

Clasificación Supervisada para el Mapeo del Maíz Forrajero Mediante Teledetección en la Región Lagunera, México Supervised Classification for Mapping Forage Maize Using Remote Sensing in the Laguna Region, Mexico

Gerardo Delgado-Ramírez^{1,2} , Martín A. Bolaños-González^{2*} , Abel Quevedo-Nolasco² ,
Adolfo López-Pérez² y Juan Estrada-Ávalos¹

¹ Instituto Nacional de Investigaciones Forestales, Centro Nacional de Investigación Disciplinaria en Relación Agua, Suelo, Planta, Atmósfera, Agrícolas y Pecuarias. Margen Derecha Canal Sacramento km 6.5, Colonia Valle Verde. 35140 Gómez Palacio, Durango, México; (G.D.R.), (J.E.A.).

² Colegio de Postgraduados, Campus Montecillo. Carretera México-Texcoco km 36.5, Montecillo. 56230 Texcoco, Estado de México, México; (G.D.R.), (M.A.B.G.), (A.Q.N.), (A.L.P.).

* Autor para correspondencia: martinb72@gmail.com

RESUMEN

La clasificación supervisada es una técnica que identifica regiones espectralmente similares mediante el uso de muestras de entrenamiento extraídas de una imagen de satélite. Los algoritmos más utilizados para la clasificación de la cobertura agrícola incluyen distancia mínima, máxima verosimilitud, mapeador de ángulos espectrales y Random Forest. En este estudio se evaluó el desempeño de estos algoritmos para identificar, mapear y cuantificar la superficie cultivada con maíz forrajero, cultivo de alta relevancia económica, en los módulos de riego X y XII del Distrito de Riego 017 Región Lagunera. Se emplearon imágenes satelitales Sentinel-2, adquiridas en tres fechas correspondientes a etapas fenológicas clave del maíz forrajero, desde el panojamiento hasta la fase reproductiva de grano lechoso. El algoritmo *Random Forest* con 100 árboles de decisión mostró el mejor desempeño, alcanzando los valores más altos de precisión global e índice de Kappa en ambos módulos de riego. El Módulo X presentó valores de precisión global de 79.1% e índice Kappa de 0.63. Por otra parte, el Módulo XII registró valores del 87.4% de precisión global y 0.79 de índice Kappa. Las precisiones más altas se lograron con la imagen del 11 de junio de 2021 (día juliano 162), cuando las diferencias fenológicas y de cobertura favorecieron la separación de los cultivos. El maíz forrajero presentó la mayor cobertura de la superficie en el área de estudio, alcanzando 44% de la superficie total. La clasificación del maíz forrajero resultó ser la más confiable en comparación con las demás clases evaluadas en ambos módulos. La identificación precisa, tanto espacial como temporal, del maíz forrajero permite la generación de inventarios actualizados y confiables, lo que contribuye de manera efectiva a la toma de decisiones en la planificación y manejo del cultivo, así como en la gestión de los recursos hídricos.

Palabras clave: algoritmos, imágenes Sentinel-2, índice Kappa, *Zea mays* L.

SUMMARY

Supervised classification is a technique that identifies spectrally similar regions using training samples extracted from a satellite image. The most used agricultural land cover classification algorithms include minimum distance, maximum likelihood, spectral angle mapper, and Random Forest. This study evaluated the performance of these algorithms in identifying, mapping, and quantifying the area cultivated with forage maize in irrigation modules X and XII of Irrigation District 017 in the Laguna Region, a crop of high economic importance. Sentinel-2 satellite imagery



Cita recomendada:

Delgado-Ramírez, G., Bolaños-González, M. A., Quevedo-Nolasco, A., López-Pérez, A., & Estrada-Ávalos, J. (2025). Clasificación Supervisada para el Mapeo del Maíz Forrajero Mediante Teledetección en la Región Lagunera, México. *Terra Latinoamericana*, 43, 1-15. e2123. <https://doi.org/10.28940/terra.v43i.2123>

Recibido: 23 de octubre de 2024.
Aceptado: 14 de febrero de 2025.
Artículo. Volumen 43.
Julio de 2025.

Editor de Sección:
Dr. Héctor Estrada Medina

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/>).

was used, acquired on three dates corresponding to key phenological stages of forage maize, from tasseling to the reproductive milky grain stage. The Random Forest algorithm with 100 decision trees performed best, achieving the highest overall accuracy and Kappa index scores in both irrigation modules. Module X presented overall accuracy values of 79.1% and a Kappa index of 0.63. On the other hand, Module XII recorded values of 87.4% overall accuracy and 0.79 Kappa index. The highest accuracies were obtained with the image from June 11, 2021 (Julian Day 162), when phenological and coverage differences favored the separation of the crops. Forage maize covered the largest surface area in the study region, reaching 44% of the total surface. The classification of forage maize proved to be the most reliable compared to the other evaluated classes in both modules. The precise identification, spatially and temporally, of forage maize allows for the generation of updated and reliable inventories, effectively contributing to decision-making in crop planning and management, as well as in the management of water resources.

Index words: *algorithms, Sentinel-2 imagery, Kappa index, Zea mays L.*

INTRODUCCIÓN

La clasificación supervisada es una técnica para detectar regiones espectralmente similares al utilizar muestras de entrenamiento contenidas en una imagen (Abburu y Golla, 2015). Esta clasificación parte de un conocimiento previo del área de estudio, adquirido a través de experiencia o trabajo de campo (Aguilar-Rivera, Galindo y Fortanelli, 2012). En este contexto, el clasificador extrapola las propiedades espectrales a otras áreas de la imagen.

El amplio interés por la clasificación de superficies ha generado una gran cantidad de clasificadores supervisados, que se pueden categorizar en paramétricos y no paramétricos (Hubert-Moy, Cotonnec, Le, Chardin y Perez, 2001). Los paramétricos parten del supuesto de una determinada clase que tiene una distribución estadística, usualmente una distribución normal (Weng, 2012). Los no paramétricos no hacen suposiciones sobre distribuciones de probabilidad (Keuchel, Naumann, Heiler y Siegmund, 2003). Por lo tanto, estos últimos pueden considerarse robustos, ya que pueden funcionar correctamente para varias distribuciones de clases (Wieland y Pittore, 2014), siempre y cuando las firmas espectrales de las clases sean lo suficientemente distintas. Algunos de los algoritmos que más se utilizan para la clasificación de la cobertura del suelo agrícola son: distancia mínima (DM), máxima verosimilitud (MV), mapeador de ángulos espectrales (MAE) y random forest (RF); los tres primeros son paramétricos y el último es no paramétrico.

La clasificación de cultivos es una de las aplicaciones de la teledetección en la agricultura (Atzberger, 2013). Esta permite reconocer los cultivos de cada parcela, que es una información muy útil, tanto en escalas locales y regionales, como en escala global (Kussul *et al.*, 2016). Además, la información que genera es esencial para la formulación de políticas agrarias, concesión y control de subsidios, seguridad alimentaria, manejo y control de cultivos agrícolas, estimación de rendimiento e inventario de cultivos agrícolas. Este último aspecto es especialmente relevante, ya que, al identificar los cultivos, es posible determinar de manera espacial y temporal los requerimientos hídricos, con el apoyo de técnicas de teledetección y sistemas de información geográfica (SIG).

La teledetección se puede utilizar con la tecnología de Sistemas de Información Geográfica (SIG) que brindan una mayor comprensión acerca de la cobertura del suelo (Rwanga y Ndambuki, 2017). Esta combinación proporciona una herramienta de análisis cuantitativo de los cambios en el uso y la cobertura del suelo (Chowdhury, Hasan y Abdullah, 2020), y para revisar y editar mapas a diferentes escalas (Rujoiu-Mare y Mihai, 2016). Las imágenes satelitales multiespectrales de resolución moderada y de acceso libre, como Landsat 7 y 8, MODIS, Sentinel-1 y Sentinel-2, se utilizan para el monitoreo y clasificación de cultivos agrícolas.

Entre estos satélites, Sentinel-2 se destaca como el más relevante y preciso para la clasificación de cultivos agrícolas, gracias a su resolución espacial de 10 m y su capacidad multiespectral. Song, Huang, Hansen y Potapov (2021) evaluaron la utilidad de los sensores Landsat 7 y 8, Sentinel-1 y Sentinel-2 para la clasificación supervisada de maíz, identificando a este último como el sensor más valioso y preciso. Este desempeño sobresaliente se atribuye principalmente a la inclusión de bandas específicas, como el borde rojo, el infrarrojo cercano y el infrarrojo de onda corta, que mejoran significativamente la detección y discriminación de cultivos. Por otro lado, Saini y Ghosh (2018) realizaron un estudio comparativo de la clasificación supervisada de la cobertura agrícola usando imágenes Sentinel-2 y dos algoritmos de aprendizaje automático: Random Forest y máquina de vectores soporte.

En este análisis, Random Forest obtuvo los valores más altos de precisión global e índice Kappa, destacándose como el algoritmo más efectivo para este propósito.

Por otro lado, el complemento gratuito y de código libre Semiautomatic Classification Plugin (SCP) del software QGIS.org (2020) realiza una clasificación semiautomática con base en múltiples satélites (ASTER, MODIS, SPOT, RapidEye, Landsat, Sentinel, etc.). Además de la clasificación, SCP integra herramientas para el procesamiento previo y posterior de imágenes espectrales, lo que convierte a SCP en una herramienta importante en todo el flujo de trabajo para el mapeo de cobertura de suelo (Leroux, Congedo, Bellón, Gaetano y Bégué, 2018). Algunos investigadores han utilizado el SCP para monitorear los cambios de cobertura de suelo (Vincent, Varalakshmi, Nithya, Sona y Thomas, 2022), mapeo y clasificación de cobertura terrestre (Leroux et al., 2018; Rolando, D'Uva y Scandiffio (2023).

En los últimos años el cultivo de maíz forrajero se ha consolidado como el principal cultivo en la Región Lagunera, donde se ubica el Distrito de Riego (DR) 017; ya que se han establecido 54 000.00 ha de una superficie total de riego de 167 000.00 ha (Reyes-González, Zavala, de Paul, Cano y Rodríguez, 2022). El ensilaje de maíz es uno de los principales ingredientes de la dieta del ganado lechero, pues constituye entre 30 y 40% de la ración (en materia seca) de las vacas de producción (González-Castañeda, Peña, Núñez y Jiménez, 2005). De 2011 a 2021 el número de cabezas de ganado bovino lechero aumentó alrededor de 83 mil (SIAP, 2023), lo que ha llevado a un incremento en el área sembrada. Sin embargo, a pesar de la importancia de este cultivo en el DR 017, existe una carencia de información precisa y oportuna. Por lo tanto, un monitoreo exacto y actualizado de la cobertura de maíz forrajero, facilita la toma de decisiones en la gestión del recurso hídrico en las unidades de producción y distritos de riego.

Ante la falta de estudios que comparen específicamente los algoritmos DM, MV, MAE y RF en el cultivo de maíz forrajero en regiones con características agroclimáticas similares a las de la Región Lagunera, este estudio tiene como objetivo evaluar y comparar el desempeño de los cuatro algoritmos de clasificación supervisada (DM, MV, MAE y RF) en la identificación, mapeo y cuantificación del maíz forrajero en los módulos de riego X (Masitas) y XII (El Porvenir) del Distrito de Riego 017 (DR017). Para lograrlo, se utilizó información espectral obtenida de imágenes del satélite Sentinel-2 en tres fechas específicas de evaluación, que coincidieron con un periodo clave en el desarrollo del cultivo.

MATERIALES Y MÉTODOS

Área de Estudio

El estudio se realizó en el ciclo primavera-verano (PV) 2021 en los módulos X (Masitas) y XII (El Porvenir) del DR 017 Región Lagunera. Las coordenadas extremas que definen el área de estudio son: Por el Norte, el Módulo XII llega hasta los 25° 54' 39.27" N y 103° 18' 43.61" O en el ejido Batopilas, municipio de Francisco I. Madero, Coahuila. Por el Sur, el Módulo X llega hasta los 25° 33' 22.23" N y 103° 27' 22.17" O en el ejido Las Huertas, municipio de Gómez Palacio, Durango. Por el Oeste, el Módulo X llega hasta los 103° 31' 20.72" O y 25° 45' 4.30" de N en el ejido La Luz, municipio de Gómez Palacio, Durango. Por el Este, el Módulo XII llega hasta los 103° 15' 17.74" O y 25° 46' 27.92" N en el ejido Nuevo Linares, municipio de Francisco I. Madero, Coahuila. Ambos módulos cubren una superficie de 14 276.70 ha. La pendiente de la zona de estudio es suave, de aproximadamente 0.05%, con dirección de sur a norte (Figura 1), y la elevación oscila entre 1104 y 1123 m (INEGI, 2013).

Datos de Campo, Tamaño de la Muestra y Fechas de Evaluación

El maíz forrajero es el cultivo importante en el área de estudio, con una superficie de siembra programada para el ciclo agrícola PV 2021 de 2405.00 ha para el módulo X y 1510.00 ha para el módulo XII (información oficial que proporciono el personal administrativo de los dos módulos), Que representan 57.8 y 53.3% de la superficie total de riego programada con agua superficial (agua de río) en ambos módulos de riego, respectivamente.

Algunos productores de estos módulos cuentan con derechos de riego para usar tanto agua superficial (río) como subterránea (pozo). El agua subterránea se utiliza para el riego de aniego o presiembra, y el primer riego de auxilio del maíz forrajero. Los riegos de auxilio posteriores se realizan con agua superficial.

Para determinar el tamaño de la muestra se utilizó el método propuesto por Murray y Larry (2009); se empleó como referencia la superficie de siembra programada de maíz forrajero para el ciclo PV 2021. Resultó un tamaño de muestra de 331.00 ha para el módulo X y 306.00 ha para el módulo XII, con un nivel de confianza de 95%, y un error deseado del 5 por ciento.




Figura 1. Localización del sitio de estudio: a) Parcelas de entrenamiento y validación, b) ubicación de los módulos, y c) altimetría del área de estudio.

Figure 1. Location of the study site: a) Training and validation plots, b) location of the modules, and c) altimetry of the study area.

Se establecieron tres fechas para realizar la evaluación de los algoritmos de clasificación supervisada: 1) 22 de mayo de 2021 (día juliano 142); 2) 11 de junio de 2021 (día juliano 162); y 3) 26 de junio de 2021 (día juliano 177). Estas fechas correspondieron al periodo de las etapas fenológicas del maíz forrajero entre V_T (panojamiento) y R_3 (etapa reproductiva: grano lechoso). Las fechas se definieron mediante la predicción fenológica del maíz forrajero, por medio de los grados días de desarrollo (GDD) utilizando el método racional (Snyder, 1985). Para ello, se tuvo en cuenta una temperatura base de 10 °C y una temperatura máxima de 30 °C. También, se consideró el acumulado de GDD del maíz forrajero reportado por Delgado-Ramírez, Bolaños, Quevedo, López y Estrada (2023) en trabajos previos en el área de estudio, el cual fue de 1526.1 GDD para maíz irrigado con agua subterránea (fecha de siembra: 26 de febrero) y 1722.6 GDD con agua superficial, para una fecha de siembra en el 9 de abril.

Descarga de Imágenes de Satélite

Se utilizaron tres imágenes multiespectrales de los satélites Sentinel 2A (22 de mayo y 11 de junio de 2021) y Sentinel B (26 de junio de 2021), sin nubosidad, las cuales cubren satisfactoriamente el área de estudio (malla de barrido = T13RFJ). En el Cuadro 1 se presentan las características generales de las doce bandas en las que captan información espectral los sensores a bordo de los satélites Sentinel-2 para la clasificación supervisada.

Las imágenes se descargaron gratuitamente desde el sitio web Copernicus Open Access Hub (Copernicus Programme, 2024) con un nivel de procesamiento 2A, también denominado reflectancia a nivel de suelo (ESA, 2015). Este nivel garantiza que las imágenes están calibradas radiométricamente, corregidas geométricamente y con valores de reflectancia calculados en la superficie terrestre (Kuhn *et al.*, 2019).

Determinación de Clases

Para realizar la clasificación supervisada en los dos módulos de riego, se definieron tres clases que abarcan la mayoría de la superficie: 1) maíz forrajero, 2) otros cultivos, y 3) suelo desnudo o vacante. En el Cuadro 2 se muestran las clases y superficie evaluadas mediante los algoritmos de clasificación supervisada. En el módulo X se evaluó una superficie total de 764.20 ha en 92 parcelas y en el módulo XII fueron 783.49 ha en 109 parcelas. Asimismo, se puede constatar que la superficie evaluada de maíz forrajero (Clase 1) corresponde al tamaño de muestra previamente calculada para los dos módulos de estudio.

Cuadro 1. Características de las bandas utilizadas del satélite Sentinel-2 para la clasificación supervisada en los dos módulos de estudio (Fuente: ESA, 2012).**Table 1. Characteristics of the Sentinel-2 satellite bands used for the supervised classification in the two study modules (Source: ESA, 2012).**

Bandas Sentinel-2	Longitud de Onda Central	Ancho de Bandas	Resolución (m)
	----- nm -----		m
Banda 1 - Aerosol	443	20	60
Banda 2 - Azul	490	65	10
Banda 3 - Verde	560	35	10
Banda 4 - Rojo	665	30	10
Banda 5 - Borde Rojo 1	705	15	20
Banda 6 - Borde Rojo 2	740	15	20
Banda 7 - Bordo Rojo 3	783	20	20
Banda 8 - Infrarrojo Cercano (NIR) 1	842	115	10
Banda 8A - Infrarrojo Cercano (NIR) 2	865	20	20
Banda 9 - Vapor de Agua	945	20	60
Banda 11 - Infrarrojo Onda Corta (SWIR) 1	1610	90	20
Banda 12 - Infrarrojo Onda Corta (SWIR) 2	2190	180	20

La delimitación de las parcelas correspondientes a la Clase 1 (Maíz Forrajero) y la Clase 2 (Otros Cultivos) se realizó en campo mediante la utilización de un GPS marca Garmin modelo Etrex 32x. En cuanto a la Clase 3 (Vacante), se seleccionaron las parcelas con valores comprendidos entre el rango de 0.08 y 0.10 del Índice de Vegetación de Diferencia Normalizada (NDVI) en cada una de las imágenes clasificadas. Estos valores de NDVI corresponden a suelo desnudo (denominada línea de suelo). El NDVI se calculó con la Ecuación 1 propuesta por Rouse, Jr, Haas, Schell y Deering (1974).

$$NDVI = \frac{NIR - R}{NIR + R} \quad (1)$$

Cuadro 2. Clases y superficies evaluadas con los algoritmos de clasificación supervisada en los módulos X y XII del DR 017.**Table 2. Classes and surfaces evaluated with the supervised classification algorithms in modules X and XII of ID 017.**

No. Clase	Nombre de la Clase	Cultivos	Módulo X		Módulo XII	
			No. Parcelas	Superficie	No. Parcelas	Superficie
				ha		ha
Clase 1	Maíz Forrajero	Maíz Forrajero	34	332.96	25	306.05
Clase 2	Otros Cultivos	Sorgo Forrajero	14	78.10	20	117.09
		Nogal	7	80.88	2	21.59
		Algodón	14	98.80		
		Alfalfa	5	40.15		
Clase 3	Vacante	Vacante (22 mayo 2021)	8	51.83	27	137.35
		Vacante (11 junio 2021)	4	30.18	25	137.41
		Vacante (26 junio 2021)	6	51.30	10	64.00

Vacante = Suelo desnudo (sin cultivo).

Vacant = Bare soil (no cultivation).

NDVI es el índice de vegetación de diferencia normalizada (adimensional), NIR es la reflectancia en la banda del infrarrojo cercano (%) y R es la reflectancia en la banda del rojo (%). Según las bandas espectrales que contienen las imágenes Sentinel-2; B8 corresponde a la banda NIR y B4 a la banda R , ambas con una resolución espacial de 10 metros.

La línea de suelo es fácil de definir, pero su valor no es universal y depende del conjunto de datos considerado (Gilabert, González y García, 1997). Algunos autores estimaron valores de la línea de suelo del NDVI de 0.10 (Delgado-Ramírez *et al.*, 2023) y 0.12 (Gilabert *et al.*, 1997). Con base en la delimitación de las parcelas en ambos módulos de riego, se asignaron aleatoriamente las áreas de entrenamiento y validación, se consideró el 70 y 30%, respectivamente. La determinación del porcentaje de áreas de entrenamiento se fundamentó en las investigaciones de Argañaraz y Entraigas (2011), quienes demostraron que la precisión global se mejora significativamente al ampliar el intervalo de áreas de entrenamiento desde un 2.5% hasta un 70 por ciento.

Algoritmos de Clasificación Supervisada

En el área de estudio, la clasificación supervisada se llevó a cabo mediante la implementación de tres algoritmos paramétricos: distancia mínima (DM), máxima verosimilitud (MV) y mapeador de ángulos espectrales (MAE). Adicionalmente, se empleó un algoritmo no paramétrico, Random Forest (RF), que se configuró con dos variantes de árboles de decisión: 20 ($k = 20$) y 100 ($k = 100$). Los cuatro algoritmos se describen a continuación:

Distancia mínima (DM). Es un clasificador sencillo y de rápida ejecución. Utiliza las áreas de entrenamiento para determinar el promedio de las clases seleccionadas y luego coloca cada pixel en la clase con el promedio más cercano según la medida de distancia euclidiana (Avogadro y Padró, 2019; Ghayour *et al.*, 2021). DM ignora las varianzas en los vectores espectrales promedio de diferentes clases (Altamirano, Rubio, López y Guerra, 2020). Sin embargo, brinda buenos resultados, sí no existe un gran traslape de clases. Como siempre hay una clase adyacente, no hay espacio para píxeles sin clasificar, incluso si están lejos del centroide de la clase (Sathya y Deepa, 2017). El cálculo de la distancia euclidiana se realiza con la Ecuación 2 (Richards, 1999; Mohamed, Belal y Shalaby, 2015).

$$Dist = \sqrt{(BV_{ijk} - \mu_{ck})^2 + (BV_{ijl} - \mu_{cl})^2} \quad (2)$$

$Dist$ representa la distancia de la puntuación promedio al pixel desconocido, μ_{ck} es el vector promedio de la clase c en la banda k y μ_{cl} es el vector promedio de la clase c en la banda l .

Máxima verosimilitud (MV). Es el algoritmo más utilizado en teledetección debido a su facilidad de aplicación e interpretación de resultados. Además, se considera uno de los métodos de discriminación más precisos y eficaces (Herbei, Sala y Boldea, 2015; Makandar y Kaman, 2021), siempre y cuando los datos sigan una distribución normal (Mondal, Kundu, Chandniha, Shukla y Mishra, 2012; Topaloğlu, Sertel y Musaoğlu, 2016). En la fase de aprendizaje, el MV crea una "imagen espectral" para cada clase, a partir del promedio y la varianza/covarianza de los sitios de entrenamiento que se localizan en la imagen (Otukey y Blaschke, 2010). Durante la fase de clasificación, la probabilidad de que cada pixel pertenezca a cada clase se calcula en función de su respuesta espectral de acuerdo a la Ecuación (3) (Richards, 1999; Otukey y Blaschke, 2010). Finalmente, el pixel se asigna a la clase con mayor probabilidad de pertinencia.

$$D = \ln(a_c) - [0.5\ln(|COV_c|)] - [0.5(X - M_c)T(COV_c - 1)(X - M_c)] \quad (3)$$

D es la distancia ponderada que indica la probabilidad de pertinencia, c representa la clase especificada, X es el vector de mediación del pixel deseado, M_c es el vector promedio de la clase c y COV_c representa la matriz de covarianza de los píxeles de la clase c .

Mapeador de ángulos espectrales (MAE). Es un clasificador espectral supervisado autogenerado, que se utiliza para determinar la similitud espectral entre los espectros de una imagen determinada y los espectros de referencia en el espacio dimensional, calculando el ángulo entre los espectros (Petropoulos, Vadrevu, Xanthopoulos, Karantounias y Scholze, 2010; Tang *et al.*, 2015). Los espectros de referencia se adquieren mediante investigación de campo o directamente a partir de imágenes satelitales. Estos espectros funcionan como firmas espectrales para la clasificación de imágenes satelitales (Li, Ke, Gong y Li, 2015). El MAE se basa exclusivamente en información angular para determinar el espectro de los píxeles. Este algoritmo asume que el espectro de

reflectancia observado, representado en forma vectorial, que se encuentra en un espacio multidimensional, donde el número de dimensiones es equivalente al número de bandas espectrales (Talukdar *et al.*, 2020). La discrepancia entre los espectros de la imagen y los espectros de referencia se cuantifica mediante el ángulo espectral en el espacio vectorial multidimensional. Un ángulo pequeño indica una alta similitud, mientras que un ángulo grande representa una baja similitud (Kumar, Gupta, Mishra y Prasad, 2015). El ángulo espectral o similitud se determina utilizando la Ecuación (4) (Tembhurne y Malik, 2012; Tang *et al.*, 2015).

$$\theta = \cos^{-1} \left(\frac{(x, r)}{\|x\| \cdot \|r\|} \right) \quad (4)$$

$x, r \in \mathbb{R}^q$, q es el número de la banda, x representa un pixel vector espectral, r representa una referencia de clase vector, (x, r) es el producto escalar de los valores característicos x y r , y $\|\cdot\|$ es el módulo vectorial. El criterio de clasificación asigna al píxel en cuestión la etiqueta de clase que minimiza el ángulo θ definido en la Ecuación (4). **Random forest** (RF). Es una herramienta de regresión y clasificación supervisada con base en aprendizaje automático (*Machine Learning*), la cual es ampliamente utilizada, ya que proporciona los mejores resultados y la mayor precisión para la obtención de información agrícola (Dash, Pearse y Watt, 2018; Zhao *et al.*, 2019). Este método entrena una gran cantidad de árboles de decisión (k) y cada árbol, a su vez, entrena un subconjunto de los datos de entrenamiento obtenidos mediante *bootstrapping* (Chen, Hou, Huang, Zhang, y Li, 2021). El *bootstrapping* es una técnica de re-muestreo estadístico, que implica muestrear aleatoriamente el conjunto de datos con reemplazo (Valbuena, Maltamo y Packalen, 2016). El algoritmo RF requiere solo dos parámetros, m (el número de variables aleatorias o variables predictoras en cada división) y k (el número de árboles de clasificación) (Thanh-Noi y Kappas, 2017). Un árbol de decisión se construye mediante consultas binarias sucesivas sobre los datos de entrenamiento establecidos en subconjuntos (nodos) de homogeneidad creciente. Esta homogeneidad está determinada por el índice de Gini (G), una medida del grado de "impureza" del nodo (Raileanu y Stoffel, 2004). Un valor del índice G igual a cero indica que los datos pertenecen a una sola clase, mientras que un índice mayor que cero y un valor máximo de uno indica nodos donde los datos pertenecen a varias clases (Cortés-Macías *et al.*, 2023). El índice G se determina con la Ecuación (5).

$$G = \sum_{i=1}^c P(i) * (1 - P(i)) \quad (5)$$

C es el número total de clases y P representa la probabilidad de pertinencia de un elemento a la clase i . Para aplicar el algoritmo Random Forest (RF) se utiliza el complemento Semi-Automatic Classification plugin (SCP) versión 7.10.11 (Congedo, 2021), es crucial tener en cuenta los siguientes parámetros: el tamaño de la muestra de entrenamiento (número de píxeles) y la cantidad de árboles de decisión (k). Algunos autores consideran que por defecto el valor óptimo de k es 500 (Thanh-Noi y Kappas, 2017; Rodríguez-Valero y Alonso-Sarria, 2019). Sin embargo, otros autores como Cortés-Macías *et al.* (2023) y Ramírez *et al.* (2020) lograron valores de precisión global más altos con $k = 20$ y con $k = 100$, respectivamente. Por lo tanto, en este trabajo se utilizaron los valores de k de 20 y 100 para la implementación de RF.

Los cuatro algoritmos se desarrollaron con el software de libre acceso QGIS.org (2020) mediante el complemento SCP y la herramienta Region Of Interest (ROI). El software QGIS.org (2020) es un sistema de información geográfica que permite usar formatos ráster y vectoriales, así como una base de datos. Entre sus atribuciones se encuentran: el análisis vectorial y ráster, el muestreo, el geoprocesamiento, la geometría y la gestión de bases de datos. El complemento SCP permite la clasificación supervisada de imágenes multiespectrales de satélites, aeroplanos o drones, cuenta con herramientas para el preprocesamiento y postprocesamiento de imágenes, permite crear áreas de entrenamiento (ROIs), cuenta con algoritmos de clasificación supervisada y no supervisada. Asimismo, permite evaluar la precisión de los resultados de la clasificación.

La clasificación de la cobertura agrícola se realizó a partir de un archivo ráster virtual compuesto por las bandas especificadas en la Cuadro 1. Este archivo permitió la delimitación de polígonos que representan las áreas de entrenamiento para cada clase (regiones de interés o ROIs), y la generación de una firma espectral, característica para cada una. Posteriormente, se utilizó el complemento SCP para clasificar la totalidad de la imagen utilizando las firmas espectrales definidas. Asimismo, con SCP se elaboró la matriz de confusión, utilizando las parcelas de validación de cada clase y los resultados obtenidos de cada algoritmo de clasificación. La matriz es una tabla que muestra el número de instancias de verdad fundamental de una clase particular en comparación con el número de instancias de clase previstas. Esta tabla permite determinar la precisión y concordancia del algoritmo utilizado en la clasificación supervisada.

Evaluación de la Precisión y Concordancia

La precisión de los algoritmos de clasificación supervisada se evaluó al analizar la matriz de confusión (Kohavi y Provost, 1998), que se generó para cada imagen clasificada. La matriz en cuestión contiene datos que representan el valor total o el porcentaje de observaciones y estimaciones para cada característica clasificada. A partir de esta información, es posible calcular los parámetros de evaluación propuestos por Congalton (1991) mencionados en el Cuadro 3.

Para interpretar el valor del índice ($\hat{K}$), Landis y Koch (1977) propusieron utilizar una escala de la fuerza de concordancia, donde valores menores de cero se clasifican como pobres, de 0.01 a 0.20 como leves, de 0.21 a 0.40 como aceptables, de 0.41 a 0.60 moderadas, de 0.61 a 0.80 considerables o buenas, de 0.81 a 1.00 casi perfectas.

La integración de datos de campo, imágenes Sentinel-2 y algoritmos de clasificación supervisada (paramétricos y no paramétricos) permitió identificar, mapear y cuantificar la superficie cultivada con maíz forrajero en los módulos de riego X y XII. El complemento SCP en QGIS.org (2020) facilitó la generación de firmas espectrales y la evaluación del desempeño de los algoritmos, garantizando resultados confiables para cumplir los objetivos del presente estudio.

RESULTADOS Y DISCUSIÓN

Precisión Global e Índice Kappa

En el Cuadro 4 se muestran los valores de P y $\hat{K}$ que se calcularon con todos los algoritmos de clasificación supervisada para cada imagen de Sentinel-2, en las tres fechas de evaluación. El algoritmo RF con un valor de k de 100 árboles de decisión (RF_{100}) destacó como el más eficiente, obtuvo su mejor desempeño el 11 de junio de 2021, donde logró precisiones del 79.1% en el Módulo X y del 87.4% en el Módulo XII. Estos resultados reflejan una clasificación muy confiable, como lo sugieren estudios previos (Alrababah y Alhamad, 2006; Ikiel, Ustaoglu, Dutucu, y Kilic, 2012). Además, el valor estimado de $\hat{K}$ indica una buena concordancia de la clasificación en ambos módulos (Landis y Koch, 1977).

En comparación con otros algoritmos, RF_{100} superó consistentemente a RF con 20 árboles (RF_{20}) y a los métodos paramétricos evaluados. Entre los algoritmos paramétricos, el de MV mostró un desempeño competitivo, con precisión global y valores de $\hat{K}$ superiores a los de los otros métodos de esta categoría. Sin embargo, su rendimiento fue inferior al de RF_{100} , especialmente en el Módulo XII.

Estudios previos concuerdan con estos resultados. Por ejemplo, Ramírez *et al.* (2020) reportaron valores similares de P y $\hat{K}$ al utilizar RF_{100} en imágenes Sentinel-2 para clasificar la cobertura de suelo agrícola. De manera similar, Chen *et al.* (2021) obtuvieron valores de P y $\hat{K}$ cercanos a los estimados en el Módulo X al mapear la superficie de maíz con imágenes multitemporales de Sentinel-2 al emplear el mismo algoritmo RF. Por su parte, Saini y Ghosh (2018) obtuvieron valores de P y $\hat{K}$ parecidos a los del Módulo XII al comparar los métodos de RF y máquinas de vectores de soporte (MVS) para la clasificación de cultivos, también utilizando imágenes Sentinel-2.

Cuadro 3. Parámetros utilizados para la evaluación del desempeño de los algoritmos de clasificación supervisada en el área de estudio.
Table 3. Parameters used for performance evaluation of supervised classification algorithms in the study area.

Parámetro	Unidad	Ecuación	
Precisión Global (P)	(%)	$P = \frac{\sum_{i=1}^m x_{ii}}{N}$	(6)
Precisión del Productor (P_p)	(%)	$P_p = \frac{x_{ii}}{x_{\Sigma i}}$	(7)
Precisión del Usuario (P_u)	(%)	$P_u = \frac{x_{ii}}{x_{i\Sigma}}$	(8)
Índice Kappa ($\hat{K}$)	(Adimensional)	$\hat{K} = \frac{N \sum_{i=1}^m x_{ii} - \sum_{i=1}^m x_{i\Sigma} x_{\Sigma i}}{N^2 - \sum_{i=1}^m x_{i\Sigma} x_{\Sigma i}}$	(9)

m es el número total de clases, N es el número total de píxeles en las m clases de referencia, x_{ii} son los elementos de la diagonal principal de la matriz de confusión, $x_{\Sigma i}$ es la suma de los píxeles de la clase i de referencia, $x_{i\Sigma}$ es la suma de los píxeles clasificados como la clase i .

Cuadro 4. Precisión global (P) e índice Kappa ($\hat{K}$) calculados para los módulos X y XII en las tres fechas de evaluación.
Table 4. Overall precision (P) and Kappa index ($\hat{K}$) calculated for modules X and XII on the three evaluation dates.

Algoritmos	22-May-21				11-Jun-21				26-Jun-21			
	Módulo X		Módulo XII		Módulo X		Módulo XII		Módulo X		Módulo XII	
	P	$\hat{K}$	P	$\hat{K}$	P	$\hat{K}$	P	$\hat{K}$	P	$\hat{K}$	P	$\hat{K}$
DM	26.5	0	69.3	0.51	44.7	0.2	69	0.51	60.5	0.38	67.3	0.46
MV	57.1	0.33	75.6	0.63	75.2	0.58	77.7	0.64	74.9	0.6	71.3	0.51
MAE	32.2	0.09	67.5	0.49	40.4	0.15	68	0.49	42.1	0.14	44.2	0.21
RF, $k = 20$ (RF ₂₀)	62.2	0.36	84.8	0.75	77.9	0.61	85.9	0.77	76.9	0.61	83.5	0.7
RF, $k = 100$ (RF ₁₀₀)	64.3	0.4	86.5	0.78	79.1	0.63	87.4	0.79	77.6	0.62	84	0.71

DM = distancia mínima; MV = máxima verosimilitud; MAE = mapeador de ángulos espectrales; RF₂₀ = random forest con 20 árboles de decisión; RF₁₀₀ = random forest con 100 árboles de decisión.

DM = minimum distance; MV = maximum likelihood; MAE = spectral angle mapper; RF₂₀ = random forest with 20 decision trees; RF₁₀₀ = random forest with 100 decision trees.

Por otra parte, Guerschman, Paruelo, Bella, Giallorenzi y Pacin, *et al.* (2003) obtuvieron valores similares de P y $\hat{K}$ al clasificar las 14 clases de cobertura de suelo, incluidos maíz y soya, al utilizar imágenes Landsat TM con el algoritmo MV. Por otro lado, estudios posteriores han reportado valores de P superiores al 80% al clasificar los tipos de cobertura del suelo con el mismo clasificador MV e imágenes satelitales Landsat TM (Argañaraz y Entraigas, 2011) y Landsat 8 (Mahmon, Ya'acob y Yusof, 2015).

En términos generales, los valores más altos de P y $\hat{K}$ se registraron el 11 de junio de 2021. Esto sugiere que las condiciones de captura de la imagen y la etapa fenológica de los cultivos pueden influir significativamente en la precisión de la clasificación. Estos resultados resaltan la robustez del algoritmo RF₁₀₀ con 100 árboles de decisión (k) frente a alternativas paramétricas y no paramétricas.

Matriz de Confusión y Precisiones de Productor y Usuario de RF₁₀₀

El Cuadro 5 muestra la matriz de confusión del algoritmo RF₁₀₀ para el Módulo X, del día 11 de junio de 2021. La Clase 1 (Maíz forrajero) presentó una precisión de usuario (P_u) del 90.5%, lo que indica que el 100% de los píxeles clasificados como maíz forrajero fueron etiquetados correctamente, aunque 9.5% fueron erróneamente clasificados como Clase 2 (Otros cultivos) y ninguno fue identificado como Clase 3 (Vacante). En cuanto a la precisión de productor (P_p), esta fue del 75.4%, lo que implica que el 75.4% del total de los píxeles que fueron referenciados como maíz forrajero se clasificaron correctamente como maíz, el 17.7% como otros cultivos y el 6.9% como vacante.

Por otro lado, la Clase 3 tuvo la menor P_u ya que del total de píxeles clasificados como Vacante el 32.8% fueron confundidos con Maíz forrajero y el 38.0% como Otros cultivos. Este nivel de error afectó significativamente la precisión global (P) del algoritmo de clasificación, que fue del 79.1 por ciento.

El Cuadro 6 muestra la matriz de confusión para RF₁₀₀ aplicado al Módulo XII el mismo día (11 de junio de 2021). El Maíz forrajero reportó una P_u del 90.3 % y una P_p del 90.1%, indicando que 90% de los píxeles fueron clasificados y referenciados correctamente como maíz forrajero. La Clase 2 tuvo el valor de P_p más bajo, debido a que 21.2% de los píxeles referenciados como Otros cultivos fueron confundidos con Maíz forrajero, y el 8.4% fueron clasificados como Vacante.

Interpretación de los Resultados de la Clasificación

De acuerdo con los resultados de las matrices de confusión de los Cuadros 4 y 5, la Clase 1 (Maíz forrajero) mostró valores altos de P_u y P_p cercanos al 90% en ambos módulos, con excepción de la P_p para el Módulo X, donde fue del 75.4%. La mejor precisión de P_p se logró para el Maíz forrajero debido a las marcadas diferencias espectrales con respecto a las otras dos clases en la fecha de clasificación (11 de junio de 2021), ya que el maíz se encontraba entre las etapas fenológicas de panojamiento (V_1) y grano lechoso (R_3). En contraste, los otros cultivos

Cuadro 5. Matriz de confusión del algoritmo Random Forest (RF) con 100 árboles de decisión (k = 100) para el módulo X (día 11 de junio de 2021).**Table 5. Confusion matrix of the Random Forest (RF) algorithm with 100 decision trees (k = 100) for module X (June 11, 2021).**

Datos de Clasificación	Datos de Referencia				
	Clase 1	Clase 2	Clase 3	Total	P _u
Clase 1	7554	790	0	8344	90.5
Clase 2	1770	7315	24	9109	80.3
Clase 3	694	805	620	2119	29.3
Total	10 018	8910	644	19 572	
P _p	75.4	82.1	96.3		

Clase 1 = maíz forrajero; Clase 2 = otros cultivos; Clase 3 = vacante (suelo denudo); P_u = precisión de usuario; P_p = precisión del productor.
 Class 1 = forage maize; Class 2 = other crops; Class 3 = vacant (bare soil); P_u = user precision; P_p = producer precision.

(Clase 2), como el sorgo forrajero, se encontraban en buche (bota) o en grano lechoso - masoso; el algodón en floración y el nogal en desarrollo del fruto. Durante la etapa reproductiva, los cultivos sufren cambios en las propiedades ópticas (cambios en su coloración), que alteran su respuesta espectral (Paz-Pellat, Casiano, Zarco y Bolaños, 2013); situación que favoreció la separación entre las clases en esta fecha.

Además, las diferencias en la cobertura del suelo de los cultivos contribuyeron a su separación. El maíz forrajero, que alcanzó un valor del índice de área foliar (IAF) de 5, tiene una mayor cobertura que los otros cultivos (Montemayor-Trejo *et al.*, 2012; Delgado-Ramírez *et al.*, 2023), que facilitó su diferenciación en las imágenes satelitales. Por el contrario, la baja precisión de P_p en el Módulo X se debió a la confusión entre las Clases 1 y 2, ya que sus respuestas espectrales son muy similares en esa fecha de clasificación. El valor de P_u para la Clase 1 en ambos módulos de riego reveló la clasificación del maíz forrajero fue la más confiable.

Algunos autores han reportado valores similares de P_u para clasificar el maíz forrajero al utilizar el algoritmo RF y datos de imágenes satelitales Sentinel-2, con bandas de resolución espacial de 10 y 20 m (Akbari *et al.*, 2020). Incluso, Abubakar *et al.* (2020) lograron valores de P_u y P_p superiores al 90% al mapear campos de maíz.

Mapas de Cultivos Generados

La Figura 2 muestra el mapa de clasificación de cultivos para el Módulo X generado con el algoritmo RF₁₀₀. Los valores más altos de P (79.1) y R (0.63) se obtuvieron con este clasificador, en la fecha de evaluación del 11 de junio de 2021 (día juliano 162). El algoritmo RF₁₀₀ clasificó el 46.5% de la superficie del módulo como maíz forrajero, el 43.3% como otros cultivos (sorgo forrajero, nogal, algodón y alfalfa) y el 10.2% como vacante.

Cuadro 6. Matriz de confusión del algoritmo Random Forest (RF) con 100 árboles de decisión (k = 100) para el módulo XII (día 11 de junio de 2021).**Table 6. Confusion matrix of the Random Forest (RF) algorithm with 100 decision trees (k = 100) for module XII (June 11, 2021).**

Datos de Clasificación	Datos de Referencia				
	Clase 1	Clase 2	Clase 3	Total	P _u
Clase 1	8277	893	0	9170	90.3
Clase 2	411	2967	65	3443	86.2
Clase 3	494	355	4075	4924	82.8
Total	9182	4215	4140	17 537	
P _p	90.1	70.4	98.4		

Clase 1 = maíz forrajero; Clase 2 = otros cultivos; Clase 3 = vacante (suelo denudo); P_u = precisión de usuario; P_p = precisión del productor.
 Class 1 = forage corn; Class 2 = other crops; Class 3 = vacant (bare soil); P_u = user precision; P_p = producer precision.




Figura 2. Superficie de cultivo del Módulo X del DR 017 del ciclo PV 2021 (imagen satelital del 11 de junio de 2021): a) Mapa de composición de falso color infrarrojo con las bandas 8, 4 y 3 del satélite Sentinel-2, y b) Mapa de clasificación de cultivos generado por el algoritmo RF con 100 árboles de decisión (k).

Figure 2. Crop area of Module X of ID 017 of SS cycle 2021 (satellite image of June 11, 2021): a) False color infrared composition map with Sentinel-2 satellite bands 8, 4 and 3, and b) Crop classification map generated by RF algorithm with 100 decision trees (k).

La Figura 3 muestra el mapa de clasificación de cultivos con tres clases para el Módulo XII del DR 017. Este mapa se generó con el algoritmo RF_{100} , el cual alcanzó valores de precisión global (P) de 87.4 e índice Kappa (K) de 0.79 para la misma fecha (11 de junio de 2021). El RF_{100} clasificó el 43.9% de la superficie total como maíz forrajero, el 38.6% de otros cultivos (sorgo forrajero y nogal) y el 17.5% de áreas vacantes.




Figura 3. Superficie de cultivo del Módulo XII del DR 017 del ciclo PV 2021 (imagen satelital del 11 de junio de 2021): a) Mapa de composición de falso color infrarrojo con las bandas 8, 4 y 3 del satélite Sentinel-2 y b) Mapa de clasificación de cultivos generado por el algoritmo RF con 100 árboles de decisión (k).

Figure 3. Crop area of Module XII of ID 017 of SS cycle 2021 (satellite image of June 11, 2021): a) False color infrared composition map with Sentinel-2 satellite bands 8, 4 and 3 and b) Crop classification map generated by RF algorithm with 100 decision trees (k).

Se confirma que el maíz forrajero es el cultivo dominante en términos de superficie cultivada en los módulos X y XII, que representan aproximadamente 45% del área total. Al comparar los cuatro algoritmos de clasificación supervisada utilizando imágenes Sentinel-2, el algoritmo RF con 100 árboles de decisión presentó el mejor rendimiento, que permitió identificar y mapear de manera confiable el maíz forrajero. Esta información puede facilitar la toma de decisiones en la gestión del agua a diferentes escalas, desde las unidades de producción, de los módulos o del distrito de riego.

CONCLUSIONES

El presente estudio demostró la efectividad de los algoritmos de clasificación supervisada, con base en la información espectral contenida en imágenes de los satelitales Sentinel-2, que permitieron identificar el cultivo de maíz forrajero en los módulos de riego X y XII del distrito de riego 017, Región Lagunera. De los cuatro algoritmos evaluados, Random Forest con un parámetro k de 100 árboles de decisión mostró el mejor rendimiento, al alcanzar los valores más altos de precisión global e índice Kappa en ambos módulos de riego, lo que resalta su robustez frente a alternativas paramétricas y no paramétricas. El Módulo X presentó valores de precisión global de 79.1% e índice Kappa de 0.63, mientras que en el Módulo XII se registraron valores del 87.4% de precisión global y 0.79 de índice Kappa.

La imagen del 11 de junio de 2021 permitió obtener las mayores precisiones, debido a que la fenología del maíz forrajero y las diferencias en la cobertura vegetal entre los cultivos facilitaron su discriminación, siendo el maíz forrajero el que tuvo la mayor cobertura del suelo. Los resultados mostraron que la clasificación del maíz forrajero fue la más confiable en comparación con las demás clases evaluadas.

Además, se cuantificó una superficie irrigada de 3461.47 ha en el módulo X y 3360.86 ha en el módulo XII durante el ciclo primavera-verano de 2021, valores que superaron ampliamente la superficie programada en ambos módulos de riego. La identificación precisa del maíz forrajero, tanto en el espacio como en el tiempo, permite la creación de inventarios confiables y actualizados, lo que contribuye significativamente a mejorar la toma de decisiones en la planificación y manejo del cultivo, así como en la gestión eficiente de los recursos hídricos.

DECLARACIÓN DE ÉTICA

No aplicable.

CONSENTIMIENTO PARA PUBLICACIÓN

No aplicable.

DISPONIBILIDAD DE DATOS

Los conjuntos de datos generados o analizados durante el estudio actual no están disponibles públicamente debido a regulaciones institucionales, pero 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, diseño y metodología: G.D.R. y M.A.B.G. Redacción e investigación: G.D.R. Revisión y edición: M.A.B.G., A.Q.N., A.L.P. y J.E.A. Preparación del borrador original: G.D.R., M.A.B.G., A.Q.N., A.L.P. y J.E.A.

AGRADECIMIENTOS

Al CONAHCYT por la beca recibida al primer autor. Al INIFAP (CENID-RASPA) por el apoyo recibido en el desarrollo de la presente investigación.

LITERATURA CITADA

- Abburu, S., & Golla, S. B. (2015). Satellite image classification methods and techniques: a review. *International Journal of Computer Applications*, 119(8), 20-25. <https://doi.org/10.5120/21088-3779>
- Abubakar, G. A., Wang, K., Shahtahmssebi, A., Xue, X., Belete, M., Gudo, A. J. A., ... & Gan, M. (2020). mapping maize fields by using multi-temporal sentinel-1a and sentinel-2a images in makarfi, northern nigeria, africa. *Sustainability*, 12(6), 2539. <https://doi.org/10.3390/su12062539>
- Aguilar-Rivera, N., Galindo-Mendoza, G., & Fortanelli-Martínez, J. (2012). Evaluación agroindustrial del cultivo de caña de azúcar (*Saccharum officinarum* L.) mediante imágenes SPOT 5 HRV en la huasteca México. *Revista de la Facultad de Agronomía*, 111(2), 64-74.
- Akbari, E., Darvishi-Bolloorani, A., Neysani-Samany, N., Hamzeh, S., Soufizadeh, S., & Pignatti, S. (2020). Crop mapping using random forest and particle swarm optimization based on multi-temporal sentinel-2. *Remote Sensing*, 12(9), 1449. <https://doi.org/10.3390/rs12091449>
- Alrababah, M. A., & Alhamad, M. N. (2006). Land use/cover classification of arid and semi-arid mediterranean landscapes using landsat ETM. *International Journal of Remote Sensing*, 27(13), 2703-2718. <https://doi.org/10.1080/01431160500522700>
- Altamirano, H. L., Rubio, A. P., López, D. H., & Guerra, O. E. (2020). Clasificación de coberturas terrestres: métodos supervisados y no-supervisados aplicados a cultivos de caña de azúcar. *Tectapic: Revista Académico-Científica*, 6(2), 59-70.
- Argañaraz, J. P., & Entraigas, I. (2011). Análisis comparativo entre las máquinas de vectores soporte y el clasificador de máxima probabilidad para la discriminación de cubiertas del suelo. *Revista de Teledetección*, 36, 26-39.
- Atzberger, C. (2013). Advances in Remote Sensing of Agriculture: context description, existing operational monitoring systems and major information needs. *Remote Sensing*, 5(2), 949-981. <https://doi.org/10.3390/rs5020949>
- Avogadro, E. G., & Padró-García, J. C. (2019). Comparación de métodos de clasificación aplicados a imágenes sentinel-2 y landsat-8, para la diferenciación de plantaciones forestales entre ríos, argentina. *GeoFocus Revista Internacional de Ciencia y Tecnología de La Información Geográfica*, 24, 117-139. <https://doi.org/10.21138/gf.652>
- Chen, Y., Hou, J., Huang, C., Zhang, Y., & Li, X. (2021). Mapping maize area in heterogeneous agricultural landscape with multi-temporal sentinel-1 and sentinel-2 images based on random forest. *Remote Sensing*, 13(15), 2988. <https://doi.org/10.3390/rs13152988>
- Chowdhury, M., Hasan, M. E., & Abdullah-Al-Mamun, M. M. (2020). Land use/land cover change assessment of halda watershed using remote sensing and GIS. *The Egyptian Journal of Remote Sensing and Space Science*, 23(1), 63-75. <https://doi.org/10.1016/j.ejrs.2018.11.003>
- Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1), 35-46. [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B)
- Congedo, L. (2021). Semi-automatic classification plugin: a python tool for the download and processing of remote sensing images in QGIS. *Journal of Open Source Software*, 6(64), 1-6. <https://doi.org/10.21105/joss.03172>
- Cortés-Macias, L. Z., Rivera-Caicedo, J. P., Cepeda-Morales, J., Hernández-Almeida, Ó. U., García-Morales, R., & Velarde-Alvarado, P. (2023). Análisis espacio-temporal de florecimientos algales nocivos en un lago-cráter tropical usando datos MODIS (2003-2020). *Revista de Teledetección*, 62, 39-55. <https://doi.org/10.4995/raet.2023.19673>
- Copernicus Programme (2024). Copernicus Open Access Hub. Consultado el 17 de noviembre, 2023, desde <https://scihub.copernicus.eu/>
- Dash, J., Pearce, G., & Watt, M. (2018). UAV Multispectral imagery can complement satellite data for monitoring forest health. *Remote Sensing*, 10(8), 1-22. <https://doi.org/10.3390/rs10081216>
- Delgado-Ramírez, G., Bolaños-González, M. A., Quevedo-Nolasco, A., López-Pérez, A., & Estrada-Ávalos, J. (2023). Estimating the crop coefficient of forage maize using remote sensing. *Ingeniería Agrícola y Biosistemas*, 15(1), 17-35. <https://doi.org/10.5154/r.inagbi.2022.09.075>
- ESA (European Space Agency). (2012). Sentinel-2 ESA's Optical High-Resolution Mission for GMES Operational Services. Consultado el 17 de noviembre, 2023, desde https://sentinel.esa.int/documents/247904/349490/s2_sp-1322_2.pdf
- ESA (European Space Agency). (2015). Sentinel-2 User Handbook. Consultado el 30 de noviembre, 2023, desde https://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook
- Ghayour, L., Neshat, A., Paryani, S., Shahabi, H., Shirzadi, A., Chen, W., ... & Ahmad, A. (2021). Performance evaluation of sentinel-2 and landsat 8 oli data for land cover/use classification using a comparison between machine learning algorithms. *Remote Sensing*, 13(7), 1-21. <https://doi.org/10.3390/rs13071349>
- Gilabert, M. A., González-Piqueras, J., & García-Haro, J. (1997). Acerca de los índices de vegetación. *Revista de Teledetección*, 8(1), 1-10.
- González-Castañeda, F., Peña-Ramos, A., Núñez-Hernández, G., & Jiménez-González, C. A. (2005). Efecto de la densidad y altura de corte en el rendimiento y calidad del forraje de maíz. *Revista Fitotecnica Mexicana*, 28(4), 393-397. <https://doi.org/10.35196/rfm.2005.4.393>
- Guerschman, J. P., Paruelo, J. M., Bella, C. D., Giallorenzi, M. C., & Pacin, F. (2003). Land cover classification in the Argentine pampas using multi-temporal landsat tm data. *International Journal of Remote Sensing*, 24(17), 3381-3402. <https://doi.org/10.1080/0143116021000021288>
- Herbei, M. V., Sala, F., & Boldea, M. (2015). Using mathematical algorithms for classification of landsat 8 satellite images. In *AIP Conference Proceedings*, 1648(1), 670004. <https://doi.org/10.1063/1.4912899>
- Hubert-Moy, L., Cotonnec, A., Le, D. L., Chardin, A., & Perez, P. (2001). A comparison of parametric classification procedures of remotely sensed data applied on different landscape units. *Remote Sensing of Environment*, 75(2), 174-187. [https://doi.org/10.1016/S0034-4257\(00\)00165-6](https://doi.org/10.1016/S0034-4257(00)00165-6)
- Ikiel, C., Ustaoglu, B., Dutucu, A. A., & Kilic, D. E. (2012). Remote sensing and GIS-based integrated analysis of land cover change in duzce plain and its surroundings (north western Turkey). *Environmental Monitoring and Assessment*, 185, 1699-1709. <https://doi.org/10.1007/s10661-012-2661-6>
- INEGI. (Instituto Nacional de Estadística y Geografía). (2013). Continuo de elevaciones mexicano (CEM 3.0), Coahuila. Consultado el 19 de julio, 2023, desde <https://www.inegi.org.mx/app/geo2/elevacionesmex/>
- INEGI. (Instituto Nacional de Estadística y Geografía). (2013). Continuo de elevaciones mexicano (CEM 3.0), Durango. Consultado el 27 de diciembre, 2023, desde <https://www.inegi.org.mx/app/geo2/elevacionesmex/>
- Keuchel, J., Naumann, S., Heiler, M., & Siegmund, A. (2003). Automatic land cover analysis for tenerife by supervised classification using remotely sensed data. *Remote Sensing of Environment*, 86(4), 530-541. [https://doi.org/10.1016/s0034-4257\(03\)00130-5](https://doi.org/10.1016/s0034-4257(03)00130-5)
- Kohavi, R., & Provost, F. (1998). Glossary of terms. *Machine Learning*, 30, 271-274. <https://doi.org/10.1023/A:1017181826899>

- Kuhn, C., de Matos Valerio, A., Ward, N., Loken, L., Sawakuchi, H. O., Kampel, M., ... & Butman, D. (2019). Performance of landsat-8 and sentinel-2 surface reflectance products for river remote sensing retrievals of chlorophyll-a and turbidity. *Remote Sensing of Environment*, 224, 104-118. <https://doi.org/10.1016/j.rse.2019.01.023>
- Kumar, P., Gupta, D. K., Mishra, V. N., & Prasad, R. (2015). Comparison of support vector machine, artificial neural network, and spectral angle mapper algorithms for crop classification using LISS IV data. *International Journal of Remote Sensing*, 36(6), 1604-1617. <https://doi.org/10.1080/2150704x.2015.1019015>
- Kussul, N., Lemoine, G., Gallego, F. J., Skakun, S. V., Lavreniuk, M., & Shelestov, A. Yu. (2016). Parcel-based crop classification in ukraine using landsat-8 data and sentinel-1a data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(6), 2500-2508. <https://doi.org/10.1109/jstars.2016.2560141>
- Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33(1), 159-174. <https://doi.org/10.2307/2529310>
- Leroux, L., Congedo, L., Bellón, B., Gaetano, R., & Bégué, A. (2018). Land cover mapping using sentinel-2 images and the semi-automatic classification plugin: a northern burkina faso case study. En N. Baghdadi, C. Mallet, M. Zribi, (Eds.). *QGIS and applications in agriculture and forest*, 2, (pp. 119-151). Hoboken, NJ, USA: John Wiley & Sons. <https://doi.org/10.1002/9781119457107.ch4>
- Li, D., Ke, Y., Gong, H., & Li, X. (2015). Object-based urban tree species classification using bi-temporal worldview-2 and worldview-3 images. *Remote Sensing*, 7(12), 16917-16937. <https://doi.org/10.3390/rs71215861>
- Mahmon, N. A., Ya'acob, N., & Yusof, A. L. (2015). Differences of image classification techniques for land use and land cover classification. En 2015 IEEE 11th International Colloquium on Signal Processing & Its Applications (CSPA) (pp. 90-94). Kuala Lumpur, Malasia: IEEE. <https://doi.org/10.1109/CSPA.2015.7225624>
- Makandar, A., & Kaman, S. (2021). Land use land cover study of sentinel-2a and landsat-5 images using NDVI and supervised classification techniques. *Computational Intelligence and Machine Learning*, 2(2), 20-29. <https://doi.org/10.36647/ciml/02.02.a003>
- Mohamed, E. S., Belal, A., & Shalaby, A. (2015). Impacts of soil sealing on potential agriculture in egypt using remote sensing and GIS techniques. *Eurasian Soil Science*, 48, 1159-1169. <https://doi.org/10.1134/s1064229315100075>
- Mondal, A., Kundu, S., Chandniha, S. K., Shukla, R., & Mishra, P. K. (2012). Comparison of support vector machine and maximum likelihood classification technique using satellite imagery. *International Journal of Remote Sensing and GIS*, 1(2), 116-123.
- Montemayor-Trejo, J. A., Lara-Mireles, J. L., Woo-Reza, J. L., Munguía-López, J., Rivera-González, M., & Trucíos-Caciano, R. (2012). Producción de maíz forrajero (*Zea mays* L.) en tres sistemas de irrigación en la Comarca Lagunera de Coahuila y Durango México. *Agrociencia*, 46(3), 267-278.
- Murray, R., & Larry, J. (2009). Estadística (4.ª ed.). México, D.F.: McGraw-Hill.
- Otukei, J. R., & Blaschke, T. (2010). Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms. *International Journal of Applied Earth Observation and Geoinformation*, 12(1), 27-31. <https://doi.org/10.1016/j.jag.2009.11.002>
- Paz-Pellat, F., Casiano-Domínguez, M., Zarco-Hidalgo, A., & Bolaños-González, M. (2013). Estimación de las propiedades ópticas de la vegetación usando medios radiativos equivalentes y espacios n-paramétricos. *Terra Latinoamericana*, 31(2), 119-134.
- Petropoulos, G. P., Vadrevu, K. P., Xanthopoulos, G., Karantounias, G., & Scholze, M. (2010). A comparison of spectral angle mapper and artificial neural network classifiers combined with Landsat TM imagery analysis for obtaining burnt area mapping. *Sensors*, 10(3), 1967-1985. <https://doi.org/10.3390/s100301967>
- QGIS.org (2020). *QGIS Geographic Information System. User's Guide. Version 3.16.5*. Grüt, Switzerland: QGIS Association.
- Raileanu, L. E., & Stoffel, K. (2004). Theoretical comparison between the gini index and information gain criteria. *Annals of Mathematics and Artificial Intelligence*, 41, 77-93. <https://doi.org/10.1023/b:amai.0000018580.96245.c6>
- Ramírez, M., Martínez, L., Montilla, M., Sarmiento, O., Lasso, J., & Díaz, S. (2020). Obtención de coberturas del suelo agropecuarias en imágenes satelitales Sentinel-2 con la inyección de imágenes de dron usando Random Forest en Google Earth Engine. *Revista de Teledetección*, 56, 49-68. <https://doi.org/10.4995/raet.2020.14102>
- Reyes-González, A., Zavala-Borrego, F., de Paul, V., Cano-Ríos, P., & Rodríguez-Moreno, V. M. (2022). Efecto de la tasa de evapotranspiración en área foliar, potencial hídrico y rendimiento de maíz forrajero. *Revista Mexicana de Ciencias Agrícolas*, 13(3), 407-420. <https://doi.org/10.29312/remexca.v13i3.2294>
- Richards, J. A. (1999). *Remote sensing digital image analysis* (4th ed.). Berlin, Germany: Springer-Verlag.
- Rodríguez-Valero, M. I., & Alonso-Sarria, F. (2019). Clasificación de imágenes Landsat-8 en la demarcación hidrográfica del segura. *Revista de Teledetección*, 53, 33-44. <https://doi.org/10.4995/raet.2019.11016>
- Rolando, A., D'Uva, D., & Scandiffio, A. (2023). The role of semi-automatic classification techniques for mapping landscape components: The case study of Tratturo Magno in Molise region. En R. Stouffs, S. Sariyildiz, I. Österreicher, & A. Nagy (Eds.). *Beyond digital representation: Digital innovations in architecture, engineering and construction* (pp. 549-562). Cham, Switzerland: Springer. https://doi.org/10.1007/978-3-031-36155-5_35
- Rouse, J. W., Jr., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). *Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation*. Greenbelt, MD, USA: NASA Goddard Space Flight Center.
- Rujoiu-Mare, M. R., & Mihai, B. A. (2016). Mapping Land Cover Using Remote Sensing Data and GIS Techniques: A Case Study of Prahova Subcarpathians. *Procedia Environmental Sciences*, 32, 244-255. <https://doi.org/10.1016/j.proenv.2016.03.029>
- 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), 611-622. <https://doi.org/10.4236/ijg.2017.84033>
- Saini, R., & Ghosh, S. K. (2018). Crop Classification on Single Date Sentinel-2 Imagery Using Random Forest and Support Vector Machine. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-5, 683-688. <https://doi.org/10.5194/isprs-archives-xlii-5-683-2018>
- Sathya, P., & Deepa, V. B. (2017). Analysis of supervised image classification method for satellite images. *International Journal of Computer Science Research (IJCSR)*, 5(2), 16-19.
- SIAP (Servicio de Información Agroalimentaria y Pesquera). (2023). *Población ganadera 2013-2022. Bovino para leche*. Consultado el 5 de enero, 2024, desde https://nube.siap.gob.mx/poblacion_ganadera/
- Snyder, R. (1985). Hand calculating degree days. *Agricultural and Forest Meteorology*, 35(1-4), 353-358. [https://doi.org/10.1016/0168-1923\(85\)90095-4](https://doi.org/10.1016/0168-1923(85)90095-4)
- Song, X. P., Huang, W., Hansen, M. C., & Potapov, P. (2021). An evaluation of Landsat, Sentinel-2, Sentinel-1 and MODIS data for crop type mapping. *Science of Remote Sensing*, 3, 100018. <https://doi.org/10.1016/j.srs.2021.100018>
- Talukdar, S., Singha, P., Mahato, S., Shahfahad, Pal, S., Liou, Y. A., & Rahman, A. (2020). Land-use land-cover classification by machine learning

- classifiers for satellite observations-a review. *Remote Sensing*, 12(7), 1135. <https://doi.org/10.3390/rs12071135>
- Tang, B., Liu, Z., Xiao, X., Nie, M., Chang, J., Jiang, W., ... & Zheng, C. (2015). Spectral-spatial hyperspectral classification based on multi-center SAM and MRF. *Optical Review*, 22(6), 911-918. <https://doi.org/10.1007/s10043-015-0139-9>
- Tembhurne, O. W., & Malik, L. G. (2012). Hybrid classification using combination of optimized spectral angle mapping algorithm and interpolation method on multispectral and hyper spectral image. In *2012 International Conference on Computing, Communication and Applications*. (pp. 1-4). Dindigul, India: IEEE. <https://doi.org/10.1109/iccca.2012.6179210>
- Thanh-Noi, P., & Kappas, M. (2017). Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using Sentinel-2 Imagery. *Sensors*, 18(18), 1-20. <https://doi.org/10.3390/s18010018>
- Topaloğlu, R. H., Sertel, E., & Musaoğlu, N. (2016). Assessment of classification accuracies of Sentinel-2 and Landsat-8 data for land cover/ use mapping. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLI-B8*, 1055-1059. <https://doi.org/10.5194/isprsarchives-xli-b8-1055-2016>
- Valbuena, R., Maltamo, M., & Packalen, P. (2016). Classification of forest development stages from national low-density lidar datasets: a comparison of machine learning methods. *Revista de Teledetección*, 45, 15-25. <https://doi.org/10.4995/raet.2016.4029>
- Vincent, M. J., Varalakshmi, P., Nithya, U., Sona, S., & Thomas, A. M. (2022). Land use land cover change detection using semi-automatic classification- a case study in chennai, tiruvallur and kanchipuram districts. En *2022 International Conference on Data Science, Agents & Artificial Intelligence (ICDSAAI)*, (pp. 1-6). Chennai, India: IEEE. <https://doi.org/10.1109/icdsaaai55433.2022.10028962>
- Weng, Q. (2012). Remote sensing of impervious surfaces in the urban areas: Requirements, methods, and trends. *Remote Sensing of Environment*, 117, 34-49. <https://doi.org/10.1016/j.rse.2011.02.030>
- Wieland, M., & Pittore, M. (2014). Performance Evaluation of Machine Learning Algorithms for Urban Pattern Recognition from Multi-spectral Satellite Images. *Remote Sensing*, 6(4), 2912-2939. <https://doi.org/10.3390/rs6042912>
- Zhao, L., Shi, Y., Liu, B., Hovis, C., Duan, Y., & Shi, Z. (2019). Finer classification of crops by fusing UAV images and sentinel-2a data. *Remote Sensing*, 11(24), 1-17. <https://doi.org/10.3390/rs11243012>