

DOI: 10.24850/j-tyca-15-01-02

Artículos

Geoestadística para integrar mediciones de campo con estimaciones satelitales adecuados para escala local
Geostatistics to integrate gauge measurements with downscaled satellite estimates suitable for the local scale

Felipe-Omar Tapia-Silva¹, ORCID: <https://orcid.org/0000-0002-5618-7594>

¹Universidad Autónoma Metropolitana-Iztapalapa, Ciudad de México, México, otapia@xanum.uam.mx

Autor para correspondencia: Felipe-Omar Tapia-Silva, otapia@xanum.uam.mx

Resumen

En países como México hacen falta más estaciones de medición de lluvia. Además, en la cuenca Grijalva, datos de solo tres o menos estaciones se integran en productos satelitales de misiones como Tropical Rainfall Monitoring Mission (TRMM) o Global Precipitation Mission (GPM). Aunque las misiones satelitales permiten obtener estimaciones de lluvia a un



espaciamiento constante (p. ej., 11 km para GPM), esta resolución no es adecuada para gestión local. La integración de una mayor cantidad de datos de pluviómetros con valores de satélite aumentados de escala puede ser útil para obtener datos de precipitación de escala local. En este trabajo se aplicó kriging ordinario (OK) a los datos satelitales de precipitación (GPM y TRMM) agregados anualmente y regresión kriging (RK) para integrar los datos resultantes con datos de todos los pluviómetros disponibles. Los resultados de esta integración se compararon con los resultados de la interpolación de datos de pluviómetros utilizando OK y kriging universal (UK). Una interpolación del inverso de la distancia al cuadrado (IDW) se consideró como criterio de bajo desempeño. Los métodos de evaluación y de definición de similitud fueron validación cruzada (Lou-CV), análisis de componentes principales, matriz de correlación y mapa de calor con análisis de conglomerados. OK funcionó bien para desescalar las estimaciones satelitales de GPM. La integración RK de datos de pluviómetros con datos de GPM desescalados con OK obtuvo los mejores parámetros de validación en comparación con las interpolaciones de mediciones de pluviómetros. Los métodos geoestadísticos son prometedores para desescalar las estimaciones satelitales e integrarlas con todos los datos disponibles de pluviómetros. Los resultados indican que la evaluación usando parámetros para evaluar la efectividad de la interpolación usando datos medidos debe complementarse con métodos para definir similitud entre las capas espaciales obtenidas. Este enfoque permite obtener datos de precipitación útiles para modelado y manejo del agua a nivel local.

Palabras clave: Bajo Grijalva, cuenca tropical, desescalamiento geoestadístico de datos, precipitación satelital, regresión kriging

Abstract

In countries such as Mexico, there is a lack of rain measurement stations. Additionally, in the Bajo Grijalva Basin, data of only three or fewer stations are integrated into satellite products of missions such as Tropical Rainfall Monitoring Mission (TRMM) and Global Precipitation Mission (GPM). Although Satellite missions enable obtaining rainfall at constant spacing (e.g., 11 km for GPM), this resolution is not suitable for local management. Integrating a larger quantity of gauge data with downscaled satellite values allows for obtaining local-scale precipitation data. In this work, Ordinary kriging (OK) was applied to downscale yearly aggregated precipitation satellite data (GPM-IMERG and TRMM: TMPA/3B43) and regression kriging (RK) to integrate them with the gauge measurements available in the basin of study. The resulting data were compared with the interpolation results of gauge measurements using OK and universal kriging (UK). Leave-one-out cross-validation (Lou-CV), principal components analysis, a correlation matrix, and a heat map with cluster analysis helped to evaluate the performance and to define similarity. An Inverse Distance Weighting (IDW) interpolation was included as a low-performance criterion in the comparison. OK performed well to downscale GPM satellite estimates. The RK integration of gauge data with downscaled GPM data got the best validation values compared to the interpolation of gauge measurements. Geostatistical methods are promising for downscaling satellite estimates and integrating them with

all the available gauge data. The results indicate that the evaluation using performance metrics should be complemented with methods to define similarity among the values of the obtained spatial layers. This approach allows obtaining precipitation data useful for modeling and water management at the local level.

Keywords: Bajo Grijalva, geostatistical data downscaling, regression kriging, satellite precipitation, tropical basin.

Recibido: 28/02/2022

Aceptado: 06/06/2022

Publicado online: 15/07/2022

Introducción

El conocer dónde, cómo y qué tanta lluvia se precipita es esencial para la investigación científica y para aplicaciones requeridas por la sociedad (Skofronick-Jackson *et al.*, 2018). Una mejor comprensión de los patrones temporales y espaciales de la precipitación (PP) es aún necesaria para cuantificar los riesgos y diseñar medidas de mitigación en el contexto de cambio climático (Agou, Varouchakis, & Hristopulos, 2019). Como Smalley y L'Ecuyer (2015) lo apuntan, el proceso de toma de decisiones para hidrólogos, infraestructura y uso de suelo bajo predicciones de incremento o decremento del volumen de PP puede ser efectuado con

conocimiento detallado y de escala fina de la cantidad, y de la distribución espacial de PP.

De acuerdo con Todd, Hulme y Jones (2001), la medición mediante pluviómetros en localizaciones específicas permanece como el enfoque más común para realizar mediciones en campo y son la referencia final, y el único método de mediciones disponible en muchas regiones del mundo. Sin embargo, la dirección y magnitud de tendencias climáticas no puede ser inferida de manera confiable desde registros puntuales, incluso sobre terreno relativamente homogéneo (Pielke *et al.*, 2000). Lograr una buena ubicación de estaciones para colección de datos es difícil (WMO, 2008). Las observaciones sinópticas deben ser representativas de un área hasta de 100 km alrededor de la estación, pero para aplicaciones de escala pequeña o local, el área considerada requiere tener dimensiones de 10 km o menos (WMO, 2008).

En países como México, en particular en regiones tropicales como el área de este estudio, se tienen pocas estaciones de medición. Tapia-Silva, Silván-Cárdenas y Rosales-Arriaga (2013) reportaron que las estaciones del Servicio Meteorológico Nacional (SMN) incluyen unos 3 300 sitios de observación. Asumiendo que cada sitio fue representativo de un área de 100 km², como lo define WMO (2008) para sitios planos, 330 000 km² serían cubiertos, lo que comprende solo 17 % de la extensión territorial de México.

Estimados satelitales de PP han sido investigados desde la década de 1970 (New *et al.*, 2001). Una de las misiones emblemáticas ha sido Tropical Rainfall Monitoring Mission (TRMM) (Kummerow, Barnes, Kozu, Shiue, & Simpson, 1998; Kummerow *et al.*, 2000; Huffman *et al.*, 2007).

TRMM contó con un sistema de microondas activo montado en un satélite. Global Precipitation Mission (GPM) (Kidd *et al.*, 2020) es una misión conjunta de EUA y Japón lanzada en 2014 que sigue, extiende y mejora el legado de TRMM (Kidd *et al.*, 2020). El proyecto Integrated Multi-satellitE Retrievals for GPM (IMERG), lanzado en 2014, incluye estimados de PP intercalibrados desde la constelación internacional de satélites relevantes para PP y otros datos como PP superficial mensual obtenida con pluviómetros, para obtener conjuntos de datos rasterizados con resolución de $0.1^\circ \times 0.1^\circ$ (Kidd *et al.*, 2020, p. 343).

No obstante, datos de muy pocas estaciones (tres o menos) han sido integradas en TRMM y GPM para la región de la cuenca de este estudio (GPCC, 2012). TRMM incluye productos de lluvia con una resolución de 30 km^2 aproximadamente e IMERG (GPM) de cerca de 11 km^2 . Como lo sugieren Smalley y L'Ecuyer (2015), el conocimiento acerca del volumen y distribución espacial de PP a escala fina no puede ser representado usando esta resolución. Adicionalmente, productos satelitales de lluvia no están libres de errores (Huffman *et al.*, 2020, p. 350; Anagnostou *et al.*, 2010; AghaKouchak, Behrangi, Sorooshian, Hsu, & Amitai, 2011; Zulkafli *et al.*, 2014, p. 515), y se han desarrollado procesos de validación extendida (Kidd *et al.*, 2020, pp. 11-12; Anagnostou *et al.*, 2020). Los errores se deben a las frecuencias del sensor y canales el tipo de PP, su heterogeneidad en el campo de visión del sensor y el algoritmo usado para calcular la tasa de PP (Massari & Maggioni, 2020, p. 515). En cuanto a los métodos de estimación implementados por Greene y Morrysey (2000), la incertidumbre de los estimados de PP se asoció con variaciones desconocidas en el espacio y

tiempo de relaciones estadísticas y físicas entre PP y la radiancia registrada en el satélite.

Las mediciones en tierra se han usado con frecuencia para validar o comparar la información obtenida mediante satélites (Kidd *et al.*, 2020, pp. 11-12; Laurent, Jobard, & Toma, 1998; Bowman, 2005; Bell, 2003). De acuerdo con lo expuesto, las mediciones de pluviómetros y los estimados satelitales presentan problemas para capturar la variabilidad espacial en zonas como la cuenca de este estudio. Por tal razón se han desarrollado esquemas de integración. Por ejemplo, New *et al.* (2021) presentaron un procedimiento que pondera los valores de los componentes de entrada por el inverso del error aleatorio para producir un producto final combinado. Wu, Zhang, Sun, Lin y He (2018) integraron datos de TRMM Multi-Satellite P Analysis (TMPA) 3B42 con pluviómetros.

Otra posibilidad de integración es la aplicación de geoestadística, kriging, en particular (Matheron, 1963). De acuerdo con Curran y Atkinson (1998), se ha observado una sinergia poderosa entre geoestadística y percepción remota desde la década de 1980. Sin embargo, Van der Meer (2012) menciona que aunque la investigación relacionada con el uso de geoestadística en percepción remota está creciendo no se ha establecido aún como una práctica estándar. Puede hacerse una integración geoestadística dado que los productos satelitales permiten obtener valores de lluvia para una región particular a un espaciamiento constante y que las mediciones puntuales permiten obtener el valor considerado correcto. Regresión kriging (RK) (Hengl, Gerard, Heuvelink, & Rossiter, 2007) permite predecir valores

desconocidos basados en mediciones puntuales usando estimaciones de productos satelitales como variables auxiliares.

Kriging se ha definido como el estimador óptimo lineal no desviado (Cressie, 1990; Hengl, 2009) para predecir valores en ubicaciones sin mediciones. Estas técnicas se han explorado para generar capas espaciales más representativas desde mediciones puntuales (Smalley & L'Ecuyer, 2015; Holawe & Dutter, 1999; Goovaerts, 2000; Keblouti, Ouerdachi, & Boutaghane, 2012). Sin embargo, en países como México, la aplicación de kriging presenta problemas para capturar la variabilidad espacial local debido al reducido número de pluviómetros. Además, su localización no es favorable debido a que muchas de ellas fueron instaladas en áreas fácilmente accesibles sin consideración de un diseño de muestreo geográfico y a que otras ya no están funcionando.

Los estimados satelitales de TRMM has sido previamente desescalados (volviéndolos útiles para escala local) e integrados con mediciones en campo usando kriging Abdollahipour, Ahmadi, & Aminnejad, 2022). Park, Kyriakidis y Hong (2017) utilizaron kriging para desescalar datos mensuales de TRMM-3B43 a ~25 km de resolución sobre Corea del Sur. Posteriormente, los autores aplicaron kriging con deriva externa (KED) y kriging simple con medias locales para integrar datos de pluviómetros con los estimados de precipitación desescalados. Chen, Gao y Li (2020) deescalaron datos diarios de PP de TRMM cubriendo la provincia china de Henan para el periodo del 1° de enero de 2015 al 31 de diciembre de 2018 mediante una estrategia denominada "temporal upscaling-spatial downscaling-temporal downscaling strategy". Después los autores combinaron los resultados con observaciones de pluviómetros

en un marco geoestadístico multivariado. Chen, Zhang, She y Chen (2019) utilizaron kriging y otros métodos de análisis espacial, como regresión geográficamente pesada, para deescalar datos de PP desde el producto TRMM-3B43V7 e integrarlos con datos de pluviómetros de 2001 a 2014 sobre tramos del río Yangtze en China. Cersosimo *et al.* (2018) deescalaron otros datos satelitales sobre el sur de Italia, como los de Operative Precipitation Estimation at Microwave Frequencies (OPEMW) y Microwave Humidity Sounder (MHS) observation usando KED. Otros esquemas de integración geoestadística han sido reportados en la literatura (Wang & Lin, 2015; Lin & Wang, 2011; Verdin, Rajagopalan, Kleiber, & Funk 2015; Sivasubramaniam, Sharma, & Alfredsen, 2019; Wu *et al.*, 2018; Nerini *et al.*, 2015). Asimismo, se ha desarrollado trabajo para integrar datos de radar y de pluviómetros empleando geoestadística (Dumitrescu, Brabec, & Matreata, 2020; Berndt, Rabiei, & Haberlandt, 2013; Yang & Ng, 2019).

De acuerdo con esta revisión, antes del presente estudio, estimados de PP desde GPM no habían sido desescalados e integrados con mediciones satelitales usando geoestadística, y este tipo de desescalamiento e integración no había sido efectuado y evaluado para áreas tropicales fuera de Asia y Europa. En esta investigación se aplicaron métodos geoestadísticos para obtener un patrón espacial adecuado para la escala local (cuenca) de agregados anuales de PP. Este tipo de valores de PP son valiosos indicadores de procesos de disponibilidad de agua (Tapia-Silva & Gómez-Reyes, 2020), desertificación (Morin, Marra, & Armon, 2020), uso y extracción de agua (Ruiz-Alvarez, Singh, Enciso-Medina, Ontiveros-Capurata, & Corrales-Suastegui, 2020), y manejo de

agua, así como identificación de regiones vulnerables al cambio climático (Rata, Douaoui, Larid, & Douaik, 2020).

Kriging ordinario (OK) fue aplicado para desescalar datos satelitales (GPM y TRMM) y RK para integrar los resultados con datos de pluviómetros. Los resultados de la integración se compararon con los resultados de interpolación de datos de pluviómetros usando OK y kriging universal (UK). IDW se incluyó como criterio de comparación, dado que ofrece capacidades limitadas para capturar el patrón espacial de la variable. Validación cruzada, dejando uno afuera (Lou-CV), análisis de componentes principales, una matriz de correlación y un mapa de calor con análisis de clúster ayudaron a evaluar los resultados y a definir valores similares entre ellos.

Como resultado principal, un método geoestadístico de integración y desescalado entre estimados satelitales de PP de GPM y TRMM, y de toda la información disponible obtenida con pluviómetros se desarrolló y evaluó. El objetivo de este trabajo fue responder a las siguientes preguntas: ¿es posible generar, mediante métodos geoestadísticos, una capa espacial desescalada de PP satelital que pueda ser integrada con toda la información de pluviómetros disponibles para obtener una capa espacial adecuada para la escala local, ocupando agregados anuales de PP para un año particular?, ¿cuáles son los resultados de comparar la capa espacial obtenida mediante RK con otros métodos de interpolación como OK y UK?

Materiales y métodos

Región de estudio

La cuenca Bajo Grijalva (Figura 1) está localizada en el sureste mexicano y cubre una superficie de 9 830 km² (Conagua, 2015). Se generó un buffer de 30 sobre el polígono de la cuenca obtenido desde el Instituto Nacional de Estadística y Geografía (INEGI) (INEGI, 2010) para delimitar el área de estudio (Figura 1).

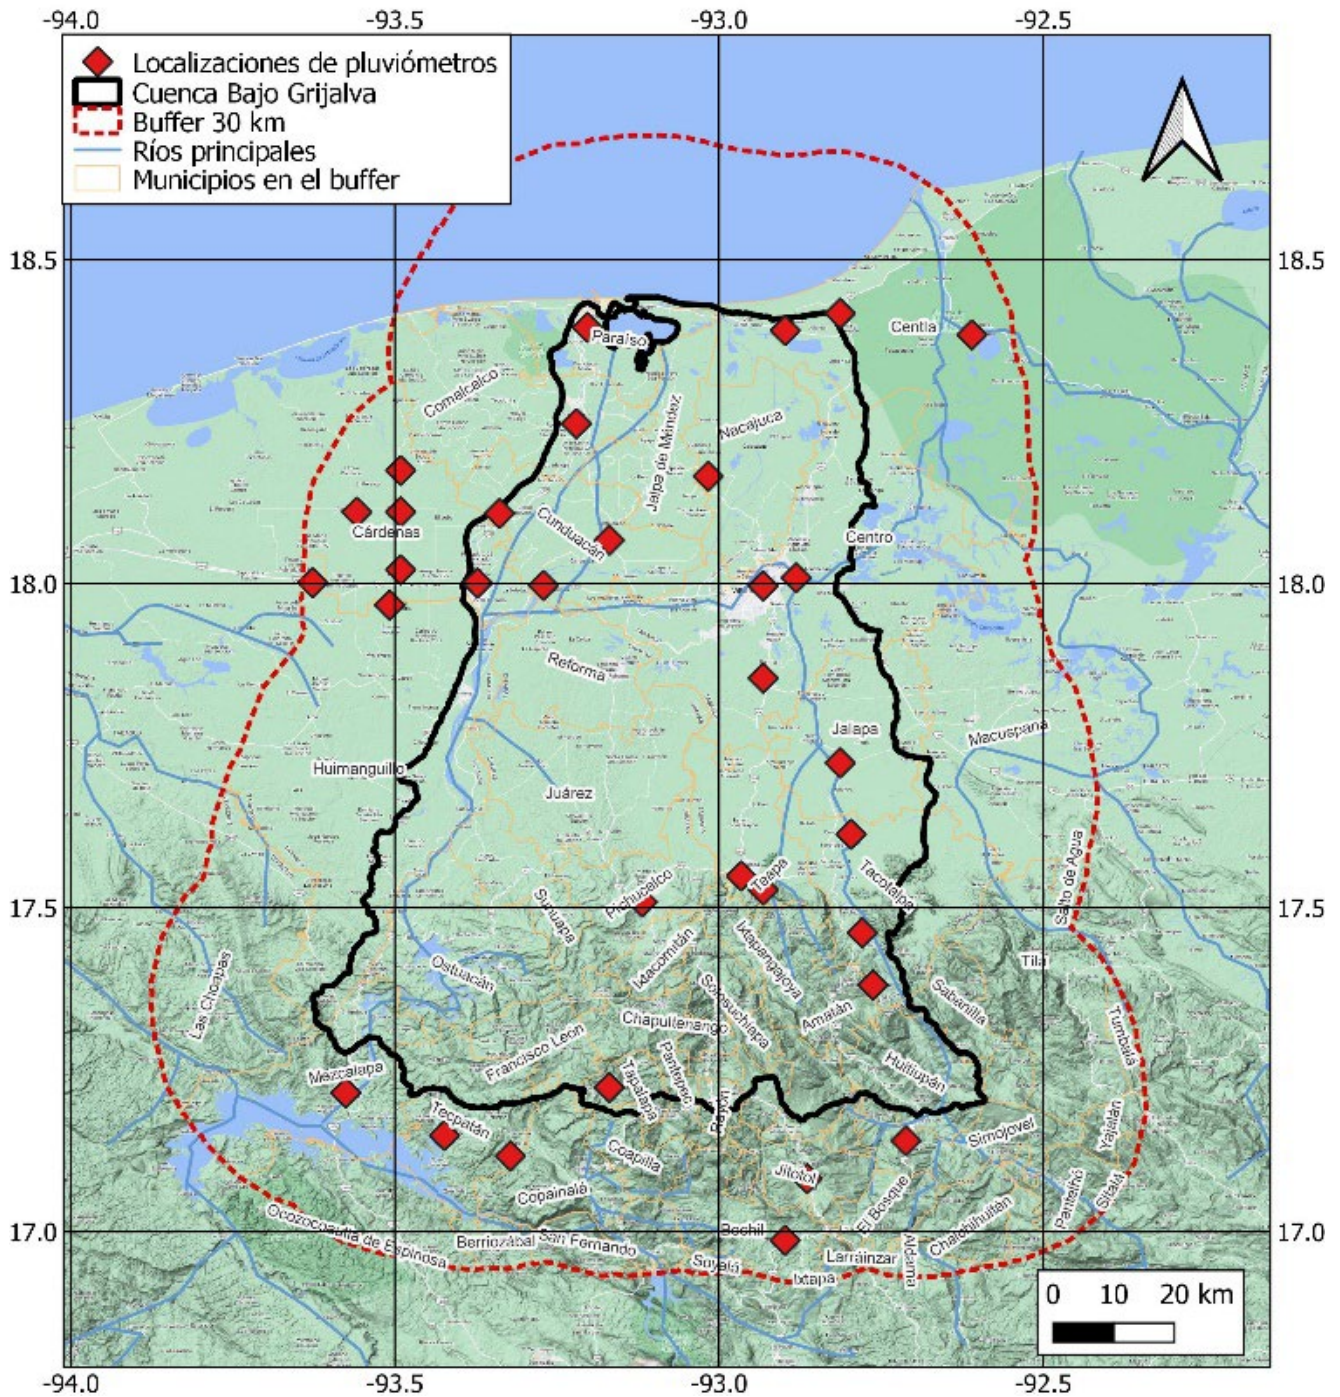


Figura 1. Cuenca Bajo Grijalva y sus municipios, con un buffer de 30 km y la localización de los pluviómetros.

La cuenca incluye 12 municipios de Tabasco y 20 de Chiapas. El sistema rivereño más largo del país, el Grijalva-Usumacinta, converge en esta área. El escurrimiento de sus ríos es el más grande de la república mexicana, con cerca de 3 700 m³/s en promedio anual (Conagua, 2015). Las planicies de esta cuenca presentan inundaciones recurrentes debido al escurrimiento generado por lluvias intensas, principalmente conducidas por el río Sierra (Cepal & Cenapred, 2008).

Datos

Los datos de pluviómetros para 2001 de las estaciones localizadas en el buffer de 30 km se obtuvieron de la base de datos provista por el SMN (Gobierno de México, 2020). Como ya se mencionó, el intervalo de tiempo seleccionado (valores anuales) es adecuado para actividades de modelaje y permite la estimación de disponibilidad de agua a escala local en la misma cuenca de estudio (Tapia-Silva & Gómez-Reyes, 2020). Los datos de los pluviómetros se revisaron para evitar registros faltantes y se agruparon por año. Por otro lado, agregados anuales de TRMM (TMPA/3B43) (Kummerow *et al.*, 1998; Kummerow *et al.*, 2000) para 2001 se descargaron desde GES DISC (2011). Los datos correspondientes de GPM (IMERG Final Precipitation) (Huffman, Stocker, Bolvin, Nelkin, & Tan, 2019) fueron descargados desde Google Earth Engine (GEE©) usando el script incluido en el apéndice.

Las propiedades estadísticas (coeficiente de desviación y de variación, ajuste a normalidad, media e intervalos de confianza) de los datos usados se presentan en la Tabla 1. Como puede observarse, los parámetros indican muchas diferencias entre ellos. Por ejemplo, la media de los datos de los pluviómetros fue menor que el mismo valor de los estimados de TRMM. Los datos transformados logarítmicamente de los pluviómetros pueden ser asumidos como normales y su coeficiente de desviación se acercó a cero.

Tabla 1. Propiedades estadísticas (coeficiente de desviación y de variación, ajuste a normalidad, media e intervalos de confianza) de los datos usados.

Agregados anuales para 2001	Coeficiente de desviación	Coeficiente de variación	Valor p del Shapiro Wilcoxon test (si >0.05 se asume normalidad)	Media	Intervalos de confianza de la media	
					Izquierda	Derecha
Mediciones de pluviómetros	1.06	48.3	0.0013	1601.5	1393.3	1809.6
Mediciones de pluviómetros transformados logarítmicamente (usados para interpolar)	0.009	6.5	0.753	3.157	3.102	3.212
TRMM estimaciones por satélite	0.25	36.19	0.0005	508.1	478.1	538.1
GPM estimaciones por satélite	-0.67	0.64	8.9e-11	2174.2	2140.2	2208.2

Descripción general de la metodología

La Figura 2 incluye un diagrama de flujo mostrando una descripción general de la metodología desarrollada. Los agregados para 2001 de los pluviómetros fueron interpolados usando OK, UK e IDW. Como método de desescalamiento, los valores de las celdas de TRMM a una resolución original de 30 km aproximadamente se interpolaron usando OK. Se implementó el mismo procedimiento usando las celdas de GPM a su resolución original (unos 11 km). Los datos de pluviómetros se interpolaron usando RK con los datos de TRMM a la resolución original (30 km) como variable auxiliar. Para mejorar el patrón espacial de la capa de PP resultante, RK de datos de pluviómetros se implementó con los valores de TRMM desescalados con OK, en un caso, y en el otro con los valores de GPM igualmente desescalados como información secundaria. Tal es el enfoque propuesto en este trabajo para integrar datos de pluviómetros con estimaciones de satélite de PP. En RK, la media se estimó desde la relación lineal con la variable secundaria (capas de TRMM o GPM desescaladas con OK). Dado que solo se encontró relación lineal de las mediciones de pluviómetros con los datos satelitales y no con elevación, ese último parámetro no se incluyó en la interpolación RK. Todas las capas resultantes se inspeccionaron visualmente para observar discontinuidades espaciales. La capa obtenida de la integración de mediciones de pluviómetros con mediciones satelitales de TRMM sin previo desescalamiento fue la única que presentó lo anterior, y por ello fue considerada incorrecta y no se sometió a evaluación.

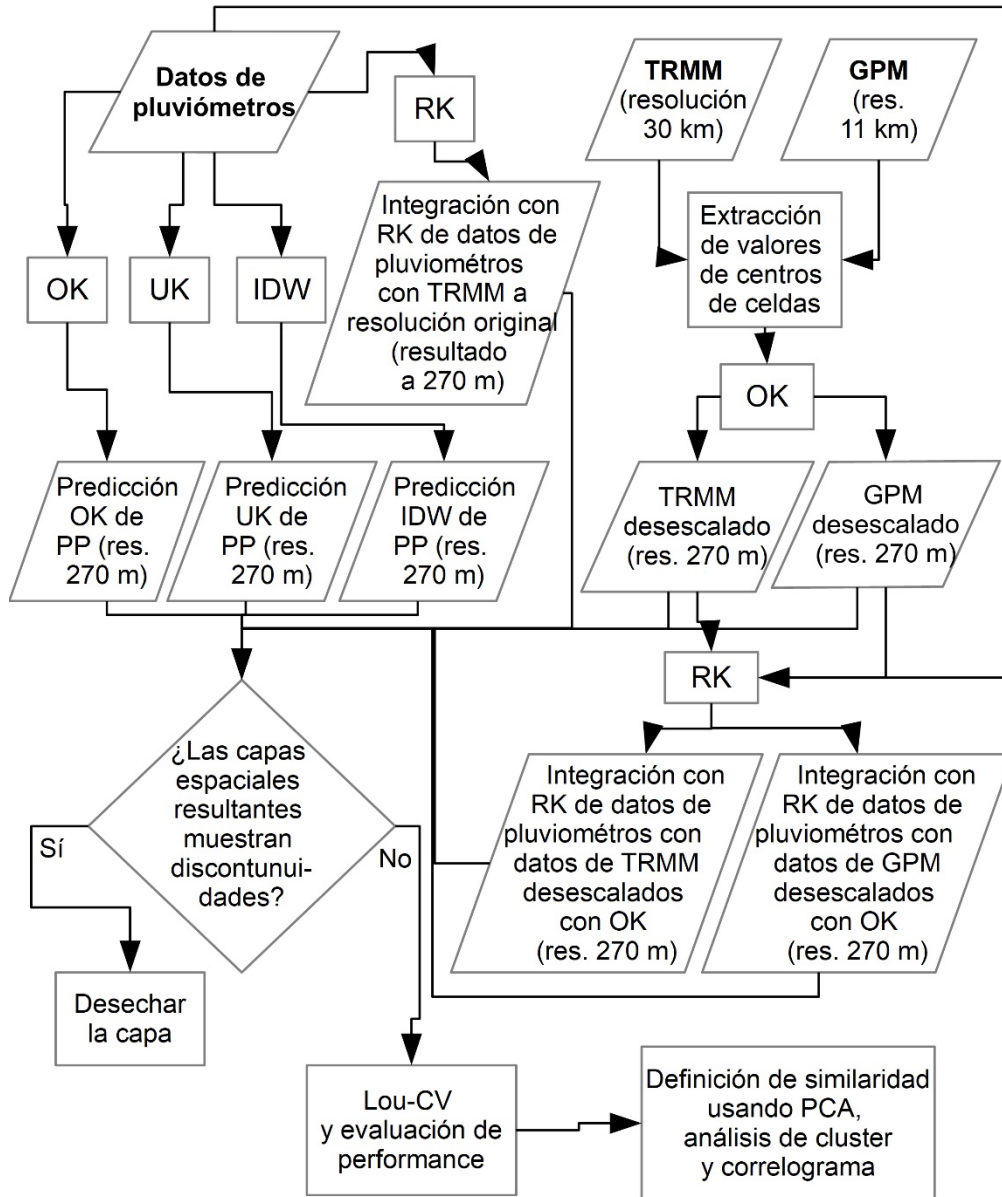


Figura 2. Descripción general de la metodología.

Como las mediciones de pluviómetros presentaron desviación (Tabla 1), se transformaron logarítmicamente. El modelo de variograma (Ecuación (6) en sección kriging) se ajustó a los valores empíricos usando un procedimiento de optimización en R (R Core Team, s.f.) con la función 'fit.variogram' del paquete gstat (Pebesma, 2004).

Se seleccionó la resolución final de 270 m porque es útil para obtener capas espaciales de PP para actividades de manejo y planeación, como balances hidrológicos a la escala de cuenca (Tapia-Silva & Gómez-Reyes, 2020). La teoría de los métodos de kriging aplicados y procedimientos como Lou-CV, evaluación de rendimiento y definición de similitud de valores resultantes se describen en los párrafos siguientes.

Kriging

De acuerdo con Hengl (2009), la idea original de kriging vino desde el ingeniero de minas D. G. Krige y el estadístico H. S. Sichel. Matheron (Matheron, 1963; Matheron, 1965) siguió el trabajo empírico de Krige y estableció la teoría de variables regionalizadas, que es la base de la geoestadística (Oliver & Webster, 2015). Dado que la formulación de kriging puede ser muy extensiva en la literatura (Goovaerts, 1997), se provee un resumen de las bases matemáticas de las técnicas de kriging aplicado.

Kriging toma en cuenta variaciones locales en la media limitando el dominio de estacionaridad a una vecindad local, Ω , alrededor de la posición, x , donde la variable será estimada. Sea $Z(x) = Y(x) + m(x)$ un

proceso estocástico con una media variable determinada por $m(x)$ y una función de covarianza $C(h)$. Como tal, $Y(x)$ es un proceso estocástico con media nula. Un estimador lineal es una combinación de mediciones $Z(x_1)$, $Z(x_2), \dots, Z(x_n)$ en posiciones $x_1, x_2, \dots, x_n \in \Omega$. Específicamente (Goovaerts, 1997, p. 126):

$$\hat{Y}(x) = \sum_{k=1}^n \lambda_k(x) Y(x_k) \quad (1)$$

o:

$$\hat{Z}(x) = m(x) + \sum_{k=1}^n \lambda_k(x) [Z(x_k) - m(x_k)] \quad (2)$$

Si la media es constante en el dominio Ω , entonces puede ser eliminada de la ecuación de arriba forzando los pesos de kriging a sumar uno, en cuyo caso, el estimador es llamado OK y es expresado como (Goovaerts, 1997, p.133):

$$\hat{Z}_{KO}(x) = \sum_{k=1}^n \lambda_k(x) Z(x_k) \quad (3)$$

con:

$$\sum_{k=1}^n \lambda_k(x) = 1 \quad (4)$$

El método de multiplicadores de Lagrange (Goovaerts, 1997, p. 133) se usa para obtener los pesos óptimos que minimizan la estimación de la varianza del error, lo que resulta en el siguiente sistema de ecuaciones:

$$\begin{cases} \sum_{k=1}^n \lambda_k(x) C(x_j - x_k) + \mu(x) = C(x_j - x), j = 1, \dots, n \\ \sum_{k=1}^n \lambda_k(x) = 1 \end{cases} \quad (5)$$

donde μ denota al multiplicador de Lagrange. Alternativamente, cuando se considera la relación entre la función de covarianza y la función de semivariograma $\gamma(h)$, por ejemplo $C(h) = C(0) - \gamma(h)$, entonces el sistema anterior puede escribirse como:

$$\begin{cases} \sum_{k=1}^n \lambda_k(x) \gamma(x_j - x_k) + \mu(x) = \gamma(x_j - x), j = 1, \dots, n \\ \sum_{k=1}^n \lambda_k(x) = 1 \end{cases} \quad (6)$$

OK asume una media estacionaria, esto es, es constante de la función aleatoria $Z(x)$ del valor subyacente real. Sin embargo, con frecuencia no es constante sobre toda el área de estudio. Cuando tal es el caso, una variable regionalizada no estacionaria tiene dos componentes: el *drift* o tendencia (que es el promedio del valor esperado de la variable regionalizada, llamado el componente estructurado) y el residual (que es la diferencia entre los valores del parámetro que son considerados verdaderos y el *drift* o tendencia, llamado el componente aleatorio) (Matheron, 1971, p. 5).

UK divide la función aleatoria en una combinación lineal de funciones determinísticas: la tendencia no estacionaria y suavizada (*drift* o media) $\mu(x) \in R$, y la función residual aleatoria $Y(x) = Z(x) - \mu(x)$ (Wackernagel, 2003, p. 300). UK asume que $\mu(x)$ es una función de la localización espacial y puede ser aproximada por el modelo siguiente (Kumar, 2007):

$$\mu(x) = \sum_{i=1}^n \alpha_i f_i(x) \quad (7)$$

Donde α_i es el coeficiente a estimar basado en los datos, $f_i =$ la función básica o *drift* como una función de las coordenadas espaciales y $n =$ el número de funciones usadas en el modelo de *drift*.

Como con OK, los pesos en UK se obtienen minimizando la varianza del error de la predicción sujeto a la restricción de insesgamiento. El multiplicador de Lagrange se aplica de nuevo, tomando en consideración la estructura de autocorrelación espacial para obtener los pesos óptimos.

RK es la mejor predicción insesgada lineal (BLUP, por sus siglas en inglés) para datos espaciales, y todas las demás técnicas como OK, IDW, etcétera pueden ser vistas como casos especiales (Hengl, 2009, pp. 29-30; Hengl *et al.*, 2007). En notación matricial, RK se escribe por lo común como (Hengl, 2009, p. 28):

$$\hat{Z}_{RK}(x_o) = q_o^T \cdot \hat{\beta}_{GLS} + \lambda_o^T \cdot (Z - q \cdot \hat{\beta}_{GLS}) \quad (8)$$

$\hat{Z}_{RK}(x_o)$ es el valor predicho en la locación x_o ; q_o es el vector de $p + 1$ predictores; $\hat{\beta}_{GLS}$ son coeficientes de regresión estimados con OLS (*Ordinary Least Squares*) u óptimamente con GLS (*Generalized Least Squares*), y λ_o es el vector de n pesos de kriging usados para interpolar el residual. RK tiene una varianza de las predicciones que refleja la posición de nuevas localizaciones (extrapolación) en los espacios geográficos y de atributos (Hengl, 2009, p. 28; Hengl *et al.*, 2007):

$$\hat{\sigma}_{RK}^2(x_o) = (C_o - C_1) - c_o^T \cdot C^{-1} \cdot c_o + (q_o - q^t \cdot C^{-1} \cdot c_o)^T \cdot (q^t \cdot C^{-1} \cdot q)^{-1} \cdot (q_o - q^t \cdot C^{-1} \cdot c_o) \quad (9)$$

Donde $C_o + C_1$ es la variación del *sill* y c_o es el vector de covarianzas de residuales en la locación no medida.

De acuerdo con Hengl (2009, p. 29), si los residuos no muestran autocorrelación espacial (efecto *nugget* puro), RK converge a regresión lineal múltiple, dado que la matriz de covarianza (C) se vuelve una matriz identidad. Hengl (2009, p. 29) indica que si la variable objetivo no muestra correlación con los predictores auxiliares, RK se reduce a OK debido a que la parte determinística iguala el valor de la media (global).

Evaluación y similitud de resultados

Todos los resultados de las interpolaciones se evaluaron usando Lou-CV. Los parámetros de evaluación fueron coeficientes de determinación y de

correlación (R^2 y r , respectivamente) y z -scores (z_i) calculados como (Bivand, Pebesma, & Gómez-Rubio, 2013, p. 225):

$$z_i = \frac{Z(x_i) - \hat{Z}_{[i]}(x_i)}{\sigma_{[i]}(x_i)} \quad (10)$$

con $Z_{[i]}(x_i)$ y $\hat{Z}_{[i]}(x_i)$ como la predicción de validación cruzada para x_i y $\sigma_{[i]}(x_i)$ como el correspondiente error estándar de kriging. De acuerdo con Bivand *et al.* (2013, p. 225), z_i es un residual estandarizado, y si el modelo de variograma es correcto, debe tener media y varianza cercanos a 0 y 1.

Los residuales de *Lou-CV* se analizaron calculando su valor medio. La raíz del error cuadrático medio (RMSE, por sus siglas en inglés) se calculó como:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Z(x_i) - \hat{Z}(x_i))^2}{n}} \quad (11)$$

Los parámetros de eficiencia Nash-Sutcliffe (NSE) y el cociente de la desviación estándar (RSD) también se incluyeron en las evaluaciones de los resultados de *Lou-CV*. Se calcularon como:

$$NSE = 1 - \frac{\sum_{i=1}^n (Z(x_i) - \hat{Z}(x_i))^2}{\sum_{i=1}^n (Z(x_i) - \bar{Z})^2} \quad (12)$$

$$RSD = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (Z(x_i) - \hat{Z}(x_i))^2}}{\sqrt{\frac{1}{n} \sum_{i=1}^n (Z(x_i) - \bar{Z})^2}} \quad (13)$$

Siguiendo a Burgan y Aksoy (2022), los rangos de estos parámetros y sus comentarios son los siguientes: $-\infty \leq NSE \leq 1$, NSE acercándose a 1 muestra mejor rendimiento; $0 \leq RMSE \leq \infty$, RMSE tiene la dimensión de la variable y si se acerca a cero muestra mejor rendimiento. Para NSE y RSD, Burgan y Aksoy (2022) proveen los siguientes criterios de medidas de rendimiento: muy bueno: $0.75 < NSE \leq 1.00$, $0.00 \leq RSD \leq 0.50$; bueno $0.65 < NSE \leq 0.75$, $0.50 < RSD \leq 0.60$; adecuado: $0.50 < NSE \leq 0.65$, $0.60 < RSD \leq 0.70$, y finalmente inadecuado: $NSE \leq 0.50$, $RSD > 0.70$.

Además, para definir la similitud de los valores de las capas espaciales obtenidas y sus agrupaciones, se incluyó un análisis de correlación, con un mapa de calor y un dendograma, así como un análisis de componentes principales (PCA, por sus siglas en inglés). Todos los procedimientos de validación se hicieron en el programa estadístico libre R (R Core Team, s.f.) usando su paquete *gstat* (Pebesma, 2004).

Resultados

Resultados de OK, UK y IDW y de Lou-CV

Los parámetros de evaluación resultantes obtenidos de la Lou-CV para todas las interpolaciones están en la Tabla 2.

Tabla 2. Parámetros resultantes de las interpolaciones de valores anuales de PP para 2001.

Método de Interpolación	R^2 ajustado	r	p	Media de los residuales	NSE	RSD	RMSE	Z_i	
								media	varianza
OK de datos de pluviómetros	0.31	0.57	9.258e-06	1.08	0.23	0.87	671.8	0.01	1.33
UK de datos de pluviómetros	0.29	0.54	1.666e-05	1.083	0.19	0.89	690.2	0.01	1.38
IDW de datos de pluviómetros	0.2	0.44	0.0005	111.05	0.19	0.89	688.5	na	na
Desescalamiento de TRMM con OK	0.91	0.95	2.2e-16	0.53	0.91	0.30	135.91	-0.001	1.33
Desescalamiento de GPM con OK	0.99	0.99	2.2e-16	-0.02	0.99	0.1	37.11	-0.020	2.98
Integración con RK de datos de pluviómetros con datos de TRMM desescalados con OK	0.35	0.59	1.546e-06	1.07	0.29	0.83	644.5	-0.01	1.53
Integración con RK de datos de pluviómetros con datos de GPM desescalados con OK	0.41	0.64	1.266e-07	1.06	0.40	0.76	590.8	-0.001	1.41

Los resultados de las predicciones y de Lou-CV de la interpolación de datos de pluviómetros usando OK, UK e IDW se incluyeron en la Figura 3. Para la interpolación OK (parte a en la Figura 3), se ajustó un modelo gaussiano de semivariograma. Los resultados de la interpolación de OK mostraron un patrón espacial suavizado con los valores más altos de PP en la parte oeste del área de estudio seguida por la parte este. Los resultados de la Lou-CV de la predicción OK fueron R^2 ajustado de 0.31, $r = 0.57$, y p -value = $9.26e-06$. La media de los residuales de CV y el RMSE fueron 1.08 y 671.8, respectivamente. Los parámetros NSE y RSD tuvieron los valores 0.23 y 0.87, respectivamente, indicando un rendimiento inadecuado (Burgan & Aksoy, 2022). No obstante, los valores obtenidos de Lou-CV- z_i tuvieron media de 0.009 y varianza de 1.33, lo que de acuerdo con Bivand *et al.* (2013, p. 225) indica un buen ajuste para el modelo de semivariograma. El mapa de valores de z_i muestra las locaciones con los valores más bajos (con un mínimo de -4.87) localizado al centro y en la parte sureste del área de estudio. Las locaciones con los valores más altos de z_i (con un máximo de 2.26) estuvieron en el centro y sur del área.

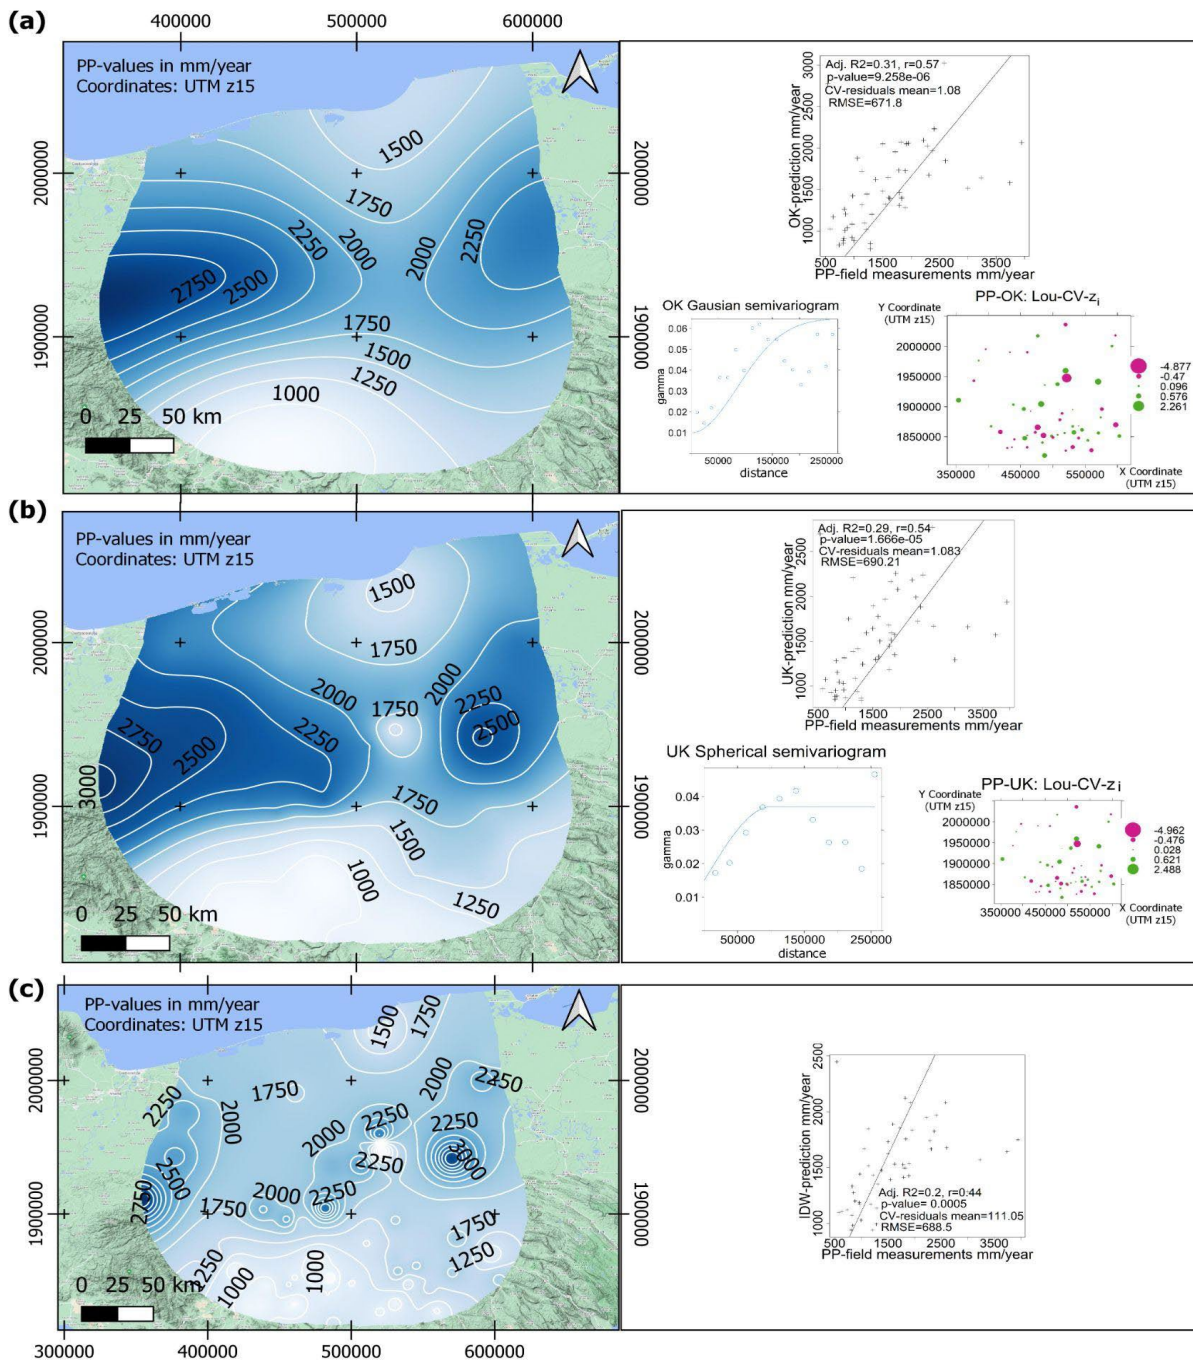


Figura 3. Resultados de la predicción y de Lou-CV de las interpolaciones OK (a), UK (b), y IDW (c) de valores anuales para 2001 de datos de PP medidos en pluviómetros; (a) y (b) incluyen gráficas de los

semivariogramas ajustados, así como un mapa mostrando la distribución espacial de los z_i obtenidos desde la Lou-CV; (a), (b) y (c) incluyen un diagrama de dispersión que compara los valores predichos y los datos de pluviómetros agregados para 2001 y muestra los coeficientes de determinación (R^2) y correlación (r), el p -value, la media de los residuales de CV y el RMSE.

Para las interpolaciones de UK (parte b en la Figura 3), se ajustó un modelo esférico de semivariograma y los datos de pluviómetros se transformaron logarítmicamente. El patrón espacial de la capa espacial resultante puede definirse como suave, así resultó de la interpolación OK. Los valores predichos más altos se localizaron en las partes este y oeste del área. Se puede observar una diferencia entre las interpolaciones OK y UK en la parte central de capa de predicción con UK, en la que una pequeña zona con los valores más bajos estuvo presente, la cual no se advirtió para la predicción con OK. Los resultados de Lou-CV para la predicción UK fueron los siguientes: R^2 ajustado de 0.29, r de 0.54 y p de $1.66e-05$. Los valores de media de los residuales de CV y RMSE fueron 1.08 y 690.2, respectivamente. Los parámetros NSE y RSD obtuvieron valores de 0.19 y 0.89, respectivamente, indicando un rendimiento inadecuado (Burgan & Aksoy, 2022). Sin embargo, la media de los z_i fue 0.011 y su varianza 1.38, lo que indica un buen ajuste del modelo de semivariograma (Bivand *et al.*, 2013, p. 225). Los parámetros de la Lou-CV para la predicción UK fueron ligeramente menores que los correspondientes parámetros de la predicción OK.

La distribución espacial de las locaciones con los valores más bajos y altos de los z_i de la predicción UK fue similar a la de OK. Para UK el valor más bajo fue -4.96 y el valor más alto fue 2.48. En ambos casos (OK y UK), la media y varianza de los z_i fue cercana a 0 y 1, respectivamente, lo que de acuerdo con Bivand *et al.* (2013, p. 225) indica un buen ajuste del modelo de semivariograma, con un rendimiento ligeramente menor para la interpolación OK.

Los resultados de la interpolación IDW se muestran en la Figura 3 parte c. Para esta interpolación pudo observarse el efecto de los valores medidos en estaciones individuales, que genera zonas de influencia circular alrededor de ellas. Este patrón espacial puede considerarse incorrecto, dado que los patrones de PP están distribuidos sobre un contexto regional o global más que en un rango local alrededor de los pluviómetros (Smalley & L'Ecuyer, 2015). Como se esperaba, los parámetros de Lou-CV para esta interpolación $R^2 = 0.2$ y $r = 0.44$ (p -value = 0.0005) fueron los más bajos, comparados con los resultados de OK y UK. Los parámetros NSE y RSD obtuvieron valores 0.19 y 0.89, respectivamente, indicando un rendimiento inadecuado (Burgan & Aksoy 2022).

Evaluación de desescalamiento de estimados satelitales con OK

Los resultados del desescalamiento geoestadístico de estimados de PP de TRMM y GPM usando OK se presentan en la Figura 4.

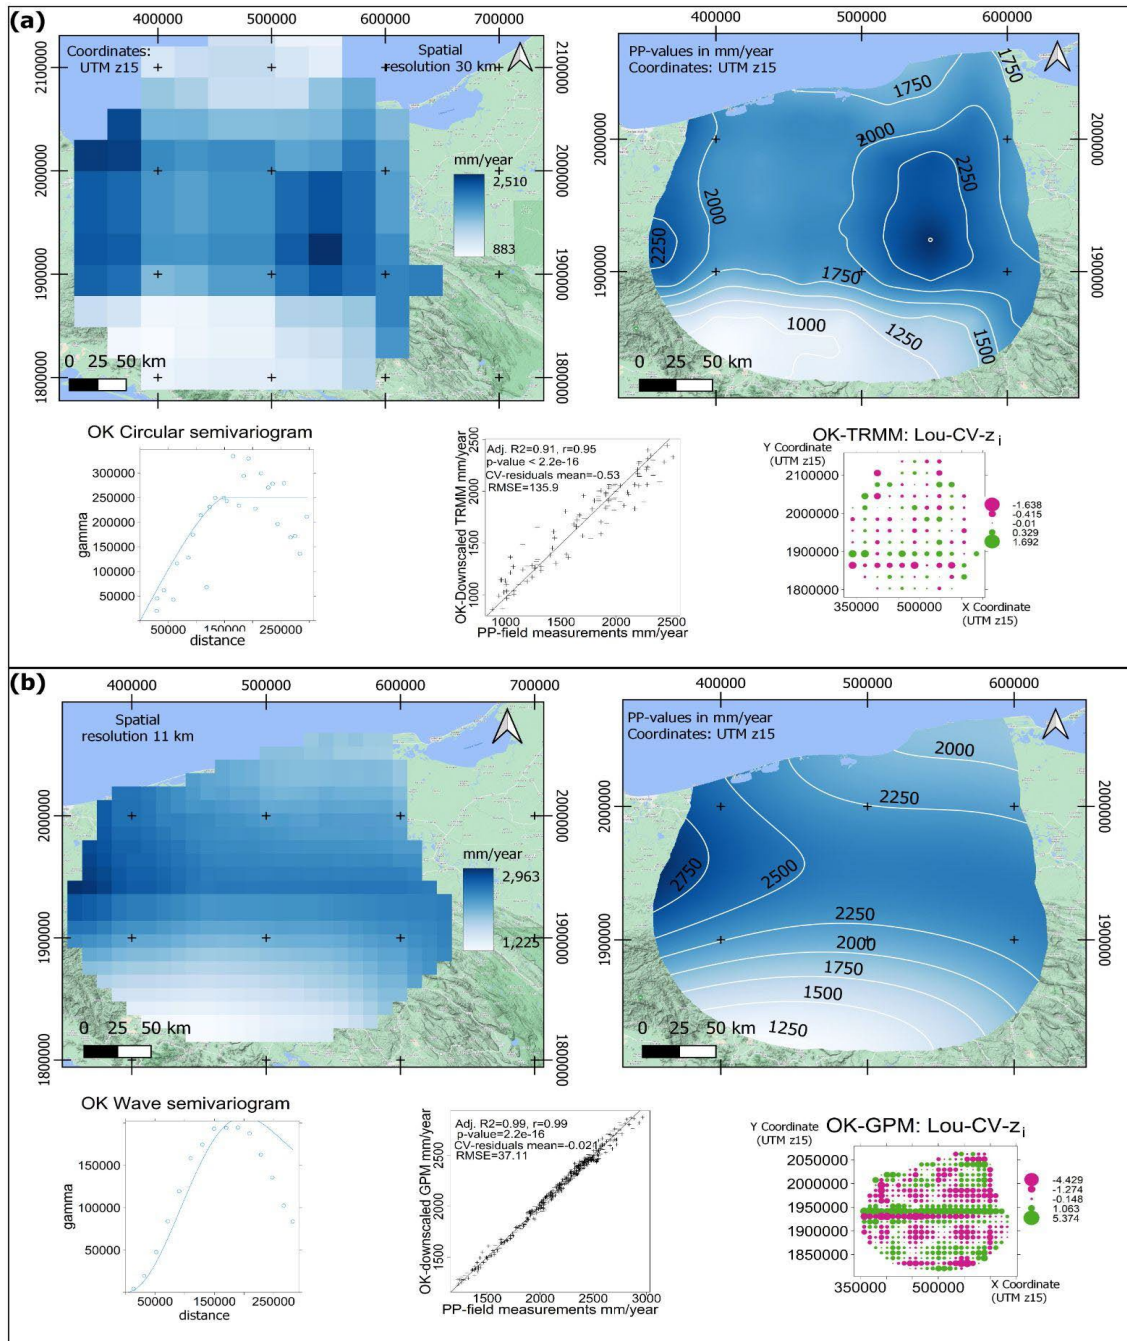


Figura 4. Resultados de la predicción y de Lou-CV del procedimiento de desescalamiento usando OK de estimados satelitales de TRMM (a) y de

de GPM (b), agregados para el año 2001. Cada parte de la figura incluye mapas de los datos a la resolución original y mapas de los valores desescalados, los semivariogramas ajustados a estos datos, los resultados de Lou-CV en dos gráficas: un diagrama de dispersión entre las predicciones OK y los valores originales (valores de centros de celda) incluyendo R^2 y r , p -, la media de los residuales de CV, el RMSE y un mapa mostrando la distribución espacial de los z_i .

Las mediciones con pluviómetros tuvieron valores entre 540 y 3 948 mm, los estimados de TRMM (parte (a), izquierda) de 883 a 2 510 mm, y los de GPM (parte (b), izquierda) de 1 225 a 2 963 mm (rangos de 3 408, 1 627 y 1 738 mm, respectivamente). Los estimados satélites tienen los rangos menores porque se consideran suavizadores espaciales debido al gran tamaño de la celda en comparación con las mediciones puntuales con pluviómetros (Toté *et al.*, 2015).

Para el desescalamiento con OK de TRMM (Figura 4, parte a), no fue necesario transformar los datos y se ajustó un modelo circular de semivariograma. La capa espacial obtenida tuvo un patrón más suavizado que la capa original de TRMM, lo que es más adecuado para la escala local.

Los parámetros de Lou-CV del desescalamiento con OK de TRMM (Figura 4, parte a, debajo de los mapas) fueron R^2 ajustada = 0.91, r = 0.95 y p = 2.2e-16. La media de los residuales de CV y el RMSE fueron 0.53 y 135.9, respectivamente. NSE y RSD obtuvieron los valores 0.91 y 0.30, respectivamente, indicando muy buen rendimiento (Burgan & Aksoy, 2022).

Los z_i resultantes tuvieron media de 0.001 y varianza de 0.43, indicando un buen ajuste del modelo de semivariograma (Bivand *et al.*, 2013, p. 225). Los valores de z_i tuvieron un mínimo de -1.64 y un máximo de 1.69. Los parámetros resultantes indicaron un fuerte ajuste entre los valores de PP predichos y los medidos.

Se ajustó un modelo wave de semivariograma para el desescalamiento con OK de GPM (Figura 4, parte b). De acuerdo con la Lou-CV, se observó un ajuste casi perfecto entre las mediciones con pluviómetros y los valores predichos (R^2 ajustado = 0.99, $r = 0.99$, y $p = 2.2e-16$). La media de los residuales de CV y el RMSE fueron -0.021 y 37.11. NSE y RSE obtuvieron los valores 0.99 y 0.1, respectivamente, indicando muy buen rendimiento (Burgan & Aksoy, 2022). Los z_i tuvieron una media de -0.0204 y varianza de 2.98, lo que señala un buen ajuste del modelo de semivariograma (Bivand *et al.*, 2013, pp. 225). Estos parámetros de evaluación fueron los mejores comparados con los de las demás interpolaciones (para integración o para desescalamiento).

Evaluación de la integración con RK de mediciones de pluviómetros con estimados satelitales

Los resultados de la integración con TRMM a su resolución original se muestran en la Figura 5 parte a. Se ajustó un modelo de semivariograma gaussiano. Una relación lineal entre las mediciones de pluviómetros y los correspondientes valores de TRMM se observó con un R^2 ajustado de 0.48 ($r = 0.69$, p -value = $3.77e-09$). Sin embargo, la resolución original de

TRMM generó un patrón espacial con muchas discontinuidades en la capa espacial resultante.

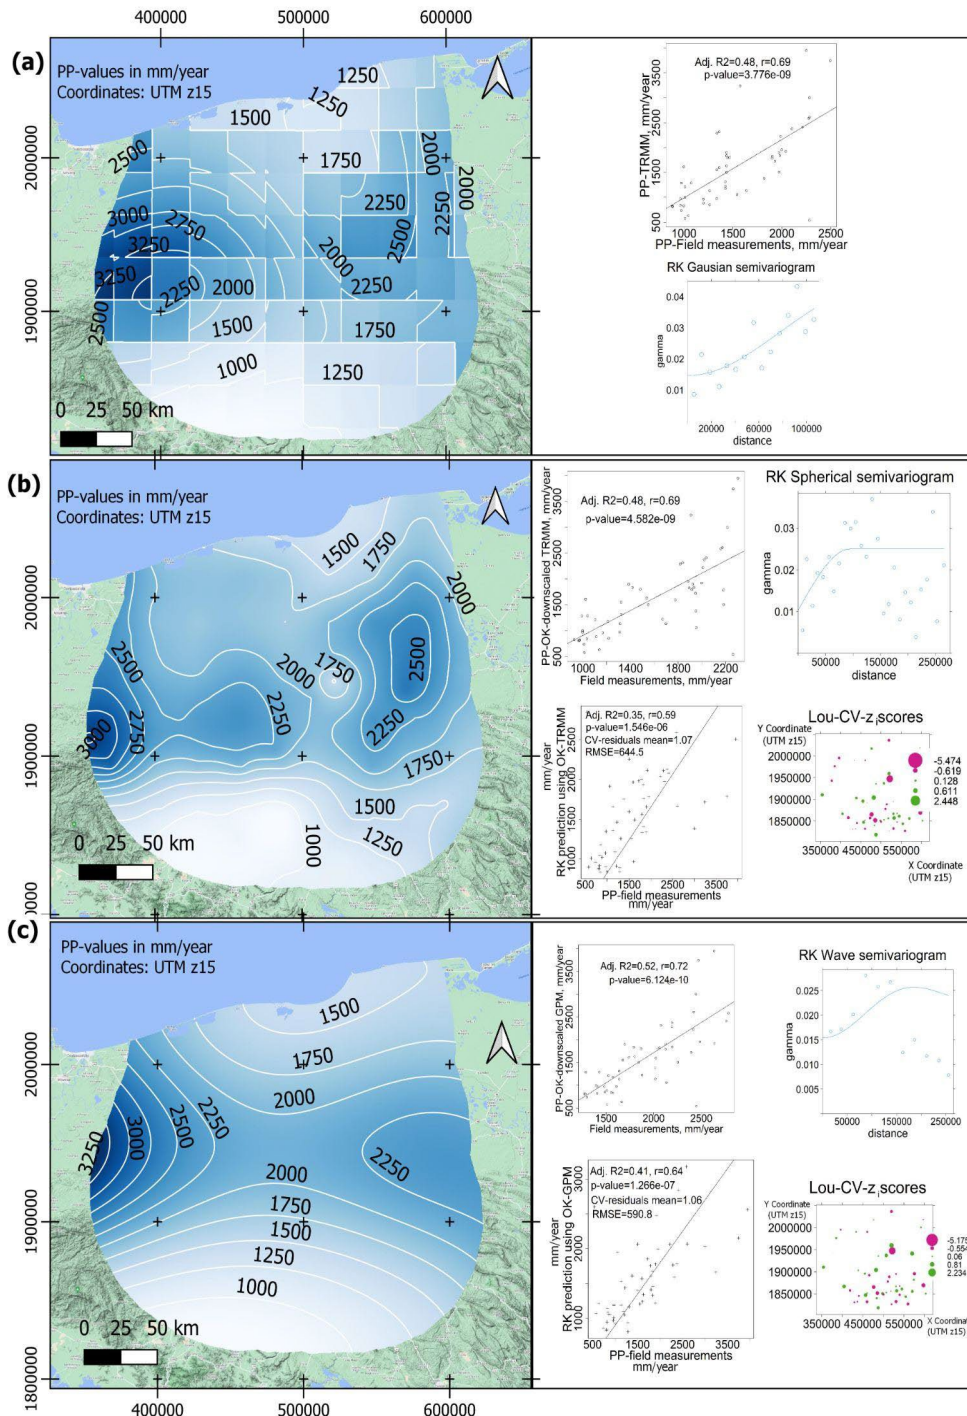


Figura 5. Predicción y resultados de Lou-CV de la integración con RK de datos agregados anuales de PP para 2001 obtenidos desde mediciones

de pluviómetros y de estimados satelitales. Parte a: resultados de la integración con TRMM a resolución original. Parte b: resultados de la integración con valores desescalados con OK de TRMM. Parte c: resultados de la integración con datos desescalados con OK de GPM. Cada parte de la figura incluye el mapa de valores predichos de PP, el diagrama de dispersión que muestra la relación lineal entre los valores integrados y el semivariograma ajustado. Partes (b) y (c) incluyen los resultados de Lou-CV con dos gráficas: un scatterplot entre las predicciones y los valores medidos mostrando los valores de R^2 , r , p , la media de los residuales de CV, RMSE, y un mapa mostrando la distribución espacial de los z_i .

Los resultados de la integración con RK de los datos de pluviómetros con datos desescalados de TRMM como variable auxiliar se muestran en la Figura 5, parte b. Una relación lineal ($R^2 = 0.48$, $r = 0.69$, $p = 4.582e-09$) entre las mediciones con pluviómetros y los correspondientes valores desescalados de TRMM permitió el uso de estos valores desescalados para obtener el valor tendencial de los valores predichos en modelo de RK aplicado. Un modelo esférico de semivariograma ajustó las mediciones de pluviómetros transformadas logarítmicamente. La capa espacial resultante fue similar a la de la predicción con UK (Figure 3, parte b). Los parámetros de la Lou-CV $R^2 = 0.35$, $r = 0.59$, $p = 1.54e-06$, media de los residuales de CV y RMSE = 644.5 indicaron un ajuste moderado entre los valores predichos y los valores medidos de PP. Los parámetros NSE y RSD tuvieron valores de 0.29 y 0.83, respectivamente, indicando un rendimiento inadecuado (Burgan & Aksoy, 2022). Los valores de R^2 y r

fueron más altos para esta interpolación, comparados con los correspondientes valores de las interpolaciones de mediciones con pluviómetros usando OK (Figura 3, parte a) y UK (Figura 3, parte b). Esto también puede apreciarse en la Tabla 2. Los z_i tuvieron una media de -0.009 y una varianza de 1.53. Estos valores indican un buen ajuste del modelo de semivariogram de RK (Bivand *et al.*, 2013, p. 225). El mapa de z_i muestra que las locaciones con los valores más bajos (con un mínimo de -5.47) estuvieron localizados en las partes centro y sureste del área de estudio. Las locaciones con los valores más altos de z_i (con un máximo de 2.23) estuvieron en el centro y la mitad del área de estudio.

En el caso de la integración con RK usando como información auxiliar datos desescalados con OK de GPM, una relación lineal (R^2 ajustada = 0.52, $r = 0.72$ y $p = 6.124e-10$) entre las mediciones con pluviómetros y esos datos desescalados permitió obtener la tendencia de los valores predichos con el modelo RK aplicado. Se ajustó un semivariograma tipo wave. Los parámetros de Lou-CV ($R^2 = 0.41$, $r = 0.64$, p -value = $1.26e-06$, media de los residuales de CV = 1.07 y RMSE = 590.8) indicaron una relación lineal moderada entre los datos de PP integrados. NSE y RSD (0.40 y 0.76) señalaron un rendimiento inadecuado (Burgan & Aksoy, 2022). Sin embargo, la media (-0.009) y varianza (1.53) de los z_i indicaron un buen ajuste del modelo de semivariograma. Los valores más bajos del mapa de z_i (con un mínimo de -5.17) estuvieron localizados en las partes centro y sureste del área de estudio. Los valores más altos (con un máximo de -2.45) se tienen también en las partes central y sureste. Dichos resultados indican un rendimiento aceptable del modelo predictivo para obtener una capa

espacial adecuada para la escala local. Entre los métodos de interpolación de mediciones de pluviómetros, la integración de estas mediciones con valores desescalados con OK de GPM obtuvieron los mejores parámetros de Lou-CV (ver Tabla 2).

PCA y comparación de correlaciones entre capas de valores predichos de PP

El mapa de calor, el correlograma y el biplot de PCA para definir similitud entre los valores de capas de PP obtenidas se incluyeron en la Figura 6. Los resultados de la integración con RK de datos de pluviómetros con datos desescalados con OK de GPM (mostrados en la figura como RK_OK.GPM) y los del desescalamiento con OK de GPM (mostrados en la figura como OK_GPM) fueron los más cercanos entre sí, al formar un clúster de colores encendidos en el mapa de correlación (Figura 6, parte a). Los resultados de TRMM desescalados con OK (mostrados en la figura como OK_TRMM) y de IDW fueron los resultados más separados de todos los demás. Estos resultados no fueron agrupados en ningún clúster y tuvieron los colores más fríos en el mapa de calor. La misma situación se observó con el biplot (Figura 6, parte c). Los resultados del desescalamiento con OK de TRMM fueron los más separados de los demás, seguidos por IDW. Como se observó en este biplot, los resultados del desescalamiento con OK de GPM (mostrados en la figura como OK-GPM) y los de la integración con RK de datos de pluviómetros y datos desescalados con OK de GPM estuvieron cercanos entre sí. Los resultados

mostrados en las tres partes de la Figura 6 verificaron la similitud entre las predicciones de OK y UK de mediciones de pluviómetros. Estos resultados estuvieron separados de los demás resultados, pero cercanos entre sí en el biplot y en el mapa de calor, que mostró colores encendidos para ellos con r de 0.96.

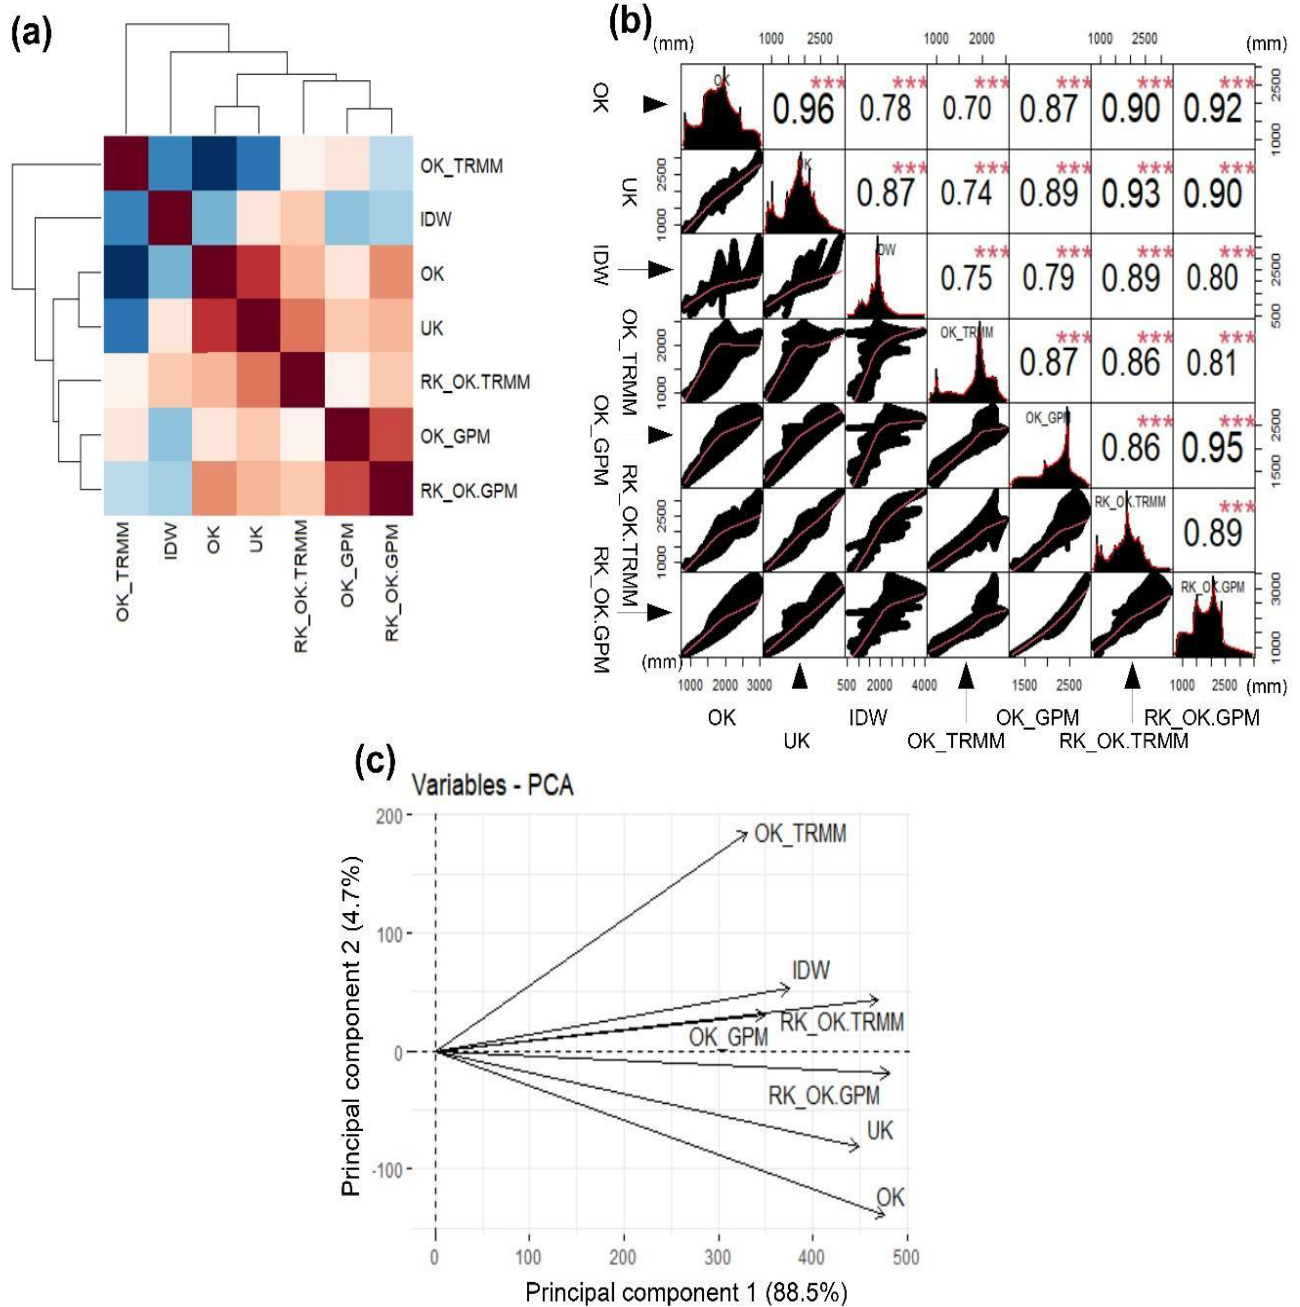


Figura 6. (a): Mapa de calor del análisis de correlación mostrando el dendrograma de agrupamientos, (b): correlograma con diagramas de dispersión de las comparaciones bivariadas, r y significancias mostradas

con asteriscos (tres significan alta significancia), así como histogramas de cada resultado de predicción, y (c): biplot de PCA de los valores predichos de PP. Los valores comparados son predicciones de OK, UK e IDW de mediciones de pluviómetros, estimaciones satelitales de TRMM desescaladas con OK (OK_TRMM) y de GPM desescaladas con OK (OK_GPM), al igual que resultados de la integración de datos de pluviómetros con valores de TRMM desescalados con OK (RK_OK.TRMM) y con valores de GPM desescalados con OK (RK_OK.GPM).

La cercanía entre los resultados de datos de GPM desescalados con OK con los de la integración de éstos con RK de datos de pluviómetros con datos de GPM desescalados con OK fue confirmada en el correlogama (Figure 6, parte b) con un r de 0.95. Todas las correlaciones fueron altamente significantes (indicadas con tres asteriscos en la matriz de correlación). IDW mostró una $r < 0.8$ con todos los otros resultados con la excepción de $r = 0.89$ con la integración con RK de datos de pluviómetros con datos de TRMM desescalados con OK, lo que confirma su bajo rendimiento y cercanía entre ambos resultados.

En cuanto a los diagramas de dispersión de la comparación bivariada (Figura 6, parte b), los resultados fueron diferentes, en particular para los valores más altos de PP. Se pudo ajustar una línea de tendencia para los valores bajos, pero presentó una reducción abrupta de pendiente para los valores mayores. Esto pasó, por ejemplo, con la comparación de resultados entre IDW y los de la integración con RK de mediciones de pluviómetros con GPM desescalado con OK, así como entre los de GPM desescalado con OK y los de TRMM desescalado con OK. Los

histogramas de los resultados de las predicciones se muestran en la Figura 6, parte b, como una diagonal de cuadros, formado desde la esquina superior izquierda a la esquina inferior derecha. Ellos indican la disimilitud de IDW con respecto a las otras predicciones. La disimilitud se observó en términos de forma y escala del histograma.

Discusión

El enfoque del presente trabajo fue evaluar geoestadística para desescalar estimados satelitales de GPM y TRMM, e integrar los resultados con mediciones de pluviómetros para obtener una capa espacial de valores anuales de PP adecuada para ser usada a escala local en una cuenca tropical, tomando un año como un caso de estudio. Lo anterior es parte de lo innovador del trabajo, debido a que de acuerdo con la revisión de literatura, previo a este estudio, no se había efectuado investigación acerca del desescalamiento geoestadístico de estimados de GPM para ser integrados usando RK con datos de pluviómetros en una cuenca tropical, y en zonas externas a Asia y Europa.

Los estimados satelitales estudiados integran, desde su producción, datos de pluviómetros de algunas pocas estaciones (tres o menos) para la zona del estudio (GPCC, 2012). Por ello, en el presente estudio, todos los datos disponibles de pluviómetros se integraron con las estimaciones satelitales para obtener una capa espacial de PP adecuada para la escala local. El procedimiento de desescalamiento con OK de estimados

satelitales de GPM permitió una mejora sustancial del patrón espacial local de la capa resultante.

Entre los enfoques de interpolación de mediciones de pluviómetros, el método mejor evaluado con los parámetros de Lou-CV fue el que integró mediante RK estas mediciones con valores desescalados con OK de GPM. Estos resultados pueden ser adecuados para la escala local, porque integraron todos los valores medidos de PP, que se consideran los valores de referencia (New *et al.*, 2001), y los estimados de GPM que pueden capturar la variabilidad espacial de la PP. Sin embargo, NSE y RSE indicaron un rendimiento inadecuado de esta integración geoestadística. Al respecto, es necesario llevar a cabo más investigación de otros años y otras condiciones climáticas para confirmar estos resultados. Las interpolaciones OK y UK tuvieron valores menores de los parámetros de la Lou-CV respecto a los de RK. OK fue ligeramente superior que UK. El patrón espacial observado de los valores predichos de IDW, UK y RK fue diferente. Este patrón puede ser el primer elemento para seleccionar un método para obtener un continuo espacial de PP útil a la escala local. Dado que los patrones de PP se distribuyen sobre un contexto regional o global más que sobre un rango local sobre las estaciones de medición (Smalley & L'Ecuyer, 2015), el patrón espacial resultante de IDW se consideró incorrecto.

De acuerdo con los parámetros de la Lou-CV, la integración con OK de datos de pluviómetros con los de GPM desescalados con OK sobrepasa el rendimiento de la otra integración de estos datos con estimados de TRMM desescalados con OK. La cercanía entre los resultados de GPM desescalados con OK y los de la integración con RK de mediciones de

pluviómetros con los valores de GPM desescalados con OK, observados en el PCA y en el análisis de correlación (abordados en la sección anterior) es interesante dado que los primeros resultados incluyen mediciones y los últimos no. Además, la Figura 4 (parte b) y Figura 5 (parte c) muestran un patrón espacial similar entre ambas predicciones, pero diferente de los otros resultados. Esta observación confirma que los estimados de GPM pueden ser desescalados utilizando OK para obtener una capa espacial adecuada a la escala local con o sin integración de mediciones en campo.

Cokriging colocado (CK) no fue incluido en este trabajo para hacer la integración debido a que fue desarrollado para situaciones en las que la información auxiliar no es exhaustiva espacialmente (Knotters, Brus, & Voshaar, 1995; Hengl *et al.*, 2007), es decir, que no está disponible en todo el espacio de predicción. De acuerdo con Hengl *et al.* (2007), al aplicar RK no es necesario que la variable auxiliar defina el 100 % de la variabilidad del valor a interpolar. La condición es que ambas variables estén correlacionadas. No se encontró relación lineal entre los datos de pluviómetros y valores de altitud. Sin embargo, para otras condiciones climáticas y zonas geográficas, la elevación puede ser un factor que defina buena parte de la variabilidad espacial de PP. Por tanto, su inclusión puede mejorar los estimados en la integración estadística propuesta en este estudio, como se encontró en otros (Goovaerts, 2000; Rata *et al.*, 2020). Los efectos del tamaño de pixel, métodos que manejan incertidumbre, como kriging bayesiano y la inclusión de otras variables auxiliares, como distancia a la costa, pueden ser investigados posteriormente y están incluidos para desarrollar trabajo futuro.

Investigación realizada de forma previa (Abdollahipour *et al.*, 2022; Park *et al.*, 2017; Chen *et al.*, 2020; Chen *et al.*, 2019) incluyó parámetros de rendimiento para validar con mediciones en campo, pero no la determinación de la similitud de los valores predichos de PP utilizando PCA, análisis de correlación y de clúster, tomando un enfoque reconocido de bajo rendimiento como referencia. En esta investigación, IDW de mediciones de pluviómetros se consideró la referencia de bajo rendimiento. Así, se encontró similitud entre los resultados de IDW con los de la integración con RK de mediciones de pluviómetros con datos desescalados de TRMM usando OK y también con los del desescalamiento de TRMM con OK por sí solos. Estos resultados y el hecho de que los valores más bajos de los parámetros de la Lou-CV correspondieron a IDW, indicaron que los estimados de TRMM no resultaron adecuados para ser usados a la escala local; no obstante, el desescalamiento con OK de TRMM obtuvo buenos parámetros de evaluación con Lou-CV (z_i , RMSE, NSE y RSD). Estos descubrimientos son relevantes, dado que en la literatura revisada, los estimados satelitales de TRMM agrupados en diferentes periodos de tiempo han sido los más integrados con mediciones en campo usando kriging (Abdollahipour *et al.*, 2022; Park *et al.*, 2017; Chen *et al.*, 2020; Chen *et al.*, 2019).

Conclusión

El estudio presente muestra que las técnicas geoestadísticas pueden ayudar a desescalar datos satelitales de PP e integrarlos con valores



medidos en campo para generar capas espaciales de PP que pueden ser útiles a la escala local para cuencas tropicales, como el área estudiada. La evaluación de resultados —que por lo común envuelve métricas de rendimiento desde procedimientos de validación cruzada— debe ser complementada con métodos que definen similitud de los valores resultantes a un resultado de interpolación que puede ser de bajo rendimiento, como se hizo en la presente investigación. La razón de esto es que, aunque el resultado de interpolación puede tener buenas métricas de rendimiento, al mismo tiempo puede tener un alto grado de similitud con la capa de bajo rendimiento. Esto significa que el método de interpolación aplicado puede funcionar bien para predecir los valores observados, pero puede hacerlo no tan bien para predecir los valores de locaciones sin mediciones, como pasa con la capa de referencia (de bajo rendimiento). Como se encontró en investigación previa, las técnicas geoestadísticas pueden ser aplicadas para desescalar datos satelitales de TRMM e integrarlas con valores medidos. No obstante, este estudio encontró que el resultado puede ser similar a IDW y, por lo tanto, en esos casos, no es recomendable usarla a escala local en cuencas tropicales como la zona de estudio. En cambio, datos desescalados con OK de GPM pueden ser usados con o sin integración geoestadística con RK con datos de pluviómetros para obtener una capa espacial adecuada a la escala local. La investigación desarrollada permite concluir que OK funciona bien para desescalar estimados satelitales de GPM.

La integración usando RK de GPM desescalada con OK con mediciones de pluviómetros puede mejorar de modo sustancial los indicadores de Lou-CV, en comparación con los valores resultantes de las

predicciones con UK y OK de mediciones de pluviómetros. La capa espacial resultante puede considerarse un producto mejorado en términos de ser más adecuado para la escala local, en la que el proceso de toma de decisiones puede ser llevado a cabo. De acuerdo con los análisis de PCA, clúster y correlación, las capas espaciales obtenidas desde datos de GPM desescalados con OK, así como los de la integración de éstos con mediciones de pluviómetros, muestran valores similares, lo cual indica que son adecuados para la escala local.

Esta investigación demuestra que los métodos geoestadísticos son efectivos para desescalar estimados satelitales y para integrarlos con mediciones de pluviómetros para obtener capas espaciales capaces de apoyar el proceso de toma de decisiones a nivel local.

Agradecimientos

Se agradece al Dr. Eugenio Reyes por invitar al autor a participar en el proyecto de Conacyt 248719. Gracias a la Dra. Charlotte Smith (Berkeley University) por sus comentarios.

Esta investigación fue financiada por proyecto CONACYT número 248719 de las propuestas sobre problemas nacionales 2014 y por el proyecto FORDECYT 2018-10 297259.

Apéndice

```
// Google Earth Engine (GEE) script to download GPM data.

var dataset =
ee.ImageCollection('NASA/GPM_L3/IMERG_MONTHLY_V06')
.filterDate('2001-01-01', '2001-12-31');

// Select the max precipitation and mask out low precipitation values.
var precipitation = dataset.select('precipitation').sum();
var mask = precipitation.gt(0.01);
var precipitation = precipitation.updateMask(mask);
var precipitation = precipitation.multiply(720)
var palette = [
'000096', '0064ff', '00b4ff', '33db80', '9beb4a',
'ffeb00', 'ffb300', 'ff6400', 'eb1e00', 'af0000'
];
var precipitationVis = {min: 0.0, max: 2000, palette: palette};
Map.addLayer(precipitation, precipitationVis, 'Precipitation');
Map.setCenter(-92, 17, 7);

var geometry = ee.Geometry.Rectangle([-94.4, 18.8, -91.5116, 15.0]);
```

```
Export.image.toDrive({  
  image: precipitation,  
  description: "GPM_Precipitation_2001_mmanno",  
  scale: 11000,  
  region: geometry,  
  fileFormat: "GeoTIFF",  
});  
1
```

Referencias

- Abdollahipour, A., Ahmadi, H., & Aminnejad, B. (2022). A review of downscaling methods of satellite-based precipitation estimates. *Earth Science Informatics* 15, 1-20. Recuperado de <https://doi.org/10.1007/s12145-021-00669-4>
- AghaKouchak, A., Behrangi, A., Sorooshian, S., Hsu, K., & Amitai, E. (2011). Evaluation of satellite-retrieved extreme precipitation rates across the central United States. *Journal of Geophysical Research*, 116, 1-11. Recuperado de <https://doi.org/10.1029/2010jd014741>
- Agou, V. D., Varouchakis, E. A., & Hristopoulos, D. T. (2019). Geostatistical analysis of precipitation in the island of Crete (Greece) based on a sparse monitoring network. *Environmental Monitoring Assessment* 191(353), 1-24. Recuperado de <https://doi.org/10.1007/s10661-019-7462-8>

- Anagnostou, E. N., Maggioni, V., Nikolopoulos, E. I., Meskele, T., Hossain, F., & Papadopoulos, A. (2010). Benchmarking high-resolution global satellite rainfall products to radar and rain-gauge rainfall estimates. *IEEE Transactions Geosciences and Remote Sensing*, 48, 1667-1683. Recuperado de <https://doi.org/10.1109/TGRS.2009.2034736>
- Bell, T. L. (2003). Comparing satellite rainfall estimates with rain gauge data: Optimal strategies suggested by a spectral model. *Journal of Geophysical Research*, 108(D3)4121, 1-15. Recuperado de <https://doi.org/10.1029/2002JD002641>
- Berndt, C., Rabiei, E., & Haberlandt, U. (2013). Geostatistical merging of rain gauge and radar data for high temporal resolutions and various station density scenarios, *Journal of Hydrology*, 508, 88-101. Recuperado de <https://doi.org/10.1016/j.jhydrol.2013.10.028>
- Bivand, R. S., Pebesma, E. J., & Gómez-Rubio, V. (2013). *Applied spatial data analysis with R*. New York, USA: Springer. Recuperado de <https://doi.org/10.1007/978-0-387-78171-6>
- Bowman, K.P. (2005). Comparison of TRMM P retrievals with rain gauge data from ocean buoys. *Journal of Climate*, 18(1), 178-190. Recuperado de <https://doi.org/10.1175/JCLI3259.1>
- Burgan, H. I., & Aksoy, H. (2022). Daily flow duration curve model for ungauged intermittent sub-basins of gauged rivers. *Journal of Hydrology*, 604, 127429. Recuperado de <https://doi.org/10.1016/j.jhydrol.2021.127249>

Cepal & Cenapred, Centro Nacional de Prevención de Desastres & Comisión Económica para América Latina y el Caribe. (2008). *Tabasco: características e impacto socioeconómico de las inundaciones provocadas a finales de octubre y a comienzos de noviembre de 2007 por el frente frío número 4. Informe LC/MEX/L.864.* Recuperado de <https://repositorio.cepal.org/handle/11362/25881>

Cersosimo, A., Larosa, S., Romano, F., Cimini, D., Di Paola, F., Gallucci, D., Gentile, S., Geraldini, E., Teodosio-Nilo, S., Ricciardelli, E., Ripepi, E., & Viggiano, M. (2018). Downscaling of satellite OPEMW surface rain intensity data. *Remote Sensing*, 10(11), 1763, 1-16. Recuperado de <https://doi.org/10.3390/rs10111763>

Chen, F., Gao, Y., Yiguo, W., & Li, X. (2020). A downscaling-merging method for high-resolution daily precipitation estimation. *Journal of Hydrology*, 581(124414), 1-15. Recuperado de <https://doi.org/10.1016/j.jhydrol.2019.124414>.

Chen, S., Zhang, L., She, D., & Chen, J. (2019). Spatial downscaling of tropical rainfall measuring mission (TRMM) annual and monthly precipitation data over the middle and lower reaches of the Yangtze River Basin, China. *Water*, 11(3), 568. Recovered from <https://doi.org/10.3390/w11030568>

Conagua, Comisión Nacional del Agua. (2015). *Estadísticas del agua en México.* Recuperado de <https://agua.org.mx/biblioteca/estadisticas-del-agua-en-mexico-edicion-2015/>

Cressie, N. (1990). The origins of kriging. *Mathematical Geology*, 22, 239-252. Recuperado de <https://doi.org/10.1007/BF00889887>

Curran, P. J., & Atkinson, P. M. (1998). Geostatistics and remote sensing. *Progress in Physical Geography: Earth and Environment*, 22(1), 61-78. Recuperado de <https://doi.org/10.1177/030913339802200103>

Dumitrescu, A., Brabec, M., & Matreata, M. (2020). Integrating ground-based observations and radar data into gridding sub-daily precipitation. *Water Resources Management*, 34, 3479-3497. Recuperado de <https://doi.org/10.1007/s11269-020-02622-4>

GPCC, Global Precipitation Climatology Centre. (2012). *Number of stations used by GPC for May 2012*. Recuperado de <https://climatedataguide.ucar.edu/climate-data/gpcc-global-precipitation-climatology-centre>

Gobierno de México. (November 12, 2020). *Información de estaciones climatológicas*. Recuperado de <https://smn.conagua.gob.mx/es/climatologia/informacion-climatologica/informacion-estadistica-climatologica>

GES DISC, Goddard Earth Sciences Data and Information Services Center. (2011). *Tropical Rainfall Measuring Mission (TRMM) (2011), TRMM (TMPA/3B43) Rainfall Estimate L3 1 month 0.25 degree x 0.25 degree V7. [Data file]*. Recuperado de <https://doi.org/10.5067/TRMM/TMPA/MONTH/7>

Goovaerts, P. (1997). *Geostatistics for natural resource evaluation*. New York, USA: Oxford University Press.

- Goovaerts, P. (2000). Geostatistical approaches for incorporating elevation into the spatial interpolation of rainfall. *Journal of Hydrology*, 228(1-2), 113-129. Recuperado de [https://doi.org/10.1016/S0022-1694\(00\)00144-X](https://doi.org/10.1016/S0022-1694(00)00144-X)
- Greene, J. S., & Morrysey, M. L. (2000). Validation and uncertainty analysis of satellite rainfall algorithms. *Professional Geographer*, 52(29), 247-258. Recuperado de <https://doi.org/10.1111/j.0033-0124.2000.t01-1-x>
- Hengl, T. (2009). *A practical guide to geostatistical mapping of environmental variables*. Luxembourg, Luxembourg: European Communities, Publications Office. Recuperado de http://spatial-analyst.net/book/system/files/Hengl_2009_GEOSTATE2c1w.pdf
- Hengl, T., Gerard, B., Heuvelink, M., & Rossiter, D. G. (2007). About regression-kriging: From equations to case studies. *Computer and Geosciences*, 33(10), 1301-1315. Recovered from <https://doi.org/10.1016/j.cageo.2007.05.001>
- Holawe, F., & Dutter, R. (1999). Geostatistical study of precipitation series in Austria: Time and space. *Journal of Hydrology*, 219(1-2), 70-82. Recuperado de [https://doi.org/10.1016/S0022-1694\(99\)00046-3](https://doi.org/10.1016/S0022-1694(99)00046-3)

- Huffman, G. J., Bolvin, D. T., Braithwaite, D., Hsu, K.-L., Joyce, R. J., Kidd, C. E., Nelkin, J., Sorooshian, S., Stocker, E. F., Tan, J., Wolff, D. B., & Xie, P. (2020). Integrated multi-satellite retrievals for the global precipitation measurement (GPM) mission (IMERG). In: Levizzani, V., Kidd, C., Kirschbaum, D., Kummerow, C., Nakamura, K., & Turk, F. (eds.). *Satellite precipitation measurement. Advances in global change research*. Vol. 69 (pp. 3-23). Cham, Switzerland: Springer. Recuperado de https://doi.org/10.1007/978-3-030-35798-6_1
- Huffman, G. J., Bolvin, D. T., Nelkin, E. J., Wolff, D. B., Adler, R. F., Gu, G., Hong, Y., Bowman, K. P., & 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. Recuperado de <https://doi.org/10.1175/JHM560.1>
- Huffman, G. J., Stocker, E. F., Bolvin, D. T., Nelkin, E. J., & Tan, J. (2019). *GPM IMERG final precipitation L3 half hourly 0.1 degree x 0.1 degree V06*. GES DISC, Goddard Earth Sciences Data and Information Services Center. Recuperado de <https://doi.org/10.5067/GPM/IMERG/3B-HH/06>
- INEGI, Instituto Nacional de Estadística y Geografía. (2010). *Red hidrográfica mexicana*. Recuperado de <https://www.inegi.org.mx/temas/hidrografia/default.html#Descargas>

- Keblouti, M., Ouerdachi, L., & Boutaghane, H. (2012). Spatial interpolation of annual precipitation in Annaba-Algeria. Comparison and evaluation of methods. *Energy Procedia*, 18, 468-475. Recuperado de <https://doi.org/10.1016/j.egypro.2012.05.058>.
- Kidd, C., Takayabu, Y. N., Skofronick-Jackson, G. M., Huffman, G. J., Braun, S. A., Kubota, T., & Turk, F. J. (2020). The global precipitation measurement (GPM) mission. Integrated multi-satellite retrievals for the global precipitation measurement (GPM) mission (IMERG). In: Levizzani, V., Kidd, C., Kirschbaum, D., Kummerow, C., Nakamura, K., & Turk, F. (eds.). *Satellite precipitation measurement. Advances in global change research*. Vol. 69 (pp. 3-23). Cham, Switzerland: Springer. Recuperado de https://doi.org/10.1007/978-3-030-24568-9_19
- Knotters, M., Brus, D., & Voshaar, J. (1995). A comparison of kriging, co-kriging and kriging combined with regression for spatial interpolation of horizon depth with censored observations. *Geoderma*, 67 (3-4), 227-246.
- Kumar, V. (2007). Optimal contour mapping of groundwater levels using universal kriging—A case study. *Hydrological Sciences Journal*, 52, 1038-1050. Recuperado de <https://doi.org/10.1623/hysj.52.5.1038>

- Kummerow, C., Simpson, J., Thiele, O., Barnes, W., Chang, A. T. C., Stocker, E., Adler, R. F., Hou, A., Kakar, R., Wentz, F., Ashcroft, P., Kozu, T., Hong, Y., Okamoto, K., Iguchi, T., Kuroiwa, H., Im, E., Haddad, Z., Huffman, G., Ferrier, B., Olson, W. S., Zipser, E., Smith, E. A., Wilheit, T. T., North, G., Krishnamurti, T., & Nakamura, K. (2000). The status of the tropical rainfall measuring mission (TRMM) after two years in orbit. *Journal of Applied Meteorology and Climatology*, 39, 1965-1982. Recuperado de [https://doi.org/10.1175/1520-0450\(2001\)040<1965:TSOTTR>2.0.CO;2](https://doi.org/10.1175/1520-0450(2001)040<1965:TSOTTR>2.0.CO;2)
- Kummerow, C., Barnes, W., Kozu, T., Shiue, J., & Simpson, J. (1998). The tropical rainfall measuring mission (TRMM) sensor package. *Journal of Atmospheric and Oceanic Technology*, 15, 809-817. Recuperado de [https://doi.org/10.1175/1520-0426\(1998\)015<0809:TTRMMT>2.0.CO;2](https://doi.org/10.1175/1520-0426(1998)015<0809:TTRMMT>2.0.CO;2)
- Laurent, H., Jobard, I., & Toma, A. (1998). Validation of satellite and ground based estimates of precipitation over the Sahel. *Atmospheric Research*, 47-48, 651-670. Recuperado de [https://doi.org/10.1016/S0169-8095\(98\)00051-9](https://doi.org/10.1016/S0169-8095(98)00051-9)
- Lin, A., & Wang, X. L. (2011). An algorithm for blending multiple satellite precipitation estimates with in situ precipitation measurements in Canada. *Journal of Geophysical Research: Atmospheres*, 116(D21), 1-19. Recuperado de <https://doi.org/10.1029/2011JD016359>

- Massari, C., & Maggioni, V. (2020). Error and uncertainty characterization. In: Levizzani V., Kidd C., Kirschbaum D., Kummerow C., Nakamura K., & Turk F. (eds.). *Satellite precipitation measurement. Advances in global change research*. Vol. 69. Cham, Switzerland: Springer. Recuperado de https://doi.org/10.1007/978-3-030-35798-6_4
- Matheron, G. (1963). Principles of geostatistics. *Economic Geology*, 58, 1246-1266.
- Matheron, G. (1965). *Les variables régionalisées et leur estimation*. (Thèse). Paris, France: Masson.
- Matheron, G. (1971). *The theory of regionalized variables* (English translation). Les Cahiers du Centre de Morphologie Mathématique, Fasc 5. Paris, France: Ecole Nationale Supérieure des Mines de Paris (ENSMP).
- Morin, E., Marra, F., & Armon, M. (2020). Dryland precipitation climatology from satellite observations. In: Levizzani, V., Kidd, C., Kirschbaum, D., Kummerow, C., Nakamura, K., & Turk, F. (eds.). *Satellite precipitation measurement. Advances in global change research*. Vol. 69 (pp. 843-860). Cham, Switzerland: Springer. Recuperado de https://doi.org/10.1007/978-3-030-35798-6_19

- Nerini, D., Zulkafli, Z., Wang, L. P., Onof, C., Buytaert, W., Lavadocasimiro, W., & Guyot, J. L. (2015). A comparative analysis of TRMM-rain gauge data merging techniques at the daily time scale for distributed rainfall-runoff modeling applications. *Journal of Hydrometeorology*, 16, 2153-2168. Recuperado de <https://doi.org/10.1175/JHM-D-14-0197.1>
- New, M., Todd, M., Hulme, M., & Jones, P. (2001). Precipitation measurements and trends in the twentieth century. *International Journal of Climatology* 21, 1899-1922. Recuperado de <https://doi.org/10.1002/joc.680>
- Oliver, M. A., & Webster, R. (2015). *Basic steps in geostatistics: The variogram and kriging*. Heidelberg, New York, Dordrecht, London: Springer Cham. Recuperado de <https://doi.org/10.1007/978-3-319-15865-5>
- Park, N. W., Kyriakidis, P. C., & Hong, S. (2017). Geostatistical integration of coarse resolution satellite precipitation products and rain gauge data to map precipitation at fine spatial resolutions. *Remote Sensing*, 9(3), 255, 1-19. Recuperado de <https://doi.org/10.3390/rs9030255>
- Pebesma, E. J. (2004). Multivariable geostatistics in S: The gstat package. *Computer and Geosciences*, 30, 683-691. Recuperado de <https://doi.org/10.1016/j.cageo.2004.03.012>

Pielke, R. A., Stohlgren, T., Parton, W., Doesken, N., Money, J., & Schell, L. (2000). Spatial representativeness of temperature measurements from a single site. *Bulletin of the American Meteorological Society*, 81(4), 826-830. Recuperado de <https://www.jstor.org/stable/26215143>

R Core Team. (s.f.). *R: A language and environment for statistical computing*. Vienna, Austria: R Foundation for Statistical Computing. Recuperado de <https://www.R-project.org>

Rata, M., Douaoui, A., Larid, M., & Douaik, A. (2020). Comparison of geostatistical interpolation methods to map annual rainfall in the Chélif watershed, Algeria. *Theoretical and Applied Climatology*, 141, 1009-1024. Recuperado de <https://doi.org/10.1007/s00704-020-03218-z>

Ruiz-Alvarez, O., Singh, V. P., Enciso-Medina, J., Ontiveros-Capurata, R. E., & Corrales-Suastegui, A. (2020). Spatio-temporal trends of monthly and annual precipitation in Aguascalientes, Mexico. *Atmosphere*, 11(5), 437. Recuperado de <https://doi.org/10.3390/atmos11050437>

Sivasubramaniam, K., Sharma, A., & Alfredsen, K. (2019). Merging radar and gauge information within a dynamical model combination framework for P estimation in cold climates. *Environmental Modelling & Software*, 119, 99-110. Recuperado de <https://doi.org/10.1016/j.envsoft.2019.05.013>

Skofronick-Jackson, G., Kirschbaum, D., Petersen, W., Huffman, G., Kidd, C., Stocker, E., & Kakar, R. (2018). The global p measurement (GPM) mission's scientific achievements and societal contributions: Reviewing four years of advanced rain and snow observations. *Quarterly Journal of the Royal Meteorological Society*, 144(Suppl. 1), 27-48. Recuperado de <https://doi.org/10.1002/qj.3313>.

Smalley, M., & L'Ecuyer, T. (2015). A Global assessment of the spatial distribution of precipitation occurrence. *Journal of Applied Meteorology and Climatology*, 54(11), 2179-2197. Recuperado de <https://doi.org/10.1175/JAMC-D-15-0019.1>

Tapia-Silva, F. O., & Gómez-Reyes, E. (2020). Disponibilidad natural de agua en las subregiones de estudio. En: Aguilar-Benitez (ed.). *La gestión de los usos del agua en tres subregiones hidrológicas: río San Juan, Valle de México y Bajo Grijalva* (pp. 55-80), Tijuana, México: El Colegio de la Frontera Norte.

Tapia-Silva, F. O., Silván-Cárdenas, J. L., & Rosales-Arriaga, E. (2013) Análisis espacial, hacia una utilización mejorada de la información medida en campo y por satélites, para apoyar la toma de decisiones en materia hídrica y Ambiental. *Tecnología y ciencias del agua*, 4(1), 149-166. Recuperado de <http://www.revistatyca.org.mx/index.php/tyca/article/view/343/304>

- Toté, C., Patricio, D., Boogaard, H., Van der Wijngaart, R., Tarnavsky, E., & Funk, C. (2015). Evaluation of satellite rainfall estimates for drought and flood monitoring in Mozambique. *Remote Sensing*, 7(2), 1758-1776. Recuperado de <https://doi.org/10.3390/rs70201758>
- Van der Meer, F. (2012). Remote-sensing image analysis and geostatistics. *International Journal of Remote Sensing*, 33(18), 5644-5676. Recuperado de <https://doi.org/10.1080/01431161.2012.666363>
- Verdin, A., Rajagopalan, B., Kleiber, W., & Funk, C. (2015). A Bayesian kriging approach for blending satellite and ground precipitation observations. *Water Resources Research*, 51(2), 908-921. Recuperado de <https://doi.org/10.1002/2014wr015963>
- Wackernagel, H. (2003). *Multivariate geostatistics: An introduction with applications* (3rd ed.). Berlin, Heidelberg, Germany: Springer Science & Business Media.
- Wang, X. L., & Lin, A. (2015). An algorithm for integrating satellite precipitation estimates with in situ precipitation data on a pentad time scale. *Journal of Geophysical Research: Atmospheres*, 120, 3728-3744. Recuperado de <https://doi.org/10.1002/2014JD022788>

- WMO, World Meteorological Organization. (2008). *Guide to meteorological instruments and methods of observation*. WMO-No. 8 (7th ed.). Geneva, Switzerland: World Meteorological Organization. Recuperado de <https://www.weather.gov/media/epz/mesonet/CWOP-WMO8.pdf>
- Wu, Z., Zhang, Y., Sun, Z., Lin, Q., & He, H. (2018). Improvement of a combination of TMPA (or IMERG) and ground-based P and application to a typical region of the East China Plain. *Science of the Total Environment*, 640-641, 1165-1175. Recuperado de <https://doi.org/10.1016/j.scitotenv.2018.05.272>
- Yang, P., & Ng, T. L. (2019). Fast Bayesian regression kriging method for real-time merging of radar, rain gauge, and crowdsourced rainfall data. *Water Resources Research*, 55, 3194-3214. Recuperado de <https://doi.org/10.1029/2018WR023857>
- Zulkafli, Z., Buytaert, W., Onof, C., Manz, B., Tarnavsky, E., Lavado, W., & Guyot, J.-L. (2014). A comparative performance analysis of TRMM 3B42 (TMPA) versions 6 and 7 for hydrological applications over Andean-Amazon River Basins. *Journal of Hydrometeorology*, 15, 581-592. Recuperado de <https://doi.org/10.1175/JHM-D-13-094.1>