

Clasificación de plantas de maíz y maleza: Hacia la mejora de la fertilización en México

Marcos Yamir Gómez-Ramos, J. Sergio Ruíz-Castilla,
Farid García-Lamont

Universidad Autónoma del Estado de México,
Centro Universitario UAEM Texcoco,
Estado de México,
México

{marcos.yamir, jsergioruizc}@gmail.com,
fglamont@yahoo.com.mx

Resumen. El cultivo del maíz es muy importante en México y aún podemos encontrar métodos tradicionales de labranza desde la siembra hasta la cosecha; sin embargo, se llegan a observar algunos ejemplos de uso de maquinaria sofisticada. El maíz se siembra en hileras llamadas surcos, separados por unos 0.75 m entre sí. Se siembran de 4 a 5 semillas por mata a una distancia de 0.50 m entre cada una. Por diversos factores, no siempre nace el 100 % de semillas, incluso en ocasiones no germina ninguna semilla. En las primeras semanas se lleva a cabo la fertilización, que consiste en depositar una cantidad de fertilizante químico al pie de la planta. Dicho proceso se hace de manera manual, en el que algún trabajador coloca un puñado de la sustancia por mata, buscando hacerlo de la mejor manera posible, aunque no exacta. Por ende, la actividad resulta lenta, tardada y costosa. Actualmente se ha implementado el uso de maquinaria que deposita fertilizante a lo largo de todo el surco. Con este método se hace más rápido y barato. Sin embargo, se esparce fertilizante en donde hay ausencia de mata de maíz e incluso a la maleza. El fertilizante que no es absorbido por la planta se va al subsuelo, generando contaminación de los mantos acuíferos. El presente trabajo propone la clasificación de plantas de maíz y de maleza, pues al identificar la planta de maíz es posible depositar fertilizante a éstas evitando la maleza e incluso donde no hay planta. Para lograr el objetivo, se obtuvieron 1000 imágenes de maíz y maleza. Se aplicaron métodos de procesamiento de imágenes, como segmentación con PCA y Otsu; después se aplicaron algoritmos de clasificación: Naive Bayes, Random Forest, SVM, KNN, CNN y redes neuronales Backpropagation logrando resultados con hasta el 98.98 % de precisión. Con la finalidad de que la solución mejore el proceso de fertilización.

Palabras clave: Visión artificial, extracción de características, clasificación, fertilización.

Classification of Corn and Weed Plants: Towards Improving Fertilization in Mexico

Abstract. Maize cultivation is very important in Mexico. There are traditional methods for growing maize from planting to harvest. However, there are other cases using sophisticated machinery. During the first weeks after the growing the fertilization is carried out, which consists of depositing a quantity of chemical fertilizer at the foot of the plant. This process is made manually and exactly but this activity is slow and expensive. Currently, the sophisticated machinery deposits fertilizer along the furrow uninterruptedly. This method is faster but the fertilizer is deposited in the absence of maize plant and even to the weed. When the fertilizer is not absorbed by the plant goes to the subsoil, generating contamination of the aquifers. The present work proposes the classification of maize and weed plants. First, we obtained 1000 images from a scenario uncontrolled. We process the images as segmentation with PCA and Otsu. After, we apply classification algorithms as: Naive Bayes, Random Forest, SVM, KNN, CNN and Backpropagation neural networks. The results obtained were a 98.98% of precision. The purpose of work is to improve the techniques of fertilization and avoid the contamination of the subsoil.

Keywords: Artificial vision, features extraction, classification, fertilization.

1. Introducción

Los efectos de los fertilizantes químicos sobre el medio ambiente son inquestionables, su uso genera un riesgo elevado de daños ambientales, como la contaminación de las aguas subterráneas y del suelo y subsuelo en los que se aplican. Es relevante aclarar que un *fertilizante* es cualquier sustancia que se utiliza para aportar nutrientes al suelo, cuyo objetivo es aumentar la concentración de nutrientes que favorezcan y propicien el crecimiento de las plantas. Es importante mencionar que "No todos los fertilizantes actúan igual y tampoco todos los fertilizantes son saludables para el suelo y el medio ambiente" [21]. Los productores agrícolas se han centrado en aportar nitrógeno (N), fósforo (P) y potasio (K) a los sembradíos, práctica que aún se sigue implementando aunque fue descubierta a mediados del siglo XIX. La contaminación por fertilizantes se produce cuando éstos se utilizan en mayor cantidad de la que pueden absorber los cultivos o cuando se eliminan por acción del agua o del viento de la superficie del suelo antes de que puedan ser absorbidos. La contaminación de los mantos acuíferos por los productos y residuos agroquímicos es uno de los problemas más importantes en casi todos los países desarrollados y, cada vez más, en muchos países en vías de desarrollo. Estudios realizados en el Reino Unido han calculado

que se filtran entre 50 y 60 kilogramos de nitrógeno por hectárea al año y que el 58 % de los nitratos que contaminan los mantos acuíferos proceden de la agricultura [21]. El nitrógeno (N), es el fertilizante que más requieren las plantas de maíz y otros cultivos para crecer, además de ser uno de los insumos más costosos dentro de la producción de un agricultor. “Un agricultor de maíz en Sinaloa, México puede llegar a gastar 1700 dolares por hectárea y de esto, un 40 % a 60 % es lo que gasta en fertilizantes; de este porcentaje, hasta un 80 % corresponde al gasto por el nitrógeno” [21].

Hoy en día, el uso de algoritmos de visión computacional ha sido implementado en diversos campos como la agricultura, manufactura, educación, medicina, entre otras. La agricultura es una de las más importantes en México por ser parte del sector primario. Las aplicaciones en este rubro son variadas: detección de plantas [3], reconocimiento de plantas a partir de hojas [18], clasificación de enfermedades [28], reconocimiento de malezas [24] y detección de frutas [8]. Aunque realizar cualquiera de estas tareas resulta complicado, son ampliamente trascendentales para la agricultura, pues la identificación de plantas, frutas o tallos es vital para la toma de decisiones de los agricultores y sus plantíos.

El documento se divide en las siguientes secciones principales: La sección 2 describe el estado del arte en el uso de algoritmos de visión computacional para la agricultura. La sección 3 explica el método propuesto con una descripción detallada de cada conjunto de datos experimentales. En la sección 4 se muestran los resultados obtenidos y la sección 5 presenta las conclusiones de los autores y trabajo futuro.

2. Estado del arte

En los artículos revisados se encuentran diferentes métodos de extracción de características y técnicas de clasificación haciendo uso de diferentes algoritmos. Enseguida se describe la información relevante de los artículos consultados:

Existen algunas características para poder realizar la identificación de plantas y maleza, entre éstas se encuentran: forma, textura y color [4]. Algunas investigaciones actuales se han centrado en características de histogramas y wavelet [5], representación dispersa [24], madurez de las hojas, movimientos rotativos y calibración [14], utilizando SVM [18], CNN [30], FCN [28], KNN [14] como clasificadores con los mejores resultados.

Otros investigadores como [1] propone clasificar una planta en función de su hoja identificando características morfológicas y descriptores de Fourier, usando una Red Neuronal Artificial, ANN por sus siglas en inglés con Backpropagation como clasificador [4]. Utilizó técnicas de selección de características eliminando atributos que introducen ruido, facilita su uso en conjuntos de datos pequeños [3]. Empleó técnicas de extracción de características geométricas invariantes a escalado, traslación y rotación, texturales y cromáticas. Utilizando un clasificador Bayesiano, Backpropagation y SVM [6] propuso un modelo de reconocimiento de características basado en redes de cápsulas y [8] de igual forma propuso

caracterizar frutas empleando descriptores de Fourier y momentos de Hu, la caracterización del color es la contribución de su artículo.

Algunos estudios son muy completos en cuanto al estudio de la segmentación de imágenes por características de color como el de [7], se basó en las características más importantes del color que son la intensidad y cromaticidad, además hace mención de los espacios de color más utilizados en trabajos relacionados y describe las características de estos espacios comparando las ventajas y desventajas de su uso. Ciertos estudios como el de [15] proponen el uso de un algoritmo genético para reducción de ruido con la característica de dimensionalidad. También [29] propone caracterizar imágenes a través de la forma, tipo de margen y geometría ya que estas características tienen patrones comunes en hojas de varias especies. [4] menciona que los métodos de identificación actuales implican algoritmos avanzados para medir las características morfológicas y de textura de los objetos contenidos en la imagen, ya que éstos proporcionan mucha información para clasificarlos.

En [27] et al. se aborda el problema de distinguir las plantas de maíz de las malas hierbas, implementando una red neuronal artificial (ANN) usando el algoritmo backpropagation, teniendo un porcentaje de detección en maíz del 100 % y en maleza del 80 %. [16] plantea el problema de encontrar una herramienta clasificadora para identificar las malas hierbas en los campos de maíz en la etapa temprana de crecimiento, esto a través de una SVM (Máquina de Soporte Vectorial); los resultados arrojaron que los clasificadores SVM podrían identificar con éxito malezas con una precisión del 100 %. [2] expone el problema de reconocimiento de malezas sobre campo con cultivo con técnicas de Deep Learning, el sistema de visión propuesto está basado en Convolutional Neural Networks (CNN) y utiliza una SVM; los resultados fueron la identificación de la maleza en un 91 % con SVM y 84 % con KMEANS. [11] propuso un enfoque de visión artificial para discriminar cultivos y malezas de imágenes de zanahoria logrando un valor de precisión del 93.8 % utilizando el método de Otsu para la segmentación.

[13] desarrollaron un método para discriminar entre cultivos y malezas con un porcentaje de clasificación del 66.7 %. [26] sugiere un método automático para extraer fruta madura de un fondo agrícola complejo obteniendo un valor de precisión del 95 %; se basa en un algoritmo mejorado en el umbral de Otsu que utiliza una nueva función en el espacio de color OHTA. [23] ofrece un método automático para la detección de vegetación en cultivos herbáceos mediante un algoritmo de análisis de imágenes basado en objetos de umbral a través del método Otsu, la clasificación de la vegetación da como resultado el 90 %. [17] desarrolló un método de segmentación de vegetación en imágenes de remolacha azucarera y maíz con una precisión del 87 %; su método se basó en un modelo Bayesiano Naive usando características de espacios de color RGB y HSV.

En los artículos revisados se encuentran variados métodos de extracción de características y técnicas de clasificación, haciendo uso de algoritmos como: SVM (Máquinas de soporte vectorial), Backpropagation, KNN (K- vecino más cercano), CNN (Redes Neuronales Convolucionales), kmeans, Fuzzy c-means,

cadena de Markov, árboles de decisión y Naive Bayes; además de que el método Otsu para la segmentación es el más utilizado previo a la extracción de características.

La detección de maíz y maleza en un entorno natural busca detectar las regiones de interés y realizar la segmentación. La visión artificial es la tecnología clave para identificar correctamente las plantas de maíz y las puedan diferenciar de la maleza para realizar una adecuada fertilización, haciéndolo de forma automatizada y precisa.

2.1. Dataset

Como ya lo hemos mencionado anteriormente, es difícil encontrar un dataset específico de plantas de maíz con las características necesarias para los experimentos a realizar, las encontradas en la web no cumplen con ello o las imágenes son insuficientes para las pruebas que se necesitan hacer. Debido a esto se creó un dataset propio, que incluye 1000 imágenes de alta resolución, de las cuales obtendremos la información para realizar las pruebas en Matlab y Python.

Tabla 1. Características de imágenes del dataset.

Clase	Planta	Imágenes	Ancho	Altura	Formato
1	Maíz	500	768	1024	JPG
2	Maleza	500	768	1024	JPG

Todas las capturas se hicieron a cielo abierto. Se obtuvieron 1000 fotos para las primeras pruebas, tomadas con un celular iPhone 8 plus con cámara de 12 megapíxeles y un selfie stick modelo L01. La toma de fotos se realizó de las 10:00 a las 12:00 horas, el día 9 de mayo del 2020, usando para las muestras todas las plantas de 10 surcos de aproximadamente 100 metros cada uno.



Fig. 1. Imágenes de maíz y maleza.

3. Metodología

En esta sección, se propone un método que permite la identificación con mayor precisión de las plantas de maíz y de maleza en los cultivos, utilizando técnicas de extracción de características y algoritmos de inteligencia artificial; contribuyendo así a la eficiencia en la aplicación y uso de fertilizantes agrícolas en los cultivos de maíz en México, disminuyendo pérdidas económicas a los agricultores, además de evitar la contaminación de suelos y mantos acuíferos. La mayoría de los algoritmos implementados en este estudio han sido codificados internamente en Matlab R2019b a excepción de CNN que fue codificado en Python (versión 3.5) . Los cálculos se implementaron en una computadora MacBook Pro 2014 con procesador Intel core i5 de 2.6 Ghz y memoria RAM de 8 Gb.

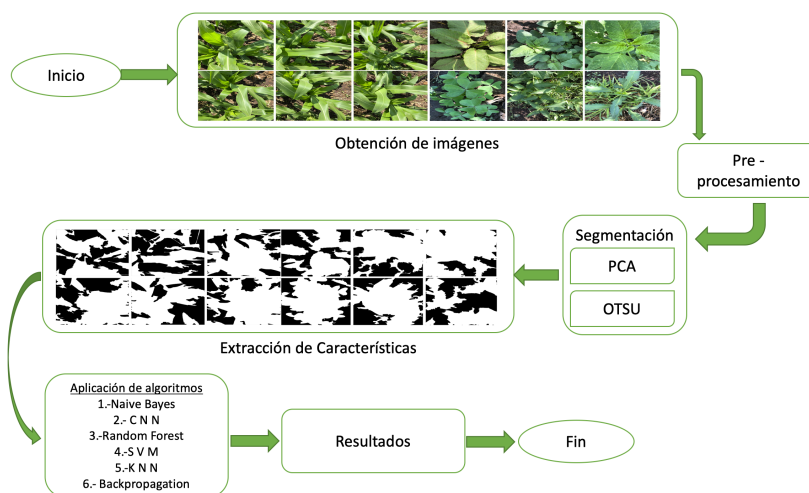


Fig. 2. Metodología usada.

3.1. Pre-procesamiento

El tratamiento de imágenes es una técnica que permite modificar una imagen con el objetivo de lograr una mayor calidad, o bien para obtener una composición totalmente diferente que distorsione la realidad. En nuestro caso, como lo especificamos en el apartado de captura de imágenes, el dataset incluye fotografías de alta resolución. Para un mejor manejo de las mismas y usando el software Matlab se han reducido, eliminando el ruido y opacidad, disminuyendo el brillo, etc. Para reducir el ruido en las imágenes, los métodos de pre-procesamiento son usados antes de la segmentación, pues condicionan la calidad de esta última, por

lo tanto, son necesarios para un diagnóstico preciso. Para mejorar la calidad de la segmentación, el filtro Gaussiano se utiliza para reducir el ruido en la imágenes; esto se realiza mediante una convolución con una función Gaussiana centrada en cada uno de los píxeles de la imagen.

El valor final de cada píxel se obtiene a partir de la contribución de todos sus vecinos ponderados según la función Gaussiana, el efecto que produce es una suavización y una pérdida de detalle de la imagen original. La función Gaussiana se muestra en la ecuación 1:

$$G(x, y) = \frac{1}{\sqrt{(2\pi\sigma)^2}} e^{-\left(\frac{x^2 + y^2}{2\sigma^2}\right)}, \quad (1)$$

donde x , y y σ son constantes reales; el parámetro x es el valor del punto más alto de la campana; y es la posición del centro de la campana y σ es la desviación estándar que controla el ancho de la campana. El grado de suavizado depende de la desviación estándar σ de la función Gaussiana y los valores mayores de σ implican mayor suavizado de la imagen.

En resumen, el uso del filtro Gaussiano en este apartado es para reducir el impacto de la iluminación y otros factores en la imagen original, logrando así mejorar su calidad, realizando una segmentación efectiva y adecuada para la siguiente etapa.

3.2. Segmentación

PCA (Análisis de Componentes Principales), es una técnica de selección de características concreta que utiliza una transformación ortogonal para convertir un conjunto de observaciones de variables, posiblemente correlacionadas, en un conjunto más reducido de variables que ya no guardan correlación y que se conocen como componentes principales [20]. La razón de usar PCA es porque puede minimizar las correlaciones lineales entre variables y maximizar la entropía de la información sobre distintas extracciones principales; también PCA proporciona una forma directa de reducción de dimensiones.

Otsu es una de las técnicas de binarización de imágenes digitales ampliamente utilizadas en inteligencia artificial, sobre todo cuando se trabaja en imágenes reales tomadas en entornos externos; este método que se adapta a diversas condiciones se basa en conceptos estadísticos, en concreto se utiliza la varianza que es una medida de dispersión de valores (dispersión de los niveles de gris); el objetivo del método es calcular el valor del umbral de forma que la dispersión dentro de cada clase sea lo más pequeña posible, pero al mismo tiempo que la dispersión sea lo más alta posible entre clases diferentes. Otra característica importante de Otsu radica en que es un método no supervisado, es decir, es automático y no necesita supervisión humana ni información previa de la imagen.

Las imágenes de maíz y maleza fueron segmentadas con éxito empleando los siguientes pasos: 1) Cálculo de alto contraste en escala de grises a partir de combinación lineal óptima de los componentes de color RGB [9,22]; 2) Estimar

la frontera óptima ejecutando el algoritmo de segmentación de borde adaptativo *Otsu* [9,22] y una fase del análisis de componentes principales *PCA* [20]; 3) Operaciones morfológicas para rellenar posibles espacios vacíos en la imagen segmentada [9,22].

Todo esto con el fin de obtener la mejor segmentación aun teniendo cambios en las condiciones globales de brillo. Al segmentar la imagen, el sistema puede utilizar únicamente la región de las hojas, determinar sus bordes y calcular las propiedades mediante la extracción de características [3].

3.3. Extracción de características

Cuando una imagen es segmentada con éxito, el sistema hace uso de la región de interés y calcula las propiedades mediante la extracción de características, en este experimento solo se extraen características texturales.

La extracción de características es considerada una piedra angular de los algoritmos de aprendizaje automático; la correcta implementación de los métodos de extracción de características define los descriptores utilizados para el reconocimiento de maíz y maleza.

Los métodos de extracción de características más utilizados son: extracción de características geométricas, texturales y cromáticas. Las imágenes tienen muchas características, las cuales al extraerse se van agregando a un vector que contiene todas las características de la imagen.

En esta sección la imagen está representada a través de un conjunto de valores numéricos con un potencial discriminativo; por lo que, las características obtenidas son invariantes a escala, rotación y traslación, permitiendo al clasificador reconocer objetos a pesar de tener diferentes tamaños, posiciones y orientaciones.

Características texturales: Estas características dan lugar a una propiedad que puede ser rugosa, áspera, suave, entre otras características más. La textura es invariante a los desplazamientos porque repite un patrón a lo largo de una superficie; por lo tanto, allí es donde se explica por qué la percepción visual de una textura es independiente de una posición visual. Las características texturales se extraen de las superficies, en este caso de las hojas del maíz y de la maleza; para este fin se implementó el algoritmo Haralick [10] utilizando matrices de coincidencia de niveles grises. Los descriptores utilizados por Haralick se describen a continuación:

$$f_1 = \sum_i \sum_j [p(i, j)^2], \quad (2)$$

$$f_2 = \sum_{n=0}^{N_g-1} n^2 \left\{ \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j)}{|i - j| = n} \right\}, \quad (3)$$

$$f_3 = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} [ijp(i, j) - \mu_x \mu_y]}{\sigma_x \sigma_y}, \quad (4)$$

$$f_4 = \sum_i \sum_j (i - \mu_x)^2 p(i, j), \quad (5)$$

$$f_5 = \sum_i \sum_j \frac{1}{1 + (i - j)^2} p(i, j), \quad (6)$$

$$f_6 = \sum_{i=2}^{2N_g} i P_{x+y}(i), \quad (7)$$

$$f_7 = \sum_{i=2}^{2N_g} (i - f_8)^2 P_{x+y}(i), \quad (8)$$

$$f_8 = - \sum_{i=2}^{2N_g} P_{x+y}(i) \log\{P_{x+y}(i)\}, \quad (9)$$

$$f_9 = - \sum_i \sum_j p(i, j) \log\{p(i, j)\}, \quad (10)$$

$$f_{10} = \sum_{i=0}^{N_g-1} (i - f_8)^2 P_{x-y}(i), \quad (11)$$

$$f_{11} = - \sum_{i=0}^{N_g-1} P_{x-y}(i) \log\{P_{x-y}(i)\}, \quad (12)$$

$$f_{12} = \frac{HXY - HXY1}{\max\{HX, HY\}}, \quad (13)$$

$$f_{13} = (1 - e^{[-2(HXY2 - HXY)])^{\frac{1}{2}}}, \quad (14)$$

$$f_{14} = (\text{Segundo valor más grande de } Q)^{\frac{1}{2}}, \quad (15)$$

donde $p(i, j)$ = define el valor de la matriz de co-ocurrencia en la posición (i, j) . N_g = Niveles de intensidad trabajados en la región segmentada de la imagen. $p_x(i)$ = i ésima entrada en la matriz de probabilidad de co-ocurrencia original que se obtiene sumando las filas en $p(i, j)$. $p_y(j)$ = j ésima entrada en una matriz de probabilidad de co-ocurrencia original que se obtiene mediante la suma de las columnas en $p(i, j)$. R = Número total de elementos en la matriz de co-ocurrencia. μ_x, μ_y = Media de P_x y P_y . σ_x, σ_y = Desviación estándar de P_x y P_y . HX, HY = Entropía de P_x y P_y . El vector de características texturales X_t obtenido puede ser representado como:

$$X_t = [x_1, x_2, \dots, x_{85}], \quad (16)$$

$$X_t = [x_{Rlbp}, x_{RH}, x_{Glp}, x_{GH}, x_{Blbp}, x_{BH}], \quad (17)$$

donde $x_{Rlbp}, x_{Glbp}, x_{Blbp}$ representan las características (LBP) [12,25] obtenidas en el canal de color R, G y B respectivamente, x_{RH}, x_{GH} y x_{BH} representan las características texturales de Haralick obtenidas en los canales R, G and B respectivamente.

Una vez obtenidas las características más relevantes de las plantas de maíz y maleza, en la siguiente sección se utilizarán seis algoritmos diferentes para llevar a cabo pruebas y generar los resultados. Los algoritmos fueron elegidos por su uso en experimentos e investigaciones anteriores mencionadas en el estado del arte; las corridas de los algoritmos de clasificación ayudarán al desarrollo de un análisis comparativo de los métodos de extracción de características texturales utilizados en la segmentación (PCA y Otsu).

3.4. Algoritmos de clasificación

Se han utilizado para pruebas los siguientes algoritmos: En la primer experimentación usando Matlab y el entorno Weka (*Waikato Environment for Knowledge Analysis*) se probó con Naive Bayes, Random Forest, SVM, KNN y Backpropagation; para la segunda ronda de pruebas se realizó en Python con el algoritmo CNN.

Naive Bayes: Los clasificadores bayesianos se basan en la teoría de decisión de Bayes, el principio de Bayes provee una metodología fundamental para resolver problemas de clasificación de patrones cuando la distribución de probabilidad de los patrones es conocida.

Random Forest: Es un algoritmo compuesto por los clasificadores de árboles de decisión, cada árbol depende de los valores de un vector aleatorio con muestreo independiente y con la misma distribución para todos los árboles en el bosque.

SVM: Las Máquinas de Vectores Soporte (SVM) son unas técnicas de clasificación muy utilizadas en los últimos años, los puntos clave de las SVM son el uso de kernels al trabajar con conjuntos no-lineales, la ausencia de los mínimos locales, la solución depende de un pequeño subconjunto de datos y el poder discriminativo del modelo obtenido al optimizar el margen de separabilidad entre clases, estas características permiten a las SVM obtener resultados muy competitivos en comparación a otros clasificadores.

KNN: El algoritmo KNN clasifica un nuevo punto en el conjunto de datos basado en la distancia euclidiana, encontrando las k distancias más cercanas al objeto a clasificar.

Backpropagation: De los distintos algoritmos de aprendizaje de las redes neuronales artificiales, uno de los más utilizados es el algoritmo Backpropagation. Este algoritmo cambia iterativamente los pesos entre las neuronas minimizando el error cuadrático entre la salida deseada y la obtenida con los pesos actuales; todo esto para llevar a cabo el proceso de aprendizaje.

CNN: Las Redes Neuronales Convolucionales (Convolutional Neural Networks), es un tipo de red neuronal enfocada al proceso de clasificación de imágenes, texto, audio y discursos. Las CNNs están inspiradas en las redes con perceptron multi-nivel. La CNN permite hacer una convolución mediante un filtro de 3x3 o 5x5 sobre la matriz de píxeles de la imagen fila por fila hasta recorrer

toda la imagen, una activación RELU y un pooling. Como resultado se obtiene una nueva matriz a la cual se le puede aplicar otra vez una convolución.

Es posible aplicar varias convoluciones; de ahí lo de aprendizaje profundo. Después de aplicar las convoluciones se obtiene una red completamente conectada que puede ser clasificada mediante una función como softmax. La arquitectura de una CNN es como la de la Figura 3.




Fig. 3. Arquitectura de una CNN pro deep learning with TensorFlow [19].

Para este trabajo se ha usado Python y la librería Keras de TensorFlow. Para implementar una CNN se requieren dos conjuntos de datos, en este caso se tomaron 800 imágenes para el entrenamiento y 200 para la evaluación. Al final se aplicó validación cruzada con 5 configuraciones de imágenes que dio como resultado un 96 % de efectividad [19].

4. Resultados

En esta sección, se presentan los resultados de los experimentos realizados en las pruebas; mostrando porcentajes de precisión para reconocimiento de planta de maíz y maleza usando diferentes algoritmos de clasificación y la comparación de resultados usando dos métodos de segmentación diferentes. Las abreviaturas en las tablas son: Acc=Accuracy; S=Sensibilidad; E=Especificidad; P=Precisión; R=Recall; F-m=F-measure y MCC=Coefficiente de Correlación de Matthew que son las *medidas de desempeño* generadas en los resultados.

En la Tabla 2 se pueden ver los resultados obtenidos al hacer uso del método de segmentación PCA y la comparación de los algoritmos de clasificación utilizados; siendo el mejor porcentaje de precisión Backpropagation con 98.78 %.

En la Tabla 3 se pueden ver los resultados obtenidos al hacer uso del método de segmentación Otsu y la comparación de los algoritmos de clasificación utilizados; siendo el mejor porcentaje de precisión Backpropagation con 98.98 %.

La figura 4 corresponde a la gráfica donde se muestran los mejores resultados de esta investigación, comparando los dos métodos de segmentación utilizados y mostrando los algoritmos probados, Naive Bayes, CNN, Random Forest, SVM,

Tabla 2. Resultados con segmentación PCA.

Algoritmo	Acc	S	E	P	R	F-m	MCC
Naive Bayes	78.44 %	0.909 %	0.658 %	0.803 %	0.784 %	0.781 %	0.587 %
Random Forests	93.11 %	0.961 %	0.90 %	0.933 %	0.931 %	0.931 %	0.864 %
SVM	93.21 %	0.969 %	0.894 %	0.935 %	0.932 %	0.932 %	0.867 %
KNN	93.62 %	0.967 %	0.904 %	0.938 %	0.936 %	0.936 %	0.874 %
CNN	96 %	1.0 %	0.92 %	0.96 %	0.96 %	0.96 %	0.954 %
Backpropagation	98.78 %	0.989 %	0.985 %	0.988 %	0.988 %	0.988 %	0.976 %
Promedio	92.19 %	0.965 %	0.876 %	0.926 %	0.921 %	0.921 %	0.853 %

Tabla 3. Resultados con segmentación Otsu.

Algoritmo	Acc	S	E	P	R	F-m	MCC
Naive Bayes	77.3 %	0.898 %	0.647 %	0.792 %	0.773 %	0.769 %	0.564 %
Random Forests	91.9 %	0.941 %	0.897 %	0.92 %	0.919 %	0.919 %	0.839 %
SVM	95.6 %	0.975 %	0.935 %	0.956 %	0.956 %	0.956 %	0.912 %
KNN	93.2 %	0.955 %	0.909 %	0.933 %	0.932 %	0.932 %	0.866 %
CNN	96 %	1.0 %	0.92 %	0.96 %	0.96 %	0.96 %	0.954 %
Backpropagation	98.98 %	0.987 %	0.991 %	0.99 %	0.99 %	0.99 %	0.98 %
Promedio	92.16 %	0.959 %	0.883 %	0.925 %	0.921 %	0.921 %	0.852 %

KNN y Backpropagation en el eje x ; y en el eje y podemos ver el porcentaje de precisión obtenido.

La línea azul pertenece a las pruebas realizadas y los resultados obtenidos con el método de segmentación *PCA* y la línea naranja pertenece a las pruebas obtenidas con el método de segmentación *Otsu*.

La precisión más alta se obtuvo con el método de segmentación *Otsu* y el algoritmo *Backpropagation* con un 98.98 % (99 %).

5. Conclusiones y trabajo futuro

Después de concluir nuestra metodología, podemos inferir que, a partir de 1000 imágenes de plantas de maíz y de maleza tomadas directamente del sembradío sin un ambiente controlado, se ha creado un Dataset de 500 imágenes de plantas de maíz y 500 de malezas. A este Dataset se le aplicó un procesamiento de PCA y Otsu para proceder a la clasificación. Mediante las técnicas Naive Bayes, CNN, Random Forest, SVM, KNN y Backpropagation se lograron resultados de clasificación muy interesantes. Los algoritmos de clasificación mostraron resultados que van del 77.27 % hasta un 98.98 % de precisión en la clasificación de plantas de maíz y malezas, y nos permiten determinar que la mejor técnica fue Backpropagation, ya que una precisión del 98.98 % puede ser eficaz en la implementación de tecnologías de detección de plantas de maíz para su fertilización u otros procesos. Si se llevara a cabo su implementación en el proceso de fertilización actual en México, podría hacer la actividad mucho más precisa y eficaz, pudiendo traer consigo beneficios económicos a largo plazo

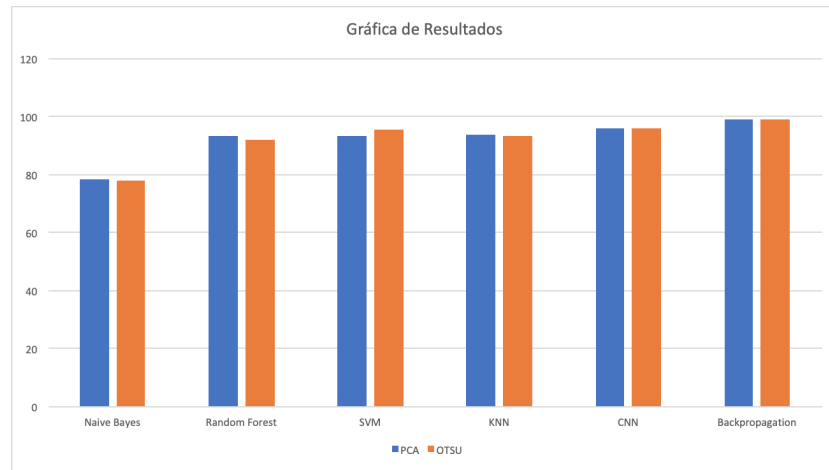


Fig. 4. Gráfica de resultados con los dos métodos de segmentación utilizados.

para este sector productivo, al evitar el desperdicio de fertilizante en la maleza. Finalmente, recalcar que la inteligencia artificial en sus diferentes técnicas debe empezar a utilizarse con mayor frecuencia en todas las áreas con nichos de oportunidad, incluyendo la agricultura. Como trabajo a futuro se realizarán experimentos con características geométricas y cromáticas para compararlas con los resultados obtenidos en este artículo y encontrar si existe un mejor porcentaje de efectividad.

Referencias

1. Aakif, A., Khan, M.F.: Automatic classification of plants based on their leaves. *Biosystems Engineering* 139, pp. 66–75 (2015)
2. Baruffaldi, J.M.: Redes neuronales adversarias para el reconocimiento de malezas. Tesis, Facultad de Ciencias Exactas, Ingeniería y Agrimensura, Universidad Nacional de Rosario, Argentina, pp. 47–61 (2016)
3. Cervantes, J., Taltempa, J., Garca-Lamont, F., Castilla, J.S.R., Rendon, A.Y., Jalili, L.D.: Analisis comparativo de las tecnicas utilizadas en un sistema de reconocimiento de hojas de planta. *Revista Iberoamericana de Automatica e Informatica Industrial RIAI* 14(1), pp. 104–114 (2017)
4. Cervantes, J., Lamont, F.G., Mazahua, L.R., Hidalgo, A.Z., Castilla, J.S.R.: Complex identification of plants from leaves. In: *Intelligent Computing Methodologies*, Springer International Publishing, pp. 376–387 (2018)
5. Chau, A.L., Hernandez, R.R., Mora, V.T., Canales, J.C., Mazahua, L.R., Lamont, F.G.: Detection of compound leaves for plant identification. *IEEE Latin America Transactions* 15(11), pp. 2185–2190 (2017)
6. Dong, M., Mu, S., Su, T., Sun, W.: Image recognition of peanut leaf diseases based on capsule networks. In: *Communications in Computer and Information Science*, Springer Singapore, pp. 43–52 (2019)

7. Garcia-Lamont, F., Cervantes, J., Lopez, A., Rodriguez, L.: Segmentation of images by color features: A survey. *Neurocomputing* 292, pp. 1–27 (2018)
8. Garcia, F., Cervantes, J., Lopez, A., Alvarado, M.: Fruit classification by extracting color chromaticity, shape and texture features: Towards an application for supermarkets. *IEEE Latin America Transactions* 14(7), pp. 3434–3443 (2016)
9. Gonzalez, R.C., Woods, R.E., Eddins, S.L.: *Digital image processing using MATLAB*. Pearson Education India (2004)
10. Haralick, R.M., Shanmugam, K., Dinstein, I.: Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics SMC* 3(6), pp. 610–621 (1973)
11. Haug, S., Michaels, A., Biber, P., Ostermann, J.: Plant classification system for crop/weed discrimination without segmentation. In: *IEEE Winter Conference on Applications of Computer Vision*, pp. 1142–1149 (2014)
12. He D.C., Wang L.: Texture Unit, Texture Spectrum, And Texture Analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 28, pp. 509–512 (1990)
13. Su Hnin Hlaing, Aung Soe Khaing: Weed and crop segmentation and classification using area thresholding. *IJRET*, pp. 375–382 (2014)
14. Imanov, E., Alzouhbi, A.K.: Machine learning comparative analysis for plant classification. In: *13th International Conference on Theory and Application of Fuzzy Systems and Soft Computing, ICAFS-2018*, Springer International Publishing, pp. 586–593 (2018)
15. Jalili, L.D., Morales, A., Cervantes, J., Ruiz-Castilla, J.S.: Improving the performance of leaves identification by features selection with genetic algorithms. In: *Communications in Computer and Information Science*, Springer International Publishing, pp. 103–114 (2016)
16. Lanlan Wu, Youxian Wen: Weed corn seedling recognition by support vector machine using texture features. *African Journal of Agricultural Research* 4(9), pp. 840–846 (2009)
17. Krishna, M.: Effective segmentation of green vegetation for resource-constrained real-time applications. *Precision agriculture*, pp. 257–266 (2015)
18. Niño, D.A., Castilla, J.S.R., Zenteno, M.D.A., Jalili, L.D.: Complex leaves classification with features extractor. In: *Intelligent Computing Theories and Application*, Springer International Publishing, pp. 758–769 (2019)
19. Pattanayak, S.: *Pro Deep Learning with TensorFlow*. Bangalore, Karnataka, India (2017)
20. Schor, N., Bechar, A., Ignat, T., Dombrovsky, A., Elad, Y., Berman, S.: Robotic disease detection in greenhouses: Combined detection of powdery mildew and tomato spotted wilt virus. *IEEE Robotics and Automation Letters* 1(1), pp. 354–360 (2016)
21. Silva, A.R.E., Cobelas, M.A., Gonzalez, E.M.: Impactos del nitrógeno agrícola en los ecosistemas acuáticos. *Ecosistemas* 26(1), pp. 37–44 (2017)
22. Sonka, M., Hlavac, V., Boyle, R.: *Image Processing, Analysis and Machine Vision*. Springer US (1993)
23. Jorge Torres. An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops. *Computers and Electronics in Agriculture*. pp. 43–52 (2015)
24. Feng Wang, X., Wang, Z., Wen Zhang, S.: Segmenting crop disease leaf image by modified fully-convolutional networks. In: *Intelligent Computing Theories and Application*, Springer International Publishing, pp. 646–652 (2019)
25. Wang, L., He, D.: Texture Classification Using Texture Spectrum. *Pattern Recognition*, 23(8), pp. 905–910 (1990)

26. Wei Xiangqin: Automatic method of fruit object extraction under complex agricultural background for vision system of fruit picking robot. *Optik - International Journal for Light and Electron Optics*, pp. 5684–5689 (2014)
27. Yang, C.C. Prasher, S.O. Landry, J.A. Ramaswamy, H.S. et al.: Application of artificial neural networks in image recognition and classification of crop and weeds. *Can. Agric. Eng.* 42, pp. 147–152 (2015)
28. Zhang, S., Wang, X., Wang, Z.: Weed recognition in wheat field based on sparse representation classification. In: *Intelligent Computing Theories and Application*, Springer International Publishing, pp. 511–519 (2019) https://doi.org/10.1007/978-3-030-26763-6_49
29. Zhao, C., Chan, S.S., Cham, W.K., Chu, L.: Plant identification using leaf shapes – a pattern counting approach. *Pattern Recognition* 48(10), pp. 3203–3215 (2015)
30. Zheng, Y., Yuan, C.A., Shang, L., Huang, Z.K.: Leaf recognition based on capsule network. In: *Intelligent Computing Theories and Application*, Springer International Publishing, pp. 320–325 (2019)