

Uso de modelos de regresión para interpolar espacialmente la precipitación media mensual en la cuenca del río Conchos*

Using regression models for spatially interpolated monthly average rainfall in the Conchos River Basin

Daniel Núñez López^{1,2§}, Eduardo Javier Treviño Garza¹, Víctor Manuel Reyes Gómez², Carlos Alfonso Muñoz Robles³, Oscar Alberto Aguirre Calderón¹ y Javier Jiménez Pérez¹

¹Facultad de Ciencias Forestales. Universidad Autónoma de Nuevo León. Carretera Nacional, km 145. C. P. 67700 Linares, Nuevo León, México (eduardo.trevinogr@uanl.mx; oscar.aguirrecl@uanl.mx; javier.jimenezp@uanl.mx). ²Instituto de Ecología A.C. Carretera Chihuahua-Ojinaga, km 33.3. C. P. 32910, Cd. Aldama, Chihuahua, México. (victor.reyes@inecol.edu). ³Instituto de Investigación de Zonas Desérticas, UASLP y Coordinación de Ciencias Sociales y Humanidades, UASLP. Altair no. 200, Col. del Llano C. P. 78377. San Luis Potosí, S. L. P. (carlos.munoz@uaslp.mx). [§]Autor para correspondencia: daniel.nunez@live.com.mx.

Resumen

En el presente estudio se analizaron datos mensuales de precipitación provenientes de 110 estaciones climáticas ubicadas al interior y en los alrededores de la Cuenca del Río Conchos (CRC) con el propósito de representar fiablemente la distribución espacial de la precipitación media mensual (PMM) para cada mes del año. Con la información de 60% de estaciones seleccionadas aleatoriamente, se ajustaron modelos de regresión lineal múltiple (MRLM) por pasos para predecir la PMM en función de la elevación del relieve, la proximidad de zonas marítimas y la localización geográfica de las estaciones. Los MRLM se utilizaron para interpolar espacialmente la PMM, obteniéndose mapas mensuales que fueron calibrados en función de los residuales. Pruebas de validación estadística se llevaron a cabo antes y después de la calibración espacial, utilizando el restante 40% de estaciones no consideradas en el proceso de ajuste de modelos. La proporción de varianza atribuible a las variables predictivas de los MRLM que comprenden el periodo de verano (junio a septiembre) osciló entre 71 y 76%, en tanto que para los modelos del periodo invernal (diciembre y enero) se mantuvo cercana a 50%. Las pruebas de validación estadística mostraron mejoras significativas en la fiabilidad después de calibrar los mapas

Abstract

In the present study, we analyzed monthly precipitation data from 110 weather stations located within and around Rio Conchos Basin (CRC) in order to reliably represent the spatial distribution of mean monthly precipitation (MMP) for each month of the year. With information from 60% of randomly selected stations were adjusted multiple linear regression models (MLRM) by MMP steps to predict based on the elevation of the terrain, the proximity of sea areas and the geographical location of the stations. The MLRM used to spatially interpolate the MMP; yielding monthly maps were calibrated according to the residuals. Statistical validation tests were conducted before and after the spatial calibration, using the remaining 40% of stations not considered in the model fitting process. The proportion of variance attributable to the predictors of MLRM comprising the summer period (June to September) ranged between 71 and 76%, while for models of the winter period (December and January) remained close to 50%. The validation tests showed statistically significant improvements in the reliability after calibrating MMP maps, resulting the months between May and September and November to January period, as the most reliable maps spatially represent the MMP.

* Recibido: julio de 2013
Aceptado: enero de 2014

de PMM, resultando los meses comprendidos entre mayo y septiembre, así como del periodo noviembre a enero, como los mapas más confiables para representar espacialmente la PMM.

Palabras clave: Cuenca del río Conchos, eficiencia de modelos, fiabilidad.

Introducción

La descripción espacial y temporal de variables climáticas es de gran utilidad para comprender el funcionamiento de procesos bio-físicos. La precipitación es una de las principales variables climáticas requeridas para la estimación de balances hídricos, recargas de frontera en la modelación de flujos de agua subterránea, evaluar procesos de erosión así como para definir las condiciones climáticas actuales. Sin embargo, la representación espacial fiable de la precipitación, es particularmente difícil en zonas montañosas con escasa disponibilidad de estaciones climáticas en donde el efecto orográfico es grande (Hevesi *et al.*, 1992; Huade *et al.*, 2005).

Diversos métodos estadísticos han sido desarrollados para predecir la distribución espacial de variables climáticas que difieren en su concepto y formulación matemática. Métodos de interpolación locales como polígonos de Thiessen e inverso de distancia ponderada (IDW) han sido de los más frecuentemente utilizados en la predicción climática y desarrollo cartográfico (New *et al.*, 2000; Vicente-Serrano *et al.*, 2003), al igual que procedimientos geo-estadísticos como Kriging, co-Kriging y Spline (Vicente-Serrano *et al.*, 2003; Apaydin *et al.*, 2004; Hong *et al.*, 2005).

Estudios como los de Dirks *et al.*, (1998) y Michaud y Sorooshian (1994) sugieren que cuando existe una alta densidad de estaciones climáticas, no existen diferencias significativas al interpolar datos de precipitación con los métodos de IDW y el de Kriging. En México, a pesar de la importancia que representa la información climática para la toma de decisiones, han sido pocos los esfuerzos realizados para evaluar la bondad de métodos de interpolación de datos climáticos, destaca el análisis comparativo desarrollado por Díaz *et al.* (2008) en el que evalúan cuatro métodos de interpolación para representar espacialmente la precipitación particularmente en la región de sotavento y barlovento del Golfo de México, concluyen que el método thin plate smoothing spline fue el de mayor eficiencia.

Key words: Conchos River Basin, modeling efficiency, reliability.

Introduction

The spatial and weather variables are useful for understanding the operation of biophysical processes. Precipitation is a major climatic variable required for estimation of water balances, recharge boundary in modeling groundwater flow, evaluate erosion processes and to define the current weather conditions. However, reliable spatial representation of precipitation is particularly difficult in mountainous areas with limited availability of weather stations where the orographic effect is large (Hevesi *et al.*, 1992; HUADE *et al.*, 2005).

Several statistical methods have been developed to predict the spatial distribution of climatic variables that differ in concept and mathematical formulation. Local interpolation methods as Thiessen polygons and inverse distance weighted (IDW) have been among the most frequently used in weather forecasting and mapping development (New *et al.*, 2000; Vicente-Serrano *et al.*, 2003), as that geostatistical methods such as Kriging, co-Kriging and Spline (Vicente-Serrano *et al.* 2003; Apaydin *et al.*, 2004; Hong *et al.*, 2005).

Studies such as those of Dirks *et al.* (1998) and Michaud and Sorooshian (1994) suggested that when there is a high density of weather stations, there are no significant differences when precipitation data interpolated methods IDW and Kriging. In Mexico, despite the importance of representing weather information for decision making, there has been few efforts to assess the goodness of interpolation methods for climate data, highlights the comparative analysis developed by Díaz *et al.* (2008) that evaluated four methods to represent spatial interpolation of precipitation particularly in the windward and leeward region of the Gulf of Mexico, concluded that the thin plate smoothing spline method was the most efficient.

Global interpolation methods that enable the processing of topographic and geographic data have been widely used in various parts of the world to generate precipitation maps (Hevesi *et al.*, 1992; Agnew and Palutikof, 2000; Ninyerola *et al.*, 2000; Daly *et al.*, 2002; Brown and Comrie, 2002).

Métodos globales de interpolación que permiten el procesamiento de datos topográficos y geográficos han sido ampliamente utilizados en diversas partes del mundo para generar mapas de precipitación (Hevesi *et al.*, 1992; Agnew y Palutikof, 2000; Ninyerola *et al.*, 2000; Daly *et al.*, 2002, Brown y Comrie, 2002). Éstos métodos se basan en el uso de modelos estadísticos multivariados que permiten evaluar las relaciones de los datos climáticos con las variables geográficas y topográficas de las estaciones climáticas y su correlación espacial (Ninyerola *et al.*, 2000; Brown y Comrie, 2002). Actualmente, la combinación de modelos de regresión con métodos geo-estadísticos hace posible el desarrollo de cartografía climática con predicciones precisas y mínima varianza espacial (Vicente-Serrano *et al.*, 2003).

En el norte de México, la distribución de la precipitación se encuentra fuertemente influenciada por diversos patrones de circulación atmosférica de escala global como la Oscilación del Sur y la ocurrencia del fenómeno El Niño (Magaña *et al.*, 2003), de escala regional como el sistema del Monzón de Norteamérica (Douglas *et al.*, 1994; Reyes *et al.*, 1994), y localmente, los rasgos geográficos y orográficos también tienen efectos importantes en la distribución espacial de la precipitación (García, 2003).

La Cuenca del Río Conchos (CRC) es una de las más importantes de la Región Río Bravo y del norte de México. La presión sobre el uso del agua al interior de la cuenca por los sectores agrícola, doméstico e industrial se ha intensificado en los últimos años, situación que se ha complicado debido a la ocurrencia de eventos de sequía. Aunado a esto, existe una presión de carácter internacional debida a la necesidad de cumplir con el Tratado Internacional de 1944 (Kelly, 2001) en el cual se establece que México debe entregar anualmente a EE.UU. 432 millones m³ de agua al cauce Río Bravo/Grande. De no cumplir con esta cuota, el adeudo se acumula para el siguiente ciclo de cinco años, con aguas procedentes de la CRC, principal afluente mexicano del río Bravo/Grande (Velasco *et al.*, 2004).

La precipitación que ocurre en la CRC presenta una variabilidad espacial influenciada por su ubicación geográfica, su proximidad a las zonas marítimas, así como por la complejidad de su relieve. La hipótesis que se plantea en el presente estudio parte del supuesto de que la distribución espacial de la precipitación media mensual (PMM) de la CRC puede ser determinada de manera confiable a partir del análisis estadístico de variables geográficas, topográficas y de proximidad a los océanos,

These methods are based upon the use of multivariate statistical models that allow evaluating the relationship of climate data with geographic and topographic variables of the seasons and spatial correlation (Ninyerola *et al.*, 2000; Brown and Comrie, 2002). Currently, the combination of regression models with geostatistical methods makes possible the development of climatic mapping with accurate predictions and minimum spatial variance (Vicente-Serrano *et al.*, 2003).

In northern Mexico, the distribution of rainfall is strongly influenced by different patterns of global atmospheric circulation and the Southern Oscillation and El Niño occurrence (Magaña *et al.*, 2003), regional scale as the North American Monsoon System (Douglas *et al.*, 1994; Reyes *et al.*, 1994), and locally, the geographic and orographic characteristics also have important effects on the spatial distribution of precipitation (García, 2003).

The Conchos River Basin (CRC) is one of the most important in the region of the Río Grande and north of Mexico. Water use within the basin by the agricultural, domestic and industrial use has intensified in recent years, a situation that is complicated due to the occurrence of drought events. Added to this, there is international pressure due to the need to comply with the International Treaty of 1944 (Kelly, 2001) which states that Mexico must submit annually to the EE.UU 432 million m³ of water to the river Río Bravo-Grande. Not meeting this quota, the debt accumulates for the next five-year cycle, with water from the CRC, the main Mexican source of the Rio Grande/Bravo (Velasco *et al.*, 2004).

The precipitation that occurs in the CRC presents a spatial variability influenced by its geographic location, its proximity to the sea areas and the complexity of its relief. The hypothesis proposed in this study assumes that the spatial distribution of mean monthly precipitation (MMP) of the CRC can be reliably determined from statistical analysis of geographic variables, topography and proximity to oceans, by the above we propose the following objectives: 1) determine the spatial distribution of the MMP in the CRC by using multiple linear regression models (MRLM) designed according to the longitude, latitude, elevation above sea level near coastal areas; and 2) statistically evaluate the reliability of the interpolations obtained for each month of the year.

por lo anterior se proponen los siguientes objetivos: 1) determinar la distribución espacial de la PMM en la CRC mediante el uso de modelos de regresión lineal múltiple (MRLM) concebidos en función de la longitud, latitud, altitud sobre el nivel del mar y proximidad de las zonas costeras, y 2) evaluar estadísticamente la fiabilidad de las interpolaciones obtenidas para cada mes del año.

Materiales y métodos

Área de estudio

La CRC se sitúa entre los 104° 20' y 107° 55' de longitud oeste, y los 26° 05' y 29° 55' de latitud norte (Figura 1). La CRC se distribuye en una superficie aproximada de 67 800 km² que representa alrededor de 14% de la superficie total de la Cuenca del Río Bravo del lado mexicano (Kelly, 2001).

El régimen de precipitación que ocurre en la CRC se caracteriza por la presencia de un periodo de lluvias abundantes claramente establecido entre junio y septiembre, siendo julio y agosto los meses más húmedos. La precipitación acumulada del periodo húmedo representa aproximadamente 74% de la precipitación total anual captada en la cuenca (CNA, 2003).

Metodología

Datos de entrada

En el presente estudio se recopilieron series históricas de precipitación mensual provenientes de las estaciones climatológicas administradas por la Comisión Nacional del Agua (CONAGUA) y el Servicio Meteorológico Nacional (SMN), que se encuentran distribuidas al interior y en las proximidades de la CRC. Preferentemente se consideró el uso de las estaciones que cumplieran con un periodo común de datos con al menos de 35 años de continuidad (1970 - 2004); sin embargo, y debido a la calidad de la información disponible, el número de estaciones que cuentan con este periodo en su historial es muy reducido y siendo verdaderamente estricto, podrían quedar excluidas estaciones que a pesar de tener ligeras ausencias de datos, son de gran valor por ubicarse en zonas donde no existen estaciones climáticas.

Materials and methods

Study area

The CRC is located between 104° 20' and 107° 55' west longitude and 26° 05' and 29° 55' north latitude (Figure 1). The CRC is spread over an area of approximately 67 800 km², which represents about 14% of the total area of the basin of the Río Grande from the Mexican side (Kelly, 2001).

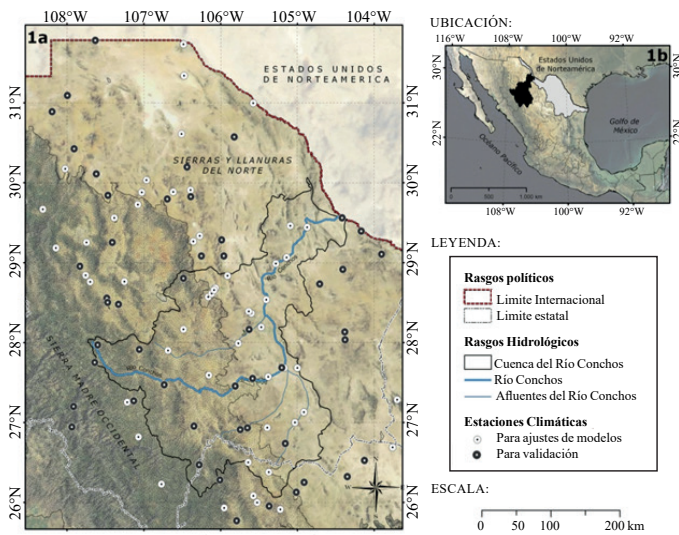


Figura 1. Ubicación geográfica de la cuenca del río Conchos. 1a) red de estaciones climáticas empleadas en el análisis. 1b) totalidad de la cuenca del río Bravo.
Figure 1. Geographical location of the Conchos River Basin. 1a) network of weather stations used in the analysis. 1b) entire Río Grande basin.

The precipitation regime happens in the CRC is characterized by the presence of a period of clearly established rains between June and September, July and August being the wettest months. The cumulative rainfall wet period represents approximately 74% of the total annual rainfall captured in the basin (CNA, 2003).

Methodology

Input data

In the present study were collected monthly precipitation time series from weather stations managed by the National Water Commission (CNA) and the National Weather Service

De manera práctica, es difícil poder utilizar un período común a todas las estaciones, ya que una cantidad importante de éstas tienen periodos extremadamente cortos en sus registros o bien lagunas de datos faltantes de información. Con el propósito de incluir el mayor número de estaciones posibles para la realización del presente estudio, se seleccionaron estaciones que contaron con al menos 85% de los registros mensuales de precipitación durante el periodo comprendido de 1970 a 2004. En total se seleccionaron 110 estaciones climatológicas (Figura 1) a partir de las cuales, se determinaron los datos faltantes mediante el desarrollo de análisis de regresión entre estaciones con datos completos e incompletos de acuerdo a lo sugerido por Young (1992) y Wanielista *et al.* (1997). Finalmente, considerando el periodo de 1970 a 2004, para cada estación climatológica, se calculó la PMM correspondiente a cada mes del año, y con auxilio de un sistema de información geográfica (SIG), se obtuvo la distancia Euclidiana respecto a las zonas marítimas, así como el valor de altitud sobre el nivel del mar apoyándose de un modelo digital de elevaciones (MDE) con resolución espacial de 90 m (INEGI, 2003).

Obtención y ajuste de los MRLM

Con el propósito de predecir espacialmente la PMM histórica de la CRC, para cada uno de los meses del año se ajustó un MRLM como (1). Del total de las estaciones climatológicas en estudio, se seleccionaron en forma aleatoria 60% para la obtención y ajuste del MRLM (1) de manera separada para cada mes del año.

$$PMM_i = \beta_0 + \beta_1 LON + \beta_2 LAT + \beta_3 ELEV + \beta_4 DEM + \varepsilon \quad (1)$$

Donde: PMM_i representa el valor de respuesta de la precipitación media mensual en milímetros del i ésimo mes, LON , LAT , $ELEV$ y DEM denotan respectivamente, las variables independientes longitud, latitud (representadas en el sistema de coordenadas Cónica Conforme Lambert), elevación sobre el nivel medio del mar (metros) y la distancia Euclidiana a la zonas marítimas (metros). Las constantes β_0 , β_1 , β_2 , β_3 , y β_4 son parámetros que se estiman en el proceso de ajuste del modelo.

El término ε representa el error aleatorio del MRLM; se asume que los errores del modelo ε son independientes e idénticamente ajustados a una distribución normal de media 0 y varianza constante σ^2 , analíticamente se expresa como $\varepsilon \sim iidN(0, \sigma^2)$. Para verificar dichos supuestos se aplicaron respectivamente las siguientes pruebas estadísticas Durbin-

(NWS), which are distributed within and near the CRC. We considered using the stations that met common data period with at least 35 years of continuity (1970-2004); however, due to the quality of information available, the number of stations with This period in history is very small and being really strict, could be excluded stations despite having absences light data are of great value to be located in areas where there are no seasons.

Practically, it is difficult to use a common period of all seasons, since a significant number of these have extremely short periods in your records or data gaps missing information. In order to include the largest possible number of stations for the realization of this study, we selected stations counted at least 85% of monthly precipitation records for the period of 1970-2004. A total of 110 weather stations were selected (Figure 1) from which, missing data were determined by developing regression analysis between stations with complete and incomplete data as suggested by Young (1992) and Wanielista *et al.* (1997). Finally, considering the period from 1970 to 2004, for each weather station, MMP was calculated for each month of the year, and with the aid of a geographic information system (GIS), the Euclidean distance was obtained regarding the maritime areas, and the value of altitude above sea level leaning of a digital elevation model (DEM) with a spatial resolution of 90 m (INEGI, 2003).

Getting and setting the MLRM

In order to predict spatially historical MMP of CRC, for each of the months of the year adjusted a MLRM as (1). Of all the weather stations in the study, we randomly selected 60% for obtaining and setting MLRM (1) separately for each month of the year.

$$PMM_i = \beta_0 + \beta_1 LON + \beta_2 LAT + \beta_3 ELEV + \beta_4 DEM + \varepsilon \quad (1)$$

Where: MMP_i represents the response value of the average monthly rainfall in millimeters of the i th month, LON , LAT , $ELEV$ and DEM denote respectively, the independent variables longitude, latitude (represented in the coordinate system Lambert Conformal Conic), elevation above mean sea level (meters) and Euclidean distance to the sea areas (meters). The constants β_0 , β_1 , β_2 , β_3 , and β_4 are parameters estimated in the model fitting process.

The term ε represents the random error of MRLM; it is assumed that the model errors ε are independent and identically adjusted to a normal distribution with mean 0 and constant variance

Watson y Kolmogorov-Smirnov descritas ampliamente por Marquínez *et al.* (2003); en tanto que la homogeneidad de la varianza fue evaluada de manera gráfica, verificando la inexistencia de algún patrón sistemático o tendencia entre los errores y las predicciones del modelo tal y como lo sugiere Hession y Moore (2011).

El proceso de ajuste se llevó a cabo utilizando el procedimiento de mínimos cuadrados por pasos con selección de variables hacia delante "forward stepwise". El método permite incluir todas las variables independientes en un simple paso y descartar en pasos subsecuentes las variables que no cumplan con el nivel de significancia estadística esperado ($p < 0.05$). Cada vez que una variable es removida de la función, el modelo es reajustado y el valor de R^2 resultante, explica la varianza global, mayores detalles del proceso son descritos por Marquínez *et al.* (2003) y Hession y Moore (2011).

Interpolación espacial y calibración de la PMM

La interpolación espacial se llevó a cabo utilizando el programa Arc/Info 9.2[®]. La ecuación de cada MRLM fue resuelta mediante la sumatoria algebraica del valor de la constante del modelo B_0 y los productos de las variables independientes con sus correspondientes coeficientes de regresión ($\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2, \hat{\beta}_3$, y $\hat{\beta}_4$). En otras palabras, en cada MRLM mensual se sustituyeron los valores de coordenadas geográficas representadas en el sistema de coordenadas métrico: cónica conforme Lambert, de elevación del relieve con la información proveniente del MDE y de la proximidad de las zonas de costa.

Los valores predichos por los MRLM fueron comparados con los observados en 60% de estaciones, obteniéndose el error residual para cada estación climática. Los valores residuales se interpolaron espacialmente empleando la técnica spline, con un valor de 400 en el parámetro de tensión, tal y como lo sugiere Vicente-Serrano *et al.* (2003). Las matrices de valores residuales resultantes se integraron espacialmente a los valores de PMM interpolados con los MRLM con propósitos de calibración.

Validación estadística de las interpolaciones

La capacidad predictiva de cada MRLM fue evaluada confrontando los valores de PMM predichos por los modelos, con los observados en el restante 40% de estaciones climatológicas que no fueron incluidas en los procesos de ajuste. Asimismo y con el propósito de determinar si la

σ^2 analíticamente expresado como $\varepsilon \sim iidN(0, \sigma^2)$. To verify these assumptions were respectively applied the following tests Durbin-Watson statistics and Kolmogorov-Smirnov widely described by Marquínez *et al.* (2003), while the homogeneity of variance was evaluated graphically, verifying the absence of any systematic pattern or trend between errors and model predictions as suggested Hession and Moore (2011).

The adjustment process was performed using the method of least squares for variable selection steps forward "forward stepwise". The method allows to include all independent variables in a single step and subsequent steps discard variables that do not meet the expected level of statistical significance ($p < 0.05$). Every time a variable is removed from the function, the model is adjusted and the value of R^2 resulting overall variance explained, further details of the process are described by Marquínez *et al.* (2003) and Hession and Moore (2011).

Spatial interpolation and calibration of the MMP

Spatial interpolation was performed using Arc/Info 9.2[®]. Each MLRM equation was solved by the algebraic sum of the constant value of model B_0 and the products of independent variables with corresponding regression coefficients ($\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2, \hat{\beta}_3$, and $\hat{\beta}_4$). In other words, in each were replaced monthly MLRM geographic coordinate values represented in the coordinate system metric: Lambert Conformal Conic, with elevation terrain information from the MDE and the proximity of coastal areas.

The values predicted by the MLRM were compared with those observed in 60% of stations, obtaining the residual error for each weather station. Residual values were interpolated using the technique spatially spline, with a value of 400 in the voltage parameter as suggested Vicente-Serrano *et al.* (2003). Matrices resulting residual values were integrated spatially interpolated values with MLRM MMP calibration purposes.

Statistical validation of the interpolations

The predictive ability of each MLRM was evaluated confronting MMP values predicted by the models, with those observed in the remaining 40% of weather stations that were not included in the adjustment process. Likewise, and in order to determine if the reliability of each MLRM improved or at least remained the same after the process of calibration, validation criteria included before and after the calibration process: the efficiency test models EF, performed

fiabilidad de cada MRLM mejoró o al menos se mantuvo igual después del proceso de calibración, se consideraron como criterios de validación antes y después del proceso de calibración: la prueba de eficiencia de modelos EF , interpretada como la proporción de la varianza que es explicada por el modelo (Nash and Sutcliffe, 1970) y el valor porcentual del error medio absoluto (% EMA), como una medida de la precisión.

$$EF=1-\frac{\sum [y_i - \hat{y}]^2}{\sum [y_i - \bar{y}]^2} \quad (2)$$

$$\%EMA=100*\frac{\sum |y_i - \hat{y}_i|}{n} \quad (3)$$

Donde: y_i es el valor de PMM observada en el 40% de estaciones no consideradas en el ajuste, \hat{y} es el valor de precipitación estimado por el MRLM, \bar{y} es la precipitación media observada y n es el número de observaciones. La prueba EF es un indicador que permite evaluar la fiabilidad de modelos; valores de EF cercanos a uno indican que las predicciones son relativamente cercanas a la perfección, mientras que valores próximos a cero o negativos indica ajustes inadecuados, por lo que no deben ser recomendados (Nash and Sutcliffe, 1970; Krause *et al.*, 2005; Bellocchi *et al.*, 2009).

Resultados

Calidad de ajuste de MRLM

Como puede observarse en el Cuadro 1 los coeficientes de determinación de los MRLM oscilaron entre 0.18 y 0.76, siendo los modelos de los meses que comprenden el periodo de verano (junio-septiembre) los que mejor explicaron la varianza de la precipitación (entre 71 y 76%), en tanto que en los modelos del periodo de invierno (dic y ene) la varianza explicada se mantuvo cercana a 50%. Los modelos de los meses que comprenden el periodo seco (febrero-mayo) así como los de octubre y noviembre, mostraron la mayor incertidumbre dado que no explicaron más de 46% de la varianza de la precipitación. Éstos resultados son consistentes con lo encontrado por Ninyerola *et al.* (2000) y Diodato (2005) quienes reportaron valores de R^2 comprendidos entre 0.32 y 0.75.

as the proportion of variance that is explained by the model (Nash and Sutcliffe, 1970) and the percentage value of the mean absolute error (% EMA) as a measure of precision.

$$EF=1-\frac{\sum [y_i - \hat{y}]^2}{\sum [y_i - \bar{y}]^2} \quad (2)$$

$$\%EMA=100*\frac{\sum |y_i - \hat{y}_i|}{n} \quad (3)$$

Where: y_i is the MMP value is observed in 40% of stations not considered in the setting; \hat{y} is the value estimated by the MLRM precipitation; \bar{y} average precipitation is observed and n is the number of observations. The EP test is an indicator for assessing the reliability of models EF values close to one indicate that the predictions are relatively close to perfection, while values close to zero or negative indicates improper adjustments, so that should not be recommended (Nash and Sutcliffe, 1970; Krause *et al.*, 2005; Bellocchi *et al.*, 2009).

Results

MLRM quality adjustment

As shown in Table 1, the coefficients of determination ranged MLRM 0.18 and 0.76, with the models of the months comprising the summer period (June to September) that best explained the variance of precipitation (between 71 and 76%), while in the winter period models (Dec and Jan) explained variance remained close to 50%. The models comprising the months of the dry season (February to May) as well as October and November, showed the greatest uncertainty because they did not explain more than 46% of the variance of the precipitation. These results are consistent with those found by Ninyerola *et al.* (2000) and Diodato (2005) who reported R^2 values between 0.32 and 0.75.

The MMP corresponding to the summer months showed a statistically significant elevation in the CRC field and proximity to coastal areas. The positive significance of the elevation of the terrain in wet period MLRM indicates MMP values increase as the ground elevation of the basin, while the proximity of the coast area shows an inverse relation to the MMP, so that the most remote areas of the coastline have the lowest values of MMP. The longitude meanwhile, showed statistically significant negative during the dry months of the year, indicating that precipitation increases with length values decrease

Cuadro 1. Resultados del ajuste del MRLM (1) a los datos de PMM en 60% de estaciones climatológicas.
Table 1. Results of MLRM adjustment (1) to the data of MMP in 60% of weather stations.

Mes	R ²	$\hat{\sigma}$ (EE)	$\hat{\beta}_0$	$\hat{\beta}_1$ (LON)	$\hat{\beta}_2$ (LAT)	$\hat{\beta}_3$ (ELEV)	$\hat{\beta}_4$ (DEM)
Ene.	0.53	8.03	988.2	-0.000294	-0.000199	0.01037	-0.000317
Feb.	0.24	7.83	52.5	-0.000012	NS	0.00843	NS
Mar.	0.46	4.57	26.8	-0.000019	NS	0.00647	NS
Abr.	0.18	3.25	17.4	-0.000007	NS	0.00226	NS
May.	0.24	4.44	-33.8	-0.000028	NS	0.00282	NS
Jun.	0.71	9.65	243.3	NS	-0.000070	0.01630	NS
Jul.	0.76	21.21	181.7	NS	NS	0.01888	-0.00029
Ago.	0.75	19.36	124.8	NS	NS	0.03232	-0.000202
Sep.	0.71	15.71	172.8	NS	-0.000031	0.01972	-0.000058
Oct.	0.34	10.28	308.5	-0.000077	-0.000043	-0.008035	NS
Nov.	0.33	6.24	15.5	NS	NS	0.004732	-0.000025
Dic.	0.50	9.93	134.4	-0.000052	-0.000016	0.011372	NS

R²= coeficiente de determinación; $\hat{\sigma}$ (EE)= error estándar; $\hat{\beta}_1$ (LON)= longitud; $\hat{\beta}_2$ (LAT)= latitud; $\hat{\beta}_3$ (ELEV)= elevación; $\hat{\beta}_4$ (DEM)= proximidad a la zona de costa; NS= variables descartadas en el proceso de ajuste de modelos por presentar valor de $p > 0.05$.

La PMM correspondiente a los meses del verano mostró una relación estadísticamente significativa con la elevación del terreno en la CRC y la proximidad de las zonas de costa. La significancia positiva de la elevación del relieve en los MRLM del periodo húmedo indica que los valores de PMM aumentan conforme la elevación del terreno de la cuenca; en tanto que la proximidad de las zona de costa muestra una relación inversa con la PMM, de tal manera que las zonas más alejadas de la línea de costa presentan los mas bajos valores de PMM. La longitud geográfica por su parte, mostró significativa estadística negativa durante los meses secos del año, lo cual indica que la precipitación aumenta conforme los valores de longitud disminuyen en dirección hacia el oeste; mientras que la latitud geográfica tiene significancia estadística durante los meses de septiembre, octubre diciembre y enero con una tendencia poco clara que indica que la precipitación es menor en latitudes mas próximas al norte de la cuenca.

Las pruebas estadísticas de Kolmogorov-Smirnov revelaron con un nivel de significancia de 0.05, que con excepción de los meses de febrero y marzo, los valores residuales del resto de los MRLM se distribuyen normalmente, cumpliendo así con el supuesto de normalidad de residuos. Asimismo, y considerando un nivel de significancia de 0.05, un valor de $n = 66$ y un total de 4 regresores incluidos en el modelo (1), se determinó que los límites inferior (d_L) y superior (d_U) que permiten estimar los valores críticos para evaluar

toward the west, while the geographical latitude has statistical significance during the months of September, October, December and January with an unclear trend indicating that precipitation is lower in latitudes near the north of the basin.

Statistical tests of Kolmogorov-Smirnov test revealed a significance level of 0.05, which with the exception of the months of February and March, the residual values of the remaining MLRM normally distributed, thus meeting the assumption of normality of residuals. Also, considering a significance level of 0.05, a value of $n = 66$ and a total of 4 regressors included in the model (1), it was determined that the lower limit (d_L) and upper (d_U) that estimate critical values to assess the presence or absence of autocorrelation through the Durbin-Watson statistic test (d) were d_U and $d_L = 1.47$ 1.73. According to Goldbenger (1962), the absence of auto-correlation is established when: $d_U < d < (4 - d_U)$, for this analysis would be the limits set at: $1.73 < d < 2.27$. According to the results, the exception of February and May, the values of the Durbin-Watson test statistic (d) obtained in the setting of other models remained between 1.79 and 2.08, which confirms the absence of autocorrelation.

Spatial interpolation

Spatial interpolation residual values identified areas where MMP estimates were less efficient. Areas with light colors observed in Figure 2a, indicate that MMP values predicted by MLRM are very close to the observed values, while areas

la presencia o ausencia de auto-correlación a través de la prueba estadística Durbin-Watson (d) fueron $d_L = 1.47$ y $d_U = 1.73$. De acuerdo con Goldbenger (1962), la inexistencia de auto-correlación se establece cuando: $d_U < d < (4 - d_U)$; para el presente análisis quedaría los límites quedaron establecidos en: $1.73 < d < 2.27$. De acuerdo con los resultados obtenidos puede mencionarse que con excepción de febrero y mayo, los valores de la prueba estadística Durbin-Watson (d) obtenidos en el ajuste del resto de los modelos se mantuvieron entre 1.79 y 2.08, lo cual confirma la inexistencia de auto-correlación.

Interpolación espacial

La interpolación espacial de los valores residuales permitió identificar las zonas en donde las estimaciones de la PMM fueron menos eficientes. Las zonas con tonalidades claras que se observan en la Figura 2a, indican que los valores de PMM predichos por los MRLM son muy próximos a los valores observados; mientras que las zonas en tonos intensos muestran las anomalías de los modelos; intensidades hacia el color azul representan sub-estimaciones, mientras que intensidades hacia el color rojo corresponden a sobre-estimaciones.

Los MRLM de los meses del periodo de verano (junio - septiembre) pronosticaron eficientemente la PMM en gran parte del territorio de la CRC. Los errores extremos se observaron aisladamente en zonas con relieve complejo de la CRC en un rango de error comprendido entre 30 y 40 mm. Las sub-estimaciones producidas por los MRLM de los meses de junio y julio se presentaron principalmente en la parte alta y baja de la CRC, mientras que sobre-estimaciones se ubicaron generalmente en la parte media de la CRC. Éste patrón de distribución de errores, cambia ligeramente en agosto, la sobreestimación se concentra más en la franja oriental de la CRC y se acentúa más en septiembre.

Fiabilidad de las interpolaciones

Las pruebas de validación aplicadas a los MRLM previo al proceso de calibración se presentan en el Cuadro 2, en donde puede observarse que los MRLM correspondientes a los meses de julio y agosto mostraron los más bajos valores porcentuales del error medio absoluto (16 y 17.2% respectivamente) así como los más altos valores de la prueba de eficiencia EF (0.72 y 0.63 respectivamente) por consecuencia, fueron los que mejor capacidad demostraron para predecir la PMM. Los MRLM correspondientes a los meses de mayo, junio y septiembre mostraron un rango de valores porcentuales del error medio absoluto comprendidos

in deep shades show anomalies of patterns; toward blue intensities represent underestimates, while the red color intensities to correspond to over-estimates.

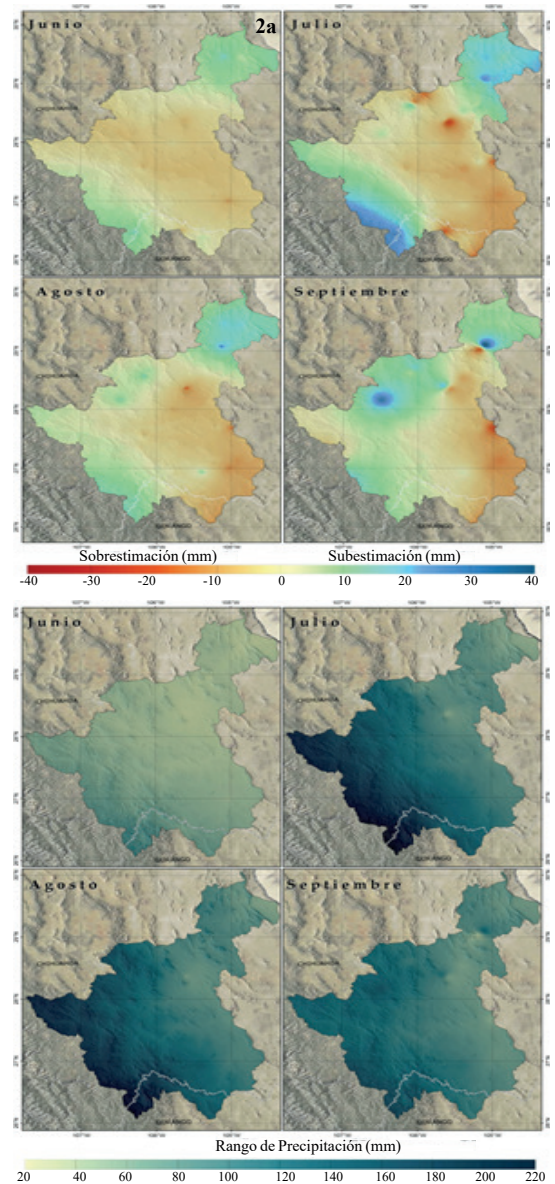


Figura 2a. Mapas de interpolación espacial de los meses que comprenden el periodo húmedo; 2a) errores residuales producidos por los MRLM; 2b) precipitación media mensual obtenida con MRLM espacialmente corregidos.

Figure 2a. Spatial interpolation maps; months comprising the wet period; 2a) residuals produced by MRLM; 2b) mean monthly precipitation obtained with MLRM spatially corrected.

The MLRM of the months of the summer period (June to September) efficiently predicted MMP in much of the territory of the CRC. Extreme errors were observed in areas

entre 20.9 y 25.2% y valores de eficiencia *EF* de 0.36 a 0.47; mientras que los modelos del periodo invernal: noviembre, diciembre y enero, presentaron un rango de valores de *EF* comprendidos entre 0.11 y 0.28, y errores medios porcentuales por encima de 30%. El resto de los MRLM: febrero, marzo y abril mostraron la mayor incertidumbre en las predicciones.

Las pruebas de validación aplicadas a los modelos después del proceso de calibración, mostraron mejorías significativas prácticamente en todos los MRLM, que se manifestaron con reducciones en los valores del error medio absoluto e incrementos en los valores de eficiencia. Por ejemplo, los modelos de los meses del periodo invernal mostraron mejorías notables que se reflejan con un incremento en el rango de valores de *EF* (entre 0.56 y 0.82), y errores porcentuales por debajo de 23.5.

embossed isolation complex CRC error in a range between 30 and 40 mm. The sub- estimates produced by MLRM of the months of June and July were presented mainly in the high and low of the CRC, while over-estimates are usually placed in the middle of the CRC. This distribution pattern of errors, changes slightly in August, and the overestimation is more concentrated in the eastern fringe of the CRC and is more noticeable in September.

Reliability of the interpolations

Validation tests applied to MLRM prior to the calibration process are presented in Table 2, where it can be seen that the MLRM for the months of July and August showed lower values mean absolute percentage error (16 and 17.2% respectively) and the highest values of *EF* efficiency

Cuadro 2. Pruebas estadísticas empleadas para la validación de los mapas de PMM antes y después de la calibración.
Table 2. Statistical tests employed for validating MMP maps before and after calibration.

Mes	Antes de calibración		Después de calibración	
	EF	%EMA	EF	%EMA
Enero	0.11	45.9	0.70	23.5
Febrero	-0.01	49.1	0.11	36.7
Marzo	0.09	49.0	0.30	36.5
Abril	-0.78	29.8	-0.15	23.0
Mayo	0.36	25.2	0.63	18.2
Junio	0.47	21.6	0.66	17.5
Julio	0.72	16.0	0.84	11.6
Agosto	0.63	17.2	0.72	14.0
Septiembre	0.45	20.9	0.66	15.0
Octubre	-0.71	24.0	-0.78	19.2
Noviembre	0.28	30.0	0.56	19.8
Diciembre	0.21	41.8	0.82	21.9

EF= prueba de eficiencia de modelos; %EMA= valor porcentual del error medio absoluto.

En términos generales las pruebas de validación estadística obtenidas posterior al proceso de calibración indican que los modelos de los meses comprendidos entre mayo y septiembre ($EF > 0.63$ y $\%EMA < 18.2\%$) así como los del periodo invernal (noviembre-enero) resultaron confiables ($EF > 0.56$ y $\%EMA < 23.5\%$) para representar espacialmente la correspondiente PMM en la CRC. Los modelos de febrero y marzo a pesar de haber mostrado ligeras mejorías después del proceso de calibración, continúan presentando incertidumbre en las predicciones; en tanto que los meses de abril y octubre, en definitiva los valores de eficiencia indicaron que no pueden ser recomendados para representar espacialmente la PMM.

test (0.72 and 0.63 respectively) as a consequence, the showed best ability to predict the MMP. The MLRM for the months of May, June and September showed a range of values of the mean absolute error percentage between 20.9 and 25.2% and *EF* efficiency values from 0.36 to 0.47 to models while the winter period: November, December and January, showed a range of values between *EF* 0.11 and 0.28, and average errors percentage above 30%. The rest of the MRLM: February, March and April showed the highest uncertainty.

Validation tests applied to models after calibration showed significant improvements in virtually all MRLM, manifested by reductions in mean absolute error values and increases in

Discusión

La distribución espacial de la PMM que ocurre durante el periodo de verano en la cuenca del río Conchos (CRC) mostró una relación estrecha con la elevación del relieve y la proximidad de las zonas de costa de las estaciones climatológicas (Cuadro 1); éstas variables lograron explicar al menos 64% de la varianza espacial en la distribución de la PMM. La relación entre la elevación y los altos valores de precipitación durante los meses del verano podría ser explicada por el efecto orográfico que producen las montañas en la zona de barlovento, en donde las masas de aire húmedo provenientes del mar son forzadas a ascender por las barreras montañosas hasta alcanzar su nivel de condensación y precipitación (Maderey y Jiménez, 2005).

La precipitación que ocurre entre los meses que comprenden el periodo de junio a septiembre presenta los máximos valores en las zonas de mayor altitud de la CRC y tienden a decrecer conforme la altitud del relieve disminuye en dirección al río Bravo y la distancia de las zonas de costa aumenta (Figura 2b). Este patrón de distribución concuerda con lo señalado por Brito-Castillo *et al.* (2010) y Douglas *et al.* (1993), quienes sugieren que el origen de las precipitaciones de los meses del verano están influenciadas en gran medida por el sistema atmosférico regional conocido como Monzón del suroeste de Norteamérica (Reyes *et al.*, 1994) o Monzón mexicano (Douglas *et al.*, 1993) que se caracteriza por la formación de un centro de baja presión en Sonora y Arizona, el cual modula el flujo de humedad sobre el Golfo de California y produce una gran convergencia y vorticidad ciclónica sobre la Sierra Madre Occidental (Reyes *et al.*, 1994).

En términos generales, los MRLM correspondientes al periodo de verano estimaron eficientemente la PMM en gran parte del territorio de la CRC, observándose sobre-estimaciones principalmente en la parte central de la cuenca y estimaciones por debajo de lo esperado tanto en la parte alta como en la parte baja de la cuenca (Figura 2a). Los más notables errores de los modelos ocurrieron puntualmente en regiones donde el relieve es complejo; y podrían ser explicados por la alta variabilidad que tiene la precipitación en la cuenca en donde los eventos de tormenta ocurren de manera muy irregular (Brito-Castillo *et al.*, 2010). La incorporación de los residuales a los valores de precipitación predichos por los modelos permitió reducir la variabilidad espacial, mejorar notablemente la calidad de las interpolaciones y obtener coberturas geográficas de PMM confiables (Figura 2b).

efficiency values. For example, models of the months of the winter period showed significant improvement reflected an increase in the range of EF values (between 0.56 and 0.82), and percentage errors below 23.5

Overall statistical validation tests obtained after calibration models indicate that the months between May and September (EF > 0.63 and % EMA < 18.2%) and the winter period (November-January) were reliable (EF > 0.56 and % EMA < 23.5%) to represent the corresponding spatially MMP in the CRC. The models of February and March despite slight improvements shown after calibration, continue to have uncertainty in predictions, while the months of April and October, ultimately the efficiency values indicated that there may be recommended to represent MMP spatially.

Discussion

The spatial distribution of MMPs that occurs during the summer in the Conchos River Basin (CRC) showed a close relationship with the elevation of the terrain and proximity to coastal areas of the weather stations (Table 1), these variables able to explain at least 64% of the variance in the distribution space of the MMP. The relationship between elevation and the high values of rainfall during the summer months could be explained by the orographic effect produced by the mountains on the windward side, where moist air masses from the sea are forced to climb the barriers mountain to reach the level of condensation and precipitation (Maderey and Jiménez, 2005).

The precipitation occurs between the months comprising the period from June to September has the highest values in the higher elevations of the CRC and tend to decrease as the elevation of the relief decreases towards the Río Grande and the distance from the area of coast increases (Figure 2b). This distribution pattern is consistent with those reported by Brito-Castillo *et al.* (2010) and Douglas *et al.* (1993), who suggested that, the origin of precipitation in the summer months are largely influenced by regional weather system known as the American Southwest Monsoon (Reyes *et al.*, 1994) or Mexican Monsoon (Douglas *et al.*, 1993) which is characterized by the formation of a low pressure center in Sonora and Arizona, which modulates the flow of moisture over the Gulf of California and produces a large convergence and cyclonic vorticity over the Sierra Madre Occidental (Reyes *et al.*, 1994).

Resultados similares fueron obtenidos por Ninyerola *et al.* (2000) y Agnew y Palutikof (2000), quienes derivaron coberturas geográficas de precipitación y temperatura mediante MRLM corregidos considerando como variables predictoras factores geográficos y topográficos, y de manera similar al presente estudio, determinaron que la variable elevación tiene significancia estadística positiva en la contribución de los MRLM.

Conclusiones

La interpolación espacial de la PMM mediante el uso de MRLM calibrados con los valores residuales, permitió la obtención de coberturas continuas de PMM estadísticamente confiables para los meses de los periodos: mayo a septiembre y, noviembre a enero en la CRC. En futuros estudios podría evaluarse el efecto de incorporar otras variables predictivas al MRLM como: humedad relativa, cobertura de nubes, dirección de vientos dominantes y la condición del vigor de la cubierta vegetal; lo cual podría contribuir en mejorar la fiabilidad de los modelos desarrollados para meses de febrero, marzo y abril que mostraron claras inconsistencias en la interpolación espacial de la PMM.

La principal contribución del presente estudio radica en la generación de coberturas continuas de PMM de alta resolución espacial y estadísticamente fiables, tal y como lo demostraron las pruebas de validación (Cuadro 2). Los mapas producidos podrían ser utilizados como variables de entrada en modelos desarrollados para evaluar las variaciones espaciales y temporales de los procesos hidrológicos que ocurren en la CRC, así como en estudios de caracterización del clima de la región.

Literatura citada

- Agnew, M. D. and Palutikof, J. P. 2000. GIS-based construction of base line climatologies for the Mediterranean using terrain variables. *Climate Res.* 14:115-127.
- Aguado, E. and Burt, J. E. 2001. *Understanding weather and climate*, 2nd ed. Prentice Hall, Upper Saddle River, New Jersey, U.S.A. 505 pp.
- Apaydin, H.; Kemal, F. S. and Ersoy, Y. Y. 2004. Spatial interpolation techniques for climate data in the GAP region in Turkey. *Climate Res.* 28:31-40.
- Bellocchi, G.; Rivington, M.; Donatelli, M. and Matthews, K. 2009. Validation of biophysical models: issues and methodologies: A review. *Agron. Sustain. Dev.* 30(1):109-130.

Overall, the MLRM for the summer period efficiently estimated MMP in much of the territory of the CRC; overestimates observed mainly in the central part of the basin and estimates lower than expected both in the upper and in the lower part of the basin (Figure 2a). Most notable errors occurred punctually models in regions where the terrain is complex and could be explained by the high variability that is the precipitation in the basin where storm events occur quite irregularly (Brito-Castillo *et al.*, 2010). The incorporation of residual precipitation values predicted by the models has reduced the spatial variability, improve significantly the quality of the interpolations and get reliable MMP geographical coverage (Figure 2b).

Similar results were obtained by Ninyerola *et al.* (2000) and Agnew and Palutikof (2000), who derived geographical coverage by MLRM precipitation and temperature as predictors corrected considering geographical and topographical factors, and similar to the present study, determined that the Variable is statistically significant elevation positive contribution of MRLM.

Conclusions

The MMP spatial interpolation using calibrated MLRM residual values, allowed obtaining continuous coverage for statistically reliable MMP during the month periods: May to September and November to January in the CRC. Future studies could evaluate the effect of adding other predictors to MLRM as relative humidity, cloud cover, prevailing wind direction and force condition of vegetation cover, which could contribute to improve the reliability of the models developed for months of February, March and April that showed clear inconsistencies in the spatial interpolation of the MMP.

The main contribution of this study lies in generating MMP continuous coverage of high spatial resolution and statistically reliable, as demonstrated by the validation tests (Table 2). The maps produced could be used as input variables in developed models to assess spatial and temporal variations of hydrological processes occurring in the CRC, as well as characterization studies of the climate of the region.

End of the English version



- Brito-Castillo, L.; Vivoni, E. R.; Gochis, D. J.; Filonov, A.; Tereshchenko, L. and Monzon, C. 2010. An anomaly in the occurrence of the month of maximum precipitation distribution in northwest Mexico. *J. Arid Environ.* 74:531-539.
- Brown, D. P. and Comrie, A. C. 2002. Spatial modeling of winter temperature and precipitation in Arizona and New Mexico, USA. *Climate Res.* 22:115-128.
- Comisión Nacional del Agua (CONAGUA). 2003. Programa hidráulico regional 2002-2006. Región Río Bravo. México. 242 pp.
- Daly, C.; Gibson, W. P.; Taylor, G. H.; Johnson, G. L. and Pasteris, P. 2002. A knowledge-based approach to the statistical mapping of climate. *Climate Res.* 22:99-113.
- Díaz, P. G.; Sánchez, C. I.; Quiroz, R.; Garatuza, P. J.; Watts, T. Ch. y Cruz, M. I. 2008. Interpolación espacial de la precipitación pluvial en la zona de barlovento y sotavento del Golfo de México. *Agric. Téc. Méx.* 34(3):279-287.
- Diodato, N. 2005. The influence of topographic co-variables on the spatial variability of the precipitation over small regions of complex terrain. *Inter. J. Climatol.* 25:351-363.
- Dirks, K. N.; Hay, J. E.; Stow, C. D. and Harris, D. 1998. High-resolution studies of rainfall on Norfolk Island. Part II: interpolation of rainfall data. *J. Hydrol.* 208(3-4):187-193.
- Douglas, M. W.; Maddox, R. A.; Howard, K. and Reyes, S. 1993. The Mexican Monsoon. *J. Climate.* 6:1665-1677.
- García, E. 2003. Distribución de la precipitación en la República Mexicana. *Investigaciones Geográficas.* 50:67-76.
- Goldberger, S. 1962. Best linear unbiased prediction in the generalized linear regression model. *J. Am. Statistical Assoc.* 57:369-375.
- Hession, S. L. and Moore, N. 2011. A spatial regression analysis of the influence of topography on monthly rainfall in East Africa. *Int. J. Climatol.* 31:1440-1456.
- Hevesi, J. A.; Istok, J. D. and Flint, A. L. 1992. Precipitation estimation in mountainous terrain using multivariate geostatistics. Part I: structural analysis. *J. Appl. Meteorol.* 31:661-676.
- Huade, G.; Wilson, J. L. and Makhnin, O. 2005. Geostatistical mapping of mountain precipitation incorporating autosearched effects of terrain and climatic characteristics. *J. Hydrometeorol.* 6:1018-1031.
- Hong, Y.; Nix, H. A.; Hutchinson, M. F. and Booth, T. H. 2005. Spatial interpolation of monthly mean climate data for China. *Int. J. Climatol.* 25:1369-1379.
- Instituto Nacional de Geografía Estadística e Informática (INEGI). 2003. Sistema de descarga del continuo de elevaciones de México. [Disponible para world wide web: <http://www.inegi.org.mx/geo/contenidos/datosrelieve/continental/continuoElevaciones.aspx>(consultado febrero, 2012).
- Kelly, E. M. 2001. The Rio Conchos: a preliminary overview. Texas center for policy studies. available from world wide web: <http://www.texascenter.org/publications.html#texasmexico> (consultado enero, 2011).
- Krause, P.; Boyle, D. P. and Båse, F. B. 2005. Comparison of different efficiency criteria for hydrological model assessment. *Advances in Geosciences.* 5:89-97.
- Maderey, R. L. E. y Jiménez, R. A. 2005. Principios de hidrogeografía: estudio del ciclo hidrológico. Universidad Autónoma de México (UNAM), México, D. F., 15-20 p.
- Magaña, V. O.; Vázquez, J. L.; Pérez, J. L. and Pérez, J. B. 2003. Impact of El Niño on precipitation in México. *Geofísica Internacional.* 42(3):313-330.
- Marquínez, J.; Lastra, J. and García, P. 2003. Estimation models for precipitation in mountainous regions: the use of GIS and multivariate analysis. *J. Hydrol.* 270:1-11.
- Michaud, J. D. and Sorooshian, S. 1994. Effect of rainfall-sampling errors on simulations of desert flash floods. *Water Resour. Res.* 30(10):2765-2775.
- Nash, J. E. and Sutcliffe, J. V. 1970. River flow forecasting through conceptual models. Part I - A discussion of principles. *J. Hydrol.* 10:282-290.
- New, M. and Hulme, M. 2000. Representing twentieth-century space-time climate variability. Part II. Development of 1901 monthly grids of terrestrial surface climate. *J. Climatol.* 13:2217-2238.
- Ninyerola, M.; Pons, X. and Roure, J. M. 2000. A methodological approach of climatological modelling of air temperature and precipitation through GIS techniques. *Int. J. Climatol.* 20:1823-1841.
- Reyes, S.; Douglas, M. W. and Maddox, R. A. 1994. El monzón del suroeste de Norteamérica (Travason/Swamp). *Atmósfera.* 7:117-137.
- Vicente-Serrano, S. M.; Saz-Sánchez, M. A. and Cuadrat, J. M. 2003. Comparative analysis of interpolation methods in the middle Ebro Valley (Spain): application to annual precipitation and temperature. *Climate Res.* 24:161-180.
- Velasco, V. I.; Aparicio, F. J.; Valdés, J. y Velázquez, J. 2004. Evaluación de índices de sequía en las cuencas afluentes del Río Bravo-Grande. *Ingeniería Hidráulica en México.* 9(3):37-53.
- Wanielista, M. P.; Kersten, R. and Eaglin, R. 1997. *Hydrology.* Wiley and Sons. New York, USA. 567 p.
- Young, K. C. 1992. A three-way model for interpolating for monthly precipitation values. *Monthly Weather Rev.* 120:2561-2569.