VOLUMEN 48
XXXI Verano De la Ciencia
ISSN 2395-9797
www.jovenesenlaciencia.ugto.mx

Integración de Inteligencia Artificial y Sensado Óptico VIS/NIR para la Agricultura de Precisión

Integration of Artificial Intelligence and VIS/NIR Optical Sensing for Precision Agriculture

Fernando Alonso Vargas Robles[1], Evelyn Naomi Gallardo Licea[2], Esteban Liedo Castellanos[3], Diana Paulina Moreno Miranda[4], Oleksiy Shulika[5*]

[1]Licenciatura en Ingeniería en Mecatrónica, División de Ingenierías del Campus Irapuato-Salamanca (DICIS), Universidad de Guanajuato.
[2]Licenciatura en Ingeniería en Sistemas Computacionales, División de Ingenierías del Campus Irapuato-Salamanca (DICIS), Universidad de Guanajuato.
[3]Licenciatura en Ingeniería de Datos e Inteligencia Artificial, División de Ingenierías del Campus Irapuato-Salamanca (DICIS), Universidad de Guanajuato.
[4]Departamento de Ingeniería en Tecnologías de la Información e Innovación Digital, Universidad Tecnológica de Salamanca.
[5]Departamento de Ingeniería Electrónica, División de Ingenierías del Campus Irapuato-Salamanca (DICIS), Universidad de Guanajuato.
oshulika@ugto.mx
*Autor de correspondencia

Resumen

La agricultura de precisión requiere herramientas tecnológicas eficientes para el monitoreo no destructivo de los cultivos. En este trabajo se presenta el desarrollo e implementación de un flujo de procesamiento automatizado en Python para el análisis de imágenes multiespectrales utilizando la cámara multiespectral Parrot Sequoia. Se construyeron bases de datos de cultivos de apio, cacahuate, cilantro y maíz en etapa juvenil y madura, donde cada muestra estaba constituida por cuatro bandas (Verde, Rojo, Rojo extremo e Infrarrojo Cercano) y una imagen RGB. Las imágenes fueron preprocesadas mediante la calibración radiométrica, la corrección de viñeteo, la normalización por irradiancia solar y el alineamiento geométrico de las bandas para garantizar un correcto cálculo del Índice de Vegetación de Diferencia Normalizada (NDVI). A partir de descriptores estadísticos globales y métricas por clases de vigor se conformó un conjunto de datos de alta dimensionalidad donde la aplicación del Análisis de Componentes Principales (PCA) permitió reducirla, conservando el 95% de la información con solo cinco componentes principales. Finalmente, mediante el algoritmo de clasificación no supervisada K-Means, fueron agrupadas muestras en diferentes estados fisiológicos. Los resultados demuestran que la integración de censado óptico VIS/NIR y técnicas de aprendizaje automático son una alternativa no destructiva para el monitoreo del estado fisiológico de los cultivos.

Palabras clave: espectroscopía; inteligencia artificial; aprendizaje de máquina; clasificación; índices vegetativos; agricultura de precisión; imágenes multiespectrales.

Introducción

La agricultura es uno de los sectores más importantes en el desarrollo económico y la industria alimenticia. A menudo, este sector enfrenta diversos problemas debido a enfermedades, plagas o estrés hídrico en las plantas. Cuando esto sucede, se buscan distintas maneras de remediarlo, ya sea con fertilizantes, pesticidas, o algún otro producto químico, esto no solo puede afectar el crecimiento de la hierba, sino que también suele afectar la salud de la gente que consume los alimentos que provengan de esta. En los últimos años, ha surgido una estrategia llamada agricultura de precisión, la cual utiliza tecnologías digitales para medir y analizar variables del suelo y el clima (Rayhana *et al*., 2023). Esta metodología es clave para optimizar la distribución de recursos y mejorar la eficiencia en el campo mediante el monitoreo constante de los cultivos (Rayhana *et al*., 2023).

Es crucial detectar de manera oportuna cualquier problema en una planta para evitar pérdidas económicas grandes además de proteger la salud de los consumidores (Rayhana *et al*., 2023). Para ello se suelen utilizar drones con una cámara hiperespectral o multiespectral, estas toman imágenes de los cultivos de longitudes

de onda específicas, como el espectro visible e infrarrojo cercano (VIS/NIR), permitiendo obtener información detallada del estado de la planta (López-García *et al*., 2021; Moreno Miranda & Shulika, 2026; Rayhana *et al*., 2023). Debido a que las imágenes se toman bajo la luz del sol, suele haber variaciones en la iluminación, todo esto genera ruido que impide al algoritmo hacer un análisis correcto de las imágenes, por lo cual es necesario hacer un procesamiento previo de estas imágenes para que de esta manera el reflejo de luz que se presente no afecte en la clasificación de la planta (Rayhana *et al*., 2023).

El uso de algoritmos de reducción de dimensionalidad, como el Análisis de Componentes Principales (PCA) y el Análisis Discriminante Lineal (LDA), junto con la evaluación de índices vegetativos, permite aislar las características clave y automatizar el diagnóstico (Rayhana *et al*., 2023).

Por lo tanto, el objetivo de este trabajo es construir una base de datos de imágenes multiespectrales, así como presentar el desarrollo y la implementación de un flujo de procesamiento en Python para aislar, analizar y clasificar plantas a partir de bases de datos de imágenes VIS/NIR.

Marco teórico

Agricultura de Precisión

La agricultura de precisión se refiere al uso de un conjunto de tecnologías de la información (TICs) aplicadas para la producción del sector agrícola con el objetivo de una eficiente toma y ejecución de decisiones. Las herramientas utilizadas en la agricultura de precisión engloban desde el posicionamiento global, dispositivos de distribución de riego, fertilizantes, plaguicidas variables, sensores climatológicos de cultivo y drones hasta sensores, el manejo de grandes volúmenes de datos (Big Data) y el internet de las cosas (Internet of Things IoT). La aplicación de la tecnología tiene un efecto positivo al eficientizar el tiempo de visita al campo, obteniendo información precisa con nuevas soluciones tecnológicas. Sin embargo, la tecnología no está al alcance de todos los agricultores, especialmente los pequeños o medianos productores debido a restricciones económicas, además es posible encontrar problemas en la compactibilidad de las tecnologías. La extensión del uso de la agricultura de precisión entre los agricultores favorecerá la obtención y aplicación de datos adquiridos para la creación de redes de investigación y experimentación, logrando replicar en parcelas que compartan similitud, para ello será necesario la capacitación del personal (Rambauth-Ibarra, 2021).

Espectroscopía

La espectroscopía es una técnica fundamental para la coo que nos rodea pues nos permite estudiar la interacción entre la materia y la radiación electromagnética, es decir, la luz (D. W. Ball 2006). De acuerdo con Moreno y Shulika (2026), la espectroscopía es una herramienta precisa, rápida y no destructiva que permite monitorear la salud de las plantas al detectar cambios fisiológicos antes de que sean visibles ya que el estado físico de la superficie foliar se ve reflejado en las propiedades ópticas de las hojas.

Imágenes multiespectrales

Las imágenes multiespectrales, a diferencia de las hiperespectrales que abarcan un gran número de bandas, recogen datos en una sección limitada del espectro electromagnético. Normalmente se constituyen entre cinco a diez bandas que suelen abarcar RGB y algunas bandas infrarrojas (Kogut, P. 2026). Las cámaras hiperespectrales utilizan cientos de longitudes de onda individuales mientras que las cámaras multiespectrales operan en rangos de longitudes de onda específicos. Por otro lado, las cámaras o sensores RGB operan en tres regiones del espectro visible, con un rango aproximado de $400nm$ a $499nm$ para el azul, de $500nm$ a $549nm$ para el verde y de $550nm$ a $750nm$ para el rojo, sin embargo, la resolución de las imágenes dependerá en el nivel de iluminación, el tiempo y las condiciones ambientales al momento de capturar la fotografía. (Rayhana *et al*., 2023).

Cámara Sequoia

La cámara multiespectral Parrot Sequoia es un sensor multiespectral que capta la luz que reflejan las plantas. Es capaz de obtener imágenes en cinco canales que miden el estado de la vegetación: un sensor RGB y cuatro bandas espectrales que comprenden la banda verde (longitud de onda de $550nm$), roja ($660nm$), rojo extremo con ($735nm$) e infrarrojo cercano ($790nm$). Esto resulta de gran utilidad porque, de acuerdo con

Bauer *et al*. (2011), el canal infrarrojo permite la discriminación entre áreas con y sin clorofila. El sistema se compone por la cámara multiespectral y el sensor de radiación solar Sunshine que se encarga de registrar la intensidad del sol, permitiendo comparar la actividad solar con el cultivo. La Parrot Sequoia es precisa, de un reducido tamaño y peso que facilitan su uso en aviones no tripulados (Juan, 2025)

Procesamiento de imágenes multiespectrales

Las técnicas de análisis de imágenes han adquirido popularidad al ser capaces de identificar estrés en plantas de forma no invasiva a diferencia de los métodos tradicionales. Consiste en el procesamiento automatizado de las imágenes adquiridas para extraer las mediciones deseadas (Rayhana *et al*., 2023). En la literatura, se observa una alta frecuencia de algoritmos de aprendizaje automático, técnicas de reducción de dimensionalidad y clasificación. Entre los modelos más implementados destacan análisis de componentes principales (PCA), análisis discriminante lineal (LDA), KNN, redes neuronales convolucionales (CNN) y máquinas de soporte vectorial (SVM) (Rayhana *et al*., 2023; Moreno Miranda & Shulika, 2026).

Como señala Carlotto (1985), las imágenes multiespectrales se procesan siguiendo el flujo de preprocesamiento, donde implica procesos como la restauración y normalización de imágenes. Posteriormente, se calculan mediciones espectrales, de textura o temporales durante la extracción de características que serán utilizadas para alimentar el entrenamiento de modelos predictivos.

Principal Component Analysis - PCA

El análisis de componentes principales es una técnica que permite reducir la dimensionalidad de un conjunto de datos para extraer las características más importantes y facilitar su interpretación. Las mediciones espectrales tienen alta dimensionalidad, correlación y redundancia entre las longitudes de onda adyacentes, el PCA ha demostrado ser una herramienta eficaz al preservar la información más importante del sistema (Moreno Miranda & Shulika, 2026).

K-means

Es un algoritmo de aprendizaje no supervisado con una implementación sencilla que puede procesar grandes conjuntos de datos de gran volumen. Ha demostrado ser capaz de aislar regiones enfermas y sanas de una planta utilizando su perfil espectral (Rayhana *et al*., 2023).

Índices de Vegetación

Los índices de vegetación son utilizados para examinar de forma remota la vegetación en un área determinada; entre ellos, el más utilizado corresponde al Índice de Vegetación de Diferencia Normalizada o por sus siglas en inglés NDVI (NASA Earthdata, 2026). El NDVI refleja la relación entre la cantidad de luz reflejada por la superficie terrestre en las regiones del espectro electromagnético roja e infrarroja. Su valor es calculado como (INEGI, s. f.).:

$$ndvi = \frac{(nir - red)}{(nir + red)}$$

Algunas aplicaciones del NDVI es el seguimiento de sequías, la supervisión y predicción de producciones agrícolas o zonas con riesgo de incendio, pero sobre todo el seguimiento de la vegetación global gracias a que compensa los cambios en las condiciones de iluminación, la pendiente de la superficie, la orientación y otros factores (González *et al*., 2016).

Metodología

El presente apartado describe el procedimiento realizado para la obtención y posterior análisis de imágenes multiespectrales. Para ello, el proyecto se estructuró en tres fases principales: captura de imágenes multiespectrales, creación de base de datos y aplicación de algoritmos de aprendizaje de máquina.

VOLUMEN 48
XXXI Verano De la Ciencia
ISSN 2395-9797
www.jovenesenlaciencia.ugto.mx

La obtención de las imágenes se realizó con la cámara multiespectral Parrot Sequoia que captura la luz reflejada por las plantas en cuatro bandas espectrales que miden el estado de la vegetación tal como se aprecia en la figura 1.

- *Verde:* Longitud de onda de $550nm$, ancho de banda de $40nm$
- *Rojo:* Longitud de onda de $660nm$, ancho de banda de $40nm$
- *Rojo extremo (Red-Edge):* Longitud de onda de $735nm$ ancho de banda de $10nm$
- *Infrarrojo cercano:* Longitud de onda de $790nm$, ancho de banda de $40nm$

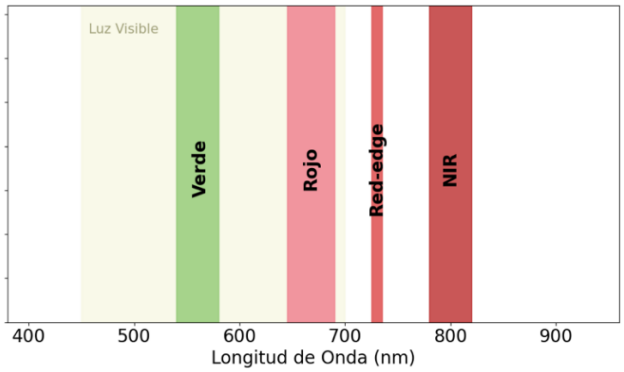

Figura 1. Longitudes de onda y anchos de banda para cada rango en el espectro.

Cada imagen tiene dimensiones de 1280×960 pixeles con resolución de 1,2Mpx, son almacenadas en escala de grises en un archivo .TIF (Tagged Image File Format) el cual es un formato estándar para imágenes de alta resolución. Además, se incluye también un sensor RGB que captura imágenes de dimensiones 4608×3456 con una resolución de 1,2Mpx y el sensor Sunshine de radiación solar que permite registrar la intensidad del sol para la calibración de las imágenes.



Figura 2. Cuerpo principal de cámara Parrot Sequoia y Sensor Sunshine. Tomado de Ficha técnica Parrot Sequoia (p. 1), por Grupo Acre, 2020.

Se estableció un protocolo para la toma de las imágenes: la cámara y el sensor Sunshine fueron anclados a un tripié con una altura aproximada de 1.5 m donde se buscó un plano cenital para abarcar la zona superior de la planta. Se realizaron capturas de cultivos de apio, cacahuate, cilantro y maíz blanco en etapas juvenil y madura conformando un conjunto de datos inicial. Estas imágenes fueron inspeccionadas y filtradas, descartando tomas desenfocadas o con elementos externos que pudieran alterar los resultados. La base de datos resultante se organizó en carpetas por cultivo, cada directorio contiene subcarpetas con muestras individuales compuestas por sus cinco imágenes correspondientes (GREEN, NIR, RED, REG y RGB).

A partir de las bases de datos obtenidas, fue aplicado un algoritmo que calcula el NDVI de cada muestra utilizando las bandas NIR y RED con lo cual se calcularon estadísticas globales como el valor mínimo, media, desviación, el porcentaje de distribución entre clases, entre otras.

Para el tratamiento sistemático de las capturas multiespectrales obtenidas en campo, se desarrolló un flujo de procesamiento en Python que automatiza la calibración, alineación espacial y extracción cuantitativa del NDVI. El procedimiento contempla la supresión de ruido térmico, corrección polinomial de viñeteo,

normalización por irradiancia solar mediante el sunshine sensor y el co-registro geométrico entre bandas con el algoritmo de Coeficiente de Correlación Mejorado (ECC).

La secuencia lógica de este procesamiento por lotes se sintetiza a continuación en el **Algoritmo 1**:

```
Inicio del Algoritmo
Entradas:
  - base_folder: Ruta del directorio raíz con subcarpetas ordenadas de capturas.
  - outdir: Ruta del directorio de salida para almacenar los resultados.
  - start, end: Límites numéricos del bucle iterativo de subcarpetas.
Salidas:
  - Archivos GeoTIFF individuales (_NDVI.tif, _NDVI_clases.tif).
  - Reportes de análisis cuantitativo local (_analisis.txt, _clases.csv).
  - Matriz de datos consolidada (base_datos_ndvi.csv).


1.  Crear el directorio de salida (outdir) si no existe en el sistema.
2.  Para cada identificador i desde start hasta end hacer:
3.      Definir subfolder = concatenar(base_folder, i con ceros a la izquierda)
4.      Si subfolder no existe o no constituye un directorio válido:
5.          Omitir iteración actual y continuar con la siguiente subcarpeta.
6.      Fin Si
7.
8.       Buscar y agrupar archivos que coincidan con los sufijos espectrales (_GRE, _RED,
_REG, _NIR).
9.      Si el grupo de capturas está incompleto (faltan bandas para el análisis):
10.         Omitir iteración actual y continuar con la siguiente subcarpeta.
11.     Fin Si
12.
13.     Para cada banda espectral B en {GRE, RED, REG, NIR} hacer:
14.          Leer la matriz de píxeles crudos (raw_matrix) mediante el lector de archivos
TIF.
15.            Extraer metadatos embebidos XMP (BlackLevel, ExposureTime, ISO, FNumber,
VignettingPolynomial2D, Irradiance).
16.
17.         // Calibración Radiométrica
18.         Restar ruido térmico del sensor: P = max(raw_matrix - BlackLevel, 0)
19.         Calcular factor de viñeteo polinomial 2D: V = VignettingFactor(shape, vpoly)
20.         Corregir atenuación óptica periférica: P_corrected = P / V
21.         Compensar parámetros intrínsecos de exposición óptica:
22.             Cam_Signal = P_corrected * (FNumber^2) / (ExposureTime * ISO * BandGain)
23.
```

ISSN 2395-9797
www.jovenesenlaciencia.ugto.mx

```
        Si Irradiance está disponible en el sunshine sensor y es > 0:
            E = Irradiance / (IrradianceExposureTime * IrradianceGain)
            Banda_Normalizada[B] = Cam_Signal / E  // Normalización por irradiancia
        Sino:
            Banda_Normalizada[B] = Cam_Signal  // Fallback a normalización fotométrica
        Fin Si
    Fin Para

    // Co-registro Espacial (Alineación Geométrica)
    Establecer Referencia = Banda_Normalizada["NIR"]
    Para cada banda móvil M en {GRE, RED, REG} hacer:
        Calcular matriz de transformación warp utilizando el coeficiente de correlación mejorado (ECC).
         Aplicar transformación afín o de traslación inversa para superponer M sobre Referencia.
        Banda_Alineada[M] = warpAffine(Banda_Normalizada[M], warp)
    Fin Para
    Banda_Alineada["NIR"] = Referencia

    // Extracción de Características y Clasificación
    Calcular NDVI píxel por píxel:
        NDVI = (Banda_Alineada["NIR"] - Banda_Alineada["RED"]) / (Banda_Alineada["NIR"] + Banda_Alineada["RED"] + 1e-6)
    Limitar valores de NDVI al rango matemático estricto [-1.0, 1.0].

    Inicializar matriz de clases (Clases_NDVI) con ceros.
    Para cada rango k definido en la escala ordinal de vigor vegetal hacer:
        Asignar etiqueta k a los píxeles donde lo_k <= NDVI < hi_k.
        Calcular porcentaje de área relativa ocupada por la clase k en la imagen.
        Calcular el valor medio de NDVI para la clase k.
    Fin Para

    // Exportación de Resultados Locales
    Guardar mapas ráster individuales en formato GeoTIFF.
     Generar panel gráfico de diagnóstico visual (falso color, continuo, segmentado e histograma).
    Escribir archivos de texto y CSV con el desglose estadístico de la captura.
    Construir vector de características de la muestra actual y añadirlo a la colección global.
Fin Para
```

```
59.
60. Concatenar la colección global de vectores de características en una estructura tabular de datos.
61. Exportar la base de datos estructurada a un archivo maestro final (base_datos_ndvi.csv).
Fin del Algoritmo
```

Asimismo, las imágenes multiespectrales sometidas al preprocesamiento (calibración radiométrica, normalización y co-registro geométrico) fueron exportadas para reemplazar las capturas originales y servir como base en etapas posteriores. Una vez obtenido el mapa continuo del NDVI, el algoritmo ejecuta una rutina de análisis cuantitativo y estructuración de datos. Este proceso transforma la información espacial bidimensional en un vector de características numéricas, esencial para el posterior entrenamiento de los modelos de clasificación. El análisis se divide en tres fases metodológicas:

Extracción de Estadísticas Globales

El sistema evalúa la matriz completa del NDVI de la hoja y extrae sus descriptores estadísticos fundamentales: el valor mínimo, máximo, la media aritmética, la mediana y la desviación estándar. Estas métricas globales permiten identificar la dispersión del vigor vegetal en toda la zona de captura. Adicionalmente, se establece un umbral duro en $NDVI > 0.2$ para discriminar el fondo (suelo, sombras o estructuras) y calcular el porcentaje exacto de cobertura vegetal efectiva en la imagen.

Segmentación y Clasificación Ordinal

Para detallar el estado de estrés fisiológico, el mapa continuo se somete a una segmentación por múltiples umbrales estáticos. Los valores de cada píxel se agrupan en una escala ordinal de seis niveles de vigor vegetal:

- No vegetación / Agua / Sombra ($-1.01 \leq NDVI < 0.00$)
- Suelo desnudo ($0.00 \leq NDVI < 0.20$)
- Vegetación escasa o con estrés ($0.20 \leq NDVI < 0.40$)
- Vegetación moderada ($0.40 \leq NDVI < 0.60$)
- Vegetación densa ($0.60 \leq NDVI < 0.80$)
- Vegetación muy vigorosa ($0.80 \leq NDVI \leq 1.01$)

Por cada clase, el algoritmo cuantifica el número absoluto de píxeles, el porcentaje de área relativa que ocupan dentro de la región de interés y el valor medio del NDVI específico para esa subdivisión.

Estructuración y Generación de la Base de Datos

Finalmente, las variables continúas extraídas y las métricas de las clases segmentadas se consolidan dinámicamente utilizando estructuras de datos tabulares (mediante la librería Pandas). El código realiza una sanitización automática de las etiquetas (eliminando espacios, barras y caracteres especiales) para garantizar la compatibilidad con los algoritmos matemáticos posteriores. Por cada captura (e.g., cada planta de cacahuate), se genera una fila única de datos que se concatena en un archivo maestro en formato CSV. Este documento constituye el ***dataset*** final, completamente numérico y balanceado, sobre el cual se aplicará el Análisis de Componentes Principales (PCA).

Se generó una base de datos de $nFilas \times 24\ columnas$, donde el número de filas corresponde al número de muestras del cultivo y las columnas a las estadísticas globales del conjunto de muestras.

Tabla 1. *Resumen de las variables estadísticas globales y métricas extraídas a partir del NDVI.*

Categoría	Variable	Descripción
Estadísticas globales	NDVI_min, NDVI_max, NDVI_medio, NDVI_mediana, NDVI_desv	Descriptores estadísticos de la distribución del NDVI en toda la muestra.
Cobertura Total	Cobertura_vegetal_pct	Porcentaje del área total cubierta por tejido vegetal excluyendo el fondo
Métricas por clase	[Clase]_pixeles	Conteo de los pixeles perteneciente a la clase.
	[Clase]_area_pct	Área relativa que ocupa la clase respecto al total de la imagen
	[Clase]_ndvi_medio	Valor promedio del índice NDVI exclusivo para la clase

Debido a que la base de datos generada presenta variables altamente correlacionadas además de alta dimensionalidad, se aplicó un algoritmo de análisis de componentes principales para reducir la redundancia en los datos sin perder información relevante. Para realizarlo, los datos fueron estandarizados utilizando StandarScaler proveniente de la librería de Python Sklearn, centrando la media en cero y escalando a una varianza unitaria debido a que las características presentaban magnitudes diversas. Una vez las características fueron escaladas, se aplicó PCA y se generó una curva de varianza acumulativa en relación con el número de componentes. Este análisis permitió identificar el número optimo de componentes principales necesarios para conservar al menos el 95% de la información del conjunto de datos original.

Para clasificar el estado de las muestras de los cultivos se implementó un algoritmo de aprendizaje automático no supervisado (K-Means) aplicado sobre el espacio de características reducido. El algoritmo fue configurado para dividir las muestras en K = 2 para separar las muestras en dos clústeres que representan dos estados fisiológicos diferentes.

Resultados y Discusión

Como resultado del proceso de adquisición, se obtuvo un conjunto de imágenes por cada tipo de cultivo. Tras la inspección, filtrado y preprocesamiento, quedó distribuido de la siguiente manera (ejemplos ilustrados en la Tabla 1):

- Maíz blanco adulto: 21 muestras. **Único cultivo capturado con un plano frontal debido a su altura.*
- Maíz blanco joven: 77 muestras.
- Apio variedad Tango: 92 muestras.
- Cacahuate Criollo: 58 muestras
- Cilantro: 66 muestras.

Tras procesar las muestras que conforman las bases de datos por cultivo y calcular sus respectivos índices vegetativos y estadísticas, el sistema genera de forma automatizada un panel de diagnóstico visual por cada muestra analizada (Tabla 3). Como se puede observar, se integra la imagen RGB del cultivo como referencia; el mapa de NDVI continuo, en la parte superior derecha, que mapea la actividad fotosintética con una escala estandarizada; en la sección inferior izquierda, el mapa NDVI segmentado por clase clasifica el vigor de la planta en seis niveles desde no vegetación hasta vegetación vigorosa; finalmente en la esquina inferior derecha se encuentra el histograma de frecuencias del NDVI donde la línea punteada marca un umbral de separación con respecto al suelo y la vegetación.

Tabla 2. *Ejemplos de imágenes multiespectrales tomadas en campo para cada tipo de cultivo.*

Cultivo	GREEN	NIR	RED	REG	RGB
Apio Tango					
Cacahuate Criollo	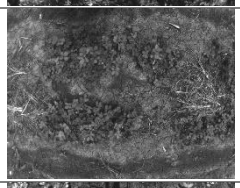	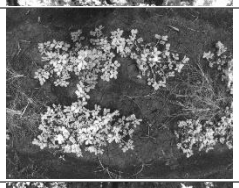	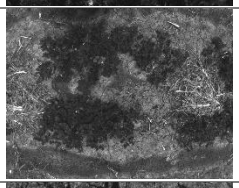		
Cilantro	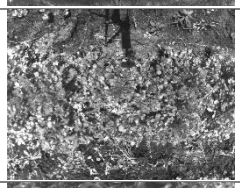				
Maíz blanco joven					
Maíz blanco adulto					

Tras procesar las muestras que conforman las bases de datos por cultivo y calcular sus respectivos índices vegetativos y estadísticas, el sistema genera de forma automatizada un panel de diagnóstico visual por cada muestra analizada (Tabla 3). Como se puede observar, se integra la imagen RGB del cultivo como referencia; el mapa de NDVI continuo, en la parte superior derecha, que mapea la actividad fotosintética con una escala estandarizada; en la sección inferior izquierda, el mapa NDVI segmentado por clase clasifica el vigor de la planta en seis niveles desde no vegetación hasta vegetación vigorosa; finalmente en la esquina inferior derecha se encuentra el histograma de frecuencias del NDVI donde la línea punteada marca un umbral de separación con respecto al suelo y la vegetación.

Tabla 3. *Paneles de diagnóstico visual del NDVI para los cultivos evaluados: apio, cacahuate, cilantro, maíz blanco joven y adulto.*

Apio Tango	**Cacahuate Criollo**
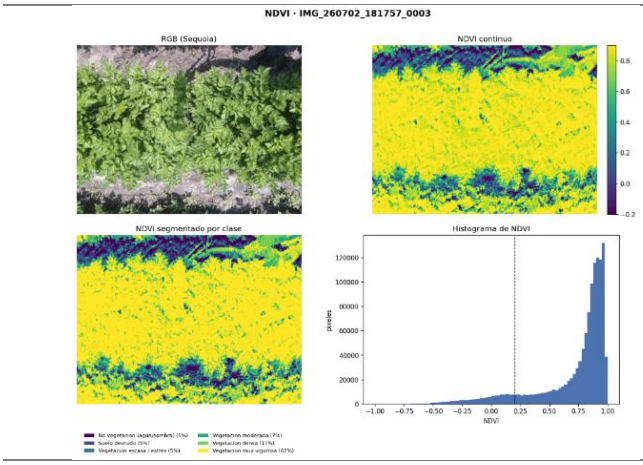	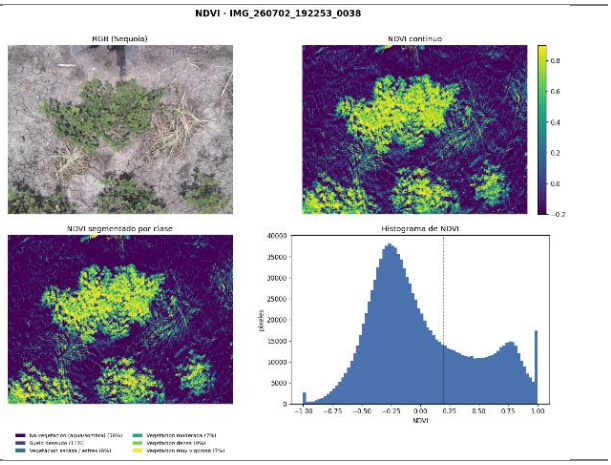
Cilantro	Maíz blanco joven
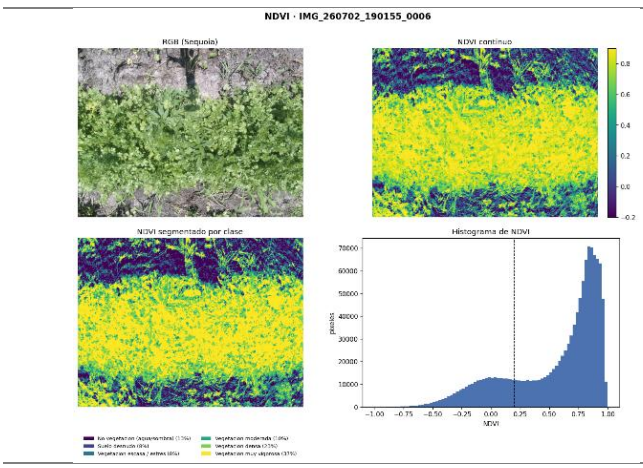	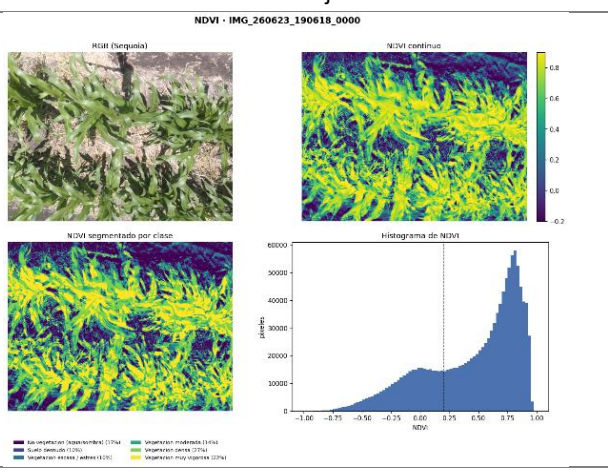
Maíz blanco Adulto	
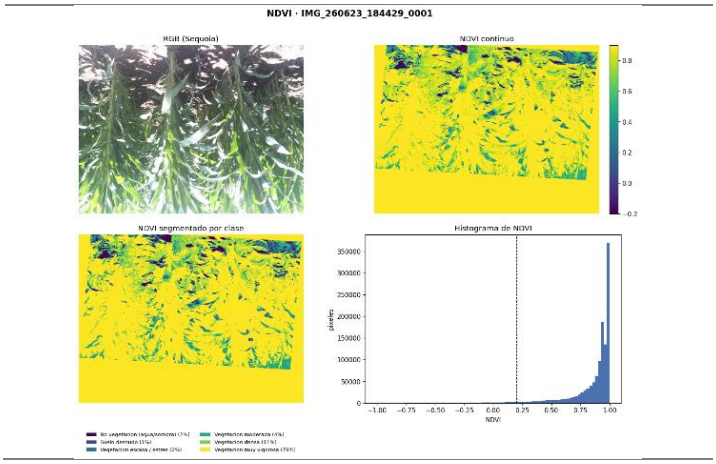	

A partir de las estadísticas del NDVI para cada muestra de cultivo analizada, fue aplicado PCA para la reducción de dimensionalidad. La curva de varianza acumulativa en relación con el número de componentes (Figura 3) demostró que es posible reducir el espacio de 24 características a 5 componentes principales, conservando el 95% de la información del conjunto original e incluso elevar el porcentaje a casi un 100% si se utilizan 10 componentes, tal como se visualiza en la figura 3.

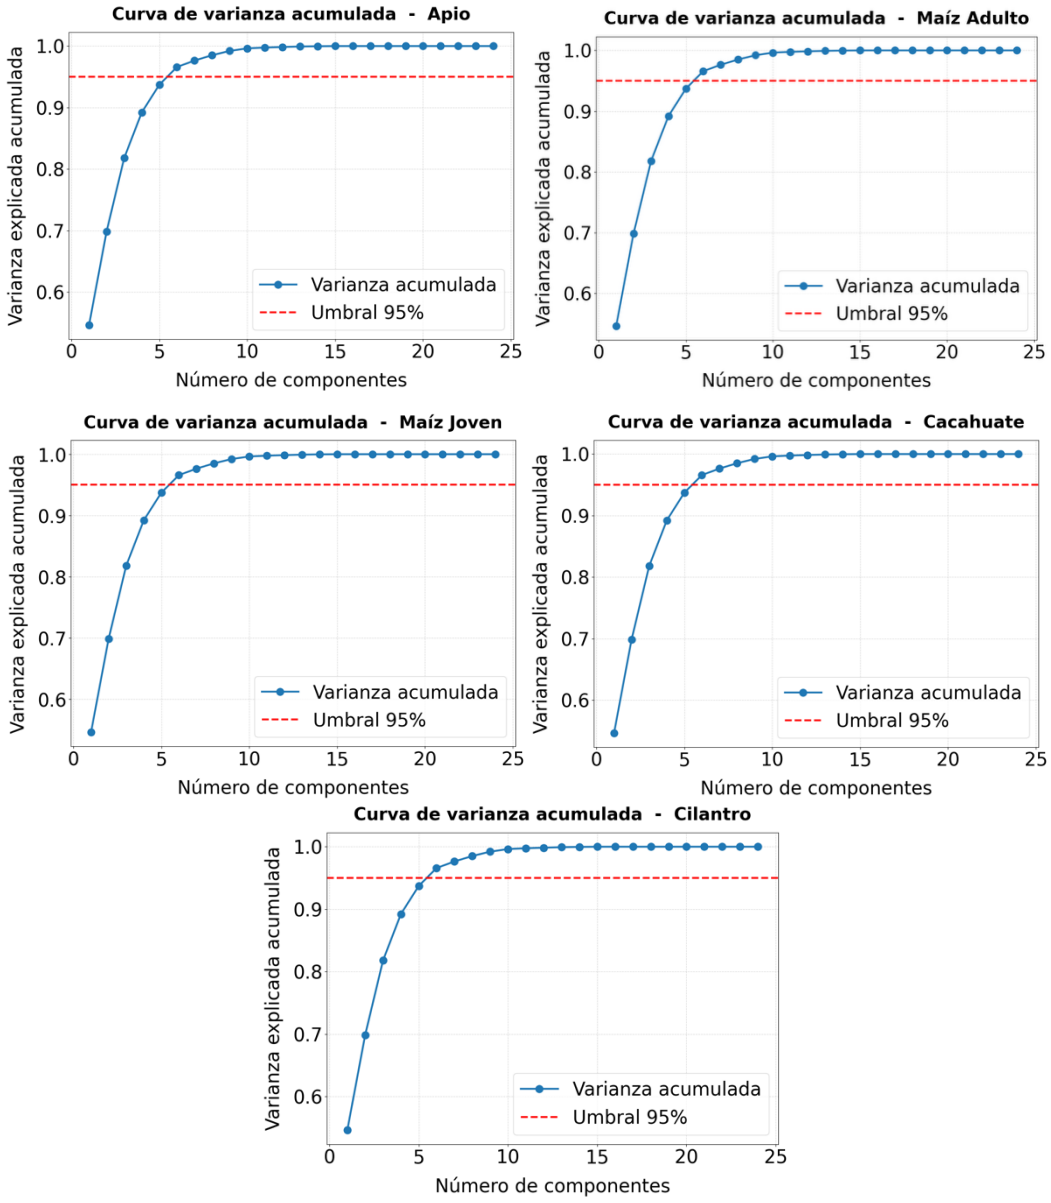

Figura 3. Varianza acumulada respecto al número de componentes a partir de las bases de datos de estadísticas NDVI de cada cultivo.

La aplicación de K-Means al conjunto de datos reducido permitió clasificar las muestras de cultivo en dos grupos diferenciados, tal como se observa en la Figura 4. El gráfico de dispersión relaciona el NDVI medio (eje horizontal) con el porcentaje de vegetación muy vigorosa (eje vertical), con una relación positiva entre las variables. En los gráficos resultantes para cada cultivo se observa el agrupamiento por clases, donde un clúster corresponde a un estado fisiológico optimo y alta densidad de biomasa, mientras que el otro mantiene un menor desarrollo o indicios de estrés.

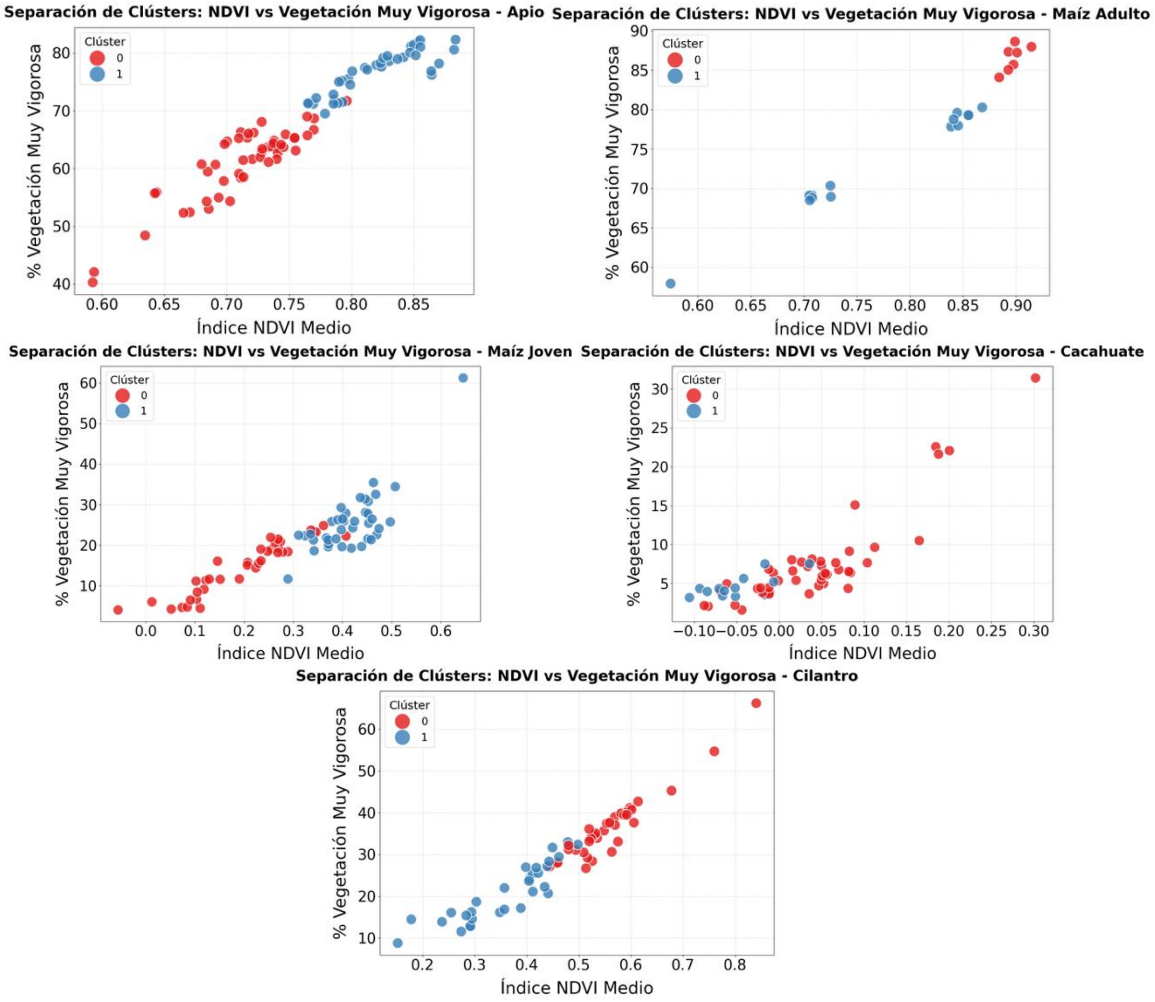

Figura 4. Resultados de aplicación de K-Means a base de datos reducida por cultivo.

Conclusión

En este trabajo se presentó el desarrollo de un flujo de procesamiento automatizado en Python para el análisis de imágenes multiespectrales como parte de la agricultura de precisión. La construcción de una base de datos de cultivos como apio, cacahuate, cilantro y maíz fue posible al utilizar la cámara Parrot Sequoia, obteniendo muestras conformadas por cuatro bandas espectrales (Verde, Rojo, Rojo extremo e Infrarrojo Cercano) y una imagen RGB. El conjunto de imágenes inicial obtenido fue filtrado para establecer una base de datos por cultivo, conservando las muestras de mayor calidad.

A través del algoritmo fue posible sistematizar el preprocesamiento: la calibración radiométrica, la corrección del viñeteo, la normalización por irradiancia solar y la alineación espacial de las bandas, etapas indispensables para un cálculo confiable del NDVI. La información adquirida generó paneles visuales en falso color útiles para mapear de forma continua y segmentada el estado de los cultivos con los que puede evaluar el vigor de la vegetación de manera no invasiva. A partir del cálculo del NDVI de las muestras, se extrajeron los principales descriptores estadísticos, el porcentaje de cobertura vegetal y las métricas correspondientes a cada una de las clases de vigor vegetal para la formación de una base de datos exclusiva de 24 columnas.

La reducción de dimensionalidad utilizando PCA mostró que es posible representar el 95% de la información utilizando únicamente 5 componentes principales debido a la redundancia de los datos. Sobre el espacio reducido la aplicación de K-Means permitió la clasificación de las muestras de manera no supervisada en dos

grupos que representaron dos estados fisiológicos distintos diferenciados porque uno tiene mayor vigor y densidad de biomasa mientras el otro es de menor desarrollo o con indicios de estrés.

Los resultados demuestran que la integración entre sensores ópticos VIS/NIR como cámaras multiespectrales en conjunto con técnicas de aprendizaje automático son una alternativa no destructiva para el monitoreo del estado fisiológico de los cultivos. Sin embargo, es necesario enfrentar diversos retos para continuar su desarrollo e implementación en campo. Se plantea ampliar la base de datos con un mayor número de muestras y cultivos, explorar otras técnicas de aprendizaje no supervisado, así como modelos de aprendizaje profundo que permitan distinguir entre distintos estados de la vegetación. De esta manera, el trabajo sienta las bases hacia el desarrollo de herramientas tecnológicas para contribuir a la agricultura de precisión.

Agradecimientos

Una parte de ese trabajo fue apoyado por la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI) bajo el proyecto CBF-2025-G-1076 (PALADIN) y por la Universidad de Guanajuato bajo el proyecto CIIC-170/2026 (ECLIPSE) y el programa institucional Verano de la Ciencia UG.

Bibliografía

Ball, D. W. (2006). *Field Guide to Spectroscopy*, SPIE Press, Bellingham, WA.

Bauer, S. D., Korč, F., & Förstner, W. (2011). The potential of automatic methods of classification to identify leaf diseases from multispectral images. *Precision Agriculture*, 12, 361–377.

Carlotto, M. J. (1985). Techniques for multispectral image classification. SPIE Vol. 528 Digital Image Processing, 174-182.

De Estadística, Y, I. N. (s.f.). Índice de Vegetación de Diferencia Normalizada (NDVI).

González, A., Amarillo, G., Amarillo, M., & Sarmiento, F. (2016). Drones aplicados a la agricultura de precisión. *Publicaciones e Investigación*, 10, 23-37.

Grupo Acre. (2020). Ficha técnica Parrot Sequoia [Ficha técnica].

Juan. (2025). Sequoia: Cámara con sensor multibanda para agricultura. ACG DRONE.

Kogut, P. (2026). Hiperespectral y multiespectral: diferencias y usos. EOS Data Analytics.

Moreno Miranda, D. P., & Shulika, O. V. (2026). Optical sensing system based on visible reflectance spectroscopy for classification of strawberry leaves. Proc. SPIE 14086, Optical Sensing and Detection IX, 1408618. doi: 10.1117/12.3100205.

Normalized Difference Vegetation Index (NDVI) | NASA EarthData. (2026). NASA Earthdata.

Rambauth-Ibarra, G. (2021). Agricultura de precisión: La integración de las TIC en la producción agrícola. *J. Comput. Electron. Sci.: Theory Appl.,* 3(1), 34-38.

Rayhana, R., Ma, Z., Liu, Z., Xiao, G., Ruan, Y., & Sangha, J. S. (2023). A review on plant disease detection using hyperspectral imaging. IEEE Transactions on AgriFood Electronics.