

# Integración del modelo Gamma Earth S2DR3 para la mejora superresolutiva de imágenes Sentinel-2 en agricultura digital

Integration of the Gamma Earth S2DR3 model for Super-Resolution enhancement of Sentinel-2 imagery in digital agriculture

Fabiola Olvera-Rincón<sup>1</sup> , Sergio Salgado-Velázquez<sup>2</sup> , Luz del Carmen Lagunes-Espinoza<sup>1</sup> , Carlos Fredy Ortiz-García<sup>1</sup> , Joaquín Alberto Rincón-Ramírez<sup>1\*</sup> , Eder Ramos-Hernández<sup>2</sup> 

<sup>1</sup> Colegio de Postgraduados, Campus Tabasco, km 3.5 periférico Carlos A. Molina s/n, 86500, Cárdenas, Tabasco, México.

<sup>2</sup> Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias, Campo Experimental Huimanguillo, km 1 carretera Huimanguillo-Cárdenas, 86400, Huimanguillo, Tabasco, México.

\*Autor para correspondencia: jrincon@colpos.mx

## Fecha de recepción:

11 de noviembre de 2025

## Fecha de aceptación:

4 de febrero de 2026

## Disponible en línea:

29 de abril de 2026

Este es un artículo en acceso abierto que se distribuye de acuerdo a los términos de la licencia Creative Commons.



Reconocimiento-  
NoComercial-  
CompartirIgual 4.0  
Internacional  
(CC BY-NC-SA 4.0)

## Cómo citar:

Olvera-Rincón, F., Salgado-Velázquez, S., Lagunes-Espinoza, L. del C., Ortiz-García, C. F., Rincón-Ramírez, J. A., & Ramos-Hernández, E. (2025). Integración del modelo Gamma Earth S2DR3 para la mejora superresolutiva de imágenes Sentinel-2 en agricultura digital. *Acta Agrícola y Pecuaria*, 11(núm. esp. 2), e0111038. https://doi.org/10.30973/aap/2025.11.0111038

## RESUMEN

La mejora de la resolución espacial de imágenes satelitales representa un avance clave en la tele-detección aplicada a la agricultura de precisión. En este estudio, se implementó el modelo Gamma Earth S2DR3 (Sentinel-2 Deep Resolution 3.0), basado en redes neuronales profundas, para transformar imágenes Sentinel-2 de 10 m a 1 m de resolución en una parcela de 20 ha de limón persa. Las imágenes originales fueron descargadas y corregidas atmosféricamente en Google Earth Engine. Posteriormente, el modelo se ejecutó en Google Colab, generando composiciones RGB a 10 m y 1 m para comparación visual y cuantitativa. La validación se realizó con métricas estadísticas (RMSE, R<sup>2</sup>, PSNR y SSIM), evidenciando mejoras en la fidelidad espacial y radiométrica. Además, se calcularon los índices NDVI, GNDVI y SAVI, observándose mayor variabilidad espacial a 1 m frente a patrones homogéneos a 10 m. Esto permitió identificar microzonas de estrés y heterogeneidad no detectables en resolución estándar, confirmando el potencial del modelo para mejorar la gestión agrícola.

## PALABRAS CLAVE

Agricultura de precisión, sensores remotos, aprendizaje profundo, índices de vegetación.

## ABSTRACT

Enhancing the spatial resolution of satellite imagery represents a key advancement in remote sensing applied to precision agriculture. In this study and based on deep neural networks, the Gamma Earth S2DR3 model (Sentinel-2 Deep Resolution 3.0) was implemented to transform Sentinel-2 imagery from 10 m to 1 m resolution in a 20 ha Persian lime field. Original images were downloaded and atmospherically corrected in Google Earth Engine. Subsequently, the S2DR3 model was executed in Google Colab, generating RGB composites at 10 m and 1 m for visual and quantitative comparison. Validation was performed using statistical quality metrics (RMSE, R<sup>2</sup>, PSNR, and SSIM), demonstrating improvements in spatial and radiometric fidelity. Additionally, NDVI, GNDVI, and SAVI vegetation indexes were calculated, revealing greater spatial variability at 1 m compared to the homogeneous patterns observed at 10 m resolution. This enabled the identification of micro-zones of stress and heterogeneity not detectable at standard resolution, confirming the potential of the model to enhance spatial discrimination and support more precise agricultural management.

## KEYWORDS

Precision agriculture, remote sensing, deep learning, vegetation indexes.

## INTRODUCCIÓN

La revolución digital en la agricultura se enmarca en lo que diversos autores denominan agricultura 4.0, un paradigma caracterizado por el empleo intensivo de tecnologías de la información y comunicación, sensores remotos, inteligencia artificial y sistemas automatizados para optimizar la producción agrícola (Wolfert et al., 2017). Este enfoque busca integrar datos a distintas escalas espaciales y temporales para generar conocimiento que permita incrementar la productividad, reducir costos, minimizar riesgos y garantizar la sostenibilidad de los sistemas agrícolas. La agricultura atraviesa una transformación profunda impulsada por la digitalización y la integración de nuevas tecnologías de teledetección, inteligencia artificial y *big data*. Este proceso, conocido como revolución digital agrícola, busca responder a los desafíos globales de seguridad alimentaria, cambio climático, sostenibilidad y eficiencia en el uso de los recursos. Los datos satelitales se consolidan cada vez más como una herramienta adecuada para el monitoreo de cultivos agrícolas. Este tipo de datos puede apoyar la producción de alimentos y forrajes orgánicos. Los avances científicos y tecnológicos en teledetección han mejorado de forma significativa nuestra capacidad para detectar y cuantificar las cargas físicas y biológicas que afectan la productividad de los cultivos.

Los datos del satélite Sentinel-2 (S2) han sido utilizados con éxito para distinguir entre distintos sistemas de cultivo como el convencional, el orgánico o el biodinámico (Kociszewski et al., 2020). El rendimiento de los cultivos es quizás la información más importante para la gestión agrícola de precisión, y resulta de interés no solo para los agricultores, sino también para numerosas organizaciones públicas y privadas (Nadzirah et al., 2024). En general, la teledetección representa un método alternativo para la estimación de rendimientos. Otra ventaja de los datos de S2 es que ofrecen la oportunidad de desarrollar un método moderno, más fácil y preciso, para monitorear la productividad de diversos cultivos en la agricultura. Además, este tipo de información permite estimar la disponibilidad de suministros alimentarios (Atanasova et al., 2021). Los datos de S2 constituyen un recurso valioso para la observación de la Tierra, ya que proporcionan imágenes multiespectrales con resoluciones espaciales

de 10 m, 20 m y 60 m, que en algunos casos pueden resultar insuficientes. Este problema puede resolverse con datos de mejor resolución (Tarasiewicz et al., 2023).

El incremento de la resolución espacial de los datos satelitales mediante inteligencia artificial es de gran interés para los especialistas en teledetección, ya que ofrece la posibilidad de contar con datos de resolución mejorada (Michel et al., 2022). Un problema estrechamente relacionado con la estimación del rendimiento es la cartografía de cultivos. Se requieren mapas precisos de la distribución de cada cultivo para aplicar modelos de rendimiento específicos, estimar superficies cultivadas y, en general, disponer de información que respalde el monitoreo y la toma de decisiones (Olvera-Rincón et al., 2024; Salgado-Velázquez et al., 2020; Weiss et al., 2020).

Entre las herramientas más innovadoras, las imágenes satelitales de alta resolución han demostrado ser fundamentales para mejorar la gestión de los cultivos, la planificación territorial y la toma de decisiones basadas en datos. En este contexto, el modelo de superresolución Gamma Earth S2DR3, aplicado a las imágenes de S2, representa un avance disruptivo que permite obtener datos con un nivel de detalle cercano al de sensores de muy alta resolución, pero con la ventaja de la frecuencia temporal y cobertura global de S2. Esta combinación abre nuevas posibilidades para la agricultura de precisión, facilitando un monitoreo más detallado del estado de los cultivos, detección temprana de plagas y enfermedades, así como la optimización en el uso del agua y fertilizantes.

En este contexto, la teledetección satelital se ha convertido en una herramienta fundamental. Según Salgado-Velázquez et al. (2025) y Vadrevu et al. (2022), los datos multiespectrales obtenidos por sensores como los de S2 son esenciales para el monitoreo de la vegetación y la agricultura, ya que permiten calcular índices como el NDVI (índice de vegetación de diferencia normalizada), que ofrecen información sobre el vigor, la biomasa y el estado fenológico de los cultivos. Además, la periodicidad de S2 (revisita de cinco días) garantiza la disponibilidad de series temporales para evaluar la dinámica agrícola a lo largo de la temporada. No obstante, la resolución espacial de S2 (10 m en bandas visibles e infrarrojo cercano) limita su aplicación en escenarios donde se requiere un análisis a nivel de parcela o incluso de subparcela. Para superar

esta restricción, la comunidad científica ha desarrollado algoritmos de superresolución, definidos como técnicas que permiten reconstruir imágenes de mayor resolución a partir de datos de menor resolución (Yang et al., 2019). Estas metodologías, inicialmente aplicadas en visión computacional, han sido adaptadas al ámbito de la observación de la Tierra mediante el uso de redes neuronales convolucionales y modelos de aprendizaje profundo capaces de capturar patrones espaciales y espectrales de manera eficiente.

El modelo Gamma Earth S2DR3 surge como una solución de vanguardia en este campo. Basado en arquitecturas de redes profundas entrenadas con grandes volúmenes de datos satelitales, este modelo logra generar imágenes S2 con resolución de hasta 1 m. Según DigiFarm (s. f.), empresa desarrolladora de esta tecnología, S2DR3 permite mejorar significativamente la identificación de estructuras agrícolas, la cartografía de parcelas y la evaluación precisa de cultivos a una escala que antes estaba reservada a sensores de muy alta resolución comercial.

En síntesis, la integración del modelo Gamma Earth S2DR3 con S2 representa un avance crucial en la revolución digital agrícola al unir la cobertura global y temporal de un satélite gratuito con la resolución espacial propia de sensores de élite (Xia et al., 2021). Esto constituye una oportunidad única para países en desarrollo, donde la disponibilidad de datos gratuitos y de alta resolución puede marcar la diferencia en la adopción de prácticas agrícolas más sostenibles y productivas. Por ello, el objetivo principal fue demostrar que el mejoramiento de las imágenes S2 por medio del modelo Gamma Earth S2DR3 permite generar productos de una resolución espacial de 1 m para usos de monitoreo agrícolas en cultivos tropicales como el sureste mexicano.

## MATERIALES Y MÉTODOS

### Área de estudio

El área de estudio (Figura 1) se ubicó en una parcela comercial de limón persa de cinco años con una superficie de 20 ha. Se encuentra en suelos ácidos que se caracterizan por fijar fósforo con deficiencias de zinc, bajos niveles de amonio, nitratos, calcio, magnesio y potasio, y elevado porcentaje de saturación de alu-

minio. Estas condiciones restrictivas de la fertilidad producen deficiencias nutricionales que reducen el rendimiento y la calidad de los frutos (Salgado-García et al., 2016). Los rendimientos de limón persa en la región son de 9.95 t ha<sup>-1</sup> y 11.8 t ha<sup>-1</sup> (Servicio de Información Agroalimentaria y Pesquera, 2024).

### Delimitación del polígono

Se realizó una visita técnica al predio de estudio y, con apoyo de un GPS E22 (Garmin, Olathe, Estados Unidos), se procedió a capturar puntos de referencia. Posteriormente, en el *software* QGIS versión 3.40.13, se procedió a cargar los puntos sobre un mapa base de Google satellite con el complemento QuickMapServices y, así, delimitar el polígono del área de estudio.

### Descarga y procesamiento de las imágenes de Sentinel-2

Para la obtención y preprocesamiento de las imágenes S2, se utilizó la plataforma Google Earth Engine (GEE), empleando su API de JavaScript en el Code Editor para la ejecución interactiva de *scripts* y la API de Python mediante el paquete *earthengine-api* para procesos automatizados y reproducibles (Berra et al., 2024). La primera etapa consistió en la definición del área de interés (AOI), correspondiente a una parcela de 20 ha de limón persa ubicada en las inmediaciones del poblado Estación Chontalpa, municipio de Huimanguillo, Tabasco, México. El polígono de la parcela se cargó a GEE como un objeto de tipo *FeatureCollection*, lo que permitió recortar las imágenes a la extensión específica del cultivo, asegurando precisión espacial mediante la proyección a un sistema de referencia adecuado (UTM zona 15 Norte). Posteriormente, se procedió a la selección de la recolección de datos, empleando el conjunto *COPERNICUS/S2\_SR*, que corresponde a imágenes S2 Nivel 2A con corrección atmosférica integrada a través del procesador *Sen2Cor*, garantizando así que los valores de reflectancia de superficie fueran consistentes y comparables (Bui et al., 2022). Complementariamente, se integró la colección *COPERNICUS/S2\_CLOUD\_PROBABILITY* para la estimación de probabilidad de nubosidad, con el fin de optimizar la detección y enmascaramiento de nubes (Aybar et al., 2024).

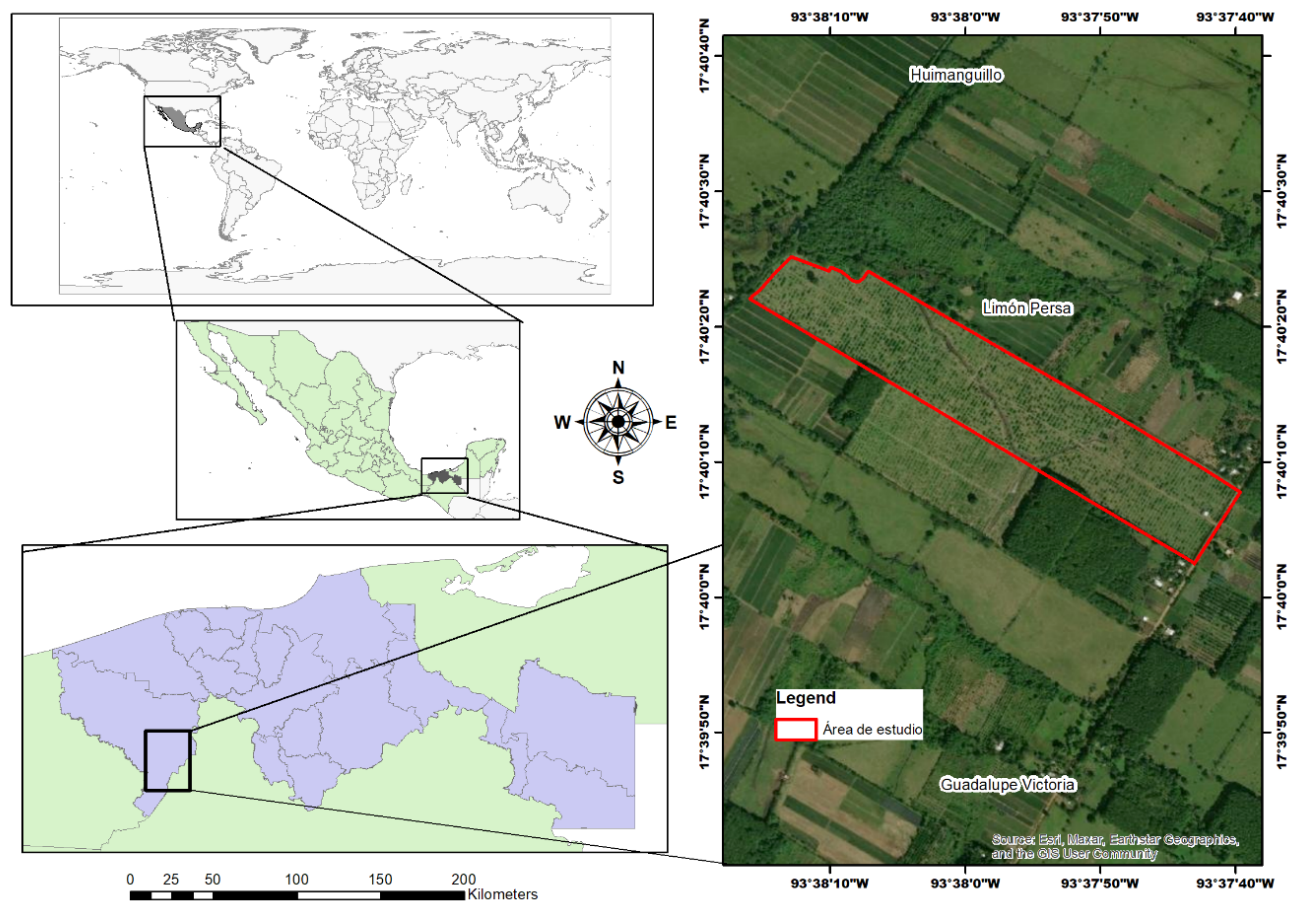


Figura 1. Área de estudio con cultivo de limón persa en el ejido Pedregal Moctezuma del municipio de Huimanguillo, Tabasco, México.

En la etapa de filtrado temporal y espacial, se aplicaron funciones nativas de la API de GEE, como `filterBounds`, `filterDate` y `filterMetadata`, para restringir las imágenes al AOI, al periodo de estudio y a un umbral máximo del metadato `CLOUDY_PIXEL_PERCENTAGE`, lo cual permitió descartar escenas con cobertura nubosa excesiva. A continuación, se llevó a cabo el preprocesamiento radiométrico y enmascaramiento de nubes y sombras, empleando la combinación de la banda `SCL` (Scene Classification Layer) incluida en la colección `SR` y la probabilidad de nubes derivada de `COPERNICUS/S2_CLOUD_PROBABILITY` (Tejido-Murias et al., 2024). Para ello, las colecciones fueron unidas mediante la función `ee.Join`, y posteriormente se aplicaron operaciones de filtrado con `updateMask` para excluir píxeles clasificados como nubes, sombras, aerosoles o saturados, preservando únicamente los píxeles libres de perturbaciones atmosféricas. De manera adicional, se utilizó la función `clip` para recortar cada imagen al polígono de la parcela, optimizando así el almacenamiento y procesamiento en las fases subsecuentes (Shelestov et al., 2017).

### Implementación del modelo Gamma Earth S2DR3

La mejora de la resolución espacial de las imágenes S2 se implementó mediante el modelo Gamma Earth S2DR3 (Sentinel-2 Deep Resolución 1 m) en un entorno de procesamiento basado en Google Colab con soporte de GPU (T4), lo que permitió ejecutar de manera eficiente los algoritmos de superresolución basados en redes neuronales profundas (Galar et al., 2020). Inicialmente, se configuró el entorno de trabajo importando librerías fundamentales de análisis de datos y geoinformación, incluyendo NumPy, Pandas y GeoPandas para la manipulación y estructuración de datos vectoriales y tabulares, así como Rasterio para la lectura y escritura de archivos ráster georreferenciados. Posteriormente, se instaló el paquete especializado de superresolución S2DR3 desde el repositorio oficial de Gamma Earth, asegurando la disponibilidad de las funciones de inferencia que implementan la arquitectura de redes neuronales convolucionales profundas para generar imágenes de alta resolución (Sambandham et al., 2024). El flujo ope-

rativo consistió en definir los parámetros de entrada requeridos por el modelo: la fecha de adquisición de la escena S2 y las coordenadas geográficas (longitud y latitud) del área de interés. Una vez definidos, se invocó la función `s2dr3.inferutils.test()`, la cual procesa la escena S2 de resolución original (10 m) y genera un producto sintético con resolución de 1 m, preservando la coherencia espectral y la integridad radiométrica de la imagen (Kowalczyk et al., 2023). El modelo emplea redes neuronales previamente entrenadas sobre grandes conjuntos de datos S2 y utiliza aprendizaje profundo para reconstruir detalles espaciales finos ausentes en la resolución original, logrando así una mejora significativa en la definición de elementos del paisaje y la estructura de los cultivos (Zabalza & Bernardini, 2022).

La salida del proceso se almacenó en un directorio de trabajo definido en Google Colab, con opción de vinculación a Google Drive para facilitar la descarga y la gestión de los productos generados. La estructura de los archivos exportados incluyó imágenes georreferenciadas listas para análisis visual o procesamiento posterior, permitiendo la comparación entre la resolución original de 10 m y la resolución mejorada de 1 m (Chanev et al., 2025). Este enfoque asegura trazabilidad, reproducibilidad y consistencia metodológica, ya que todos los parámetros, librerías y rutas de almacenamiento fueron documentados y controlados dentro del entorno de Colab.

### Cálculo de índices de vegetación

Todos los productos descargados y generados de las imágenes de S2, fueron llevados al programa de QGIS, donde se calcularon índices de vegetación como NDVI, SAVI y GNDVI y, se realizaron composiciones de imágenes en RGB. Los cálculos se realizaron por medio de la calculadora ráster y se usaron las bandas espectrales según fuera el caso (Salgado Velázquez et al., 2023). Posteriormente en el programa Rstudio, se calcularon las firmas espectrales de las imágenes con la mejora de resolución y corregidas atmosféricamente con las librerías raster, ggplot y mapview.

### Evaluación de la calidad del modelo Gamma Earth S2DR3

La evaluación de la calidad de las imágenes S2 superresueltas mediante Gamma Earth S2DR3 se realizó

en Python usando NumPy, Rasterio, scikit-image, scikit-learn y Matplotlib. Las imágenes originales de 10 m se emplearon como referencia y las de 1 m, como predicción. Para garantizar comparabilidad, se aplicó el método *block averaging* y reproyección para alinear resoluciones, dimensiones y sistemas de coordenadas. Se normalizaron los datos y se excluyeron píxeles no válidos. La evaluación cuantitativa de la calidad de la imagen se realizó mediante métricas estandarizadas, incluyendo el error cuadrático medio (RMSE), el coeficiente de determinación ( $R^2$ ), el *peak signal-to-noise ratio* (PSNR) y el *structural similarity index* (SSIM), calculadas sobre las bandas multispectrales más relevantes; y se complementó con diagramas de dispersión que muestran la concordancia entre referencia y predicción (Kowalczyk et al., 2023; Salgueiro Romero et al., 2020). Este procedimiento cuantifica la mejora espacial, preserva la coherencia espectral y valida estadísticamente la eficacia del modelo S2DR3 utilizado.

## RESULTADOS Y DISCUSIÓN

### Mejora de la resolución de imágenes satelitales con Gamma Earth S2DR3

La aplicación del modelo Gamma Earth S2DR3 permitió incrementar la resolución espacial de las imágenes S2 de 10 m a 1 m en composición RGB (Figura 2), manteniendo la coherencia espectral y la integridad radiométrica de la escena correspondiente a la parcela de limón persa en Huimanguillo, Tabasco. Visualmente, las composiciones RGB generadas a partir de las imágenes superresueltas mostraron un incremento notable en la definición espacial (Figura 1), con mayor claridad en los límites de las plantas y mejor percepción de heterogeneidad en el dosel. Esto permite identificar con mayor precisión áreas potenciales de estrés hídrico o deficiencias nutricionales, así como pequeñas variaciones en la densidad de plantación que serían difíciles de discernir en imágenes de 10 m de resolución. Comparando estos resultados con estudios recientes, como lo reportado por Chanev et al. (2025), se observa consistencia en la eficacia de modelos de superresolución basados en redes neuronales profundas para preservar la información espectral y mejorar la definición espacial de imágenes S2.

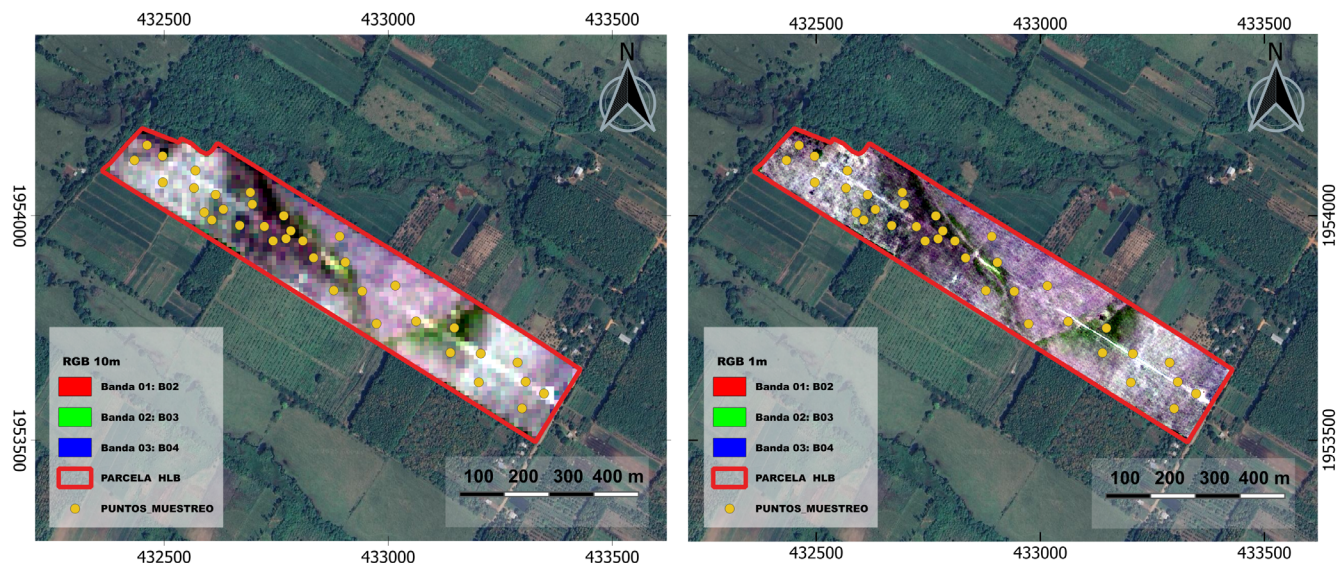


Figura 2. Visualización RGB de la parcela de estudio: izquierda 10 m (original), derecha 1 m (mejora de resolución con el modelo S2DR3) en Huimanguillo, Tabasco, México.

## Índices de vegetación

El análisis de los índices de vegetación derivados de las imágenes S2 mostró diferencias significativas entre la resolución original de 10 m y las imágenes mejoradas a 1 m mediante el modelo S2DR3. En la resolución estándar (10 m), los valores de  $NDVI$ ,  $GNDVI$  y  $SAVI$  (Figuras 3, 4 y 5, respectivamente) evidenciaron patrones generales de vigor vegetativo dentro de la parcela de limón persa; sin embargo, la heterogeneidad intraparcelsaria se encontraba suavizada debido a la mezcla espectral de los píxeles. Esto se tradujo en mapas homogéneos con valores promedio estables, pero con limitada capacidad para identificar zonas de estrés o variabilidad espacial fina.

Con la aplicación de S2DR3, la resolución espacial se incrementó a 1 m, lo que permitió una caracterización mucho más detallada de la cobertura vegetal (Hunt et al., 2019). En los índices generados a esta escala, se observaron microvariaciones en el dosel que resultaron imperceptibles en la resolución de 10 m. En particular, el  $NDVI$  presentó una mayor dispersión de valores (Figura 3), identificando diferencias en el vigor entre hileras de árboles y áreas con menor densidad foliar. De manera similar, el  $GNDVI$  (Figura 5), más sensible al contenido de clorofila, mostró un contraste más marcado entre zonas de alta y baja vitalidad, lo que aporta un valor adicional para la detección temprana de deficiencias nutrimentales (Donike et al., 2025). En el caso del  $SAVI$  (Figura 4), el ajuste por cobertura del

suelo fue más preciso en 1 m, reduciendo la influencia de espacios descubiertos entre plantas y mejorando la delimitación de las hileras de cultivo.

La comparación estadística entre ambas resoluciones reflejó un incremento en la capacidad de discriminar variabilidad espacial a escala submétrica. Mientras que los mapas de 10 m ofrecían una visión general de la salud del cultivo, los resultados a 1 m mostraron un mosaico más detallado que facilita la identificación de microzonas críticas dentro de la parcela. Este hallazgo es relevante en el contexto de la agricultura de precisión, donde la detección temprana de variabilidad espacial permite optimizar insumos y mejorar la toma de decisiones (Galar et al., 2020; Lanaras et al., 2018; Nadzirah et al., 2024).

Estos resultados coinciden con lo reportado por Kowaleczko et al. (2023) y Salgueiro Romero et al. (2020), quienes destacan que los modelos de superresolución basados en redes neuronales profundas aumentan la capacidad de análisis en cultivos perennes al revelar detalles que antes quedaban enmascarados en resoluciones satelitales más bajas. Asimismo, se alinean con lo planteado por Donike et al. (2025), quienes enfatizan que el aumento de resolución no solo mejora la calidad visual de las imágenes, sino también la consistencia de métricas cuantitativas como los índices de vegetación, lo que incrementa su valor científico y operativo en estudios agrícolas.

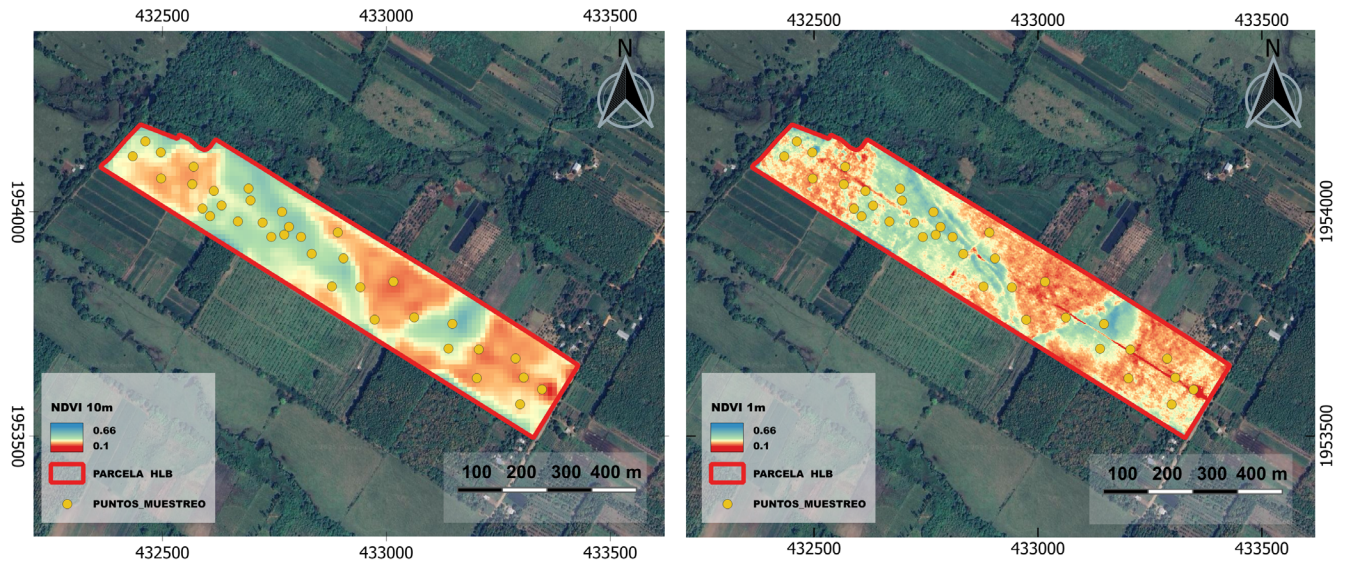


Figura 3. Visualización del ndvi de la parcela de estudio: izquierda 10 m (original), derecha 1 m (mejora de resolución con el modelo S2DR3) en Huimanguillo, Tabasco, México.



Figura 4. Visualización del saví de la parcela de estudio: izquierda 10 m (original), derecha 1 m (mejora de resolución con el modelo S2DR3) en Huimanguillo, Tabasco, México.



Figura 5. Visualización del gndvi de la parcela de estudio: izquierda 10 m (original), derecha 1 m (mejora de resolución con el modelo S2DR3) en Huimanguillo, Tabasco, México.

## Validación del modelo Gamma Earth S2DR3

Los resultados indicaron un RMSE promedio de 0.012, un  $R^2$  de 0.83, un PSNR de 38.5 dB y un SSIM de 0.94, evidenciando que las imágenes superresueltas presentan una alta fidelidad estructural y radiométrica frente a la imagen de referencia de 10 m (Figura 6).

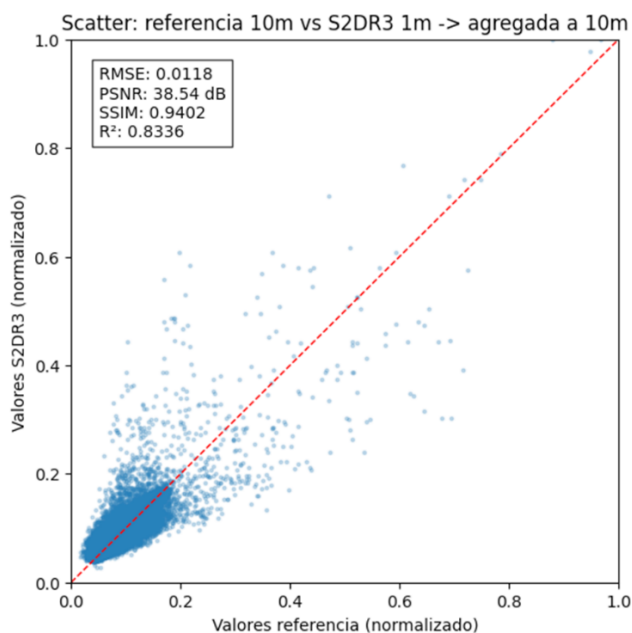


Figura 6. Validación cruzada de los resultados de las imágenes S2 con una resolución de 10 m vs. 1 m (mejorados con el modelo S2DR3) en Huimanguillo, Tabasco, México.

La técnica de *block averaging* y la reproyección mediante Rasterio aseguraron que las comparaciones se realizaran en la misma grilla espacial, minimizando errores por desalineamiento o diferencias en resolución. Estas cifras reflejan que el modelo S2DR3 es capaz de reconstruir detalles finos del cultivo, incluyendo la delimitación de filas de plantas, bordes de cobertura vegetal y microestructuras del dosel, elementos esenciales para la agricultura de precisión. Asimismo, la evaluación mediante métricas cuantitativas coincide con hallazgos previos de Kowaleczko et al. (2023) y Salgueiro Romero et al. (2020), quienes reportan que técnicas de superresolución generan productos con PSNR y SSIM elevados, aptos para análisis detallados de cultivos y clasificación de coberturas terrestres. El RMSE es muy bajo. La diferencia de la imagen mejorada y la original es muy baja. El PSNR >30 dB suele considerarse de excelente calidad de reconstrucción, y significa que el modelo preserva bien la información radiométrica:

el ruido introducido al *super-resolver* es muy bajo. El SSIM de 0.9 se considera de calidad perceptual muy alta, por lo que las formas y patrones de la imagen mejorada se parecen mucho a la original.

## Conclusiones

La superresolución de imágenes Sentinel-2 a 1 m mediante el algoritmo Gamma Earth S2DR3 representa un avance significativo. Esta optimización permitió obtener un nivel de detalle espacial cercano al de sensores comerciales de muy alta resolución, pero con la ventaja de la cobertura gratuita, amplia y periódica de S2. En este sentido, fue posible generar insumos espectrales de alta precisión para el cálculo de NDVI, SAVI, GNDVI y composiciones RGB. Los valores bajos registrados en estos índices reflejan claramente el estrés fisiológico, la pérdida de vigor y la afectación fotosintética en las parcelas de estudio. La fusión entre *big data* satelital y técnicas de superresolución permite transformar píxeles en diagnósticos agrícolas de alta precisión, destacando el potencial de estas herramientas para el monitoreo detallado del estado fisiológico de los cultivos.

## LITERATURA CITADA

- Atanasova, D., Bozhanova, V., Biserkov, V., & Maneva, V. (2021). Distinguishing areas of organic, biodynamic and conventional farming by means of multispectral images. A pilot study. *Biotechnology & Biotechnological Equipment*, 35(1), 977-993. <https://doi.org/10.1080/13102818.2021.1938675>
- Aybar, C., Montero, D., Contreras, J., Donike, S., Kalaitzis, F., & Gómez-Chova, L. (2024). SEN2NAIP: A large-scale dataset for Sentinel-2 Image Super-Resolution. *Scientific Data*, 11, 1389. <https://doi.org/10.1038/s41597-024-04214-y>
- Berra, E. F., Fontana, D. C., Yin, F., & Breunig, F. M. (2024). Harmonized Landsat and Sentinel-2 data with Google Earth Engine. *Remote Sensing*, 16(15), 2695. <https://doi.org/10.3390/rs16152695>
- Bui, Q.-T., Jamet, C., Vantrepotte, V., Mériaux, X., Cauvin, A., & Mognane, M. A. (2022). Evaluation of Sentinel-2/MSI atmospheric correction algorithms over two con-

- trasted French coastal waters. *Remote Sensing*, 14(5), 1099. <https://doi.org/10.3390/rs14051099>
- Chaney, M., Kamenova, I., Dimitrov, P., & Filchev, L. (2025). Evaluation of Sentinel-2 deep resolution 3.0 data for winter crop identification and organic barley yield prediction. *Remote Sensing*, 17(6), 957. <https://doi.org/10.3390/rs17060957>
- DigiFarm. (S. f.). *AI-Powered Satellite Data for Instant Decision Making*. Worldwide. DigiFarm. <https://digifarm.io>
- Donike, S., Aybar, C., Gómez-Chova, L., & Kalaitzis, F. (2025). Trustworthy super-resolution of multispectral sentinel-2 imagery with latent diffusion. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 18, 6940-6952. <https://doi.org/10.1109/JSTARS.2025.3542220>
- Galar, M., Sesma, R., Ayala, C., Albizua, L., & Aranda, C. (2020). Super-resolution of sentinel-2 images using convolutional neural networks and real ground truth data. *Remote Sensing*, 12(18), 2941. <https://doi.org/10.3390/rs12182941>
- Hunt, M. L., Blackburn, G. A., Carrasco, L., Redhead, J. W., & Rowland, C. S. (2019). High resolution wheat yield mapping using Sentinel-2. *Remote Sensing of Environment*, 233, 111410. <https://doi.org/10.1016/j.rse.2019.111410>
- Kociszewski, K., Graczyk, A., Mazurek-Łopacinska, K., & Sobocińska, M. (2020). Social values in stimulating organic production involvement in farming-The case of Poland. *Sustainability*, 12(15), 5945. <https://doi.org/10.3390/su12155945>
- Kowalczyk, P., Tarasiewicz, T., Ziaja, M., Kostrzewa, D., Nalepa, J., Rokita, P., & Kawulok, M. (2023). A real-world benchmark for Sentinel-2 multi-image super-resolution. *Scientific Data*, 10, 644. <https://doi.org/10.1038/s41597-023-02538-9>
- Lanaras, C., Bioucas-Dias, J., Galliani, S., Baltsavias, E., & Schindler, K. (2018). Super-resolution of Sentinel-2 images: Learning a globally applicable deep neural network. *ISPRS Journal of Photogrammetry and Remote Sensing*, 146, 305-319. <https://doi.org/10.1016/j.isprsjprs.2018.09.018>
- Michel, J., Vinasco-Salinas, J., Inglada, J., & Hagolle, O. (2022). Sen2venµs, a dataset for the training of Sentinel-2 super-resolution algorithms. *Data*, 7(7), 96. <https://doi.org/10.3390/data7070096>
- Nadzirah, R., Qurrohman, T., Indarto, Putra, B. T. W., & Andriyani, I. (2024). Estimating harvest yield using Sentinel 2 derivative vegetation indices (Case study: Organic paddy in Candipuro, Lumajang). *AIP Conference Proceedings*, 3176(1), 030061.
- Olvera-Rincón, F., Salgado-Velázquez, S., Córdova-Sánchez, S., Palma-López, D. J., López-Castañeda, A., & Castañeda-Ceja, R. (2024). Defoliación del cultivo de caña de azúcar (*Saccharum officinarum*) en la Chontalpa, Tabasco, México. *Agronomía Mesoamericana*, 35, 53608. <http://doi.org/10.15517/am.2024.53608>
- Salgado-García, S., Palma-López, D. J., Zavala-Cruz, J., Córdova-Sánchez, S., Castelán-Estrada, M., Lagunes-Espinoza, L. del C., Ortiz-García, C. F., Rivera-Cruz, M. del C., Ventura-Ulloa, F., Marín-Aguilar, Á., Moreno-Caliz, E., & Rincón-Ramírez, J. A. (2016). Programa de fertilización sustentable para plantaciones de cítricos en Tabasco, México. *Ecosistemas y Recursos Agropecuarios*, 3(9), 345-356.
- Salgado-Velázquez, S., Salgado-García, S., Rincón-Ramírez, J. A., Rodrigues Jr, F. A., Palma-López, D. J., Córdova-Sánchez, S., & López-Castañeda, A. (2020). Spatial variability of soil physicochemical properties in agricultural fields cultivated with sugarcane (*Saccharum officinarum* L.) in Southeastern Mexico. *Sugar Tech*, 22, 65-75. <https://doi.org/10.1007/s12355-019-00742-9>
- Salgado Velázquez, S., Becerril Hernández, H., Córdova Sánchez, S., Aceves-Navarro, L., & Rincón Ramírez J. J. A. (2023). *Análisis temporal de diferentes índices de vegetación para monitorear el cultivo de caña de azúcar en la Chontalpa, Tabasco*. XLIII Convención y EXPOATAM, Boca del Río, México.
- Salgado-Velázquez, S., Becerril-Hernández, H., Rincón-Ramírez, J. A., Aceves-Navarro, L., & Córdova-Sánchez, S. (2025). Remote sensing and machine learning techniques used to predict sugarcane (*Saccharum spp.*) yield. *Agro Productividad*, 18(9), 229-237. <https://doi.org/10.32854/dp4qtd40>
- Salgueiro Romero, L., Marcello, J., & Vilaplana, V. (2020). Super-resolution of sentinel-2 imagery using generative adversarial networks. *Remote Sensing*, 12(15), 2424. <https://doi.org/10.3390/rs12152424>
- Sambandham, V. T., Kirchheim, K., Ortmeier, F., & Mukhopadhyaya, S. 2024. Deep learning-based harmonization and super-resolution of Landsat-8 and Sentinel-2 images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 212, 274-288. <https://doi.org/10.1016/j.isprsjprs.2024.04.026>

- Servicio de Información Agroalimentaria y Pesquera. (2024). *Avance de siembras y cosechas*. SIAP. [https://nube.agricultura.gob.mx/avance\\_agricola/](https://nube.agricultura.gob.mx/avance_agricola/)
- Shelestov, A., Lavreniuk, M., Kussul, N., Novikov, A., & Skakun, S. (2017). Exploring Google Earth Engine platform for big data processing: Classification of multi-temporal satellite imagery for crop mapping. *Frontiers in Earth Science*, 5, 71. <https://doi.org/10.3389/feart.2017.00017>
- Tarasiewicz, T., Nalepa, J., Farrugia, R. A., Valentino, G., Chen, M., Briffa, J. A., & Kawulok, M. (2023). Multitemporal and multispectral data fusion for super-resolution of Sentinel-2 images. *IEEE Transactions on Geoscience and Remote Sensing*, 61, 5406519. <https://doi.org/10.1109/TGRS.2023.3311622>
- Tejjido-Murias, I., Barrio-Anta, M., & López-Sánchez, C. A. (2024). Evaluation of correction algorithms for Sentinel-2 images implemented in Google Earth Engine for use in land cover classification in Northern Spain. *Forests*, 15(12), 2192. <https://doi.org/10.3390/f15122192>
- Vadrevu, K. P., Le Toan, T., Ray, S. S., & Justice, C. O. (2022). *Remote Sensing of Agriculture and Land Cover/Land Use Changes in South and Southeast Asian Countries*. Springer.
- Weiss, M., Jacob, F., & Duveiller, G. (2020). Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, 236, 111402. <https://doi.org/10.1016/j.rse.2019.111402>
- Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M.-J. (2017). Big data in smart farming-A review. *Agricultural Systems*, 153, 69-80. <https://doi.org/10.1016/j.agsy.2017.01.023>
- Xia, X., Fu, D., Fei, Y., Shao, W., & Xia, X. (2021). An improved assessment method and its application to the latest IMERG rainfall product in mainland China. *Remote Sensing*, 13(24), 5107. <https://doi.org/10.3390/rs13245107>
- Yang, W., Zhang, X., Tian, Y., Wang, W., Xue, J.-H., & Liao, Q. (2019). Deep learning for single image super-resolution: A brief review. *IEEE Transactions on Multimedia*, 21(12), 3106-3121. <https://doi.org/10.1109/TMM.2019.2919431>
- Zabalza, M., & Bernardini, A. (2022). Super-resolution of Sentinel-2 images using a spectral attention mechanism. *Remote Sensing*, 14(12), 2890. <https://doi.org/10.3390/rs14122890>