

## **Validación de las estimaciones de precipitación con CHIRPS e IRE/IDEAM**

Alexander Martinez Pedraza  
Julieta Serna Cuenca

## Contenido

|      |                                                                                                 |    |
|------|-------------------------------------------------------------------------------------------------|----|
| 1.   | Introducción.....                                                                               | 3  |
| 2.   | Datos.....                                                                                      | 4  |
| 2.1. | Datos de precipitación.....                                                                     | 4  |
| 2.2. | Estimaciones de precipitación basadas en CHIRPS.....                                            | 6  |
| 2.3. | Estimaciones de precipitación basadas en IRE/IDEAM .....                                        | 7  |
| 3.   | Metodología .....                                                                               | 7  |
| 3.1. | Validación estadística.....                                                                     | 7  |
|      | Prueba de diferencias de medianas.....                                                          | 8  |
|      | Prueba de comparaciones de distribución .....                                                   | 9  |
|      | Coeficiente de correlación de Spearman .....                                                    | 9  |
|      | Error absoluto medio.....                                                                       | 10 |
|      | Coeficiente de Eficiencia Modificado.....                                                       | 10 |
| 4.   | Resultados .....                                                                                | 10 |
| 4.1. | Series de datos de precipitación mensual en el periodo 1981-2010 .....                          | 10 |
| 4.2. | Series de datos de precipitación asociadas a cada mes del año (12) en el periodo 1981-2010..... | 16 |
| 5.   | Conclusiones.....                                                                               | 22 |
| 5.1. | Validación series mensuales.....                                                                | 22 |
| 5.2. | Validación series asociadas a cada mes del año .....                                            | 22 |
| 6.   | Recomendaciones .....                                                                           | 23 |
| 7.   | Referencias .....                                                                               | 24 |

# 1. Introducción

Los análisis de la variabilidad y las tendencias climáticas requieren series de precipitación históricas de largo periodo y consistentes temporalmente. Las aplicaciones que utilizan datos de lluvia para pronóstico o para modelar el impacto de la variabilidad y el cambio del clima en diferentes actividades socioeconómicas, también requieren datos de series cronológicas de la atmósfera a largo plazo con altas resoluciones temporales y espaciales.

Tradicionalmente, las mediciones de precipitación de las estaciones meteorológicas convencionales son fuente primaria de dichos datos climáticos. Sin embargo, los registros históricos de las observaciones de estaciones son inadecuados en muchas partes del mundo, puesto que las redes son dispersas y en muchos casos en declive o inexistentes. Por lo tanto, los productos de lluvia derivados de satélites, se han convertido en una alternativa de complemento y reemplazo de observaciones in situ (Dinku et al., 2018). No obstante, como se presenta en (Dinku et al., 2018) para regiones de topografía compleja como la de Etiopía, las estimaciones satelitales de precipitación presentan importantes desafíos, ya que varían enormemente con la topografía y los patrones de lluvia estacional. Es posible entonces, que Colombia, bajo sus condiciones geográficas complejas, presente estimaciones de lluvia con baja calidad.

Actualmente en el Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM), como insumo de predicción climática y análisis agrometeorológico, se hace uso de las estimaciones del Climate Hazards Group Infrared Precipitation with Stations (CHIRPS) (Funk et al., 2014; 2015). Esta base de datos de precipitación presenta una resolución espacial de  $0.05^{\circ} \times 0.05^{\circ}$  (~5.5 kmX~5.5 km) y resolución temporal (diaria, pentadal, decadal y mensual) desde 1981.

En el contexto operativo, los resultados de los pronósticos generados en la Subdirección de Meteorología, utilizando CHIRPS como variable respuesta, mediante el software Climate Prediction Tool (CPT) desarrollado por (Mason y Tippett, 2016), sugieren diversos cuestionamientos acerca de la calidad de los datos estimados CHIRPS, puesto que se evidencian diferencias significativas con respecto a los resultados generados con los datos registrados en las estaciones meteorológicas. De hecho, en el trabajo de Funk et al. (2015) encontraron un desempeño deficiente en la estimación de las cantidades de precipitación con CHIRPS para Colombia, luego de evaluar diferentes productos de estimación satelital.

En este contexto, el objetivo de la presente investigación consiste en evaluar las estimaciones CHIRPS, comparando sus valores frente a los datos observados de 1.052 estaciones convencionales de la red de estaciones del IDEAM en el periodo

climatológico 1981 – 2010. Las estaciones de validación fueron seleccionadas teniendo en cuenta que sus series temporales de precipitación cumplieran criterios de completitud y homogeneidad. Adicionalmente, se realizó la comparación de los datos observados frente al conjunto de datos CHIRPS e IRE/IDEAM siendo éste último una interpolación corregida de CHIRPS.

En los diferentes estudios realizados para la evaluación de las estimaciones CHIRPS (Ayehu, Tadesse, Gessesse, y Dinku, 2018; Dinku et al., 2018; Funk et al., 2015; Paredes-Trejo, Barbosa, Peñaloza-Murillo, Moreno, y Farías, 2016; Paredes-Trejo, Barbosa, y Lakshmi Kumar, 2017; Verdin, Funk, Rajagopalan, y Kleiber, 2016), predomina el uso de diferentes métricas numéricas, como el coeficiente de correlación de Pearson ( $r$ ), del error absoluto medio (MAE, por sus Siglas en inglés), el coeficiente de eficiencia de Nash-Sutcliffe y el sesgo porcentual. Cabe aclarar que en el presente trabajo, se realizó la validación con el coeficiente de correlación de Spearman ( $\rho$ ), ya que no se garantiza la normalidad en la distribución de los datos, el MAE y el Coeficiente de Eficiencia Modificado (CEM) expuesto en (Legates y McCabe Jr., 1999) que es una modificación del Coeficiente de Eficiencia de Nash – Sutcliffe; adicionalmente, se realizaron pruebas de hipótesis sobre la igualdad de las medianas y distribuciones, que respectivamente son la prueba del rango signado de Wilcoxon y la prueba de Kolmogorov – Smirnov. No se presenta la prueba de igualdad de medias ya que la prueba  $t$  – student parte del supuesto que la distribución de los conjuntos de datos se distribuye o se aproximan a la distribución normal, este supuesto no se garantiza para la variable precipitación.

## 2. Datos

### 2.1. Datos de precipitación

Las series de tiempo de precipitación mensual corresponden a los datos registrados en estaciones convencionales de la Red Nacional de Estaciones, almacenadas en el banco de datos del Sistema de Información Hidrológica y Meteorológica (SISDHIM) del IDEAM.

La selección de las estaciones para la evaluación se realiza bajo la verificación de los siguientes criterios:

1. Identificar un mínimo de 25 datos en el periodo 1981 – 2010 (15% de datos faltantes) en las series de los meses calendario<sup>1</sup>.

---

<sup>1</sup> Las **series de los meses calendario** hacen referencia a las series que tienen información solo de un mes específico, por ejemplo: la serie enero contiene la información solo de ese mes en el periodo observado, por lo

## 2. No rechazar la hipótesis de homogeneidad.

A las 1.404 series que cumplieron con el criterio No. 1, se les realizó la prueba de homogeneidad normal estándar (SNHT, por sus siglas en inglés). Las pruebas de homogeneidad se realizan agrupando las series según la ubicación de la estación en las diferentes regiones pluviométricamente homogéneas definidas por Guzmán, Ruíz, y Cadena, (2014), que se distribuyen como se presenta en la Tabla 1; asimismo, dentro de cada grupo se realiza un análisis de clasificación a la matriz de correlaciones, de tal manera que las pruebas de homogeneidad se efectúan teniendo en cuenta información de estaciones cercanas y altamente correlacionadas. Finalmente, se obtienen 1.052 series de estaciones para la evaluación de las estimaciones CHIRPS, cuya distribución geográfica se muestra en la Figura 1.

Tabla 1. Distribución de estaciones según las regiones pluviométricamente homogéneas.

| <b>Región pluviométricamente homogénea</b> | <b>No. series</b> |
|--------------------------------------------|-------------------|
| Caribe - Cesar                             | 194               |
| Catatumbo                                  | 48                |
| Medellín - Carare - Opón                   | 94                |
| Norte Amazonía                             | 71                |
| Orinoquía Occidental                       | 124               |
| Orinoquía Oriental                         | 9                 |
| Pacífico Norte y Central                   | 40                |
| Patía y Mira                               | 11                |
| Risaralda - Saldaña                        | 145               |
| San Andrés                                 | 3                 |
| Sinú - San Jorge - Porce                   | 172               |
| Sogamoso - Lebrija - Altiplano             | 231               |
| Sur Magdalena Cauca                        | 255               |
| Trapezio Amazónico                         | 7                 |

---

cual, ellas tienen periodicidad anual, no confundir con las series mensuales cuya periodicidad es mensual. En lo que sigue de este texto se referenciarán como series de los meses.




Figura 1. Distribución de las estaciones seleccionadas para el análisis de precipitación y número de días con lluvia

## 2.2. Estimaciones de precipitación basadas en CHIRPS

El conjunto de estimaciones mensuales de precipitación CHIRPS (versión 2) se obtuvo del repositorio (<http://iridl.ldeo.columbia.edu/SOURCES/UCSB/CHIRPS/>), con la información del periodo 1981 – 2010.

El conjunto de datos CHIRPS fue diseñado explícitamente para monitorear la sequía agrícola y el cambio ambiental global sobre la tierra (Funk et al., 2015), el algoritmo CHIRPS combina tres fuentes de datos principales: (a) la climatología de Precipitación del grupo de Riesgos Climáticos (CHPclim, por sus siglas en inglés), a una resolución de latitud / longitud de  $0.05^\circ$ , estimada para cada mes en función de los datos de la estación, las observaciones satelitales promediadas, la elevación,

latitud y longitud (Funk et al., 2015); (b) estimaciones de precipitación satelital basadas en infrarrojo térmico (IRP); y (c) mediciones in situ de pluviómetro. El CHPclim se distingue de otras climatologías de precipitación, en el sentido que utiliza campos satelitales promedio de lluvia a largo plazo como una guía para obtener superficies climatológicas (Funk et al., 2015). El producto presenta una resolución espacial de  $0.05^\circ$  desde  $50^\circ\text{S}$  a  $50^\circ\text{N}$  (a lo largo de todas las longitudes) con un registro de precipitación mensual desde 1981 hasta el presente.

### **2.3. Estimaciones de precipitación basadas en IRE/IDEAM**

El conjunto de datos IRE/IDEAM es una interpolación CHIRPS corregida mediante la herramienta de interpolación asistida en segundo plano para superficies climáticas mejoradas (BASICS, por sus siglas en inglés), incorporada en el software GeoCLIM (Magadzire y Pedreros, 2008), donde se combinan los ráster de las estimaciones CHIRPS con datos de las 2.046 estaciones utilizadas para el cálculo de la climatología nacional oficial de precipitación del IDEAM.

La base de datos del IRE/IDEAM, solo tiene estimaciones para la región continental de Colombia, por lo cual no se puede realizar comparaciones con las áreas insulares. Cabe mencionar, que el ráster que contiene la información de este conjunto de datos, cubre espacialmente el área de 1.039 estaciones, siendo 1.049 disponibles para el análisis en el territorio continental.

## **3. Metodología**

### **3.1. Validación estadística**

La validación se realiza para la escala mensual, pero, dividiendo el análisis dependiendo del tipo de serie temporal, para:

1. Series de datos de precipitación mensual en el periodo 1981-2010 por cada estación.
2. Series de datos de precipitación asociadas a cada mes del año (12) en el periodo 1981-2010 por cada estación.

Se aplicó un análisis de punto a píxel para comparar los datos de precipitación de series de tiempo observados (estaciones seleccionadas) con la celda respectiva de la cuadrícula como se presenta en (Zambrano-Bigiarini, Nauditt, Birkel, Verbist, y Ribbe, 2017). Es decir, para cada estación y mes, las series temporales de datos observados en los pluviómetros seleccionados (Figura 1) se compararon con el píxel CHIRPS correspondiente. Se utilizaron dos (2) pruebas de hipótesis y tres (3)

métricas numéricas. La prueba del rango asignado de Wilcoxon y la de Kolmogorov – Smirnov descritas en (Corzo, 2005), se realizan para hacer los contrastes de las hipótesis de igualdad de medianas y distribución entre los datos observados y los datos estimados, . El coeficiente de correlación de Spearman ( $r_s$ ), el MAE y el Coeficiente de Eficiencia Modificado (CEM), son. métricas que permiten evaluar la habilidad de las estimaciones.

## Prueba de diferencias de medianas

La prueba de rangos signados de Wilcoxon es una prueba no paramétrica, utilizada en lugar de la t de Student cuando los datos no cumplen el requisito de normalidad, como en el caso de la precipitación. Se utiliza para comprobar si la tendencia central (la mediana) de dos muestras es la misma.

Con  $X$  y  $Y$  las variables sujetas a la comparación, para esta prueba se define  $d_i = x_i - y_i$ , la diferencia entre la pareja  $i$ -ésima; si alguna de estas diferencias es nula la pareja correspondiente se elimina del análisis, de forma que el número de diferencias es  $n$ . La hipótesis se plantea como  $H_0: \theta = 0$ , donde  $\theta$  es la diferencia entre las medianas de los dos conjuntos.

A continuación, se asignan rangos desde 1 hasta  $n$  atendiendo únicamente al valor absoluto de las  $d_i$  y se suman los rangos correspondientes a las diferencias positivas y a las diferencias negativas por separado. Si la hipótesis nula es cierta,  $X$  y  $Y$  tienen el mismo valor central y es de esperar que los rangos se distribuyan aleatoriamente entre las diferencias positivas y negativas y, por tanto, que ambas sumas de rangos sean aproximadamente iguales. El estadístico de prueba,  $T$ , es la menor de las dos sumas de rangos. Cuando  $n > 15$  la distribución muestral de  $T$  bajo el supuesto de que  $H_0$  es cierta se aproxima a una normal de parámetros:

$$\mu_T = \frac{n(n+1)}{4} \quad \sigma_T^2 = \frac{n(n+1)(2n+1)}{24}$$

El estadístico de prueba es el valor  $Z$ :

$$Z = \frac{T - \mu_T}{\sigma_T}$$

Que se distribuye según una normal estándar, el nivel de significancia para el contraste de la hipótesis es  $\alpha = 0.05$ . La prueba de Wilcoxon se realiza a una y dos vías de la siguiente manera:

1. Dos vías ( $H_0: Mediana_{Est} = Mediana_{Obs}$ ): Identificando las estaciones donde la mediana de las observaciones no difiere estadísticamente de la mediana de las estimaciones.
2. Una vía (por debajo  $H_0: Mediana_{Est} \leq Mediana_{Obs}$  y por encima  $H_0: Mediana_{Est} \geq Mediana_{Obs}$ ): Identificando en qué puntos hay indicios para afirmar que los modelos están sobreestimando o subestimando la mediana.

## Prueba de comparaciones de distribución

Para verificar estadísticamente si la distribución de los dos conjuntos de datos es semejante, se emplea el estadístico Kolmogorov – Smirnov, que mide la distancia entre las distribuciones; formalmente lo que se plantea es un contraste de la hipótesis.

$$H_0: F_X = F_Y$$

Donde  $F_x$  es la distribución de las observaciones y  $F_y$  es la distribución de los datos estimados. El nivel de significancia para el contraste de la hipótesis es  $\alpha = 0.05$ . El contraste se basa en las diferencias entre las frecuencias relativas acumuladas, el estadístico de prueba es:

$$D_n = \max |F_{X_n}(x) - F_{Y_n}(y)|$$

Donde  $F_{X_n}(x)$  es la frecuencia relativa acumulada de las observaciones y  $F_{Y_n}(x)$  es la frecuencia relativa acumulada de los datos estimados.

## Coeficiente de correlación de Spearman

Esta medida no paramétrica mide la relación lineal entre dos variables, “este coeficiente, propuesto por Spearman en 1904, es una versión del coeficiente de correlación de Pearson, pero calculado sobre una sucesión transformada de rangos en las dos variables” (Corzo, 2005, p. 78) y puede ser expresado de la siguiente forma:

$$r_s = 1 - \frac{6}{n(n^2 - 1)} \sum_{i=1}^n d_i^2$$

Donde  $d_i$  es la diferencia entre los rangos de las dos variables comparadas. Para la interpretación es suficiente tener en cuenta que los valores de  $r_s$  cercanos a uno (1) indican asociación positiva o directa, los valores cercanos a menos uno (-1) indican asociación negativa o inversa y los valores cercanos a cero (0) revelan que no hay ningún tipo de asociación.

## Error absoluto medio

Para calcular la bondad de los datos estimados, se propone el uso del error absoluto medio (MAE). Esta métrica registra en unidades reales el nivel de acuerdo general entre los conjuntos de datos observados y modelados. Es una métrica no negativa que no tiene límite superior y para un modelo perfecto el resultado sería cero (0). No proporciona información sobre subestimación o sobreestimación, no pondera hacia eventos de magnitud alta o baja, sino que evalúa todas las desviaciones de los valores observados, manera igual como independientemente del signo.

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - y_i|$$

## Coeficiente de Eficiencia Modificado

El Coeficiente de Eficiencia Modificado (CEM) expuesto en (Legates y McCabe Jr., 1999) es una modificación del Coeficiente de Eficiencia de Nash – Sutcliffe, esta es una métrica muy usada en hidrología, que permite comparar el Error Absoluto Medio con el promedio de los errores absolutos de las observaciones con respecto a la media. Esta medida tiene valor máximo uno (1) y no tiene cota inferior, el valor máximo corresponde al modelo perfecto, el valor de cero (0) indica que no hay diferencia entre el modelo y la media de las observaciones, y los valores negativos indican que el modelo no es apropiado.

$$CEM = 1 - \frac{\sum_{i=1}^n |x_i - y_i|}{\sum_{i=1}^n |x_i - \bar{x}|}$$

Donde  $x_i$  es el valor observado,  $y_i$  es el valor estimado y  $\bar{x}$  la media de los valores observados.

## 4. Resultados

### 4.1. Series de datos de precipitación mensual en el periodo 1981-2010

Para las tres estaciones insulares ubicadas en el Caribe, el coeficiente de correlación de Spearman está por debajo de 0.4, por lo que se puede afirmar que CHIRPS no estima bien para San Andrés y Providencia. Esta aseveración se confirma con los resultados de las pruebas de Wilcoxon y Kolmogorov – Smirnov donde se rechazan las pruebas de igualdad de mediana y distribución. En adelante se presentarán los resultados de las 1.049 estaciones emplazadas en el territorio continental colombiano. Con el propósito de comparar el grado de asociación de las series estimadas con las observadas, en la Tabla 2 se presentan las frecuencias del

coeficiente de correlación de Spearman. Se destaca que las series de estimadas IRE están mejor correlacionadas con las observaciones que las CHIRPS, dado que los valores de  $r_s \geq 0.8$  están en el 92,6% de los casos para IRE y en el 78% para CHIRPS.

Tabla 2. Resultados del coeficiente de correlación de Spearman para la precipitación en las 1.052 estaciones

|                      | CHIRPS | IRE |
|----------------------|--------|-----|
| $r_s < 0.4$          | 2      | 2   |
| $0.4 \leq r_s < 0.6$ | 16     | 0   |
| $0.6 \leq r_s < 0.8$ | 213    | 66  |
| $r_s \geq 0.8$       | 818    | 971 |
| NA                   | 0      | 10  |

En la Tabla 3 se presentan los resultados de los contrastes de las tres pruebas de hipótesis sobre la mediana, para las estimaciones CHIRPS 438 (42%) estaciones no rechazan la hipótesis de igualdad, 471 (45%) dan evidencia de sobreestimación de la mediana y 200 (19%) de subestimación, la distribución de las estaciones que no rechazan la igualdad (Figura 2, izquierda) muestran una predominancia en el sur y centro de la región Caribe, en la Orinoquía, en el Magdalena Medio y en un sector del departamento del Tolima. Las estaciones con sobreestimación (Figura 2, centro) se distribuyen a través de todo el territorio (excluyendo las zonas de igualdad), destacándose la península de la Guajira; mientras que las estaciones donde se subestima (Figura 2, derecha) tienen un patrón de distribución sin agregaciones sobresalientes.

Los contrastes de las pruebas de Wilcoxon para las estimaciones IRE resultan en 519 (50%) estaciones que no rechazan la hipótesis de igualdad de mediana, 425 (41%) dan evidencia para decir que sobreestiman y 148 (14%) que subestiman. La distribución de las estaciones que evidencian la igualdad o sobreestiman tienen una distribución semejante a las del caso CHIRPS (Figura 3, izquierda y centro) mientras que las estaciones que tienen evidencia de subestimación tienen mayor presencia en la región Andina, especialmente en la cordillera oriental, en el departamento de Boyacá (Figura 3, derecha).

En los mapas de las pruebas de dos vías (Igualdad), se utilizó una paleta de colores tipo semáforo, los verdes indican el no rechazo de la hipótesis. En tanto que para los mapas de las pruebas a una vía (sobrestimación o subestimación), se utiliza una paleta de colores similar al índice de precipitación (IDEAM), es decir, los colores azules, indican sobreestimación y los naranjas subestimación.

Tabla 3. Resultado prueba de Wilcoxon series mensuales 1981 - 2010

|            | Test Wilcoxon                        |     |                                         |     |                                         |     |
|------------|--------------------------------------|-----|-----------------------------------------|-----|-----------------------------------------|-----|
|            | $H_0: Mediana_{Est} = Mediana_{Obs}$ |     | $H_0: Mediana_{Est} \leq Mediana_{Obs}$ |     | $H_0: Mediana_{Est} \geq Mediana_{Obs}$ |     |
|            | CHIRPS                               | IRE | CHIRPS                                  | IRE | CHIRPS                                  | IRE |
| Rechaza    | 611                                  | 520 | 471                                     | 425 | 200                                     | 148 |
| No rechaza | 438                                  | 519 | 578                                     | 614 | 849                                     | 891 |

*Test de Wilcoxon (CHIRPS vs. Obs.)*




Figura 2. Distribución de los contrastes (Wilcoxon) CHIRPS Vs. Obs.

*Test de Wilcoxon (IRE vs. Obs.)*




Figura 3. Distribución de los contrastes (Wilcoxon) IRE Vs. Obs.

Para evaluar si las estimaciones mantienen las distribuciones de las observaciones, se realizaron los contrastes de la prueba Kolmogorov – Smirnov; los resultados se presentan en la Tabla 4 y su distribución en la Figura 4. De las estimaciones CHIRPS solo 189 (18%) estaciones no rechazan la hipótesis de igualdad de distribución y se destaca la ubicación de ellas en el departamento del Vichada; mientras que en las estimaciones IRE 465 (45%) no rechazan la hipótesis de igualdad, la distribución de estos puntos muestra un buen comportamiento en las regiones Orinoquía, Amazonía y piedemonte Llanero, y unas interacciones predominantes en el departamento de Santander, sur de la cordillera oriental y sur de la región Caribe.

Tabla 4. Resultado prueba de Kolmogorov - Smirnov series mensuales 1981 - 2010

|            | Test Kolmogorov - Smirnov |     |
|------------|---------------------------|-----|
|            | CHIRPS                    | IRE |
| Rechaza    | 860                       | 574 |
| No rechaza | 189                       | 465 |




Figura 4. Distribución de los contrastes Prueba komogorov - Smirnov

Para calcular la bondad de los datos estimados, se utilizaron el Error Absoluto Medio (MAE, por sus siglas en inglés) y el Coeficiente de Eficiencia Modificado (CEM). En general, las estimaciones IRE tienen menor MAE que las estimaciones CHIRPS, sin embargo, tienen una distribución semejante según los percentiles (Figuras Figura 5 - Figura 6), con valores bajos en la zona media y alta de la región Caribe, igual que en el altiplano Cundiboyacense; la predominancia de valores altos se presenta sobre el corredor Pacífico, Magdalena Medio y Norte de Santander. Con base en el CEM, se evidencia que las estimaciones IRE se ajustan mejor que las estimaciones CHIRPS, ya que IRE muestra un CEM con valores mayores a 0,6 en gran parte del territorio nacional, mientras CHIRPS solo tiene un mejor comportamiento en el norte de la Orinoquía y Magdalena medio-bajo, sumado a una baja eficiencia en todo en corredor Pacífico.




Figura 5. Métricas de bondad de ajuste de las estimaciones CHIRPS.




Figura 6. Métricas de bondad de ajuste de las estimaciones IRE.

#### 4.2. Series de datos de precipitación asociadas a cada mes del año (12) en el periodo 1981-2010

El efecto de la estacionalidad se elimina cuando se trabaja con las series de los meses. En la Tabla 5, se puede observar que las correlaciones son más bajas en comparación a las obtenidas con las series mensuales, presentando un mayor porcentaje de estaciones que se encuentran en los rangos ( $r_s < 0.4$ ) y ( $0.4 \leq \rho < 0.6$ ) y disminución en los porcentajes del rango ( $r_s > 0.8$ ). De esta manera, para las estimaciones CHIRPS, los mejores meses en términos de correlación son diciembre, enero, febrero y agosto; mientras que, septiembre y julio son los menos correlacionados:

- **Diciembre:** 89% ( $r_s > 0.6$ ) y 0,6% ( $r_s < 0.4$ ).
- **Septiembre:** 77% ( $r_s > 0.6$ ) y 3% ( $r_s < 0.4$ ).

Con las estimaciones IRE de diciembre a marzo se presentan las mejores correlaciones; en contraste con los meses de octubre y julio que son los menos correlacionados:

- **Diciembre:** 96% ( $r_s > 0.6$ ) y 0,2% ( $r_s < 0.4$ ).
- **Octubre:** 90% ( $r_s > 0.6$ ) y 2% ( $r_s < 0.4$ ).

En términos espaciales en el archivo anexo “corr\_Spearman.pdf”, se presentan los mapas de la distribución de los coeficientes de correlación como el que se presenta en la Figura 7, en donde se observa la predominancia de los valores de  $r_s > 0.6$  en la región Andina, mientras que en los meses de enero, febrero y marzo los valores bajos de correlación tienen mayor agregación en la región Caribe, en abril los valores de  $r_s < 0.4$  tienen un cúmulo en la península de La Guajira, en mayo no se observa ningún patrón definido, en el bimestre junio-julio para las estimaciones CHIRPS se vuelve a presentar el agregado de correlaciones bajas de la península de La Guajira, desde agosto hasta diciembre la distribución de las correlaciones no muestra agregados por resaltar.




Figura 7. Mapas de la distribución de los coeficientes de correlación de Spearman de las observaciones frente a las estimaciones CHIRPS e IRE (enero).

Tabla 5. Resultados del Coeficiente de correlación de Spearman de las series de meses.

| Mes | Spearman CHIRPS |                      |                      |                | Spearman IRE |                      |                      |                |
|-----|-----------------|----------------------|----------------------|----------------|--------------|----------------------|----------------------|----------------|
|     | $r_s < 0.4$     | $0.4 \leq r_s < 0.6$ | $0.6 \leq r_s < 0.8$ | $r_s \geq 0.8$ | $r_s < 0.4$  | $0.4 \leq r_s < 0.6$ | $0.6 \leq r_s < 0.8$ | $r_s \geq 0.8$ |
| 1   | 38              | 123                  | 466                  | 421            | 12           | 59                   | 327                  | 640            |
| 2   | 34              | 127                  | 482                  | 405            | 19           | 46                   | 307                  | 666            |
| 3   | 38              | 171                  | 565                  | 275            | 9            | 56                   | 385                  | 589            |
| 4   | 33              | 172                  | 605                  | 239            | 10           | 72                   | 432                  | 525            |
| 5   | 27              | 177                  | 617                  | 226            | 9            | 82                   | 435                  | 513            |
| 6   | 43              | 141                  | 505                  | 360            | 15           | 75                   | 342                  | 607            |
| 7   | 39              | 182                  | 541                  | 287            | 19           | 82                   | 413                  | 525            |
| 8   | 40              | 122                  | 459                  | 428            | 13           | 61                   | 313                  | 652            |
| 9   | 32              | 211                  | 580                  | 226            | 21           | 70                   | 439                  | 509            |
| 10  | 37              | 176                  | 594                  | 242            | 20           | 81                   | 454                  | 484            |
| 11  | 20              | 153                  | 618                  | 258            | 9            | 60                   | 435                  | 535            |
| 12  | 6               | 111                  | 608                  | 324            | 2            | 40                   | 397                  | 600            |

La evaluación sobre las medianas de las estimaciones se presenta en la Tabla 6; en el caso CHIRPS la prueba de igualdad de medianas muestra que los mejores meses son febrero y marzo, donde el número de estaciones que no rechazan la hipótesis es 737 (70%) y 756 (72%) respectivamente, mientras que enero y julio son los meses con menor número de estaciones que no rechazan 640 (61%) en ambos

casos. Con respecto a la sobreestimación de la mediana, se destaca enero por presentar evidencias significativas, mientras que durante marzo se sobrestima poco. En términos de subestimación, es septiembre es el más alto, cuando enero presenta bajo número de estaciones asociados a esa característica de la estimación.

Los resultados de las estimaciones IRE en el contraste de igualdad de medias, sugieren que en febrero, marzo, agosto y diciembre se presenta el mayor número de estaciones que no rechazan la hipótesis, con porcentajes mayores al 80%; al tiempo que enero y julio tienen porcentajes menores al 76%. Los resultados correspondientes a las estaciones que tienen evidencias significativas de sobreestimación muestran que enero es el mes con mayores valores en comparación a los meses de marzo, abril, mayo, septiembre y octubre, donde los valores son menores. En cuanto a la prueba relacionada a las subestimaciones, en octubre se presentan los valores más altos de subestimación de la precipitación en contraste a los valores del primer trimestre del año.

Tabla 6. Resultado de la prueba de Wilcoxon, series de meses 1981 – 2010

| Mes | Prueba de Wilcoxon                                               |        |     |                                                                     |        |     |                                                                     |        |     |
|-----|------------------------------------------------------------------|--------|-----|---------------------------------------------------------------------|--------|-----|---------------------------------------------------------------------|--------|-----|
|     | $H_0: \text{Mediana}_{\text{Est}} = \text{Mediana}_{\text{Obs}}$ |        |     | $H_0: \text{Mediana}_{\text{Est}} \leq \text{Mediana}_{\text{Obs}}$ |        |     | $H_0: \text{Mediana}_{\text{Est}} \geq \text{Mediana}_{\text{Obs}}$ |        |     |
|     | Decisión                                                         | CHIRPS | IRE | Decisión                                                            | CHIRPS | IRE | Decisión                                                            | CHIRPS | IRE |
| 1   | No rechaza                                                       | 640    | 786 | Rechaza                                                             | 414    | 295 | Rechaza                                                             | 80     | 38  |
| 2   | No rechaza                                                       | 737    | 840 | Rechaza                                                             | 298    | 236 | Rechaza                                                             | 103    | 44  |
| 3   | No rechaza                                                       | 756    | 835 | Rechaza                                                             | 234    | 203 | Rechaza                                                             | 119    | 58  |
| 4   | No rechaza                                                       | 719    | 823 | Rechaza                                                             | 274    | 201 | Rechaza                                                             | 129    | 74  |
| 5   | No rechaza                                                       | 694    | 826 | Rechaza                                                             | 294    | 205 | Rechaza                                                             | 142    | 90  |
| 6   | No rechaza                                                       | 659    | 802 | Rechaza                                                             | 368    | 227 | Rechaza                                                             | 106    | 77  |
| 7   | No rechaza                                                       | 640    | 781 | Rechaza                                                             | 351    | 242 | Rechaza                                                             | 142    | 83  |
| 8   | No rechaza                                                       | 674    | 836 | Rechaza                                                             | 350    | 213 | Rechaza                                                             | 110    | 72  |
| 9   | No rechaza                                                       | 713    | 818 | Rechaza                                                             | 264    | 203 | Rechaza                                                             | 170    | 86  |
| 10  | No rechaza                                                       | 670    | 809 | Rechaza                                                             | 331    | 207 | Rechaza                                                             | 127    | 108 |
| 11  | No rechaza                                                       | 676    | 817 | Rechaza                                                             | 329    | 219 | Rechaza                                                             | 123    | 86  |
| 12  | No rechaza                                                       | 690    | 849 | Rechaza                                                             | 342    | 224 | Rechaza                                                             | 114    | 59  |

Desde el punto de vista de la distribución, en la Tabla 7 se presentan los resultados de la prueba de Kolmogorov –Smirnov, donde se observa que en las estimaciones CHIRPS la hipótesis de igualdad de distribución se rechaza con más frecuencia para enero, mientras que en marzo y abril el número de estaciones que rechazan la hipótesis es menor; en tanto que para las estimaciones IRE el mes en que más se

rechaza la hipótesis de igualdad es enero y en los que menos se rechaza son abril, mayo, noviembre y diciembre.

Tabla 7. Resultado de la prueba Kolmogorov - Smirnov, series de meses 1981 – 2010.

| Mes | Test Kolmogorov - Smirnov |        |     |
|-----|---------------------------|--------|-----|
|     | Decisión                  | CHIRPS | IRE |
| 1   | No rechaza                | 502    | 805 |
| 2   | No rechaza                | 641    | 854 |
| 3   | No rechaza                | 700    | 858 |
| 4   | No rechaza                | 710    | 865 |
| 5   | No rechaza                | 668    | 865 |
| 6   | No rechaza                | 627    | 845 |
| 7   | No rechaza                | 594    | 821 |
| 8   | No rechaza                | 636    | 856 |
| 9   | No rechaza                | 692    | 859 |
| 10  | No rechaza                | 668    | 851 |
| 11  | No rechaza                | 672    | 863 |
| 12  | No rechaza                | 661    | 866 |

En la Tabla 8 se presentan las estaciones que no rechazan las hipótesis de igualdad en mediana y distribución. Se observa que enero es el mes en que menos estaciones cumplen con los criterios para las dos estimaciones, en tanto que los meses marzo y abril son los mejores para CHIRPS, siendo abril, agosto y diciembre los mejores de IRE.

Tabla 8. Número de estaciones que no rechazan las dos pruebas de igualdad

| Mes | CHIRPS | IRE |
|-----|--------|-----|
| 1   | 465    | 746 |
| 2   | 598    | 804 |
| 3   | 670    | 817 |
| 4   | 663    | 805 |
| 5   | 618    | 810 |
| 6   | 583    | 792 |
| 7   | 568    | 773 |
| 8   | 596    | 816 |
| 9   | 641    | 798 |
| 10  | 615    | 792 |
| 11  | 620    | 804 |
| 12  | 613    | 817 |

En la Figura 8 se presentan los mapas de distribución de las métricas de bondad de ajuste MAE y CEM del mes de enero para las estimaciones CHIRPS, los mapas correspondientes a todos los meses de las estimaciones CHIRPS e IRE se presentan en el archivo anexo “métricas\_meses.pdf”. En el mapa de resultados del MAE (Figura 8, izquierda), los cinco (5) rangos de visualización se determinaron con base en el valor mínimo y los percentiles 20, 40, 60, 80, recordando que el MAE no tiene cota superior; mientras que los rangos del mapa de resultados del CEM (Figura 8, derecha), varían desde menos infinito, ya que este índice no tiene cota inferior, hasta 1, siendo éste último el mejor resultado.




Figura 8. Mapas de la distribución de las métricas de bondad de ajuste (enero).

Hay unas zonas del país donde los rangos de MAE no varían durante todo el año, estas son: la región Pacífico y el Catatumbo donde los valores de MAE permanecen por encima del valor del percentil 80, además, las zonas del altiplano Cundiboyacense y norte de la península de La Guajira que durante todo el año los valores MAE están por debajo del percentil 20.

El cuatrimestre diciembre – enero – febrero – marzo se caracteriza por presentar muy buenas estimaciones para toda la región Caribe y la zona de la cordillera oriental correspondiente a los departamentos de Boyacá y Cundinamarca, mientras que la zona centro y occidente de la región Andina sumada a la región Pacífica tienen los mayores valores de MAE.

En abril se identifica una transición donde los valores MAE de la región Caribe aumentan su magnitud pasando al intervalo de los percentiles 20 – 40, al tiempo que el sur de la región andina los MAE bajan de magnitud y se empieza a consolidar el altiplano cundiboyacense como la zona de mejores estimaciones; los valores del MAE en la Orinoquía empiezan a tener predominancia por encima del percentil 60.

Entre mayo y septiembre los valores más bajos del MAE están en el sur de la región Andina y a través de toda la cordillera oriental, en la región Caribe los valores van aumentando hasta predominar los asociados al intervalo de los percentiles 60 – 100.

En octubre – noviembre hay una variación en los valores de MAE, de tal manera que su distribución cambia hasta volver a la distribución inicial descrita para el cuatrimestre diciembre – enero – febrero – marzo, la zona de valores bajos de MAE empieza a reducirse al altiplano cundiboyacense y de nuevo a tomar posición en la región Caribe.

El MAE para las estimaciones IRE según los percentiles, muestra una distribución espacial semejante a la descrita para las estimaciones CHIRPS, no obstante, se destaca que los valores de MAE calculados para la estimación IRE son en general menores a los de CHIRPS.

Los valores del Coeficiente de Eficiencia Modificado (CEM) para CHIRPS en todos los meses, presentan una predominancia de valores menores a 0.4, por lo que se podría inferir que el ajuste de esta base no es tan bueno.

De otro lado, para las estimaciones IRE los valores del CEM varían principalmente en el intervalo (0,2, 0,6], indicando mayor eficiencia que las estimaciones CHIRPS, además, se destaca el buen ajuste que se presenta para todos los meses en la región Orinoquía, con valores del CEM mayores a 0,6.

## 5. Conclusiones

### 5.1. Validación series mensuales

Las estimaciones para San Andrés y Providencia no se recomiendan para futuros análisis, ya que presentan bajas correlaciones con las observaciones y se rechaza la prueba de igualdad de medianas evidenciando subestimación de la precipitación. Adicionalmente se rechaza la prueba de igualdad de distribución.

Las estimaciones CHIRPS e IRE para la región continental están altamente correlacionadas con las observaciones, no obstante, el 58% rechaza la prueba de igualdad de medianas para CHIRPS y el 50% para IRE, indicando la tendencia a sobrestimar según la prueba de Wilcoxon a una vía, además, la prueba de igualdad de distribuciones da porcentajes de no rechazo del 18% para CHIRPS y de 45% para IRE.

Los valores del MAE están asociados al régimen de precipitación, es decir, los valores bajos se presentan en las zonas de menor precipitación y los valores altos corresponden a las zonas de mayor magnitud de precipitación, por lo tanto, se concluye que las estimaciones son más confiables en las temporadas secas, ya que en las temporadas de lluvia los errores de estimación son más altos y en general están asociados a sobrestimación.

Con base en el CEM, se puede afirmar que las estimaciones CHIRPS tienen una eficiencia buena en la región Orinoquía, aceptable en las regiones Andina y Caribe, y moderada en la región Pacífico y Amazonía, mientras que las estimaciones IRE tienen una eficiencia entre aceptable a muy buena en todo el país.

### 5.2. Validación series asociadas a cada mes del año

La desagregación de las series de la precipitación según los meses del año, elimina la estacionalidad y permite verificar de forma más concreta las estimaciones.

Las estimaciones tienen una correlación aceptable, puesto que, un alto porcentaje de estaciones evidenció valores  $r_s > 0.6$ , sin embargo, se esperaría que los valores estimados del mismo fenómeno en el mismo punto tuvieran una correlación muy cercana a uno (1).

Se identificó que los meses con mayores precipitaciones tienen mejores correlaciones que los meses secos.

Desde el punto de vista de las pruebas de igualdad de medias y distribuciones los resultados por meses muestran un panorama más favorable en comparación con la

verificación a toda la serie mensual, con porcentajes de no rechazo de las dos pruebas en todos los meses alrededor de 58% para CHIRPS y del 77% para IRE, se evidenció que los meses con mejor correlación no necesariamente son los meses que mejor se comparten en términos de mediana y distribución. Los valores del MAE confirman lo que se observó para las series mensuales, que hay una relación positiva de la magnitud de la precipitación con la magnitud del error de estimación. Finalmente, los resultados del CEM dan una alerta sobre el uso de las estimaciones CHIRPS.

## **6. Recomendaciones**

Con base en los resultados se recomienda el uso de las estimaciones IRE, las cuales tienen mejor desempeño que las estimaciones CHIRPS, no obstante, para ello se hace necesaria la construcción de un protocolo donde se documenten los parámetros de entrada y todo el procedimiento que se realiza en la herramienta BASIICS, incorporada en el software GeoCLIM.

## 7. Referencias

- Ayehu, G. T., Tadesse, T., Gessesse, B., y Dinku, T. (2018). Validation of new satellite rainfall products over the Upper Blue Nile Basin, Ethiopia. *Atmospheric Measurement Techniques*, 11(4), 1921–1936. <https://doi.org/10.5194/amt-11-1921-2018>
- Corzo, J. A. (2005). *Notas de clase. Estadística no paramétrica (Métodos basados en rangos)*. Univ. Nacional de Colombia.
- Dinku, T., Funk, C., Peterson, P., Maidment, R., Tadesse, T., Gadain, H., y Ceccato, P. (2018). Validation of the CHIRPS satellite rainfall estimates over eastern Africa. *Quarterly Journal of the Royal Meteorological Society*, (August), 292–312. <https://doi.org/10.1002/qj.3244>
- Funk, C., Peterson, P., Landsfeld, M. F., Pedreros, D. H., Verdin, J. P., Rowland, J., ... Verdin, A. P. (2014). A Quasi-Global Precipitation Time Series for Drought Monitoring. *U.S. Geological Survey Data Series*, 832, 4. <https://doi.org/http://dx.doi.org/110.3133/ds832>
- Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., ... Michaelsen, J. (2015). The climate hazards infrared precipitation with stations - A new environmental record for monitoring extremes. *Scientific Data*, 2, 1–21. <https://doi.org/10.1038/sdata.2015.66>
- Guzmán, D., Ruíz, J. F., y Cadena, M. (2014). Regionalización de Colombia según la estacionalidad de la precipitación media mensual, a través de análisis de componentes principales (ACP). *Nota Técnica IDEAM, METEO*, 54.
- Legates, D. R., y McCabe Jr., G. J. (1999). Evaluating the sse of “Goodness of Fit” measures in hydrologic and hydroclimatic model validation. *Water Resources Research*, 35(1), 233–241. <https://doi.org/10.1029/1998WR900018>
- Magadzire, T., y Pedreros, D. (2008). GeoCLIM Manual, 1–62.
- Mason, S. J., y Tippett, M. K. (2016). Climate Predictability Tool version 15.3. 9.
- Paredes-Trejo, F. J., Barbosa, H. A., y Lakshmi Kumar, T. V. (2017). Validating CHIRPS-based satellite precipitation estimates in Northeast Brazil. *Journal of Arid Environments*, 139, 26–40. <https://doi.org/10.1016/j.jaridenv.2016.12.009>
- Trejo, F. J. P., Barbosa, H. A., Peñaloza-Murillo, M. A., Moreno, M. A., y Farías, A. (2016). Intercomparison of improved satellite rainfall estimation with CHIRPS gridded product and rain gauge data over Venezuela. *Atmósfera*, 29(4), 323–342.
- Verdin, A., Funk, C., Rajagopalan, B., y Kleiber, W. (2016). Kriging and local polynomial methods for blending satellite-derived and gauge precipitation estimates to support hydrologic early warning systems. *IEEE Transactions on Geoscience and Remote Sensing*, 54(5), 2552–2562. <https://doi.org/10.1109/TGRS.2015.2502956>

Zambrano-Bigiarini, M., Nauditt, A., Birkel, C., Verbist, K., y Ribbe, L. (2017). Temporal and spatial evaluation of satellite-based rainfall estimates across the complex topographical and climatic gradients of Chile. *Hydrology and Earth System Sciences*, 21(2), 1295–1320. <https://doi.org/10.5194/hess-21-1295-2017>