

Evaluación del rendimiento del modelo U-Net en la segmentación de cultivos de maíz y sorgo: Un estudio de caso en Tabasco.

Evaluating the performance of the U-Net model in the segmentation of corn and sorghum crops: A case study in Tabasco.

Luis Antonio López Gómez (1).
Tecnológico Nacional de México/Instituto Tecnológico de Superior de los Ríos.
luisjezra@gmail.com.

Fernando Pech May* (2). Tecnológico Nacional de México/Instituto Tecnológico de Superior de los Ríos,
fernando.pech@cinvestav.mx.

Edna Mariel Mil Chontal (3). Tecnológico Nacional de México/Instituto Tecnológico de Superior de los Ríos,
edna.mc@rios.tecnm.mx.

Jorge Magaña Govea (4). Tecnológico Nacional de México/Instituto Tecnológico de Superior de los Ríos,
totosaus@hotmail.com.

*corresponding author.

Artículo recibido en febrero 03, 2026; aceptado en junio 30, 2026.

Resumen.

U-Net es una red neuronal convolucional diseñada para la segmentación semántica, se ha consolidado por su capacidad para analizar imágenes a nivel de píxeles y clasificarlos en función de sus características. Su arquitectura codificador-decodificador permite identificar el contexto global y las características locales de las imágenes, proporcionando soluciones a problemas complejos, lo que la sitúa como una herramienta para enfrentar desafíos actuales en la agricultura. Este estudio evalúa su desempeño en la identificación y clasificación de cultivos de sorgo y maíz en Balancán, Tabasco, empleando datos multiespectrales del satélite Sentinel-2 procesadas mediante herramientas de sistemas de información geográfica como Google Earth Engine y QGIS, correspondientes a los años 2018 al 2022. Estas imágenes fueron manipuladas mediante algoritmos de corrección y cálculo de índices espectrales como NDVI, GNDVI, EVI, SAVI y NDWI, mejorando la calidad y precisión. El rendimiento del modelo fue evaluado por métricas precisión, recall y F1-Score. Los mejores resultados obtuvieron las precisiones del 92% para sorgo en la temporada primavera-verano y 86% para el maíz en la temporada otoño-invierno. A pesar de ciertos retos para reconocer áreas pequeñas o densas, se destaca la importancia de U-Net en la agricultura, mostrando su capacidad de adaptación a distintos contextos y su papel en la optimización de la gestión agrícola. Estas aplicaciones no solo mejoran la eficiencia productiva, sino que fortalece la resiliencia frente a los efectos del cambio climático, mejorar la seguridad alimentaria y promueve prácticas agrícolas más sostenibles en áreas vulnerables de Tabasco.

Palabras claves: Monitoreo de cultivos, percepción remota, redes neuronales convolucionales, Sentinel-2.

Abstract.

U-Net is a convolutional neural network designed for semantic segmentation. It has been consolidated for its ability to analyze images at the pixel level and classify them based on their characteristics. Its encoder-decoder architecture allows to identify the global context and local characteristics of the images, providing solutions to complex problems, which places it as a tool to face current challenges in agriculture. This study evaluates its performance in the identification and classification of sorghum and corn crops in Balancán, Tabasco, using multispectral data from the Sentinel-2 satellite processed by geographic information system tools such as Google Earth Engine and QGIS, corresponding to the years 2018 to 2022. These images were manipulated using correction algorithms and calculation of spectral indexes such as NDVI, GNDVI, EVI, SAVI and NDWI, improving quality and accuracy. The performance of the model was evaluated by precision, recall and F1-Score metrics. The best results were obtained with 92% accuracy for sorghum in the spring-summer season and 86% for corn in the fall-winter season. Despite certain challenges in recognizing small or dense areas, the importance of U-Net in agriculture is highlighted, showing its ability to adapt to different contexts and its role in optimizing agricultural management. These applications not only improve productive efficiency, but also strengthen resilience to the effects of climate change, improve food security and promote more sustainable agricultural practices in vulnerable areas of Tabasco.

Keywords: Convolutional neural networks, crop monitoring, remote sensing, Sentinel-2.

1. Introducción.

En los últimos años, los avances en aprendizaje profundo han permitido abordar problemas complejos en diversos campos, desde la biomedicina hasta la agricultura. Dentro de estas tecnologías, la arquitectura U-NET ha emergido como una herramienta altamente efectiva para la segmentación de imágenes. Diseñada inicialmente para aplicaciones biomédicas, esta red neuronal convolucional ha demostrado ser versátil y adaptable a múltiples dominios, especialmente en escenarios que requieren segmentación semántica de alta precisión, como el análisis de imágenes satelitales (FAO, IFAD, UNICEF, WFP & WHO, 2023; World Economic Forum, 2023).

La arquitectura U-NET se basa en un modelo de codificador-decodificador, donde el codificador extrae características relevantes mediante capas convolucionales y operaciones de agrupamiento, reduciendo la resolución de la imagen mientras se identifican patrones clave. Por otro lado, el decodificador utiliza convoluciones transpuestas para restaurar la resolución espacial original, generando mapas de segmentación detallados. Las conexiones de salto entre las capas del codificador y el decodificador permiten transferir información espacial de bajo nivel, lo que mejora la precisión al conservar detalles esenciales de la imagen (CIMMYT, 2021).

Trabajos relacionados.

La detección y monitoreo de cultivos han sido objeto de diversos estudios que combinan imágenes satelitales y técnicas de aprendizaje profundo. A continuación, se presentan algunos trabajos relevantes en este ámbito.

Mora-Fallas et al. (2020) proponen un enfoque de segmentación de instancias para la detección automática de malezas y cultivos en campos agrícolas, utilizando técnicas avanzadas de visión por computadora y redes neuronales convolucionales (CNN). Utilizan el modelo Mask R-CNN, una arquitectura de red neuronal de segmentación de instancias que no solo clasifica las áreas de la imagen, sino que también segmenta de manera precisa cada objeto en instancias individuales. Permite no solo identificar la presencia de malezas y cultivos, sino también delinear de manera precisa los bordes de cada instancia (es decir, cada planta, ya sea maleza o cultivo). Emplearon la métrica de precisión promedio de MSCOCO. El modelo alcanzó una tasa de precisión superior al 85% en la detección de cultivos y malezas, lo que indica una alta efectividad del sistema en la clasificación y segmentación precisa de las plantas en los campos agrícolas.

Onojeghuo, Miao y Blackburn (2023) proponen un enfoque para la segmentación y mapeo de arrozales de pequeños agricultores utilizando redes neuronales convolucionales profundas, específicamente diseñadas para combinar

imágenes de radar de apertura sintética (SAR) de Sentinel-1 e imágenes ópticas de Sentinel-2. Utilizaron una red neuronal de segmentación ResU-Net, que es una variante avanzada de la arquitectura U-Net. El desempeño del modelo fue evaluado utilizando métricas estándar como la precisión, recall, F1 score y el índice de intersección sobre la unión (IoU). Los resultados indicaron una buena capacidad para identificar correctamente tanto los arrozales como las áreas no cultivadas, con valores del F1 score cercanos al 90%, lo que refleja un buen equilibrio entre la precisión y la capacidad de detectar todas las instancias relevantes.

González Díez (2019) propone utilizar CNNs para aprender representaciones jerárquicas de las características espectrales y espaciales de las imágenes satelitales, lo que permite la clasificación precisa de los cultivos sin necesidad de intervención manual intensiva. El estudio se centra en el uso de imágenes satelitales ópticas obtenidas de la misión Sentinel-2 de la ESA. El modelo CNN demostró una alta precisión en la clasificación de cultivos, alcanzando tasas de precisión superiores al 90% en la mayoría de los casos. La capacidad de las CNN para identificar características complejas en las imágenes, como las diferencias en la textura y el color de los cultivos, contribuyó a estos resultados. En cuanto a la evaluación de métricas de desempeño utilizaron *F1*. Los resultados mostraron que la red neuronal logró un *F1* score promedio superior al 85%, lo que indica un buen equilibrio entre precisión y capacidad para detectar todos los cultivos relevantes. Este desempeño fue consistente incluso cuando se utilizó una base de datos con diferentes condiciones climáticas y tipos de terreno.

Por otro lado, Singh et al. (2022) abordan el uso de Deep Learning (U-NET) específicamente Redes Neuronales Convolucionales (CNN), para mapear el uso de la tierra agrícola mediante el análisis de imágenes satelitales de Sentinel-2 en una parte de Punjab, India. El modelo fue entrenado utilizando un conjunto de datos de entrenamiento etiquetado, en el que se identificaron manualmente las diferentes categorías de uso del suelo. Para evaluar las tierras agrícolas, se han considerado los principales tipos de cultivos de la temporada de invierno, es decir, trigo, berseem, mostaza y otra vegetación. En los resultados experimentales, los clasificadores RF y de aprendizaje profundo de U-Net alcanzaron un 97,8 % (valor kappa: 0,9691) y un 96,2 % (valor kappa: 0,9469), respectivamente. Estos resultados demuestran la capacidad de ambas metodologías para la clasificación precisa de los diferentes usos de la tierra agrícola en la región.

Estos estudios demuestran la efectividad de combinar imágenes satelitales, como las proporcionadas por Sentinel-2, con técnicas de aprendizaje profundo para la detección y monitoreo de cultivos, contribuyendo a la optimización de prácticas agrícolas y a la seguridad alimentaria.

2. Materiales y métodos.

La estrategia propuesta para la detección de cultivos consta de cinco etapas. La Figura 1 muestra la metodología y descripción de las actividades en cada etapa. A continuación, se explica cada etapa.




Figura 1. Metodología propuesta para la detección de cultivos.

Delimitación y captura de datos.

Se enfoca exclusivamente en las zonas agrícolas del municipio de Balancán, situado en el estado de Tabasco, ubicado en la región zona Ríos de México (ver Figura 2). Cuenta con un área aproximada de 3,626 km², presenta un clima cálido húmedo con abundantes lluvias en el verano. Se caracteriza por ser hábitat de una rica fauna silvestre, y por tener ecosistemas como praderas, bosques y selvas. Su principal actividad económica es la agricultura, destacando cultivos de maíz, sorgo, frijol, arroz y hortalizas como la sandía, por su parte, el sector ganadero es importante para la economía local (Gobierno de Tabasco, 2024). La delimitación geográfica se realizó utilizando capas vectoriales de límites administrativos proporcionadas por el Instituto Nacional de Estadística y Geografía (INEGI) y datos SIG del municipio.




Figura 2. Ubicación geográfica del área de estudio.

Selección del periodo de estudio.

Abarcan los años 2018 a 2022, dividiendo las temporadas en dos ciclos agrícolas principales: Primavera-Verano (P-V), comprende del 21 de marzo y concluye el 20 de octubre y Otoño-Invierno (O-I), inicia el 21 de octubre y finaliza el 20 de marzo. El maíz, su época de siembra es del 15 de mayo al 30 de junio y el sorgo del 10 de enero a 10 de marzo.

Adquisición de imágenes.

Se adquirieron a través de la plataforma Google Earth Engine (GEE), que permite el acceso a datos satelitales de manera eficiente. Los datos satelitales utilizados fueron obtenidos de la misión Sentinel-2, lanzada por la Agencia Espacial Europea (ESA) como parte del programa Copernicus (ESA, 2015.). Las imágenes de Sentinel-2 ofrecen una resolución espacial de 10 metros en las bandas visibles (rojo, verde, azul), y de 20 metros en el infrarrojo cercano (NIR) y otras bandas espectrales, lo que las hace adecuadas para la clasificación de cultivos agrícolas. El sensor está disponible para descarga de manera gratuita. Se seleccionaron imágenes representativas de las temporadas agrícolas de primavera-verano y otoño-invierno de los años 2018-2022. Las imágenes fueron seleccionados con intervalos de tiempo adecuados para capturar las distintas fases del ciclo de cultivo, garantizando que se abarcara el crecimiento vegetativo, la floración y madurez de los cultivos. Estas fueron exportadas a Google Drive para su descarga.

Preparación de las imágenes Sentinel 2.

La preparación de las imágenes Sentinel-2 implicó una serie de pasos específicos para garantizar la calidad y precisión necesarias en el análisis de detección de cultivos. A continuación, se detallan las etapas involucradas:

Enmascaramiento de nubes.

El área de estudio es susceptible a nubosidad debido al clima cálido y húmedo de la región obstruyendo el monitoreo de la cobertura terrestre (ver Figura 3). Para minimizar este problema, se aplicaron filtros para limitar la nubosidad en las imágenes al rango de **10%-20%**, asegurando una mejor calidad para el análisis. Esto fue posible utilizando la banda QA60 de Sentinel-2 para enmascarar nubes y mejorar la precisión de las imágenes procesadas (ver Figura 4).




Figura 3. Área de estudio con nubosidad.




Figura 4. Área de estudio sin nubosidad.

Selección de bandas espectrales y cálculo de índices espectrales.

Las imágenes satelitales de Sentinel-2 ofrecen una amplia gama de bandas espectrales que cubren diferentes longitudes de onda, que permite analizar las características físicas y biológicas de la superficie terrestre. Para identificar la vegetación se calcularon el NDVI con el fin de resaltar la vegetación densa y saludable, GNDVI para identificar diferentes tasas de concentración de clorofila, EVI se utilizó ya que es más sensible a la vegetación densa, y SAVI a fin de corregir el NDVI por la influencia del brillo del suelo en las áreas donde la cobertura vegetativa es baja. Para diferenciar el agua se aplicó el índice NDWI.

Creación y clasificación de muestra.

La etapa se centró en el proceso de identificar áreas de cultivos específicos, como maíz y sorgo, utilizando las imágenes satelitales procesadas. Este paso fue crucial para entrenar el modelo de aprendizaje profundo y realizar una clasificación precisa de los cultivos. La creación de las etiquetas se llevó a cabo mediante ArcGIS Pro, las imágenes tienen aplicado índices de vegetación y una paleta de colores para diferenciar los colores. A continuación, se detallan los pasos involucrados en la creación y clasificación de muestras para el análisis de cultivos.

En la Tabla 1 se presentan las muestras en el proceso de entrenamiento del modelo, corresponden a los años 2018 al 2022.

Tabla 1. Muestras de entrenamiento del modelo.

Primavera – verano		Otoño – invierno	
Maíz			
Images	Features	Images	Features
31367	72184	22538	58926
Sorgo			
14738	30902	10740	43602

Entrenamiento del modelo DL.

El entrenamiento del modelo implica varias etapas clave que van desde la preparación de los datos hasta el ajuste de los parámetros del modelo. A continuación, se detallan cada una de estas etapas en detalle.

- 1) Preparación de los Datos: a) Imágenes de Entrada: Son imágenes preprocesadas de Sentinel-2, donde se han seleccionado las bandas espectrales relevantes y se han creado imágenes de tamaño adecuado 256x256 píxeles. Estos son las muestras de entrada que se utilizarán durante el entrenamiento del modelo. B) Etiquetas de Entrada: Son las áreas de las imágenes que han sido etiquetadas manualmente con las clases correspondientes: maíz, sorgo. Estas etiquetas el modelo utilizará para aprender a segmentar las diferentes clases en las imágenes. C) División de los Datos: Se utiliza un 80% de los datos para el entrenamiento y un 20% para la validación. Esta división permite que el modelo aprenda de una gran cantidad de datos y sea validado en un conjunto separado para medir su desempeño.
- 2) Arquitectura del Modelo U-Net: U-Net es una arquitectura de red neuronal convolucional que consta de dos partes principales: a) El encoder se encarga de extraer características espaciales de la imagen a medida que la red pasa por varias capas convolucionales. Estas capas comprimen la información de entrada y extraen patrones de alto nivel, como bordes y formas. B) El decoder toma las características extraídas en el encoder y las convierte en una segmentación precisa de las clases de interés. Utiliza transposiciones convolucionales para restaurar la resolución espacial de la imagen y generar una salida con la misma forma que la imagen de entrada. C) Skip Connections: permite que el modelo retenga detalles finos como bordes de las imágenes de entrada.
- 3) Entrenamiento del modelo: se deben definir ciertos parámetros de entrenamiento, como la función de pérdida, el optimizador, la tasa de aprendizaje, etc. A) Entrenamiento por Épocas: El modelo se entrena con las épocas 30 y 50, el modelo ajusta sus parámetros para minimizar el error entre las predicciones y las etiquetas. B) Ajuste de Parámetros: se evalúa el rendimiento del modelo utilizando el conjunto de validación. Esto ayuda a ajustar los parámetros y verificar si el modelo está sobreajustando los datos de entrenamiento. C) Evaluación del modelo: Al final de cada época, se calcula el rendimiento del modelo utilizando métricas como precisión, recall, F1-score, para medir qué tan bien el modelo está segmentando las áreas de maíz y sorgo.

Evaluación de las métricas y clasificación de mapas de cultivos

Son pasos cruciales para medir el rendimiento del modelo en la segmentación de maíz y sorgo en imágenes de Sentinel-2. Para asegurar que el modelo sea efectivo y adecuado para aplicaciones de agricultura, es esencial evaluar el desempeño en términos de precisión, recall, F1 y otras métricas, así como validar la calidad de los mapas segmentados. Una vez que el modelo ha segmentado las imágenes, se genera un mapa de cultivos donde cada píxel está etiquetado con su clase correspondiente (por ejemplo, maíz, sorgo). Estos mapas de cultivos pueden ser utilizados para diversas aplicaciones agrícolas.

3. Resultados.

A continuación, se muestran los resultados del entrenamiento del modelo en términos de la tarea para la que fue entrenado.

Pérdida de entrenamiento y validación: Refleja qué tan bien o mal el modelo está aprendiendo en relación con los datos de entrenamiento. Durante cada época del entrenamiento, el modelo ajusta sus pesos para minimizar la función de pérdida. Cuanto menor sea el valor, mejor será el rendimiento. De acuerdo con los parámetros de entrenamiento establecidos, la pérdida de validación se calculó para el 10% del total de muestras utilizadas. Las Figuras 5 y 6 muestran los gráficos de la función de pérdida de entrenamiento y validación de los modelos de aprendizaje profundo entrenados con diferentes tiempos y muestras de entrenamiento del cultivo del maíz. Las Figuras 9 y 10 reflejan pérdida de entrenamiento y validación y muestras de entrenamiento del cultivo del sorgo.

Precisión: Representa el porcentaje de veces que el modelo realiza una predicción correcta respecto al número total de predicciones realizadas. Por lo tanto, mide la proporción de veces que el modelo etiqueta correctamente una instancia de una muestra de datos. En las Figuras 7 y 8 se muestran las imágenes tomadas como muestra respecto a las clasificaciones realizadas por el modelo correspondiente al cultivo del maíz. En las Figuras 11 y 12 se aprecian la proporción de píxeles correctamente clasificados para una clase en particular sobre el total de píxeles que el modelo

ha clasificado como pertenecientes a esa clase respecto al cultivo del maíz y sorgo, respectivamente. Esto es para comparar los resultados y la precisión de los modelos. En la Tabla 7 se presenta la precisión promedio de cada modelo, así como otros parámetros de validación.




Figura 5. Pérdida y validación en el modelo entrenado en la temporada primavera-verano, del cultivo del maíz: **a)** 30 épocas y **b)** 50 épocas.




Figura 6. Pérdida y validación en el modelo entrenado en la temporada otoño - invierno, del cultivo del maíz: **c)** 30 épocas y **d)** 50 épocas.




Figura 7. Comparación automática de las muestras de entrenamiento y las clasificaciones generadas por el modelo entrenado en la temporada primavera - verano, del cultivo de maíz: **a)** 30 épocas y **b)** 50 épocas.




Figura 8. Comparación automática de las muestras de entrenamiento y las clasificaciones generadas por el modelo entrenado en la temporada otoño - invierno, del cultivo del maíz: **a)** 30 épocas y **b)** 50 épocas.




Figura 9. Pérdida y validación en el modelo entrenado en la temporada primavera - verano, del cultivo del sorgo: **a)** 30 épocas y **b)** 50 épocas.




Figura 10. Pérdida y validación en el modelo entrenado en la temporada otoño - invierno, del cultivo del sorgo: **c)** 30 épocas y **d)** 50 épocas.




Figura 11. Comparación automática de las muestras de entrenamiento y las clasificaciones generadas por el modelo entrenado en la temporada primavera - verano, del cultivo del sorgo: **a)** 30 épocas y **b)** 50 épocas.




Figura 12. Comparación automática de las muestras de entrenamiento y las clasificaciones generadas por el modelo entrenado en la temporada otoño-invierno, del cultivo del sorgo: **a)** 30 épocas, **b)** 50 épocas.

Evaluación del modelo.

Para evaluar el desempeño del modelo se utilizan varias métricas clave que permiten medir la precisión, la capacidad de recuperación, la superposición entre las áreas segmentadas y las áreas reales, y el equilibrio entre estas métricas. En este sentido, es necesario calcular la precisión en la clasificación de los píxeles. Para ello, se midió la proporción de píxeles que el modelo ha clasificado correctamente entre todas las predicciones, la capacidad del modelo para identificar todos los píxeles relevantes de una clase específica y la media armónica entre la precisión y el recall, proporcionando una medida equilibrada de ambas. La Tabla 1 muestra los parámetros de validación mencionados anteriormente.

Tabla 2. Evaluaciones del modelo neuronal entrenado.

Temporada: Primavera verano			Temporada: Otoño-invierno	
Cultivo: Maíz				
Evaluación	Épocas: 30	Épocas: 50	Épocas: 30	Épocas: 50
Precision	85%	90%	80%	86%
Recall	68%	73%	54%	83%
F1	76%	81%	65%	85%
Cultivo: Sorgo				
Precision	91%	92%	89%	91%
Recall	90%	92%	90%	92%
F1	99%	92%	85%	91%

Clasificación de mapas de cultivos.

Una vez que el modelo ha segmentado las imágenes de Sentinel-2, cada píxel de la imagen es clasificado en una de las clases definidas previamente, como maíz, sorgo. A partir de estas clasificaciones, se generan mapas de cultivos que proporcionan información espacial sobre la distribución de los cultivos. Abarcan desde el año 2018 hasta el 2022, contemplando las temporadas de primavera-verano (ver Figura 13) y otoño-invierno (ver Figura 14) en el municipio de Balancán, Tabasco. Se empleó una combinación específica de bandas espectrales adaptada para la detección y clasificación de cultivos agrícolas las cuales son las bandas B11, B8A, B2.




Figura 13. Mapa de cultivo temporada primavera verano.




Figura 14. Mapa de cultivo temporada otoño – invierno.

Conclusiones.

El modelo U-Net ha demostrado un rendimiento particularmente bueno para la segmentación de cultivos de maíz y sorgo en imágenes de Sentinel-2. Los resultados obtenidos de este estudio, se centraron en el municipio de Balancán, Tabasco. El modelo alcanzó una **precisión** de hasta el 92% para la detección de sorgo y el 90% para maíz, durante la temporada de primavera-verano, lo que refleja que el modelo tiene un buen desempeño tanto en la identificación precisa de las áreas cultivadas como en la captura de la mayor parte de las áreas reales de cultivo. Sin embargo, durante la temporada de otoño-invierno, la precisión disminuyó ligeramente un 86% para maíz y 91% para sorgo. Esta caída puede atribuirse a la menor densidad vegetativa de los cultivos. Los mapas de segmentación generados permiten mejorar la toma de decisiones en agricultura, facilitando la gestión de recursos y el monitoreo continuo de los cultivos. Aunque existen algunas limitaciones relacionadas con la calidad de las imágenes y el etiquetado, el modelo muestra que es capaz de segmentar con precisión áreas cultivadas de maíz y sorgo, pero también podría aplicarse a otros cultivos y áreas agrícolas de forma similar, siempre que se cuente con imágenes satelitales adecuadas y datos para entrenamiento.

Por finalizar, este estudio es relevante tanto para la investigación agrícola como para las aplicaciones prácticas en la gestión de recursos y la optimización de cultivos. El modelo tiene un gran potencial para transformar la forma en que se lleva a cabo el monitoreo agrícola y la toma de decisiones sobre la gestión de cultivos.

Referencias bibliográficas.

Agencia Espacial Europea (ESA). (2015). Sentinel 2.

https://www.esa.int/Space_in_Member_States/Spain/SENTINEL_2

CIMMYT. (2021). *La producción de alimentos hacia un mundo con más de 9 mil millones de habitantes.*

<https://idp.cimmyt.org/la-produccion-de-alimentos-hacia-un-mundo-con-mas-de-9-mil-millones-de-habitantes/>

FAO, IFAD, UNICEF, WFO, & WHO. (2023). *El estado de la seguridad alimentaria y la nutrición en el mundo 2023.* <https://doi.org/10.4060/cc3017es>.

Gobierno de Tabasco. (2024). Balancán.

[https://tabasco.gob.mx/balancan#:~:text=Extensi%C3%B3n%20territorial&text=Territorialmente%20el%20municipio%20de%20Balanc%C3%A1n,nivel%20del%20mar%20\(msnm\)](https://tabasco.gob.mx/balancan#:~:text=Extensi%C3%B3n%20territorial&text=Territorialmente%20el%20municipio%20de%20Balanc%C3%A1n,nivel%20del%20mar%20(msnm))

González Díez, S. (2019). *Evaluación del uso de redes neuronales convolucionales para clasificación de cultivos mediante imagen multiespectral.* <http://uvadoc.uva.es/handle/10324/38792>

IINEGI. (2023). *Nota técnica: Encuesta Nacional de la Dinámica Demográfica (ENADID) 2023.*

Mora-Fallas, A., Goëau, H., Joly, A., Bonnet, P., & Mata-Montero, E. (2020). *Segmentación de instancias para detección automática de malezas y cultivos en campos de cultivo.* *Revista Tecnología en Marcha*, marzo.

<https://doi.org/10.18845/tm.v33i5.5069>

Onojeghuo, A. O., Miao, Y., & Blackburn, G. A. (2023). *Deep ResU-Net convolutional neural networks segmentation for smallholder paddy rice mapping using Sentinel 1 SAR and Sentinel 2 optical imagery.* *Remote Sensing*, 15(6), 1517. <https://doi.org/10.3390/rs15061517>

Singh, G., Singh, S., Sethi, G., & Sood, V. (2022). *Deep learning in the mapping of agricultural land use using Sentinel-2 satellite data.* *Geographies*, 2(4), 691–700. <https://doi.org/10.3390/geographies2040042>

World Economic Forum. (2023). *Cómo enfocarnos en la salud del suelo puede ayudarnos a alimentar a la creciente población mundial.* <https://es.weforum.org/stories/2023/11/la-salud-del-suelo-puede-ayudarnos-a-alimentar-a-la-creciente-poblacion-mundial-sin-danar-el-planeta-asi-es-como/>

Información de los autores.



Luis Antonio López Gómez, es Profesor del Instituto Tecnológico Superior de los Ríos en el área de Computación. Imparte docencia de Programación Web, Redes, en la carrera de Ingeniería en Sistemas Computacionales. Su labor de investigación se centra en las líneas de Inteligencia Artificial y Sistemas Distribuidos. Es Ingeniero en Sistemas Computacionales. Cuenta con 15 años de experiencia. Es miembro del cuerpo académico computo distribuido. Asimismo, acredita numerosas contribuciones a congresos y participaciones el desarrollo de proyectos de investigación de PRODEP y TecNM. Ha publicado más de 10 artículos nacionales e internacionales, artículos indexados en revistas de prestigio en los últimos años. Ha dirigido Tesis de Licenciatura. Actualmente es miembro del Sistema Estatal de Investigadores. Imparte talleres sobre Diseño de Apps Móviles, Uso de Látex en trabajos académicos y Consejos para la elaboración de trabajos académicos.



Fernando Pech May, es Profesor investigador del Instituto Tecnológico Superior de los Ríos (ITSR). Realizó sus estudios de maestría en el Centro de Investigación y Estudios Avanzados del IPN (CINVESTAV) en el área de Inteligencia Artificial. Se especializó en Web Semántica en la Universidad de Chile. Finalizó su doctorado en Ciencias de la Computación en el Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET). Líder del cuerpo académico Cómputo Distribuido del ITSR, miembro activo de la Sociedad Mexicana de Inteligencia Artificial y la Asociación Mexicana para el Procesamiento de Lenguaje Natural. Sus áreas de interés son Deep Learning, Web Semántica y PLN.



Edna Mariel Mil Chontal, es Maestra en Ciencias en la Computación por el Centro de Investigación y de estudios avanzados del IPN, campus Tamaulipas. Es Licenciada en Computación por la Universidad Autónoma de Tabasco. Profesora del Instituto Tecnológico Superior de los Ríos y pertenece al cuerpo Académico “Cómputo Distribuido”. Sus áreas de interés son: Sistemas Distribuidos, Procesamiento de Lenguaje Natural y Redes de Próxima Generación.



Jorge Magaña Govea, es Profesor investigador del Instituto Tecnológico Superior de los Ríos. Maestro en Ciencias de la Computación por la UJAT. Actualmente es miembro del Cuerpo Académico de Cómputo Distribuido, Perfil PRODEP y miembro del Sistema Estatal de Investigadores del estado de Tabasco. Sus áreas de interés son la ingeniería de Software, ontologías y web semántica. Ha impartido cursos orientados a la implementación de metodologías ágiles de desarrollo de software y formulación de proyectos.