

DESARROLLO DE UNA HERRAMIENTA PARA LA DETECCIÓN DE MALEZA EN CAMPOS DE GIRASOLES

Jesús C. Carmona-Frausto¹, Salvador Cervantes-Álvarez², Kevin E. Bee-Cruz¹, Adriana Mexicano-Santoyo^{1*} & Néstor M. Montoya-Pineda³

¹Tecnológico Nacional de México, Instituto Tecnológico de Ciudad Victoria, Blvd. Emilio Portes Gil, No. 1301, C.P. 87010. Cd. Victoria, Tamaulipas, México.

jesus.cf@cdvictoria.tecnm.mx, m23380019@cdvictoria.tecnm.mx,
adriana.ms@cdvictoria.tecnm.mx

²Centro Universitario de los Valles, Universidad de Guadalajara.

salvador.cervantes7964@academicos.udg.mx

³Universidad Autónoma de Tamaulipas, Centro Nacional de Innovación y Transferencia de Tecnología en Agricultura de Precisión. nmontoya@uat.edu.mx

RESUMEN. Este trabajo presenta una herramienta enfocada en la detección de maleza en un campo de girasoles por medio de técnicas de visión artificial, en el artículo se presenta la estructura general de la herramienta que, a partir de un conjunto inicial de imágenes multispectrales, calcula varios índices de vegetación, posteriormente aplica sobre los datos técnicas de análisis de datos y modelos de clasificación previamente entrenados. La herramienta desarrollada logra la identificación de las clases Fondo, Maleza y Girasol con una Precisión del 81%, Recuerdo del 81%, Exactitud del 81.5%, F1 del 81% y Cohen Kappa del 72% por parte del modelo entrenado que utiliza las técnicas de Análisis de Componentes Principales, Máquinas de Vectores de Soporte y el kernel gaussiano.

PALABRAS CLAVE: Visión Artificial, Aprendizaje Máquina, Agricultura de Precisión.

ABSTRAC. This work presents a tool focused on the detection of weeds in a sunflower field through artificial vision techniques. The article presents the general structure of the tool that, based on an initial set of multispectral images, calculates several indices of vegetation, subsequently applies data analysis techniques, and previously trained classification models to the data. The developed tool achieves the identification of the classes Background, Weed and Sunflower with a Precision of 81%, Recall of 81%, Accuracy of 81.5%, F1 of 81%, and Cohen Kappa of 72% by the trained model that uses the techniques of Principal Component Analysis, Support Vector Machines and the Gaussian kernel.

KEYWORDS: Artificial Vision, Machine Learning, Precision Agriculture.

1. INTRODUCCIÓN

En el pasado, debido a las pérdidas de cultivos en etapas tempranas, el ser humano llegó a la necesidad de implementar técnicas para controlar la maleza, enfermedades y parásitos. Algunas de estas técnicas fueron la rotación de cultivos (Espinoza *et al.*, 2007), labranza de cultivos, control biológico (Badii y Abreu, 2006), fuego controlado (Maquieyra *et al.*, 1985). No obstante, hoy en día se ha optado por innovar las técnicas para los cuidados de las cosechas con el propósito de ahorrar tiempo, esfuerzo y mejorar el desempeño de producción de los campos. Por lo cual, se ha implementado la Agricultura de Precisión (AP) (Ahmad *et al.*, 2024). La AP consiste en la incorporación de estrategias, definiciones, técnicas, herramientas tecnológicas actuales y avanzadas para sustituir las prácticas

tradicionales de la agricultura. La AP detecta, analiza y administra las variaciones dentro de los cultivos para conseguir un rendimiento, sustentabilidad y seguridad adecuada de los recursos del suelo. Las técnicas que comprenden la AP son Sistemas de Información Geográfica (SIG), Sistemas de Posicionamiento Global (GPS), tecnología de tasa variable (TRV), monitoreo de rendimiento y Percepción Remota (PR), siendo este último una parte fundamental en este trabajo. La PR se basa en la recopilación de datos de zonas o elementos sin la necesidad de tener una distancia de observación cercana a ellos. Esta particularidad ha permitido evaluar las cualidades del suelo a través del espectro electromagnético. En regiones como el visible, el infrarrojo y la región del microondas. Dicha cualidad, ha logrado la base para la

construcción de herramientas para la detección de estrés, plagas y enfermedades en los cultivos por medio de la Visión Artificial (VA).

La VA es una disciplina conformada por un grupo de técnicas que facilitan la obtención, procesamiento, y la evaluación de imágenes (Dominguez, 2021). La aspiración de la VA es que, una computadora pueda recopilar y manipular los datos para resolver preguntas acerca de su contenido. Esta capacidad ha sido esencial en trabajos como la segmentación de hojas y frutos de plantas de tomate por medio de la dominancia del color (Guerra *et al.*, 2023), la detección de plagas de maíz y soja por medio del uso de detección de objetos en tiempo real con el modelo YOLO y la biblioteca Detectron2 (Silva *et al.*, 2024).

Por lo anterior, la VA ofrece una alternativa para la detección de la maleza en campos de girasoles. La maleza al ser un problema habitual en los cultivos suele afectar de manera paulatina el crecimiento de las cosechas limitando la obtención de nutrientes para que alcancen la etapa óptima de producción muriendo durante el proceso (Gómez, 1995). Debido a ello se han realizado trabajos con el objetivo de identificar las zonas donde se encuentra la maleza, ejemplo de ello son la evaluación de la densidad de malezas a campo abierto utilizando imágenes de un Vehículo Aéreo No Tripulado (VANT) con una red neuronal U-NET (Zou *et al.*, 2021), la estimación de la densidad y dispersión de maleza por medio del aprendizaje semi-supervisado (Shorewala *et al.*, 2021), la identificación de malezas en un campo de caña por medio de imágenes obtenidas con un VANT (Yano *et al.*, 2016), la detección de maleza en cultivos de papa con apoyo de algoritmos del Aprendizaje Profundo (Khan *et al.*, 2022), la detección de malezas usando la característica de su estructura utilizando Máquinas de Vectores de Soporte (SVM) y Redes Neuronales (Bakhsipour *et al.*, 2018).

En este trabajo se presenta el desarrollo de una herramienta para detectar la maleza en campos de girasoles. Esta herramienta está basada en el uso del aprendizaje supervisado. Esta herramienta analiza los píxeles que posee cada imagen con la finalidad de localizar la zona en específico donde se encuentren las clases de interés fondo, maleza y girasol. Entendiendo por maleza cualquier tipo de planta no deseada que crece en un lugar donde

no se desea. Para el análisis de las clases, se utilizaron principalmente los Índices de Vegetación (IV) basados en la reflectancia que emitió cada una de las clases, los conjuntos de datos fueron generados mediante el uso de análisis como: el Análisis de Correlación (AC), Análisis de Componentes Principales (ACP), Auto Encoder (AE), Análisis de Correlación con Análisis de Componentes Principales (AC-ACP) y Análisis de Correlación con Auto Encoder (AC-AE). Los clasificadores SVM, k-Vecino más cercano (kNN) y Bayes Ingenuo (NB), fueron usados para clasificar los píxeles de las imágenes dentro de las clases fondo, maleza y girasol.

2. CONSTRUCCIÓN DE LA HERRAMIENTA

La herramienta consta de 2 etapas. La etapa de entrenamiento que consiste en construir el modelo de entrenamiento del algoritmo y la etapa de pruebas que consiste en la utilización de los modelos entrenados mediante una interfaz gráfica. La Figura 1 representa el diagrama general del desarrollo de la herramienta.

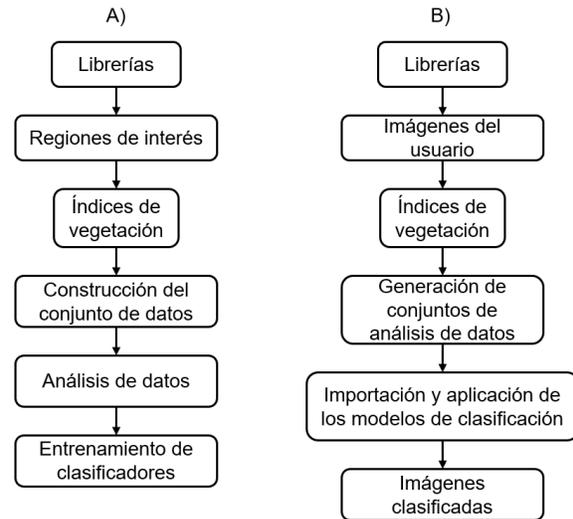


Figura 1. Etapas de construcción de la herramienta: A) Etapa de entrenamiento; B) Etapa de pruebas.

A) Etapa de entrenamiento:

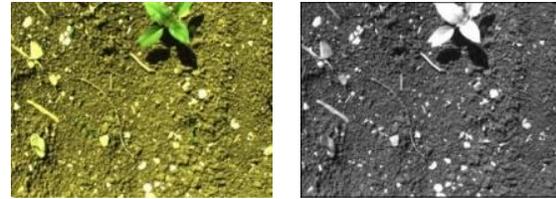
Durante esta etapa se instalaron las librerías OpenCV, Scikit-learn, Pandas, Keras, Tensorflow, Seaborn, Matplotlib, Numpy, Joblib, Pickle, Time y Random. Cada una de ellas forma la base de la construcción de modelo entrenado. Posteriormente, se construyeron y

se cargaron las regiones de interés (ROI) desarrolladas en software ENVI, las cuales están basadas en imágenes multiespectrales con los canales de colores Rojo, Verde, Azul (RGB) e Infrarrojo Cercano (NIR). Estas imágenes fueron extraídas del trabajo de Fawakherji *et al.* (2021).

Para el entrenamiento del modelo se utilizaron 25 imágenes. No obstante, al ser una cantidad pequeña, se aplicaron técnicas como el espejo, desplazamiento, rotación e incremento de brillo y contraste para tener una total de 125 imágenes divididas en ROI con lo que se logró aumentar la cantidad de imágenes. Se utilizó un 80% de las imágenes como entrenamiento y un 20% de prueba. Posteriormente, se obtuvieron los IV de las imágenes ingresadas para establecer las clases Fondo, Maleza, y Girasol que son los elementos de interés en este trabajo y se estableció la clase para cada grupo de datos generado a partir de los IV, con la finalidad de crear un sólo conjunto que almacene las 3 clases. Después, se le aplicó al nuevo conjunto de datos, cada uno de los algoritmos de AC, ACP, AE, AC-ACP y AC-AE para reducir y eliminar los datos redundantes utilizados en el proceso de clasificación, ya que sólo generan ruido y aumentan el tiempo de procesamiento. Finalmente, los 5 nuevos conjuntos de datos obtenidos a partir de los análisis anteriores son procesados por medio de los clasificadores SVM con los kernel polinomial, gaussiano y lineal; kNN con las variantes pesos uniformes y ponderados; NB con los modelos gaussiano, multinomial y Bernoulli.

B) Etapa de pruebas:

Esta etapa consistió en la implementación de las librerías; importación de las imágenes multiespectrales del campo (ver Figura 2); la aplicación de los IV; la generación de los conjuntos de análisis de datos configurados previamente en la fase de entrenamiento; la importación y aplicación de los modelos de clasificación desarrollados en la fase de entrenamiento y finalmente, la obtención de las imágenes clasificadas.



A) Imagen RGB B) Imagen NIR

Figura 2. Ejemplo de las imágenes que utiliza la herramienta. A) Imagen en canales RGB; B) Imagen en canal NIR.

3. METODOLOGÍA

Para implementar la herramienta se llevaron a cabo las fases que se muestran en la Figura 3. A) Cálculo de índices de vegetación: Consiste en representar el estado actual de las plantas a través de rangos de valores; B) Análisis de datos: consiste en el desarrollo de los conjuntos de datos que se utilizaron para la clasificación y C) Clasificación: aplicación de diferentes clasificadores sobre los datos generados en la fase B.

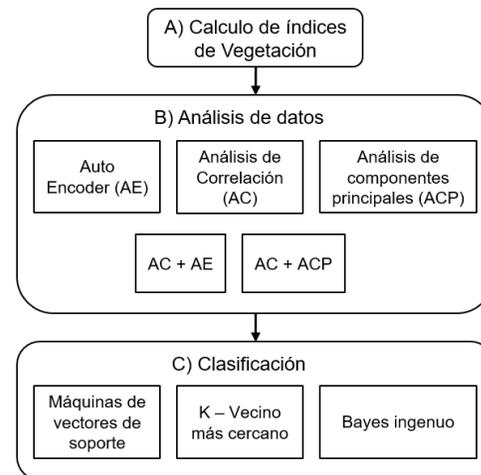


Figura 3. Fases de la metodología para implementar la parte funcional de la herramienta.

3.1. Cálculo de Índices de Vegetación

Los índices de vegetación tienen el propósito de mostrar a través de una escala de valores las regiones que pertenecen a una planta o elementos de interés en una imagen. Esto se debe a la reflectancia, es decir, si una planta está sana o enferma refleja una radiación diferente, lo cual, permitiría realizar trabajos como la detección de la salud en que se encuentre una vegetación. Para calcular un IV se requiere del uso de canales espectrales

específicos de la cámara, ejemplo de ello es el Índice de Razón Simple (SR) el cual está definido como el valor del canal *NIR* entre el *Green*.

El índice de SR utiliza los canales espectrales NIR y GREEN para estudiar la salud de la vegetación. Este índice al igual que los otros 20 que se utilizaron para el entrenamiento del modelo, tiene la finalidad de representar una característica de una clase (Lan *et al.*, 2020). Es decir, cada IV puede llegar a proporcionar valores diferentes, por lo cual, son fundamentales para el entrenamiento de los clasificadores, ya que, en base a ellos, se podrá identificar a qué clase pertenece cada píxel de las imágenes. La detección de las diferentes clases (Fondo, Maleza y Girasol) es posible por medio de la escala de valores de cada clase, lo que se traduce en diferentes valores para los índices de vegetación. Una vez aplicado cada IV sobre las imágenes, se genera un conjunto de datos que englobe todos los IV de las clases Fondo, Maleza y Girasol para que sean procesados por los algoritmos AC, ACP, AE, AC-ACP y AC-AE.

3.2. Análisis de datos

Utilizar los 20 IV puede ser redundante, ya que algunos pueden coincidir en los valores que poseen. Por lo cual, el análisis de datos ofrece una alternativa para reducir la cantidad de IV, que a su vez contribuye en reducir el tiempo de procesamiento de la herramienta. En este trabajo se aplicó el AC, ACP, AE, AC-ACP y AC-AE.

3.2.1. Análisis de Correlación (AC)

El AC permite estudiar cada una de las variables por medio del coeficiente producto – momento de Pearson. La particularidad de AC se basa en denotar cuáles variables tienen un alto índice de correlación entre el rango de 0 a 1 ya que se utilizó una transformación lineal para establecer ese rango de similitud entre las variables. Posteriormente, se eliminan aquellas variables que tienen una alta correlación debido a que representan información redundante que puede elevar el tiempo de procesamiento y ocasionar ruido al aplicar las técnicas de clasificación. En la fase de entrenamiento se estableció un rango de eliminación de correlación de 0.96 a 1 ya que fue el que mejores resultados presentó en comparación con los rangos de 0.94 a 1 y 0.98 a 1. El rango establecido eliminó los siguientes índices: el

Índice de Pigmentos Intensivos de Estructura (SIPI), Índice de Vegetación por Diferencia (DVI), Índice Optimizado de Vegetación Ajustado al Suelo (OSAVI), Índice de Vegetación por Relación (RVI), Índice de Razón Simple SR, Índice de Diferencia Normalizada de Verde (NDGI), Índice de Porcentaje de Vegetación en Infrarrojo (IPVI), Índice de Vegetación Triangular Modificada 1 (MTVI1), Índice de Vegetación Triangular Modificada 2 (MTVI2), Índice de Diferencia Vegetal Renormalizado (RDVI), Índice de Diferencia Normalizada Verde-Rojo (GRNDVI), Banda Normalizada del Infrarrojo Cercano (NormNIR).

3.2.2. Análisis de Componentes Principales (ACP)

El ACP estudia todas las variables generadas por los IV al igual que AC. No obstante, su diferencia se basa en que ACP selecciona aquellas variables que tienen una mayor varianza o que aportan más información al conjunto de datos y pueden representarlo sin la necesidad de usar todas las variables del conjunto de datos inicial. En este trabajo se seleccionaron los 3 componentes principales que presentaron la mayor varianza [0.8031, 0.1629, 0.0168] dando un total de 0.9829 de varianza. Los experimentos mostraron que los 3 componentes principales elegidos obtuvieron mejores resultados que al utilizar 5 y 10 componentes principales.

3.2.3. Auto Encoder (AE)

AE es una red neuronal que busca reducir la cantidad de variables o dimensiones, para reducir el tiempo de ejecución y proporcionar la información indispensable para clasificar correctamente los datos. El proceso de AE se compone de un Codificador y un Decodificador, el Codificador busca reducir la cantidad de variables que entran en la “capa de entrada” por medio de “capas ocultas” hasta llegar a una capa llamada “capa de código latente”. Posteriormente, el Decodificador, a partir de la capa de código latente, reconstruye nuevamente las variables totales que entraron en la capa de entrada por medio de capas ocultas y una capa de salida. Durante cada época o iteración en que se ejecuta la red neuronal, hay una pérdida de datos que determina el margen de error con el que se generó nuevamente la capa de entrada en la capa de salida. La pérdida óptima siempre será la más cercana al 0. En este trabajo, durante

las 20 épocas que se reconstruyó la red neuronal se obtuvieron pérdidas de [0.0611, 0.0118, 0.0107, 0.0043] hasta llegar a un error de $8.2753e-04$ en la última época.

3.2.4. AC-ACP

Consiste en una combinación entre el Análisis de Correlaciones y el Análisis de Componentes Principales. La finalidad es reducir aún más la cantidad de variables que se utilizan para que el tiempo de procesamiento en los clasificadores sea menor. En este caso, se tomó el conjunto de datos con los 8 IV resultantes después de aplicar AC y se le aplicó ACP seleccionando los 3 componentes principales con la mayor varianza [0.7018 0.2555 0.0197] dando un 0.9771 de varianza total.

3.2.5. AC-AE

Es una combinación entre el conjunto de datos generado por AC y AE. En esta combinación, se utiliza el conjunto de datos generado por AC y se aplica la red neuronal para reducir las variables restantes a sólo 3 neuronas dando una pérdida de datos de [0.3768, 0.0430, 0.0230, 0.0229] durante cada época hasta llegar a la época 20 con una pérdida de 0.0228.

3.3. Clasificación

3.3.1. Máquinas de vectores de soporte

Se aplicó SVM a los conjuntos de datos obtenidos anteriormente por medio de los análisis (Gupta y Sehgal, 2021). SVM tiene la facilidad de utilizar funciones (Kernel) para establecer un límite y dividir los datos por medio de la asignación de clases. El objetivo de SVM consiste en ubicar un hiperplano que divida de manera equitativa las características en distintas regiones. Las funciones (Kernel) utilizadas durante esta herramienta fueron gaussiana, lineal y polinomial.

3.3.2. k-Vecino más cercano (kNN)

La meta principal de kNN es clasificar la información en distintas clases para predecir la clase de un nuevo punto de datos. El algoritmo de kNN estima la probabilidad de que un punto de información pertenezca a un grupo estudiando los puntos de datos que se encuentran cerca de un punto en específico. En este trabajo se utilizó kNN para la clasificación utilizando los modelos pesos uniformes y ponderados de la librería Scikit-learn.

3.3.3. Bayes ingenuo

NB se reconoce como ingenuo ya que asume que cada característica aporta de manera individual a la identificación de una clase sin la necesidad de depender de otras y Bayes porque utiliza el teorema de Bayes (Webb, 2016). En este trabajo NB se utilizó para identificar las clases del Fondo, Maleza y Girasol. Las variantes del modelo que se utilizaron fueron gaussiano, multinomial, Bernoulli.

4. IMPLEMENTACIÓN DE LA HERRAMIENTA

El objetivo principal de la herramienta es generar las clases Fondo, Maleza y Girasol, a partir de las imágenes ingresadas. Para usar la herramienta se deben ingresar las imágenes multiespectrales. Las imágenes deben contener los canales combinados RGB y la imagen en escala de grises del canal NIR como se muestra en la Figura 4.



Figura 4. Selección de imágenes multiespectrales.

Posteriormente, la herramienta obtendrá los 20 IV del conjunto de imágenes ingresadas utilizando los canales separados de la imagen RGB y el canal NIR. Después, se aplica directamente el AC, se importan las configuraciones de los conjuntos de análisis de datos como ACP, AE, AC-ACP y AC-AE que se crearon durante la fase de entrenamiento del modelo. Una vez cargados los datos, se aplican sobre el conjunto de datos obtenido a partir de las imágenes ingresadas por el usuario. Se incorporan los modelos de clasificación SVM, kNN, NB que se desarrollaron durante la fase de entrenamiento. Finalmente, se aplican los modelos de clasificación y se generan las imágenes clasificadas para ser presentadas en la herramienta.

5. PRUEBA DE DESEMPEÑO

Una vez importadas las imágenes, la herramienta proporciona 3 diferentes opciones de visualización de resultados: “Índices de vegetación”, “Análisis de datos” e “Imágenes clasificadas”, como se muestra en la Figura 5. En el menú “Índices de vegetación” es posible observar las imágenes que se generan al aplicarle los 20 IV divididos en secciones. Estos IV permiten conocer cómo se interpretan ciertas áreas a través de una paleta de colores adaptada a los índices como se presenta en la Figura 6. Los colores que presenta la Figura 6 muestran que elementos como el girasol y la maleza están en una gama de amarillos a diferencia del fondo que en su mayoría es azulado.

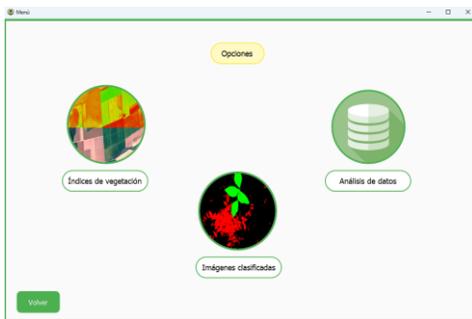


Figura 5. Menú de opciones.



Figura 6. Índices de vegetación.

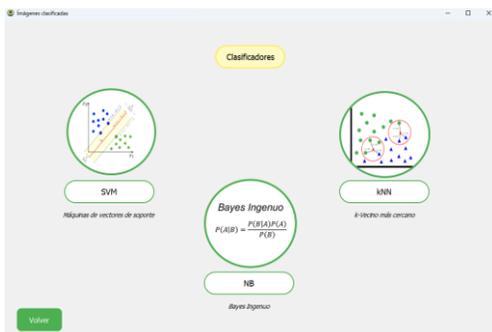


Figura 7. Selección de clasificadores.

La herramienta también cuenta con la ventana “Análisis de datos” donde se presentan las gráficas generadas al aplicar los análisis AC, ACP, AE, AC-ACP y AC-AE. Por último, se encuentra la opción de “Imágenes clasificadas”. Esta opción ofrece los resultados de los 3 clasificadores que se encuentran en la herramienta, es decir, SVM, kNN y NB como se muestra en la Figura 7. Cada uno de los algoritmos proporciona una clasificación basada en sus propias operaciones. Analizar cada una de las perspectivas ofrece la alternativa de saber que, si 2 o 3 opiniones coinciden en la clasificación un área en específico, ahí se encuentra la anomalía de este estudio, es decir, la Maleza.

6. RESULTADOS

Para la obtención de los resultados, se utilizaron imágenes en formato RGB y NIR. Estas imágenes contenían los elementos de interés, es decir, Fondo, Maleza y Girasol. Una vez clasificadas, la herramienta permitió visualizar los resultados a través de los 40 conjuntos de imágenes construidos a partir de que SVM se probó con 3 variantes y utilizó los 5 conjuntos de análisis, así mismo con las variantes de kNN y NB.

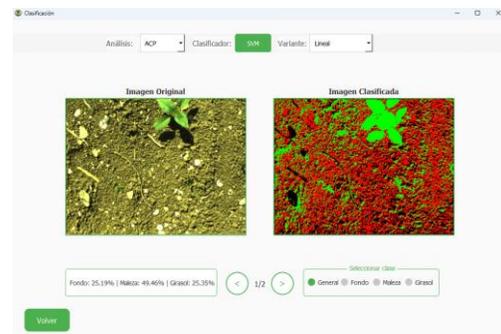


Figura 8. ACP SVM lineal.

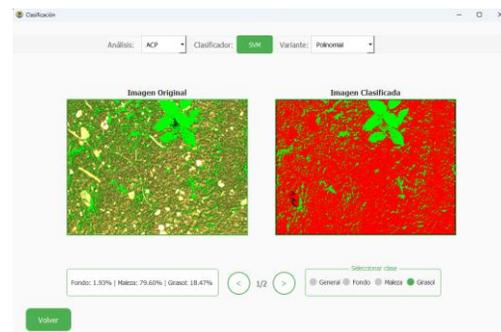


Figura 9. ACP SVM polinomial.

La Figura 8 muestra el resultado brindado al aplicar ACP con el clasificador SVM y su variante lineal. Esta imagen permite obtener una comparación entre la imagen original y la imagen clasificada donde se muestra un porcentaje del 25.19% Fondo, 49.46% Maleza y 25.35% Girasol. Estos porcentajes señalan la cantidad de píxeles que le pertenecen a cada una de las clases en cada imagen. Además, la herramienta permite pintar los píxeles que representan a cada clase en la imagen original como se muestra en la Figura 9, donde se aplicó ACP y SVM con la variante polinomial y se pintaron los píxeles que representan al Girasol en la "Imagen Original". La Figura 10 presenta el resultado obtenido por ACP kNN con pesos ponderados donde obtuvo un porcentaje de 27.47% Fondo, 56.80% de Maleza y 15.74% de Girasol en ella se ven pintados los píxeles de la clase Fondo en la "Imagen Original". En estos resultados, se presenta que la clase Maleza posee la mayor parte de la imagen. Es posible decir que esta clasificación es incorrecta, sin embargo, observar que también tomó en cuenta el Fondo y el Girasol permite saber si se están tomando en cuenta durante la clasificación.

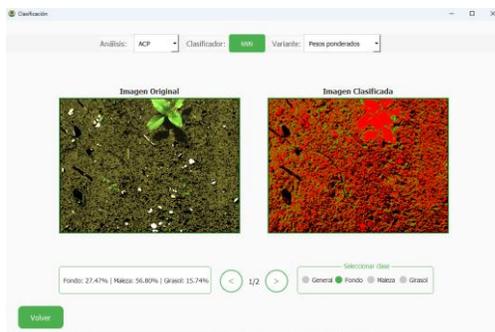


Figura 10. ACP kNN Pesos ponderados.

Por último, en la Figura 11, se presenta la clasificación obtenida al aplicar AC y NB Bernoulli. En esta imagen es posible observar cómo la mayor parte de la imagen pertenece a la clase Fondo con un 93.88%, Maleza con un 5.17% y Girasol con un 0.94% siendo una clasificación "buena" ya que, el porcentaje identificado fondo es prácticamente coincidente con el porcentaje real de dicha clase. Sin embargo, también tomó parte del Girasol como maleza presentando un bajo porcentaje de error en la clasificación. Esto se debe principalmente a que el entrenamiento del modelo se realizó con un pequeño grupo de imágenes con técnicas de aumento de datos

perdiendo variabilidad. Sin embargo, estos porcentajes de clasificación son de utilidad para lograr la detección de maleza mediante imágenes multispectrales en un ambiente práctico.

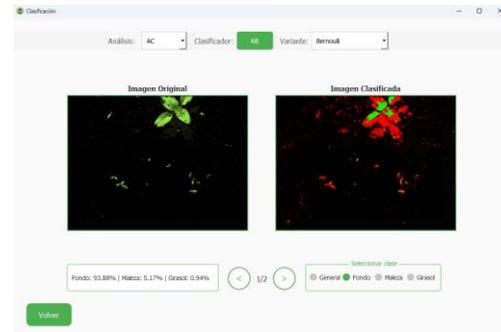


Figura 11. AC NB Bernoulli.

7. DISCUSIÓN

A lo largo de la historia, el ser humano ha desarrollado diversas estrategias para erradicar la maleza en sus cultivos, adaptándose a las condiciones del entorno y a los avances tecnológicos. Entre las primeras técnicas utilizadas destacan la labranza y el control biológico (Badii y Abreu, 2006), las cuales sentaron las bases para la identificación y gestión de malezas mediante análisis visual. Sin embargo, estos métodos presentaban limitaciones en cuanto a eficiencia y precisión. En la actualidad, la Visión Artificial (VA) ha emergido como una alternativa para mejorar la detección y clasificación de malezas en los cultivos. Ejemplos de su aplicación incluyen la segmentación de hojas y frutos (Guerra *et al.*, 2023), el estudio de la densidad de malezas en un campo (Zou *et al.*, 2021) y la detección de malezas en cultivos agrícolas (Yano *et al.*, 2016; Khan *et al.*, 2022). En este contexto, el presente trabajo proporciona una herramienta basada en Aprendizaje Supervisado para la detección de clases específicas: fondo, maleza y girasol. A diferencia de los estudios previos mencionados, este enfoque se basa en el entrenamiento de un modelo con un conjunto de datos etiquetados, lo que permite una clasificación más precisa y la obtención de datos visuales estructurados.

8. CONCLUSIONES

El desarrollo de una herramienta para la detección de maleza en los campos de girasoles a través de las técnicas que utilicen la

visión artificial no es una tarea sencilla ya que para llegar a resultados visibles, se tuvo que construir principalmente una fase de entrenamiento de la herramienta que abordara cada uno de los conjuntos de datos generados a partir de análisis como: AC, ACP, AE, AC-ACP, AC-AE y diferentes modelos de clasificación cada uno con sus variantes: SVM con los kernel polinomial, gaussiano, lineal; kNN con los modelos pesos uniformes, pesos ponderados; NB con las variantes gaussiano, multinomial, Bernoulli. Para la experimentación, se utilizaron imágenes tomadas por una cámara multispectral con los canales RGB y NIR, los cuales fueron fundamentales para el desarrollo de la herramienta ya que estos canales eran la base de la aplicación de los IV que consiste en la construcción del conjunto de datos principal.

Finalmente, se obtuvieron resultados visuales donde se pueden observar las 3 clases utilizadas en este trabajo como puntos de interés. Esto permite ofrecer una alternativa mediante el uso de visión artificial con base en el aprendizaje supervisado aplicado a la segmentación de píxeles proporcionando una base para la continuación de trabajos en el futuro que requieran detectar diferentes zonas de interés en otro tipo de cultivos e incluso la detección de alguna enfermedad que se encuentre en ellos con base en la reflectancia que proporcione la vegetación a través de los IV. Pero sobre todo se proporciona una herramienta útil y asequible para los agricultores enfocados en la fabricación de aceites, cremas y alimentos derivados del girasol de manera que resguarde el control de calidad contra la anomalía que representa la maleza para los campos de producción.

9. LITERATURA CITADA

- Ahmad, L., G. Shoaib y A. Biswas. 2024. Fundamentals and Applications of Crop and Climate Science. *Precision Agriculture*, 1: 151-161. doi: https://doi.org/10.1007/978-3-031-61459-0_7
- Badii, M. y J. Abreu. 2006. Control biológico una forma sustentable de control de plagas (Biological control a sustainable way of pest control). *Daena: International Journal of Good Conscience*, 1(1): 82-89.
- Domínguez, T. 2021. Visión artificial: Aplicaciones prácticas con OpenCV - Python. Marcombo, España, 338 pp.
- Espinoza, Y., Z. Lozano y L. Velásquez. 2007. Efecto de la rotación de cultivos y prácticas de labranza sobre las fracciones de la materia orgánica del suelo. *Interciencia*, 32(8): 554-559.
- Fawakherji, M., C. Potena, A. Pretto, D. Bloisi y D. Nardi. 2021. Multi-Spectral Image Synthesis for Crop/Weed Segmentation, Precision Farming. *Robotic and Autonomouns Systems*, 146(1). doi: <https://doi.org/10.1016/j.robot.2021.103861>
- Gómez J. 1995. Control de malezas, Pp.143-152, *In: C. Cassalett-Dávila, J. Torres-Aguas y C. Issacs Echeverri (Eds.). El cultivo de caña en la zona azucarera de Colombia, Centro de Investigación de la caña de azúcar en Colombia, Colombia.*
- Guerra J., F. Cuevas y O. Arellano. 2023. Segmentation of Leaves and Fruits of Tomato Plants by Color Dominance. *AgriEngineering*, 5(4): 1846-1864. doi: <https://doi.org/10.3390/agriengineering5040113>
- Gupta P. y N. Sehgal. 2021. Introduction to Machine Learning in the Cloud with Python. SpringerCham, 1(1). doi: <https://doi.org/10.1007/978-3-030-71270-9>
- Khan F., N. Zafar, M. Naveed, M. Aqib, S. Saleem y Z. Haroon. 2022. Deep Learning-Based Approach for Weed Detection in Potato Crops. *Environ. Sci. Proc.*, 23(1): 6. doi: <https://doi.org/10.3390/environsciproc2022023006>
- Lan Y., Z. Huang, X. Deng, Z. Zhu, H. Huang, Z. Zheng, B. Lian, G. Zeng y Z. Tong. 2020. Comparison of machine learning methods for citrus greening detection on UAV multispectral images. *Computers and Electronics in Agriculture*, 17(1). <https://doi.org/10.1016/j.compag.2020.105234>
- Maquieyra C., G. Schiavi, O. Zingaretti, V. Zorzi y E. Cano. 1985. Efecto de un Fuego Controlado en los Estratos Graminoso y Leñoso de un Bosque de Calden. *Rev. Fac. Agronomía U.N.L.Pam.* 1: 1-2.

- Shorewala S., A. Ashfaq, R. Sidharth y U. Verma. 2021. Weed Density and Distribution Estimation for Precision Agriculture Using Semi-Supervised Learning. *IEEE Access*, 9(1): 27971-27986. doi: <https://doi.org/10.1109/ACCESS.2021.3057912>
- Silva G., L. Silva, L. Silva., P. Costa, R. Oliveira, M. Cândido, M. Oliveira, M. Batista y H. Carmona. 2024. Performance Analysis of YOLO and Detectron2 Models for Detecting Corn and Soybean Pests Employing Customized Dataset. *Agronomy*, 14(10): 2194. doi: <https://doi.org/10.3390/agronomy14102194>
- Yano I., R. Alves, W. Santiago y B. Mederos. 2016. Identification of weeds in sugarcane fields through images taken by UAV and Random Forest classifier. *IFAC-PapersOnLine*, 49(16): 415-420. doi: <https://doi.org/10.1016/j.ifacol.2016.10.076>
- Zou K., X. Chen, F. Zhang, H. Zhou y C. Zhang. 2021. A Field Weed Density Evaluation Method Based on UAV Imaging and Modified U-Net. *Remote Sensing*, 13(2): 310. doi: <https://doi.org/10.3390/rs13020310>
- Bakhshipour A. y A. Jagari. 2018. Evaluation of support vector machine and artificial neural networks in weed detection using shape features. *Computers and Electronics in Agriculture*, 145(1): 153-160. doi: <https://doi.org/10.1016/j.compag.2017.12.032>
- Webb, G. 2016. Encyclopedia of Machine Learning and Data Mining. In: Sammut, C., Webb, G. (Eds). doi: https://doi.org/10.1007/978-1-4899-7502-7_581-1