

Guerrero-Evaristo, R. S., Andrades-Grassi, J., Rojas-Polanco, M. I. (2025). Clasificación bioclimática en la cuenca del río Caroní mediante el método de máxima verosimilitud. *GeoFocus, Revista Internacional de Ciencia y Tecnología de la Información Geográfica* (Artículos), 36, 63-85. <https://dx.doi.org/10.21138/GF.901>

CLASIFICACIÓN BIOCLIMÁTICA EN LA CUENCA DEL RÍO CARONÍ MEDIANTE EL MÉTODO DE MÁXIMA VERO SIMILITUD

^{1a}**Roland Said Guerrero-Evaristo** , ^{2b}**Jesús Andrades-Grassi**  , ^{3c}**María Isabel Rojas-Polanco** 

¹Fac. de Ciencias Forestales y Ambientales. Univ. de los Andes.

²Dep. de Ordenación de Cuencas. Fac. de Ciencias Forestales y Ambientales. Univ. de los Andes.

³Dep. Bosques. Fac. de Ciencias Forestales y Ambientales. Univ. de los Andes.

Campus Universitario Forestal. Edificios Principal. Mérida 5101. Venezuela

^arolandsaid25@gmail.com, ^bkoflasjesus@gmail.com, ^cmrojaspolanco@gmail.com

RESUMEN

La clasificación bioclimática es esencial para entender y manejar el territorio de manera más sostenible, así como en la gestión de la conservación de la biodiversidad y la evaluación del cambio climático. El método de clasificación supervisado de Máxima Verosimilitud (ML), es una herramienta poderosa para la clasificación bioclimática. Por ello, se aplicó el Clasificador ML en la cuenca del Rio Caroní, se utilizaron datos de fuentes globales, de los que se extrajo promedios de las variables climáticas. Para mejorar la resolución espacial del producto se utilizó la Regresión Ponderada Geográfica (GWR) y el MDE SRTM de 90 m. Además, el marco de entrenamiento estuvo fundamentado en la distribución de los diferentes ecosistemas previamente clasificados según Holdridge. A partir de esta metodología se logró una precisión general del 93 % donde las clases de bosque pluvial premontano, bosque muy húmedo tropical y bosque húmedo pre montano denotaron el peor desempeño, pues existen de por medio estructuras transitivas que el modelo de clasificación no pudo captar.

Palabras clave: Clasificación de Máxima Verosimilitud, clasificación bioclimática, Regresión Ponderada Geográfica.

BIOCLIMATIC CLASSIFICATION IN THE CARONI RIVER BASIN USING THE MAXIMUM LIKELIHOOD METHOD

ABSTRACT

Bioclimatic classification is essential for understanding and managing the territory in a more sustainable way, as well as in biodiversity conservation management and climate change assessment. The supervised Maximum Likelihood (ML) classification method is a powerful tool for bioclimatic classification. Therefore, the ML classifier was applied in the Caroni River basin, using data from global sources, from which averages of climatic variables were extracted. Geographic Weighted Regression (GWR) and the 90 m SRTM DEM were used to improve the scale. The Holdridge classification was

applied, this presented an overall accuracy of 93 % the classes of premontane rainforest, very humid tropical forest and premontane rainforest denoted the worst performance, as there are transitive structures involved that the classification model could not capture.

Key words: Maximum Likelihood Classification, bioclimatic classification, Geographic Weighted Regression.

1. Introducción

La cuenca del río Caroní, ubicada en la región de la Guayana venezolana, es un territorio de vital importancia tanto para Venezuela como para la región. Su vasta extensión y sus características hidrográficas únicas la convierten en un elemento clave para el desarrollo socioeconómico y ambiental del país. Esta cuenca es fundamental para la generación de energía hidroeléctrica, ya que alberga importantes represas como Guri, Caruachi y Macagua, que suministran un alto porcentaje de la electricidad consumida en Venezuela (Sánchez, Rosales & Vessuri 2016) y que según el informe sobre la *Situación de los Recursos Hídricos en Venezuela de 2013* (Martínez *et al.* 2013) representaba el 70 % de la energía hidroeléctrica del país en dicha cuenca para el 2006, al tanto que fuentes más actuales sitúan la generación eléctrica general por medio de fuentes renovables para 2023 en un 78,38 % ([Datosmacro.com](https://www.datosmacro.com) 2025). Además, la cuenca del Caroní es un ecosistema de gran valor biológico, hogar de una diversidad de especies de flora y fauna, muchas de ellas endémicas y únicas en el mundo (Huber 2001). Asimismo, esta región juega un papel crucial en la regulación del ciclo hidrológico y en la provisión de servicios ecosistémicos esenciales, como la captura de carbono y la conservación de la biodiversidad (PNUD 2010). Sin embargo, la cuenca del Caroní también enfrenta desafíos, como la deforestación, la minería ilegal y el cambio climático, que amenazan su integridad ecológica y la sostenibilidad de sus recursos naturales (SOS Orinoco 2021).

Por otro lado, la clasificación bioclimática se presenta como una herramienta esencial para comprender y gestionar el territorio de manera sostenible, ofreciendo un marco de referencia crucial para la toma de decisiones en diversos ámbitos. Esta disciplina, que integra el análisis del clima y sus interacciones con los seres vivos, permite delimitar zonas con características ambientales homogéneas, facilitando la identificación de ecosistemas y la evaluación de su vulnerabilidad ante el cambio climático (Rivas-Martínez *et al.* 2011). Además, la clasificación bioclimática resulta fundamental para la planificación del uso del suelo, la gestión de recursos naturales y la conservación de la biodiversidad, ya que proporciona información valiosa sobre la distribución de especies y comunidades vegetales, así como sobre su adaptación a las condiciones climáticas locales (Walter & Breckle 2002).

La clasificación bioclimática, al zonificar el territorio en función de sus características climáticas y su relación con la biota, se revela como recurso esencial para comprender y anticipar los impactos del cambio climático en los ecosistemas (Thuiller *et al.* 2005). Al analizar la distribución de especies y comunidades vegetales en relación con variables climáticas como la temperatura y la precipitación, se pueden establecer modelos predictivos que permitan evaluar la vulnerabilidad de los ecosistemas ante escenarios futuros de cambio climático (Guisan & Zimmermann 2000). Estos modelos, basados en la clasificación bioclimática, son esenciales para identificar áreas de mayor riesgo y diseñar estrategias de conservación y gestión adaptativa que minimicen los efectos negativos del cambio climático en la biodiversidad y los servicios ecosistémicos (Araújo *et al.* 2005). En este contexto, estudios realizados en Venezuela y zonas cercanas de Sudamérica han destacado la importancia de la clasificación bioclimática para comprender la distribución de la biodiversidad y los impactos del cambio climático en esta región Neotropical. Por ejemplo, Huber (1997) realizó una clasificación biogeográfica de la Guayana Venezolana, tomando en cuenta factores climáticos y florísticos, mientras que Ramírez (2000) describió los diferentes tipos de vegetación presentes en el país, incluyendo información sobre su clima y distribución geográfica. Asimismo, Josse *et al.* (2009) presentaron una clasificación de los ecosistemas de los Andes, incluyendo zonas de Colombia, Ecuador y Perú, basada en factores climáticos, altitudinales y de vegetación. Estos y otros estudios resaltan la necesidad de seguir investigando y aplicando la clasificación bioclimática en la región para promover una gestión sostenible del territorio y la conservación de la biodiversidad.

Además, la clasificación bioclimática proporciona información valiosa para la planificación del uso del suelo y la gestión de recursos naturales en un contexto de cambio climático. Al conocer la distribución de los bioclimas y su relación con la vegetación y la fauna, se pueden establecer criterios para la zonificación del territorio que tengan en cuenta la vulnerabilidad de los ecosistemas y la necesidad de mantener la conectividad entre ellos para facilitar la migración de especies y la adaptación a nuevas condiciones climáticas (Walter & Breckle 2002). En definitiva, ante el panorama del cambio global, la clasificación bioclimática se consolida como una herramienta esencial en la toma de decisiones, ya que permite integrar el conocimiento sobre el clima y la biota para promover una gestión sostenible del territorio y la conservación de la biodiversidad.

Al analizar la distribución de especies en función de variables climáticas es posible modelar su respuesta a escenarios futuros de cambio climático y anticipar posibles cambios en la composición y estructura de las comunidades (Guisan & Zimmermann, 2000). Asimismo, la clasificación bioclimática juega un papel crucial en la identificación de áreas prioritarias para la conservación, ya que permite delimitar zonas con alta diversidad biológica y endemismos, así como aquellas que son más vulnerables a los efectos del cambio climático (Araújo *et al.* 2005). En definitiva, la clasificación bioclimática se consolida como una herramienta indispensable para la gestión sostenible del territorio y la adaptación a los desafíos del cambio global.

Por otra parte, la integración de técnicas de *machine learning* en la clasificación bioclimática representa una revolución en la forma en que entendemos y modelamos la relación entre el clima y la biodiversidad. Los algoritmos de *ML* (*machine learning*), como los árboles de decisión, las redes neuronales y las máquinas de vectores de soporte, ofrecen la capacidad de analizar grandes conjuntos de datos climáticos y ecológicos de manera más eficiente y precisa que los métodos tradicionales (Reichstein *et al.* 2019). Esto permite identificar patrones complejos y relaciones no lineales entre variables climáticas y la distribución de especies, lo que mejora la capacidad de predecir los impactos del cambio climático en los ecosistemas (Elith, J. & Leathwick, J. R. 2009). Además, el *ML* facilita la integración de múltiples fuentes de datos, como imágenes satelitales, datos de teledetección y modelos climáticos, lo que proporciona una visión más completa y detallada de la distribución de los bioclimas y su relación con la biodiversidad (Reichstein *et al.* 2019). En este sentido, el uso de *ML* en la clasificación bioclimática no solo mejora la exactitud de los modelos, sino que también abre nuevas vías para la investigación y la gestión de la biodiversidad en un contexto de cambio global.

Siguiendo estas líneas de investigación, se desarrolló un estudio exhaustivo en la cuenca del río Caroní, centrado en la identificación y mapeo de las unidades bioclimáticas, con el propósito de conocer la compleja relación climática en la zona, el uso del suelo y la conservación de la biodiversidad en esta región clave de Venezuela (Huber 1997), de manera particular este estudio se centró en determinar las zonas de vida basado en la clasificación de Holdridge, utilizando un método de clasificación supervisada de Máxima Verosimilitud (*ML*, por sus siglas en inglés) (Guisan & Zimmermann 2000).

2. Área de estudio

La cuenca del río Caroní, ubicada en el centro de la Guayana venezolana, constituye un territorio de gran importancia estratégica para el país. Esta vasta región, que abarca una superficie de 9,216,908 hectáreas (aproximadamente el 10 % del territorio nacional), se extiende por el sureste del estado Bolívar, desde el punto más meridional en los 3° 37' de latitud norte, en los límites con Brasil en la Sierra Pacaraima, hasta su punto más septentrional en los 8° 21' de latitud norte en la desembocadura del Caroní en el río Orinoco. De este a oeste, se extiende desde los 60° 35' de longitud oeste en las cabeceras del río Arabopó hasta los 64° 37' de longitud oeste (Sánchez *et al.* 2016).

La cuenca del Caroní se caracteriza por su extraordinaria biodiversidad, resultado de la combinación de factores climáticos, geológicos y altitudinales que dan origen a una gran variedad de ecosistemas, desde bosques húmedos tropicales hasta sabanas y tepuyes (Huber 2001). Esta riqueza biológica incluye una gran cantidad de especies endémicas y amenazadas, lo que convierte a la región en un área prioritaria para la conservación de la biodiversidad a nivel global (PNUD 2010).

Además de su valor ecológico, la cuenca del Caroní juega un papel fundamental en el desarrollo socioeconómico de Venezuela. La región alberga importantes represas hidroeléctricas, como Guri, Caruachi y Macagua, que generan un alto porcentaje de la energía eléctrica consumida en el país. Asimismo, la cuenca del Caroní es una fuente vital de recursos naturales, como agua, madera y minerales, que sustentan diversas actividades económicas y el bienestar de las comunidades locales.

La cuenca del río Caroní, se configura como un complejo mosaico de subcuenca, cada una con un régimen climático y características biogeográficas particulares (Huber 2001). Esta se divide en 5 grandes subcuenca: Bajo Caroní, Medio Caroní, Alto Caroní, Bajo Paragua y Alto Paragua. El Alto Caroní, dominado por el bosque muy húmedo tropical, se distingue por sus elevadas precipitaciones y temperaturas cálidas constantes, condiciones que favorecen el desarrollo de bosques ombrófilos siempre verdes de extraordinaria riqueza florística y faunística (Meier & Huber 2004). En contraste, el Medio Caroní se caracteriza por un clima de sabana tropical, con una estación seca marcada y una estación lluviosa más prolongada, modelando un paisaje de sabanas y bosques de galería que alberga una fauna diversa, incluyendo especies emblemáticas como el venado y el jaguar (MARNR 1992). El Bajo Caroní, en su transición entre la sabana y el bosque húmedo tropical, comparte elementos climáticos con el Medio Caroní, pero con precipitaciones ligeramente más abundantes, lo que se traduce en una vegetación donde los bosques semideciduos y de galería cobran mayor protagonismo (MARNR 1992). Las subcuenca del Alto y Bajo Paragua, por su parte, replican patrones climáticos y biogeográficos similares al Alto y Medio Caroní, respectivamente, con el primero dominado por bosques ombrófilos siempreverdes y el segundo por sabanas y bosques de galería (MARNR 1992, Huber 2001).

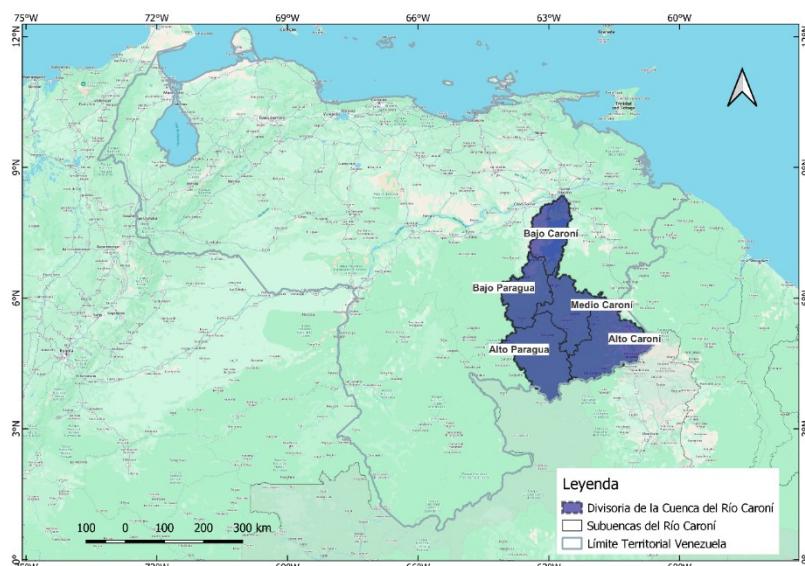


Figura 1. Mapa de la Cuenca del río Caroní

2.1. Metodología

Este estudio adoptó un enfoque basado en datos globales para la caracterización climática de la cuenca del río Caroní, diferenciándose de investigaciones previas. Se emplearon bases de datos de renombre como CHIRPS (Funk *et al.* 2015), POWER NASA PROJECT (Stackhouse *et al.* 2018), WORLDCLIM (Fick & Hijmans 2017) y ERA5-Land (Hersbach *et al.* 2020), priorizando la precisión espacial y la disponibilidad de datos actualizados. Esta elección metodológica permitió superar las limitaciones de acceso a datos oficiales y la necesidad de interpolación, minimizando errores y complementando estudios previos.

Las estimaciones derivadas de estas fuentes, que abarcan precipitación, temperatura, humedad, viento, radiación e insolación, son fundamentales para análisis de ecosistemas, modelado de nichos, estudios de cambio climático y evaluación de impactos ambientales (Hijmans *et al.* 2005). Su uso se

extiende a informes nacionales a la CMNUCC, dada la escasez de datos de observación en superficie. El acceso gratuito y la continuidad de la línea base climática (1981-2020) son ventajas adicionales. Si bien se reconoce la incertidumbre inherente a estos productos, su aplicación ofrece una oportunidad invaluable para comprender el clima de la cuenca del Caroní, crucial para la gestión de la biodiversidad y la adaptación al cambio climático.

Para el cálculo de la Evapotranspiración Potencial (ETP), se empleó el método de Hamon (1961), que es un enfoque empírico ampliamente reconocido por su simplicidad y aplicabilidad en diversas condiciones climáticas (Allen *et al.* 1998). Este método se basa en la relación fundamental entre la temperatura del aire y la demanda de agua por parte del clima, la cual está intrínsecamente ligada a la energía disponible en el entorno (Monteith, 1965). La ecuación utilizada para estimar la ETP es la siguiente:

Ecuación 1

$$ETP_{Hamon} = 13.97 \times d \times D^2 \times W_t$$

donde la ETP, está expresada en milímetros por mes, d es el número de días en un mes, D es la media mensual de horas de luz diurna en unidades de 12 hrs, W_t es un término de densidad de vapor de agua saturado, en gramos por metro cúbico, y T corresponde con la Temperatura Media Anual, calculado por:

Ecuación 2

$$W_t = \frac{4.95 \times e^{0.062 \times T}}{100}$$

La siguiente en la Tabla 1 expresa las unidades de medidas obtenidas y fuentes de datos desde cada una de las bases de datos en función de las variables requeridas. Nótese como las variables de Temperatura Máxima Anual, Temperatura Mínima Anual, Temperatura Media Anual, Humedad Relativa y Evapotranspiración poseen una resolución espacial de 30 km, mientras que la Precipitación posee una mejor resolución espacial pero que implicó un mayor costo computacional.

Tabla 1

VARIABLE	FUENTE	RESOLUCIÓN DE CELDA	UNIDADES
PRECIPITACIÓN	CHIRPS https://www.chc.ucsb.edu/data/chirps	5.5 km	mm
TEMPERATURA MÁXIMA ANUAL		30 km	°C
TEMPERATURA MÍNIMA ANUAL	NASA POWER PROJECT'S DATA https://power.larc.nasa.gov	30 km	°C
TEMPERATURA MEDIA ANUAL		30 km	°C
HUMEDAD RELATIVA	NASA POWER PROJECT'S DATA https://power.larc.nasa.gov	30 km	%
EVAPOTRANSPIRACIÓN	FUENTE DE ENTRADA LA TEMPERATURA MEDIA ANUAL ESTIMADA BAJO LA METODOLOGÍA DE HAMON	30 km	mm

Fuente: elaboración propia sobre las fuentes y datos recolectados.

Para representar el comportamiento espacial de cada variable climática a nivel mensual y anual, se utilizó el método de Regresión Ponderada Geográfica (GWR) (Fotheringham *et al.* 2002). La GWR es una técnica de regresión espacial que permite modelar relaciones no estacionarias, es decir, aquellas que varían geográficamente (Foody 2004).

A diferencia de los modelos de regresión global, que asumen que la relación entre las variables es la misma en toda el área de estudio, la GWR permite crear modelos locales que se ajustan a las particularidades de cada ubicación, donde se ajusta una ecuación de regresión a todas las entidades del conjunto de datos, pero los coeficientes de regresión no son fijos, sino que dependen de las coordenadas geográficas de las observaciones (Lloyd, 2010). Esto se logra mediante la introducción de una función de ponderación que asigna mayor peso a las observaciones cercanas al punto donde se calcula la regresión local y menor peso a las observaciones más lejanas. La ecuación de regresión para cada ubicación i se define de la siguiente forma:

$$\text{Ecuación 3} \quad y_i = \beta_0(\mu_i, \nu_i) + \sum_k^p \beta_k(\mu_i, \nu_i) x_{ik} + \varepsilon_i$$

dónde:

- y_i es el valor de la variable dependiente en la ubicación i
- (μ_i, ν_i) son las coordenadas espaciales de la ubicación i
- $\beta_0(\mu_i, \nu_i)$ es el intercepto de la regresión local en la ubicación i
- $\beta_k(\mu_i, \nu_i)$ es el coeficiente de la variable explicativa k en la regresión local en la ubicación i
- x_{ik} es el valor de la variable explicativa k en la ubicación i
- ε_i es el error de la regresión local en la ubicación i

La ventaja de este método es que permite capturar variaciones locales en los datos que los modelos globales pueden pasar por alto (Fotheringham, Brunsdon & Charlton, 2002). Además, la GWR tiene en cuenta la autocorrelación espacial, que es la tendencia de las ubicaciones cercanas a influir entre sí (Lloyd, 2010). La GWR requiere calibrar el ancho de influencia (*bandwidth*), que determina el tamaño del área local que se utiliza para calcular cada ecuación de regresión. En este estudio, para las variables Temperatura Media Anual, Temperatura Mínima Anual, Temperatura Máxima Anual y Humedad Relativa, el ancho de influencia se calibró automáticamente utilizando la función *gwr.sel* de la librería de R *spgwr*; éste estudio aplica el método de validación cruzada estimando el error cuadrático medio de predicción de las regresiones ponderadas geográficamente, eligiendo el ancho de banda que minimiza este estimador (Fotheringham *et al.* 2002). Finalmente, la GWR fue ejecutada con los datos calibrados en el software SAGA-GIS (Conrad *et al.* 2015). Es preciso señalar que este método, al ser un tipo de modelo lineal generalizado, requiere menos observaciones que otros métodos de estadística espacial, como la geoestadística, en la cual se requiere de al menos 150 observaciones (Oliver & Webster 2015). En el caso de la Evapotranspiración la misma se estimó utilizando un script de R con datos de entrada de la Temperatura Media estimada, utilizando la GWR y las ecuaciones 1 y 2.

Cabe destacar que los datos de precipitación correspondieron con un caso especial de manejo de datos. En este sentido, se creó un script de R y la librería ráster para procesar datos geoespaciales (Hijmans 2025), este lee los datos de precipitación media de cada mes como un "raster brick" (un conjunto de capas ráster), para luego calcular el promedio de precipitación para cada año (de enero a diciembre) durante un período específico (1983-2020, que comprende 38 años), con esto aludimos a la precipitación anual acumulada. Finalmente, estos mapas de precipitación promedio mensual se guardaron como nuevos archivos GeoTIFF, proporcionando una media climatológica mensual para la región de interés. Finalmente, a cada ráster mensual de precipitación se le ejecutó la GWR en SAGA-GIS (Conrad *et al.* 2015) utilizando el módulo *Geographically Weighted Regression for grid downscaling*, debido al costo computacional se utilizó un ancho de banda local de tipo Gaussiano con 7 píxeles, el ráster de precipitación media anual para la clasificación se obtuvo mediante la suma de los

doce de los *rasters* mensuales (véase los métodos y procedimientos en Fortheringham *et al.* 1998; Fortheringham *et al.* 2002, Lloyd 2010, Zhang *et al.* 2018).

Con el fin de validar la calidad de los productos del GWR se llevó a cabo una validación cruzada (Hastie *et al.* 2009), la misma se realizó mediante la evaluación del Error Medio (ME), el Error Absoluto Medio (MAE) y la Raíz del Error Cuadrático Medio (RMSE) (Willmott & Matsuura 2006). Estas métricas permitieron cuantificar la exactitud de las estimaciones climáticas y evaluar su ajuste a los datos observados. El ME, que representa la diferencia promedio entre los valores medidos y los valores pronosticados, es útil para identificar posibles sesgos en las estimaciones (Legates & McCabe 1999). El MAE, por su parte, mide la magnitud promedio de los errores, independientemente de su dirección (Chai & Draxler 2014). El RMSE, finalmente, proporciona una medida de la dispersión de los errores, siendo más sensible a los valores atípicos (Hyndman & Koehler 2006). Es importante destacar que, gracias al teorema del límite central, se espera que los errores de las estimaciones climáticas se distribuyan de forma aproximadamente normal, lo que justifica el uso de estas métricas para evaluar la precisión de las cartas climáticas (Rice 2007).

A su vez, se aplicó el método de clasificación de Máxima Verosimilitud (ML), y este corresponde con un enfoque estadístico que, a diferencia de los determinísticos, reconocen la inherente incertidumbre en los fenómenos del mundo real, ya que, al incorporar la probabilidad, los modelos estadísticos permiten cuantificar y gestionar el riesgo asociado a las decisiones (Gujarati & Porter 2009). Esta perspectiva probabilística es fundamental, ya que muchos fenómenos naturales, exhiben una variabilidad intrínseca que no puede ser completamente capturada por modelos puramente determinísticos, como lo es la superposición cartográfica tradicional, puesto que la variable dependiente no está únicamente determinada por las variables independientes, sino que su valor se describe mediante una distribución de probabilidad y un término de error en los datos, reflejando la incertidumbre inherente al proceso (Gujarati & Porter 2009). Esta es una herramienta ampliamente utilizada en la generación de capas de cobertura a partir de información multiespectral (Richards & Jia 2006). Sin embargo, su aplicación se extiende más allá de este ámbito, abarcando también estudios de clasificación climática y análisis de ecosistemas (Chuvieco 2002). En el contexto de la clasificación climática, el ML permite categorizar diferentes unidades climáticas o zonas de vida a partir de variables climáticas cuantitativas, como temperatura, precipitación y humedad (Virla & Pirela 2012). De esta manera, se pueden generar mapas de clasificación climática que delimitan áreas con características climáticas similares.

El clasificador de Máxima Verosimilitud (ML) es un método estadístico bayesiano que asigna cada observación a la clase que maximiza la probabilidad a posteriori de pertenencia, basada en la función de densidad de probabilidad multivariada de cada clase (Bishop 2006). Este clasificador asume que las observaciones de cada clase siguen una distribución normal multivariada, caracterizada por un vector de medias y una matriz de covarianza (Duda *et al.* 2001). El proceso de clasificación implica estimar los parámetros de la distribución normal multivariada para cada clase a partir de un conjunto de entrenamiento de observaciones etiquetadas. Una vez estimados los parámetros, se calcula la probabilidad a posteriori de que una nueva observación pertenezca a cada clase utilizando el teorema de Bayes. La observación se asigna a la clase con la mayor probabilidad a posteriori. El clasificador ML es un método ampliamente utilizado en diversas aplicaciones, incluyendo la clasificación de imágenes de teledetección, el reconocimiento de patrones y la clasificación de datos climáticos (Hastie *et al.* 2009). Su popularidad se debe a su capacidad para trabajar con datos multivariados, su fundamento estadístico sólido y su relativa simplicidad de implementación.

Se adoptó un enfoque de aprendizaje supervisado para la clasificación de ecosistemas, utilizando la clasificación climática de Holdridge (CVG-EDELCA 2004. *Cap. 2 Clasificación climática según Holdridge*), verificada con expertos del Plan Maestro de la Cuenca del Río Caroní (CVG-EDELCA 2004. *Cap. 6 Ecología del paisaje*), como referencia. Esta metodología permitió relacionar las variables climáticas analizadas con la distribución de ecosistemas específicos en la cuenca, basándose en la premisa de que las zonas de vida de Holdridge reflejan las condiciones climáticas que influyen en dicha distribución.

Formalmente, el método de ML calcula la probabilidad de que ese píxel pertenezca a cada una de las clases, basándose en su vector de valores mutivariantes y en los parámetros estadísticos de cada clase (vector de medias y matriz de covarianza). Este es un método de clasificación supervisada derivado del teorema de Bayes, que establece que la distribución a posteriori $P(i|\omega)$, es decir, la probabilidad de que un píxel con el vector de características ω pertenezca a la clase i , viene dada por:

Ecuación 4
$$P(i|\omega) = \frac{P(i|\omega)P(i)}{P(\omega)}$$

Dónde $P(i|\omega)$ es la función de Verosimilitud, $P(i)$ es la información a priori, es decir, la probabilidad de que la clase i se encuentre en la zona de estudio y $P(\omega)$ es la probabilidad de que ω se encuentre en la zona de estudio, que puede escribirse como:

Ecuación 5
$$P(\omega) = \sum_{i=1}^M P(i|\omega)P(i)$$

Dónde M es el número de clases. $P(\omega)$ se trata a menudo como una normalización para garantizar que $\sum_{i=1}^M P(i|\omega)P(i)$ suma 1. El píxel x se asigna a la clase i mediante la regla:

Ecuación 6
$$x \in i \text{ si } P(i|\omega) > P(j|\omega) \text{ para todo } j \neq i$$

Computacionalmente, la ecuación para calcular la probabilidad de que un píxel x pertenezca a la clase i es:

Ecuación 7
$$P(x|\omega) = \ln P(\omega|i) = -\frac{1}{2}(\omega - \mu_i)^t C_i^{-1}(\omega - \mu_i) - \frac{N}{2} \ln(2\pi) - \frac{1}{2} \ln(|C_i|)$$

Donde:

- $P(x|\omega)$: es la probabilidad de que el píxel x pertenezca a la clase ω .
- N : es el número de variables climáticas utilizadas.
- μ_i : es el vector de medias de la clase i .

El píxel se asigna a la clase que tenga la mayor probabilidad $P(x|\omega)$ (Ahmad *et al.* 2012).

Como bandas de entrada provenientes de fuentes globales de datos anuales para las variables a partir de fuentes de datos globales, esta base incluyó variables como precipitación, temperatura (máxima, media y mínima), humedad relativa, y evapotranspiración, mejoradas con la GWR por sus siglas en inglés, además se incluyó el Modelo Digital Elevación proveniente del SRTM como complemento fundamental para caracterizar el clima de la cuenca; cabe de destacar que todas las variables de entradas tenían una resolución espacial de 90 m. Es importante destacar que la clasificación ML fue ejecutada en el software SAGA-GIS (Conrad *et al.* 2015).

La evaluación de la precisión de una clasificación de imágenes es un paso fundamental para determinar la calidad y confiabilidad de los resultados obtenidos. En este estudio, se llevó a cabo una evaluación rigurosa de la exactitud de la clasificación, comparando el resultado con datos de referencia independientes. Se utilizaron métricas ampliamente reconocidas en la literatura, como la matriz de confusión, la precisión global, la exactitud del usuario y la exactitud del productor (Congalton & Green 2008). La matriz de confusión, también conocida como tabla de contingencia, es una herramienta esencial para visualizar y analizar los resultados de la clasificación. Esta tabla compara las clases asignadas por el clasificador con las clases de referencia, permitiendo identificar los errores de clasificación y cuantificar la exactitud de cada clase (Foody 2002). A partir de la matriz de confusión, se derivan métricas como la precisión global, que representa el porcentaje de píxeles correctamente clasificados; la exactitud del usuario, que indica la probabilidad de que un píxel clasificado como perteneciente a una clase realmente pertenezca a esa clase; y la exactitud del productor, que representa la probabilidad de que un píxel de referencia de una clase haya sido correctamente clasificado (Lillesand *et al.* 2015). En este estudio, se empleó un diseño de muestreo aleatorio estratificado para seleccionar

las unidades de muestreo para la evaluación de la precisión y exactitud. Este tipo de muestreo es eficiente para datos con comportamiento lineal (Quenouille 1949), como los que se analizan en este estudio (Ahmad & Quegan 2012). Se seleccionaron 118 polígonos que representan 1,115,576 ha, esto corresponde con del 10 % del área de la Cuenca del Río Caroní, lo que proporciona una muestra representativa para la evaluación de la precisión y exactitud.

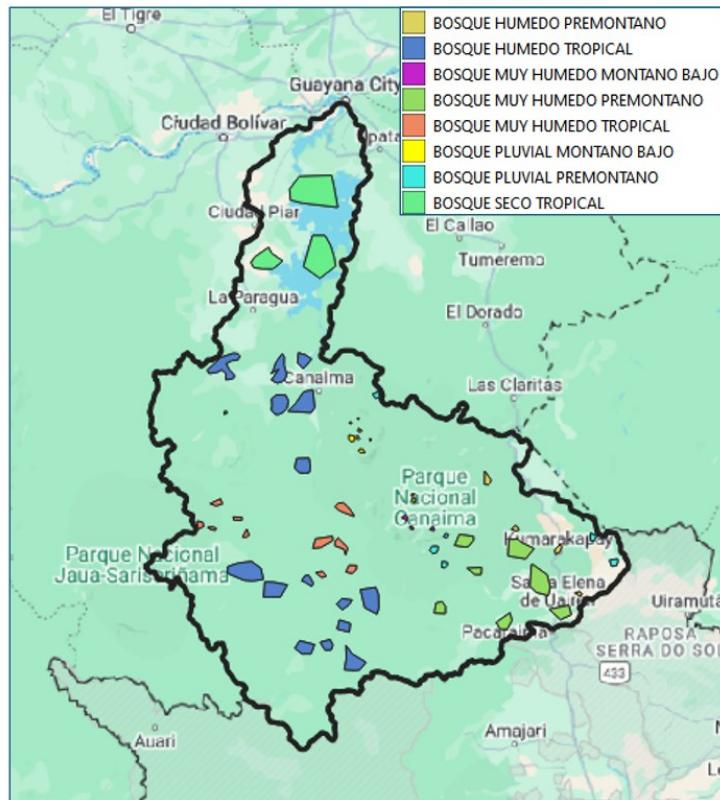


Figura 2. Mapa de distribución heterogénea de zonas de vida refleja, áreas de entrenamiento.

La superficie total evaluada en la matriz de confusión está distribuida en ocho zonas de vida distintas dentro de la cuenca del río Caroní, sumando un total de 1,115,576 hectáreas. El Bosque Húmedo Tropical se destaca como la zona de vida más extensa, abarcando 460,852 hectáreas, lo que representa un 41.3 % del área total evaluada. Le sigue el Bosque Seco Tropical con 330,898 hectáreas (29.7 %). El Bosque Muy Húmedo Premontano ocupa 189,786 hectáreas (17.0 %). En contraste, otras zonas de vida como el Bosque Húmedo Premontano (16,752 ha), Bosque Muy Húmedo Tropical (75,670 ha), Bosque Muy Húmedo Montano Bajo (5,096 ha), Bosque Pluvial Montano Bajo (10,510 ha) y Bosque Pluvial Premontano (26,012 ha) representan extensiones menores en la superficie total evaluada. Esta distribución heterogénea de zonas de vida refleja la complejidad y diversidad bioclimática de la cuenca del río Caroní, resaltando la necesidad de estrategias de gestión diferenciadas para cada ecosistema, considerando su vulnerabilidad y los servicios ecosistémicos que proveen.

3. RESULTADOS

Se presenta a continuación la validación cruzada de los diferentes indicadores de exactitud de las variables climáticas mejoradas con la GWR. Aquí se señala ante todo que el Error Medio (ME) se utiliza para evaluar el grado de sesgo en las estimaciones siguiendo la lectura de Li y Heap (2014), reconociendo el sesgo como la diferencia media entre el error y el valor real del parámetro que se está estimando (Isaaks & Srivastava 1989). En tal sentido, surge la inherente precaución al usar el ME como indicador de exactitud, ya que los errores positivos y negativos pueden contrarrestarse entre sí, lo que puede llevar a un ME que sea menor que el error real (Nalder & Wein 1998). De tal modo, el Error Medio Cuadrático Estandarizado (RMSE) terminó proporcionando una medida del tamaño del error, pero es sensible a los valores atípicos, ya que otorga un peso considerable a los errores grandes

(Hernández-Stefanoni *et al.* 2006). En contraste, el Error Absoluto Medio (MAE) es menos sensible a los valores extremos (Willmott 1982, Vicente-Serrano *et al.* 2003) y refleja hasta qué punto la estimación puede estar equivocada (Nalder & Wein 1998). En este sentido, cabe destacar que los valores con peor desempeño son la precipitación media anual, temperatura anual media mínima y la Temperatura Media Anual Máxima; esto es indicativo de dos posibles situaciones, el modelo GWR no está correctamente especificado y/o se están obviando variables independientes relevantes. Nótese que no se presentan las métricas de la ETP, ya que esta es derivada de la ecuación de *Hamon* descrita previamente. A continuación, se presentan los valores en la Tabla 2, es de destacar que los resultados no se presentan normalizados.

Tabla 2

Variable	Estadístico		
	ME	MAE	RMSE
Precipitación (mm)	-39.09	323.53	459.85
Temperatura Media Anual (°C)	-0.37	1.39	1.57
Temperatura Mínima Anual (°C)	-3.21	3.21	3.50
Temperatura Máxima Anual (°C)	5.09	5.09	5.31
Humedad Relativa (%)	1.76	3.64	4.15

Fuente: elaboración propia sobre los datos obtenidos

Los resultados de la evaluación de la exactitud revelaron que la clasificación en general tiene un 93 % de acierto global. Sin embargo, se identificaron algunas clases con menor exactitud, como el bosque pluvial pre montano, el bosque muy húmedo tropical y el bosque húmedo pre montano. Estos resultados sugieren que estas clases pueden presentar estructuras transicionales que no fueron capturadas adecuadamente por el modelo de clasificación de Máxima Verosimilitud (ML).

Es importante destacar que, si bien la clasificación en general muestra una alta exactitud, los resultados deben ser interpretados con cautela, teniendo en cuenta las limitaciones identificadas en algunas clases. No obstante, se argumenta que, debido al teorema de los grandes números, el supuesto de normalidad multivariante se cumple, lo que justifica el uso del estimador de Máxima Verosimilitud (ML) como el mejor estimador lineal e insesgado (MELI) (Hastie, Tibshirani & Friedman 2009). En este sentido, se presenta a continuación la exactitud de la clasificación comparando el resultado con datos de referencia independientes (por ejemplo, datos de campo o imágenes de mayor resolución). Se utilizaron métricas como la matriz de confusión, la precisión global, la exactitud del usuario y la exactitud del productor para cuantificar la exactitud de la clasificación.

Como el resultado obtenido corresponde con una capa categórica, el producto de validación requerido es una matriz de confusión, la misma corresponde con una tabla de aciertos entre los píxeles clasificados con los evaluados como verdad terreno, en la misma la diagonal principal representa los píxeles correctamente clasificados en Tabla 2; nótese como las clases de Bosque pluvial pre montano, Bosque muy húmedo tropical y Bosque húmedo pre montano son las que peor desempeño tienen dentro de la clasificación, ya que presenta estructuras transitivas no capturada por el modelo de clasificación de Máxima Verosimilitud (ML). Así mismo, es conveniente destacar que en general el resto de las clases superan el 90 % de los aciertos globales, con lo que se puede considerar que las mismas están convenientemente representadas dentro del modelo, y finalmente, resaltar que en general la clasificación tiene un 93 % de acierto global; estos resultados deben ser vistos con cautela, reiteramos, debido a los elementos previamente descritos.

Es gracias al teorema de los grandes números, el supuesto de normalidad multivariante se cumple, lo que justifica el uso del estimador de Máxima Verosimilitud (ML) como el mejor estimador lineal e insesgado (MELI) (Hastie *et al.* 2009).

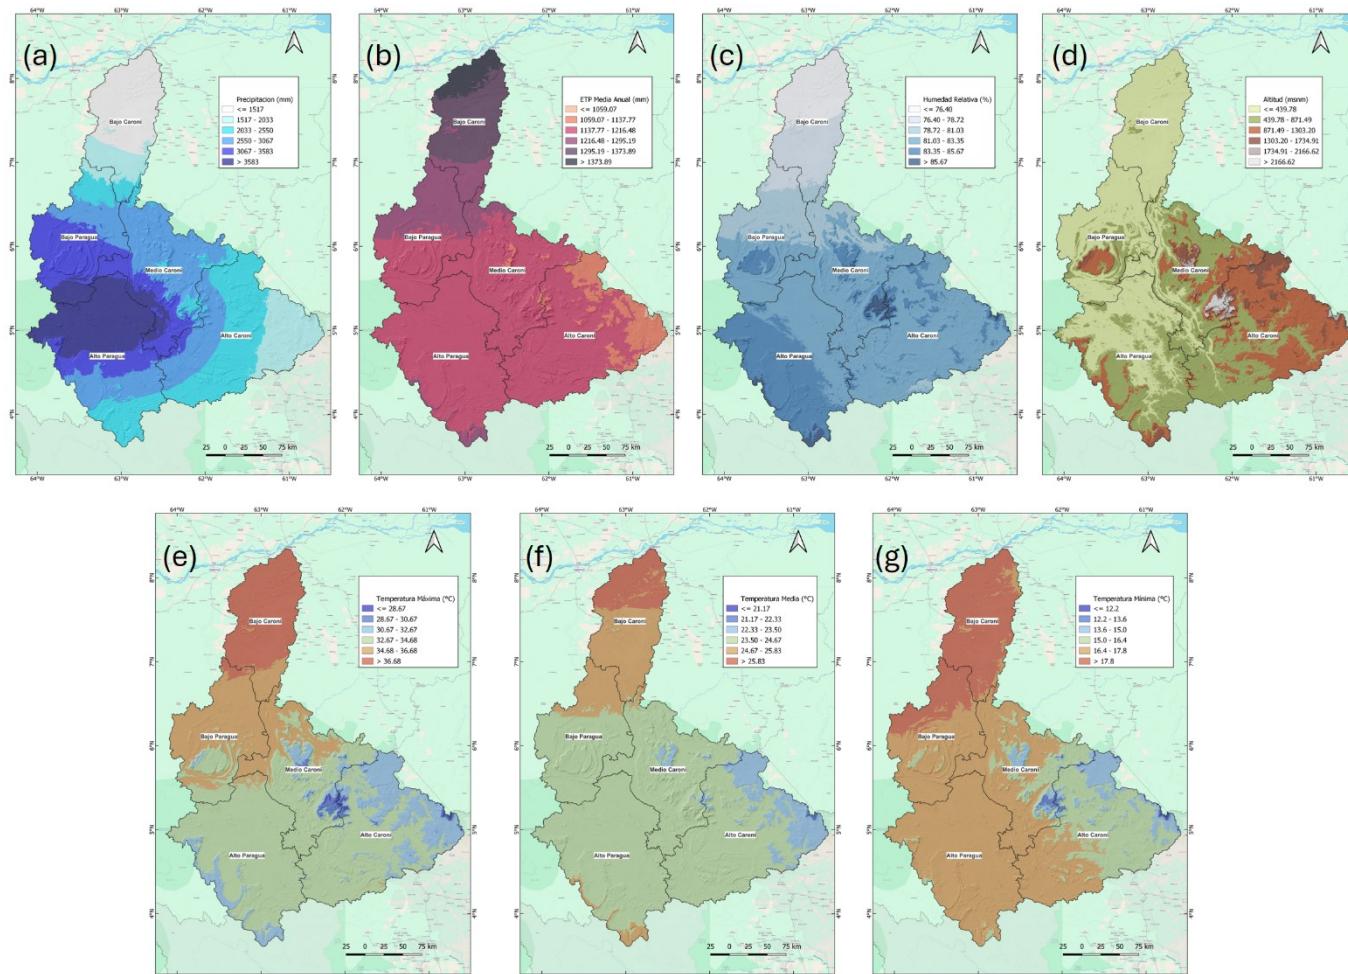


Figura 3. Mapas de: a) Precipitación Media Anual; b) ETP Media Anual; c) Humedad Relativa Media Anual; c) Modelo Digital de Elevación; e) Temperatura Máxima Anual; f) Temperatura Media Anual; g) Temperatura Mínima Anual

TABLA 3 Matriz de Confusión de la Clasificación Supervisada

CLASE BIOCLIMATICA	BOSQUE SECO TROPICAL	BOSQUE HUMEDO TROPICAL	BOSQUE MUY HUMEDO PREMONTANO	BOSQUE MUY HUMEDO TROPICAL	BOSQUE PLUVIAL PREMONTANO	BOSQUE HUMEDO PREMONTANO	BOSQUE MUY HUMEDO MONTANO BAJO	BOSQUE PLUVIAL MONTANO BAJO	Suma del Usuario	Exactitud del Usuario (%)
BOSQUE SECO TROPICAL	206722	0	0	0	0	0	0	0	206722	100
BOSQUE HUMEDO TROPICAL	230	254676	0	359	502	0	0	0	255767	99.57
BOSQUE MUY HUMEDO PREMONTANO	0	48	117521	0	3756	4276	194	3	125798	93.42
BOSQUE MUY HUMEDO TROPICAL	0	26018	0	46950	0	0	0	0	72968	64.34
BOSQUE PLUVIAL PREMONTANO	0	6044	1122	12	11637	1910	123	0	20848	55.81
BOSQUE HUMEDO PREMONTANO	0	1466	151	0	0	4268	0	3	5888	72.48
BOSQUE MUY HUMEDO MONTANO BAJO	0	0	0	0	0	0	2807	0	2807	100
BOSQUE PLUVIAL MONTANO BAJO	0	0	0	0	385	0	65	6568	7018	93.58
Suma del Productor	206952	288252	118794	47321	16280	10454	3189	6574	TOTAL (%)	93.31
Exactitud del Productor (%)	99.89	85.35	98.93	99.22	71.48	40.83	88.02	99.91		

Fuente: elaboración propia sobre los datos recolectados.

En el clasificador de Máxima Verosimilitud (ML) de SAGA GIS, se contiene la información sobre la probabilidad de pertenencia de cada píxel a la clase asignada (Richards & Jia 2006). En otras palabras, la capa de proximidad determinó cuán "seguro" está el clasificador de un píxel que pertenece a una clase específica. Así los píxeles con valores de proximidad altos generaron mayor confianza, mientras que los píxeles con valores de proximidad bajos terminaron por delimitar e identificar las zonas de mayor incertidumbre o transición entre clases (Lillesand *et al.* 2015). Entonces el mapa de probabilidad/proximidad de la clasificación de Máxima Verosimilitud (ML) (Figura 4) supera los enfoques determinísticos al proporcionar no solo la clase asignada a cada pixel, sino también su grado de certeza. De tal modo, este enfoque revela áreas con alta ambigüedad (como las afectadas por el relieve o efectos transitivos), donde la probabilidad de clasificación correcta es baja. Esto permite identificar limitaciones del modelo y priorizar validaciones en zonas conflictivas, mejorando la confiabilidad del análisis.

Además, la cuantificación de la probabilidad, una herramienta decisiva para aplicaciones críticas, ayudó a conocer el nivel de confianza en la clasificación, a optimizar recursos y reducir errores. En consecuencia, mientras un método determinístico oculta las imperfecciones del modelo, el mapa probabilístico las hace explícitas, facilitando una interpretación más transparente y robusta de los resultados. Esta ventaja lo convierte en una opción superior para estudios que requieren evaluar la exactitud espacial de manera rigurosa (Lillesand *et al.* 2015). Los resultados revelan que las clases de bosque muy húmedo pre montano y bosque pluvial pre montano presentan las medias de proximidad más bajas (85.71 y 85.99, respectivamente), lo que sugiere que la clasificación en estas áreas es menos confiable, probablemente debido a la presencia de estructuras transicionales o ecotonos no capturadas adecuadamente por el modelo de clasificación de Máxima Verosimilitud (ML) (Foody 2002). En contraste, el Bosque Seco Tropical muestra la media de proximidad más alta (99.64), lo que indica una clasificación más precisa y confiable. Otras zonas de vida como el Bosque Húmedo Premontano (89.84), Bosque Húmedo Tropical (91.45), Bosque Muy Húmedo Montano Bajo (96.56), Bosque Muy Húmedo Tropical (93.58) y Bosque Pluvial Montano Bajo (88.11) muestran valores de proximidad intermedios, lo que sugiere una clasificación con un nivel de confianza moderado. De tal modo, se hizo necesaria la revisión de los datos de entrenamiento para estas zonas de vida y, a su vez, evaluar si es necesario incluir muestras adicionales que representen mejor las estructuras transicionales, para ajustar los parámetros del clasificador de máxima verosimilitud, mejorando la discriminación entre estas clases y considerando clasificadores alternativos que sean más adecuados para trabajar con datos de alta complejidad y zonas de transición (Congalton & Green 2008).

El mapa de Clasificación Climática en la figura 5 obtenido en este estudio revela una notable diversidad de zonas de vida en la cuenca del río Caroní, resultado de la interacción entre la altitud y la humedad, siguiendo el esquema de Holdridge (1966). Se identificaron tres pisos altitudinales (Tropical, Premontano y Montano Bajo) combinados con cuatro provincias de humedad (Seca, Húmeda, Muy Húmeda y Pluvial), lo que resultó en la delimitación de ocho zonas de vida distintas: Bosque Seco Tropical (14.9 %), Bosque Húmedo Tropical (30.3 %), Bosque Muy Húmedo Tropical (12.4 %), Bosque Húmedo Premontano (7.3 %), Bosque Muy Húmedo Premontano (18.1 %), Bosque Pluvial Premontano (12.6 %), Bosque Muy Húmedo Montano Bajo (0.6 %) y Bosque Pluvial Montano Bajo (3.6 %). Esta distribución de zonas de vida refleja la complejidad climática de la cuenca, similar a lo encontrado en otros estudios de clasificación climática en regiones tropicales (e. g. Ramírez *et al.* 2010 en los Andes colombianos).

La exactitud de la clasificación fue evaluada en una matriz de confusión, comparando los píxeles clasificados con datos verificados en terreno (Congalton & Green 2008). Es así que las clases de bosque pluvial pre montano, bosque muy húmedo tropical y bosque húmedo pre montano presentaron menor desempeño, lo que sugiere la presencia de estructuras transicionales o ecotonos que no fueron capturados adecuadamente por el modelo de clasificación de Máxima Verosimilitud (ML), un problema común en áreas de alta diversidad biológica en bosques tropicales (Foody & Cutler 2006). No obstante, el resto de las clases superó el 90 % de exactitud, lo que indica una buena representación en el modelo. La clasificación global alcanzó una exactitud del 93 %, un valor comparable con otros estudios de

clasificación de cobertura vegetal (Lillesand *et al.* 2015), aunque este valor debe interpretarse con cautela debido a las limitaciones mencionadas.

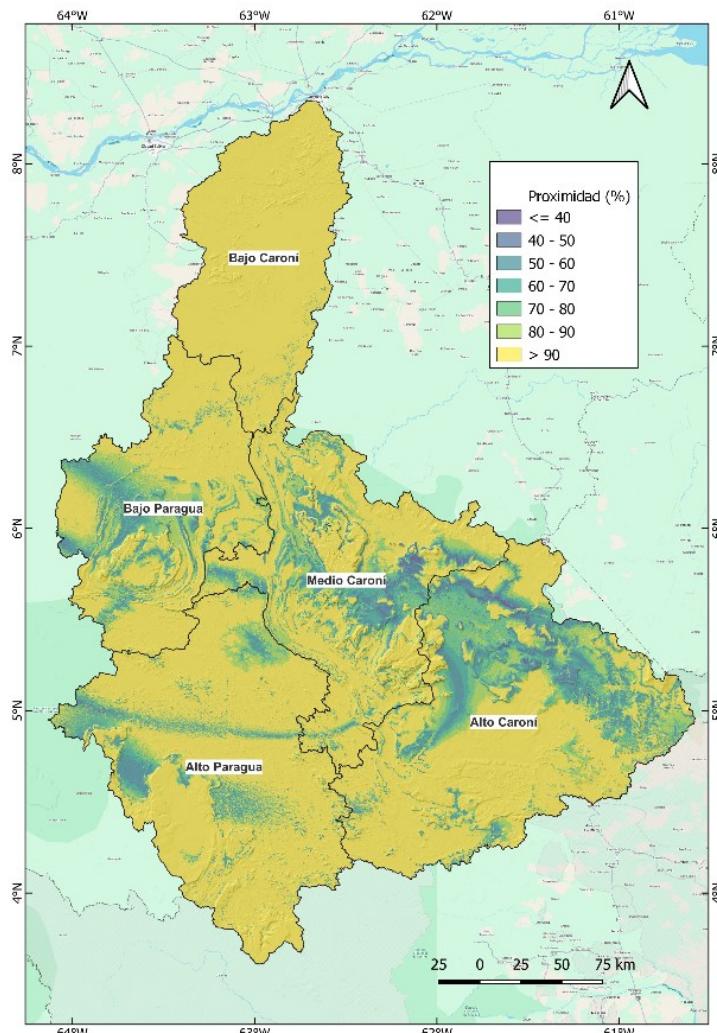


Figura 4. Mapa de probabilidad/proximidad

Las características climáticas de cada zona de vida fueron analizadas mediante estadísticas descriptivas (media, rango, desviación estándar y percentiles) de las variables climáticas a nivel anual y mensual (Tabla 3). Estos cálculos se concretan a nivel de píxel en operaciones *raster-vector*, técnica común en análisis espacial (Longley *et al.* 2015). Adicionalmente, la tipología climática en climadiagramas y en el período de crecimiento, que están definidos por la relación entre precipitación y evapotranspiración potencial (ETP), son el producto del seguimiento de la propuesta hecha por la FAO (1998). En el análisis, esto permitió identificar la condición hídrica y la fecha de inicio del período húmedo en cada zona de vida, los cuales deviene en información fundamental para comprender la dinámica de los ecosistemas (Walter & Lieth 1967).

El análisis de la temperatura y la precipitación como índice bioclimático anual promedio (1981-2020) reveló que el piso Tropical presenta temperaturas anuales promedio superiores a 24°C y la mayor variabilidad en la precipitación (1335 mm - 3732 mm), similar a lo reportado en otras zonas tropicales (Malhi & Wright, 2004). Este piso abarca el 58 % de la cuenca, con el Bosque Húmedo Tropical como zona de vida predominante (30.3 %), caracterizado por una Temperatura Media Anual de 24°C y una precipitación de 2882 mm. El piso Premontano (32.3 % de la cuenca) presenta temperaturas promedio similares a la cuenca ($24 \pm 0.2^{\circ}\text{C}$), con mínimas de 16.3°C y precipitación promedio de 2456 mm (2221 mm - 2625 mm). El piso Montano Bajo (4.2 %) registra temperaturas promedio más bajas (23.6°C), con mínimas de 14.3°C y precipitación (2440 mm) inferior al promedio anual, mostrando una

escasa diferencia con el Premontano, lo que sugiere una posible transición gradual o influencia de factores locales, como la exposición y la pendiente (Huber 1995).

En cuanto al resto de las variables climáticas, el Bosque Seco Tropical presenta la mayor ETP (1333 mm), menor humedad relativa (76.5 %) y mayor velocidad del viento (2.4 m/s), condiciones típicas de zonas áridas y semiáridas (Thornthwaite 1948). En el otro extremo, el Bosque Muy Húmedo Montano Bajo registra la menor ETP (1146.8 mm), mayor humedad relativa y las temperaturas máxima y mínima más bajas (29.2°C y 13.6°C, respectivamente), características asociadas a ambientes de alta montaña (Körner 2016). El régimen mensual de las variables climáticas es similar en todas las zonas de vida y está relacionado con la variación anual de la radiación solar, determinada por la posición geográfica de la cuenca y los movimientos astronómicos, lo que es un patrón común en regiones tropicales (Barry & Chorley 2010).

En relación con el período de crecimiento, el Bosque Seco Tropical lo inicia en abril, con mayor disponibilidad hídrica a partir de mayo, un comportamiento típico de zonas con marcada estacionalidad (Sarmiento 2002). El Bosque Húmedo Tropical lo inicia en marzo, mientras que los Bosques Muy Húmedo Tropical y Húmedo Premontano no presentan un período en que la ETP supere a la precipitación, lo que indica una condición de alta humedad durante todo el año, similar a lo encontrado en otros bosques húmedos tropicales (Whitmore 1998). En zonas de mayor altitud, el Bosque Muy Húmedo Premontano inicia su período húmedo en marzo; el Bosque Pluvial Premontano experimenta un período seco entre enero y marzo; el Bosque Muy Húmedo Montano Bajo comienza su período húmedo en la primera quincena de marzo; y el Bosque Pluvial Montano Bajo, a finales de marzo, lo que refleja la influencia de la altitud en la distribución de las lluvias (Rahbek *et al.* 2019).

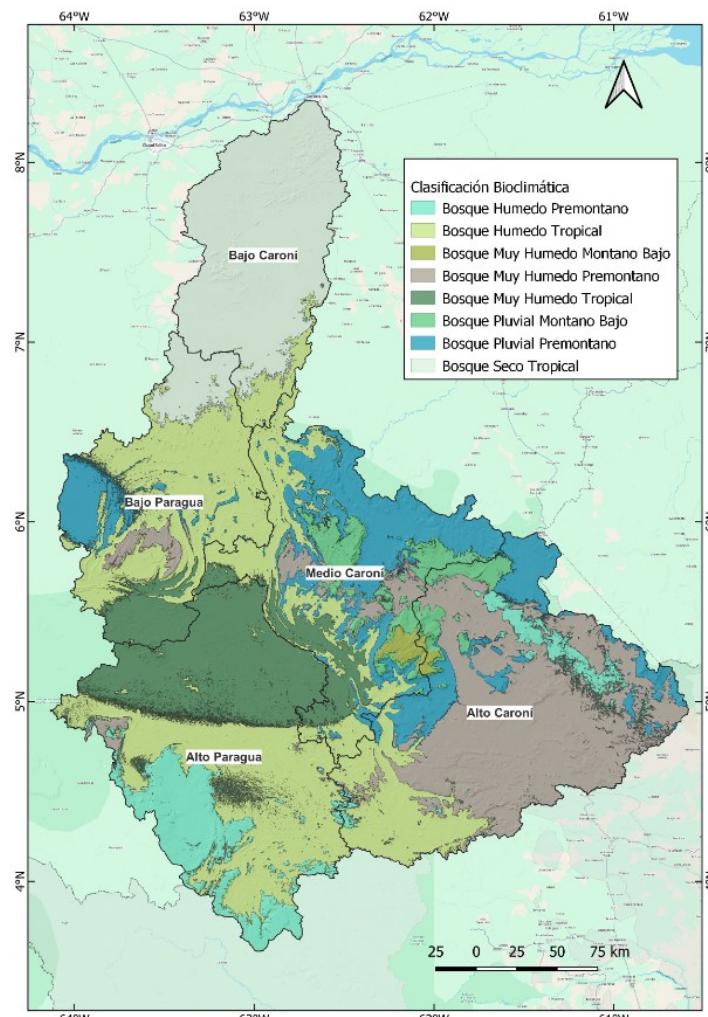


Figura 5. Mapa 3 Clasificación Climática

Siendo el análisis de los *box plots* una herramienta estadística que permite visualizar la distribución de datos (Wilcox 1949), esta revela características distintivas para cada zona de vida, lo que ayuda a comprender la exactitud de la clasificación. El Bosque Seco Tropical se distingue claramente por presentar los promedios más bajos de precipitación, altitud y humedad relativa, y los promedios más altos de temperatura (media, mínima y máxima) y evapotranspiración potencial (ETP). Esta singularidad climática, producto de su ubicación y condiciones geográficas (Trewartha & Horn 1980), explicaría su exactitud de clasificación (cerca al 100 %), ya que es la zona bioclimática más fácilmente diferenciable. El Bosque Húmedo Tropical, en segundo lugar, queda caracterizado por los mayores valores promedio de precipitación. Esta variable, fundamental para el desarrollo de la vegetación en climas tropicales (Malhi & Wright 2004), sería la que más influye en su diferenciación dentro del clasificador de Máxima Verosimilitud (ML), lo que explicaría su alto porcentaje de acierto global (97 %).

El Bosque Muy Húmedo Premontano, con un 93 % de acierto global, muestra una mayor confusión con el Bosque Pluvial Premontano y el Bosque Húmedo Premontano. La precipitación y la altitud serían las variables que más información aportan para su diferenciación. Esto sugiere que estas zonas comparten características climáticas similares, lo que dificulta su distinción mediante el clasificador de máxima verosimilitud, un modelo que asume distribuciones normales multivariadas (Anderson 2003).

Finalmente, el resto de las zonas de vida comparten un comportamiento similar en el segundo cuartil (mediana) *box plots*, diferenciándose principalmente en la varianza de las variables aleatorias. Esta superposición de características, producto de efectos transicionales entre zonas de vida o ecotones (Odum 1992), resultan en la dificultad de su categorización y esto explica su menor exactitud en la clasificación. La presencia de ecotones, zonas de transición entre ecosistemas, es común en regiones de alta diversidad biológica, generando patrones de clasificación complejos (Smith 1996).

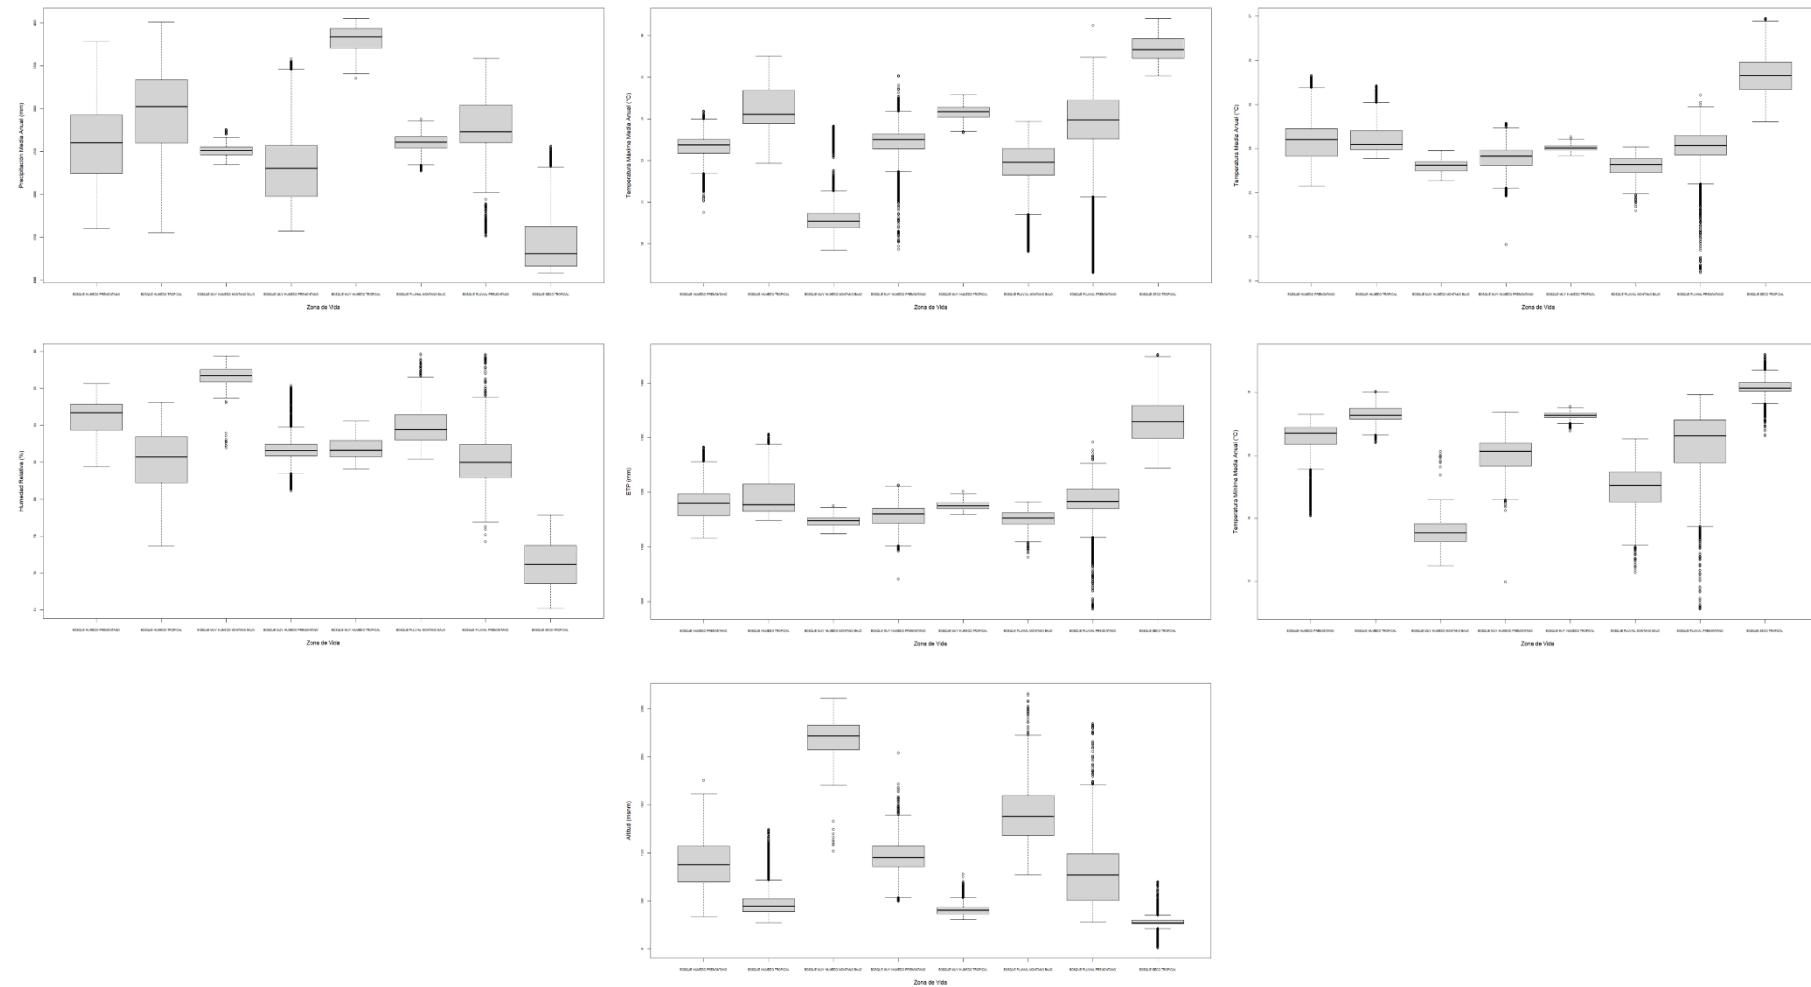


Figura 6. Box plots por zonas de vida/variable analizada

4. CONCLUSIONES Y RECOMENDACIONES

Este estudio representa un avance significativo en la comprensión del clima y la bioclimatología de la cuenca del río Caroní, proporcionando una base de datos detallada y una caracterización bioclimática esencial para la gestión integrada del paisaje, la conservación de la biodiversidad y la provisión de servicios ecosistémicos. La metodología empleada, que combina datos de fuentes globales con técnicas avanzadas como la Regresión Ponderada Geográfica (GWR) y la reducción de escala (*downscaling*), que permitió mejorar la exactitud y resolución espacial de los análisis, generando información valiosa para la toma de decisiones en la gestión de recursos naturales y la planificación territorial.

La clasificación climática supervisada de Máxima Verosimilitud (ML) demostró ser efectiva para determinar el número, distribución espacial y superficie de las diferentes zonas de vida. Sin embargo, la metodología presenta algunas limitaciones importantes que deben ser consideradas en futuros estudios. En primer lugar, al asumir un proceso estacionario en media y varianza en el espacio-tiempo, no se incluyó el análisis del cambio climático, un factor crucial que podría tener impactos significativos en la distribución y características de las zonas de vida. Para abordar esta limitación, se propone incluir momentos temporales y evaluar el comportamiento de las zonas de vida a lo largo del tiempo, incluyendo la posibilidad de migración, expansión o reducción de áreas, especialmente en aquellas zonas con mayor efecto de transición.

En segundo lugar, el clasificador consideró datos que expresan la variabilidad media anual, lo que implica una pérdida de información sobre la variabilidad intra-anual. Esta variabilidad, que incluye cambios estacionales y alteraciones en estacionalidades, es fundamental para comprender la dinámica de los sistemas bioclimáticos y su respuesta a factores como el cambio climático. Futuros estudios deberían considerar la inclusión de datos que reflejen la variabilidad temporal del clima, incluyendo cambios en medias y varianzas estacionales, para obtener una caracterización más completa y precisa de las zonas de vida.

Finalmente, el método constituye un aporte valioso para la gestión del territorio, pero es necesario avanzar hacia metodologías que incorporen la variabilidad temporal del clima y los efectos del cambio climático para una mejor comprensión de la dinámica de los ecosistemas y una toma de decisiones más informada.

Referencias bibliográficas

- Ahmad, W. & Quegan, S. (2012). *Techniques and applications of remote sensing*. CRC press. ISBN 978-14298-7250-6.
- Allen, R. G., Pereira, L. S., Raes, D. & Smith, M. *Irrigation and Drainage Paper 56*. FAO, Roma 333 pp. <http://www.climasouth.eu/sites/default/files/FAO%2056.pdf>.
- Anderson, T. W. (2003). *An introduction to multivariate statistical analysis*. John Wiley & Sons. ISBN 978-0-471-36091-9.
- Araújo, M. B., Pearson, R. G., Thuiller, W., Rahbek, C. (2005). Biogeography: climate change impacts—the need for a complete risk assessment. *Trends in Ecology & Evolution*, 20 (10), 561-569. <https://doi.org/10.1111/j.1365-2486.2005.01000.x>.
- Asmala Ahmad (2012) Analysis of Maximum Likelihood Classificationon Multispectral Data. <https://www.m-hikari.com/ams/ams-2012/ams-129-132-2012/ahmadAMS129-132-2012.pdf>.
- Barry, R. G. (2008). *Mountain weather and climate*. Cambridge University Press.
- Barry, R. G., Chorley, R. J. (2010). *Atmosphere, weather and climate*. Routledge. https://api.pageplace.de/preview/DT0400.9781135267490_A24313445/preview-9781135267490_A24313445.pdf.

- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer. <https://www.microsoft.com/en-us/research/wp-content/uploads/2006/01/Bishop-Pattern-Recognition-and-Machine-Learning-2006.pdf>.
- Chai, T. & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE): Arguments against using RMSE when comparing forecast accuracy. *Geoscientific Model Development*, 7 (3), 1247-1250. DOI:[10.5194/gmd-7-1247-2014](https://doi.org/10.5194/gmd-7-1247-2014).
- Chuvieco, E. (2002). *Análisis multivariante: métodos y aplicaciones*. Universidad Central de Venezuela.
- Chuvieco, E., Salas, J., Meza, E., Vargas, F. (2002). Empleo de la teledetección en el análisis de la deforestación tropical: el caso de la reserva forestal de Ticoporo (Venezuela). *Serie geográfica*, 10, 55-76. <http://hdl.handle.net/10017/1160>.
- Congalton, R. G. & Green, K. (2008). *Assessing the accuracy of remotely sensed data: principles and practices*. CRC press. <https://doi.org/10.1201/9781420055139>.
- Conrad, O., Bechtel, B., Bock, M., Dietrich, H., Fischer, E., Gerlitz, L., Wehberg, J., Wichmann, V., and Böhner, J. (2015): System for Automated Geoscientific Analyses (SAGA) v. 2.1.4, Geosci. Model Dev., 8, 1991-2007. doi:[10.5194/gmd-8-1991-2015](https://doi.org/10.5194/gmd-8-1991-2015).
- CVG-EDELCA (2004) Estudio Plan Maestro de la Cuenca del río Caroní. Vol. 1, Tomo 4. Cap. 2 Clasificación climática según Holdridge, pp. 1-16. Repositorio Digital CVG.
- CVG-EDELCA (2004). Estudio Plan Maestro de la Cuenca del río Caroní. Vol. 2, Tomo 3. Cap. 6 Ecología del paisaje, pp 1-124. Repositorio Digital CVG.
- Datosmacro.com (2023). *Venezuela-Generación de electricidad*. Expansión. <https://datosmacro.expansion.com/energia-y-medio-ambiente/electricidad-generacion/venezuela> [Consultado: 5 de octubre 2025].
- Derguy, M. R. (2020). *Clasificación ecológica para la República Argentina a partir del modelo de zonas de vida de Holdridge (1947, 1967): mapeo, caracterización y tendencias de cambio* (Doctoral dissertation, Universidad Nacional de La Plata). DOI:[10.35428/cds.v0i6.94](https://doi.org/10.35428/cds.v0i6.94).
- Duda, R. O., Hart, P. E., Stork, D. G. (2001). *Pattern classification*. John Wiley & Sons. https://idic.likufanele.com/~calvo/Inteligencia_Artificial_files/Duda%20R%20O,%20Hart%20P%20E,%20Stork%20D%20G_Pattern%20Classification%20%282Ed%20Wiley%29.pdf.
- Elith, J. & Leathwick, J. R., (2009). Species Distribution Models: Ecological Explanation and Prediction Across Space and Time. *Annual Review of Ecology, Evolution, and Systematic*, 40, 677-697. <https://doi.org/10.1146/annurev.ecolsys.110308.120159>.
- FAO. (1998). *Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56*. FAO. https://www.researchgate.net/publication/235704197_Crop_evapotranspiration-Guidelines_for_computing_crop_water_requirements-FAO_Irrigation_and_drainage_paper_56
- Fick, S. E. & Hijmans, R. J. (2017). WorldClim 2: new 1-km spatial resolution climate surfaces for global land areas. *International Journal of Climatology*, 37 (12), 4302-4315. <https://doi.org/10.1002/joc.5086>.
- Foody, G. M. (2002). *Remote sensing of vegetation*. CRC press. ISBN 978-0-415-27119-4.
- Foody, G. M. (2004). Exploring spatial non-stationarity in the relationship between vegetation and climate using geographically weighted regression. *Progress in Physical Geography*, 28 (2), 201-219. <https://www.sciencedirect.com/science/article/abs/pii/S0034425703001949>.
- Foody, G. M. & Cutler, M. E. J. (2006). Tree species mapping from multi-spectral and LiDAR data. *Remote Sensing of Environment*, 100 (3), 381-393. <http://doi.org/10.1016/j.rse.2005.10.012>.

- Fotheringham, S.A., Charlton, M., Brunsdon, C. (1998): Geographically weighted regression: a natural evolution of the expansion method for spatial data analysis. *Environment and Planning A* 30 (11), 19051927. <https://doi.org/10.1068/a301905>.
- Fotheringham, S.A., Brunsdon, C., Charlton, M. (2002): Geographically Weighted Regression: the analysis of spatially varying relationships. John Wiley & Sons. ISBN 978-0-471-49616-8.
- Funk, C., Peterson, P., Landsfeld, D., Pedelty, J., Aragón-Aguilar, L., Verdin, J. (2015). A quasi-global precipitation time series for drought monitoring. *US Geological Survey Data Series*, 832, 1-12. <http://pubs.usgs.gov/ds/0832/>.
- Gallant, J. C & Wilson, J. P. (2000). A grid-based approach to terrain analysis. *Photogrammetric Engineering and Remote Sensing*, 66 (6), 689-701.
- Grimmett, G. R.; Stirzaker, D. R. (1992). Probability and Random Processes, 2nd Edition. Clarendon Press, Oxford. ISBN 0-19-853665-8.
- Guisan, A. & Zimmermann, N. E. (2000). Predictive habitat distribution models in ecology. *Ecological Modelling*, 135(1-3), 147-166. [https://doi.org/10.1016/S0304-3800\(00\)00354-9](https://doi.org/10.1016/S0304-3800(00)00354-9).
- Gujarati, D. N. & Porter, D. C. (2009). *Econometría*. McGraw-Hill. ISBN 978-607-15-0299-1.
- Hamon, W. R. (1961). Estimating potential evapotranspiration. *Journal of the Hydraulics Division*, 87 (3), 107-120. <https://doi.org/10.1061/jyceaj.0000599>.
- Hastie, T., Tibshirani, R., Friedman, J. (2009). *The elements of statistical learning: data mining, inference, and prediction*. Springer Science & Business Media. ISBN 978-0-387-84857-0.
- Hernandez-Stefanoni, J. L., Ponce-Hernandez, R. (2006). Mapping the spatial variability of plant diversity in a tropical forest: comparison of spatial interpolation methods. *Environmental monitoring and assessment*, 117, 307-334. <https://doi.org/10.1007/s10661-006-0885-z>
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., ... & Dee, D. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146 (730), 1999-2049. <https://doi.org/10.1002/qj.3803>.
- Hijmans, R. (2025). *Raster: Geographic Data Analysis and Modeling*. R package version 3.6-32. <https://rspatial.org/raster>.
- Hijmans, R. J., Cameron, S. E., Parra, J. L., Jones, P. G., Jarvis, A. (2005). Very high resolution interpolated climate surfaces for global land areas. *International journal of climatology*, 25 (15), 1965-1978. <https://doi.org/10.1002/joc.1276>.
- Holdridge, L. R. (1966). *Life zone ecology*. Tropical Science Center. https://wiki.neotropicos.org/images/8/8e/LR_Holdridge_1966_life_zone_ecology.pdf.
- Huber, O. (1997). Diversidad florística de la Guayana Venezolana: un ensayo biogeográfico. *Acta Botánica Venezolana*, 20 (1), 5-40.
- Huber, O. (1995). Vegetation of the Guayana Shield. In: Steyermark, J.A., Berry, P.E., Holst, B.K. (Eds.), *Flora of the Venezuelan Guayana*. Missouri Botanical Garden Press, St. Louis, pp. 97-160.
- Huber, O. (2001). *Flora de la Gran Sabana*. Oscar Todtmann Editores.
- Hyndman, R. J. & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22 (4), 679-688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>.
- Isaaks, E., y Srivastava, R. (1989). *Applied Geostatistics*. Oxford University Press. ISBN 978-0-19-505013-4.
- Josse, C., Navarro, G., Mena, P., Balslev, H. (2009). *Ecosistemas de los Andes del Norte y Centro*. Instituto de Investigación de Recursos Biológicos Alexander von Humboldt (IAvH). ISBN 978-958-8343-16-6.

- Körner, C. (2016). *Plant adaptation to environmental change*. CABI. ISBN 978-1-78064-262-6.
- Legates, D. R. & McCabe Jr, G. J. (1999). Evaluating the use of “goodness-of-fit” measures in hydrologic and water resources model validation. *Water Resources Research*, 35 (2), 233-241. <https://doi.org/10.1029/1998wr900018>
- Li, J. & Heap, A. D. (2014). A review of spatial interpolation methods for environmental scientists. *Environmental Modelling & Software*. <https://doi.org/10.1016/j.envsoft.2013.12.008>
- Lillesand, T. M., Kiefer, R. W., Chipman, J. W. (2015). *Remote sensing and image interpretation*. John Wiley & Sons. ISBN 978-1-11891928-6.
- Lloyd, C. D. (2010). *Geographically weighted regression for the analysis of spatial data*. John Wiley & Sons. ISBN 978-0-470-74811-5.
- Lloyd, C. (2010): Spatial Data Analysis - An Introduction for GIS Users. Oxford. ISBN 978-0-19-955432-4.
- Longley, P. A., Goodchild, M. F., Maguire, D. J., Batty, M. (2015). *Geographic information science and systems*. John Wiley & Sons. ISBN 978-1-118-67695-0.
- Malhi, Y. & Wright, J. (2004). Spatial patterns and dynamics of carbon, nitrogen and water fluxes in Amazonian ecosystems. *Ecological Applications*, 14 (4), 1088-1100. <https://doi.org/10.1098/rstb.2003.1433>.
- Martínez, Z., Castillo, R., Novo, I., Díaz-Martín, D., Lizaraz, A., Gallardo, J. (2013). Situación de los recursos hídricos en Venezuela: Hacia una gestión integrada (2^a ed.). AveAgua & GWP Sudamérica. http://www.gwp.org/globalassets/global/gwp-sam_files/publicaciones/varios/situacion_recursos_hidricos_vzla.pdf.
- McCabe, G. J. & Markstrom, S. L. (2007). A monthly water-balance model driven by a graphical user interface (No. 2007-1088). US Geological Survey. <https://pubs.usgs.gov/of/2007/1088/>.
- Meier, W. & Huber, O. (2004). *El Libro Rojo de la fauna venezolana*. Provita y Fundación Polar. ISBN 978-980-6355-06-9.
- Monteith, J. L. (1965). Evaporation and environment. In *Symposia of the Society for experimental Biology* (19, 205-234). Cambridge University Press.
- Nalder, I. A. & Wein, R. W. (1998). Spatial interpolation of climatic normals: test of a new method in the Canadian boreal forest. *Agricultural and forest meteorology*, 92 (4), 211-225. [https://doi.org/10.1016/s0168-1923\(98\)00102-6](https://doi.org/10.1016/s0168-1923(98)00102-6).
- Odum, E. P. (1992). *Ecología: el puente entre la ciencia y la sociedad*. McGraw-Hill. ISBN 978-968-422-927-1.
- Oliver, M. A. & Webster, R. (2015). *Geostatistics for environmental scientists*. John Wiley & Sons. ISBN 978-1-11852219-5.
- Paez A, Farber S, Wheeler D, 2011, "A simulation-based study of geographically weighted regression as a method for investigating spatially varying relationships", *Environment and Planning A* 43 (12) 2992-3010.
- Peñuelas, J., Sabaté, S., Filella, I., Gracia, C. (2004). Efectos del cambio climático sobre los ecosistemas terrestres: observación, experimentación y simulación. *Ecología del bosque mediterráneo en un mundo cambiante*, 425-460. ISBN 978-84-00-08245-3.
- PNUD (Programa de las Naciones Unidas para el Desarrollo). (2010). *Informe sobre Desarrollo Humano 2010. La verdadera riqueza de las naciones: Camino hacia el desarrollo humano*. PNUD. [1.est.cmq.edu.mx](http://est.cmq.edu.mx).
- POWER NASA PROJECT (s. f.). *The data was obtained from the National Aeronautics and Space Administration (NASA) Langley Research Center (LaRC) Prediction Of Worldwide Energy Resources*

- (POWER). Project funded through the NASA Earth Science/Applied Science Program. <https://power.larc.nasa.gov/docs/referencing/> (consultado 28-11-2024).
- Quenouille, M.H. (1949). Problems in plane sampling. *Annals of Mathematical Statistics*, 20: 355–375.
- Rahbek, C., Borregaard, M. K., Antonelli, A., Colwell, R. K., Holt, B. G., Nogués-Bravo, D. (2019). Building mountain biodiversity. *Science*, 365 (6458), 1114-1119. [DOI: 10.1126/science.aax0151](https://doi.org/10.1126/science.aax0151).
- Ramia, M. (2000). *Tipos de vegetación de Venezuela*. Fondo Nacional de Investigaciones Agropecuarias (FONAIAP).
- Ramírez, W., Jarvis, A., Williams, C. (2010). *Clasificación climática y zonas de vida de Colombia*. Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM). ISBN 978-958-8067-99-9.
- Reichstein, M., Camps-Voutourakis, M., Stevens, B., Jung, M., Carvalhais, N., Prabhat. (2019). Deep learning predicts spatial patterns of carbon exchange from Earth observation data. *Nature communications*, 10 (1), 1-9. <https://www.nature.com/articles/s41586-019-0912-1>.
- Rice, J. A. (2007). *Mathematical statistics and data analysis*. Cengage Learning. ISBN 978-0-495-11873-2.
- Richards, J. A. & Jia, X. (2006). *Remote sensing digital image analysis*. Springer.
- Rivas-Martínez, S., Díaz, T. E., González, J. A., Cantos, F. (2011). *Mapa de los bioclimas de España*. Ministerio de Medio Ambiente y Medio Rural y Marino. ISBN 978-84-491-1138-5.
- Rivas-Martínez, S., Díaz, T. E., González, J. A., Cantos, F. (2011). *Mapa de los bioclimas de América del Sur*. Universidad de Alcalá.
- Sánchez, L., Rosales, J., Vessuri, V. (2016). *La cuenca del río Caroní: un territorio estratégico para el desarrollo de Venezuela*. En: *Agua y territorio: dimensiones socio-ambientales de la gestión hídrica en Venezuela* (pp. 123-156). Universidad Central de Venezuela. ISBN 978-980-00-2821-9.
- Sarmiento, C. (2002). Las Sábanas Tropicales de Colombia. Academia Colombiana de Ciencias Exactas, Físicas y Naturales. ISBN 978-958-9205-22-9.
- Smith, T. B. (1996). *Ecology and evolution of a neotropical migrant bird*. University of Chicago Press. ISBN 978-0-226-76387-3.
- SOS Orinoco. (2021). *La minería ilegal en la cuenca del Caroní: una amenaza para la Amazonía venezolana*. SOS Orinoco. <https://sosorinoco.org>.
- Stackhouse, P. W., Gupta, S. K., Cox, S. J., Wielicki, B. A. (2018). The NASA Langley Parameterized and Gridded Surface Radiation Budget (PGSRB) project: Description and a comparison with other data sets. *Atmospheric Measurement Techniques*, 11 (5), 2595-2615. <https://power.larc.nasa.gov/docs/referencing/>
- Thornthwaite, C. W. (1948). An approach toward a rational classification of climate. *Geographical review*, 38 (1), 55-94. <https://doi.org/10.2307/210739>.
- Thuiller, W., Lavorel, S., Araújo, M. B., Sykes, M. T., Prentice, I. C. (2005). Climate change threats to plant diversity in Europe. *Proceedings of the National Academy of Sciences*, 102 (23), 8245-8250. <https://journals.bilpubgroup.com>.
- Trewartha, G. T. & Horn, L. H. (1980). *Clima y tiempo*. Editorial Vicens Vives. ISBN 978-84-316-1234-5.
- Vicente-Serrano, S. M., Saz-Sánchez, M. A., Cuadrat, J. M. (2003). Comparative analysis of interpolation methods in the middle Ebro Valley (Spain): application to annual precipitation and temperature. *Climate research*, 24 (2), 161-180. <https://doi.org/10.3354/cr024161>.
- Virla, M. Q. & Pirela, K. I. (2012). *Análisis multivariado*. Maracaibo, Venezuela: Fondo Editorial de la Facultad de Ciencias Económicas y Sociales de la Universidad del Zulia. ISBN 978-980-232-123-4.

- Virla, M. Q., Pirela, K. I. (2012). Clasificación de las Técnicas Estadísticas Multivariantes. *Telos*, 14 (2), 275-286. <https://www.redalyc.org/pdf/993/99323311009.pdf>.
- Walter, H., Breckle, S. W. (2002). *Walter's vegetation of the earth: the ecological systems of the geo-biosphere*. Springer. ISBN 978-3-540-43315-6.
- Walter, H. & Lieth, H. (1967). *Klimadiagramm-Weltatlas*. Gustav Fischer Verlag.
- Wilcoxon, F. (1949). Some rapid approximate statistical procedures. *American Cyanamid Co.*
- Willmott, C. J. (1982). Some comments on the evaluation of model performance. *Bulletin of the American Meteorological Society*, 63 (11), 1309-1313. [https://doi.org/10.1175/1520-0477\(1982\)063<1309:SCOTEO>2.0.CO;2](https://doi.org/10.1175/1520-0477(1982)063<1309:SCOTEO>2.0.CO;2).
- Willmott, C. J., Matsuura, K. (2006). On the use of dimensioned measures of error to evaluate the performance of spatial interpolators. *International Journal of Geographical Information Science*, 20 (1), 89-102. <https://doi.org/10.1080/13658810500286976>.
- Whitmore TC (1998). *An introduction to tropical rain forests*. Oxford University Press. ISBN 978-0-19-850147-3.
- Zhang, D., Ren, N., and Hou, X. (2018): An improved logistic regression model based on a spatially weighted technique (ILRBSWT v1.0) and its application to mineral prospectivity mapping. *Geosci. Model Dev.*, 11, 2525-2539. <https://doi.org/10.5194/gmd-11-2525-2018>.

