

Análisis de la Cobertura y Uso de Suelo de la Cuenca Baja del Río Usumacinta Mediante Técnicas de Teledetección Analysis of Land Cover and Land Use in the Lower Usumacinta River Basin Using Remote Sensing Techniques

Héctor Javier Megia-Vera^{1,2} , Candelario Peralta-Carreta¹ ,
Ojilve Medrano-Pérez³ , Miguel Ángel Palomeque-De la Cruz¹ ,
Rodimiro Ramos-Reyes^{4,5†}  y Adalberto Galindo-Alcantara¹ 

¹ Universidad Juárez Autónoma de Tabasco, División Académica de Ciencias Biológicas. Carretera Villahermosa-Cárdenas km 0.5 s/n, entronque a Bosques de Saloya. 86150 Villahermosa, Tabasco, México; (H.J.M.V.), (C.P.C.), (M.A.P.C.), (A.G.A.).

² Tecnológico Nacional de México, Instituto Tecnológico Superior de Villa La Venta. Circuito Tecnológico No. 1, Colonia El Cuatro. 86410 Huimanguillo, Tabasco, México; (H.J.M.V.).

³ SECITI-Tecnológico Nacional de México, Instituto Tecnológico Superior de Misantla (ITSM). Carretera a Loma del Cojolite km 1.8, Col. Las Rosas. 93850 Misantla, Veracruz, México; (O.M.P.).

⁴ Universidad Popular de la Chontalpa. Carretera Cárdenas-Huimanguillo km 2, Col. Cañales. 86500, Cárdenas, Tabasco, México; (R.R.R.).

⁵ El Colegio de la Frontera Sur Unidad Villahermosa. Carretera a Reforma km 15.5 s/n. Guineo 2da. Sección, Centro. 86280 Villahermosa, Tabasco, México; (R.R.R.).

† Autor para correspondencia: rramos@ecosur.mx

RESUMEN

Los impulsores del cambio de uso del suelo a diversas escalas ponen en riesgo la estabilidad de los ecosistemas tropicales, que afecta tanto a la biodiversidad como a los servicios ecosistémicos esenciales. Estos cambios son particularmente críticos en áreas como la Cuenca Baja del Río Usumacinta (CBRU), una región de valor ecológico y cultural. En este contexto, el presente estudio tiene como objetivo clasificar las coberturas y usos del suelo (CUS) de la CBRU utilizando imágenes satelitales Landsat 8 OLI. Se emplearon dos métodos de clasificación: el algoritmo ISODATA para clasificación no supervisada (CNS) y el algoritmo de Máxima Verosimilitud (MLC) para clasificación supervisada (CS). La clasificación no supervisada agrupó los píxeles basándose en la distancia espectral, identificando cuatro clases generales: humedales, actividades antropogénicas, vegetación arbórea y cuerpos de agua, con una precisión moderada del 67% y un índice kappa de 0.51. Por su parte, la clasificación supervisada, utilizando 948 puntos de entrenamiento y datos auxiliares derivados del Índice de Vegetación de Diferencia Normalizada (NDVI) y el Modelo Digital de Elevación (DEM), proporcionó un mapeo más detallado, discriminando clases específicas como agricultura (41.46%), humedales (21.17%), plantaciones forestales comerciales (4.09%) y áreas urbanas (0.56%), logrando un índice kappa de 0.90, validado mediante 330 puntos de control terrestre. Los resultados muestran que la integración de los datos NDVI y DEM mejoró significativamente la discriminación espectral de la cobertura forestal tropical y los humedales, mientras que la clasificación no supervisada mostró limitaciones para diferenciar clases específicas como los bosques tropicales, bosques inundados y plantaciones de palma de aceite. Los resultados destacan la importancia de utilizar imágenes satelitales actualizadas, junto con datos auxiliares y algoritmos robustos para lograr una clasificación más precisa de las CUS, fundamental para la planificación territorial, el manejo de recursos naturales y la conservación de la biodiversidad en la CBRU.

Palabras clave: clasificación, índice de vegetación normalizada, índice espectral, modelo de elevación digital, recursos naturales.

SUMMARY

The drivers of land use change at various scales pose a threat to the stability of tropical ecosystems, affecting both biodiversity and essential ecosystem services. These changes are particularly critical in areas such as the Lower Usumacinta River



Cita recomendada:

Megia-Vera, H. J., Peralta-Carreta, C., Medrano-Pérez, O., Palomeque-De la Cruz, M. A., Ramos-Reyes, R., & Galindo-Alcantara, A. (2025). Análisis de la Cobertura y Uso de Suelo de la Cuenca Baja del Río Usumacinta Mediante Técnicas de Teledetección. *Terra Latinoamericana*, 43, 1-15. e2075. <https://doi.org/10.28940/terra.v43i.2075>

Recibido: 30 de agosto de 2024.

Aceptado: 18 de noviembre de 2024.

Artículo. Volumen 43.

Abril de 2025.

Editor de Sección:

Dr. Antonio Juárez Maldonado

Editor Técnico:

Dr. Gerardo Cruz Flores



Copyright: © 2025 by the authors.

Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY NC ND) License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).

Basin (LURB), a region of ecological and cultural value. In this context, our study aims to classify land cover and land use (LCLU) in the LURB using Landsat 8 OLI satellite imagery. Two classification methods were employed: the ISODATA algorithm for unsupervised classification (USC) and the Maximum Likelihood Classification (MLC) algorithm for supervised classification (SC). The unsupervised classification grouped the pixels based on spectral distance, identifying four general classes: wetlands, anthropogenic activities, tree vegetation, and water bodies, with a moderate accuracy of 67% and a kappa index of 0.51. In contrast, the supervised classification, using 948 training points and auxiliary data derived from the Normalized Difference Vegetation Index (NDVI) and the Digital Elevation Model (DEM), provided more detailed mapping, discriminating specific classes such as agriculture (41.46%), wetlands (21.17%), commercial forest plantations (4.09%), and urban areas (0.56%), achieving a kappa index of 0.90, validated with 330 ground control points. Our results show that the integration of NDVI and DEM data significantly improved spectral discrimination of tropical forest cover and wetlands, while the unsupervised classification exhibited limitations in differentiating specific classes such as tropical forests, flooded forests, and oil palm plantations. Our findings highlight the importance of using up-to-date satellite imagery, along with auxiliary data and robust algorithms, to achieve more accurate LCLU classification, which is essential for land planning, natural resource management, and biodiversity conservation in the LURB.

Index words: *classification, normalized difference vegetation index, spectral index, digital elevation model, natural resources.*

INTRODUCCIÓN

El uso del suelo es el resultado de las actividades socioeconómicas dirigidas a la apropiación del capital natural y la generación de bienes y servicios sobre una cobertura vegetal (Pineda-Pastrana, 2011¹). Sin embargo, estas actividades están modificando constantemente los patrones de Cobertura y Usos del Suelo (CUS) a diferentes escalas, siendo un importante impulsor del cambio climático global (Zhang *et al.*, 2024), y un motivo de preocupación debido a su impacto en el régimen hidrológico (Garg *et al.*, 2017). La cobertura vegetal puede emplearse como un indicador de los procesos biofísicos, permitiendo así determinar el grado de conservación de los ecosistemas naturales. Por lo tanto, la identificación de la cobertura es fundamental para monitorear la dinámica interna del territorio, lo que a su vez es clave para evaluar el impacto de las políticas ambientales, la toma de decisiones y el desarrollo de sistemas de alerta temprana para prevenir problemas como la desertificación (Reynolds *et al.*, 2007; Saco *et al.*, 2018; Gaitán *et al.*, 2021).

En la actualidad, la teledetección se ha convertido en una herramienta esencial para la clasificación y monitoreo eficiente de los cambios en la CUS (Rwanga y Ndambuki, 2017; Zhang, Wang, Hao, Zhang y Hu, 2017). Esto se debe a diversos factores, como la disponibilidad de conjuntos de datos más amplios y técnicas mejoradas que han optimizado los resultados de clasificación, tanto en términos de discriminación de la CUS como de precisión de las categorías obtenidas durante el procesamiento de datos (Eiumnoh y Shrestha, 2000; Yasin y Kornel, 2024; Din *et al.*, 2022). Los algoritmos de procesamiento también han incrementado el uso de imágenes satelitales (i.e., Landsat, Sentinel, etc.) en estudios relacionados con los cambios de CUS a múltiples escalas (Bunyangha, Majaliwa, Muthumbi, Gichuki y Egeru, 2021; Nay, Burchfield y Gilligan, 2017; Aplin y Atkinson, 2004). Así, la teledetección ha desempeñado un papel crucial en el mapeo y análisis de los cambios reales en la CUS a escala regional y global (Garg *et al.*, 2017; Olokeogun, Iyiola e Iyiola, 2014).

A nivel mundial, diversos estudios han abordado la dinámica de la CUS. Por ejemplo, Zhang *et al.* (2024) utilizaron la serie temporal completa de Landsat (1982-2022) a través de la plataforma Google Earth Engine (GEE) para analizar la dinámica de cambio en las áreas de cobertura del suelo a nivel global, destacando su relevancia para el desarrollo sostenible y la toma de decisiones. En México, Bonilla-Moheno y Aide (2020) evaluaron los cambios en el uso del suelo entre 2001 y 2014 utilizando imágenes MODIS, mientras que Revuelta-Acosta, Garrido, Escobedo y Alcalá (2023), analizaron los cambios de CUS en Coatzacoalcos, Veracruz, entre 2015 y 2021 usando imágenes Landsat 8. Estos estudios demuestran la aplicabilidad de la teledetección para monitorear cambios en la cobertura del suelo a distintas escalas temporales y geográficas y, su relevancia para la gestión sostenible del territorio.

¹ Pineda-Pastrana, O. (2011). *Análisis de cambio de uso de suelo mediante percepción remota en el municipio de Valle de Santiago*. Tesis para obtener el grado de Maestría en Geomática. Centro de Investigación en Geografía y Geomática Ing. Jorge L. Tamayo, A. C., México, DF, México. Disponible en: https://www.academia.edu/download/56867017/ANALISIS_DE_CAMBIO_DE_USO_DE_SUELO_MEDIANTE_PERCEPCION_REMOTA.pdf

Sin embargo, en la Cuenca Baja del Río Usumacinta (CBRU), a pesar de su importancia ecológica y cultural, no existe suficiente información actualizada sobre la dinámica de las CUS. Esta región, caracterizada por su rica biodiversidad y recursos hídricos, ha sido objeto de cambios ambientales significativos, como lo indican estudios previos (Gallardo-Cruz, de Oca y Rives, 2019; Peralta-Carreta, Gallardo, Solórzano y Hernández, 2019; Vaca et al., 2019). Ante la falta de datos recientes sobre las CUS en la CBRU, el presente estudio tiene como objetivo evaluar la clasificación de las Coberturas y Usos de Suelo (CUS) de la Cuenca Baja del Río Usumacinta (CBRU) para el año 2021 utilizando imágenes de Landsat 8 OLI. Para ello, se aplicarán dos algoritmos de clasificación: uno paramétrico (*Maximum Likelihood Classification, MLC*) y otro no paramétrico (*ISODATA, Iterative Self-Organizing Data Analysis Techniques*), con el fin de obtener un mapa detallado y preciso de las CUS en esta importante región.

MATERIALES Y MÉTODOS

Área de Estudio

La cuenca transfronteriza del río Usumacinta comprende una superficie de 772 65 km², alberga el río más largo y caudaloso de Mesoamérica, con 1100 km de longitud (Kauffer, 2021) y 1700 m³ s⁻¹ de caudal (Mifsut y Castro, 2010). Esta cuenca pertenece a un territorio hídrico compartido por las fronteras administrativas de México, Guatemala y Belice. El río Usumacinta corre en la cuenca alta y media de Guatemala hasta llegar a la Cuenca Baja del Río Usumacinta (CBRU). El área de estudio de este trabajo comprende solo la porción mexicana con una superficie de 14 291.75 km², distribuidas entre los estados de Chiapas (14.3%), Campeche (30.8%) y Tabasco (54.9%) antes de desembocar en el Golfo de México como se muestra en la Figura 1, Gallardo-Cruz et al. (2021). El área de estudio utilizada, fue delimitada en el estudio realizado por Gallardo-Cruz et al., (2019) quienes para ello, se basaron en criterios topográficos, cartográficos y geomorfológicos.




Figura 1. A) Ubicación espacial de la región de estudio. B) Cuenca alta, media y baja del Usumacinta C) Cuenca Baja del Usumacinta.
Figure 1. A) Spatial location of the study site. B) Upper, middle and lower Usumacinta basin. C) Lower Usumacinta basin.

El cauce principal en la CBRU posee una elevación promedio de 50 m de altitud y su fisiografía se compone de las Llanuras Costera del Golfo Sur (95.67%) y Sierra de Chiapas y Guatemala (2.02%), (INEGI, 2001). El clima se clasifica como Af (m) w'(i) g (García, 1988), correspondiente a un clima cálido húmedo con altas temperaturas (26.9 °C) y precipitaciones (2274 mm) durante todo el año, donde el mes de mayo es el más cálido (35.5 °C), enero es el más frío (18.6 °C) y la temporada de lluvia se presenta durante los meses de junio a noviembre, siendo septiembre el más lluvioso con 351.2 mm (CONAGUA, 2023). Respecto a la edafología (Palma-López, Cisneros, Moreno y Rincón, 2007; Castillo-Cruz y Medrano-Pérez, 2023) reportan que los suelos predominantes en la CBRU son Acrisols (3.25%), Arenosols (4.22%), Cambisols (2.42%), Cuerpo de agua 7.13%, Ferralsols (2.32%), Fluvisols (10.48%), Gleysols (19.97%), Histosols (4.51%), Leptosols (12.64%), Luvisols (13.11%), Solonchaks (2.64%) y Vertisols (17.31%).

Estas características influyen en la diversidad de especies de la CBRU, donde la vegetación es heterogénea, predominado los pastizales cultivados, agricultura de temporal, pesca y entre las actividades económicas, la industria petrolera y agroindustria. Además, existen ecosistemas representativos del bosque tropical perennifolio, humedales, manglares y bosque sub-perennifolio (Rzedowsky, 2006), dónde se encuentran, la Reserva de la Biosfera Pantanos de Centla y el Área de Protección de Flora y Fauna, Cañón del Usumacinta y el Área Natural Protegida de Laguna de Términos que albergan una población de 201 548 habitantes distribuida en 1185 localidades (SERNAPAM, 2013).

El enfoque metodológico utilizado en esta investigación se dividió en las siguientes fases: (i) recopilación de datos de imágenes de satélite y vectorial; (ii) procesamiento de datos a través del algoritmo para la clasificación no supervisada (ISODATA) y para la clasificación supervisada por el método de Máxima Verosimilitud (MLC, por sus siglas en inglés); y (iii) evaluación de la precisión de las clasificaciones. El flujo general metodológico del tratamiento de datos se ilustra en la Figura 2, posteriormente se describen a detalle los pasos seguidos en las diferentes secciones.

Base de Datos

Se utilizaron datos ráster del Modelo digital de elevación (DEM, por sus siglas en inglés) con resolución de 50 × 50 m (INEGI, 2012), datos vectoriales de la cartografía *shapefiles* de Uso del suelo y vegetación, escala 1:250000, Serie VII nacional (INEGI, 2013), como referencia para identificar los tipos de coberturas y usos del suelo. Además, para evitar el error de temporalidad, se utilizaron imágenes multispectrales de la nube de Google Earth Engine (2022). registradas por los sensores *LandSat 8 Operational Land Imager (OLI) + Thermal Infrared Sensor (TIRS)* de una resolución de píxel de 30 metros para la CBRU. La consulta se realizó mediante el análisis de las colecciones de imágenes de mayor calidad (Tier 1), y para mitigar la limitación que surge debido a la nubosidad (Tziolas *et al.*, 2020), se aplicó el criterio de selección de nubes (<10%) y para obtener la imagen compuesta a partir de los promedios mensuales del año 2021 se utilizó una imagen por mes.




Figura 2. Diagrama de flujo del análisis de coberturas y usos del suelo de la CBRU.
Figure 2. CBRU land cover and land use analysis flow chart.

Preprocesamiento

Posteriormente se llevó a cabo el preprocesamiento de imágenes de satélite en el software ArcMap v. 10.8 (ESRI, 2011) (Figura 2). Para el análisis de las firmas espectrales se realizaron combinaciones de bandas B6-B5-B2 que corresponden al (uso agrícola); B4-B3-B2 (color natural); B6-B5-B2 (vegetación vigorosa) y B5-B4-B3 (color verdadero). Además, se realizó la revisión de literatura para identificar los grupos de coberturas y usos de suelo representativos de la CBRU (Meave *et al.*, 2022) Cuadro 1.

Selección de Algoritmos

Dada su robustez y amplio uso en la teledetección, fueron seleccionados los algoritmos *Maximum Likelihood Classification (MLC)* e *Iterative Self-Organizing Data Analysis Techniques (ISODATA)* para la clasificación de la cobertura y usos del suelo (CUS) en la Cuenca Baja del Río Usumacinta (CBRU), (Gallardo-Cruz *et al.*, 2019; Makandar y Kaman, 2021; Ramírez-García *et al.*, 2022). El algoritmo MLC es un método paramétrico bien establecido que considera la variabilidad espectral entre clases, además permite incorporar información complementaria (puntos de entrenamiento) Yasin y Kornel (2024), lo cual mejora la precisión de la clasificación supervisada. De acuerdo con (Wu y Murray, 2003; Shalaby y Tateishi, 2007) el algoritmo no paramétrico ISODATA, no requiere conocimiento previo de las firmas espectrales permitiendo un ajuste automático según el número de clasificación y número de clases de manera iterativa y eficiente. Ambos algoritmos superan a otros métodos (*i. e.*: K-Means, Mínima Distancia o Paralelepípedo) en términos de precisión y manejo de valores atípicos. Existen técnicas avanzadas (*i. e.*: Random Forest, Redes Neuronales y Máquinas de Vectores de Soporte) que ofrecen resultados más precisos, pero demandan una mayor cantidad insumos y de datos de entrenamiento para un ajuste más complejo de hiperparámetros, lo cual representa un desafío en el contexto de la CBRU donde los recursos y datos de referencia pueden ser limitados (Guzmán, Bezada y Rodríguez, 2023; Rodríguez-Valero y Alonso-Sarria, 2022; Fernández-Fierro, Rosero, Beltrán y Echeverría, 2020).

Clasificación no Supervisada

La clasificación no supervisada (CNS) se presenta como un primer acercamiento del conocimiento de un territorio permitiendo describir variaciones y patrones de cambio en el paisaje (Cotler, Garrido, Bunge y Cuevas 2010; Zhao *et al.*, 2012; Trujillo *et al.*, 2022), lo que resulta fundamental para la planificación a mediano y largo plazo del territorio a través del ordenamiento territorial y planes de conservación (Mulatu, Hundera y Senbeta 2024).

El algoritmo ISODATA (Iterative Self-Organizing Data Analysis Techniques), que considera la distancia espectral mínima para la agrupación de conglomerados en función a la distancia euclidiana (ecuación 1), y no requiere conocimientos previos del área de estudio (Lemenkova, 2021a).

$$SD_{xyc} = \sqrt{\sum_i^n 1(\mu_{ci} - X_{xyi})} \quad (1)$$

Donde: n = número de bandas; i = número de banda; c = clases específica; X_{xyi} = valor del archivo de datos del píxel X, y en banda i ; μ_{ci} = media de los valores del archivo de datos (números digitales); en i para la muestra de clase c ; SD_{xyc} = Distancia espectral de los píxeles x, y , el valor medio de la clase c .

Cuadro 1. Grupos de coberturas y uso de suelos considerados en la clasificación no supervisada.
Table 1. Land cover and land use groups considered in the unsupervised classification.

Grupo	Subgrupo
Humedales (Hum)	Vegetación hidrofita, popal
Actividades antropogénicas	Agricultura, pastizal, urbano
Vegetación arbórea	Vegetación secundaria
Cuerpo de agua	río, lago

Para esta clasificación se adoptó un mínimo de cuatro y un máximo de ocho clases permitiendo realizar una clasificación completa y su validación del índice kappa (Reynoso-Santos, Valdez, Escalona y de los Santos, 2015). Los parámetros asignados para cada mapa de clasificación se mantuvieron iguales, incluido el número máximo de 4 grupos propuestos en el cuadro 1 (Lemenkova, 2021b).

Una de las ventajas de la CNS es su rapidez en el procesamiento de datos. Rullán-Silva, Gama, Galindo y Olthoff (2011), clasificaron las coberturas de suelo de la región Sierra de Tabasco mediante una CNS e imágenes LandSat ETM+, que requieren bajos insumos técnicos y económicos (Vimala, Marimuthu, Venkateswaran y Poongodi, 2020). Con el objetivo de optimizar recursos, Ma *et al.*, (2020) utilizaron la CNS para la clasificación de cultivos, considerándola una herramienta útil para el monitoreo, diagnóstico e incidencia en la ejecución de políticas públicas o planes de desarrollo en la gestión del territorio.

Posprocesamiento

Las clases grupos formados se reagruparon con la técnica de agrupamiento jerárquico de Ward, que está diseñado para optimizar la varianza mínima en los grupos (Ward, 1963; Krishna-Bahadur, 2012). Esta técnica calcula las medias para cada variable dentro de cada grupo y la distancia euclidiana al cuadrado de las medias del grupo para cada caso (Langford y Bell, 1997). Las distancias se suman para todos los casos y en cada paso, los dos grupos que se fusionan son aquellos que dan como resultado el menor aumento en la suma general de las distancias al cuadrado dentro del grupo. Las clases resultantes se identificaron sobre la base del conocimiento extraído de la revisión de literatura, del análisis de la Serie VII de INEGI y procesos en Google Earth (Ramírez-García *et al.*, 2022).

Clasificación Supervisada

La clasificación supervisada (CS) utilizando el algoritmo de Máxima Verosimilitud (MLC), por sus siglas en inglés) es el método más utilizado entre los enfoques de clasificación paramétrica (Maselli, Conese, Petkov y Resti, 1992; Sisodia, Tiwari y Tiwari, 2014). Esta metodología supone que los datos se distribuyen de acuerdo al modelo de probabilidad predefinido y los parámetros de esta distribución dependen de los datos de entrada de los sitios de entrenamiento (Ahmad y Quegan, 2012). Para ayudar al MLC a discriminar la densidad y verdor de la vegetación expresada numéricamente entre -1 y 1, se calculó el Índice de Vegetación de Diferencia Normalizada (NDVI, por sus siglas en inglés) con la ecuación 2 (Zhang *et al.*, 2006), además y se utilizó el DEM (Eiumnoh y Shrestha, 2000, Kassahun, Hundera y Senbeta, 2024) y evitar la confusión del valor espectral del bosque tropical y plantaciones forestales comerciales (Wang y Yao, 2024).

$$NDVI = \frac{\text{Infrarrojo Cercano (NIR)} - \text{Rojo (Red)}}{\text{Infrarrojo Cercano (NIR)} + \text{Rojo (Red)}} \quad (2)$$

Después de obtener una clasificación adecuada de una discriminación satisfactoria entre las clases durante la evaluación de precisión, se realizó la clasificación final para producir un mapa de coberturas y uso de suelo 2021.

Según Palaniswami, Upadhyay y Maheswarappa (2006), la combinación de NDVI, DEM, número de puntos de entrenamiento y extracción del valor de firmas garantiza una buena clasificación de imágenes y facilita la discriminación de firmas espectrales (Bendib y Boutrid, 2024; Eiumnoh y Shrestha, 2000), aumentando la precisión de la clasificación entre 10 y 20 por ciento.

Los índices espectrales se utilizan para mejorar la detección de la presencia o ausencia de cobertura vegetal, generando relaciones con las bandas normalizadas (Mohammed, Ghazi y Mustafa, 2013). El índice de vegetación normalizada (NDVI) es un indicador de la cobertura vegetal a gran escala y de la productividad (Sun y Quin, 2016), que refleja la salud de la vegetación en función de cómo las plantas reflejan rangos específicos del espectro electromagnético. A través de la teledetección, los SIG y el uso del NDVI (Peters *et al.*, 2002, Makandar y Kaman, 2021, Nay *et al.*, 2017) mejoraron significativamente la precisión de la clasificación de coberturas vegetales obtenidas para la CBRU.

Esta clasificación se caracteriza por extraer información espectral de los píxeles de la imagen satelital, siendo el algoritmo más utilizado el de máxima verosimilitud (Richards y Jia, 2006; Ahmad y Quegan, 2012; Yang *et al.*, 2020; Richards, 2022). Este algoritmo utiliza datos de entrenamiento a través de estimaciones de varianza media

de las clases y matrices de covarianza (Perumal y Bhaskaran, 2010). Los resultados de precisión alcanzados para la CBRU superan los obtenidos por Padilla-Romero y Hernández-Juárez (2023) y Jiménez, Vilchez, González y Flores (2018) en estudios sobre cambios de uso de suelo en el Estado de México y en la zona metropolitana de Tepic, Nayarit, respectivamente.

Evaluación

Los resultados de cada mapa de clasificación se compararon por separado con la matriz de confusión y precisión general (ERDAS, 1999). Finalmente, se seleccionó el mapa de clasificación que mostró resultados aproximados o superiores al índice kappa, como técnica multivariada discreta en la evaluación de la precisión temática, que utiliza todos los elementos de la matriz de confusión durante la CNS (Cohen, 1960; ecuación 3).

$$K = \frac{N \sum_{i=1}^r X_{ij} - \sum_{i=1}^r X_{i+} X_{+i}}{N^2 - \sum_{i=1}^r X_{i+} X_{+i}} \quad (3)$$

Donde: K = índice kappa; N = Número de datos muestreados; X_{ij} = Número de observaciones; $X_{i+} X_{+i}$ = Concordancia esperada.

Para evaluar el índice kappa se utilizaron los criterios de Landis y Koch (1977), donde los valores menores a 0.4 representan una concordancia pobre; valores entre 0.4 y 0.8 una concordancia moderada; y, valores mayores a 0.8 una concordancia fuerte (Guzmán, Bezada y Rodríguez, 2023).

La precisión del mapa de CUS 2021 se evaluó utilizando la metodología de Congalton y Green (2019) a través de muestreo en campo. Se establecieron 948 puntos de control y 330 puntos de verificación de forma aleatoria, las coordenadas geográficas (UTM, Zona 15N, datum WGS84), se almacenaron en un GPS Trimble Geo 7X[®]; considerando los criterios de accesibilidad (propiedad privada o ejidal) y distancia de la carretera al punto de muestreo por cada categoría, describiendo los tipos de coberturas y usos observado de acuerdo con Meave et al. (2022) (Cuadro 2).

Cuadro 2. Tipos de coberturas y usos del suelo.
Table 2. Types of land cover and land uses.

Grupo	Clave	Coberturas y usos de suelo	Descripción
Actividades antropogénicas	PF	Plantaciones forestales	Plantaciones forestales de caoba, teca, melina y hule
	PA	Palma de aceite	Establecimiento de palma de aceite
	AGP	Agropecuario	Sistemas de agropecuario, pastizal cultivado, cultivos agrícolas, ganadería intensiva
	URB	Urbano	Asentamientos humanos e Infraestructura carretera, ejidos, ciudades
Cuerpo de agua	CA	Cuerpo de agua	Sistemas estuarios, lagunas costeras, canales, cauces de ríos, excluyendo el Océano Pacífico y estanques de actividad acuícola
Humedales	HUM	Humedales	Pueden presentarse con o sin vegetación (vegetación hidrófila en asociación con la especie de <i>Quercus oleoides</i> , <i>Thali geniculata</i> , <i>typha latifolia</i> , <i>Haematoxylum campechianum</i>)
Vegetación arbórea	BI	Bosque inundado	Asociaciones de hidrófilas dominadas por especies de manglar (<i>Laguncularia racemosa</i> , <i>Rhizophora mangle</i> , <i>Avicennia germinans</i> , <i>Pachira aquatica</i>).
	BT	Bosque tropical	Vegetación secundaria de selva baja y mediana subcaducifolia, asociaciones de arbustos y vegetación perturbada.

Adaptado de Meave et al. 2022 y Ramírez-García et al. 2022.
Adapted from Meave et al., 2022 and Ramírez-García, et al., 2022.

La precisión de la clasificación se evaluó mediante una matriz de confusión, que permitió confrontar la información de los sitios de muestreo y la imagen clasificada (García-Mora y Mas, 2008) e identificar diferentes clases de cobertura, tales como agropecuario, bosque inundado, bosque tropical, cuerpos de agua, humedal, palma de aceite, plantaciones forestales y urbano.

RESULTADOS Y DISCUSIÓN

La clasificación de las imágenes satelitales de la cuenca baja del río Usumacinta se realizó utilizando dos metodologías diferentes: clasificación no supervisada (CNS) y clasificación supervisada (CS). A continuación, se presentan los resultados de cada método.

Clasificación no supervisada de la CBRU

Mediante la aplicación del algoritmo de clasificación ISODATA, de CNS se identificaron los patrones iniciales de la cobertura del suelo basados en la agrupación de píxeles similares, permitiendo así una primera aproximación a la distribución de los diferentes tipos de cobertura de la CBRU. Las clases de cobertura identificadas fueron: Cuerpos de Agua, Humedales, Vegetación arbórea y Actividades antropogénicas (Cuadro 2).

En la Figura 3 se muestra la distribución de estas clases, observándose que el 55% está ocupado por actividades antropogénicas, seguido por el 16% de los humedales, los cuales se distribuyen principalmente en la parte norte de la cuenca, mezclándose con zonas de vegetación arbórea que se encuentran de norte a sur de




Figura 3. Distribución de las clases de cobertura de suelo, mediante la clasificación no supervisada en la CBRU 2021.

Figure 3. Distribution of land cover classes by unsupervised classification in the 2021 CBRU.

la zona de estudio y ocupan el 21% del territorio, seguido del 8% de cuerpos de agua. El uso de algoritmos de clasificación basados en las características espectrales, como el ISODATA, ha demostrado ser altamente efectivos en la identificación de coberturas de suelo (Yuan *et al.*, 2019; Dai, Zhou, Ning, Xu, y Wang, 2024). De acuerdo con Abbas, Minallh, Ahmad, Abid, y Khan, (2016) tanto el ISODATA y K-means son capaces de agrupar píxeles con características similares para discriminar diferentes clases de cobertura de suelo.

Este método de CNS obtuvo un bajo porcentaje de precisión (67%), quedando por debajo de los valores de referencia sugeridos por Chuvieco (2022) (80%). En este sentido, la baja precisión de esta clasificación (67% de precisión y un índice kappa de 0.51), se puede atribuir a la heterogeneidad tropical del área (Gallardo *et al.*, 2019; Meave *et al.*, 2022) y la fragmentación de la CBRU (Tudela, 1989).

Clasificación supervisada de la CBRU

En la Figura 4 se muestra la distribución de las clases de cobertura, destacando la clase agropecuaria con el 41.46% de la superficie, que representa zonas de agricultura y ganadería.

Los humedales ocupan el 21.17% de la superficie y son principalmente zonas de vegetación herbácea (Figura 5). Los bosques inundados se localizan principalmente en los municipios de Centla, E. Zapata, y Jonuta, Tabasco representando el 13.15% y están compuestos por especies arbóreas como el mangle. El bosque tropical ocupa el 10.76% de la superficie de la cuenca y se caracteriza por la presencia de árboles de tinto. Hacia la zona oeste, en los municipios de Balancán y Emiliano Zapata, se distribuyen principalmente las plantaciones forestales, que ocupan el 4.09% de la zona de estudio.




Figura 4. Distribución de las clases de cobertura de suelo a partir de la Clasificación supervisada en la CBRU 2021.
Figure 4. Distribution of land cover classes based on the supervised classification in the 2021 CBRU.




Figura 5. Representación de la vegetación y usos de la CBRU 2021: a) Humedales, b) Palma de Aceite, c) Agropecuario, d) Plantaciones forestales, f) Bosque tropical e) cuerpos de agua.
Figure 5. Representation of vegetation and uses of the 2021 CBRU: a) Wetlands, b) Oil palm, c) Agriculture and livestock, d) Forest plantations, f) Tropical forest, e) Water bodies.

De acuerdo con Camacho-Valdez, Rodiles, Navarrete y Valencia (2022) en los últimos años el cultivo de Palma de Aceite ha incrementado en la zona baja del Usumacinta (0.96%); la CS estimó el 2.34% de la CBRU de este cultivo respecto a la CNS que no permitió identificarlo (Cuadro 3). Estos datos coinciden con Ramírez-García *et al.*, (2022) quienes determinaron que el uso agropecuario se ha incrementado de un 14% a un 61% en un periodo de 72 años, siendo la clase predominante en la CBRU.

Por otro lado, la CS mostró una alta precisión del 92%, con un índice kappa de 0.90, superior a lo obtenido por Duan *et al.* (2024) en el estudio de clasificación de imágenes multispectrales, al utilizar datos auxiliares, se logró una precisión superior al 80% en todas las categorías identificadas: agropecuario (95%), bosque inundado (90%), bosque tropical perennifolio (88%), cuerpos de agua (92%), humedales (92%), palma de aceite (94%), plantaciones forestales comerciales (93%) y urbano (95%). Estos resultados son consistentes con los reportados por Yacouba, Guangdao y Xingping (2009); Sahebjalal y Dashtekian (2013).

Cuadro 3. Distribución de CUS 2021 de la CBRU.
Table 3. Distribution of 2021 CUS of the CBRU.

Coberturas y uso de suelo	Clave	Superficie		Precisión Usuario
		ha	%	
Agropecuario	AGP	592 621.80	41.46	95
Bosque inundado	BI	187 928.22	13.15	90
Bosque tropical	BT	153 774.94	10.76	88
Cuerpo de agua	CA	92 417.63	6.47	92
Humedales	HM	302 616.30	21.17	92
Palma de aceite	PA	33 475.67	2.34	94
Plantaciones forestales comerciales	PFC	58 529.47	4.09	93
Urbano	URB	8005.38	0.56	95
Precisión Producto (%)				0.92
Índice kappa (%)				0.9
Superficie Total		1 429 369.41	100	

CONCLUSIONES

Los resultados de este estudio validan la efectividad de utilizar imágenes satelitales de LandSat 8OLI del 2021, junto con datos auxiliares como el NDVI y el DEM, para realizar un mapeo preciso de las coberturas y usos de suelo (CUS) en la Cuenca Baja del Río Usumacinta (CBRU). Este enfoque resalta la importancia de aplicar técnicas avanzadas de teledetección en regiones de alta biodiversidad, donde la gestión sostenible es crucial.

La clasificación no supervisada mediante el algoritmo ISODATA identificó rápidamente cuatro clases generales: humedales, vegetación arbórea, cuerpos de agua y actividades antropogénicas, logrando una precisión moderada del 67% con un índice kappa de 0.51. Sin embargo, esta metodología presentó limitaciones en la diferenciación de clases específicas como bosques tropicales, bosques inundados y plantaciones de palma de aceite, lo que sugiere que los resultados deben interpretarse con cautela.

Por otro lado, la clasificación supervisada utilizando el algoritmo de Máxima Verosimilitud (MLC), apoyada en 948 puntos de entrenamiento y datos auxiliares del NDVI y DEM, permitió un mapeo más detallado y preciso. Esta metodología logró discriminar clases específicas como agricultura (41.46%), humedales (21.17%), plantaciones forestales comerciales (4.09%) y áreas urbanas (0.56%), alcanzando una excelente precisión con un índice kappa de 0.90, validado por 330 puntos de control terrestre.

La integración del Modelo Digital de Elevación (DEM) mejoró significativamente la precisión en la clasificación al facilitar la diferenciación entre plantaciones forestales y el bosque tropical perennifolio. Además, el uso combinado del NDVI y DEM fue clave para mejorar la discriminación espectral en coberturas complejas como el bosque tropical y los humedales.

Estos resultados subrayan el potencial de combinar información espectral, estructural y topográfica para lograr una clasificación más precisa de las CUS. El mapeo detallado permite identificar patrones de uso del suelo y cambios en el paisaje, lo cual es fundamental para la planificación territorial y la conservación de recursos naturales.

La integración de datos como el NDVI y el DEM, junto con algoritmos avanzados en software de SIG, mejora la precisión de los resultados y contribuye a decisiones informadas en contextos locales complejos, especialmente en regiones tropicales vulnerables como la CBRU. Esta investigación genera información actualizada que sirve como base para implementar estrategias efectivas para el desarrollo sostenible y la gestión de áreas naturales protegidas.

Finalmente, se recomienda explorar técnicas de clasificación basadas en objetos, utilizar imágenes de alta resolución e integrar una mayor densidad de datos de campo para validación. Además, se sugiere analizar series temporales para monitorear dinámicas en las CUS a lo largo del tiempo. En este contexto, los Sistemas de Información Geográfica (SIG) y las técnicas de percepción remota son herramientas eficientes para identificar coberturas y usos del suelo.

Los resultados representan una contribución para tomadores de decisiones y partes interesadas en planificación territorial y manejo sostenible de recursos naturales, contribuyendo así a los esfuerzos por conservar la biodiversidad en la CBRU.

DECLARACIÓN DE ÉTICA

No aplicable.

CONSENTIMIENTO PARA PUBLICACIÓN

Todos los autores han leído y aprobado el manuscrito final y han dado su consentimiento para su publicación.

DISPONIBILIDAD DE DATOS

Los conjuntos de datos utilizados o analizados durante el estudio actual están disponibles del autor correspondiente a solicitud razonable.

CONFLICTO DE INTERESES

Los autores declaran que no tienen intereses en competencia.

FINANCIACIÓN

No aplicable.

CONTRIBUCIÓN DE LOS AUTORES

Conceptualización, metodología, software, validación, análisis formal, investigación, escritura: preparación del borrador original, escritura: revisión y edición, visualización: H.J.M.V. Conceptualización, curación de datos, análisis formal, investigación, escritura: preparación del borrador original, escritura: revisión y edición: C.P.C. Conceptualización, curación de datos, análisis formal, investigación, escritura: preparación del borrador original, escritura: revisión y edición: O.R.M.P. Supervisión, revisión y edición: M.P.C. Supervisión, revisión y edición: R.R.R. Seguimiento en la escritura y clasificación: A.G.A.

AGRADECIMIENTOS

Los autores desean agradecer a los revisores anónimos por sus comentarios y sugerencias en la mejora de esta investigación. Asimismo, HJMV agradece al Programa de Doctorado en Ciencias en Ecología y Manejo de Sistemas Tropicales de la División de Ciencias Biológicas de la Universidad Juárez Autónoma de Tabasco (UJAT), y recibir una beca (293867:) del Consejo Nacional de Ciencia, Humanidades y Tecnología (CONAHCYT). Al Centro del Cambio Global y la Sustentabilidad (CCGS) por el apoyo y las instalaciones brindadas para llevar a cabo esta investigación durante la realización de la estancia doctoral. Además, ORMP agradece al programa Investigadores por México y al proyecto Cátedras-CCGS número 963 "Hacia la gestión sustentable del agua en el sureste de México y áreas adyacentes de Centroamérica".

LITERATURA CITADA

- Abbas, A. W., Minallh, N., Ahmad, N., Abid, S. A. R., & Khan, M. A. A. (2016). K-Means and ISODATA clustering algorithms for landcover classification using remote sensing. *Sindh University Research Journal-SURJ (Science Series)*, 48 (2), 315-318.
- Ahmad, A., & Quegan, S. (2012). Analysis of maximum likelihood classification on multispectral data. *Applied Mathematical Sciences*, 6 (129), 6425-6436.
- Aplin, P., & Atkinson, P. M. (2004). Predicting missing field boundaries to increase per-field classification accuracy. *Photogrammetric Engineering & Remote Sensing*, 70(1), 141-149. <https://doi.org/10.14358/PERS.70.1.141>
- Bendib, A., & Boutrid, M. L. (2024). Use of geostatistical methods involving standard deviation and semivariogram to assess the precision of water surface extraction by supervised classification. *Journal Indian Society of Remote Sensing*, 52, 63-77. <https://doi.org/10.1007/s12524-023-01802-0>
- Bonilla-Moheno, M., & Aide, T. M. (2020). Beyond deforestation: Land cover transitions in Mexico. *Agricultural Systems*, 178, 1-33. <https://doi.org/10.1016/j.agsy.2019.102734>
- Bunyangha, J., Majaliwa, M. J., Muthumbi, A. W., Gichuki, N. N., & Egeru, A. (2021). Past and future land use/land cover changes from multi-temporal LandSat imagery in Mpologoma catchment, eastern Uganda. *The Egyptian Journal of Remote Sensing and Space Science*, 24(3), 675-685. <https://doi.org/10.1016/j.ejrs.2021.02.003>
- Castillo-Cruz, Z. G., & Medrano-Pérez, O. R. (2023). Análisis geomorfológico de las subcuencas Usumacinta y Grijalva en el sureste de México. *Acta Universitaria*, 33, 1-20. <https://doi.org/10.15174/au.2023.3684>
- Camacho-Valdez, V., Rodiles-Hernández, R., Navarrete-Gutiérrez, D. A., & Valencia-Barrera, E. (2022). Tropical wetlands and land use changes: The case of oil palm in neotropical riverine floodplains. *PLoS One*, 17(5), 1-23. <https://doi.org/10.1371/journal.pone.0266677>
- Chuvieco, E. S. (2002). *Teledetección Ambiental: La observación de la tierra desde el espacio*. Ediciones Ariel. 586 pp. ISBN: 84-344-8047-6
- Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20(1), 37-46. <https://doi.org/10.1177/001316446002000104>
- CONAGUA (Comisión Nacional del Agua). (2023). Normales Climatológicas por Estado. Search to Tabasco. Servicio Meteorológico Nacional (SMN). Consultada el 27 de agosto, 2023, desde, <https://smn.conagua.gob.mx/es/informacion-climatologica-por-estado>
- Congalton, R. G., & Green, K. (2019). *Assessing the precision of remotely sensed data: principles and practices*. Boca Raton: CRC press. <https://doi.org/10.1201/9780429052729>
- Cotler, H., Garrido, A., Bunge, V., & Cuevas, M. (2010). Las cuencas hidrográficas de México: priorización y toma de decisiones. En H. Cotler, (Ed.). *Las cuencas hidrográficas de México. Diagnóstico y priorización* (pp. 115-120). Ciudad de México, México: Instituto Nacional de Ecología/Fundación Gonzalo Río Arronte I.A.P.
- Dai, S., Zhou, J., Ning, X., Xu, J., & Wang, H. (2024). Estimation model of wild fractional vegetation cover based on RGB vegetation index and its application. *Open Geosciences*, 16(1), 1-13. <https://doi.org/10.1515/geo-2022-0661>
- Din, M. S. U., Mubeen, M., Hussain, S., Ahmad, A., Hussain, N., Ali, M. A., ... & Nasim, W. (2022). World nations priorities on climate change and food security. In W. N. Jatoti, M. Mubeen, A. Mubeen, M. A. Cheema, Z. Lin, M. Z. Hashmi, (Eds). *Building Climate Resilience in Agriculture: Theory, Practice and Future Perspective* (pp. 365-384). Dordrecht: Springer, Cham. https://doi.org/10.1007/978-3-030-79408-8_22
- Duan, M., Song, X., Li, Z., Zhang, X., Ding, X., & Cui, D. (2024). Identifying soil groups and selecting a high-accuracy classification method based on multi-textural features with optimal window sizes using remote sensing images. *Ecological Informatics*, 81, 1-9. <https://doi.org/10.1016/j.ecoinf.2024.102563>
- Eiumnoh, A., & Shrestha, R. P. (2000). Application of DEM data to LandSat image classification: Evaluation in a tropical wet-dry landscape of Thailand. *PE & RS- Photogrammetric Engineering & Remote Sensing*, 66(3), 297-304.

- ERDAS (1999). *Erdas Field Guide. (Fifth edition revised and expanded)*. Atlanta Georgia, USA: Erdas Inc.
- ESRI (2011). *ArcGis User's Guide. Released 10.8*. Redlands, CA, USA: Environmental Systems Research Institute.
- Fernández-Fierro, A. A., Rosero-Erazo, C. R., Beltrán-Dávalos, A. A., & Echeverría-Guadalupe, M. M. (2020). Caracterización y dinámica de la cobertura de suelo mediante Teledetección: caso de estudio volcán Tungurahua, Ecuador. *Dominio De Las Ciencias*, 6 (2), 906-938. <https://doi.org/10.23857/dc.v6i2.1201>
- Gaitán, J., Ciano, N., Oliva, G., Bran, D., Butti, L., Cariac, G., ... & Maestre, F. (2021). La variación temporal del índice NDVI predice los cambios temporales de la cobertura vegetal en las tierras secas de la Patagonia Argentina: *Ecosistemas*, 30(3), 1-11. <https://doi.org/10.7818/ECOS.2229>
- Gallardo-Cruz, J. A., Peralta-Carreta, C., Solórzano, J. V., Fernández-Montes de Oca, A. I., Nava, L. F., Kauffer, E., & Carabias, J. (2021). Deforestation and trends of change in protected areas of the Usumacinta River basin (2000-2018), México and Guatemala. *Regional Environmental Change*, 21(97), 1-15. <https://doi.org/10.1007/s10113-021-01833-8>
- Gallardo-Cruz, A., de Oca, A. F. M., & Rives, C. (2019). Detección de amenazas y oportunidades para la conservación en la cuenca baja del Usumacinta a partir de técnicas de percepción remota. *Ecosistemas*, 28(2), 1-18. <https://doi.org/10.7818/ECOS.1611>
- García-Mora, T. J., & Mas, J. F. (2008). Comparación de metodologías para el mapeo de la cobertura y uso del suelo en el sureste de México. *Investigaciones geográficas*, 67, 7-19.
- García, A. E. (1988). *Modificaciones al sistema de clasificación climática de Köppen*. México: Instituto de Geografía, Universidad Nacional Autónoma de México.
- Garg, V., Aggarwal, S. P., Gupta, P. K., Nikam, B. R., Thakur, P. K., Srivastav, S. K., & Senthil Kumar, A. (2017). Assessment of land use land cover change impact on hydrological regime of a basin. *Environmental Earth Sciences*, 76, 1-17. <https://doi.org/10.1007/s12665-017-6976-z>
- Google Earth Engine (2022). Imágenes Multiespectrales. Consultado el 20 de septiembre de 2022 desde <https://developers.google.com/earth-engine/datasets/catalog/landsat-8>.)
- Guzmán, R., Bezada, M., & Rodríguez-Santalla, I. (2023). Land cover mapping using remote sensing data in the Apure River Flood Plain (Venezuela). *Cuadernos De Investigación Geográfica*, 49(1), 113-137. <https://doi.org/10.18172/cig.5607>
- INEGI (Instituto Nacional de Estadística y Geografía). (2001). Conjunto de datos vectoriales fisiográficos. Continuo nacional. Escala 1:1 000 000. Serie I. Consultada el 13 de febrero, 2024, desde, <https://www.inegi.org.mx/aplicación/b/ficha.html?upc=702825267575>
- INEGI (Instituto Nacional de Estadística y Geografía). (2012). Continuo de Elevaciones Mexicano 3.0 (CEM 3.0). Modelo de elevación, 15 metros. Consultada el 13 de febrero, 2024, desde, <https://www.inegi.org.mx/app/geo2/elevacionesmex/>
- INEGI (Instituto Nacional de Estadística y Geografía). (2013). Conjunto Nacional de Uso del Suelo y Vegetación a escala 1:250,000, Serie VII, DGG-INEGI, México. Consultada el 13 de febrero, 2024, <http://geoportal.conabio.gob.mx/metadatos/doc/html/usv250s7gw.html>.
- Jiménez, A. A., Vilchez, F. F., González, O. N., & Flores, S. M. M. (2018). Analysis of the Land Use and Cover Changes in the Metropolitan Area of Tepic-Xalisco (1973-2015) through LandSat Images. *Sustainability*, 10(6), 1-15. <https://doi.org/10.3390/su10061860>
- Kassahun, M., Hundera, K. & Senbeta, F. (2024). Analysis of land use/ land cover changes and landscape fragmentation in the Baro-Akobo Basin, Southwestern Ethiopia. *Heliyon*, 10(7), 1-13. <https://doi.org/10.1016/j.heliyon.2024.e28378>
- Kauffer, E. (2021). Hydroextractivism in the Usumacinta River basin: Among transboundary dynamics and border differentiation. *Revista Trace*, 80, 171-199. <https://doi.org/10.22134/trace.80.2021.792>
- Krishna-Bahadur, K. C. (2012). Spatio-temporal patterns of agricultural expansion and its effect on watershed degradation: a case from the mountains of Nepal. *Environmental Earth Sciences*, 65(7), 2063-2077. <https://doi.org/10.1007/s12665-011-1186-6>
- Landis, J. R., & Koch, G. G. (1977). An application of hierarchical kappa-type statistics in the assessment of majority agreement among multiple observers. *Biometrics*, 33(4), 671-679. <https://doi.org/10.2307/2529465>
- Langford, M., & Bell, W. (1997). Land cover mapping in a tropical hillsides environment: A case study in the Cauca region of Colombia. *International Journal of Remote Sensing*, 18 (6), 1289-1306. <https://doi.org/10.1080/014311697218421>
- Lemenkova, P. (2021a). Evaluating land cover types from LandSat TM using SAGA GIS for vegetation mapping based on ISODATA and K-means clustering. *Acta Agriculturae Serbica*, 26(56), 159-165. <https://doi.org/10.5937/AASer2152159L>
- Lemenkova, P. (2021b). SAGA GIS for Computing Multispectral Vegetation Indices by LandSat TM for Mapping Vegetation Greenness. *Contemporary Agriculture*, 70(1-2) 1-9. <https://doi.org/10.2478/contagri-2021-0011>
- Ma, Z., Liu, Z., Zhao, Y., Zhang, L., Liu, D., Ren, T., ... & Li, S. (2020). An unsupervised crop classification method based on principal components isometric binning. *ISPRS International Journal of Geo-Information*, 9(11), 1-24. <https://doi.org/10.3390/ijgi9110648>
- Makandar, A., & Kaman, S. (2021). Land use Land Cover Study of Sentinel-2A and LandSat-5 Images using NDVI and Supervised Classification Techniques. *Explorer*, 12(2), 1-7.
- Mifsut, I. M., & Castro, M. (2010). La Cuenca del Río Usumacinta: Perfil y perspectivas para su conservación y desarrollo sustentable. En H. A. Cotler (Ed.), *Las cuencas hidrográficas de México. Diagnóstico y priorización* (pp. 193-197). Distrito Federal, México: SEMARNAT-INE-IAF. ISBN: 978-607-7655-07-7
- Maselli, F., Conese, C., Petkov, L., & Resti, R. (1992). Inclusion of prior probabilities derived from a nonparametric process into the maximum-likelihood classifier. *Photogrammetric Engineering and Remote Sensing*, 58(2), 201-207.
- Meave, J. A., Gallardo-Cruz, J. A., Hernández, C. A. M., Martínez-Camilo, R., Pérez, M. E. V., & Carabias, J. (2022). *Tipos de vegetación de la cuenca del río Usumacinta*. Ciudad de México, México: Universidad Iberoamericana AC.
- Mohammed, N. Z., Ghazi, A., & Mustafa, H. E. (2013). Positional precision testing of Google Earth. *International Journal of Multidisciplinary Sciences and Engineering*, 4(6), 1-4.
- Mulatu, K., Hundera, K., & Senbeta, F. (2024). Analysis of land use/land cover changes and landscape fragmentation in the Baro-Akobo Basin, Southwestern Ethiopia. *Heliyon*, 10(7), 1-13. <https://doi.org/10.1016/j.heliyon.2024.e28378>
- Nay J., Burchfield E. & Gilligan J. (2017). A machine-learning approach to forecasting remotely sensed vegetation health. *International Journal of Remote Sensing*, 39(6), 1-17. <https://doi.org/10.1080/01431161.2017.1410296>
- Olokeogun, O. S., Iyiola, K., & Iyiola, O. F. (2014). Application of remote sensing and GIS in land use/land cover mapping and change detection in Shasha Forest reserve, Nigeria. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 40(8), 613-616. <https://doi.org/10.5194/isprsarchives-XL-8-613-2014>
- Ortiz-Pérez, M. A. (2022). Cambio de uso agrícola y vegetación (1947-2019) en la región de Los Ríos, Tabasco, México. *Revista Chapingo Serie Ciencias Forestales y del Ambiente*, 28(3), 465-481. <https://doi.org/10.5154/r.chscfa.2022.01.001>
- Padilla-Romero, A., & Hernández-Juárez, M. (2023). Land use change by the NAICM construction in Texcoco, Mexico State. *Terra Latinoamericana*, 41, 1-15. <https://doi.org/10.28940/terra.v41i0.1608>

- Palaniswami, C., Upadhyay, A. K., & Maheswarappa, H. P. (2006). Spectral mixture analysis for subpixel classification of coconut. *Current Science*, 91(12), 1706-1711.
- Palma-López, D. J., Cisneros, D. J., Moreno, C. E., & Rincón-Ramírez, J. A. (2007). Suelos de Tabasco: su uso y manejo sustentable. Villahermosa, Tabasco, México: Colegio de Postgraduados-ISPOTAB-FUPROTAB. ISBN: 968-839-552-8
- Peralta-Carreta, C., Gallardo-Cruz, J. A., Solórzano, J. V., & Hernández-Gómez, M. (2019). Clasificación del uso de suelo y vegetación en áreas de pérdida de cobertura arbórea (2000-2016) en la cuenca del río Usumacinta. *Madera y Bosques*, 25(3), 1-19.
- Perumal, K., & Bhaskaran, R. (2010). Supervised classification performance of multispectral images. *Journal of Computing*, 2(2), 1-6. <https://doi.org/10.48550/arXiv.1002.4046>
- Peters, A. J., Walter-Shea, E. A., Ji, L., Vina, A., Hayes, M., & Svoboda, M. D. (2002). Drought monitoring with NDVI-based standardized vegetation index. *Photogrammetric engineering and remote sensing*, 68(1), 71-75.
- Ramírez-García, A. R., Zavala-Cruz, J., Rincón-Ramírez, J. A., Guerrero-Peña, A., García-López, E., Sánchez-Hernández, R., ... & Ortiz-Pérez, M. A. (2022). Cambio de uso agrícola y vegetación (1947-2019) en la región de Los Ríos, Tabasco, México. *Revista Chapingo Serie Ciencias Forestales y del Ambiente*, 28(3), 465-481. <https://doi.org/10.5154/r.rchscfa.2022.01.001>
- Revuelta-Acosta, J. D., Garrido-Melendez, J., Escobedo-Trujillo, B. A., & Alcalá, G. (2023). LULC Evolution of Southeast Mexico Based on Geographical Information Systems and Remote Sensing. In: M. Espinoza-Andaluz, E. Melo-Vargas, J. Santana-Villamar, & Á. Encalada-Dávila (Eds). *Congress on Research, Development, and Innovation in Renewable Energies: Selected Papers from CIDiER 2022* (pp. 89-106). Cham, Switzerland: Springer International Publishing. https://doi.org/10.1007/978-3-031-26813-7_6
- Reynolds, J. F., Smith, D. M. S., Lambin, E. F., Turner, B. L., Mortimore, M., Batterbury, S. P., ... & Walker, B. (2007). Global desertification: Building a science for dryland development. *Science*, 316 (5826), 847-851. <https://doi.org/10.1126/science.1131634>
- Reynoso-Santos, R., Valdez-Lazalde, J. R., Escalona-Maurice, M. J., & de los Santos-Posadas, H. M. (2015). Análisis de la dinámica del uso del suelo de la cuenca Metztlán en Hidalgo, México. *Ingeniería Hidráulica y Ambiental*, 36(3), 1-10.
- Richards, J. A., & Jia, X. (2022). Remote sensing digital image analysis. Berlin, Germany: Springer. <https://doi.org/10.1007/3-540-29711-1>
- Richards, J. A. (2022). Supervised classification techniques. In *Remote Sensing Digital Image Analysis*. (pp. 263-367). Cham, Switzerland: Springer Nature. https://doi.org/10.1007/978-3-030-82327-6_8
- Rodríguez-Valero, M. I., & Alonso-Sarria, F. (2022). Obtención de cartografías de usos y coberturas del suelo de la demarcación hidrográfica del Segura para el periodo 1986-2019, empleando teledetección y clasificación digital de imágenes. *Papeles de Geografía*, 67, pp. 45-65. <https://doi.org/10.6018/geografia.472241>
- Rullán-Silva, C. D., Gama-Campillo, L. M., Galindo-Alcántara, A., & Olthoff, A. E. (2011). Clasificación no supervisada de la cobertura de suelo de la región Sierra de Tabasco mediante imágenes LANDSAT ETM+. *Universidad y Ciencia*, 27(1), 1-9.
- Rwanga, S. S., & Ndambuki, J. M. (2017). Accuracy assessment of land use/land cover classification using remote sensing and GIS. *International Journal of Geosciences*, 8(4), 1-13. <https://doi.org/10.4236/ijg.2017.84033>
- Rzedowsky, J. (2006). *Vegetación potencial de México*. México: CONABIO.
- Saco, P. M., Moreno-de las Heras, M., Keesstra, S., Baartman, J., Yetemen, O., & Rodríguez, J. F. (2018). Vegetation and soil degradation in drylands: non linear feedbacks and early warning signals. *Current Opinion in Environmental Science & Health*, 5, 67-72. <https://doi.org/10.1016/j.coesh.2018.06.001>
- Sahebjalal, E., & Dashtekian, K. (2013). Analysis of land use-land covers changes using normalized difference vegetation index (NDVI) differencing and classification methods. *African Journal of Agricultural Research*, 8(37), 1-9. <https://doi.org/10.5897/AJAR11.1825>
- SERNAPAM (2013). Programa Estatal de Ordenamiento Ecológico del Estado de Tabasco (2013-2018). Secretaría de Recursos Naturales y Protección Ambiental. Gobierno del Estado de Tabasco, México. Consultada el 20 de marzo, 2024, desde https://tabasco.gob.mx/sites/default/files/sites/default/files/public_files/POET2013.pdf
- Shalaby, A., & Tateishi R. (2007). Remote sensing and GIS for mapping and monitoring land cover and land-use changes in the Northwestern coastal zone of Egypt. *Applied Geography*, 27(1), 28-41. <https://doi.org/10.1016/j.apgeog.2006.09.004>
- Sisodia, P. S., Tiwari, V., & Tiwari, A. (2014). Analysis of supervised maximum likelihood classification for remote sensing image. In *International conference on recent advances and innovations in engineering (ICRAIE-2014)* (pp. 1-4). Jaipur, India: IEEE. <https://doi.org/10.1109/ICRAIE.2014.6909319>
- Sun, J., & Qin, X. (2016). Precipitation and temperature regulate the seasonal changes of NDVI across the Tibetan Plateau. *Environmental Earth Sciences*, 75(4), 291. <https://doi.org/10.1007/s12665-015-5177-x>
- Trujillo-Jiménez, M. A., Liberoff, A. L., Pessacq, N., Pacheco, C., Díaz, L., & Flaherty, S. (2022). SatRed: New classification land use/land cover model based on multi-spectral satellite images and neural networks applied to a semiarid valley of Patagonia. *Remote Sensing Applications: Society and Environment*, 26, 100703. <https://doi.org/10.1016/j.rsase.2022.100703>
- Tudela, F. (1989). *La modernización forzada del trópico: el caso de Tabasco*. Distrito Federal, México: Colegio de México.
- Tziolas, N., Tsakiridis, N., Ogen, Y., Kalopesa, E., Ben-Dor, E., Theocharis, J., & Zalidis, G. (2020). An integrated methodology using open soil spectral libraries and Earth Observation data for soil organic carbon estimations in support of soil-related SDGs. *Remote Sensing of Environment*, 244, 111793. <https://doi.org/10.1016/j.rse.2020.111793>
- Vaca, R. A., Golicher, D. J., Rodiles-Hernández, R., Castillo-Santiago, M. Á., Bejarano, M., & Navarrete-Gutiérrez, D. A. (2019). Drivers of deforestation in the basin of the Usumacinta River: Inference on process from pattern analysis using generalised additive models. *Plos One*, 14(9), 1-21. <https://doi.org/10.1371/journal.pone.0228328>
- Vimala R., Marimuthu A., Venkateswaran S. & Poongodi R. (2020). Unsupervised ISODATA algorithm classification used in the landSat image for predicting the expansion of Salem urban, Tamil Nadu. *Indian Journal of Science and Technology*, 13(16): 1619-1629. <https://doi.org/10.17485/IJST/v13i16.271>
- Wang, B. & Yao, Y. (2024) Mountain Vegetation Classification Method Based on Multi-Channel Semantic Segmentation Model. *Remote Sensing*, 16(2), 1-16. <https://doi.org/10.3390/rs16020256>
- Ward, J. H. (1963). Hierarchical Grouping to Optimize an Objective Function. *Journal of the American Statistical Association*, 58(301), 236-244. <https://doi.org/10.1080/01621459.1963.10500845>
- Wu, C., & Murray, A. T. (2003). Estimating impervious surface distribution by spectral mixture analysis. *Remote sensing of Environment*, 84(4), 493-505. [https://doi.org/10.1016/S0034-4257\(02\)00136-0](https://doi.org/10.1016/S0034-4257(02)00136-0)
- Yacouba, D., Guangdao, H., & Xingping, W. (2009). Assessment of land use cover changes using NDVI and DEM in Puer and Simao counties, Yunnan Province, China. *World Rural Observations*, 1(2), <https://doi.org/10.7537/marswro010209.01>

- Yang, H., Zhang, X., Xu, M., Shao, S., Wang, X., Liu, W., ... & Liu, H. (2020). Hyper-temporal remote sensing data in bare soil period and terrain attributes for digital soil mapping in the Black soil regions of China. *Catena*, 184, 104259. <https://doi.org/10.1016/j.catena.2019.104259>
- Yasin, E. H., & Kornel, C. (2024). Evaluating satellite image classification: Exploring methods and techniques. En R. M. Abdalla (Ed.), *Geographic information systems-Data science approach*. London: IntechOpen. <https://doi.org/10.5772/intechopen.1003196>
- Yuan, L., Yan, P., Han, W., Huang, Y., Wang, B., Zhang, J., & Bao, Z. (2019). Detection of anthracnose in tea plants based on hyperspectral imaging. *Computers and Electronics in Agriculture*, 167, 105039. <https://doi.org/10.1016/j.compag.2019.105039>
- Zhang, X., Wang, D., Hao, H., Zhang, F., & Hu, Y. (2017). Effects of Land Use/Cover Changes and Urban Forest Configuration on Urban Heat Islands in a Loess Hilly Region: Case Study Based on Yan'an City, China. *International Journal of Environmental Research and Public Health*, 14(8), 1-25. <http://dx.doi.org/10.3390/ijerph14080840>
- Zhang, X., Yan, G., Li, Q., Li, Z. L., Wan, H., & Guo, Z. (2006). Evaluating the fraction of vegetation cover based on NDVI spatial scale correction model. *International Journal of Remote Sensing*, 27(24), 5359-5372. <https://doi.org/10.1080/01431160600658107>
- Zhang, X., Zhao, T., Xu, H., Liu, W., Wang, J., Chen, X., & Liu, L. (2024). The first global 30-m land-cover dynamic monitoring product with a fine classification system from 1985 to 2022 using dense time-series Landsat imagery and continuous change-detection method. *Earth System Science Data Discussions*, 16(3), 1-29. <https://doi.org/10.5194/essd-2023-3201>
- Zhao, Q., Liu, S., Deng, L., Dong, S., Yang, Z., & Yang, J. (2012). Landscape change and hydrologic alteration associated with dam construction. *International Journal of Applied Earth Observation and Geoinformation*, 16, 17-26. <https://doi.org/10.1016/j.jag.2011.11.009>