TECNOLÓGICO NACIONAL DE MEXICO

Instituto Tecnológico de Culiacán

TITULACIÓN INTEGRAL

OPCION:

TESIS PROFESIONAL

NOMBRE DEL PROYECTO:

Módulo De IA Para Detección De Estrés Hídrico En Plataforma De Gestión De Imágenes Multiespectrales Para Agricultura De Precisión.

ALUMNO(S)

ACOSTA CHANG LUIS XAVIER

CARRERA :

INGENIERÍA EN SISTEMAS COMPUTACIONALES

Num(s). De Control.

21170229

Culiacán, Sinaloa,(2026)



Instituto Tecnológico de Culiacán

DIVISION DE ESTUDIOS PROFESIONALES
ASUNTO: **Autorización de Impresión**

Culiacán, Sinaloa, 17/03/2026 12:10

C. LUIS XAVIER ACOSTA CHANG
PASANTE(S) DE LA CARRERA DE INGENIERÍA EN SISTEMAS COMPUTACIONALES
P R E S E N T E.

De acuerdo con fallo emitido por la Comisión Revisora Integrada por:

		Cédula Profesional
Presidente:	Doctorado en Ciencias de la Ingeniería **Zuriel Dathan Mora Felix**	14236234
Secretario:	Doctor en Ciencia y Tecnología con Especialidad en Ingeniería Ambiental **Jesús Gabriel Rangel Peraza**	8327423
Vocal:	Maestría en Ciencias en Ciencias Computacionales **Arcelia Judith Bustillos Martínez**	13118410

Y considerando que reúne los requisitos establecidos en la Opción: **TITULACIÓN INTEGRAL: TESIS PROFESIONAL "MÓDULO DE IA PARA DETECCIÓN DE ESTRÉS HÍDRICO EN PLATAFORMA DE GESTIÓN DE IMÁGENES MULTIESPECTRALES PARA AGRICULTURA DE PRECISIÓN",** damos a usted nuestra autorización para que proceda a imprimir su trabajo profesional.

Sin otro particular, quedo de usted.

A T E N T A M E N T E
Excelencia en Educación Tecnológica®

CONCEPCIÓN MENDOZA ROSALES

LIC. CONCEPCIÓN MENDOZA ROSALES
JEFA DE LA DIVISIÓN DE ESTUDIOS PROFESIONALES

Educación
Secretaría de Educación Pública
INSTITUTO TECNOLÓGICO DE CULIACÁN
DEPARTAMENTO DE
DIVISIÓN DE ESTUDIOS PROFESIONALES



2026 año de Margarita Maza

HOJA DE FIRMAS

CULIACÁN, SINALOA JULIO 2025

DEDICATORIA

Quisiera dedicar este trabajo a todas aquellas personas que han sido fundamentales en mi camino hacia la culminación de mi tesis. A mis padres, por ser el pilar fundamental e inquebrantable de mi vida. Gracias por su amor incondicional, por sus sacrificios silenciosos y por enseñarme que con perseverancia todo es posible. Este logro es el fruto de su esfuerzo y de la fe que siempre han depositado en mí, impulsándome a seguir adelante incluso en los momentos de mayor adversidad durante el desarrollo de esta plataforma y a TWICE, por ser la banda sonora que me acompañó durante las incontables y largas noches de programación, diseño y análisis de datos, cuya energía e inspiración constante, me brindaron la fuerza y la motivación necesarias para superar los retos técnicos y culminar exitosamente esta meta.

AGRADECIMIENTOS

Agradezco a ti, madre, por ser el pilar fundamental de mi vida. Gracias por tu amor incondicional, por tus sacrificios silenciosos y por enseñarme que con perseverancia todo es posible. Este logro no es solo mío, es el fruto de tu esfuerzo y de la fe que siempre has tenido en mí. Gracias por impulsarme a seguir adelante incluso en los momentos más difíciles.

A mis compañeros de tesis: A mis colegas y amigos, por compartir este camino de retos y aprendizajes. Gracias por su compromiso, por las largas noches de programación y por aportar tus conocimientos para que este proyecto saliera adelante. Tu apoyo fue clave para materializar esta plataforma; ha sido un honor trabajar con ustedes.

A mis asesores: Expreso mi sincero agradecimiento a mis asesores, Dr. Zuriel Dathan Mora Felix y Dr. Jesús Gabriel Rangel Peraza, por su acertada dirección y supervisión durante todo este proceso. Gracias por compartir sus conocimientos, por su disposición para resolver dudas y por la guía metodológica que fue indispensable para estructurar y culminar exitosamente este proyecto.

DECLARACIÓN DE AUTENTICIDAD

Por la presente, declaro que el contenido de este proyecto es original y ha sido desarrollado por nuestra parte. Salvo cuando se haga referencia específica al trabajo de otras personas o fuentes externas, este documento no es producto de colaboración externa ni de plagio. Toda la información, el análisis y el desarrollo presentados son resultado de nuestro esfuerzo.

Asimismo, afirmamos que este proyecto no ha sido presentado total ni parcialmente para la obtención de ningún otro título o grado académico, en esta ni en ninguna otra institución.

Acosta Chang Luis Xavier.

Culiacán, Sinaloa, México, 2025

RESUMEN

El presente trabajo de tesis expone el diseño, desarrollo e implementación de la plataforma web de agricultura de precisión, denominada DEEPCROP, para automatizar la gestión y el análisis de imágenes multiespectrales, permitiendo detectar y diagnosticar el estrés hídrico en cultivos mediante modelos de aprendizaje profundo, así como automatizar el procesamiento de series temporales de imágenes satelitales para extraer indicadores vegetativos clave, tales como el NDVI, NDWI y SAVI. Para el desarrollo del estudio, se aplicó una metodología de enfoque tecnológico, iterativo e incremental, apoyándose en el marco de trabajo ágil Scrum y en un diseño de arquitectura distribuida de microservicios.

La población de estudio comprendió diversas parcelas agrícolas ubicadas en la región productiva de Sinaloa. De manera particular, la muestra se conformó por series temporales de imágenes de alta resolución obtenidas de campos de cultivo de chile durante la temporada agrícola de 2023 a 2024. Las técnicas empleadas consistieron en la teledetección satelital, utilizando como instrumento principal los sensores de la constelación PlanetScope, capaces de capturar 8 bandas espectrales con una resolución espacial de 3 metros por píxel, apoyados por scripts de umbralización de Otsu para la creación de las etiquetas de referencia.

El procesamiento masivo de datos se orquestó de forma asíncrona mediante microservicios en Python gestionados a través de Celery y Redis. En esta etapa, las imágenes satelitales fueron normalizadas y segmentadas en parches espaciales de 128x128 píxeles para alimentar y entrenar arquitecturas de redes neuronales, específicamente el modelo supervisado U-Net. Los resultados del demuestran cuantitativamente la capacidad predictiva del modelo U-Net sobre los enfoques de umbralización tradicionales, logrando clasificar las áreas de estrés con una Exactitud (Accuracy) global superior al 93% y un índice de Intersección sobre Unión (IoU) de entre 0.6753 y 0.7213, todo ello operando con una alta eficiencia de latencia promedio cercana a 1.2 segundos por inferencia. Concluyendo que la convergencia del aprendizaje profundo con la teledetección multiespectral facilita el diagnóstico temprano y exacto del déficit de humedad. Con esto, la plataforma DEEPCROP logra cerrar la brecha entre la ciencia de datos geoespaciales y la práctica agrícola, dotando al sector agroalimentario de una herramienta predictiva, escalable y vital para la sostenibilidad hídrica.

PALABRAS CLAVE

- Agricultura de precisión (AP)
- Agricultura sostenible
- Gestión hídrica sostenible
- Estrés hídrico
- Cultivo de tomate / chile
- Teledetección satelital
- Sistemas de Información Geográfica (SIG)
- GPS (Global Positioning System)
- Imágenes Multiespectrales
- Sentinel-2
- PlanetScope / PlanetScope SuperDove
- Google Earth Engine (GEE)
- MSI (MultiSpectral Instrument)
- SWIR (Infrarrojo de onda corta)
- RedEdge (Banda 7)
- Índices de vegetación y agua: NDVI, NDWI, NDRE, PRI, SAVI.
- Procesamiento de imágenes espectrales
- Segmentación Semántica
- IoU (Intersection over Union)
- Aprendizaje Profundo (Deep Learning)
- Arquitectura de red U-Net
- Arquitectura de microservicios
- Sistema web cliente-servidor
- Procesamiento Asíncrono
- Instituto Nacional de Investigaciones Forestales Agrícolas y Pecuarias (INIFAP)
- Secretaría de Agricultura y Desarrollo Rural (SADER)

INDICE GENERAL

CAPÍTULO 1 ..... *C*

1. INTRODUCCIÓN ..... *C*

1.1. Planteamiento del problema **7**

1.2. Formulación de los objetivos **8**

1.2.1. Objetivo general 8

1.2.2. Objetivos específicos 8

1.3. Justificación ..... **G**

CAPÍTULO 2 ..... *10*

2. Marco teórico *10*

2.1. Agricultura de precisión **10**

2.1.1. Evolución y beneficios 10

2.1.2. Aplicación real en México 11

2.2. Teledetección en agricultura **11**

2.3. Imágenes multiespectrales e hiperespectrales **12**

2.4. Índices de vegetación (NDVI, EVI, SAVI) **14**

2.5. Aprendizaje profundo aplicado al análisis de cultivos **15**

2.6. Fuentes de datos **16**

2.6.1. Satélites 17

2.6.2. Vehículos aéreos no tripulados (VANT) 18

2.6.3. Sensores 19

2.7. Estrés hídrico **20**

2.7.1. Efectos fisiológicos del estrés hídrico 20

2.8. Métodos tradicionales y tecnológicos, para su detección **21**

2.G. Teledetección satelital aplicada a la agricultura **21**

2.10. Gestión hídrica mediante agricultura de precisión **21**

2.11. Uso de índices de vegetación e inteligencia artificial en la detección de

estrés hídrico **22**

2.12. Herramientas y software de desarrollo **23**

2.12.1. Lenguaje de programación TypeScript 23

2.12.2. Biblioteca de JavaScript React 24

2.12.3. Lenguaje de programación PHP 25

2.12.4. Framework de desarrollo Laravel 25

2.12.5. Gestor de base de datos MongoDB 26

2.12.6. Python y su ecosistema 26

2.12.7. Sistema de almacenamiento de objetos MinIO 28

CAPÍTULO 3 ..... ***23***

3. Estado del arte ***23***

3.1. Instituciones de datos geográficos **2G**

3.2. Plataformas de obtención de imágenes multiespectrales **30**

3.2.1. Copernicus Browser 30

3.2.2. Planet Scope 31

3.3. Plataformas comerciales de agricultura de precisión en México **32**

3.3.1. AGROLIKA 32

3.3.2. NXTAgro 32

3.4. Plataformas internacionales de agricultura de precisión **33**

3.4.1. PIX4Dfields 33

3.4.2. Agremo 34

3.5. Área de Oportunidad **35**

CAPÍTULO 4 ..... ***3C***

4. Desarrollo del proyecto ***3C***

4.1. Contexto del desarrollo de la plataforma **37**

4.2. Metodología de desarrollo **37**

4.2.1. Adaptación de los roles de Scrum 38

4.2.2. Artefactos de Scrum 39

4.2.3. Especificación de requisitos 39

4.2.4. Planificación general de los Sprints 42

4.2.5. Diseño de la arquitectura 44
4.2.6. Diseño del modelo de datos 48
4.2.7. Diseño de las interfaces 52
4.3. Módulo de Inteligencia Artificial para Detección de Estrés 58
4.3.1. Construcción del Dataset (PlanetScope SuperDove) 58
4.3.2. Arquitectura de la Red Neuronal (U-Net) 59
4.3.3. Proceso de Entrenamiento e Hiperparámetros 60
4.3.4. Arquitectura de la Red Neuronal No Supervisada (Autoencoder Convolucional) 60
4.4. Gestión y Entrenamiento de Modelos (AI Model Manager) 62
4.4.1. Interfaz Funcional 62
4.4.2. Procesamiento Asíncrono con Celery 63
CAPÍTULO 5 ..... C3
5. RESULTADOS Y ANÁLISIS C3
5.1. Casos de Estudio e Inferencias en la Plataforma 63
5.1.1. Caso A: Evaluación en Cultivo con Estrés Severo 63
5.1.2. Caso B: Evaluación en Cultivo con Vigor Saludable 65
5.2. Evaluación Global de Métricas 66
5.3. Análisis de Latencia y Eficiencia Operativa 66
CAPÍTULO C C7
C. CONCLUSIONES C7
6.1. Conclusiones del Proyecto 67
6.2. Trabajo Futuro 67
7. GLOSARIO TÉCNICO INTEGRAL C8
8. REFERENCIAS 70

ÍNDICE DE FIGURAS

FIGURA 1: Teledetección agrícola (Fuente: Imasgal) 11
FIGURA 2: Landsat 1 (Fuente: NASA) 12
FIGURA 3: Imágenes multiespectrales e hiperespectrales (Fuente: JOUAV) 13
FIGURA 4: Índices de vegetación (Fuente: researchgate) 14
FIGURA 5: Imágenes según tipos de cámara y espectros (RGB y NIR) 19
FIGURA 6: Proceso de la metodología Scrum 38
FIGURA 7: Patrón arquitectónico MVC 45
FIGURA 8: Inicio de sesión 52
FIGURA 9: Dashboard principal 53
FIGURA 10: Resultados de la búsqueda de imágenes 53
FIGURA 11: Dashboard de procesamiento de imágenes (Calculos de IV) 54
FIGURA 12: Workspace con resultados de imágenes procesadas 54
FIGURA 13: Resultado de imagen procesada con sus metadatos 55
FIGURA 14:Interfaz de entrenamiento del AI Model Manager con configuración de parámetros y monitoreo de progreso 55
FIGURA 15: Interfaz de inferencia del AI Model Manager con configuración de parámetros y panel de ejecución 56
FIGURA 16: Interfaz de resultados de inferencia con visualizaciones multiespectrales, estadísticas de estrés y opciones de descarga 57
FIGURA 17: Máscara de Ground Truth generada mediante el script de procesamiento tradicional.64
FIGURA 18: Visualización de la anomalía detectada por el modelo U-Net en la plataforma 64
FIGURA 19: Ground Truth del caso B con manchas de estrés periférico 65
FIGURA 20: Inferencia de la plataforma mostrando una mínima activación de anomalías 65

ÍNDICE DE TABLAS

TABLA 1: Comparación entre métodos tradicionales y tecnológicos para la detección del estrés hídrico 21
TABLA 2: Mapeo y aplicación de las bandas espectrales de PlanetScope SuperDove en el modelo 59
TABLA 3: Hiperparámetros y configuración del proceso de entrenamiento supervisado ... 60
TABLA 4:Hiperparámetros del entrenamiento no supervisado. 62

CAPÍTULO 1

1. INTRODUCCIÓN

En las últimas décadas, la agricultura ha experimentado una transformación significativa impulsada por tecnologías que optimizan el uso de recursos y reducen impactos ambientales (Gebbers & Adamchuk, 2010). La agricultura de precisión se ha consolidado como un enfoque estratégico orientado a la gestión específica de cultivos mediante el análisis de datos espaciales y temporales (Arcadia Peralta et al., 2024).

El análisis de imágenes multiespectrales e hiperespectrales se ha convertido en una herramienta relevante para evaluar condiciones fisiológicas de los cultivos a gran escala (Bhakal et al., 2024). Estas imágenes permiten calcular índices de vegetación que reflejan variables como la salud foliar, el contenido de clorofila y el estrés hídrico. Sin embargo, el volumen de información y la complejidad de su procesamiento representan un reto técnico para productores e investigadores.

Este proyecto propone el desarrollo de una plataforma web para la gestión y análisis de imágenes multiespectrales aplicadas a la agricultura de precisión. Su propósito es automatizar la obtención, procesamiento e interpretación de información espectral mediante algoritmos de aprendizaje profundo para apoyar la detección de anomalías en cultivos. La plataforma integra en un solo entorno la consulta de imágenes, el cálculo de índices de vegetación y la visualización geoespacial, facilitando el uso de tecnologías de monitoreo avanzado en contextos donde el acceso a soluciones especializadas es limitado.

El presente documento se organiza en seis capítulos. En el Capítulo 1 se expone la introducción del problema, los objetivos y la justificación del proyecto. En el Capítulo 2 se desarolla el marco teórico, donde se abordan los conceptos fundamentales relacionados con la agricultura de precisión, la teledetección, los índices de vegetación y el aprendizaje profundo aplicado al análisis de cultivos. En el Capítulo 3 se presenta el estado del arte, mediante el análisis de plataformas, herramientas y antecedentes relevantes para la propuesta.

En el Capítulo 4 se describe el desarollo del proyecto, incluyendo la metodología empleada, la arquitectura de la solución y los componentes principales de la plataforma. En el Capítulo

5 se presentan los resultados obtenidos del entrenamiento y validación del modelo de segmentación semántica U-Net, incluyendo las métricas de evaluación (IoU, Accuracy, F1-Score), el análisis de rendimiento y la comparación con trabajos relacionados. Finalmente, en el Capítulo 6 se establecen las conclusiones derivadas del trabajo, las contribuciones al campo de la agricultura de precisión, las limitaciones encontradas y las líneas de trabajo futuro para la continuidad del proyecto.

1.1. Planteamiento del problema

Uno de los desafíos más persistentes en el ámbito agrícola contemporáneo es la limitada capacidad de monitoreo continuo, preciso y en tiempo real del estado fisiológico de los cultivos, especialmente en grandes extensiones de terreno o en zonas con baja disponibilidad de infraestructura tecnológica.

Los métodos tradicionales de supervisión agronómica basados en inspecciones visuales o en el muestreo manual de parcelas resultan lentos, costosos, subjetivos y, en muchos casos, ineficaces para detectar a tiempo variaciones en la salud del cultivo, afectaciones por plagas, deficiencias hídricas o estrés nutricional. Esta falta de precisión y oportunidad en el diagnóstico puede traducirse en decisiones tardías o inadecuadas, con impactos directos en el rendimiento productivo y la sustentabilidad de los sistemas agrícolas.

El uso de imágenes multiespectrales e hiperespectrales obtenidas por satélites representa una oportunidad significativa para evaluar las condiciones fisiológicas de los cultivos mediante la generación de índices de vegetación. Estos índices permiten inferir, de manera remota y objetiva, variables como el vigor de la vegetación, el contenido de clorofila y la presencia de estrés biótico o abiótico. Sin embargo, a pesar de su potencial, la adopción de estas tecnologías en el sector agrícola sigue siendo limitada, debido a factores como la complejidad en el procesamiento de imágenes, la falta de conocimientos especializados en teledetección y el elevado umbral técnico para interpretar los resultados de forma práctica.

Por tanto, se identifica una necesidad urgente de contar con una plataforma integral que automatice el procesamiento y análisis de imágenes hiperespectrales, permita visualizar los índices de vegetación mediante representaciones intuitivas y brinde soporte a la toma de decisiones agrícolas mediante modelos de aprendizaje profundo entrenados con datos

históricos confiables. Dicha solución no solo facilitaría el acceso a tecnologías avanzadas por parte de productores, investigadores y técnicos agrícolas, sino que también permitiría elevar la eficiencia, sostenibilidad y resiliencia del manejo agronómico en entornos diversos.

1.2. Formulación de los objetivos

1.2.1. Objetivo general

Desarrollar una plataforma web para la gestión y análisis automatizado de imágenes multiespectrales e hiperespectrales aplicadas a la agricultura de precisión, que permita calcular índices de vegetación, representar visualmente los resultados en mapas geoespaciales, y detectar anomalías en cultivos mediante el uso de modelos de aprendizaje profundo entrenados con datos históricos.

1.2.2. Objetivos específicos

1. Desarrollar un módulo interactivo que permita al usuario seleccionar zonas agrícolas de interés y obtener imágenes satelitales correspondientes o subir sus propias imágenes para procesar.
2. Diseñar un sistema de almacenamiento interno que permita guardar las imágenes obtenidas para que puedan ser utilizadas en el análisis agrícola.
3. Implementar algoritmos para el cálculo de índices de vegetación (como NDVI, EVI, entre otros) a partir de las imágenes almacenadas, permitiendo al usuario elegir el tipo de análisis que desea realizar.
4. Construir un visor geoespacial interactivo, que represente los resultados de los análisis mediante una codificación cromática intuitiva, facilitando la comprensión visual del estado de los cultivos.
5. Incorporar funcionalidades de análisis histórico y detección de anomalías mediante modelos de aprendizaje profundo, que permitan identificar patrones atípicos en nuevas imágenes con base en datos históricos de cultivos saludables.

1.3. Justificación

En un contexto agrícola cada vez más afectado por fenómenos climáticos, escasez de recursos y la necesidad de mejorar la eficiencia productiva, la incorporación de tecnologías de monitoreo avanzado se ha convertido en una necesidad estratégica para el sector agroalimentario (Valencia, 2018). La agricultura de precisión, como enfoque basado en datos y tecnologías digitales, representa una respuesta eficaz a estos desafíos, permitiendo tomar decisiones informadas en función del estado real y localizado de los cultivos. Sin embargo, su implementación enfrenta todavía múltiples limitaciones técnicas y económicas, especialmente en regiones con escasa infraestructura tecnológica o bajo acceso a herramientas especializadas.

Uno de los principales obstáculos radica en la falta de plataformas accesibles que integren, en un solo entorno, la capacidad de obtener imágenes satelitales, analizarlas de manera automatizada y brindar resultados visuales claros para usuarios no especializados.

Este proyecto de tesis propone una solución integral a esa brecha tecnológica mediante el desarrollo de una plataforma web interactiva y automatizada, que simplifique el acceso, análisis y visualización de información espectral relevante para la agricultura. A través de una interfaz gráfica intuitiva, el usuario podrá seleccionar áreas de interés sobre un mapa para obtener las imágenes satelitales o incluso subir sus propias imágenes. Posteriormente, podrá procesarlas para calcular índices de vegetación, visualizar los resultados de forma comprensible mediante mapas codificados por colores, y guardar estos análisis dentro de su cuenta para consulta futura.

Sin embargo, la incorporación de modelos de aprendizaje profundo (deep learning) que, entrenados con datos históricos de cultivos saludables, podrán identificar patrones anómalos o atípicos en nuevas imágenes otorga valor agregado al sistema, al permitir no solo un diagnóstico actual, sino también una capacidad de alerta temprana basada en datos.

CAPÍTULO 2

2. Marco teórico

El presente capítulo tiene como propósito fundamentar teóricamente el desarrollo del proyecto, proporcionando el marco conceptual necesario para su comprensión integral. En él se examinan los principios que rigen la agricultura de precisión y su importancia estratégica en la administración eficiente de los sistemas de cultivo. Asimismo, se analiza de manera detallada el fenómeno del estrés hídrico, poniendo particular atención en su impacto sobre el cultivo de tomate. Finalmente, se describen las principales herramientas tecnológicas involucradas en la propuesta, entre ellas la teledetección satelital y la aplicación de técnicas de inteligencia artificial, destacando su papel en el análisis y la toma de decisiones en entornos agrícolas.

2.1. Agricultura de precisión

La agricultura de precisión (AP) es un enfoque habilitado por tecnologías de información que observa, mide y analiza las condiciones del cultivo a nivel de parcela individual. Basada en el principio de producir más con menos (Monteiro et al., 2021), esta metodología aprovecha sensores remotos, sistemas de posicionamiento global (GPS), sistemas de información geográfica (SIG) y maquinaria automatizada para optimizar el manejo agronómico y mejorar la toma de decisiones (Ríos Hernández, 2021).

2.1.1. Evolución y beneficios.

Durante las décadas de 1990 y 2000, la agricultura de precisión incorporó GPS, IoT y drones para recolectar datos masivos. Estos avances permiten, por ejemplo, generar mapas de rendimiento en tiempo real, riego variable y fertilización localizada. Sus beneficios reportados incluyen un uso más eficiente de fertilizantes, agua y combustibles, así como una reducción de costos y del impacto ambiental.(Arcadia Peralta et al., 2024)

2.1.2. Aplicación real en México.

Aunque históricamente limitada en grandes áreas por barreras económicas y de capacitación, la agricultura de precisión avanza en México a través de proyectos gubernamentales y de investigación. El INIFAP, SADER y varias universidades han desarrollado plataformas y sistemas de campo. Por ejemplo, SADER e INIFAP lanzaron la plataforma digital Irrimodel, orientada al riego de precisión (Sader, 2023). Esta herramienta permite monitoreo en tiempo real y ahorro de hasta un 40 % de agua en cultivos de riego. Ya se ha implementado en módulos de riego en el norte de Sinaloa, donde reportan ahorros de hasta 1,600 m^3/ha de agua en cultivos de maíz y sorgo, sin reducciones en el rendimiento.

Además, se vincula con sensores de suelo e imágenes satelitales para recomendar cuándo y cuánto regar. Estos casos ilustran aplicaciones concretas de tecnologías de precisión en el contexto sinaloense (Sader, 2023).

2.2. Teledetección en agricultura

La teledetección en agricultura consiste en obtener información sobre los cultivos y suelos sin contacto directo, mediante sensores instalados en plataformas aéreas, satelitales o terrestres (Chuco, 2021). En la Figura 1, se muestra un ejemplo de una imagen obtenida a partir de teledetección sobre un campo agrícola.

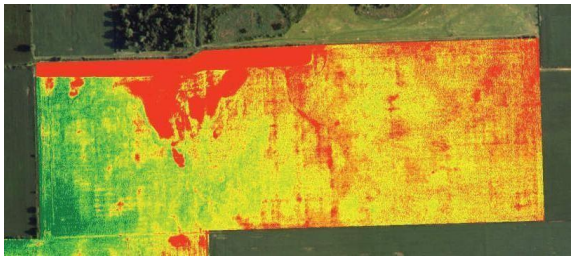


FIGURA 1: Teledetección agrícola
(Fuente: Imasgal).

Estas tecnologías permiten monitorear variables agronómicas (salud vegetal, humedad del suelo, etc.) a grandes escalas y frecuencias regulares. Históricamente, el uso de satélites ha sido fundamental: la era de la teledetección agrícola inició con el lanzamiento del satélite Landsat 1 en 1972.



FIGURA 2: Landsat 1
(Fuente: NASA).

Las sucesivas misiones Landsat (2–8) proporcionaron imágenes multiespectrales de alta calidad para la gestión de recursos naturales. En 1986 y 1988 fueron lanzados satélites multiespectrales adicionales (SPOT 1, IRS-1A) usados en clasificación de cultivos y evaluación de cobertura terrestre (Sishodia et al., 2020).

Asimismo, en las últimas décadas se incorporaron plataformas más flexibles. Los satélites modernos (Sentinel, MODIS, Landsat 8/9, etc.) ofrecen datos multiespectrales gratuitos de resolución moderada, útiles para índices de vegetación y monitoreo climático. Para escalas más finas, se emplean vehículos aéreos no tripulados (VANT) con sensores multi/hiperespectrales y termales, que brindan información a nivel de parcela con alta resolución espacial (Sishodia et al., 2020).

2.3. Imágenes multiespectrales e hiperespectrales

Las imágenes multiespectrales capturan un número reducido de bandas (ej. visible e infrarrojo) abarcando rangos espectrales amplios (decenas a cientos de nm). En cambio, las imágenes hiperespectrales adquieren cientos de bandas contiguas muy estrechas (<10 nm), lo que permite captar respuestas espectrales muy detalladas de los cultivos. Por ejemplo, sensores multiespectrales satelitales (Landsat, Sentinel-2, SPOT) han sido muy usados para estimar atributos agrícolas como contenido de clorofila, biomasa, rendimiento y degradación

del suelo. Sin embargo, su limitada resolución espectral hace que sea difícil detectar señales tempranas de estrés vegetal o diferencias sutiles entre especies (Lu et al., 2020).

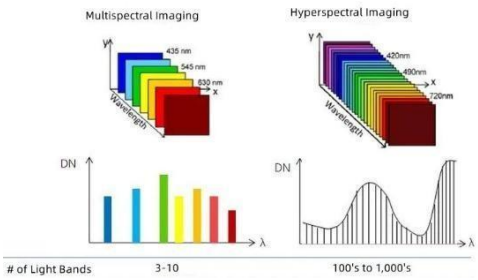


FIGURA 3: Imágenes multiespectrales e hiperespectrales (Fuente: JOUAV).

En contraste, las imágenes hiperespectrales (p.ej. sensores Hyperion, CASI, sistemas montados en drones) pueden revelar variaciones espectrales finas, mejorando la identificación de tipos de cultivo, niveles de nutrientes o estrés hídrico. Estudios han demostrado que las hiperespectrales superan a las multiespectrales al estimar propiedades vegetales Lu et al. (2020) demostraron que las imágenes hiperespectrales permiten detectar estrés hídrico en cultivos de maíz con mayor precisión que los sensores multiespectrales tradicionales, al capturar información continua del espectro electromagnético entre 400 y 2500 nm.

Asimismo, Niu et al. (2025) utilizaron datos hiperespectrales combinados con técnicas de aprendizaje profundo para la clasificación y segmentación de cultivos, logrando mejoras significativas en la precisión del mapeo agrícola mediante el uso de índices de vegetación derivados de bandas espectrales estrechas: por ejemplo, se logra mayor precisión en índices como el área foliar (LAI), clasificación de cultivos, estimación de biomasa y contenido de nitrógeno foliar. No obstante, las imágenes hiperespectrales generan volúmenes de datos muy grandes y requieren sensores y misiones costosas.

Además, presentan desafíos técnicos (ruido, calibración compleja) que dificultan su uso masivo. Recientemente han surgido sensores hiperespectrales más pequeños y económicos, así como nuevos satélites (DESIS, PRISMA, EnMAP) que amplían su disponibilidad (Lu et al., 2020).

2.4. Índices de vegetación (NDVI, EVI, SAVI)

Existen diversos indicadores de vegetación utilizados en la agricultura de precisión, sin embargo, los más importantes y utilizados actualmente se mencionan a continuación:

Los índices de vegetación (IV) son combinaciones matemáticas de bandas espectrales diseñadas para resaltar la presencia y estado de vegetación. Los más recomendados se mencionan a continuación:

- NDVI (Normalized Difference Vegetation Index): calcula la diferencia normalizada entre la reflectancia en banda infrarroja cercana (NIR) y roja

$$NDVI = \frac{(NIR - ROJO)}{(NIR + ROJO)}$$

Toma valores entre –1 y +1; valores cercanos a +1 (p.ej. 0.6–0.9) indican vegetación densa y saludable. El NDVI es valorado por su simplicidad y amplia aplicabilidad en seguimiento vegetativo. Sin embargo, tiende a saturarse en vegetación muy densa y es sensible a suelos brillantes o condiciones atmosféricas adversas (Nițu et al., 2025).

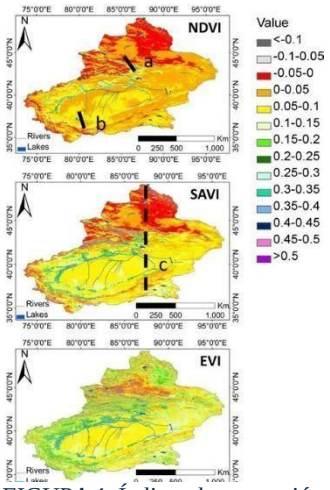


FIGURA 4: Índices de vegetación (Fuente: researchgate).

- EVI (Enhanced Vegetation Index): índice mejorado que corrige la influencia del suelo y la atmósfera. Incorpora la banda azul para atenuar efectos de aerosoles y alta reflectancia en rojo, resultando más útil en zonas de alta biomasa donde el NDVI se satura (Nițu et al., 2025).
- SAVI (Soil-Adjusted Vegetation Index): similar al NDVI, pero incorpora un factor de ajuste L para reducir la influencia del suelo desnudo. Cuando L=0 el SAVI coincide con NDVI; típicamente se recomienda L=0.5 en áreas de vegetación baja. Gracias a este ajuste, el SAVI mejora el monitoreo en paisajes heterogéneos con fondo de suelo expuesto (Nițu et al., 2025).
- NDWI (Normalized Difference Water Index): Índice diseñado para detectar el contenido de agua en la vegetación y cuerpos de agua superficial. Utiliza la banda del infrarrojo cercano (NIR) y el infrarrojo de onda corta (SWIR), aprovechando la absorción del agua en esta última región del espectro. La fórmula es:

$$\text{NDWI} = \frac{(\text{NIR} - \text{SWIR})}{(\text{NIR} + \text{SWIR})}$$

Donde valores cercanos a 1 indican alta presencia de agua, mientras que valores cercanos a -1 corresponden a suelo seco o vegetación sin estrés hídrico.

- NDRE (Normalized Difference Red Edge): Índice que utiliza la banda del borde rojo (Red Edge, 705-750 nm) para estimar el contenido de clorofila y el estado nutricional de la vegetación. Es particularmente útil para detectar estrés en etapas tempranas antes de que sea visible con índices tradicionales como NDVI. La fórmula es:

$$\text{NDRE} = \frac{(\text{NIR} - \text{RedEdge})}{(\text{NIR} + \text{RedEdge})}$$

Donde valores más altos indican mayor contenido de clorofila y mejor estado fisiológico del cultivo.

Estos índices se usan para estimar vigor vegetal, cobertura foliar, contenido de clorofila o estrés hídrico a escala de campo. Cada uno tiene ventajas y limitaciones: por ejemplo, NDVI es ampliamente confiable para vegetación moderada, pero EVI y SAVI ofrecen correcciones cuando el suelo o la atmósfera afectan la señal. En la práctica, se eligen según la situación del cultivo y disponibilidad de bandas espectrales, como se muestra en la Figura 4.

2.5. Aprendizaje profundo aplicado al análisis de cultivos

El aprendizaje profundo (Deep Learning, DL) ha revolucionado el procesamiento de datos agrícolas. Estas técnicas de inteligencia artificial utilizan redes neuronales profundas con múltiples capas para aprender características directamente de las imágenes sin necesidad de extracción manual. DL puede modelar relaciones complejas y no lineales entre las bandas espectrales y atributos del cultivo, mejorando la predicción de variables difíciles de modelar con métodos tradicionales (Joshi et al., 2023).

Entre las arquitecturas más empleadas en teledetección agrícola destacan las redes neuronales convolucionales (CNN), las redes neuronales recurrentes (RNN/LSTM) y los transformadores (Transformers). Las CNN, en particular, han demostrado gran éxito en tareas de visión por computadora: son excelentes identificando patrones espaciales en imágenes, por ejemplo, para clasificación de cultivos o segmentación de áreas afectadas. Por su parte, las RNN/LSTM son útiles para analizar series temporales (p.ej. evoluciones

fenológicas), y los transformadores permiten procesar secuencias de datos complejas. Gracias a estas capacidades, el DL se aplica a problemas como detección de enfermedades, estimación de rendimiento, mapeo de malezas y predicción de estrés, brindando herramientas automatizadas para el monitoreo y gestión agrícola (Joshi et al., 2023).

En México varios estudios han entrenado las CNN como Montiel-González et al. (2022) que aplicaron redes CNN a imágenes satelitales (Sentinel-2) para clasificar uso de suelo y vegetación en la cuenca Atoyac-Salado (Puebla/Morelos). Su CNN aprendió a reconocer 22 clases de cobertura terrestre diferentes, obteniendo una precisión del 84.6 % en su conjunto de prueba. Esto demuestra que el aprendizaje profundo puede manejar información compleja (patrones espectrales y espaciales) para mapear cultivos y áreas naturales, utilidad clave en agricultura de precisión (Montiel González et al., 2022).

2.6. Fuentes de datos

Las plataformas de gestión utilizadas en la agricultura de precisión requieren de múltiples fuentes de datos que permitan realizar un análisis integral, confiable y contextualizado del estado de los cultivos. Estos datos no solo deben ser precisos y actualizados, sino también proporcionar información histórica que facilite la toma de decisiones a corto, mediano y largo plazo.

La capacidad de procesar y visualizar esta información de manera eficiente es esencial para definir las propiedades y características del suelo para lograr una productividad óptima, que ayude a resolver los problemas del uso adecuado de los recursos, los altos costos y el impacto medioambiental (Ríos, 2021).

Algunas de las fuentes de datos más relevantes utilizadas en este tipo de plataformas son los satélites, VANT, también conocidos como drones, y los sensores terrestres. Cada una de estas tecnologías contribuye de manera complementaria a la recopilación de información clave para el monitoreo y análisis de los cultivos. Por ejemplo, los sensores de suelo proporcionan datos en tiempo real sobre variables críticas como la humedad y la temperatura del suelo. Estos datos permiten a los agricultores optimizar el riego, reduciendo el consumo de agua y mejorando la eficiencia de las operaciones agrícolas. Asimismo, los VANT se utilizan cada vez más para realizar monitoreos detallados de los cultivos, detectando enfermedades y

evaluando el rendimiento de manera precisa. Estas tecnologías no solo aumentan la productividad, sino que también promueven prácticas más sostenibles y menos perjudiciales para el medio ambiente (Guamán-Rivera, 2023).

2.6.1. Satélites

Un satélite artificial se define como un vehículo tripulado o no que se coloca en órbita alrededor de la Tierra o de otro astro, y que lleva aparatos apropiados para recoger información y retransmitirla. Así pues, un satélite artificial es un dispositivo fabricado por el ser humano para la realización de unas funciones determinadas, describiendo una trayectoria determinada en el espacio exterior (Ordoñez, 2013).

Con la variedad de satélites que orbitan la Tierra, hoy en día es posible obtener datos valiosos para una amplia gama de aplicaciones, que van desde el monitoreo ambiental hasta la agricultura de precisión. La utilidad de estos datos depende en gran medida de la resolución espacial (nivel de detalle de las imágenes) y espectral (número y tipo de bandas de luz captadas) de los sensores a bordo de cada satélite. Entre los sistemas de observación más destacados se encuentra la misión Sentinel-2, parte del Programa Copernicus de la Agencia Espacial Europea (ESA), dedicada a la observación sistemática y continua de la superficie terrestre (Borras et al, 2017).

La misión Sentinel-2 está compuesta por dos satélites gemelos: Sentinel-2A, lanzado en junio de 2015, y Sentinel-2B, lanzado en marzo de 2017. Esta constelación fue diseñada para ofrecer una cobertura global con un tiempo de revisita de tan solo cinco días en el ecuador, lo que permite obtener imágenes frecuentes y actualizadas de cualquier punto del planeta. Gracias a esta alta frecuencia temporal, Sentinel-2 se convierte en una herramienta clave para detectar cambios en la superficie terrestre, clasificar usos del suelo, generar mapas de riesgos, monitorear desastres naturales y analizar el estado de la vegetación a lo largo del tiempo. (Borràs et al., 2017; Sishodia et al., 2020; Mulla, 2013).

El instrumento principal de Sentinel-2 es el sensor multiespectral (MSI), que captura imágenes en 13 bandas espectrales que abarcan desde el espectro visible hasta el infrarrojo de onda corta (SWIR). Estas bandas se distribuyen en distintas resoluciones: cuatro de 10 metros (tres en el visible y una en el infrarrojo cercano), seis de 20 metros y tres de 60 metros

dedicadas principalmente a la corrección atmosférica y detección de nubes. En particular, se incluyen tres bandas en la región del red-edge (borde rojo), las cuales ofrecen mejoras significativas en la detección y análisis del estado de la vegetación y cuerpos de agua, en comparación con satélites más antiguos como Landsat o SPOT (CDSE, 2025).

Los datos brutos de Sentinel-2 (nivel 1C) pueden ser procesados mediante el software Sen2Cor, desarrollado por la ESA, el cual aplica técnicas de corrección atmosférica y genera productos de reflectancia de nivel 2A (Bottom-of-Atmosphere) (Main-Knorn et al., 2017), además de mapas auxiliares como el espesor óptico de aerosoles, vapor de agua y mapas de clasificación de escenas. Este proceso garantiza que los datos sean más precisos y útiles para análisis cuantitativos en estudios de medio ambiente, agricultura, hidrología, entre otros.

Sentinel-2 fue diseñado con una órbita heliosincrónica a 786 km de altitud, lo que le permite tomar imágenes a las 10:30 a.m. hora local solar, momento ideal para minimizar la presencia de nubes y asegurar buena iluminación solar. Además, su horario de paso es cercano al de otras misiones como Landsat, lo que permite complementar y comparar datos entre satélites. Con una vida útil estimada de 7 años, extendida mediante propulsión hasta 12 años, Sentinel-2 asegura la continuidad y estabilidad de datos en el largo plazo (Borras et al, 2017)

2.6.2. Vehículos aéreos no tripulados (VANT)

Los VANT permiten el desarrollo autónomo o semiautónomo de diferentes tipos de misiones que abarcan desde los sectores de defensa y seguridad hasta los de agricultura y medio ambiente. El interés en su desarrollo, tanto a nivel de centros de investigación como de sectores productivos, ha crecido debido a su versatilidad, menor costo operativo y capacidad para adquirir información detallada del territorio. (Barrientos et al, 2007)

El empleo de VANT para la toma de imágenes aéreas de una elevada resolución posee múltiples beneficios sobre el uso de aviones tripulados y satélites con iguales fines, ya que estos pueden brindar una calidad superior en los mapas, operan en el ámbito local y logran sobrevolar áreas inaccesibles.

De acuerdo con Kharuf (2018), la obtención de imágenes del terreno se lleva a cabo de manera simultánea en distintas franjas del espectro electromagnético, conocidas como bandas. Su importancia radica en que permiten registrar las características espectrales del

suelo y de la vegetación, como la reflectancia, la transmitancia y la absorbancia, las cuales están relacionadas con procesos y factores esenciales como la fotosíntesis, el contenido de agua, la concentración de clorofila o la biomasa presente. En el ámbito de la agricultura de precisión, estas imágenes han demostrado ser herramientas eficaces. Entre sus aplicaciones destacan el análisis para estimar el nivel de carotenoides en hojas de viñedos, la detección de condiciones de estrés hídrico en plantas y la elaboración de modelos de superficie destinados a calcular el rendimiento de cultivos como el maíz.

En el mercado internacional hay diversos tipos de drones para la agricultura. Los más utilizados en este campo son el multirrotor-cuadricóptero (tiempo de vuelo de 30 minutos y cobertura por vuelo de 65 ha). Un aspecto importante son los sensores utilizados y calibrados para la agricultura, ver un ejemplo en la Figura 5 de sensores que capturan imágenes rojo-verde-azul (RGB) e infrarrojo cercano (NIR) (Rios, 2021).

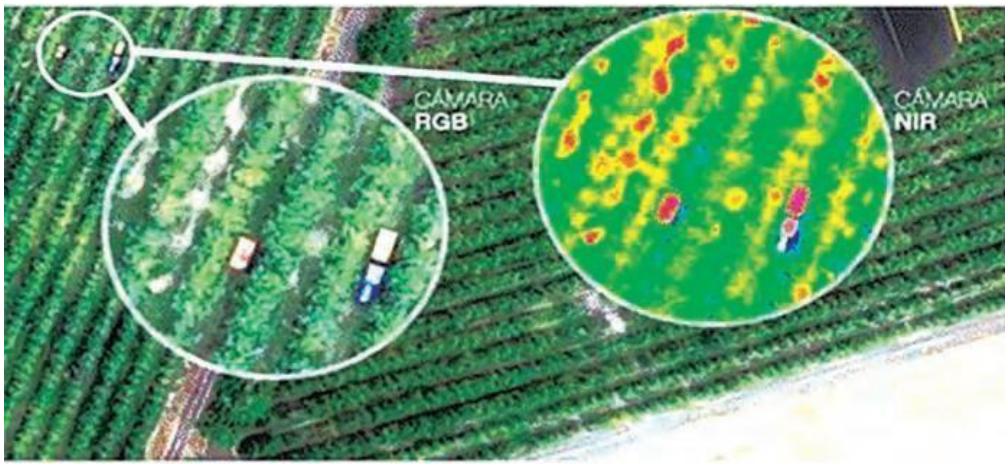


FIGURA 5: Imágenes según tipos de cámara y espectros (RGB y NIR)

Fuente: Revista de ingeniería agrícola.

2.6.3. Sensores

"El sensor es la parte de la cámara encargada de transformar la energía de la radiación electromagnética que recibe en corriente eléctrica. Los sensores digitales, de interés para este proyecto, están formados por un área rectangular compuesto por un conjunto de células fotosensibles." (Morales 2019)

De acuerdo con Guamán-Rivera (2023), en el contexto de la agricultura de precisión, los sensores desempeñan un papel esencial al permitir la recolección de información detallada y

localizada sobre el estado del suelo y de los cultivos. Gracias a ellos es posible identificar la variabilidad espacial y temporal dentro de un terreno agrícola, detectando factores como diferencias en humedad, disponibilidad de nutrientes, presencia de plagas o estrés hídrico. Esta información facilita la aplicación de insumos de manera específica y controlada, optimizando recursos como agua y fertilizantes, al tiempo que se minimizan los costos y el impacto ambiental. De esta forma, los sensores se convierten en una herramienta estratégica que contribuye a mejorar el rendimiento, la sostenibilidad y la eficiencia en los procesos productivos de la agricultura moderna.

Como menciona Guzmán et al. (2022), el uso de sensores en conjunto con VANT se ha intensificado en las últimas décadas, destacando por su capacidad de capturar imágenes con alta resolución espacial y por la flexibilidad de realizar adquisiciones en el momento requerido. Estos sensores se caracterizan por ser portátiles, versátiles, livianos y de bajo costo operativo en comparación con los instalados en plataformas aéreas tripuladas. Asimismo, los VANT pueden incorporar una amplia gama de dispositivos en su carga útil, incluyendo sensores activos y pasivos, cámaras ópticas en las bandas visible, infrarrojo cercano e infrarrojo térmico, así como sistemas de microondas (SAR) y escáneres láser (LIDAR).

2.7. Estrés hídrico

El estrés hídrico ocurre cuando la disponibilidad de agua en el suelo es insuficiente para satisfacer las necesidades fisiológicas del cultivo (Jones, 2007). Esto afecta directamente el crecimiento, rendimiento y calidad del fruto (Ripoll et al., 2016).

2.7.1. Efectos fisiológicos del estrés hídrico

- Reducción de la fotosíntesis: Cierre estomático limita la absorción de CO2 (Chaves et al., 2003).
- Alteración en la producción de frutos: Frutos más pequeños y con mayor concentración de sólidos solubles (Ripoll et al., 2016).
- Mayor susceptibilidad a enfermedades: Las plantas estresadas son más vulnerables a patógenos (Jones, 2007).

2.8. Métodos tradicionales y tecnológicos, para su detección

La detección del estrés hídrico ha evolucionado desde métodos manuales y subjetivos, a menudo tardíos, hacia tecnologías modernas que ofrecen análisis objetivos y a gran escala. En la TABLA 1 se comparan ambos enfoques.

TABLA 1: Comparación entre métodos tradicionales y tecnológicos para la detección del estrés hídrico.

MÉTODO TRADICIONAL	MÉTODO TECNOLÓGICO
Inspección visual (subjetiva)	Imágenes multiespectrales (NDVI)
Medición manual de humedad del suelo	Sensores de humedad en tiempo real
Muestreo destructivo	Teledetección satelital (Landsat, Sentinel-2)

2.9. Teledetección satelital aplicada a la agricultura.

La teledetección permite obtener información espectral de los cultivos mediante sensores instalados en satélites (Lillesand et al., 2015). Es una herramienta clave. Su principal valor es que permite monitorear variables agronómicas, como la salud vegetal y la humedad del suelo, a grandes escalas y con una frecuencia regular. Es invaluable para identificar variaciones espaciales dentro de los cultivos, permitiendo a los agricultores detectar zonas específicas con problemas, como estrés hídrico, en lugar de tratar todo el campo por igual.

2.10. Gestión hídrica mediante agricultura de precisión

La administración eficiente del agua en los sistemas agrícolas constituye un elemento esencial para avanzar hacia modelos productivos sostenibles y capaces de enfrentar los efectos del cambio climático. En este sentido, la agricultura de precisión se ha consolidado como un enfoque tecnológico que favorece la optimización del recurso hídrico mediante la incorporación de herramientas como sensores remotos, sistemas de información geográfica (SIG) y modelos predictivos sustentados en técnicas de inteligencia artificial.

La implementación de sensores de humedad del suelo, estaciones meteorológicas automatizadas y plataformas de observación satelital posibilita el seguimiento continuo de variables determinantes, entre ellas la evapotranspiración, el contenido de agua disponible en el perfil edáfico y las condiciones fisiológicas del cultivo. Estos datos son integrados en

sistemas de apoyo a la toma de decisiones (Decision Support Systems, DSS), los cuales generan recomendaciones precisas respecto al momento oportuno y al volumen de riego requerido en cada sector del terreno (Universidad de Palermo, 2022).

Una de las principales ventajas de este enfoque radica en la capacidad de discriminar espacialmente las necesidades hídricas dentro de una misma parcela, permitiendo ajustar el riego de manera diferenciada.

Esta segmentación reduce pérdidas por sobreaplicación, incrementa la eficiencia energética de los sistemas de irrigación y contribuye a una gestión más racional del recurso.

De igual forma, la teledetección satelital y el análisis multitemporal de índices como el NDVI y el NDWI facilitan la elaboración de mapas de estrés hídrico basados en información objetiva y actualizada, fortaleciendo el proceso de toma de decisiones.

Adicionalmente, el uso de modelos predictivos posibilita anticipar escenarios de déficit hídrico y simular alternativas de manejo bajo distintas condiciones climáticas, lo que representa una ventaja estratégica frente a contextos de variabilidad ambiental. Estas capacidades no solo inciden positivamente en el rendimiento productivo, sino que también favorecen la conservación del agua y la adaptación del sector agrícola a escenarios de mayor presión sobre los recursos naturales.

En consecuencia, la adopción de estrategias de agricultura de precisión orientadas al manejo del riego se presenta no solo como una opción técnicamente factible, sino como una necesidad estructural para garantizar la sostenibilidad de la producción agrícola en regiones con limitaciones hídricas.

2.11. Uso de índices de vegetación e inteligencia artificial en la detección de estrés hídrico

Investigaciones recientes evidencian que la integración de imágenes satelitales con algoritmos de aprendizaje automático constituye una metodología robusta para la identificación del estrés hídrico en cultivos. En particular, el estudio desarrollado por Ghulam et al. (2022) examina la efectividad de diversos índices de vegetación derivados de imágenes

Sentinel-2 en la predicción del estrés hídrico en cultivos de tomate mediante técnicas de machine learning.

En dicha investigación se analizaron índices como el NDVI (Normalized Difference Vegetation Index), NDWI (Normalized Difference Water Index), SAVI (Soil-Adjusted Vegetation Index) y EVI (Enhanced Vegetation Index), estableciendo correlaciones con mediciones de campo relacionadas con la humedad del suelo y el contenido hídrico de las plantas. Posteriormente, se entrenaron modelos predictivos tales como Random Forest (RF), Support Vector Machine (SVM) y K-Nearest Neighbors (KNN), obteniéndose niveles de precisión superiores al 80 % en la clasificación de áreas afectadas por estrés hídrico.

Los hallazgos del estudio confirman la pertinencia del enfoque que combina teledetección e inteligencia artificial dentro del marco de la agricultura de precisión, especialmente en el caso del tomate, cultivo altamente sensible a variaciones en la disponibilidad de agua. Asimismo, se demuestra que el análisis multiespectral junto con la modelación automatizada permite identificar de manera geoespacial zonas críticas dentro del predio agrícola, facilitando decisiones fundamentadas sobre la programación y ajuste del riego (Ghulam et al., 2022).

2.12. Herramientas y software de desarrollo

En el diseño y construcción de plataformas orientadas a la gestión de información, resulta esencial la elección de herramientas tecnológicas que faciliten tanto el desarrollo como el mantenimiento del sistema. Estas deben garantizar la integración entre los distintos procesos involucrados, desde la captura y procesamiento de datos hasta su almacenamiento y visualización. Actualmente, existe una amplia variedad de lenguajes, frameworks y gestores de bases de datos que pueden emplearse para este fin; sin embargo, para el presente proyecto se seleccionaron aquellas tecnologías que mejor se adaptan a los requerimientos planteados y que se describen en los apartados siguientes.

2.12.1. Lenguaje de programación TypeScript

TypeScript es un lenguaje de programación de código abierto desarrollado por Microsoft que extiende las funcionalidades de JavaScript al incorporar un sistema de tipado estático y

características propias de lenguajes orientados a objetos. De acuerdo con Goldberg (2022), su principal objetivo es facilitar la escritura de código más seguro, legible y mantenible, reduciendo errores comunes durante el desarrollo. Entre sus características más destacadas se encuentran: la compatibilidad total con JavaScript, lo que permite utilizar cualquier biblioteca existente; el sistema de tipos estáticos que ayuda a detectar fallos antes de la ejecución; el soporte para interfaces, genéricos y módulos, que fomentan la reutilización y escalabilidad del código; y una integración nativa con herramientas de desarrollo e IDEs que mejora la autocompletación y la refactorización. Además, TypeScript se compila a JavaScript estándar, lo que asegura su ejecución en cualquier navegador o entorno que soporte dicho lenguaje, convirtiéndolo en una herramienta ampliamente adoptada en el desarrollo de aplicaciones web modernas.

2.12.2. Biblioteca de JavaScript React

De acuerdo con Lazuardy et al. (2022) React.js es una biblioteca de JavaScript enfocada en la construcción de interfaces de usuario interactivas y eficientes, ampliamente utilizada en el desarrollo de aplicaciones web modernas. Su arquitectura se basa en el uso de componentes reutilizables, lo que facilita la creación de interfaces modulares y bien estructuradas. Una de sus principales características es el empleo del Virtual DOM, el cual optimiza la actualización de los elementos en pantalla al renderizar únicamente los cambios necesarios, mejorando así el rendimiento de la aplicación. Además, React soporta tanto componentes de clase como funcionales (Hooks), ofrece flexibilidad en la gestión del ciclo de vida de los elementos y promueve la construcción de aplicaciones bajo el modelo de Single Page Application (SPA), lo que permite experiencias más rápidas y dinámicas para el usuario.

Entre las principales ventajas de React.js se encuentran su capacidad para reutilizar componentes, lo que reduce la redundancia en el código y acelera el desarrollo, así como el soporte para renderizado del lado del cliente (*Client-Side Rendering*), que disminuye la carga sobre el servidor y mejora la experiencia del usuario en aplicaciones dinámicas. Sin embargo, también presenta algunas limitaciones: la dependencia del renderizado en el cliente puede generar pantallas en blanco en la carga inicial, lo que impacta en la optimización para motores de búsqueda (SEO); además, requiere librerías adicionales como React Router para el manejo de rutas o para evitar problemas en la comunicación entre componentes. A pesar de estas

desventajas, React se mantiene como una de las tecnologías más populares gracias a su flexibilidad, rendimiento y el amplio ecosistema de herramientas que lo acompaña.

2.12.3. Lenguaje de programación PHP

Según Kumar (2022), PHP (Hypertext Pre-Processor) es un lenguaje de script del lado del servidor utilizado principalmente para el desarrollo de páginas web dinámicas e interactivas. El código escrito en PHP se inserta dentro del HTML mediante etiquetas específicas y es procesado por el servidor para generar el contenido que se envía al cliente. Se trata de uno de los lenguajes más utilizados en el ámbito del desarrollo web debido a su facilidad de aprendizaje, amplia comunidad de soporte y capacidad de integración con múltiples herramientas y tecnologías. Entre sus características principales destacan ser un software libre y de código abierto, la posibilidad de incrustar código directamente en HTML, su sintaxis sencilla, la compatibilidad multiplataforma, el soporte para programación orientada a objetos y la integración nativa con bases de datos. Asimismo, PHP proporciona seguridad, buen rendimiento en servidores web e infraestructura sólida para la gestión de errores y el desarrollo de aplicaciones escalables.

En cuanto a sus aplicaciones, PHP es ampliamente empleado en la creación y administración de sitios web y aplicaciones, el desarrollo de interfaces gráficas, soluciones de comercio electrónico y sistemas de gestión de contenidos. También permite generar documentos PDF, enviar y gestionar correos electrónicos, manipular e interpretar imágenes, crear plantillas dinámicas y dar soporte a diversas funciones relacionadas con la gestión de datos en entornos web. Estas características convierten a PHP en una de las herramientas más versátiles y extendidas dentro del ecosistema de tecnologías para el desarrollo de aplicaciones basadas en internet.

2.12.4. Framework de desarrollo Laravel

Laravel es un framework de desarrollo web basado en PHP que facilita la creación de aplicaciones modernas mediante el uso del patrón de arquitectura Modelo–Vista–Controlador (MVC). De acuerdo con Subecz (2021), se trata de una de las herramientas más utilizadas por programadores principiantes y avanzados debido a su sintaxis expresiva, modularidad y capacidad para reducir significativamente el tiempo de desarrollo. Entre sus

principales funciones destacan un motor de enrutamiento simple y rápido, la integración con diferentes bases de datos a través del ORM Eloquent, el uso de migraciones y seeders para gestionar estructuras y registros, así como la incorporación de controladores RESTful para la construcción de API. Además, Laravel ofrece un sistema de plantillas mediante Blade, servicios de autenticación y autorización integrados, middleware para gestionar solicitudes HTTP y mecanismos de validación y seguridad frente a ataques comunes como inyección SQL o XSS. Estas características convierten a Laravel en una herramienta robusta, escalable y eficiente para el desarrollo de aplicaciones web modernas.

2.12.5. Gestor de base de datos MongoDB

MongoDB es una base de datos NoSQL de tipo documental que se caracteriza por su alta escalabilidad, flexibilidad en el manejo de esquemas y rapidez en las operaciones de lectura y escritura. A diferencia de las bases de datos relacionales, que se rigen por el modelo ACID (Atomicidad, Consistencia, Aislamiento y Durabilidad), MongoDB se sustenta en el modelo BASE (Basically Available, Soft-state, Eventually Consistent), priorizando la disponibilidad y el rendimiento por encima de la consistencia inmediata. Su funcionamiento se basa en el almacenamiento de documentos en formato BSON, lo que permite un desarrollo ágil y adaptable a diversas aplicaciones como sistemas de analítica en tiempo real, entornos de Internet de las Cosas (IoT) y plataformas de contenidos. Desde la perspectiva del teorema CAP, MongoDB se clasifica como un sistema CP (Consistencia y Tolerancia a Particiones), ya que mantiene la consistencia de los datos incluso en presencia de fallos de red, aunque esto puede afectar la disponibilidad. No obstante, al distribuir las lecturas en nodos secundarios se mejora el rendimiento, introduciendo un grado de consistencia eventual. Para gestionar este equilibrio entre fiabilidad y desempeño, MongoDB emplea mecanismos configurables de lectura y escritura (read y write concerns), así como técnicas de optimización como índices, sharding, caching y control de concurrencia a nivel de documento. Si bien su principal limitación es la falta de consistencia estricta, lo que puede representar un riesgo en aplicaciones críticas como las financieras o de salud, su diseño lo convierte en una solución flexible y eficiente para sistemas distribuidos a gran escala (Dhanagari, 2024).

2.12.6. Python y su ecosistema

Python es un lenguaje de programación interpretado, de alto nivel y multipropósito, conocido por su sintaxis clara y legible, que promueve la productividad del desarrollador. De acuerdo con Grinberg (2021), en el ámbito del desarrollo web, Python se emplea frecuentemente para la creación de servicios backend y API RESTful, especialmente a través de micro-frameworks como Flask. Flask (3.0.0) proporciona una base ligera y modular para construir aplicaciones web, permitiendo a los desarrolladores escalar con extensiones según sea necesario. Para este proyecto, se utiliza en conjunto con Flask-CORS (4.0.0) para gestionar las políticas de intercambio de recursos de origen cruzado (CORS), permitiendo que el frontend (React) consuma la API de forma segura.

El verdadero poder de Python para este proyecto reside en su robusto ecosistema para el cómputo científico y el procesamiento de datos (McKinney, 2022). Se emplean las siguientes librerías clave:

- Procesamiento de datos: NumPy (1.26.0) es la biblioteca fundamental para el cómputo numérico, ofreciendo estructuras de datos de tipo *array* (arreglos) de alto rendimiento. rasterio (1.3.9) se especializa en la lectura y escritura de datos geoespaciales en formato ráster (como GeoTIFF), permitiendo el acceso a metadatos y la manipulación de bandas de imágenes satelitales.
- Manipulación de imágenes y visualización: Pillow (10.1.0) se utiliza para tareas de manipulación de imágenes, como redimensionar, recortar o cambiar formatos. matplotlib (3.8.0) permite la generación de visualizaciones estáticas, como histogramas o gráficos de las bandas de datos, que pueden ser servidas a través de la API.
- Gestión y conectividad: python-dotenv (1.0.0) facilita la gestión de la configuración del entorno, cargando variables (como claves de API o conexiones de base de datos) desde archivos .env. Finalmente, requests (2.31.0) se utiliza para realizar peticiones HTTP a otros servicios o descargar archivos externos.

Esta combinación permite a Python actuar como un potente servicio de procesamiento que expone funcionalidades complejas de análisis de datos e imágenes a través de una API simple y controlada por Flask.

2.12.7. Sistema de almacenamiento de objetos MinIO

MinIO es un sistema de almacenamiento de objetos, de código abierto, nativo de la nube y de alto rendimiento. De acuerdo con Perrin y Pahl (2023), su principal característica es ser totalmente compatible con la API de Amazon S3 (Simple Storage Service), lo que lo ha convertido en un estándar de facto para el almacenamiento de objetos en infraestructuras privadas o híbridas (on-premise).

A diferencia de los sistemas de archivos tradicionales (como NTFS o ext4) o las bases de datos (como MongoDB), MinIO está diseñado para gestionar datos no estructurados a gran escala. Almacena datos como "objetos" (archivos) dentro de "buckets" (contenedores). Esta arquitectura lo hace ideal para almacenar grandes volúmenes de datos, como imágenes, videos, copias de seguridad, archivos de log y, en el contexto de este proyecto, los archivos ráster (GeoTIFFs) o las imágenes procesadas.

MinIO está construido bajo principios de escalabilidad horizontal y resiliencia. Puede ejecutarse como un solo proceso en un solo servidor o en un modo distribuido en múltiples servidores para garantizar una alta disponibilidad y protección contra fallos de disco o nodo mediante técnicas de *erasure coding*. Para el presente proyecto, MinIO actúa como el repositorio central de datos binarios, permitiendo que el *backend* de Python (a través de librerías compatibles con S3) acceda, procese y almacene eficientemente los archivos de imagen de gran tamaño que son el núcleo de la aplicación.

CAPÍTULO 3

3. Estado del arte

El presente capítulo tiene como objetivo analizar y sintetizar las investigaciones y desarrollos tecnológicos existentes en el ámbito de la agricultura de precisión y, en particular, en el uso de imágenes multiespectrales para la gestión y monitoreo agrícola. Se busca identificar las metodologías, herramientas y enfoques actuales empleados en el procesamiento, almacenamiento y visualización de datos, así como las limitaciones y desafíos que persisten en este campo. Este análisis permitirá situar la investigación propuesta dentro del panorama científico y tecnológico contemporáneo, destacando su pertinencia y la manera en que contribuye al fortalecimiento de las soluciones digitales aplicadas al sector agrícola.

3.1. Instituciones de datos geográficos

En México, el principal organismo encargado de proporcionar datos geográficos es el Instituto Nacional de Estadística, Geografía e informática (INEGI), el cual genera, integra y difunde información cartográfica, estadística y geoespacial de gran relevancia para diversos sectores, incluido el agrícola (INEGI, 2025). A través de sus sistemas de información geográfica, censos y mapas temáticos, el INEGI facilita el acceso a datos territoriales que permiten analizar el uso de suelo, la distribución de cultivos y las condiciones ambientales del país. Esta información constituye una base fundamental para proyectos de agricultura de precisión, ya que al integrarse con imágenes multiespectrales y otras fuentes de datos, posibilita un análisis más detallado y eficiente del entorno agrícola, apoyando la toma de decisiones estratégicas en la gestión de recursos y la productividad del campo mexicano (INEGI, 2025).

Sin embargo, el INEGI no cuenta con sistemas con los cuales gestionar propiamente imágenes multiespectrales orientadas al ámbito agrícola, ya que su labor principal está enfocada en la generación de datos estadísticos, censos y cartografía base para diversos sectores. Si bien sus productos geoespaciales y temáticos constituyen un insumo valioso, estos carecen de herramientas interactivas que permitan procesar, analizar y visualizar en tiempo real la información espectral capturada por sensores satelitales, aéreos o terrestres.

Esto limita su utilidad para productores, investigadores y técnicos que requieren indicadores específicos sobre el estado de los cultivos, como índices de vegetación, humedad o detección temprana de plagas y estrés hídrico.

A diferencia de los sistemas tradicionales, esta plataforma incorpora visualización interactiva mediante mapas dinámicos, consultas personalizadas y almacenamiento flexible en bases de datos que facilitan la organización de grandes volúmenes de información. Además, está diseñada para ser accesible y escalable, lo que la convierte en una herramienta práctica para la agricultura de precisión, al ofrecer información procesada y útil que apoye la toma de decisiones estratégicas en la gestión de los cultivos.

3.2. Plataformas de obtención de imágenes multiespectrales

La adquisición de imágenes multiespectrales a partir de diversas fuentes satelitales es un proceso importante para la agricultura de precisión. Por lo tanto, existen diversas plataformas consideradas las más relevantes, y que se consideran como fuente principal para este trabajo.

Una de las funcionalidades centrales de la plataforma propuesta en esta tesis es la adquisición de imágenes multiespectrales procedentes de diversas fuentes, por lo que resulta esencial analizar las alternativas disponibles en el mercado para su obtención.

3.2.1. Copernicus Browser

Copernicus Browser es una plataforma en la nube que facilita el acceso, procesamiento y visualización de datos satelitales, especialmente de los satélites Sentinel del programa Copernicus. Opera mediante interfaces visuales y potentes APIs que permiten la integración de imágenes en aplicaciones SIG o de análisis remoto. Una de sus principales fortalezas es el procesamiento en tiempo real de datos, incluyendo la generación de índices espectrales, mosaicos sin nubes y series temporales de forma automatizada y escalable. Además, ofrece soporte para scripting personalizado, lo que permite crear flujos de trabajo específicos para generar productos derivados como índices de vegetación o mapas temáticos. La plataforma también cuenta con abundante documentación, tutoriales y comunidad activa, lo cual facilita su adopción por parte de desarrolladores, investigadores y empresas agrícolas (CDSE, 2025).

Si bien Copernicus Browser representa una solución para la obtención de imágenes satelitales, su naturaleza generalista implica que no está enfocada exclusivamente en la agricultura de precisión ni en la gestión integral de imágenes multiespectrales a nivel de parcela. Esto genera limitaciones en términos de personalización para usuarios agrícolas que requieren integrar sus propios conjuntos de datos, así como en la facilidad de uso para productores que no cuentan con experiencia técnica en programación o sistemas geoespaciales. En este sentido, la plataforma propuesta busca cubrir dichos vacíos al ofrecer un entorno especializado que centraliza la adquisición, almacenamiento y visualización de imágenes multiespectrales con un enfoque práctico y accesible, orientado a facilitar la toma de decisiones en contextos agrícolas específicos.

3.2.2. Planet Scope

PlanetScope es una constelación satelital operada por Planet Labs que ofrece imágenes de la superficie terrestre con una frecuencia de revisita diaria y una resolución aproximada de 3 a 3.7 metros a través de un sitio web con una interfaz intuitiva. Sus satélites de última generación permiten la captura de hasta 8 bandas espectrales, entre ellas RGB, infrarrojo cercano, red edge y amarillo, lo que amplía las posibilidades de análisis agrícola y ambiental. Los productos generados abarcan desde imágenes básicas hasta ortorrectificadas con corrección radiométrica y geométrica, presentadas en formatos compatibles con sistemas de información geográfica como GeoTIFF. Asimismo, PlanetScope ofrece acceso mediante API, lo que facilita la búsqueda, descarga e integración de imágenes en entornos de procesamiento remoto y en aplicaciones personalizadas para análisis geoespacial. Su frecuencia temporal diaria convierte a esta constelación en una herramienta destacada para el seguimiento de cultivos, la detección de cambios rápidos y la generación de series temporales a escala global. (ESA, 2025)

Si bien PlanetScope representa una de las soluciones comerciales más sólidas para la obtención de imágenes multiespectrales de alta frecuencia, del mismo modo que Copernicus Browser tiene un enfoque generalista lo que limita la personalización para su uso en la agricultura de precisión.

3.3. Plataformas comerciales de agricultura de precisión en México

En México, diversas empresas han desarrollado o implementado plataformas comerciales orientadas a la agricultura de precisión, las cuales buscan optimizar el manejo de los cultivos mediante el uso de tecnologías digitales, sensores remotos e imágenes satelitales. Estas soluciones ofrecen a los productores herramientas para monitorear en tiempo real variables como la humedad del suelo, el vigor de la vegetación o la presencia de plagas, facilitando así la toma de decisiones basadas en datos. Sin embargo, al ser sistemas de carácter comercial, suelen implicar costos elevados de suscripción o licenciamiento, además de limitaciones en la personalización y accesibilidad de los datos.

3.3.1. AGROLIKA

Agrolika es una plataforma avanzada de agricultura de precisión que emplea tecnología satelital, especialmente imágenes térmicas infrarrojas, para monitorear cultivos y optimizar el riego mediante el algoritmo de balance de energía superficial para la tierra SEBAL por sus siglas en inglés, validado en campo durante más de 30 años. Ofrece análisis diarios por parcela, recomendaciones del plan óptimo de riego basadas en evapotranspiración real, precipitaciones y humedad del suelo, así como asesoría automatizada mediante inteligencia artificial. Además, cuenta con su propia constelación de satélites a través de Hydrosat que permite obtener datos térmicos diarios, convirtiéndose en una de las pocas plataformas con esta capacidad. Con acceso a más de 200 parámetros a través de API y con cobertura en más de 35 países, Agrolika procesa grandes volúmenes de datos para ofrecer información accionable en múltiples tipos de cultivo (Agrolika, 2025).

No obstante, pese a su fortaleza en el monitoreo satelital y recomendaciones de riego, Agrolika no integra otras funcionalidades clave como permitir el almacenamiento estructurado de imágenes multiespectrales, la visualización interactiva en mapas personalizados, ni la gestión documental o consulta flexible que se adapte a distintos perfiles de usuario.

3.3.2. NXTAgro

NXTAgro es una solución tecnológica mexicana de agricultura de precisión que integra sensores de bajo consumo energético instalados directamente en el campo, junto con análisis

basado en inteligencia artificial y monitoreo en tiempo real a través de aplicaciones móviles y plataformas web. Esta herramienta proporciona datos críticos sobre variables agronómicas como humedad del suelo, acidez (pH), conductividad eléctrica, presencia de plagas, condiciones climatológicas y frecuencia de riego mediante alertas inmediatas, lo que permite una gestión proactiva de los cultivos. Además, NXTAgro promueve una experiencia accesible para el usuario con capacitación continua, flexibilidad para operarse desde dispositivos móviles y escalabilidad desde pequeñas parcelas hasta extensas superficies de cultivo. (NXTAgro, 2025).

Sin embargo, NXTAgro no integra capacidades de gestión ni visualización avanzada de imágenes multiespectrales, lo que limita su alcance a la recopilación y análisis de datos puntuales obtenidos a partir de sensores instalados en campo. Aunque ofrece información valiosa en tiempo real sobre variables agronómicas, su enfoque está orientado principalmente al monitoreo directo del entorno físico, sin aprovechar el potencial de las imágenes multiespectrales capturadas por VANTs o satélites. Esto significa que no permite generar mapas temáticos de vigor vegetativo, detectar patrones espaciales en grandes superficies ni realizar comparaciones históricas que den seguimiento a la evolución de los cultivos en el tiempo. Asimismo, carece de un sistema robusto de almacenamiento y gestión de datos multiespectrales que facilite la consulta, clasificación y análisis personalizado de acuerdo con diferentes necesidades productivas.

3.4. Plataformas internacionales de agricultura de precisión

A nivel internacional, la agricultura de precisión ha impulsado aún más el desarrollo de diversas plataformas digitales que integran tecnologías como sensores multiespectrales, imágenes satelitales, inteligencia artificial y sistemas de información geográfica.

3.4.1. PIX4Dfields

Pix4Dfields es una solución software híbrida diseñada para la agricultura de precisión, que permite procesar imágenes capturadas por drones o satélite y transformarlas en mapas de salud de cultivos en tiempo real, incluso sin conexión a internet. Funciona con cámaras RGB y multiespectrales, generando productos valiosos como orto mosaicos, modelos digitales de superficie, mapas de índices vegetativos, por ejemplo, NDVI, zonificaciones precisas y

mapas de prescripción para maquinaria agrícola. Destaca por su motor de procesamiento instantáneo que permite obtener resultados rápidamente, ideal para su uso en campo o en oficina con soporte para aceleración con GPU. También incluye herramientas avanzadas como Magic Tool, que utiliza inteligencia artificial para identificar zonas específicas, por ejemplo, maleza o áreas dañadas y generar mapas de aplicación diferenciada, optimizando el uso de insumos en tratamientos dirigidos. Además, ofrece opciones de exportación flexibles, generación de informes en PDF personalizados y compatibilidad con plataformas como PIX4Dcloud para compartir resultados. (PIX4D, 2025)

Sin embargo, su software requiere una instalación local, lo que limita su uso a equipos con capacidades de hardware específicas, como procesadores potentes, memoria amplia y, en algunos casos, tarjetas gráficas dedicadas para acelerar el procesamiento. Esta dependencia tecnológica restringe su disponibilidad para usuarios que no cuentan con dichos recursos, especialmente pequeños y medianos productores que suelen carecer de infraestructura informática avanzada. Además, al no ser completamente una solución en la nube, su accesibilidad se ve reducida, ya que no permite un uso inmediato desde cualquier dispositivo o ubicación, dificultando la colaboración remota y la consulta en tiempo real de los resultados. Estas limitaciones representan un área de oportunidad que puede ser atendida mediante plataformas web más ligeras y escalables, que prescinden de instalaciones complejas y permiten gestionar imágenes multiespectrales directamente desde un navegador con conexión a internet.

3.4.2. Agremo

Agremo es una plataforma digital basada en la nube que se especializa en el análisis de imágenes aéreas capturadas principalmente por drones, con el objetivo de brindar información precisa y procesable para la agricultura de precisión. Su funcionamiento se apoya en algoritmos de inteligencia artificial, visión por computadora y aprendizaje automático entrenados con el conocimiento de expertos agrónomos, lo que le permite transformar fotografías aéreas en mapas de alta resolución y reportes interpretativos útiles para el manejo de cultivos. Dentro de sus productos más representativos se encuentran Crop Monitoring, orientado al seguimiento de los cultivos durante toda la temporada, y Field Trials, diseñado para evaluar ensayos agrícolas y medir la efectividad de diferentes

tratamientos. Entre las funcionalidades que ofrece destacan el conteo automático de plantas, la detección de zonas con estrés o daños, la generación de mapas de biomasa, la zonificación de parcelas, el cálculo de índices de vegetación como el NDVI, así como la comparación temporal entre diferentes vuelos para observar la evolución del cultivo. (Agremo, 2025)

Además, Agremo se integra con ecosistemas agrícolas más amplios, como plataformas de maquinaria como John Deere Operations Center y servicios de gestión de vuelos de drones como DroneDeploy, lo que permite una transición más fluida entre la adquisición de datos, el análisis y la ejecución de acciones en campo. Sus resultados pueden exportarse en diversos formatos compatibles con sistemas de información geográfica (SIG), incluyendo shapefiles, GeoTIFF, PDF y CSV, lo que facilita la interoperabilidad con otras herramientas de análisis y la creación de reportes personalizados. El flujo de trabajo de la plataforma es sencillo: el usuario sube las imágenes aéreas previamente procesadas, solicita uno o varios análisis y, tras el procesamiento en la nube, recibe mapas y reportes listos para su interpretación. De esta manera, Agremo se posiciona como una solución flexible tanto para productores como para investigadores, al brindar información detallada para mejorar la productividad, reducir costos y tomar decisiones más informadas en la gestión agrícola.

Si bien Agremo ofrece potentes herramientas de análisis de imágenes aéreas mediante drones, su enfoque está centrado en generar reportes y mapas específicos más que en la gestión integral de imágenes multiespectrales. La plataforma no contempla un sistema de almacenamiento estructurado ni la visualización dinámica de series históricas en entornos web interactivos.

3.5. Área de Oportunidad

En primer lugar, se confirma una sólida validación científica de las metodologías orientadas a la detección del estrés hídrico y al monitoreo de la salud vegetal mediante el uso de imágenes satelitales Sentinel-2 y algoritmos de aprendizaje automático, particularmente modelos como Random Forest. Diversas investigaciones respaldan la precisión y confiabilidad de estas técnicas, demostrando su capacidad para clasificar zonas con distintos niveles de estrés hídrico a partir de índices espectrales y datos multitemporales. En consecuencia, desde una perspectiva metodológica, el sustento técnico y científico para implementar este tipo de soluciones es consistente y robusto.

En segundo término, el análisis comparativo de las plataformas tecnológicas disponibles evidencia una brecha significativa entre el potencial científico y su implementación práctica accesible al usuario final. Las soluciones actuales pueden agruparse en distintas categorías con limitaciones claras:

(a) proveedores de datos satelitales que ofrecen información en estado bruto y requieren conocimientos técnicos avanzados para su procesamiento (por ejemplo, Copernicus o Planet);

(b) sistemas basados exclusivamente en sensores instalados en campo que prescinden de la teledetección satelital (como NXTAgro);

(c) herramientas de escritorio que demandan infraestructura computacional especializada y costos elevados de hardware (como PIX4Dfields); y

(d) plataformas en la nube centradas en la generación de reportes predeterminados, con escasa flexibilidad para que el usuario administre y procese sus propios conjuntos de datos (como Agrolika o Agremo).

Esta fragmentación del ecosistema tecnológico pone de manifiesto una desconexión entre la disponibilidad de datos, las capacidades analíticas y la experiencia de usuario. Por tanto, se identifica una oportunidad clara para el desarrollo de una plataforma web integradora que combine accesibilidad, escalabilidad y autonomía operativa. Tal sistema debería permitir a los usuarios no solo visualizar resultados, sino también adquirir, almacenar, procesar y analizar de manera interactiva sus propias imágenes multiespectrales, cerrando así la brecha entre la validación científica y la adopción tecnológica en contextos productivos reales.

CAPÍTULO 4

4. Desarrollo del proyecto

Actualmente, existe una amplia variedad de marcos de trabajo y ciclos de vida para la gestión de proyectos de software; sin embargo, para el presente proyecto se ha definido un plan de trabajo que comprende desde la especificación de requisitos y el diseño arquitectónico hasta la modelación de la base de datos. Por lo tanto, este capítulo presenta, de forma detallada el proceso completo seguido para el diseño, desarrollo e implementación de la plataforma web para la gestión y análisis de imágenes multiespectrales. Se documentan los diseños

arquitectónicos, las fases de la metodología aplicada, los retos técnicos encontrados y las soluciones propuestas para cumplir con los objetivos planteados.

4.1. Contexto del desarrollo de la plataforma

El proyecto se centra en el estado de Sinaloa, región donde la agricultura desempeña un papel crucial en la economía nacional (Bojórquez, 2023). En este ámbito de alta producción, el monitoreo oportuno y preciso de los cultivos es fundamental para optimizar los rendimientos y la sostenibilidad. Sin embargo, se ha encontrado poca documentación sobre el uso de técnicas de agricultura de precisión en la zona. Esto es coherente con la brecha, establecida anteriormente, entre la alta disponibilidad de datos satelitales y la escasez de herramientas accesibles que permitan a productores e investigadores procesarlos y extraer valor de ellos.

La plataforma tiene como propósito principal automatizar el análisis de imágenes de cultivos para calcular índices de vegetación como NDVI, visualizar estos resultados en mapas geoespaciales interactivos y detectar anomalías. El sistema busca facilitar la toma de decisiones agronómicas basadas en evidencia, permitiendo a los usuarios identificar zonas con estrés hídrico, deficiencias nutricionales o posibles afectaciones.

4.2. Metodología de desarrollo

Para la correcta ejecución del proyecto y la transformación de los requisitos funcionales en una solución de software tangible, es indispensable adoptar un marco de trabajo que estructure el ciclo de vida del desarrollo. La elección de una metodología adecuada no solo asegura la gestión ordenada de las tareas y la calidad del producto final, sino que también facilita la adaptación a los retos técnicos que surgen durante la implementación. Para el desarrollo de esta plataforma, se seleccionó el marco de trabajo ágil Scrum propuesto por (Schwaber et al. 2020), debido a su flexibilidad y su enfoque en la entrega iterativa e incremental de valor, el cual se detalla a continuación.

El marco de trabajo Scrum facilita la gestión de la complejidad y la incertidumbre al descomponer el proyecto en ciclos de trabajo cortos y definidos, denominados Sprints. Según Salazar et al. (2020), al final de cada uno de estos ciclos se entrega un incremento de software funcional. En la Figura 6 se muestra el flujo de trabajo completo que sigue esta metodología.

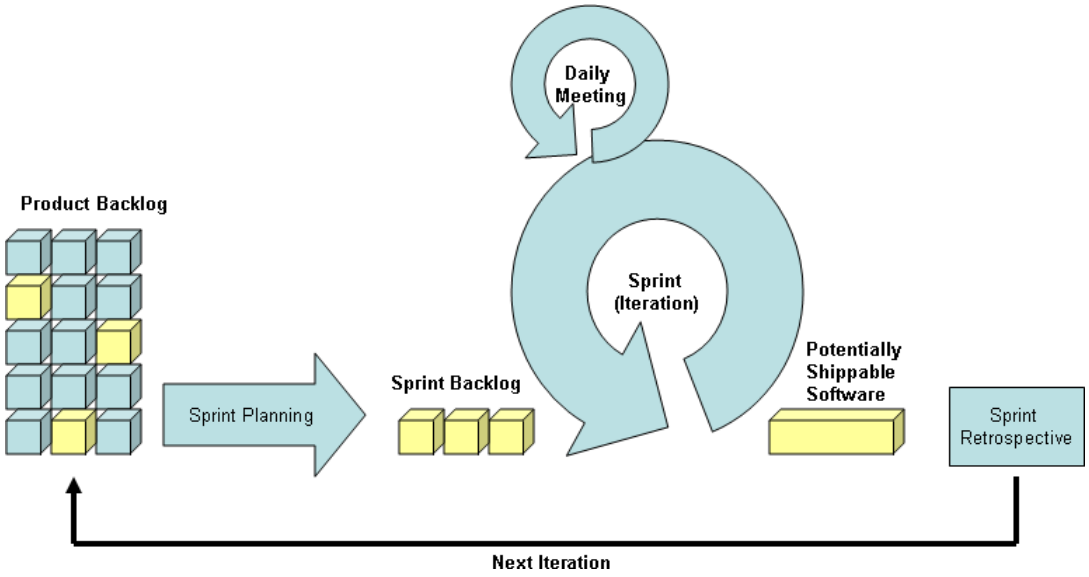


FIGURA 6: Proceso de la metodología Scrum
Fuente: Schwaber 2020: La guía Scrum

4.2.1. Adaptación de los roles de Scrum

Hema et al, 2020 menciona que Scrum define tres roles claros Scrum Master el que se encarga de que se siga la metodología de manera correcta, Product Owner que es el cliente o interesado y el Scrum Team, en el contexto de este proyecto de tesis, estos se adaptaron de la siguiente manera:

- **Product Owner:** Este rol es desempeñado principalmente por el asesor de tesis. El asesor valida los incrementos del producto al final de cada *Sprint Review* y proporciona retroalimentación clave que influye en la priorización del *Product Backlog*.
- **Scrum Master:** Rol asumido por el alumno. Su responsabilidad fue asegurar que la metodología se siguiera correctamente, eliminar impedimentos y facilitar los eventos de Scrum para mantener el proyecto enfocado.
- **Scrum Team:** Compuesto por el alumno, quien se encargará del análisis, diseño, codificación, pruebas e implementación de la plataforma.

4.2.2. Artefactos de Scrum

Según Schwaber et al. 2020, en su guía de Scrum define los siguientes artefactos necesarios para poder implementar la metodología de scrum:

- **El Product Backlog:** Se define como una lista emergente, ordenada y priorizada de todo lo que se conoce que es necesario para el producto. Es la única fuente de trabajo que el Equipo de Desarrollo debe realizar. El Product Owner es el responsable de su contenido, disponibilidad y ordenamiento. Para este proyecto de tesis, el *Product Backlog* se construyó inicialmente a partir de los objetivos específicos planteados, los cuales se descompusieron en funcionalidades tangibles.

- **El Sprint Backlog:** Es el conjunto de elementos del *Product Backlog* que han sido seleccionados por el Equipo de Desarrollo para el Sprint actual. Además, incluye un plan de acción detallado sobre cómo se entregará el *Incremento* y se alcanzará el Objetivo del Sprint. Es un plan hecho por y para los Desarrolladores y se actualiza a lo largo del Sprint conforme se va descubriendo más información.

- **El Increment:** Es la suma de todos los elementos del *Product Backlog* que se han completado durante un Sprint y el valor de todos los Sprints anteriores. Al final de cada Sprint, el nuevo *Incremento* debe estar en una condición "Hecho", lo que significa que es utilizable y cumple con la Definición de Hecho del equipo. Cada *Incremento* es aditivo a los anteriores y debe ser verificado para asegurar que todos funcionen en conjunto.

Una vez definidos los componentes de la metodología de desarrollo, se definirán los pasos que se van a desarrollar especificando que actividades se realizaran en cada una de las fases que define el marco de desarrollo.

4.2.3. Especificación de requisitos

La construcción del Product Backlog inicial, se fundamentó en un proceso formal de elicitación de requisitos. Dada la naturaleza técnica y de dominio específico del proyecto (agricultura de precisión), se priorizaron técnicas de recolección directas. Siguiendo las recomendaciones de Hinojosa et al. (2015) para la captura de necesidades en contextos de investigación y desarrollo, se optó por emplear entrevistas semiestructuradas.

En este caso concreto, se mantuvieron sesiones de trabajo con investigadores y expertos en imágenes multiespectrales y teledetección, quienes representan el perfil de usuario final clave para la plataforma. Estas entrevistas, con una duración aproximada de una hora por sesión, se diseñaron para explorar en profundidad los flujos de trabajo actuales, los desafíos en el procesamiento de imágenes multiespectrales y las funcionalidades deseadas para la toma de decisiones agronómicas.

A partir de este diálogo, se identificaron, documentaron y priorizaron los siguientes requisitos funcionales y no funcionales que conforman la base del Product Backlog del proyecto en la forma de historias de usuario como recomienda Lucassen et al. (2016):

Epic 1: Módulo de Gestión de Usuarios y Control de Acceso

Este *Epic* agrupa todas las funcionalidades necesarias para la seguridad, personalización y gestión de cuentas dentro de la plataforma.

- **HU-1:** *Como* un nuevo usuario (productor o investigador), *quiero* poder registrar una cuenta en la plataforma usando mi correo electrónico y una contraseña *para* poder acceder a los servicios de análisis.
- **HU-2:** *Como* un usuario registrado, *quiero* poder iniciar y cerrar sesión de forma segura *para* proteger el acceso a mis proyectos e imágenes.
- **HU-3:** *Como* usuario, *quiero* tener un perfil donde pueda gestionar mi información personal y mis proyectos.
- **HU-4:** *Como* administrador del sistema, *quiero* poder gestionar las cuentas de usuario *para* mantener la integridad de la plataforma.

Epic 2: Módulo de Gestión de Imágenes Multiespectrales

Este *Epic* se centra en la ingesta, almacenamiento y organización de los datos geoespaciales que son la materia prima del sistema.

- **HU-5:** *Como* usuario, *quiero* poder crear "Proyectos" o "Parcelas" que me permitan agrupar mis análisis por ubicación geográfica o fecha.

- **HU-6:** *Como* usuario, *quiero* poder subir mis propias imágenes multiespectrales (en formatos como GeoTIFF) a un proyecto específico *para* poder analizarlas.
- **HU-7:** *Como* usuario, *quiero* poder seleccionar un área de interés en un mapa interactivo y una fecha *para* solicitar y descargar imágenes satelitales de esa zona.
- **HU-8:** *Como* sistema, *debo* almacenar de forma estructurada los metadatos de cada imagen (fecha, bandas, resolución, fuente) y asociarlos al proyecto y usuario correspondientes.

Epic 3: Módulo de Procesamiento y Análisis de Imágenes

Este *Epic* contiene el núcleo funcional de la plataforma: la transformación de datos crudos en información agronómica visual.

- **HU-9:** *Como* usuario, *quiero* seleccionar una imagen almacenada en mi proyecto *para* solicitar el cálculo del índice de vegetación **NDVI**.
- **HU-10:** *Como* usuario, *quiero* tener la opción de calcular otros índices clave como **EVI** y **SAVI** *para* obtener diferentes perspectivas sobre la salud del cultivo.
- **HU-11:** *Como* usuario, *quiero* visualizar el resultado del índice calculado como una capa de color sobre un mapa base interactivo *para* identificar visualmente la variabilidad en mi parcela.
- **HU-12:** *Como* usuario, *quiero* ver una leyenda clara que explique el significado de la escala de colores (ej. -1 = Agua, 0.8 = Vegetación muy saludable) *para* poder interpretar correctamente el mapa.

Epic 4: Módulo de Inteligencia Artificial y Detección de Anomalías

Este *Epic* representa la funcionalidad avanzada del sistema, utilizando *deep learning* para ofrecer diagnósticos proactivos.

- **HU-13:** *Como* sistema, *debo* tener una API para conectarme a un modelo de *deep learning para* enviarle imágenes a procesar.

- **HU-14:** *Como* usuario, *quiero* poder seleccionar una imagen reciente y solicitar un "Análisis de Anomalías" *para* detectar patrones atípicos que no son visibles en un simple índice NDVI.
- **HU-15:** *Como* usuario, *quiero* que la plataforma resalte visualmente sobre el mapa las zonas específicas donde el modelo detectó anomalías (posible estrés hídrico, plaga o deficiencia) *para* poder enfocar mis inspecciones en campo.

Una vez establecidos los requerimientos iniciales del proyecto es necesario pasar a la planificación de los Sprint para poder solucionarlos.

4.2.4. Planificación general de los Sprints

Para abordar de manera incremental los requisitos identificados en el Product Backlog, el desarrollo total del proyecto se ha estructurado en un plan general de cuatro Sprints. Cada Sprint se define como un ciclo de trabajo con una duración fija, diseñado para entregar un Incremento de software funcional y validado por el Product Owner como se mencionó previamente con base en la recomendación de (Schwaber et al. 2020).

La agrupación de las Historias de Usuario (HU) en cada ciclo sigue una planificación estratégica que busca construir la plataforma de manera lógica, mitigando los riesgos técnicos de forma manera temprana, abordando el procesamiento de imágenes y la visualización geoespacial en Sprints intermedios.

A continuación, se presenta la distribución de las Historias de Usuario en los Sprints planificados:

Sprint 1: Fundamentos del Sistema y Gestión de Usuarios

- **Objetivo**: Establecer la arquitectura base de la aplicación (Frontend y Backend) y entregar un módulo de autenticación funcional.
- **Historias de Usuario:**
    - HU-1: Registro de nuevos usuarios.
    - HU-2: Inicio y cierre de sesión seguro.

- HU-3: Perfil de usuario.
- HU-4: Gestión de cuentas por administrador.

Sprint 2: Núcleo Geoespacial y Gestión de Datos

- **Objetivo**: Permitir al usuario crear proyectos, subir sus propias imágenes multiespectrales y visualizarlas sobre un mapa base.
- **Historias de Usuario:**
  - HU-5: Creación de "Espacios de trabajo".
  - HU-6: Subida de imágenes multiespectrales (GeoTIFF).
  - HU-8: Almacenamiento de metadatos de imágenes en la base de datos.
  - (Parcial) HU-11: Visualización de la imagen original (sin análisis) como una capa sobre el mapa interactivo.

Sprint 3: Módulo de Análisis Espectral y Visualización

- **Objetivo:** Implementar los algoritmos de cálculo de índices de vegetación y mostrar los resultados mediante una codificación cromática en el visor.
- **Historias de Usuario:**
  - HU-9: Cálculo del índice NDVI.
  - HU-10: Cálculo de los índices EVI y SAVI.
  - (Completo) HU-11: Visualización del resultado del índice con codificación cromática.
  - HU-12: Despliegue de leyenda interactiva para el mapa.

Sprint 4: Integración de Fuentes Externas y Análisis Avanzado

- **Objetivo**: Integrar la plataforma con fuentes de datos satelitales externas (Sentinel) y habilitar el módulo de detección de anomalías con *Deep Learning*.
- **Historias de Usuario:**
  - HU-7: Selección de área en mapa para obtener imágenes Sentinel-2.

- HU-13: Conexión de API con el modelo de *Deep Learning*.
- HU-14: Solicitud de "Análisis de Anomalías" sobre una imagen.
- HU-15: Visualización de polígonos de anomalías sobre el mapa.

Esta planificación de cuatro Sprints establece la hoja de ruta incremental para el desarrollo del proyecto. Con este plan de ejecución definido, el siguiente paso es diseñar la arquitectura, las interfaces y el modelo de datos.

4.2.5. Diseño de la arquitectura

Para dar soporte a los requisitos funcionales definidos en el Product Backlog y facilitar la implementación de los Sprints planificados, es esencial definir una arquitectura de sistema robusta y escalable. Esta arquitectura no solo debe integrar eficientemente las tecnologías seleccionadas, sino también manejar los procesos de cómputo intensivo, como el análisis de imágenes y la ejecución de modelos de aprendizaje profundo (*deep learning*) sin comprometer la experiencia del usuario.

El diseño de la plataforma se fundamenta teóricamente en el patrón de arquitectura Modelo-Vista-Controlador (MVC). Como señalan Adam y Andolo (2019), el propósito esencial del patrón MVC es "separar la presentación de la lógica y el almacenamiento de datos". Esta separación es un pilar fundamental en el desarrollo web moderno, ya que mitiga el riesgo de generar "código altamente enredado e inmantenible", un problema común cuando las tecnologías del lado del cliente y del servidor se combinan indiscriminadamente.Andolo (2019)

Para este proyecto, se adopta un modelo MVC distribuido, como se muestra en la figura 7, donde cada capa tiene una delimitación tecnológica clara, con una adaptación clave para manejar el procesamiento asíncrono de datos geoespaciales.

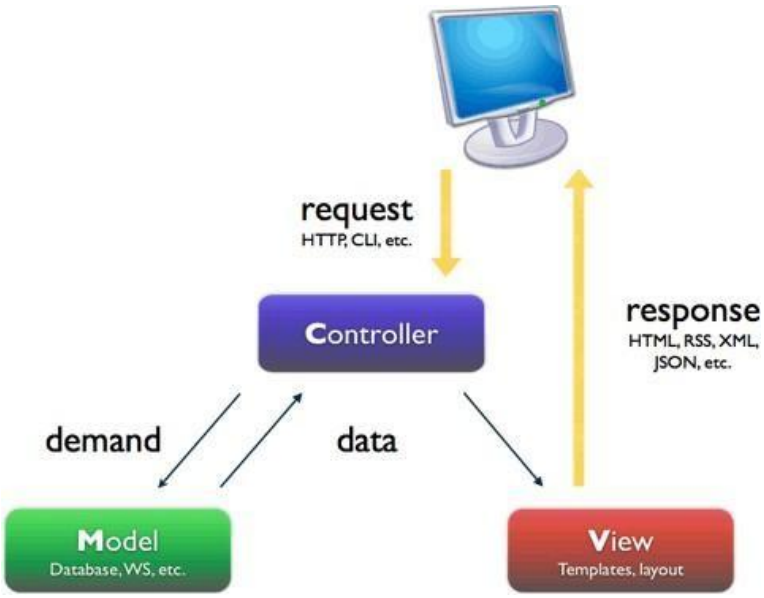


FIGURA 7: Patrón arquitectónico MVC

Fuente http://stackoverflow.com/questions/5966905/which-mvc-diagram-is-correct-web-app

A continuación, se detalla el diseño y las responsabilidades de cada componente de la arquitectura, en alineación con las Historias de Usuario (HU) definidas para los Sprints.

La Capa de Vista

Como mencionan Selfa et al. (2006), la capa de Vista es la responsable de la gestión de la interfaz gráfica de usuario. En esta arquitectura, la Vista es implementada en su totalidad por la aplicación de página única (SPA) a ser desarrollada en React.

Siguiendo el principio fundamental de MVC de que "una vista nunca debe contener elementos que pertenezcan a la lógica de la aplicación", la aplicación React se encarga exclusivamente de la presentación y la interacción con el usuario. Se comunicará con la capa de Controlador a través de una API RESTful para solicitar datos y enviar comandos.

Responsabilidades en los Sprints:

- **Sprint 1:** Renderizar los formularios de autenticación y la interfaz de perfil de usuario.
- **Sprint 2:** Implementar el visor de mapas interactivo, los formularios para la creación de proyectos y la interfaz de carga de imágenes GeoTIFF.

- **Sprint 3 y 4:** Mostrar las opciones de análisis, visualizar los resultados de los índices mediante codificación cromática y superponer los polígonos de anomalías sobre el mapa.

La Capa de Controlador

La capa de Controlador, que actúa como el "cerebro" de la aplicación, es la responsable de gestionar los eventos y la lógica de negocio. Esta capa se implementará en el backend utilizando el framework PHP/Laravel. Esta decisión se fundamenta en la recomendación de Adam & Andolo (2019), quienes en su artículo sobre aplicaciones web con el patrón MVC, señalan a PHP como una herramienta excelente para este tipo de desarrollos.

El Controlador actúa como el intermediario principal: "acepta solicitudes y prepara los datos para una respuesta". "Gestiona la relación entre la Vista y el Modelo", recibiendo peticiones HTTP desde React, aplicando la lógica de enrutamiento, validando la entrada del usuario e interactuando con la capa del modelo para recuperar o almacenar datos.

Responsabilidades en los Sprints:

- **Sprint 1:** Gestionar las rutas y la lógica de autenticación y autorización aprovechando los componentes de seguridad.
- **Sprint 2:** Proveer los *endpoints* de la API para crear, leer y actualizar proyectos y gestionar la recepción de los archivos de imágenes.
- **Sprint 3 y 4:** Orquestar el flujo de análisis. Recibirá las solicitudes de análisis y, en lugar de procesarlas directamente, delegará la tarea a la capa del Modelo, devolviendo una respuesta inmediata a la Vista.

La Capa de Modelo y Lógica de Negocio

El Modelo es la capa del sistema que "gestiona todas las tareas relacionadas con los datos" y encapsula la "lógica de negocio de una aplicación". En esta arquitectura, la capa de Modelo se divide en dos componentes especializados para manejar la naturaleza dual de los datos:

1. Abstracción de Datos (ODM/ORM): Para la gestión de la información de usuarios, proyectos y metadatos, se utilizará el Object-Relational Mapping (ORM) Eloquent de

Laravel, configurado para operar sobre MongoDB. Este diseño se alinea con la arquitectura propuesta por Adam y Andolo (2019), que prevé el uso de sistemas ORM para liberar al desarrollador de la preocupación de conocer la estructura o el esquema de la base de datos.

, indicando que el sistema debe proveer una interfaz para acceder a una serie de dichos sistemas.Andolo (2019)

- **Responsabilidad:** Definir los modelos de Usuario, Proyecto, ImagenFuente y AnalisisResultado, gestionando las relaciones entre ellos y su persistencia en MongoDB.

2. Microservicio de Procesamiento Asíncrono:

Las tareas definidas para los Sprints 3 y 4 (cálculo de NDVI, EVI, SAVI y ejecución de modelos de *Deep Learning*) son operaciones de cómputo intensivo. Ejecutar estas tareas directamente dentro del ciclo de solicitud-respuesta HTTP del Controlador (Laravel) llevaría a tiempos de espera inaceptables para el usuario, creando un cuello de botella significativo.

Esta problemática es un síntoma clásico de las arquitecturas monolíticas, las cuales, como señalan Brekalo et al. (2024), "a menudo luchan con la escalabilidad, la flexibilidad y la mantenibilidad". Si bien el patrón MVC organiza la lógica, no resuelve inherentemente el problema de la escalabilidad del cómputo intensivo dentro de un único despliegue monolítico.

Para resolver esto, en lugar de sobrecargar el Controlador o el Modelo principal, esta arquitectura adopta un enfoque híbrido, alineado con las tendencias de modernización de software. Se propone la descomposición de esta funcionalidad intensiva en un Microservicio de Procesamiento Asíncrono.

Este enfoque aborda directamente el "vacío de investigación significativo" identificado por Kristiyanto et al. (2024), quienes observan que pocos estudios se centran en la migración de arquitecturas monolíticas MVC hacia microservicios.

- **Responsabilidad**: Este microservicio, desarrollado en Python, expondrá una API interna o monitoreará una cola de trabajo. Cuando el Controlador reciba una solicitud de análisis, no ejecutará el cálculo, sino que publicará un mensaje en la cola de trabajos. El microservicio de Python tomará este trabajo, ejecutará el procesamiento

de la imagen utilizando las bibliotecas adecuadas y, al finalizar, actualizará el registro correspondiente en el Modelo con el estado "Completado" y los artefactos resultantes.

Este diseño arquitectónico basado en MVC garantiza la modularidad y mantenibilidad del sistema, permitiendo que la Vista (React) y el Controlador (Laravel) permanezcan ágiles y responsivos, mientras que la lógica de negocio compleja y el procesamiento de datos pesados (Python) se manejan de manera eficiente y asíncrona en la capa del Modelo.

4.2.6. Diseño del modelo de datos

El diseño del modelo de datos es un artefacto fundamental que define la estructura, organización y relación de la información que la plataforma gestionará. Dada la arquitectura de servicios desacoplada y la naturaleza de los datos a manejar, se ha seleccionado MongoDB como sistema gestor de base de datos por recomendación de Rimal (2019). La elección de una base de datos NoSQL orientada a documentos se justifica por su alta flexibilidad y escalabilidad horizontal. Como se discute en el contexto de la abstracción de datos, los modelos relacionales tradicionales a menudo presentan el desafío de la discordancia de impedancia objeto-relacional (Adam y Andolo, 2019). Un modelo de documentos, que utiliza un formato como BSON (Binary JSON), permite un mapeo más directo y natural con las estructuras de objetos utilizadas en las capas de la aplicación (React, Laravel y Python), simplificando el desarrollo y la persistencia de datos complejos.

El diseño se basa en un conjunto de colecciones principales, donde cada colección agrupa documentos con un propósito específico, alineados con las Historias de Usuario (HU) definidas en el Product Backlog.

Colección: users

Esta colección almacena la información de autenticación y perfil de todos los usuarios registrados. Es la base del módulo de gestión de usuarios y control de accesos. Cada documento representa a un único usuario en el sistema, en formato JSON:

```
{
  "_id": "60c72b93f0d1c25b30a9b8f2",
  "name": "Nombre del Usuario",
  "email": "usuario@ejemplo.com",
```

```
  "password": "...",
  "email_verified_at": "2025-11-03T18:00:00.000Z",
  "remember_token": "...",
  "created_at": "2025-11-03T17:55:00.000Z",
  "updated_at": "2025-11-03T17:55:00.000Z"
}
```


Colección: Workspaces

El workspace (espacio de trabajo) es el contenedor principal de la aplicación, equivalente a un "Proyecto" o "Parcela". Agrupa a los usuarios, los archivos y las imágenes asociadas a un área de interés o experimento específico.


```
{
  "_id": "60c72ba8f0d1c25b30a9b8f3",
  "name": "Parcela de Maíz - Los Mochis",
  "description": "Monitoreo de estrés hídrico y NDVI ciclo 2025.",
  "owner_id": "60c72b93f0d1c25b30a9b8f2",
  "type": "personal",
  "is_active": true,
  "created_at": "2025-11-03T17:56:00.000Z",
  "updated_at": "2025-11-03T17:56:00.000Z"
}
```


Colección: workspace_users

Esta colección implementa el Control de Acceso Basado en Roles (RBAC) para la plataforma. Actúa como una "tabla pivot" que asocia los documentos de la colección users con los documentos de la colección workspaces, asignando un rol específico (owner, editor, viewer) que define los permisos del usuario dentro de ese proyecto.


```
{
  "_id": "60c72beff0d1c25b30a9b8f4",
  "workspace_id": "60c72ba8f0d1c25b30a9b8f3",
  "user_id": "60c72b93f0d1c25b30a9b8f2",
  "role": "owner",
  "joined_at": "2025-11-03T17:56:00.000Z",
```

```
  "created_at": "2025-11-03T17:56:00.000Z",
  "updated_at": "2025-11-03T17:56:00.000Z"
}
```


Colección: workspace_image

Esta es la colección principal para la gestión de datos geoespaciales. Almacena los metadatos de las imágenes raster, como las imágenes satelitales (GeoTIFFs) subidas por el usuarioo adquiridas de Sentinel. Los archivos físicos binarios se almacenan en un servicio de almacenamiento de objetos (S3/MinIO), y esta colección guarda la ruta (file_path) hacia ellos.


```
{
  "_id": "60c72c18f0d1c25b30a9b8f5",
  "workspace_id": "60c72ba8f0d1c25b30a9b8f3",
  "uploaded_by": "60c72b93f0d1c25b30a9b8f2",
  "name": "Imagen Drone 20-Oct-2025",
  "original_name": "DJI_0084.TIF",
  "file_path": "workspaces/60c72ba8f0d1c25b30a9b8f3/images/original_abc123.tif",
  "thumbnail_path":
"workspaces/60c72ba8f0d1c25b30a9b8f3/thumbnails/thumb_abc123.jpg",
  "mime_type": "image/tiff",
  "file_size": 125829120,
  "metadata": {
    "bandas": 5,
    "resolucion": "10m",
    "sensor": "MicaSense RedEdge"
  },
  "geospatial_bounds": [ [-109.001, 25.800], [-109.000, 25.801] ],
  "center_lat": 25.8005,
  "center_lng": -109.0005,
  "is_processed": false,
  "processing_notes": null,
  "tags": ["Fuente", "Drone", "Maíz"],
  "created_at": "2025-11-03T18:00:00.000Z",
```

```
  "updated_at": "2025-11-03T18:00:00.000Z"
}
```


Colección workspace_file

Esta colección sirve como un repositorio de metadatos para archivos *no-raster* asociados al proyecto, como pueden ser reportes en PDF, archivos vectoriales (Shapefiles) o datos CSV.


```
{
  "_id": "60c72e04f0d1c25b30a9b8f7",
  "workspace_id": "60c72ba8f0d1c25b30a9b8f3",
  "uploaded_by": "60c72b93f0d1c25b30a9b8f2",
  "name": "Reporte de Cosecha 2025",
  "original_name": "Reporte_final.pdf",
  "file_path": "workspaces/60c72ba8f0d1c25b30a9b8f3/files/reporte_qwe456.pdf",
  "mime_type": "application/pdf",
  "file_size": 1204321,
  "metadata": {
    "autor": "Ing. Agrónomo"
  },
  "geospatial_bounds": null,
  "center_lat": null,
  "center_lng": null,
  "is_processed": false,
  "processing_notes": null,
  "created_at": "2025-11-03T18:10:00.000Z",
  "updated_at": "2025-11-03T18:10:00.000Z"
}
```


Este diseño de colecciones proporciona un modelo de datos robusto y flexible, capaz de evolucionar sin migraciones de esquema complejas, al tiempo que mantiene las referencias lógicas necesarias entre las entidades clave de la plataforma.

4.2.7. Diseño de las interfaces

El diseño de la Interfaz Gráfica de Usuario (GUI) es un componente crítico, ya que es el principal punto de interacción entre el usuario y las capacidades de procesamiento de la plataforma. Un diseño de UI/UX intuitivo es fundamental para reducir la carga cognitiva y promover la adopción de la herramienta.

Para esta etapa, se adoptaron los principios del marco Figma-Enhanced App Design (FEAD), que integra herramientas de diseño profesional como Figma. El uso de Figma en esta etapa, como señala Huang (2024), es fundamental para la creación de wireframes de baja fidelidad.Huang (2024)

Correspondiendo al Sprint 1, se diseñó un flujo de autenticación claro y minimalista. La Figura 8 muestra la pantalla de inicio de sesión, que proporciona un acceso seguro a la plataforma y enlaces al formulario de registro para nuevos usuarios.



FIGURA 8: Inicio de sesión.

Para las interfaces del segundo Sprint correspondiente a el panel de control principal del usuario. La Figura 9 muestra el dashboard principal, donde el usuario puede ver y gestionar sus workspaces (Proyectos) existentes. Desde aquí, puede iniciar la búsqueda de nuevas imágenes satelitales o gestionar las imágenes existentes.



FIGURA 9: Dashboard principal

La Figura 10 detalla la interfaz de resultados de búsqueda. Cuando un usuario consulta una fuente de datos externa, los resultados se despliegan en esta vista, permitiéndole filtrar y seleccionar las imágenes que desea importar a su workspace o descargar para su posterior análisis.



FIGURA 10: Resultados de la búsqueda de imágenes.

Esta es la interfaz central de la plataforma y el objetivo principal del módulo de procesamiento de imágenes. La Figura 11 muestra el dashboard de procesamiento de imágenes satelitales para calcular índices de vegetación.

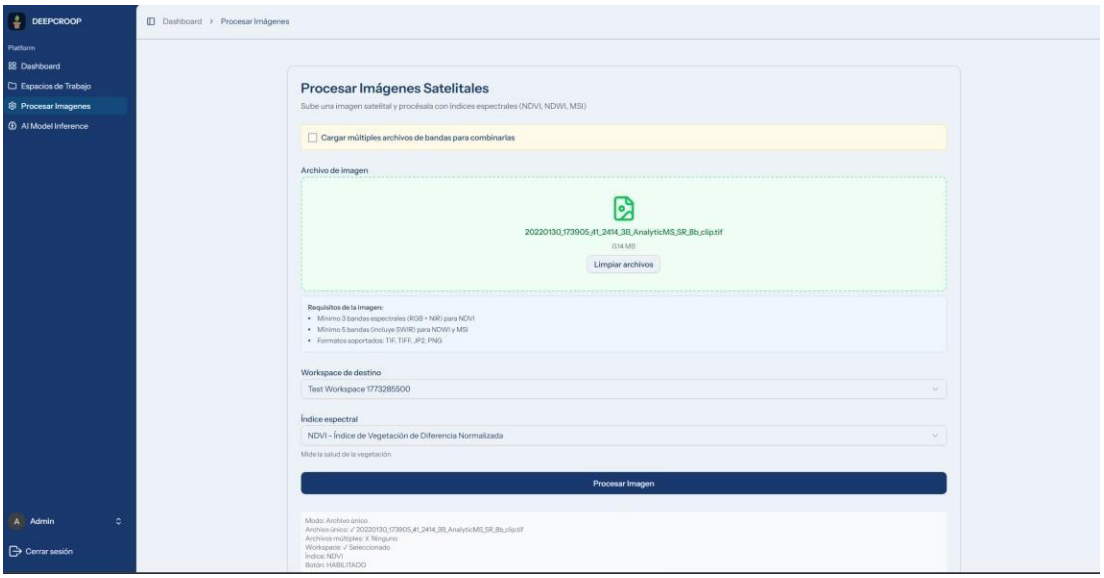


FIGURA 12: Dashboard de procesamiento de imágenes (Calculos de IV).

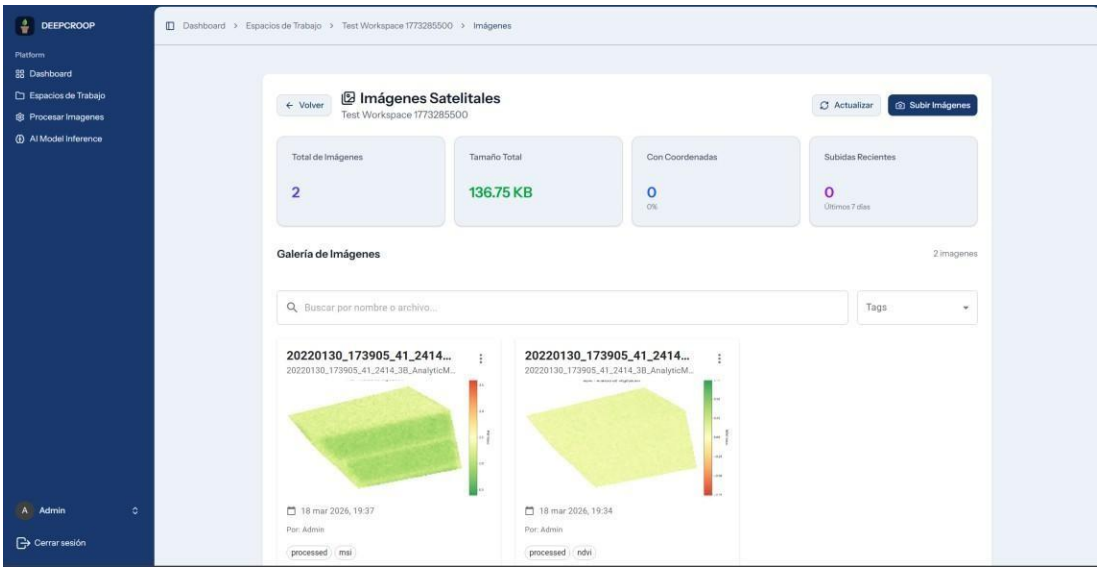


FIGURA 11: Workspace con resultados de imágenes procesadas.

La figura 12, muestra el workspace donde se almacenaron las imágenes procesadas con el cálculo de índices de vegetación (NDVI, MSI EVI). La interfaz está diseñada para mostrar el resultado (la imagen procesada) en un visor de mapa interactivo, junto con su leyenda y las estadísticas correspondientes (Figura 13).

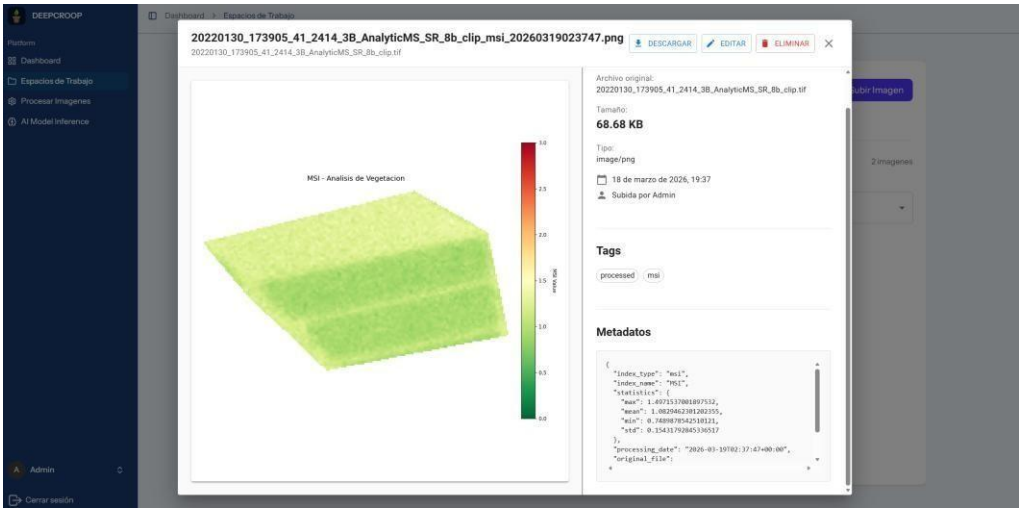


FIGURA 13: Resultado de imagen procesada con sus metadatos.

La interfaz de entrenamiento del AI Model Manager (Figura 14) permite configurar y ejecutar procesos de entrenamiento tanto supervisado (U-Net) como no supervisado (Autoencoder). El panel izquierdo muestra los parámetros configurables: selección del tipo de entrenamiento, carpetas de imágenes y máscaras (para supervisado), épocas, batch size, patch size, stride, backbone y pesos iniciales.

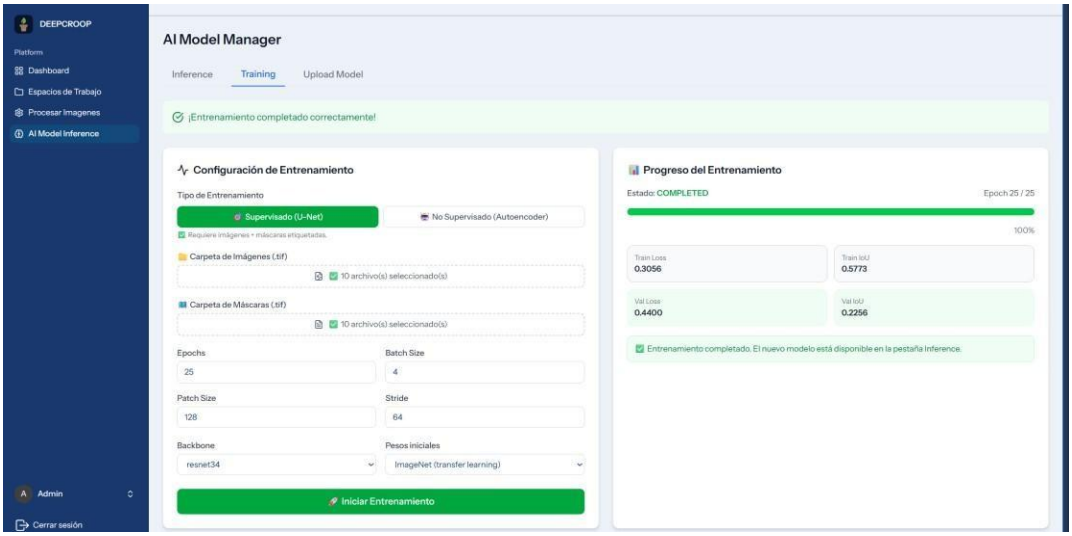


FIGURA 14:Interfaz de entrenamiento del AI Model Manager con configuración de parámetros y monitoreo de progreso.

El panel derecho presenta el progreso del entrenamiento en tiempo real, mostrando el estado actual, barra de progreso, época actual, y métricas de rendimiento (Train Loss, Train IoU, Val Loss, Val IoU). Al completarse, el sistema notifica al usuario que el modelo está disponible para su uso en la pestaña Inference.

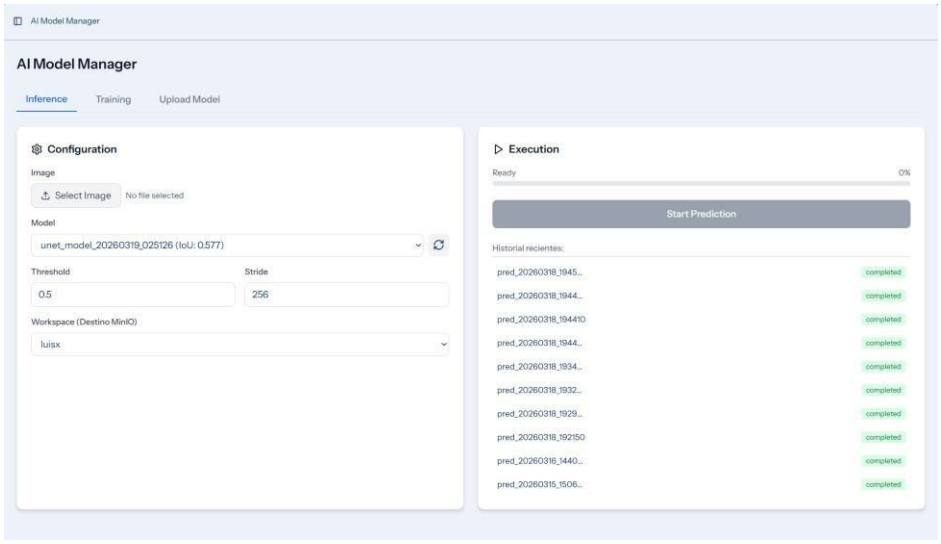


FIGURA 15: Interfaz de inferencia del AI Model Manager con configuración de parámetros y panel de ejecución.

La pestaña Inference (Figura 15) proporciona la interfaz para ejecutar predicciones sobre imágenes satelitales utilizando modelos previamente entrenados. El panel de configuración (izquierda) permite seleccionar la imagen de entrada, elegir el modelo de la lista de modelos disponibles (mostrando su IoU), ajustar el umbral de detección, configurar el stride, y seleccionar el workspace de destino. El panel de ejecución (derecha) muestra el estado del proceso, barra de progreso, botón de inicio de predicción, y un historial de inferencias recientes con sus estados (completed/failed), permitiendo al usuario revisar trabajos anteriores.

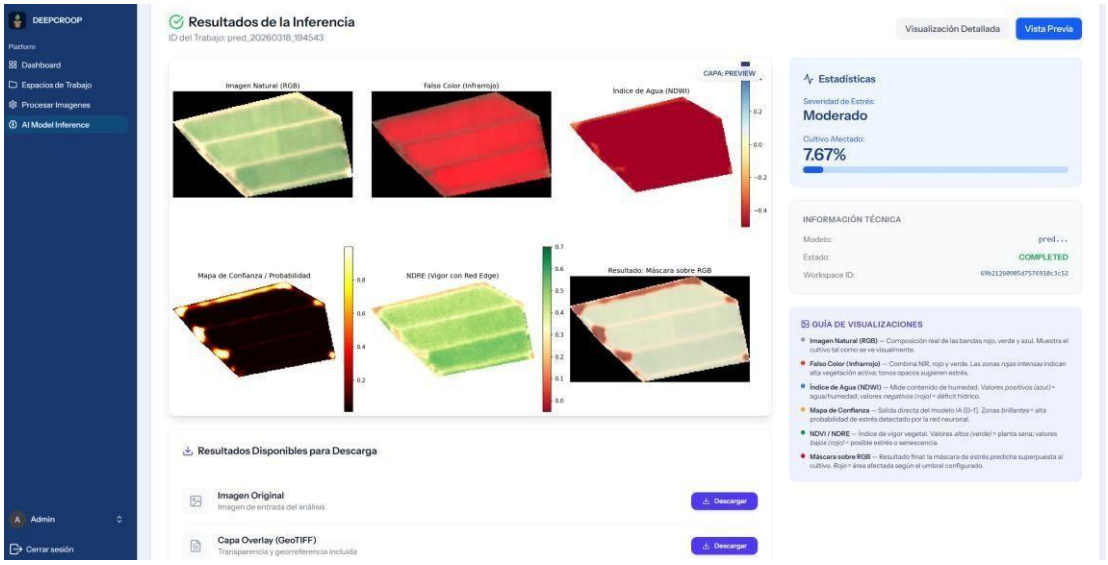


FIGURA 16: Interfaz de resultados de inferencia con visualizaciones multiespectrales, estadísticas de estrés y opciones de descarga.

La interfaz de resultados presenta una visualización comprehensiva del análisis de estrés hídrico. El panel central muestra seis visualizaciones:

- Imagen natural RGB
- Falso color infrarrojo
- Índice de agua (NDWI)
- Mapa de confianza/probabilidad del modelo
- NDRE (vigor con Red Edge),
- El resultado final con máscara sobre RGB.

El panel derecho muestra estadísticas clave: severidad del estrés (Moderado), porcentaje del cultivo afectado (7.67%), información técnica del trabajo, y una guía de visualizaciones que explica la interpretación de cada capa. En la parte inferior se presentan los resultados disponibles para descarga: imagen original, capa overlay GeoTIFF, máscara binaria, y visualización detallada.

4.3. Módulo de Inteligencia Artificial para Detección de Estrés

En esta sección se detalla la ingeniería aplicada para la construcción del modelo de segmentación semántica, centrando la atención en el uso de datos de alta resolución y el flujo de entrenamiento supervisado.

4.3.1. Construcción del Dataset (PlanetScope SuperDove)

Para la ejecución de las pruebas de resultados presentadas en este trabajo, se eligió la arquitectura de tipo U-Net, la cual fue entrenada utilizando imágenes de la constelación PlanetScope SuperDove. Esta decisión se fundamenta en la capacidad de los modelos supervisados para realizar una segmentación semántica de alta precisión, permitiendo una delimitación exacta de las áreas afectadas y una validación cuantitativa rigurosa mediante la comparativa directa con etiquetas de referencia (Ground Truth).

Asimismo, este enfoque permite aprovechar al máximo la riqueza de las 8 bandas espectrales para aprender patrones específicos de firmas de estrés hídrico que serían difíciles de aislar con métodos no supervisados.

Adicionalmente, al no contar con altas cantidades de imágenes con cultivos sanos para establecer una base de normalidad robusta (condición necesaria para el óptimo desempeño de modelos no supervisados como los Autoencoders), el tipo supervisado resultó ser la mejor opción para garantizar resultados confiables y precisos con el dataset disponible.

Características de la Fuente de Datos:

- **Sensor:** PlanetScope 8-band (SuperDove).
- **Resolución Espacial:** 3 metros por píxel.
- **Período de Captura:** Finales de 2023 a inicios de 2024 (Temporada agrícola regional).
- **Zona de Estudio:** Campos de cultivo de chile en la región de Sinaloa.

Configuración de Bandas Espectrales: El modelo procesa un tensor de entrada compuesto por las 8 bandas nativas del sensor, permitiendo capturar variaciones fisiológicas sutiles:

Canal	Banda PlanetScope	Aplicación en el Modelo
1	Coastal Blue	Corrección y detección de aerosoles
2	Blue	Clasificación de suelo y agua
3	Green I	Vigor vegetativo temprano
4	Green	Contenido de clorofila
5	Yellow	Identificación de estrés por amarillamiento
6	Red	Absorción de energía fotosintética
7	RedEdge	**Crítico:** Detección de estrés hídrico temprano
8	NIR (Infrarrojo Cercano)	Biomasa y estructura celular foliar

TABLA 2: Mapeo y aplicación de las bandas espectrales de PlanetScope SuperDove en el modelo.

Generación de Etiquetas (Ground Truth): Para el entrenamiento supervisado, se generaron máscaras binarias precisas mediante el script generate_ground_truth.py. Este proceso automatizó la clasificación en tres categorías: Clase 0 (Sano), Clase 1 (Estrés) y Clase 2 (Ignorar/Agua/Suelo). Se aplicó el algoritmo de Umbralización de Otsu sobre los índices de vegetación para separar automáticamente las zonas sanas de las anomalías espectrales.

4.3.2. Arquitectura de la Red Neuronal (U-Net)

Se implementó una arquitectura U-Net basada en PyTorch, diseñada específicamente para segmentación semántica de imágenes multiespectrales.

Estructura de la Red:

1. **Encoder (Ruta de Contracción):** Utiliza bloques *DoubleConv (Conv2d 3x3 + BatchNorm + ReLU)* seguidos de *MaxPool2d* para reducir la resolución espacial y aumentar la profundidad de características hasta un *bottleneck* de 1024 canales.
2. **Decoder (Ruta de Expansión):** Realiza un sobremuestreo mediante *ConvTranspose2d* y utiliza *Skip Connections* para concatenar mapas de

características de alta resolución del encoder, preservando la resolución espacial de 3m por píxel.

3. **Salida:** Capa *OutConv* con activación *Sigmoid* que genera el mapa de probabilidad de estrés.

4.3.3. Proceso de Entrenamiento e Hiperparámetros

Parámetro	Valor	Descripción
Learning Rate	0.001	Ajustado mediante Scheduler ReduceLROnPlateau
Batch Size	8	Tamaño de lote optimizado
Epochs	70	Ciclos completos de entrenamiento
Loss Function	CombinedLoss	Mezcla de 0.5 BCE + 0.5 Dice Loss
Patch Size	128×128	Tamaño de las muestras de entrada

TABLA 3: Hiperparámetros y configuración del proceso de entrenamiento supervisado.

Se implementó Data Augmentation en tiempo de ejecución, incluyendo *flips* horizontales/verticales y rotaciones de 90°, 180° y 270° para robustecer la generalización ante diferentes orientaciones de cultivo.

4.3.4. Arquitectura de la Red Neuronal No Supervisada (Autoencoder Convolucional)

Para el entrenamiento no supervisado se implementó un **Autoencoder Convolucional**, el cual aprende a comprimir y reconstruir imágenes de cultivos sanos, permitiendo detectar anomalías (estrés hídrico) mediante el error de reconstrucción.

Estructura de la Red: El autoencoder consta de dos componentes principales: un **Encoder** que comprime la información en un espacio latente de menor dimensionalidad, y un **Decoder** que reconstruye la imagen original a partir de dicha representación.

1. **Encoder (Compresión):**
   - `Conv2d(C → 32, kernel=3, stride=2, padding=1) + ReLU`
   - `Conv2d(32 → 64, kernel=3, stride=2, padding=1) + ReLU`
   - `Conv2d(64 → 128, kernel=3, stride=2, padding=1) + ReLU`

- `Flatten + Linear → 128` (Espacio latente) Cada capa convolucional reduce a la mitad las dimensiones espaciales (stride=2), generando una compresión progresiva de 128×128 → 64×64 → 32×32 → 16×16. El espacio latente de 128 dimensiones captura las características esenciales de un cultivo sano.

2. **Decoder (Reconstrucción):**
   - `Linear(128 → flattened_size)`
   - `Unflatten a (128, 16, 16)`
   - `ConvTranspose2d(128 → 64, stride=2) + ReLU`
   - `ConvTranspose2d(64 → 32, stride=2) + ReLU`
   - `ConvTranspose2d(32 → C, stride=2) + Sigmoid` Las capas de convolución transpuesta recuperan progresivamente la resolución espacial 16×16 → 32×32 → 64×64 → 128×128. La activación Sigmoid en la capa final normaliza la salida al rango [0, 1].

Detección de Anomalías: Durante la inferencia, el modelo reconstruye parches de entrada. Las regiones sanas se reconstruyen con bajo error, mientras que zonas con estrés hídrico (anomalías) generan alto error de reconstrucción:

$$\text{Error}(x, y) = \text{MSE}(\text{entrada}(x, y), \text{reconstrucción}(x, y))$$

- Si $\text{Error} > \text{threshold}$ → Anomalía detectada (estrés).
- Si $\text{Error} \leq \text{threshold}$ → Normal (cultivo sano).

El umbral (*threshold*) se calcula automáticamente como el percentil 95 de los errores en el conjunto de validación.

Parámetro	**Valor**	**Descripción**
Learning Rate	0.001	Tasa de aprendizaje Adam
Batch Size	16	Mayor que en supervisado (no hay máscaras)
Epochs	50	Ciclos de entrenamiento
Loss Function	MSE	Mean Squared Error
Latent Dim	128	Dimensiones del espacio latente

Canales entrada	4 o 6	BGRN estándar o con índices NDWI/NDMI
Validación	20%	Partición train/val

TABLA 4:Hiperparámetros del entrenamiento no supervisado.

Ventajas del Enfoque No Supervisado:

- No requiere máscaras *ground truth* etiquetadas manualmente.
- Aprende automáticamente el patrón de "normalidad" del cultivo.
- Adaptable a diferentes tipos de cultivos sin re-etiquetado.
- Útil como primera aproximación cuando no se dispone de datos anotados.

4.4. Gestión y Entrenamiento de Modelos (AI Model Manager)

La plataforma integra un módulo especializado denominado AI Model Manager, que permite administrar el ciclo de vida de los modelos de inteligencia artificial desde una interfaz unificada. Este componente es esencial para garantizar que el sistema sea evolutivo y personalizable por el usuario.

4.4.1. Interfaz Funcional

El administrador de modelos se organiza en tres áreas clave que cubren el flujo operativo completo:

1. **Inferencia:** Permite ejecutar predicciones cargando imágenes satelitales y seleccionando el modelo deseado de la biblioteca local disponible en el sistema.
2. **Entrenamiento:** Permite configurar y ejecutar nuevos procesos de aprendizaje personalizados. El sistema ofrece flexibilidad al admitir dos paradigmas: entrenamiento supervisado (mediante la arquitectura U-Net que requiere pares de imágenes y máscaras de referencia) y entrenamiento no supervisado (basado en Autoencoders que aprenden patrones de cultivos sanos). El usuario puede definir rutas de datos y ajustar hiperparámetros como épocas, tamaño de parche y tasa de aprendizaje.

3. **Carga de Modelos:** Provee una utilidad para importar pesos de redes entrenadas externamente en formato PyTorch (.pt), registrando automáticamente sus metadatos en la base de datos MongoDB para su uso inmediato.

4.4.2. Procesamiento Asíncrono con Celery

Debido a que el entrenamiento y la inferencia son tareas de alto consumo computacional, el sistema utiliza una arquitectura asíncrona:

- **Gestión de Tareas:** Cuando se inicia un proceso, el backend (FastAPI) registra un TrainingJob y delega la ejecución a un Worker de Celery utilizando Redis como broker.
- **Monitoreo en Tiempo Real:** El frontend realiza consultas (*polling*) cada 2 segundos a la API para obtener el progreso de la tarea (pérdida, IoU actual, época), permitiendo al usuario visualizar el avance sin bloquear la interfaz web.
- **Almacenamiento:** Los modelos resultantes se almacenan en el sistema de archivos con un registro correspondiente en MongoDB que incluye su arquitectura y métricas finales.

CAPÍTULO 5

5. RESULTADOS Y ANÁLISIS

5.1. Casos de Estudio e Inferencias en la Plataforma

Para validar la capacidad diagnóstica de la plataforma DEEPCROP, se seleccionaron dos escenarios contrastantes en parcelas de la región de Sinaloa. Estas pruebas se realizaron utilizando el modelo U-Net entrenado, aplicando un umbral de decisión (*Threshold*) de 0.30 y un desplazamiento de procesamiento (*Stride*) de 256 píxeles para asegurar una cobertura completa del área de interés.

5.1.1. Caso A: Evaluación en Cultivo con Estrés Severo

Este primer escenario corresponde a una parcela capturada el 30 de enero de 2022. Visualmente, el cultivo presenta una coloración heterogénea en las bandas de infrarrojo, lo

que sugiere un déficit hídrico significativo. El objetivo de este caso fue poner a prueba la sensibilidad de la red neuronal ante afectaciones extensas en el follaje.

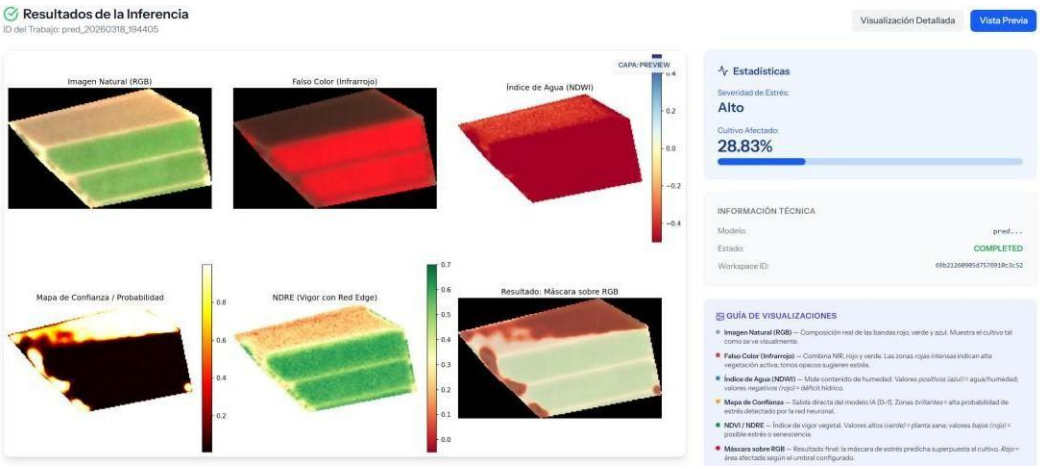


FIGURA 18: Visualización de la anomalía detectada por el modelo U-Net en la plataforma.

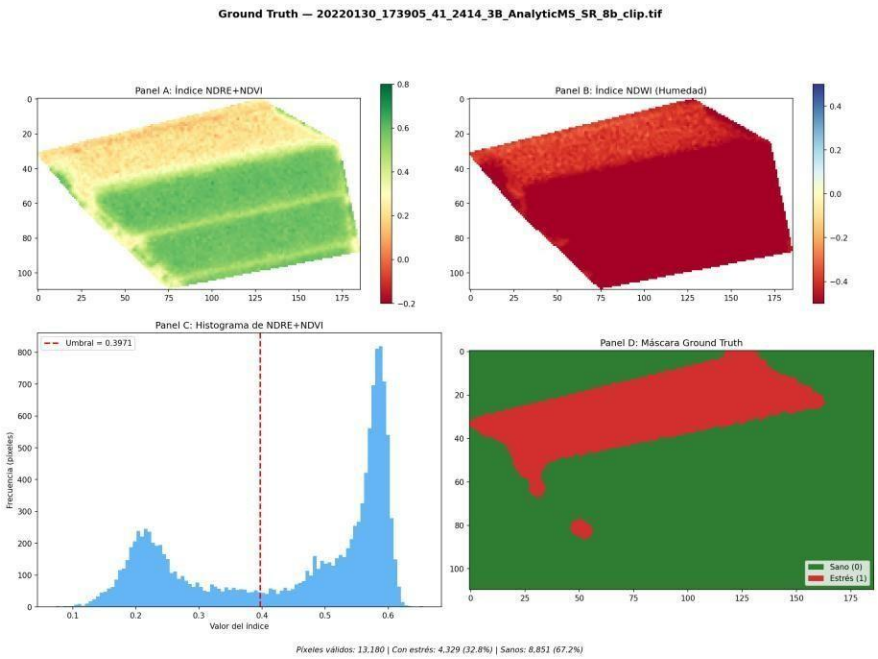


FIGURA 17: Máscara de Ground Truth generada mediante el script de procesamiento tradicional.

` En este caso, el método tradicional reportó un 32.8% de área afectada por estrés. La inferencia realizada por el sistema DEEPCROP identificó un 28.83% de anomalía, logrando localizar con precisión el núcleo de la franja superior donde la firma espectral indicaba la

mayor pérdida de vigor. La comparativa directa arrojó un IoU de 0.7213, un F1-Score de 0.8381 y una Exactitud (Accuracy) de 0.9326.

5.1.2. Caso B: Evaluación en Cultivo con Vigor Saludable

El segundo escenario analiza una imagen del 28 de febrero de 2023. En este caso, el cultivo se encuentra en una etapa de desarrollo estable con irrigación óptima, presentando solo manchas mínimas de estrés en los bordes de la parcela. Se utilizó para evaluar la capacidad de la plataforma para evitar falsos positivos en cultivos sanos.

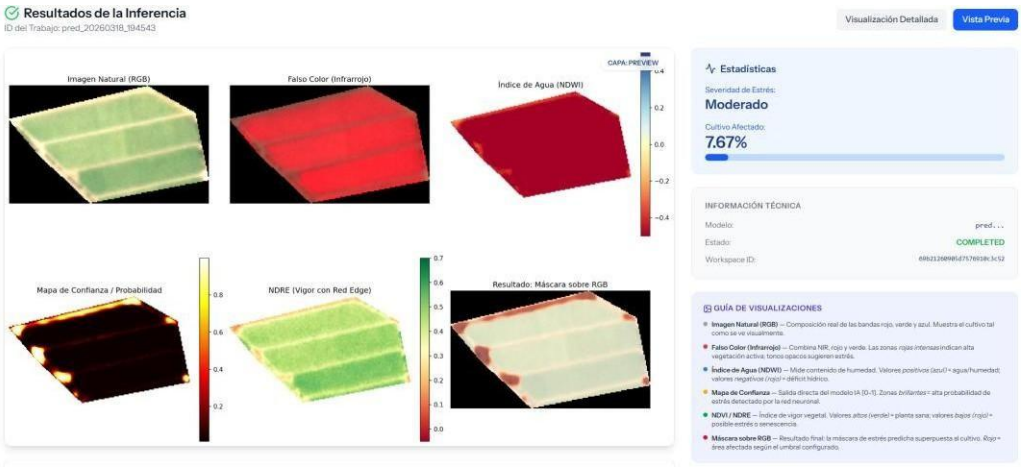


FIGURA 20: Inferencia de la plataforma mostrando una mínima activación de anomalías.

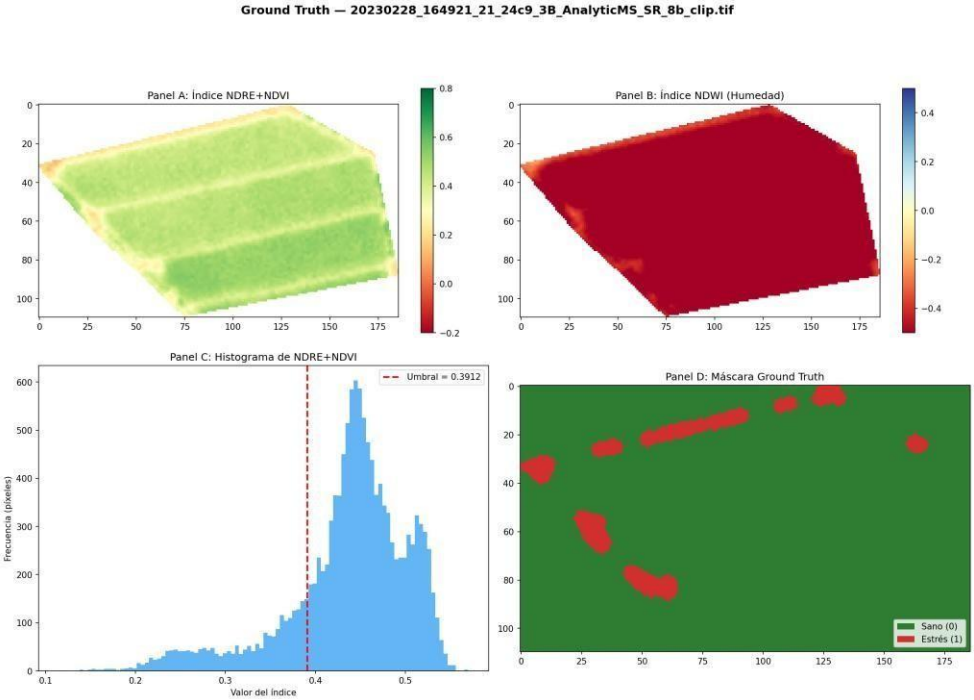


FIGURA 19: Ground Truth del caso B con manchas de estrés periférico.

El diagnóstico tradicional arrojó un valor de 7.9% de estrés disperso. La plataforma DEEPCROP, tras el procesamiento multiespectral, reportó un 7.67% de área con anomalías, clasificando la severidad como "Moderada". Las métricas obtenidas fueron un IoU de 0.6753, un F1-Score de 0.8061 y una elevada Exactitud (Accuracy) de 0.9778, lo que confirma que el modelo no sobreestima las fallas en cultivos saludables.

5.2. Evaluación Global de Métricas

El desempeño del modelo U-Net fue evaluado de manera integral mediante el análisis de su capacidad de segmentación y precisión de píxel. Los resultados obtenidos en los casos de prueba reflejan un comportamiento robusto, donde el modelo alcanza niveles de IoU superiores al 0.67 en escenarios diversos. Específicamente, el sistema demostró que a mayor presencia de estrés real (Caso A), la capacidad de intersección del modelo mejora, alcanzando un IoU máximo de 0.7213. Por otro lado, la exactitud global se mantiene por encima del 93% en todos los escenarios, lo que indica que la plataforma minimiza los falsos positivos y proporciona información confiable para el productor agrícola.

5.3. Análisis de Latencia y Eficiencia Operativa

Desde la perspectiva del rendimiento técnico, el sistema demostró una latencia óptima durante el procesamiento de imágenes de alta resolución de PlanetScope. En el Caso B, el tiempo de respuesta fue de 1,256.31 ms, mientras que en el Caso A fue de 1,288.36 ms. Estos tiempos, cercanos a los 1.2 segundos por inferencia, validan la eficiencia de la arquitectura asíncrona y la capacidad de la plataforma para servir como una herramienta de diagnóstico rápido en el campo.

CAPÍTULO 6

6. CONCLUSIONES

6.1. Conclusiones del Proyecto

La implementación de la arquitectura U-Net en la plataforma DEEPCROP ha demostrado ser una estrategia superior a los métodos de umbralización fija tradicionales. Los resultados obtenidos, con un IoU que oscila entre el 67% y el 72%, validan la capacidad del sistema para segmentar con precisión las zonas de estrés hídrico en cultivos de la región de Sinaloa. Esta fiabilidad diagnóstica es consecuencia directa de la integración de la banda RedEdge de PlanetScope, la cual permite identificar firmas espectrales de falta de humedad antes de que el daño sea perceptible visualmente.

Es importante destacar que el modelo actual fue entrenado con un dataset selecto y limitado de imágenes centradas principalmente en el cultivo de chile. Aunque los resultados actuales son satisfactorios y funcionalmente útiles, se identifica una oportunidad de mejora significativa en las métricas de desempeño si se escala el entrenamiento hacia un repositorio de datos más amplio y diverso. Un dataset que cubra mayor variabilidad geográfica y distintas etapas fenológicas permitiría elevar el IoU de validación y robustecer la capacidad de generalización de la inteligencia artificial frente a otros tipos de cultivos.

Finalmente, DEEPCROP logra cerrar la brecha tecnológica entre la teledetección científica avanzada y la práctica agrícola cotidiana. A través del AI Model Manager y el procesamiento asíncrono, la plataforma no solo ofrece diagnósticos precisos en tiempo real, sino que dota al usuario de una herramienta evolutiva capaz de adaptarse a las necesidades específicas de cada ciclo agrícola. Este proyecto sienta las bases para una gestión hídrica más inteligente y sostenible, optimizando los recursos y mejorando la resiliencia del sector agroalimentario frente a los desafíos climáticos actuales.

6.2. Trabajo Futuro

Como línea de acción inmediata, se propone la expansión masiva del dataset de entrenamiento para mitigar las limitaciones del volumen actual de datos. Asimismo, se recomienda la integración de análisis de series temporales que permitan predecir la evolución

del estrés y la posible pérdida de rendimiento, transformando la plataforma de una herramienta de diagnóstico en un sistema de pronóstico agronómico avanzado.

7. GLOSARIO TÉCNICO INTEGRAL

- **Accuracy (Exactitud):** Porcentaje total de píxeles correctamente clasificados por el modelo de IA.
- **API (Application Programming Interface):** Interfaz que permite la comunicación entre el frontend y el backend de IA.
- **Autoencoder:** Red neuronal que aprende a comprimir y reconstruir datos para detectar anomalías.
- **U-Net:** Arquitectura de red neuronal especializada en segmentación de imágenes.
- **Banda Espectral:** Rango específico de longitudes de onda capturado por un sensor satelital.
- **Celery:** Sistema de gestión de colas para ejecutar tareas pesadas de forma asíncrona.
- **F1-Score (Dice Coefficient):** Medida estadística de la precisión de la segmentación.
- **GeoTIFF:** Formato de imagen que incluye metadatos de georreferenciación.
- **Ground Truth:** Datos de referencia que representan la realidad comprobada del terreno.
- **Inferencia:** Acto de procesar una imagen a través de un modelo entrenado para obtener un diagnóstico.
- **IoU (Intersection over Union):** Métrica que mide la superposición entre la predicción y el suelo real.
- **Latencia:** Tiempo total de respuesta desde la solicitud hasta la visualización del resultado.
- **NDRE (Normalized Difference Red Edge):** Índice de vegetación basado en la banda RedEdge para detectar estrés hídrico temprano.
- **NDVI (Normalized Difference Vegetation Index):** Índice estándar para medir el vigor y la densidad de la vegetación.
- **NDWI (Normalized Difference Water Index):** Índice diseñado para monitorear el contenido de agua en la vegetación y delinear cuerpos de agua.
- **Polling:** Técnica de consulta periódica al servidor para verificar el estado de una tarea asíncrona (utilizada para monitorear el progreso en Celery).

- **PyTorch:** Framework de código abierto para aprendizaje profundo utilizado en la implementación de las arquitecturas U-Net y Autoencoder.
- **RedEdge:** Rango espectral altamente sensible al estrés fisiológico temprano de las plantas.
- **Stride (Paso):** Parámetro que define el desplazamiento de la ventana de procesamiento (parche) sobre la imagen original.
- **Threshold (Umbral):** Valor límite utilizado para clasificar reconstrucciones o probabilidades como anomalías o áreas normales.
- **Umbralización de Otsu:** Algoritmo de binarización automática utilizado para separar el fondo del primer plano (sano vs. estrés) minimizando la varianza intraclase.

8. REFERENCIAS

Adam, S. I., & Andolo, S. (2019, August). A new PHP web application development framework based on MVC architectural pattern and ajax technology. In *2019 1st International Conference on Cybernetics and Intelligent System (ICORIS)* (Vol. 1, pp. 45–50). IEEE.

Agremo (2025). *Crop Monitoring & Field Analytics Platform*. https://agremo.com

Agrolika. (2025). *Plataforma de agricultura de precisión*. https://www.agrolika.mx

Arcadia Peralta, É. A., Marceleño Flores, S. M. L., & Flores Vílchez, F. (2024). Agricultura de precisión en la producción de caña de azúcar: Diagnóstico para revisar las relaciones entre prácticas agrícolas tradicionales y la adopción de tecnologías. *Desafíos en el Contexto Empresarial: Sostenibilidad, Innovación y Competitividad*, 35–47. https://doi.org/10.52501/cc.250.02

Barrientos, A., Del Cerro, J., Gutiérrez, P., San Martín, R., Martínez, A., & Rossi, C. (2007). *Vehículos aéreos no tripulados para uso civil. Tecnología y aplicaciones*. Universidad Politécnica de Madrid.

Bhakal, S., Pandey, A., & Jain, K. (2024). Precision Agriculture: A Web-GIS Framework for Health and Stress Assessment Using Multi-Source Remote Sensing Data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLVIII-4-2024, 59–64. https://doi.org/10.5194/isprs-archives-xlviii-4-2024-59-2024

Bojorquez-Delgado, G., et al. (2023). Análisis y Evaluación Económica de la Producción Agrícola en el Estado de Sinaloa para el Año 2022 utilizando Ciencia de Datos. *Revista Interdisciplinaria de Ingeniería Sustentable y Desarrollo Social*, 9(1), 97–108.

Borràs, J., et al. (2017). Land use classification from Sentinel-2 imagery. *Revista de Teledetección*, (48), 55–66. https://doi.org/10.4995/raet.2017.7133

CDSE (2025). *Copernicus Data Space Ecosystem*. https://dataspace.copernicus.eu/

Chaves, M. M., Maroco, J. P., & Pereira, J. S. (2003). Understanding plant responses to drought — from genes to the whole plant. *Functional Plant Biology*, 30(3), 239–264. https://doi.org/10.1071/FP02076

Congedo, L. (2021). *Semi-Automatic Classification Plugin Documentation*.

Dhanagari, M. R. (2024). MongoDB and Data Consistency: Bridging the Gap between Performance and Reliability. *Journal of Computer Science and Technology Studies*, 6(2), 183–198. https://doi.org/10.32996/jcsts.2024.6.2.21

ESA (2025). *European Space Agency*. https://earth.esa.int/eogateway/missions/planetscope

FAO. (2017). *Water for sustainable food and agriculture: A report produced for the G20 Presidency of Germany*. https://www.fao.org/3/i7959e/i7959e.pdf

Gao, B. C. (1996). NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257–266.

Gebbers, R., & Adamchuk, V. I. (2010). Precision agriculture and food security. *Science*, 327(5967), 828–831.

Ghulam, A., et al. (2022). Monitoring tomato crop water stress using Sentinel-2 vegetation indices and machine learning algorithms. *Open Agriculture*, 7(1), 1211–1221.

Goldberg, J. (2022). *Learning TypeScript: Enhance Your Web Development Skills Using Type-Safe JavaScript*. O'Reilly Media.

Gorelick, N., et al. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*.

Grinberg, M. (2021). *Flask Web Development* (2.ª ed.). O'Reilly Media.

Guamán-Rivera, S. A. (2023). Aplicación de Tecnologías en la Agricultura de Precisión mediante Evidencia de Fuentes Científicas. *Horizon Nexus Journal*, 1(2), 1–13.

Guzmán Albores, J. M., et al. (2024). *XIKUA Boletín Científico de la Escuela Superior de Tlahuelilpan*. https://doi.org/10.29057/xikua.v12i24.12790

Guzmán-Álvarez, J. A., et al. (2022). Uso de sensores remotos en la agricultura: aplicaciones en el cultivo del banano. *Agronomía Mesoamericana*, 33(3).

Hema, V., et al. (2020). Scrum: An effective software development agile tool. *IOP Conference Series: Materials Science and Engineering*, 981.

Hinojosa, C., et al. (2015). La Gestión del Conocimiento Aplicada en la Ingeniería de Requisitos: Un Caso de Estudio en Ecuador. WER.

Huang, T. (2024). FEAD: Figma-Enhanced App Design Framework for Improving UI/UX in Educational App Development. *arXiv preprint arXiv:2412.06793*.

INEGI. (2025). *Instituto Nacional de Estadística, Geografía e Informática*. https://www.inegi.org.mx/

Jones, H. G. (2007). Monitoring plant and soil water status. *Journal of Experimental Botany*, 58(2), 119–130.

Joshi, A., et al. (2023). Remote-Sensing Data and Deep-Learning Techniques in Crop Mapping and Yield Prediction: A Systematic Review. *Remote Sensing*, 15(8), 2014.

Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90.

Khan, A., et al. (2020). A convolutional neural network-based approach for drought stress detection in soybean. *Computers and Electronics in Agriculture*, 179, 105830.

Kharuf-Gutierrez, S., et al. (2018). Análisis de imágenes multiespectrales adquiridas con vehículos aéreos no tripulados. *Ingeniería electrónica, automática y comunicaciones*, 39(2), 79–91.

Kristiyanto, D. Y., et al. (2024). Comprehensive Framework for Transitioning Monolithic to Microservices in MVC Context. IEEE.

Kumar, R. R. (2022). A Concept of PHP Scripting in Web Development.

Lazuardy, M. F. S., & Anggraini, D. (2022). Modern front end web architectures with React.js and Next.js. *Research Journal of Advanced Engineering and Science*, 7(1), 132–141.

Lillesand, T., et al. (2015). *Remote sensing and image interpretation* (7th ed.). John Wiley & Sons.

Lucassen, G., et al. (2016). The use and effectiveness of user stories in practice. Springer.

Lu, B., et al. (2020). Recent Advances of Hyperspectral Imaging Technology and Applications in Agriculture. *Remote Sensing*, 12(16), 2659.

Magdalena Main-Knorn, et al. (2017). Sen2Cor for Sentinel-2. *Proc. SPIE 10427*.

McKinney, W. (2022). *Python for Data Analysis* (3.ª ed.). O'Reilly Media.

Monteiro, A., et al. (2021). Precision Agriculture for Crop and Livestock Farming—Brief Review. *Animals*, 11(8), 2345.

Montiel González, R., et al. (2022). Clasificación de uso del suelo y vegetación con redes neuronales convolucionales. *Revista Mexicana de Ciencias Forestales*, 13(74), 97–119.

Morales Carreño, A. (2019). Implementación y metodología de calibración de cámaras multiespectrales para aplicaciones en agricultura de precisión.

Mulla, D. J. (2013). Twenty five years of remote sensing in precision agriculture. *Biosystems Engineering*, 114(4), 358–371.

Nițu, A., et al. (2025). NDVI and Beyond: Vegetation Indices as Features for Crop Recognition and Segmentation in Hyperspectral Data. *Sensors*, 25(12), 3817.

NXTAgro (2025). *Soluciones para la agricultura de precisión en México*. https://nxtagro.io

Ordóñez, J. L. (2013). Comunicaciones por satélite. *Revista Digital de ACTA*, 19.

Perrin, A., & Pahl, C. (2023). *MinIO for Dummies*. John Wiley & Sons.

PIX4D (2025). *Software híbrido de mapeo con drones y satélites*. https://www.pix4d.com/

Poblete, T., et al. (2021). Vineyard water status estimation using machine learning and multispectral imagery. *Computers and Electronics in Agriculture*, 190, 106454.

Ripoll, J., et al. (2016). Water shortage and quality of fleshy fruits. *Journal of Experimental Botany*, 65(15), 4097–4117.

Ríos Hernández, R. (2021). La Agricultura de Precisión. Una necesidad actual. *Revista Ingeniería Agrícola*, 11(1), 67–74.

Rimal, A. (2019). Developing a web application on NodeJS and MongoDB using ES6 and beyond.

Rouse, J. W., et al. (1974). Monitoring vegetation systems in the Great Plains with ERTS.

Sader desarrolla plataforma digital que contribuye al ahorro de agua en cultivos de riego. (2023).

Sahil Bhakal, Pandey, A., & Jain, K. (2024). Precision Agriculture: A Web-GIS Framework...

Salazar, E. Y. H., & Beltrán, C. A. (2020). SCRUM, un enfoque práctico de metodología ágil.

Schwaber, K., & Sutherland, J. (2020). *La guía definitiva de Scrum.*

Selfa, D. M., et al. (2006). A database and web application based on MVC architecture. IEEE.

Sishodia, R. P., et al. (2020). Applications of Remote Sensing in Precision Agriculture: A Review. *Remote Sensing*, 12(19), 3136.

Subecz, Z. (2021). Web-development with Laravel framework. *Gradus*, 8(1), 211–218.

Talib, R., et al. (2022). Water stress detection in wheat crop using Sentinel-2 imagery. *Geocarto International*, 37(25), 7291–7309.

Universidad de Palermo. (2022). Tecnologías de agricultura de precisión para el uso eficiente del agua.

Valencia, T. (2018). Determinar los efectos de los fenómenos naturales de escasez de agua... Umsa.bo.

Xu, J., et al. (2024). The evolution of precision agriculture and food safety: a bibliometric study. *Frontiers in Sustainable Food Systems*, 8.

Brekalo, S., & Sedlarević, T. (2024). The comparison of monolithic MVC and microservices architectures in Laravel applications. Polytechnic and Design, 12(3), 216–225. https://doi.org/10.19279/TVZ.PD.2024-12-3-17

Chuco Soto, D. V. (2021). La teledetección como herramienta para la agricultura y el riego. Universidad Nacional de Educación Enrique Guzmán y Valle. https://repositorio.une.edu.pe/entities/publication/431334e8-f1d5-4da4-b061-6bd30fb4258e

Zhang, C., et al. (2020). Applications of low altitude remote sensing in agriculture upon the advent of lightweight drones. *Remote Sensing*, 12(7), 1121.