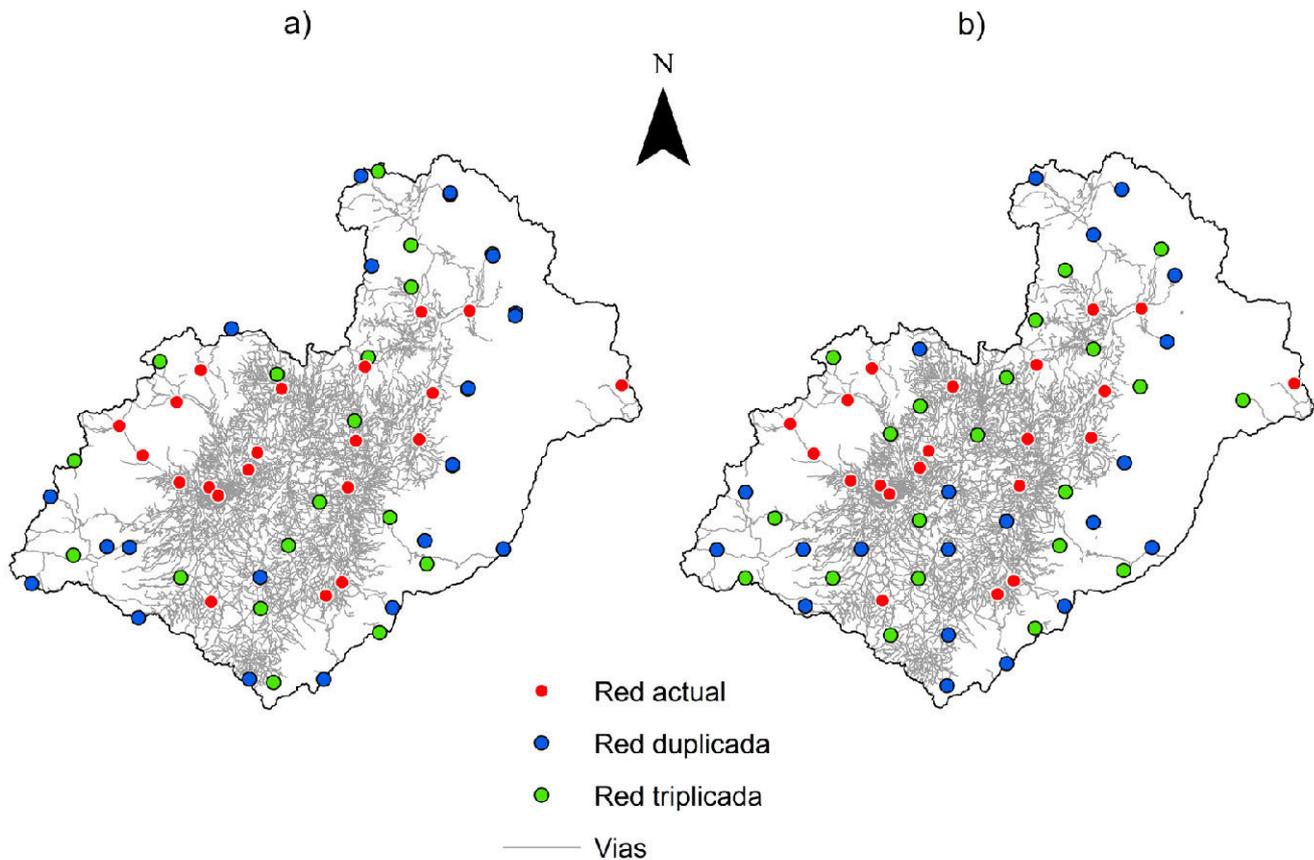


Figura 6. Ubicación de los nuevos lugares de monitoreo de precipitación. a) Red densificada con KO y b) red densificada con KU.

y de la dinámica de nubosidad en la variabilidad espacial y temporal de la precipitación en la zona de estudio. Por otra parte, la menor correlación fue encontrada con el aspecto y la TSN. A pesar de que se esperaba una buena correlación con la precipitación y TSN, esta no fue encontrada para la zona de estudio debido a las características orográficas y convectivas de la precipitación en la cuenca del Paute (Ward et al., 2011). El análisis multivariado indicó una interacción entre la elevación y VAA, la pendiente y la FN, y el VAA y la FN.

Mediante el análisis de variograma los tres modelos fueron evaluados con el fin de seleccionar el mejor modelo para la optimización de la red de precipitación. De esta manera, la red de diseño fue optimizada con el VAA la FN y la longitud como variables auxiliares mediante KU.

Los puntos resultantes de la optimización se ubicaron por todo el territorio cerca de las vías de acceso y estos presentaron una menor varianza en comparación con KO. Esta mejora en el muestreo mediante KU se debe a que este método optimiza el muestreo en dos componentes, tanto en el espacio geográfico como el de atributos. Para minimizar el primer componente, los puntos de muestreo deben cubrir lo más posible el espacio geográfico; esto explica la distribución uniforme de los puntos de muestreo que se observan en la Figura 6. Para minimizar el segundo componente, los puntos de muestreo deben cubrir lo máximo posible el espacio de atributos, de manera que las estimaciones de los coeficientes de regresión lineal sean más exactos (Brus & Heuvelink, 2007). Para mostrar de forma más clara la optimización de este úl-

timo componente, gráficos de la distribución de probabilidad de los puntos muestreados como el de toda la imagen satelital de precipitación se muestran en la Figura 7. Se observa en la Figura 7 que la forma de la curva de los puntos muestreados con KU se acerca más a la forma de la curva de toda la imagen satelital de la precipitación captada por TRMM. Esto corrobora la mayor representatividad de los puntos obtenidos por KU que con KO.

La red propuesta por KU puede ser usada como guía para una densificación paulatina de la red duplicándola en primera instancia hasta llegar al número óptimo de la misma (63 puntos) o puede ser usada también para la reubicación de otros puntos de monitoreo ya existentes en la zona pertenecientes a otras instituciones.

Sin embargo, es necesario analizar la relación de la precipitación con variables a escalas más pequeñas como la rugosidad del terreno, la temperatura en la superficie de la tierra, el contenido de humedad en el suelo, el albedo y el Índice de Vegetación Normalizado (NDVI) los cuales pueden ayudar a mejorar las estimaciones de precipitación y por ende a una mejor identificación de los sitios de muestreo (Alexakis & Tsanis, 2016; Fang et al., 2013). Además, se necesitan más investigaciones para establecer pautas para seleccionar adecuadamente predictores a partir de datos de teledetección y conjuntos de datos auxiliares que podrían ser de interés, especialmente para modelar conjuntos de datos correspondientes a diferentes escalas de tiempo (Bajat et al., 2013).

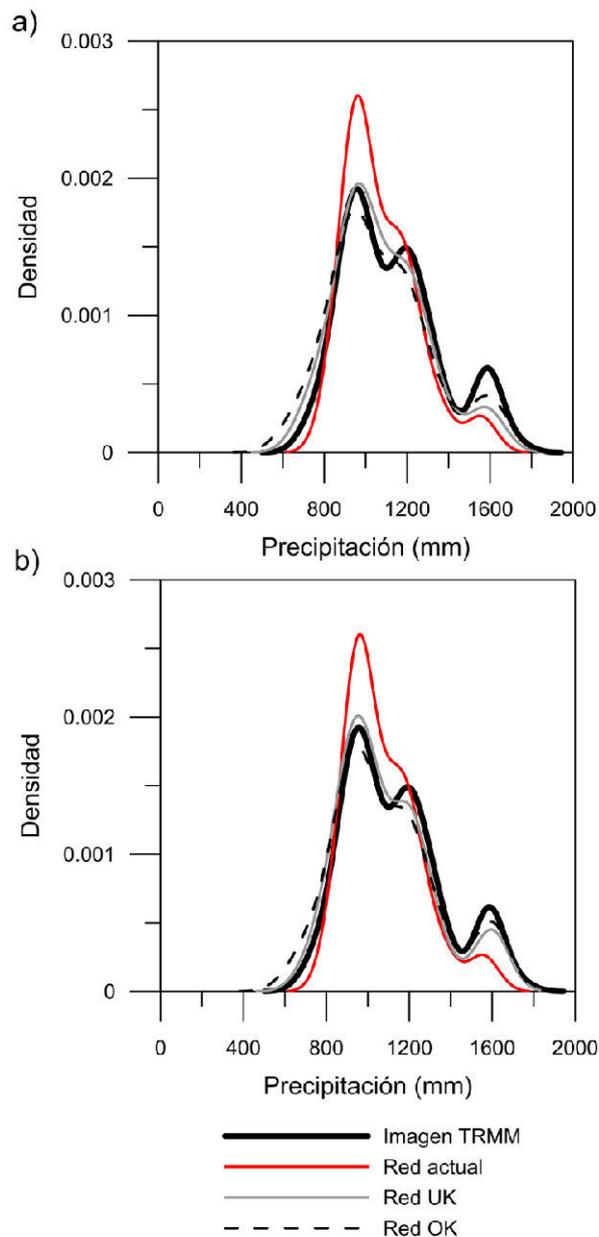


Figura 7. Comparación de la distribución de densidad de los atributos de los puntos de la red densificada y de la distribución de densidad de la imagen de precipitación TRMM. Densificación con: a) 21 puntos (red duplicada) y b) 42 puntos (red triplicada).

#### AGRADECIMIENTOS

El presente estudio ha sido financiado por la DIUC - Universidad de Cuenca a través del proyecto. "Optimización de muestreo espacial de la precipitación con geoestadística multivariada".

#### REFERENCIAS

- Adhikary Kumar, S., Gokhan Yilmaz, A., & Muttill, N. (2014). Optimal design of rain gauge network in the Middle Yarra River catchment, Australia. *Hydrological Processes*, 29(11), 2582-2599. <http://doi.org/10.1002/hyp>
- Baume, O. P., Gebhardt, a., Gebhardt, C., Heuvelink, G. B. M., & Pilz, J. (2011). Network optimization algorithms and scenarios in the context of automatic mapping. *Computers and Geosciences*, 37(3), 289-294. <http://doi.org/10.1016/j.cageo.2010.04.014>
- Bostan, P. a., Heuvelink, G. B. M., & Akyurek, S. Z. (2012). Comparison of regression and kriging techniques for mapping the average annual precipitation of Turkey. *International Journal of Applied Earth Observation and Geoinformation*, 19(1), 115-126. <http://doi.org/10.1016/j.jag.2012.04.010>

- Brus, D. J., & Heuvelink, G. B. M. (2007). Optimization of sample patterns for universal kriging of environmental variables. *Geoderma*, 138(1-2), 86-95. <http://doi.org/10.1016/j.geoderma.2006.10.016>
- Buytaert, W., Celleri, R., Willems, P., Bièvre, B. De, & Wyseure, G. (2006). Spatial and temporal rainfall variability in mountainous areas: A case study from the south Ecuadorian Andes. *Journal of Hydrology*, 329(3-4), 413-421. <http://doi.org/10.1016/j.jhydrol.2006.02.031>
- Camposano, L., Célleri, R., Trachte, K., Bendix, J., & Samaniego, E. (2016). Rainfall and Cloud Dynamics in the Andes: A Southern Ecuador Case Study. *Advances in Meteorology*, 2016. <http://doi.org/10.1155/2016/3192765>
- Camposano, L., Tenelanda, D., Sanchez, E., Samaniego, E., & Feyen, J. (2016). Comparison of Statistical Downscaling Methods for Monthly Total Precipitation: Case Study for the Paute River Basin in Southern Ecuador. *Advances in Meteorology*, 2016(February). <http://doi.org/10.1155/2016/6526341>
- Celleri, R., Willems, P., Buytaert, W., & Feyen, J. (2007). Space-time rainfall variability in the Paute basin, Ecuadorian Andes. *Hydrological Processes*, 21(24), 3316-3327. <http://doi.org/10.1002/hyp.6575>
- Chebbi, A., Bargaoui, Z. K., & Cunha, C. (2011). Optimal Extension of Rain Gauge Monitoring Network for Rainfall Intensity and Erosivity Index Interpolation. *Journal of Hydrologic Engineering*, 16(August), 665-676. [http://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000353](http://doi.org/10.1061/(ASCE)HE.1943-5584.0000353)
- Chebbi, A., Bargaoui, Z. K., & da Conceição Cunha, M. (2013). Development of a method of robust rain gauge network optimization based on intensity-duration-frequency results. *Hydrology and Earth System Sciences*, 17(10), 4259-4268. <http://doi.org/10.5194/hess-17-4259-2013>
- Cheng, K. S., Lin, Y. C., & Liou, J. J. (2008). Rain-gauge network evaluation and augmentation using geostatistics. *Hydrological Processes*, 22(14), 2554-2564. <http://doi.org/10.1002/hyp.6851>
- Condom, T., Rau, P., & Espinoza, J. C. (2010). Correction of TRMM 3B43 monthly precipitation data over the mountainous areas of Peru during the period 1998-2007. *Hydrological Processes*, 25(12), 1924-1933. <http://doi.org/10.1002/hyp.7949>
- Feki, H., & Slimani, M. (2015). A comparison of three geostatistical procedures for rainfall network optimization. *IAHS-AISH Proceedings and Reports*, 366(June 2014), 166-167. <http://doi.org/10.5194/piahs-366-166-2015>
- Feki, H., Slimani, M., & Cudennec, C. (2016). Geostatistically based optimization of a rainfall monitoring network extension: case of the climatically heterogeneous Tunisia. *Hydrology Research*, 1-28. <http://doi.org/10.2166/nh.2016.256>
- Ge, Y., Wang, J. H., Heuvelink, G. B. M., Jin, R., Li, X., & Wang, J. F. (2014). Sampling design optimization of a wireless sensor network for monitoring ecohydrological processes in the Babao River basin, China. *International Journal of Geographical Information Science*, 29(1), 92-110. <http://doi.org/10.1080/13658816.2014.948446>
- Goovaerts, P. (2000). Geostatistical approaches for incorporating elevation into the spatial interpolation of rainfall. *Journal of Hydrology*, 228(1-2), 113-129. [http://doi.org/10.1016/S0022-1694\(00\)00144-X](http://doi.org/10.1016/S0022-1694(00)00144-X)
- Hengl, T. (2009). *A Practical Guide to Geostatistical Mapping*. Government Publications Review (Vol. 13). [http://doi.org/10.1016/0277-9390\(86\)90082-8](http://doi.org/10.1016/0277-9390(86)90082-8)
- Hengl, T., Heuvelink, G. B. M., Tadić, M. P., & Pebesma, E. J. (2012). Spatio-temporal prediction of daily temperatures using time-series of MODIS LST images. *Theoretical and Applied Climatology*, 107(1-2), 265-277. <http://doi.org/10.1007/s00704-011-0464-2>
- Huffman, G. J., Bolvin, D. T., Nelkin, E. J., Wolff, D. B., Adler, R. F., Gu, G., ... Stocker, E. F. (2007). The TRMM Multisatellite Precipitation Analysis (TMPA): Quasi-Global, Multiyear, Combined-Sensor Precipitation Estimates at Fine Scales. *Journal of Hydrometeorology*, 8(1), 38-55. <http://doi.org/10.1175/JHM560.1>
- Mahmud, M. R., Numata, S., Matsuyama, H., Hosaka, T., & Hashim, M. (2015). Assessment of effective seasonal downscaling of TRMM precipitation data in Peninsular Malaysia. *Remote Sensing*, 7(4), 4092-4111. <http://doi.org/10.3390/rs70404092>
- Melles, S. J., Heuvelink, G. B. M., Twenhöfel, C. J. W., van Dijk, a., Hiemstra, P. H., Baume, O., & Stöhlker, U. (2011). Optimizing the spatial pattern of networks for monitoring radioactive releases. *Computers and Geosciences*, 37(3), 280-288. <http://doi.org/10.1016/j.cageo.2010.04.007>
- Michaelides, S., Levizzani, V., Anagnostou, E., Bauer, P., Kasparis, T., & Lane, J. E. (2009). Precipitation : Measurement , remote sensing , climatology and modeling. *Atmospheric Research*, 94(4), 512-533. <http://doi.org/10.1016/j.atmosres.2009.08.017>
- Ochoa, a., Pineda, L., Crespo, P., & Willems, P. (2014). Evaluation of TRMM 3B42 precipitation estimates and WRF retrospective precipitation simulation over the Pacific-Andean region of Ecuador and Peru. *Hydrology and Earth System Sciences*, 18(8), 3179-3193. <http://doi.org/10.5194/hess-18-3179-2014>
- Padrón, R. S., Wilcox, B. P., Crespo, P., & Célleri, R. (2015). Rainfall in the Andean Páramo: New Insights from High-Resolution Monitoring in Southern Ecuador. *Journal of Hydrometeorology*, 16(3), 985-996. <http://doi.org/10.1175/JHM-D-14-0135.1>
- Pardo-Igúzquiza, E. (1998). Optimal selection of number and location of rainfall gauges for areal rainfall estimation using geostatistics and simulated annealing. *Journal of Hydrology*, 210(1-4), 206-220. [http://doi.org/10.1016/S0022-1694\(98\)00188-7](http://doi.org/10.1016/S0022-1694(98)00188-7)
- Pebesma, E. J. (2004). Multivariable geostatistics in S: The gstat package. *Computers and Geosciences*, 30(7), 683-691. <http://doi.org/10.1016/j.cageo.2004.03.012>
- Shaghaghian, M. R., & Abedini, M. J. (2013). Rain gauge network design using coupled geostatistical and multivariate techniques. *Scientia Iranica*, 20(2), 259-269. <http://doi.org/10.1016/j.scient.2012.11.014>
- Tapiador, F. J., Turk, F. J., Petersen, W., Hou, A. Y., Garcia-Ortega, E., Machado, L. a T., ... de Castro, M. (2012). Global precipitation measurement: Methods, datasets and applications. *Atmospheric Research*, 104-105, 70-97. <http://doi.org/10.1016/j.atmosres.2011.10.021>
- Vuille, M., Bradley, R. S., Keimig, F., Vuille, M., Bradley, R. S., & Keimig, F. (2000). Climate Variability in the Andes of Ecuador and Its Relation to Tropical Pacific and Atlantic Sea Surface Temperature Anomalies. [http://dx.doi.org/10.1175/1520-0442\(2000\)013<2520:CVITAO>2.0.CO;2](http://dx.doi.org/10.1175/1520-0442(2000)013<2520:CVITAO>2.0.CO;2), (Hastenrath 1981), 2520-2535.