

Estimación de Cosecha de Maíz Forrajero (*Zea mays* L.) Mediante Índices Espectrales Derivados de LANDSAT-8 y SENTINEL-2 Harvest Estimation of Forage Corn (*Zea mays* L.) by Means of Spectral Indices Derived from LANDSAT-8 and SENTINEL-2

Bonifacio Cano-Mejía¹ , Ricardo D. Valdez-Cepeda² y
Armando López-Santos^{1*}

¹ Universidad Autónoma Chapingo, Unidad Regional Universitaria de Zonas Áridas. Carretera Gómez Palacio-Chihuahua km 40. 35230 Bermejillo, Durango, México; (B.C.M.), (A.LS).

*Autor para correspondencia: alopez@chapingo.uruza.edu.mx

² Universidad Autónoma Chapingo, Centro Regional Universitario Centro-Norte. Calle Cruz del Sur No. 100, Col. Constelación. Apdo. Postal 196. 98085 El Orto, Zacatecas, México; (R.D.V.C.).

RESUMEN

La estimación de cosecha basada en índices espectrales conforma un elemento de decisión importante para quienes participan en la actividad agrícola; sin embargo, muchas interrogantes sobre su utilidad aún persisten. Los objetivos de esta investigación fueron: 1) relacionar propiedades radiativas del maíz forrajero (MF) y producción de biomasa mediante imágenes LANDSAT-8 y SENTINEL-2; y 2) seleccionar el índice de vegetación (IV) con mejor desempeño que permita modelar el rendimiento del MF para condiciones similares. El estudio se realizó en el ciclo PV-2019 con mediciones morfológicas en distintas etapas de crecimiento del MF y mediante muestreos aleatorios destructivos a los 72 dds para determinar magnitud de biomasa en laboratorio; los datos de biomasa se relacionaron con valores de reflectancia e IV de LANDSAT-8 y SENTINEL-2 para estimar rendimiento mediante regresión lineal múltiple; ocho IV (NDVI, TVI TTVI, RDVI, RVI, RATIO, SAVI, MSAVI2) se evaluaron mediante evaluaciones cruzadas con base en estadísticos clave. Los resultados del análisis de regresión múltiple indicaron que el mejor modelo ($R^2 = 0.66$) se obtuvo con datos de imágenes SENTINEL-2 a partir de las bandas 3 ($\alpha_3 = 0.54-0.57 \mu\text{m}$) y 8 ($\alpha_8 = 0.78-0.90 \mu\text{m}$) con estimadores β_i muy significativos ($P < 0.05$); RDVI presentó el mejor desempeño debido a una buena relación espacial entre los valores digitales ráster y la producción de biomasa verde producida con una asociación del 75.41%; en tanto que los indicadores estadísticos fueron $R^2 = 0.75$ y $CME = 17$; con ambos recursos (Modelos de Regresión Múltiple e IV) se pronosticó el rendimiento a los 72 dds en un rango de 10.7 - 57.01 Mg ha⁻¹. La conclusión es que SENTINEL-2 superó a LANDSAT-8 como herramienta libre para la evaluación de cultivos y estimación de biomasa debido a una mejor resolución espacial y temporal.

Palabras clave: biomasa, fenología de cultivo, índices de vegetación, rendimiento, teledetección.



Cita recomendada:

Cano-Mejía, B., Valdez-Cepeda, R. D., & López-Santos, A. (2023). Estimación de Cosecha de Maíz Forrajero (*Zea mays* L.) Mediante Índices Espectrales Derivados de LANDSAT-8 y SENTINEL-2. *Terra Latinoamericana*, 41, 1-15. e1696. <https://doi.org/10.28940/terra.v41i0.1696>

Recibido: 28 de febrero de 2023.

Aceptado: 15 de junio de 2023.

Artículo. Volumen 41.

Octubre de 2023.

Editor de Sección:

Dr. Fernando Ayala Niño

Editor Técnico:

Dr. David Cristóbal Acevedo



Copyright: © 2023 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/>).

SUMMARY

Crop yield estimation based on spectral indices is crucial for decision-making in agricultural activities; however, questions regarding their usefulness persist. The aims of our research were: 1) to relate the radiative properties of forage corn (FC) and biomass production using LANDSAT-8 and SENTINEL-2 images; and 2) to select the best-performing vegetation index (VI) to model FC yield under similar conditions. The study was conducted along the PV-2019 cycle with morphological measurements at

different FC growth stages and with destructive random sampling at 72 dds to determine biomass magnitude in the laboratory. Biomass data were then related to reflectance values and VI's from LANDSAT-8 and SENTINEL-2 to estimate yield through multiple linear regression. Eight VI's (NDVI, TVI, TTVI, RDVI, RVI, RATIO, SAVI, MSAVI2) were evaluated through cross-evaluations based on key statistics. The results of multiple regression analysis indicated that the best model ($R^2 = 0.66$) was obtained with SENTINEL-2 image data from bands 3 ($\alpha_3 = 0.54\text{-}0.57 \mu\text{m}$) and 8 ($\alpha_8 = 0.78\text{-}0.90 \mu\text{m}$) with highly significant β_i estimators ($P < 0.05$). Moreover, RDVI showed the best performance due to a good spatial relationship between raster digital values and green biomass yield produced with an association of 75.41%, the statistical indicators were $R^2 = 0.75$ and $\text{CME} = 17$. Yield at 72 dds was predicted both with Multiple Regression Models and VI's in a range of 10.7 - 57.01 Mg ha⁻¹. In conclusion, SENTINEL-2 outperformed LANDSAT-8 as a free tool for crop assessment and biomass estimation due to its better spatial and temporal resolution.

Index words: biomass, crop phenology, vegetation indices, yield, remote sensing.

INTRODUCCIÓN

En México, el Maíz Forrajero (MF) cubrió 4% de la superficie total dedicada a la producción de alimentos en años recientes (2015-2020) (SADER, 2023); en la Comarca Lagunera (CL), y otras regiones similares, el MF se ha convertido en la base de la industria lechera nacional (Navarrete-Molina *et al.*, 2019; Granados-Niño *et al.*, 2022); por ejemplo, en el ciclo agrícola PV-2020 este forraje fue cultivado en cerca de 50 mil hectáreas lo que representó el 48% de la superficie total de la CL (SIAP, 2021).

Para la agricultura en general, una estimación de cosecha rápida, confiable y de bajo costo es importante debido a sus implicaciones estadísticas, técnicas y económicas (Ali *et al.*, 2022; Son, Chen y Chen, 2022). En este sentido, las imágenes de satélite de acceso abierto de los proyectos de monitoreo terrestre como LANDSAT-8 y SENTINEL-2 ofrecen, a los actores que intervienen en la actividad agrícola (productor, asesores técnicos, agencias de crédito y seguro), la posibilidad de incorporar nuevos enfoques y herramientas para el seguimiento fenológico del cultivo, así como para la estimación de cosecha (Fernandez y Soria, 2017).

El índice de vegetación de diferencia normalizada (NDVI) derivado de imágenes LANDSAT es un índice espectral de amplio uso en el seguimiento fenológico del cultivo, así como en la estimación de cosecha; esto se debe a que se trata de un insumo de alta resolución espacio-temporal (Lai *et al.*, 2018; Roznik, Boyd y Porth, 2022).

Sin embargo, además de LANDSAT-8 con 11 bandas (0.43-12.51 μm), otras opciones con mayor resolución espectral y temporal existen, como es el caso de SENTINEL-2A y 2B con 12 bandas (0.43-2.28 μm) y MODIS con 36 bandas (0.4 -14.4 μm); de ambas opciones es posible obtener el NDVI, así como otros IV que podrían mejorar las estimaciones de rendimientos y el monitoreo fenológico del cultivo (Piedad-Rubio, Hernández, Zacarías y Lárraga, 2020; Salehi *et al.*, 2020).

Los IV y su relación con la cosecha en grano o biomasa han sido ampliamente estudiados; los IV derivados de MODIS aplicados a nivel regional pueden ser usados con buen ajuste ($R^2 > 0.80$) del rendimiento; por ejemplo, en soya (Shammi y Meng, 2021), trigo, maíz y caña de azúcar (Jovanovic, Sabo, Govedarica y Marinkovic, 2014), el valor mayor del coeficiente de determinación fue $R^2 = 0.91$ en la estimación de cosecha de maíz en 15 parcelas ubicadas en el Estado de México mediante el empleo de imágenes SPOT (Fernandez y Soria, 2017).

Los avances en la mejora de las imágenes de satélite, en cuanto a resolución, espacial, temporal y radiométrica, son llevados a cabo por las distintas plataformas existentes y su aplicaciones prácticas siguen siendo un reto (Ali *et al.*, 2022); por ejemplo, las estimaciones basadas en reflectancia para cultivos a nivel regional suelen ser confusas, debido a que en algunas etapas de desarrollo pueden presentar firmas espectrales casi similares (Lobell, 2013; Kok, Shariff, Alfatni y Khairunniza, 2021; Maponya, van Niekerk y Mashimbye, 2020; Zhao, Zhong, Hu, Wei y Zhang, 2020; Ji, Pan, Zhu, Zhang y Wang, 2022).

Ji *et al.* (2022) mencionan que comúnmente se confunde la respuesta espectral en zonas agrícolas con patrones diversificados de cultivos. En esas áreas también influyen las fechas de siembra y la fenología propia de cada cultivo, así como por su ubicación espacial y cambios en cuanto a extensión de cultivos establecidos de un año a otro; es decir, las estimaciones de rendimiento no están libres de inconsistencias o incertidumbres causadas por diversos factores como ubicación, tiempo atmosférico, labores culturales y niveles de humedad de suelo, entre otros factores (Shuai y Basso, 2022).

Shuai y Basso (2022) sugieren que, en la modelación individual de parcelas agrícolas, el nivel de incertidumbre podría reducirse aun cuando se encuentren en condiciones ambientales similares; en este sentido se plantea lo siguiente: ¿Cómo contribuyen los insumos de teledetección (IT) de libre acceso como LANDSAT-8 y SENTINEL-2 en estimaciones de cosecha oportunas y confiables de maíz forrajero en parcelas agrícolas de la CL? Los objetivos de la presente investigación fueron: 1) relacionar propiedades radiativas del maíz forrajero (MF) y producción de biomasa mediante imágenes LANDSAT-8 y SENTINEL-2; y 2) seleccionar el índice de vegetación (IV) con mejor desempeño que permita modelar el rendimiento del MF para condiciones similares.

MATERIALES Y MÉTODOS

Unidad de Estudio (UE): Ubicación y Características Ambientales

La UE comprendió dos parcelas (P1 y P2) de siete hectáreas, cada una, ubicadas en el Rancho "18 de Julio", de la Universidad Autónoma Chapingo (25.9037 N y 103.5821 O); este Rancho fue elegido debido a que está dedicado a la cría y explotación de bovino lechero con una estrategia agro-productiva típica de la CL basada en el cultivo de forrajes para la alimentación del ganado (Figura 1).

En ambas parcelas (P1 y P2) de siete hectáreas cada una, en las que se sembró MF, Híbrido-NB777 (Novasem, 2022) con una densidad de 87 944 plantas ha⁻¹; las fechas de siembra fueron 12 y 22 de abril de 2019 para P1 y P2, respectivamente. El clima de la UE está clasificado como muy árido, semicálido (BWhw) (CONABIO, 2019). Para el periodo 1951-2010, los promedios anuales de temperatura y precipitación pluvial fueron de 21 °C y 248 mm, respectivamente; la evaporación fue 10.4 veces mayor que el promedio anual de la lluvia (2591mm/248mm) (CONAGUA, 2021).

En ambas parcelas se realizó una caracterización edáfica conforme a la NOM-021-RECNAT-2000 (SEMARNAT, 2002) a partir de muestreos realizados a 30 cm de profundidad, cuyos resultados se presentan en la Cuadro 1.

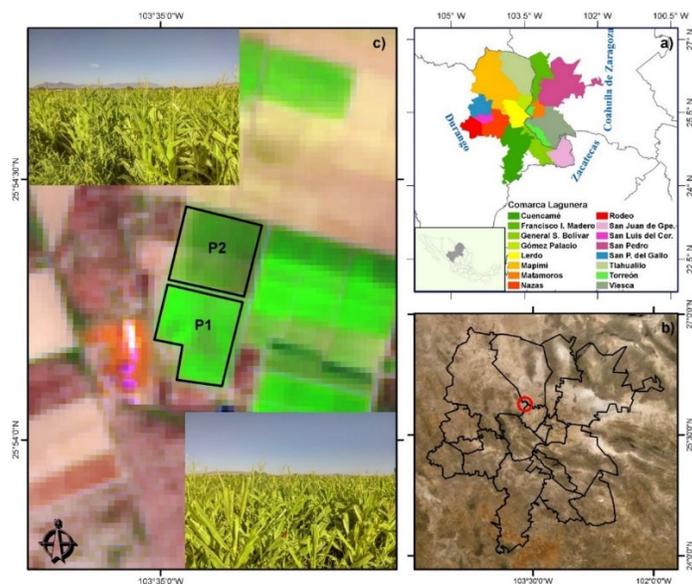


Figura 1. Ubicación de la UE. a) Comarca Lagunera y colindancias interestatales con referencia a México; b) Integración municipal sobre imagen aérea o mapa base; y c) parcelas monitoreadas. El círculo en rojo sobre el mapa base (b) indica la ubicación de la parcela 1 (P1) y la parcela 2 (P2).

Figure 1. Location of the study unit. (a) Comarca Lagunera and interstate borders with reference to Mexico; (b) Municipal integration on aerial image or base map; and (c) monitored plots. The red circle on the base map (b) indicates the location of plot 1 (P1) and plot 2 (P2).

Cuadro 1. Características edáficas por parcela al momento de la cosecha.
Table 1. Edaphic characteristics by plot at harvest time.

Variabes	Parcela 1	Parcela 2	Rango óptimo
Arena (%)	37	41	
Limo (%)	43	33	
Arcilla (%)	20	26	
Textura	Franco	Franco	
Capacidad de intercambio catiónico (meq 100 g ⁻¹)	20.13	26.35	25-50
Capacidad de campo (%)	38.28	39.90	
Punto de marchitez permanente (%)	20.92	21.80	
Densidad aparente (g cm ⁻³)	1.24	1.25	>1.2
Materia Orgánica (MO %)	0.13	1.53	>3.0
Fósforo (mg L ⁻¹)	10.60	11.11	21-40
Nitratos (mg L ⁻¹)	155.50	531.90	>60
Potasio (mg L ⁻¹)	399.20	140.00	250-800
Carbonatos CaCO ₃ (%)	9.70	8.65	>15
Hierro Fe (mg L ⁻¹)	0.95	1.23	2.5-4.5
Cobre Cu (mg L ⁻¹)	9.50	10	0.3-1.0
Zinc Zn (mg L ⁻¹)	0.70	1.65	0.5-1.0
pH	8.12	8.18	6.5-7.5
Conductividad eléctrica (dS cm ⁻¹)	3.61	3.71	2.0-8.0
Relación absorción de sodio (RAS)	4.97	0.89	<5.0
Porcentaje de sodio intercambiable (PSI)	5.72	0.06	<10.0

Fuente: Laboratorio de análisis físico, químico y microbiológico de suelos, agua y planta de la Sociedad Cooperativa Agropecuaria de la Laguna, SCL.
 Source: Laboratory for physical, chemical and microbiological analysis of soils, water and plants of the Agricultural Cooperative Society of La Laguna, (SCL, Spanish acronym).

Obtención y Procesamiento de Insumos

La obtención y procesamiento de insumos requeridos para llevar a cabo la presente investigación comprendió de cinco componentes clave: 1) Localización, descarga y procesamiento de imágenes de satélite; 2) Asociación de los valores de reflectancia y los datos de campo conforme a la resolución espacial de las imágenes de satélite empleadas; 3) Estimación de IV con base en ocho ecuaciones; 4) Gestión de información de campo conforme al tamaño de muestra de la unidad de estudio; y 5) Análisis estadístico (Figura 2).

Fuente, Descarga y Caracterización de Imágenes de Satélite

Las imágenes de satélite se obtuvieron de las plataformas del Servicio Geológico de los Estados Unidos de América (USGS, 2022) y de la Agencia Espacial Europea (ESA, 2022); las imágenes LANDSAT-8 y SENTINEL-2 fueron elegidos como insumos para la presente investigación realizada en 2019. Ello se hizo con base en dos razones que coinciden con lo descrito por Zhang *et al.* (2018): 1) por su semejanza instrumental con OLI en el primero y MSI para el segundo; y 2) por su equivalencia en la segmentación electromagnética en el espectro visible y bandas infrarrojas, conformados por 11 y 12 bandas, respectivamente. Además, su amplia disponibilidad durante el tiempo que duró la investigación fue considerada.

Las imágenes de satélite se descargaron para cinco fechas en el caso de LANDSAT-8, y 12 fechas en el caso de SENTINEL-2; la alta resolución temporal (5 días) de SENTINEL-2 permitió estudiar ambas parcelas de manera simultánea mientras que LANDSAT-8 debido su resolución temporal de 16 días permitió evaluar ambas parcelas de modo independiente; las características en cuanto a resolución radiométrica (RR), espacial (RE) y fecha de adquisición (FA) se muestran en la Cuadro 2.

Cuadro 2. Características de las imágenes obtenidas de las misiones USGS-LANSAT-8 y ESA-SENTINEL-2.
Table 2. Characteristics of images obtained from USGS-LANSAT-8 and ESA-SENTINEL-2 missions.

Bandas	SENTINEL-2			Bandas	LANDSAT-8		
	RR	RE	FA (2019)		RR	RE	FA (2019)
	Rango (μm)	m	Mes día		Rango (μm)	m	Mes día
1-Aerosol costero	0.43-0.45	60	Abr 21	1-Costera	0.43-0.45	30	May 1
2-Azul	0.45-0.52	10	May 8	2-Azul	0.45-0.51	30	May 17
3-Verde	0.54-0.57	10	May 23	3-Verde	0.53-0.59	30	Jun 4
4-Rojo	0.65-0.68	10	Jun 7	4-Roja	0.63-0.67	30	Jul 20
5-Rojo edge 1	0.69-0.71	20	Jun 22	5-Infrarrojo cercano	0.85-0.88	30	Ago 5
6-Rojo edge 2	0.73-0.74	20	Jun 25	6-Infrarrojo, onda corta 1	1.57-1.65	30	Ago 21
7-Rojo edge 3	0.77-0.79	20	Jun 30	7-Infrarrojo, onda corta 2	2.11-2.29	30	
8-Infrarrojo cercano 1	0.78-0.90	10	Jul 7	8-Pancromática	0.50-0.68	15	
8a-Infrarrojo cercano 2	0.85-0.87	20	Jul 10	9-Cirros	1.36-1.38	30	
9-Vapor de agua	0.93-0.95	60	Jul 15	10-TIRS 1	10.60-11.19	60	
10-Cirrus	1.36-1.39	60	Jul 27	11-TIRS 2	11.50-12.51	60	
11-Infrarrojo lejano 1	1.56-1.65	20					
12-Infrarrojo lejano 2	2.10-2.28	20					

Asociación Entre los Valores de Reflectancia y los Datos de Campo

La fenología y rendimiento del cultivo fueron asociados con valores de reflectancia extraída de las imágenes de satélite, cuyo procedimiento se desarrolló en dos momentos (Figura 2):

1) Preproceso. El preproceso consistió en lograr un ajuste exacto entre el tamaño de los píxeles o celdas de la imagen con la superficie de las dos parcelas en estudio, para esto se realizó un remuestreo a 15 metros de la imagen LANDSAT y a 10 metros de la imagen SENTINEL-2; la convergencia lograda implicó aproximadamente 40 celdas de 15×15 metros de la imagen LANDSAT-8 y 90 celdas de 10×10 metros de la imagen SENTINEL-2.

2) Postproceso. El postproceso se realizó como segunda fase en el módulo de Clasificación Semiautomática (CS) en Qgis, v. 3.10, cuya técnica es descrita por Congedo (2020); este módulo permite la conversión de los valores de reflectancia atmosférica (TOA, por sus siglas en inglés) con presencia de perturbaciones por ruidos o partículas a valores de reflectancia de superficie mediante la aplicación de la corrección atmosférica simple con el método Dark Object Subtraction (Chavez, 1996).

Como resultado del proceso de CS se obtuvieron imágenes calibradas y remuestreadas con resoluciones espaciales mayores a las originales, siendo de 15 m para LANDSAT-8 y de 10 m para SENTINEL.

Estimación de IV

Los IV fueron calculados mediante ocho ecuaciones; seis se identificaron en el grupo de los basados en la pendiente y dos en el grupo de los basados en la distancia (Cuadro 3) (Chen, 1996; Eastman, 2012). Los datos derivados de su aplicación en cada ecuación prevista permitieron evaluar la calidad del desarrollo y estado de salud de las parcelas de MF conforme a distintas referencias consultadas.

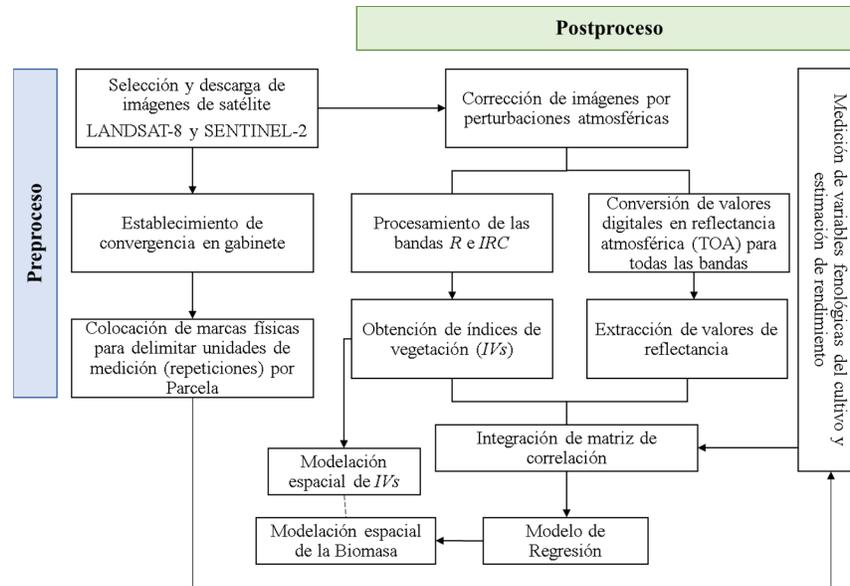


Figura 2. Diagrama de flujo que ilustra la estrategia de análisis para la modelación espacial de biomasa e índices de vegetación. (R = rojo, IRC = infrarrojo cercano).
Figure 2. Flow chart illustrating the analysis strategy for the spatial modelling of biomass and vegetation indices. (R = red, IRC = near infrared).

Gestión de Información de Campo. Tamaño de Muestra y Mediciones Realizadas

Convergencia UE Vs imágenes de satélite mediante marcas física en tierra. La convergencia entre las imágenes de satélite con los límites y colindancias de la UE fue fundamental. A partir de referencias geográficas obtenidas de las imágenes de satélite se procedió a su identificación en ambas parcelas mediante el uso de un receptor satelital (GPS, Garmin), con lo cual se crearon polígonos delimitados con marcas físicas en cada vértice (Figura 3).

Obtención de datos de biomasa. Con base en las características de resolución espacial tanto de LANDSAT-8 (15 m × 15 m), como de SENTINEL-2 (10 m × 10 m) y considerando la superficie parcelaria en estudio (70 000 m² c/u) se seleccionaron de modo aleatorio tres plantas de maíz en 10 cuadrantes, 5 cuadrantes por parcela, correspondiendo a un tamaño de muestra de 6.42% para cada parcela.



Figura 3. Delimitación de las unidades de muestreo mediante marcas físicas en tierra (a, b y c). Levantamiento de variables morfológicas de las parcelas (d y e). Etapa de floración (f).
Figure 3. Delimitation of the sampling units by physical marks on the surface (a), (b), and (c). Survey of morphological variables of the plots (d) and (e). Flowering stage (f).

Cuadro 3. Índices de vegetación utilizados para establecer su relación con la biomasa cosechada de las parcelas en estudio.
Table 3. Vegetation indices used to establish their relationship with the harvested biomass of the plots under study.

Tipo de modelo	Nombre	Acrónimo (en inglés)	Ecuación	Referencia
	Índice normalizado de vegetación	NDVI (Ecuación 1)	$\frac{NIR - Red}{NIR + Red}$	Rouse, Haas, Schell y Deering (1974)
	Índice de vegetación transformado	TVI (Ecuación 2)	$\sqrt{\frac{NIR - Red}{NIR + Red} + 0.5}$	Deering (1975)
MBP	Índice de vegetación transformada de Thiam	TTVI (Ecuación 3)	$\sqrt{ABS(NDVI + 0.5)}$	Thiam (1997)
	Índice de vegetación diferencial renormalizado	RDVI (Ecuación 4)	$\frac{NIR - Red}{\sqrt{NIR + Red}}$	Roujean y Breon (1995)
	Índice de vegetación de cociente simple	RVI (Ecuación 5)	$\frac{NIR}{Red}$	Pearson y Miller (1972)
	Índice de vegetación ratio	RATIO (Ecuación 6)	$\frac{Red}{NIR}$	Silleos, Alexandridis, Gitas y Perakis (2006)
	Índice de vegetación ajustado al suelo	SAVI (Ecuación 7)	$\frac{NIR - Red}{NIR + Red + L} * (1 + L)$	Huete (1988)
MBD	Índice de vegetación 2° de suelo ajustado transformado	MSAVI2 (Ecuación 8)	$\frac{(2 * (NIR + 1)) - \sqrt{(2 * NIR + 1)^2 - 8 * (NIR - Red)}}{2}$	Qi, Chehbouni, Huete, Kerr y Sorooshian (1994)

MBP = modelo basado en la pendiente; MBD = modelo basado en la distancia; NIR = infrarrojo cercano (banda 5 y 8 para LANDSAT-8 y SENTINEL-2 respectivamente), Red = rojo (banda 4, para ambos sensores).

MBP = slope-based model; MBD = distance-based model; NIR = near infrared (band 5 and 8 for LANDSAT-8 and SENTINEL-2 respectively), Red = red (band 4, for both sensors).

Análisis Destructivo por Etapa Fenológica. De cada cuadrante se extrajeron tres plantas que fueron trasladadas al laboratorio, donde se determinó peso fresco; los resultados obtenidos fueron extrapolados conforme a la densidad de plantas por hectárea de acuerdo con la siguiente ecuación:

$$P_{bio} = P_{pp} \times NPH \quad (9)$$

Donde P_{bio} es el potencial de producción de biomasa verde en kg. P_{pp} es la biomasa promedio por planta en kg; y NPH es el número de plantas establecidas por hectárea o densidad de plantas por hectárea.

Análisis Estadístico

El análisis estadístico se realizó mediante el programa R-Studio, v. 4.0.2 (R Core Team, 2022), para ello se integró por dos apartados: Pruebas de Normalidad (PN) y Análisis de Regresión Lineal Múltiple (ARLM), cuyas características generales son las siguientes:

1) La PN consistió en realizar una prueba de bondad de ajuste de los datos bajo la hipótesis de normalidad, para lo cual se empleó la técnica de Kolmogorov-Smirnov (Kim y Jennrich, 1973).

2) El ARLM permitió obtener un modelo empírico para predecir la producción final de biomasa verde en función de las diferentes bandas de LANDSAT-8, SENTINEL-2, así como los índices de vegetación calculados para las diferentes etapas de desarrollo del cultivo en ambas parcelas.

Los criterios para juzgar la bondad de ajuste del modelo empírico se basaron en el análisis de los errores y se utilizaron para ello los estadísticos: coeficientes de determinación ajustado (R^2 ajustado), factor de inflación de la varianza como indicador de multicolinealidad (FIV) (Lopes, Ferreira, da Silva y Céspedes, 2009) y el estadístico

de Durbin-Watson (D-W) para descartar efectos de autocorrelación. Los estadísticos para la elección del mejor modelo, análisis de varianza y prueba de falta de ajuste se presentan en el Apéndice 1, cuya interpretación se realizó con base en Savin y White (1977).

Con el índice de vegetación que mostro mejor desempeño en la validación cruzada y la biomasa estimada, una línea limite que representa la relación o el efecto límite del índice de vegetación con la variación espacial del rendimiento fue estimada (López-García, Mata-González, Blanco-Macías, Méndez-Gallegos y Valdez-Cepeda, 2016).

RESULTADOS Y DISCUSIÓN

Relación Entre las Etapas de Crecimiento del Cultivo y su Respuesta Espectral

Las firmas espectrales de SENTINEL-2 para las etapas tempranas del cultivo a los 11 y 27 dds presentaron mayor reflectancia de la energía incidente en el espectro visible y mayor absorción en las bandas 8 y 8a que corresponden al infrarrojo cercano (1 y 2). Esta respuesta espectral del dosel del cultivo se redujo a los 57 dds; es decir, la mayor absorción se presentó en la banda 4 que corresponde al rojo del espectro visible y la mayor reflectancia se asoció las bandas infrarrojas (Figuras 4c, 4d).

LANDSAT-8 presentó un comportamiento similar al observado en SENTINEL-2; en la etapa inicial de crecimiento del cultivo, la absorción de energía en el espectro visible disminuyó, mientras que aumentó en el infrarrojo cercano, pero la reflectancia en el infrarrojo aumentó a medida que el cultivo creció, mientras que en el espectro visible disminuyó (Figuras 4a, 4b).

Modelación LANDSAT-8 vs SENTINEL-2

El mejor modelo para estimar rendimiento de biomasa verde del MF en ambas parcelas se obtuvo del conjunto de bandas SENTINEL-2; para su definición se emplearon las firmas espectrales derivadas de las bandas 3 y 8 correspondientes a los 72 dds como variables explicativas, teniendo estimadores β_i muy significativos ($P < 0.05$); el modelo elegido fue el que tuvo el coeficiente de determinación mayor ($R^2 = 0.66$), cuya expresión se muestra enseguida:

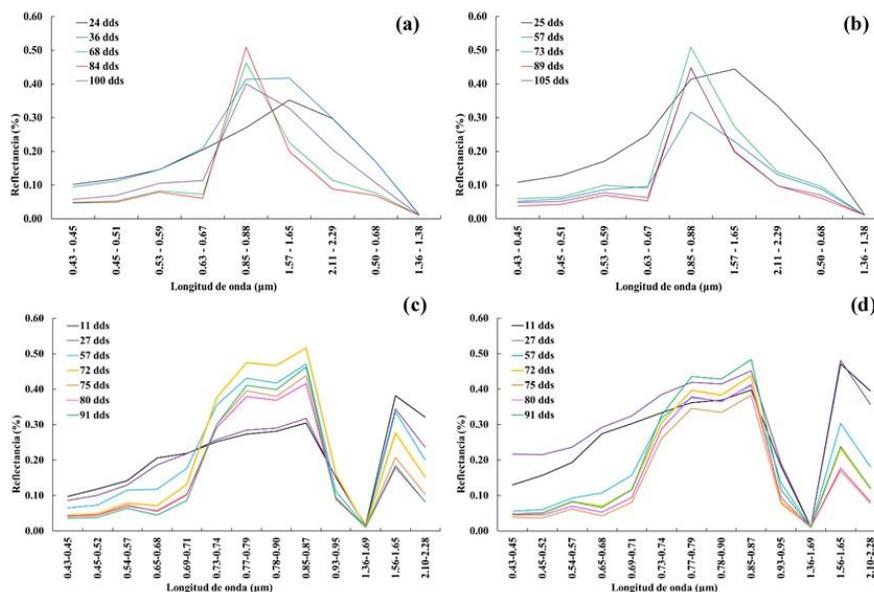


Figura 4. Respuesta espectral en diferentes días después de la siembra del maíz forrajero registradas por los sensores de LANDSAT-8 (a=P1 y b=P2) y SENTINEL-2 (c=P1 y d=P2).

Figure 4. Spectral response on different days after forage corn sowing recorded by LANDSAT-8 (a=P1 and b=P2) and SENTINEL-2 (c=P1 and d=P2) sensors.

$$\frac{1}{\text{biomasa}} = -0.07292 + 0.632 * \alpha_3 + 0.1156 * \alpha_8 + e \quad (10)$$

Donde α_3 y α_8 son las bandas 3 y 8 de SENTINEL-2 y e representa al error.

Con base en el modelo anterior (ecuación 10), los valores espectrales al sustituirse con las bandas 3 y 8 (de SENTINEL-2) se produjo un mapa de distribución espacial de biomasa para las 14 ha que suman las dos parcelas estudiadas como se muestra en la Figura 5. La producción total cosechada en P1 fue de 217.39 toneladas, mientras que para P2 fue de 120.54 toneladas. La biomasa cosechada fue de 17.22 y 31.05 Mg ha⁻¹ para P2 y P1, respectivamente, lo cual tuvo un fuerte contraste con la media regional de 50 toneladas por hectárea.

IV Evaluados con Mejor Desempeño y su Representación Geoespacial

La relación espacial entre la producción de biomasa verde y cada uno de los IV fue analizada a los 72 dds al igual que el modelo de regresión para la estimación de la cosecha. La elección del IV con mejor desempeño se llevó a cabo mediante una evaluación cruzada (EC) entre los IV y la biomasa estimada utilizando la ecuación 10 para ambas parcelas. Los IV que representaron de manera adecuada la distribución espacial de la biomasa, para ambas parcelas, fueron los del RDVI, los cuales explican 75.41% de la variabilidad en la distribución espacial de la biomasa, seguido por los de SAVI con 13.7% y MSAVI2 con 9.23% (Figura 6). Los otros índices mostraron niveles pequeños de relación con la variación de biomasa; los menores corresponden a RVI con 0.05%, RATIO con 1.66%, NDVI con 1.35% y TVI y TTVI con 1.13 por ciento.

La Figura 6 indica que a medida que incrementa el valor de los IV, la producción de biomasa aumenta. La Figura 7 proporciona un análisis del índice RDVI que fue el que mostró mayor relación espacial con la biomasa a considerar la técnica de curva límite o envolvente.

En la función cuadrática de la curva límite, lo apreciable es que la producción mínima de biomasa verde fue de 5.893 Mg ha⁻¹; ello indica que cuando el valor de RDVI asume valores cercanos a 0.210 la producción de biomasa es pequeña. Cuando el valor de RDVI asume el valor 0.469, la producción de biomasa se maximiza hasta 63.017 Mg ha⁻¹ (Figura 7).

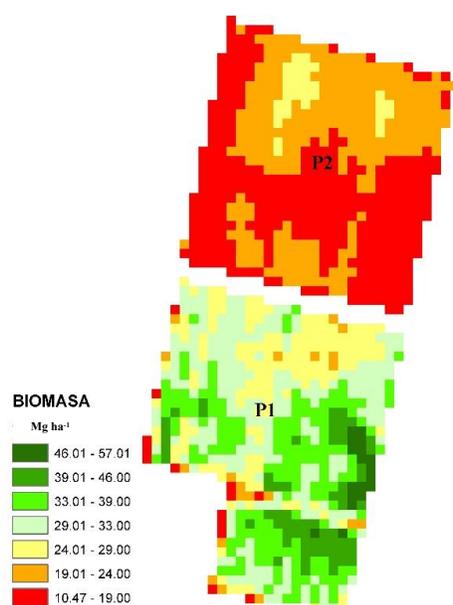


Figura 5. Biomasa estimada en las parcelas 1 y 2 a los 72 días después de la siembra con los valores de reflectancia de las bandas 3 y 8 de SENTINEL-2.

Figure 5. Estimated biomass in plots 1 and 2 at 72 days after sowing with reflectance values of SENTINEL-2 bands 3 and 8.

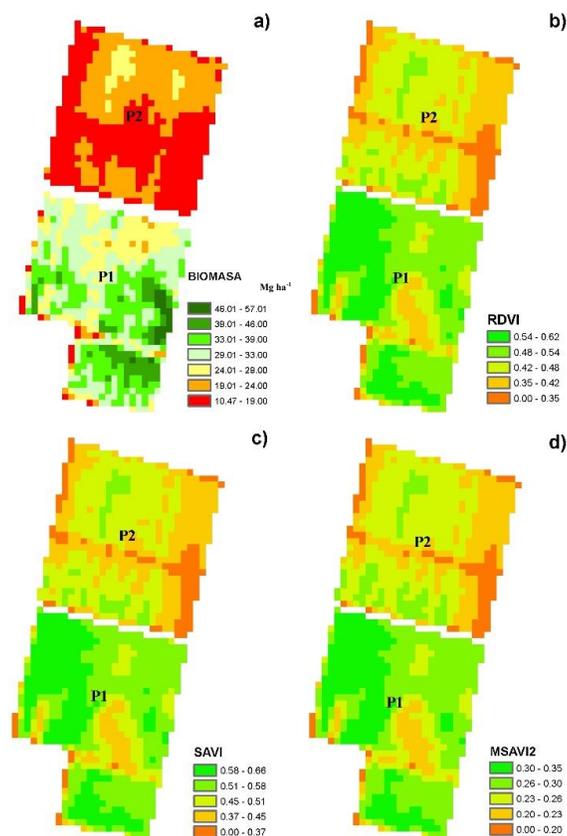


Figura 6. Comportamiento espacial de la biomasa e índices de vegetación analizados en el estudio: (a) Biomasa, (b) RDVI, (c) SAVI, y (d) MSAVI2.

Figure 6. Spatial behavior of biomass and vegetation indices analyzed in the study: (a) Biomass, (b) RDVI, (c) SAVI, and (d) MSAVI2.

Propiedades Radiativas del MF y Tiempos de Predicción de Rendimiento

Los resultados indicaron (Figura 4) que en edades tempranas la absorción o capacidad de absorber la luz por el dosel del cultivo fue menor en el espectro visible (0.45-0.68 μm), de modo que a medida que creció el cultivo hubo una absorción estimada de 8 y 16% en las bandas azul-verde y roja, respectivamente. Este comportamiento se invirtió en el infrarrojo cercano (0.78-90 μm) en la medida en que creció el cultivo; es decir, la reflectancia aumentó y la absorción disminuyó a una tasa aproximada de 14%, lo cual es consistente con lo descrito por Hamlyn (2014).

Otros estudios (p. ej.: Abd-El, Smith, Rowland, y Abd, 2019; Elders *et al.*, 2022; Hamlyn, 2014; Wang *et al.*, 2021) han consignado que la variación de estas dos propiedades radiativas (absorción y reflectancia) está fuertemente influenciada, además de la edad del cultivo, también por tamaño, grosor y orientación de la hoja, contenido de humedad y morfología; todos esos atributos varían a medida que crece el cultivo.

A los 72 dds, en la etapa de floración, las bandas 3 y 8 de SENTINEL-2 explican con mayor precisión la variabilidad de la producción final de biomasa con RLM en ambas parcelas ($R^2=0.66$); esto concuerda con Wang *et al.*, (2021), quienes señalan que, al alcanzar el máximo crecimiento del dosel, en la etapa de floración, la respuesta espectral de sensores remotos tiene mayor correlación con el rendimiento. También, Dong *et al.* (2020) precisan que la radiación en el espectro visible está muy correlacionada con el rendimiento, justo en el momento que el cultivo alcanza su crecimiento máximo.

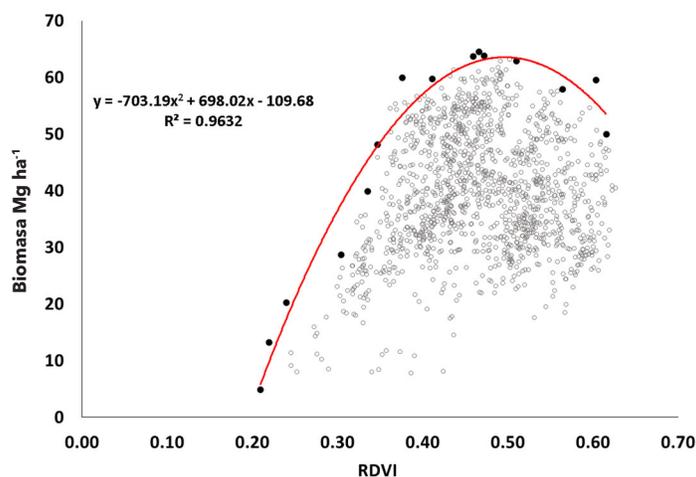


Figura 7. Comportamiento espectral de la biomasa y RDVI a los 72 días después de la siembra del maíz forrajero.
Figure 7. Spectral behavior of biomass and RDVI at 72 days after sowing forage corn.

Índices de Vegetación y Modelación de Rendimiento

Las diferencias entre el coeficiente de determinación obtenido por el modelo de regresión multivariada realizado en este estudio ($R^2=0.66$) y los consignados por Prasad, Chai, Singh y Kafatos (2006) ($R^2=0.78$) y Xin *et al.*, (2013) ($R^2=0.77$) podrían deberse al menos a tres cuestiones:

Primero. El tipo de sensor empleado por Prasad *et al.* (2006) y Xin *et al.* (2013) fue el radiómetro avanzado de muy alta resolución (AVHRR, por sus siglas en inglés) y el espectrorradiómetro de imágenes de resolución moderada (MODIS, por sus siglas en inglés), respectivamente.

Segundo. En ambos estudios se usaron datos estadísticos de rendimiento en cultivos de maíz y soya.

Tercero. Las áreas referidas en estos dos estudios citados (Prasad *et al.*, 2006; Xin *et al.*, 2013) fueron desarrollados en regiones grandes con avances tecnológicos mayores.

Lo anterior concuerda con lo expresado por Ali *et al.* (2022), quienes señalan que las características edáficas y las labores agrícolas como son: barbecho, nivelación, riego, fertilización o disponibilidad de nutrientes y malezas, entre otras, tienen impacto directo sobre el rendimiento.

Por otro lado, los mejores IV para la modelación de la producción de biomasa a nivel parcelario del MF fueron RDVI, SAVI y MSAVI2. El RDVI es un índice basado en la pendiente, mientras que SAVI y MSAVI2 son índices basados en la distancia; estos últimos proporcionan información libre de ruidos e imprecisiones ocasionados por la presencia de suelo desnudo (Eastman, 2012). Al aplicar la técnica de validación cruzada, el índice RDVI mostró una mejor modelación espacial de la producción de biomasa al presentar un $R^2 = 0.75$ en la relación lineal entre el índice y la biomasa estimada (Figura 6).

Ahmad, Singh, Fahad y Waqas (2020) encontraron, a nivel distrito en Pakistán, un $R^2 = 0.78$ con datos LANDSAT-8; Madugundu, Al-Gaadi, Tola, Kayad y Jha (2017) estimaron, en Arabia Saudita, un $R^2 = 0.96$ y $R^2 = 0.93$ con IV EVI y NDVI, respectivamente, derivados de LANDSAT-8. En contraste, los datos de reflectancia e IV derivados del sensor LANDSAT-8 no modelaron de manera satisfactoria la distribución espacial de biomasa en las etapas de desarrollo del cultivo del presente trabajo; las discrepancias, encontradas principalmente en el NDVI, pueden deberse a factores como las fechas de siembra, mientras que en nuestro caso fue para el ciclo de primavera en el citado estudio la siembra fue en el mes de agosto; por otro lado, el sistema de riego de pivote central contra sistema de inundación empleado en nuestro estudio y sobre todo, a que la biomasa o productividad primaria neta fue calculada por modelos empíricos existentes a diferencia de nuestro estudio donde se realizó un muestreo destructivo al momento de cosecha, entre otros factores de contraste como escalas y sistemas de cultivo.

La función cuadrática como curva límite muestra la estrecha relación entre el RDVI y los rendimientos en P1 y P2. Ello sugiere la existencia de una heterogeneidad grande en el rendimiento de ambas parcelas; ya que a un valor promedio de $RDVI = 0.46$ puede corresponder un rendimiento mínimo de 20 Mg ha^{-1} o bien un rendimiento máximo de 63 Mg ha^{-1} (Figura 7). Esta diferencia tan grande entre los rendimientos mínimos y máximos para un mismo valor de RDVI indica que los insumos agrícolas y el riego no se distribuyeron de manera homogénea en ambas parcelas.

Factores que Influyeron en el Bajo Rendimiento en la UE

Los datos de laboratorio (Cuadro 1) permitieron identificar al suelo de la UE como Solonetz cálcico hiposálico de textura franca (SNccszw/2), cuyo predominio y distribución espacial fue confirmada con apoyo de cartografía digital (INEGI, 2007); el origen de este suelo se deriva primordialmente de procesos aluviales, coluviales y eólicos (FAO, 2015).

Los rendimientos pequeños observados en P1 y P2 con respecto a un rendimiento promedio regional de 50 Mg ha⁻¹ se debieron al desnivel en ambas parcelas; la nivelación ineficiente inhibió la distribución homogénea del riego parcelario, no obstante que se aplicó una lámina de 60 cm (el óptimo 500-900 mm), que incluyó el riego de pre-siembra y tres de auxilio; ello pudo traer consigo, como lo señalan Espinosa *et al.* (2018), dificultades de disponibilidad de nutrientes para las plantas.

El estado del tiempo atmosférico a lo largo del ciclo es un factor que influye directamente sobre el crecimiento y el rendimiento del cultivo; la temperatura óptima para la germinación de maíz es de 16-32 °C; por ejemplo, Granados-Niño *et al.* (2022) obtuvieron 55.5 Mg ha⁻¹ de MF cultivado en la CL en el ciclo PV, cuyas temperaturas máxima, media y mínima fueron de 34.42, 27.05 y 19.61 °C respectivamente, y precipitación acumulada de 24.29 milímetros.

En contraste con el citado estudio, las temperaturas promedio del ciclo (abril-junio) en P1 y P2 fueron en el orden de 36.75, 26 y 15.25 °C, y precipitación acumulada de 10.90 mm; estas condiciones probablemente ocasionaron que los rendimientos de MF fueran 24 Mg ha⁻¹ menos en P1 y 38 Mg ha⁻¹ menos en P2, con respecto a lo consignado en el estudio citado (i.e. Granados-Niño *et al.*, 2022).

CONCLUSIONES

La mejora de SENTINEL-2 frente a LANDSAT-8 como herramienta libre para la estimación de biomasa en pequeñas parcelas de maíz forrajero en la Comarca Lagunera se debe a que adquiere mayor número de escenas para el mismo sitio en lapsos de tiempo relativamente cortos; los IVs y firmas espectrales obtenidos de estas, permiten modelar la biomasa antes de la cosecha.

Aunque el RDVI represento un insumo fundamental para la estimación de umbrales de rendimiento deberán realizarse más ensayos para un análisis más profundo y a mayor detalle de tal forma que pueda ser una alternativa para la modelación espacial de biomasa en pequeñas parcelas.

Los índices de vegetación permiten conocer el estado actual y futuro de un cultivo; el estado está asociada con diversos factores. Lo recomendable es la realización de estudios similares que permitan identificar los factores que intervienen en la variación de rendimientos en pequeñas parcelas, para lo cual se recomienda la utilización de otras variables como fertilización, presencia de plagas, labores culturales y estado del tiempo.

DECLARACIÓN DE ÉTICA

No aplicable.

CONSENTIMIENTO PARA PUBLICACIÓN

No aplicable.

DISPONIBILIDAD DE DATOS

Contactar autor por correspondencia.

CONFLICTO DE INTERESES

Los autores declaran que no tienen intereses en competencia.

FINANCIACIÓN

No aplicable.

CONTRIBUCIÓN DE LOS AUTORES

Conceptualización: B.C.M. y A.L.S. Metodología: B.C.M. Investigación: B.C.M y A.L.S. Escritura: Preparación del borrador original: B.C.M y A.L.S. Escritura: Revisión y edición: R.D.V.C.

AGRADECIMIENTOS

Los autores agradecen a la Universidad Autónoma Chapingo y a la Unidad Regional Universitaria de Zonas Áridas por las facilidades otorgadas para la realización de este trabajo, especialmente al personal del Rancho "18 de Julio", propiedad de la UACH, lugar donde se realizó buena parte del trabajo de campo y experimental. También se agradece al Consejo Nacional de Humanidades, Ciencias y Tecnologías de México por el patrocinio al primer autor para cursar el programa de Doctorado en Recursos Naturales y Medio Ambiente de Zonas Áridas. También, B.C.M agradece a sus compañeros estudiantes de posgrado Margarito Maldonado Ortiz, José Manuel Zúñiga Vásquez, Citlalli Cabral Alemán, Pedro García Ramírez y Macario García Ramírez por su apoyo en los trabajos de campo.

LITERATURA CITADA

- Abd-El Monsef, H., Smith, S. E., Rowland, D. L., & Abd El Rasol, N. (2019). Using multispectral imagery to extract a pure spectral canopy signature for predicting peanut maturity. *Computers and Electronics in Agriculture*, 162, 561-572. <https://doi.org/10.1016/j.compag.2019.04.028>
- Ahmad, I., Singh, A., Fahad, M., & Waqas, M. M. (2020). Remote sensing-based framework to predict and assess the interannual variability of maize yields in Pakistan using Landsat imagery. *Computers and Electronics in Agriculture*, 178, 105732. <https://doi.org/10.1016/j.compag.2020.105732>
- Ali, A. M., Abouelghar, M., Belal, A. A., Saleh, N., Yones, M., Selim, A. I., ... & Savin, I. (2022). Crop Yield Prediction Using Multi Sensors Remote Sensing (Review Article). *The Egyptian Journal of Remote Sensing and Space Science*, 25(3), 711-716. <https://doi.org/10.1016/j.ejrs.2022.04.006>
- Chavez, P. S. (1996). Image-based atmospheric corrections - Revisited and improved. *Photogrammetric Engineering and Remote Sensing*, 62(9), 1025-1036.
- Chen, J. M. (1996). Evaluation of Vegetation Indices and a Modified Simple Ratio for Boreal Applications. *Canadian Journal of Remote Sensing*, 22(3), 229-242. <https://doi.org/10.1080/07038992.1996.10855178>
- CONABIO (Comisión Nacional para el Conocimiento y Uso de la Biodiversidad) (2019). RTP-52 Mpimí. *Comisión Nacional Para El Conocimiento y Uso de La Biodiversidad*. Mexico: CONABIO http://www.conabio.gob.mx/conocimiento/regionalizacion/doctos/rtp_052.pdf
- CONAGUA (Comisión Nacional del Agua). (2021). Normales climatológicas de la República Mexicana, por Estado. Estación Meteorológica Tlahualilo, clave 10085 (26° 06' 23" N, 103° 26' 34" W). Servicio Meteorológico Nacional. Consultado el 15 de diciembre, 2022, desde <https://smn.conagua.gob.mx/es/climatologia/informacion-climatologica/normales-climatologicas-por-estado>
- Congedo, L. (2020). *Semi-Automatic Classification Plugin Documentation Release 7.9.5.1. User Manual*. Consultado el 22 de marzo, 2022 desde <https://media.readthedocs.org/pdf/semiautomaticclassificationmanual-v4/latest/semiautomaticclassificationmanual-v4.pdf>
- Deering, D. W., & Rouse, J. (1975). Measuring forage production of grazing units from Landsat MSS data. In *Proceedings of the Tenth International Symposium of Remote Sensing of the Environment* (pp. 1169-1198). Ann Arbor, MI, USA: ERIM.
- Dong, T., Liu, J., Qian, B., He, L., Liu, J., Wang, R., ... & Shang, J. (2020). Estimating crop biomass using leaf area index derived from Landsat 8 and Sentinel-2 data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 168, 236-250. <https://doi.org/10.1016/j.isprsjprs.2020.08.003>
- Eastman, J. R. (2012). *IDRISI Selva. Guide to GIS and image processing*. Worcester, MA, USA: Clark University.
- Elders, A., Carroll, M. L., Neigh, C. S. R., D'Agostino, A. L., Ksoll, C., Wooten, M. R., & Brown, M. E. (2022). Estimating crop type and yield of small holder fields in Burkina Faso using multi-day Sentinel-2. *Remote Sensing Applications: Society and Environment*, 27, 100820. <https://doi.org/10.1016/j.rsase.2022.100820>
- ESA (European Space Agency). (2022). Copernicus Sentinels POD Data Hub. Consultado el 23 de marzo, 2022, desde <https://scihub.copernicus.eu/gnss/#/home>
- Espinosa-Espinosa, J. L., Palacios-Vélez, E., Tijerina-Chávez, L., Ortiz-Solorio, C. A., Exebio-García, A., & Landeros-Sánchez, C. (2018). Factors that affect agricultural production under irrigation conditions: How to measure and study their effect. *Tecnología y Ciencias del Agua*, 9(2), 175-191. <https://doi.org/10.24850/j-tyca-2018-02-07>
- FAO (Organización de las Naciones Unidas para Agricultura y Alimentación). (2015). World reference base for soil resources 2014 International soil classification system for naming soils and creating legends for soil maps Update 2015. Consultado el 23 de marzo, 2022, desde <https://www.fao.org/3/i3794en/i3794en.pdf>
- Fernandez-Ordóñez, Y. M., & Soria-Ruiz, J. (2017). Maize crop yield estimation with remote sensing and empirical models. *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)* (pp. 3035-3038). Fort Worth, TX, USA: IEEE. <https://doi.org/10.1109/IGARSS.2017.8127638>
- Granados-Niño, J. A., Sánchez-Duarte, J. I., Ochoa-Martínez, E., Rodríguez-Hernández, K., Reta-Sánchez, D. G., & López-Calderón, M. J. (2022). Efecto del ciclo de producción sobre el potencial de rendimiento y calidad nutricional del maíz forrajero en la Comarca Lagunera. *Revista Mexicana de Ciencias Agrícolas*, 28, 207-217. <https://doi.org/10.29312/remexca.v13i28.3276>
- Hamlyn, G. J. (2014). *Plants and microclimate. A quantitative approach to environmental plant physiology*. (3rd Ed.). Cambridge, United Kingdom: University Press. <https://doi.org/10.1017/CBO9780511845727>
- Huete, A. R. (1988). A Soil-Adjusted Vegetation Index (SAVI). *Remote Sensing of Environment*, 25, 295-309.
- INEGI (Instituto Nacional de Estadística y Geografía). (2007). Conjunto de datos edafológicos vectoriales, carta G13-09, serie II, escala 1:250,000. Consultado el 22 de Agosto, 2022, desde <https://www.inegi.org.mx/app/mapas/>

- Ji, Z., Pan, Y., Zhu, X., Zhang, D., & Wang, J. (2022). A generalized model to predict large-scale crop yields integrating satellite-based vegetation index time series and phenology metrics. *Ecological Indicators*, 137, 108759. <https://doi.org/10.1016/j.ecolind.2022.108759>
- Jovanovic, D., Sabo, F., Govedarica, M., & Marinkovic, B. (2014). Crop yield estimation in 2014 for Vojvodina using methods of remote sensing. *Ratarstvo i Povrtarstvo*, 51(3), 145-153. <https://doi.org/10.5937/ratpov51-6712>
- Kim, P. J., & Jennrich, R. I. (1973). Tables of the exact sampling distribution of the two-sample Kolmogorov-Smirnov criterion. In H. L. Harter & D. B. Owen (Eds.). *Selected Tables in Mathematical Statistics* (79 pp.) Providence, RI, USA: American Mathematical Society.
- Kok, Z. H., Shariff, M.A. R., Alfatni, M. S. M., & Khairunniza-Bejo, S. (2021). Support Vector Machine in Precision Agriculture: A review. *Computers and Electronics in Agriculture*, 191, 106546. <https://doi.org/10.1016/j.compag.2021.106546>
- Lai, Y. R., Pringle, M. J., Kopittke, P. M., Menzies, N. W., Orton, T. G., & Dang, Y. P. (2018). An empirical model for prediction of wheat yield, using time-integrated Landsat NDVI. *International Journal of Applied Earth Observation and Geoinformation*, 72, 99-108. <https://doi.org/10.1016/j.jag.2018.07.013>
- Lobell, D. B. (2013). The use of satellite data for crop yield gap analysis. *Field Crops Research*, 143, 56-64. <https://doi.org/10.1016/j.fcr.2012.08.008>
- Lopes da Silva, A. V., Ferreira, C.R. L., da Silva, A.J.A., & Cespedes, G.G. H. (2009). Linear model alternative to estimate the green biomass of the *Bambusa vulgaris* schrad. Ex J.C. Wendl.within the appearance of multicollinearity. *Ciencia Florestal*, 19(2), 207-214.
- López-García, R., Mata-González, R., Blanco-Macías, F., Méndez-Gallegos, S. de J., & Valdez-Cepeda, R. D. (2016). Fruit attributes dependence on fruiting cladode dry or fresh matter in *Opuntia ficus-indica* (L.) Miller variety 'Rojo Pelón'. *Scientia Horticulturae*, 202, 57-62. <https://doi.org/10.1016/j.scienta.2016.02.028>
- Madugundu, R., Al-Gaadi, K. A., Tola, E. K., Kayad, A. G., & Jha, C. S. (2017). Estimation of gross primary production of irrigated maize using Landsat-8 imagery and Eddy Covariance data. *Saudi Journal of Biological Sciences*, 24(2), 410-420. <https://doi.org/10.1016/j.sjbs.2016.10.003>
- Maponya, M. G., van Niekerk, A., & Mashimbye, Z. E. (2020). Pre-harvest classification of crop types using a Sentinel-2 time-series and machine learning. *Computers and Electronics in Agriculture*, 169, 105-164. <https://doi.org/10.1016/j.compag.2019.105164>
- Navarrete-Molina, C., Meza-Herrera, C. A., Herrera-Machuca, M. A., Lopez-Villalobos, N., Lopez-Santos, A., & Veliz-Deras, F. G. (2019). To beef or not to beef: Unveiling the economic environmental impact generated by the intensive beef cattle industry in an arid region. *Journal of Cleaner Production*, 231, 1027-1035. <https://doi.org/10.1016/j.jclepro.2019.05.267>
- Novasem (2022). NOVASEM: El poder del maíz. Consultada el 23 de marzo, 2022, desde <https://novasem.com.mx/hibrido/nb777>
- Pearson, R. L., & Miller, L. D. (1972). *Remote mapping of standing crop biomass for estimation of the productivity of the shortgrass prairie*. Pawnee National Grasslands, CO, USA: Department of Watershed Sciences-College of Forestry and Natural Resources-Colorado State University.
- Piedad-Rubio, A. M., Hernández-López, D. R., Lárraga-Altamiran, H. R., & Zacarías-González, E. (2020). Teledetección en la agricultura de precisión: estado del arte de los índices de vegetación. *TECTZAPIC: Revista de Divulgación Científica y Tecnológica*, 6(2), 46-58.
- Prasad, A. K., Chai, L., Singh, R. P., & Kafatos, M. (2006). Crop yield estimation model for Iowa using remote sensing and surface parameters. *International Journal of Applied Earth Observation and Geoinformation*, 8(1), 26-33. <https://doi.org/10.1016/j.jag.2005.06.002>
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48(2), 119-126. [https://doi.org/10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1)
- R Core Team (2022). *R: A language and environment for statistical computing*. Vienna, Austria: R Foundation for Statistical Computing.
- Roujean, J. L., & Breon, F. M. (1995). Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of Environment*, 51(3), 375-384. [https://doi.org/10.1016/0034-4257\(94\)00114-3](https://doi.org/10.1016/0034-4257(94)00114-3)
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. *Proceedings of the Third Earth Resources Technology Satellite-1. Symposium* (pp. 301-304). Greenbelt, MD, USA: NASA.
- Roznik, M., Boyd, M., & Porth, L. (2022). Improving crop yield estimation by applying higher resolution satellite NDVI imagery and high-resolution cropland masks. *Remote Sensing Applications: Society and Environment*, 25, 100693. <https://doi.org/10.1016/j.rsase.2022.100693>
- SADER (Secretaría de Agricultura y Desarrollo Rural). (2023). Sistema de Información Agroalimentaria de Consulta de la Secretaría de Agricultura y desarrollo Rural. Consultado el 12 de marzo, 2023, desde: <https://www.gob.mx/siap/acciones-y-programas/produccion-agricola-33119>
- Salehi, S. H., Ashourloo, D., Moeini-Rad, A., Aghighi, H., Azadbakht, M., & Nematollahi, H. (2020). Automatic silage maize detection based on phenological rules using Sentinel-2 time-series dataset. *International Journal of Remote Sensing*, 41(21), 8406-8427. <https://doi.org/10.1080/01431161.2020.1779377>
- Savin, N. E., & White, K. J. (1977). The Durbin-Watson test for serial correlation with extreme sample sizes or many regressors. *Econometrica*, 45(8), 1989-1996.
- SEMARNAT (Secretaría de Medio Ambiente y Recursos Naturales). (2002). Norma Oficial Mexicana NOM-021 SEMARNAT-2000 antes NOM-021-RECNAT-2000. Que establece las especificaciones de fertilidad, salinidad y clasificación de suelos. Estudio, muestreo y análisis. *Diario Oficial de la Federación*. D. F., México: SEGOB.
- Shammi, S. A., & Meng, Q. (2021). Use time series NDVI and EVI to develop dynamic crop growth metrics for yield modeling. *Ecological Indicators*, 121, 107124. <https://doi.org/10.1016/j.ecolind.2020.107124>
- Shuai, G., & Basso, B. (2022). Subfield maize yield prediction improves when in-season crop water deficit is included in remote sensing imagery-based models. *Remote Sensing of Environment*, 272, 112938. <https://doi.org/10.1016/j.rse.2022.112938>
- SIAP (Servicio de Información Agroalimentaria y Pesquera). (2021). Datos Abiertos: Estadística de Producción Agrícola. Consultada el 23 de marzo, 2022, desde http://infosiap.siap.gob.mx/gobmx/datosAbiertos_a.php
- Silleos, N. G., Alexandridis, T. K., Gitas, I. Z., & Perakis, K. (2006). Vegetation indices: Advances made in biomass estimation and vegetation monitoring in the last 30 years. *Geocarto International*, 21(4), 21-28. <https://doi.org/10.1080/10106040608542399>
- Son, N. T., Chen, C. F., & Chen, C. C. (2022). Remote Sensing Time Series Analysis for Early Rice Yield Forecasting Using Random Forest Algorithm. In *Remote Sensing of Agriculture and Land Cover/Land Use Changes in South and Southeast Asian Countries* (pp. 353-366). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-92365-5_20
- Thiam, A. K. (1997). *Geographic information systems and Remote sensing methods for assessing and monitoring land degradation in the sahel: The Case of Southern Mauritania*. Ann Arbor, MI, USA: Clark University.
- USGS (United States Geological Survey). (2022). EarthExplorer. Consultada el 23 de marzo, 2023, desde <https://earthexplorer.usgs.gov/>
- Wang, S., Guan, K., Wang, Z., Ainsworth, E. A., Zheng, T., Townsend, P. A., ... & Jiang, C. (2021). Airborne hyperspectral imaging of nitrogen deficiency on crop traits and yield of maize by machine learning and radiative transfer modeling. *International Journal of Applied Earth Observation and Geoinformation*, 105, 102617. <https://doi.org/10.1016/j.jag.2021.102617>

- Xin, Q., Gong, P., Yu, C., Yu, L., Broich, M., Suyker, A. E., & Myneni, R. B. (2013). A production efficiency model-based method for satellite estimates of corn and soybean yields in the midwestern US. *Remote Sensing*, 5(11), 5926-5943. <https://doi.org/10.3390/rs5115926>
- Zhang, H. K., Roy, D. P., Yan, L., Li, Z., Huang, H., Vermote, E., ... & Roger, J. C. (2018). Characterization of Sentinel-2A and Landsat-8 top of atmosphere, surface, and nadir BRDF adjusted reflectance and NDVI differences. *Remote Sensing of Environment*, 215, 482-494. <https://doi.org/10.1016/j.rse.2018.04.031>
- Zhao, J., Zhong, Y., Hu, X., Wei, L., & Zhang, L. (2020). A robust spectral-spatial approach to identifying heterogeneous crops using remote sensing imagery with high spectral and spatial resolutions. *Remote Sensing of Environment*, 239, 111605. <https://doi.org/10.1016/j.rse.2019.111605>