

## Umbralización óptima para la clasificación del crecimiento de plantas de frijol Optimal thresholding for classification of bean plant growth

J.A. Morales-Viscaya <sup>a\*</sup>, A. A. Alonso-Ramírez <sup>a</sup>, A. I. Barranco-Gutiérrez <sup>a</sup>

<sup>a</sup> Tecnológico Nacional de México, campus Celaya, Guanajuato, Celaya, México.

### Resumen

Los sistemas para automatizar el monitoreo de cultivos pueden servir para reducir costos, incrementar la productividad y mejorar la calidad de las cosechas al crear las condiciones ambientales necesarias para cada etapa. En este trabajo se presenta un método para la clasificación de las fases de crecimiento de plantas de frijol en su etapa vegetativa. Se propone una clasificación basada en el área y dispersión de los píxeles tras una segmentación RGB óptima de las imágenes de las plantas de frijol en un ambiente controlado. Para llevar a cabo esta investigación, se utilizó una base de datos desarrollada en 2019 en el Tecnológico Nacional de México campus Celaya después de monitorear veinte plantas de frijol desde su etapa de germinación hasta la etapa de primera hoja trifoliada. Se comprueba la efectividad de la propuesta al obtener una segmentación adecuada de las plantas en las imágenes que permite identificar los estados vegetativos con un error menor al reportado en otros trabajos.

*Palabras Clave:* Clasificación, Optimización, Umbralización, Agricultura.

### Abstract

Crop monitoring systems can serve to reduce costs, increase productivity and improve the quality of the harvest by creating the necessary environmental conditions for each stage. This paper presents a method for the classification of the growth phases of bean plants in their vegetative stage. A classification based on the area and dispersion of the pixels is proposed after an optimal RGB segmentation of the images of the bean plants in a controlled environment. To carry out this research, a database developed in 2019 at the Tecnológico Nacional de México campus Celaya was used after monitoring twenty bean plants from their germination stage to the first trifoliolate leaf stage. The effectiveness of the proposal is verified by obtaining an adequate segmentation of the plants in the images that allows identifying the vegetative states with a smaller error than that reported in other works.

*Keywords:* Classification, Optimization, Threshold, Agriculture.

### 1 Introducción

El frijol es uno de los cultivos clave para la seguridad alimentaria mundial y la sostenibilidad agrícola. Esto debido a su adaptabilidad y tolerancia a condiciones ambientales extremas, lo que lo hace especialmente importante en un mundo con un clima cambiante. Además de ser una fuente importante de proteínas, fibra, vitaminas y minerales, posee la capacidad de fijar nitrógeno en el suelo, lo que mejora su fertilidad y reduce la necesidad de fertilizantes químicos.

Según la Encuesta Nacional de Ingreso y Gasto de los Hogares (ENIGH) (INEGI, 2020), el frijol es el tercer alimento más consumido en México después del maíz y el trigo, con un consumo promedio anual de 7.6 kg por persona. Sin embargo, a pesar de la importancia del frijol en la dieta mexicana, la producción nacional no siempre es suficiente

para satisfacer la demanda interna. De acuerdo al SIAP (SIAP, 2020), México importó más de 350,000 toneladas de frijol en 2020, principalmente de Estados Unidos y Canadá. A pesar de la creciente tecnificación de la agricultura existen muy pocos trabajos relacionados con el uso de IA y técnicas de visión artificial en el campo mexicano, por lo que existe la necesidad de incrementar el seguimiento y tecnificación de los cultivos agrícolas.

En años recientes se ha incrementado particularmente el uso de visión artificial, cámaras y algoritmos de procesamiento de imágenes para analizar y tomar decisiones en agricultura. Entre las principales aplicaciones se pueden mencionar las siguientes:

1. La visión artificial puede ser utilizada para identificar plagas y enfermedades en plantas, lo que permite a los agricultores intervenir de manera temprana y prevenir daños

\*Autor para la correspondencia: [d2003023@itcelaya.edu.mx](mailto:d2003023@itcelaya.edu.mx)

Correo electrónico: [d2003023@itcelaya.edu.mx](mailto:d2003023@itcelaya.edu.mx) (Joel Artemio Morales-Viscaya), [d2203002@itcelaya.edu.mx](mailto:d2203002@itcelaya.edu.mx) (Adan Antonio Alonso-Ramírez), [Israel.barranco@itcelaya.mx](mailto:Israel.barranco@itcelaya.mx) (Alejandro Israel Barranco-Gutiérrez).

significativos en los cultivos. Por ejemplo, en Toskova et al. (Toskova et al., 2020) se presentó un sistema inteligente para el reconocimiento de plagas en cultivos de trigo mientras que en Song et al. (Song et al., 2020) se elaboró un modelo para detectar y reconocer las enfermedades de hojas de cítricos.

2. La visión artificial puede ser utilizada para monitorear el crecimiento de los cultivos, lo que permite a los agricultores tomar decisiones más informadas sobre cuándo regar, fertilizar y cosechar. En Wu et al. (Wu et al. 2020) se implementó un sistema inteligente de monitoreo agrícola en una plantación de té y en Hassanzadeh et al. (Hassanzadeh et al., 2020) se clasificó el crecimiento del cultivo de frijol.

3. La visión artificial puede ser utilizada para seleccionar y clasificar productos basados en su calidad y características. Por ejemplo, en Balbin et al. (Balbin et al., 2020) se evaluó el tamaño, la calidad y el nivel de tueste de un lote de granos de café. En Onana et al. (Onana et al., 2020) se evaluaron granos de cacao, con el fin de ayudar a estimar eficientemente la calidad de estos granos y mejorar el proceso de extracción de la pulpa.

Existen muchas otras aplicaciones, como en la limpieza de cultivos (Qing et al., 2020), el control de la temperatura, la humedad y la intensidad de la luz en un invernadero (Cui et al., 2020) o la vigilancia automatizada de campos de cultivo (Khare et al., 2020).

Múltiples estudios demuestran los beneficios potenciales del uso de visión e inteligencia artificial en agricultura. Por ejemplo, en Liu et al. (Liu et al., 2021) se realizó un análisis de 67 artículos publicados sobre el impacto del uso de tecnologías en la agricultura para la producción de trigo en China. Los resultados mostraron que mejoró significativamente el rendimiento, la calidad y las ganancias.

En Rangarajan et al. (Rangarajan et al., 2020) se examinó la adopción de tecnologías de visión e inteligencia artificial por parte de los productores de manzanas en India. Los resultados mostraron que aumentó, significativamente, la rentabilidad agrícola y que los agricultores que adoptaron estas tecnologías obtuvieron ingresos netos más altos que los que no.

En este trabajo se utilizan técnicas de visión e inteligencia artificial para dar soporte al agricultor en la tarea de clasificar las etapas de crecimiento de las plantas de frijol en tiempo real de forma automatizada.

La umbralización es un proceso clave para la extracción de características en imágenes. Por lo general se lleva a cabo de manera empírica y se concentran los esfuerzos en el algoritmo de clasificación propiamente. La propuesta aquí descrita consiste en centrar los esfuerzos en hacer una umbralización óptima para la extracción de las características.

La organización del trabajo es la siguiente, en la sección II se muestran los antecedentes en la clasificación de las etapas de crecimiento en plantas de frijol con la base de datos utilizada. En la sección III se desarrolla la metodología y los algoritmos utilizados en este trabajo. La sección IV muestra los resultados obtenidos mientras que la sección V presenta las conclusiones y trabajo futuro.

## 2 Antecedentes

El proceso de crecimiento de las plantas de frijol tiene dos fases principales (Fernandez et al., 1986): la vegetativa y la reproductiva. La primera corresponde al intervalo entre el origen de la semilla y el momento en que se ramifica el tallo (conocido como racimo floral). Esta fase suele durar 35 días y

la semilla de frijol sufre varios cambios que se clasifican en cinco etapas: V0: germinación, V1: emergencia, V2: hoja primaria, V3: primera hoja trifoliada, V4: tercera hoja trifoliada. Las diferentes etapas, así como una descripción de ellas, se puede apreciar en la Tabla 1 y la Fig. 1.

Tabla 1. Etapas vegetativas del desarrollo de plantas de frijol.

Código	Nombre	Evento con el que inicia
V0	Germinación	La semilla está en condiciones favorables para germinar.
V1	Emergencia	Los cotiledones del 50% de las plantas aparecen al nivel del suelo.
V2	Hojas primarias	Las hojas primarias del 50% de las plantas están desplegadas.
V3	Primera hoja trifoliada	La primera hoja trifoliada del 50% de las plantas está desplegada.
V4	Tercera hoja trifoliada	La tercera hoja trifoliada del 50% de las plantas están desplegadas.

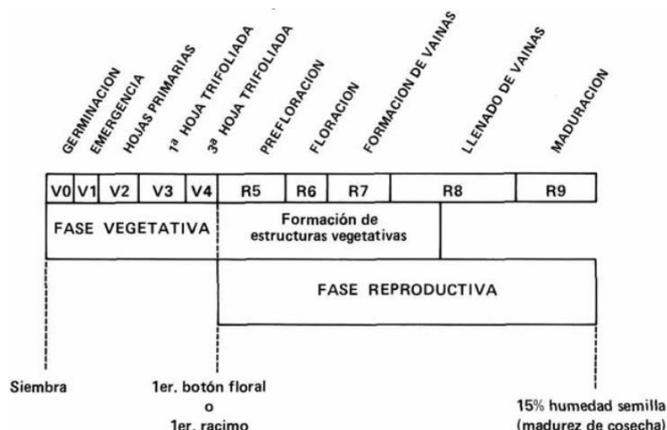


Fig. 1 Etapas de desarrollo de una planta de frijol, extraída de (Fernandez et al. 1986).

En el Tecnológico Nacional de México, campus Celaya, se creó una base de datos de imágenes de semilla de frijol; utilizando una caja de luz de 1m x 1m x 1m con paredes blancas. De forma que el color oscuro de la planta de frijol contraste con el fondo y facilite su umbralización, una fotografía de la caja se puede apreciar en la Fig. 2.

Se colocaron dos cámaras Logitech c525 en el interior de la caja. Una cámara en la pared lateral izquierda a 10 cm del piso y una segunda cámara en el techo a 70 cm de la pared lateral izquierda. Un vaso con la planta de frijol se coloca en cuatro posiciones distintas y, considerando ambas cámaras, se capturaron ocho imágenes para cada muestra de frijol.



Fig. 2. Fotografía de la caja de luz, extraída de (Correa et al., 2019).

En Correa *et al* (Correa *et al.*, 2019) se utilizó dicha base de datos para construir un sistema difuso de clasificación del crecimiento de las plantas de frijol, utilizando la biomasa promedio de cada una de las muestras.

Para ello, se segmentó primero la imagen por color y posteriormente se promedió el área de aparición de la planta en las imágenes laterales y superiores por separado. Esta área promedio y su desviación estándar (lateral y superior) se utilizaron como entrada de un sistema difuso.

En el presente trabajo se utiliza la base de datos de (Correa *et al.*, 2019) para llevar a cabo la clasificación de las etapas vegetativas de la planta de frijol, utilizando solamente una imagen lateral y una superior. Se propone la implementación de un algoritmo de optimización para encontrar un conjunto de valores adecuados para producir una umbralización óptima y el uso de una red neuronal artificial para clasificación.

### 3 Metodología

Para llevar a cabo la clasificación de la etapa en que se encuentra la planta de frijol, se decidió utilizar cuatro variables de entrada:

- El número de píxeles de la planta en la imagen lateral.
- El número de píxeles de la planta en la imagen superior.
- La desviación estándar de los píxeles en la imagen lateral.
- La desviación estándar de los píxeles en la imagen superior.

El conteo de píxeles de las plantas, así como el cálculo de la desviación, se lleva a cabo mediante la umbralización de la imagen, es decir, se utilizan filtros de color para separar los píxeles de la imagen que corresponden a la planta y los que no, a partir de los canales RGB. Se utilizan seis valores numéricos para este proceso, de tal forma que se describen los umbrales:

$$\begin{aligned} R_1 < R < R_2 \\ G_1 < G < G_2 \\ B_1 < B < B_2 \end{aligned} \quad (1)$$

Para cada canal de color, una parte de la superficie de la planta se segmenta, los tres canales se intersecan para reconstruir toda la planta y hacer el conteo de píxeles. La intersección se realiza con la operación AND de los canales R, G y B.

La realización de un buen modelo de clasificación es altamente dependiente de la calidad de los datos, por lo que un mal cálculo del área o desviación en imágenes produciría un mal modelo.

En Correa *et al.* (Correa *et al.*, 2019) el umbral de los colores en los que se encuentra la planta de frijol se lleva a cabo de forma empírica, utilizando la Herramienta de umbralización de MATLAB. En este trabajo se propone una metodología para encontrar los seis valores,  $R_1$ ,  $R_2$ ,  $G_1$ ,  $G_2$ ,  $B_1$  y  $B_2$  utilizando un algoritmo de optimización.

En el Algoritmo 1 se muestra el proceso de umbralización que regresa el área en número de píxeles y la desviación estándar, a partir de una imagen  $img$  y un vector  $\mathbf{X}$  con los parámetros  $\mathbf{X} = (R_1, R_2, G_1, G_2, B_1, B_2)$ .

Es necesario encontrar el centro de los píxeles producidos en la umbralización para calcular su desviación estándar, esto se hace con la media aritmética de las componentes (x, y) de todos los píxeles en la umbralización. Utilizando el centro, la desviación se calcula cómo la raíz cuadrada de la distancia promedio de cada punto a dicho centro.

---

```

Entradas: X,img
R=G=B=Matriz de zeros del tamaño de img.
for (i,j)∈ img do
  if img(i,j,1) > X(1) and img(i,j,1) < X(2) then
    R(i,j)=1;
  end if
  if img(i,j,2) > X(3) and img(i,j,2) < X(4) then
    G(i,j)=1;
  end if
  if img(i,j,3) > X(5) and img(i,j,3) < X(6) then
    B(i,j)=1;
  end if
end for
imgUmb=R&G&B
Area=CuentaPíxeles(imgUmb)
Centro=CalculaCentro(imgUmb)
Desv=CalculaDesv(imgUmb,Centro)
return Area,Desv

```

---

Algoritmo 1. Umbralización.

Para poder utilizar un algoritmo de optimización es necesario definir una función de aptitud que nos diga qué tan bueno es un conjunto de valores, se decidió utilizar como función de aptitud el RMSE (de las siglas en inglés Root-Mean Square Error, raíz del error cuadrático medio) de la salida de la red neuronal entrenada con el área y desviación que produce el vector de umbrales  $\mathbf{X}$ .

Al entrenar una red neuronal se recomienda el uso de validación cruzada, esto implica dividir los datos disponibles en dos conjuntos: uno de entrenamiento y uno de prueba. El modelo se entrena con el conjunto de entrenamiento y se evalúa con el conjunto de prueba.

Sin embargo, diferentes particiones del conjunto de entrenamiento pueden producir un diferente desempeño final del modelo. Por lo que se recomienda repetir  $k$  veces la validación utilizando diferentes particiones de los datos. Al final, se promedian todos los RMSE para obtener una estimación más precisa del rendimiento del modelo.

El algoritmo general para el cálculo de la aptitud de un conjunto  $\mathbf{X}$  de valores para la umbralización se puede ver en el Algoritmo 2.

---

```

Entradas: X, base de datos
Acum=0
for i=1 hasta k do
  for cada img en la base de datos do
    Datos(i)=Umbralización(X,img)
  end for
  DatosNormalizados=minmax(Datos)
  Partición=Particiona(DatosNormalizados)
  Red=EntrenaRNA(DatosNormalizados,Partición)
  Acum=Acum+RMSE(Red,DatosNormalizados)
end for
Aptitud=Acum/k
return Aptitud

```

---

Algoritmo 2. Cálculo de aptitud.

Dado que el rango de valores de los datos sin procesar varía ampliamente, se decidió normalizar el rango de todas las variables para que cada característica contribuya de manera aproximadamente proporcional al error o distancia final. Para ello se utilizó la normalización min-max.

La base de datos (BD) cuenta con 1943 imágenes, sin embargo 69 de ellas no cuentan con su respectivo par (superior o lateral) y un total de 32 imágenes de la BD original reportada en (Correa et al.,2019) se encuentran repetidas (16 están tanto en la clase germinación como en emergencia y otras 16 tanto en la clase emergencia como en hoja trifoleada), tras la limpieza de la BD se trabajó con un total de 1842 imágenes, de las cuales la mitad son laterales y la otra mitad superiores.

Por lo que el conjunto total de imágenes para entrenar la red neuronal es de 921. El total de observaciones se divide en 464 de la clase germinación, 93 de la clase emergencia, 261 de la clase hoja primaria y 103 de la clase hoja trifoliada.

El tamaño de las imágenes en la base de datos es de 480x640px, mientras que el parámetro k utilizado para promediar el desempeño del algoritmo que se utilizó fue k=10, de manera que, para calcular la aptitud, se tiene que entrenar y validar diez veces el modelo con particiones distintas.

Para el entrenamiento de la red neuronal se decidió particionar los datos en 70% para entrenamiento, 30% para validación y prueba. Además de utilizar como método de entrenamiento la retropropagación de Levenberg-Marquadt, cien neuronas en la capa oculta y el error cuadrático medio (mse) como función de desempeño. Todas estas características de la red neuronal son las predefinidas para la función "fitnet" de MATLAB.

Se utilizó la herramienta de MATLAB "Classification Learner" para probar el desempeño obtenido con otras técnicas populares de clasificación implementadas en MATLAB como las máquinas de soporte vectorial y los árboles de clasificación.

#### 4 Resultados

Se utilizó un objeto *GlobalSearch* de MATLAB para buscar el umbral óptimo con el optimizador local "fminsearch", que es una implementación del popular algoritmo de Nelder-Mead con múltiples puntos de inicio.

Los parámetros óptimos obtenidos se pueden apreciar en la Tabla 2.

Tabla 2. Parámetros óptimos de umbralización.

Parámetro	Valor numérico
R <sub>1</sub>	138
R <sub>2</sub>	227
G <sub>1</sub>	137
G <sub>2</sub>	252
B <sub>1</sub>	90
B <sub>2</sub>	243

En las Figs. 3 y 4, se muestra un ejemplo de la umbralización aplicada a una imagen de la BD con dichos parámetros. Utilizando esta umbralización para encontrar los parámetros de área y desviación, se produce una red neuronal con un RMSE promedio en los datos de validación de 0.2406, superior a los mejores valores (0.390, 0.410 y 0.369) reportados en Correa et al. (Correa et al.,2019).



Fig. 3 Imagen original de una planta clasificada como V2.

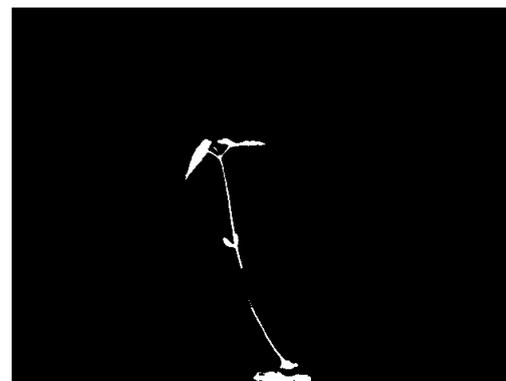


Fig. 4. Imagen segmentada de una planta clasificada como V2.

La exactitud (popularmente conocida como accuracy, del inglés) es una medida de evaluación comúnmente utilizada en los sistemas de clasificación, se calcula como el número de datos de validación clasificados correctamente dividido por el número total de datos de validación.

Se calculó la exactitud de la red neuronal propuesta con la de otras técnicas de clasificación incluidas en la herramienta "Classification Learner" de MATLAB R2018a. Los resultados se presentan en la Tabla 3.

Tabla 3. Exactitud promedio de los datos de validación.

Estrategia	Exactitud
Clasificador cuadrático	0.875
Máquina de soporte vectorial lineal	0.898
Árboles de clasificación	0.903
Máquina de soporte vectorial cuadrática	0.913
Red neuronal artificial propuesta	0.943

Las True Positive Rate (TPR o tasas de verdaderos positivos) de cada clase, así como los False Positive Rate (FPR o tasa de falsos positivos) se aprecian en la Tabla 4.

Tabla 4. TPR y FPR de cada clase con los datos de validación.

Clase	TPR	FPR
Clase 1 Germinación	97.06%	2.86%
Clase 2 Emergencia	72.73%	2.36%
Clase 3 Hojas primarias	95.24%	3.13%
Clase 4 Hojas trifoliadas	88.24%	0.83%

Las curvas ROC (característica operativa del receptor) constituyen una herramienta importante para evaluar el rendimiento de un modelo de *machine learning*. La curva ROC muestra la relación entre TPR y FPR del modelo.

El área bajo las curvas ROC es un buen indicador del desempeño del clasificador y se construye utilizando diferentes reglas para la conversión de la salida del modelo (un número real) a una clase (un conjunto discreto de posibilidades).

Los valores que se encontraron para el área bajo la curva ROC, para cada una de las clases, se puede apreciar en la Tabla 5.

Tabla 5. Área bajo cada curva ROC.

Clase	Área bajo la curva
Clase 1 Germinación	0.9959
Clase 2 Emergencia	0.9753
Clase 3 Hojas primarias	0.9919
Clase 4 Hojas trifoliadas	0.9986

Mientras que cada una de las curvas ROC en el enfoque One-Vs-All (uno contra todos) se pueden apreciar en la Figs. 5,6,7, y 8.

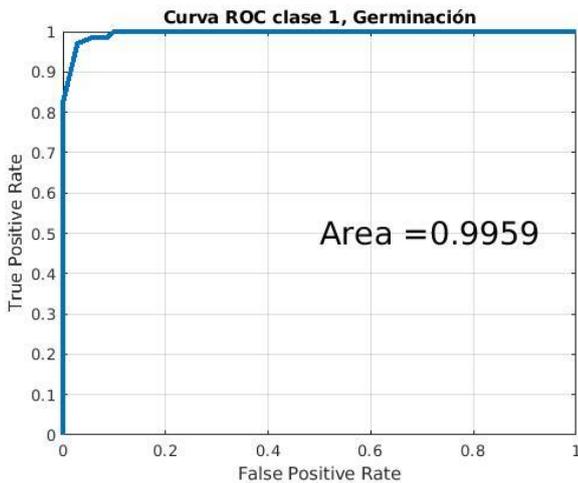


Fig. 5. Área bajo la curva ROC de la clase Germinación.

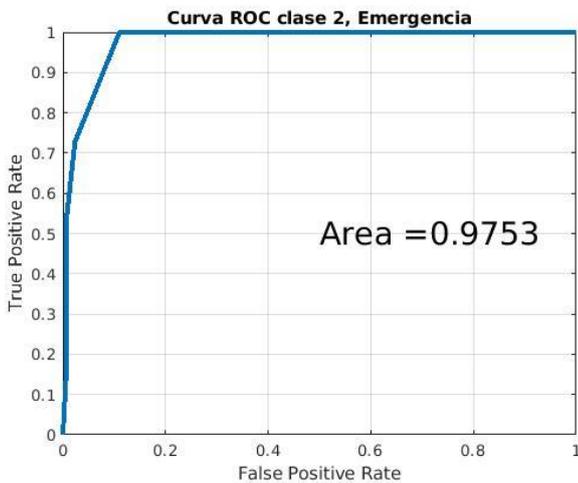


Fig. 6. Área bajo la curva ROC de la clase Emergencia.

Una manera de visualizar el desempeño de sistemas de clasificación es la matriz de confusión, una tabla que resume el desempeño del modelo clasificador en términos de los verdaderos positivos, verdaderos negativos, falsos positivos y

falsos negativos. La matriz de confusión del clasificador utilizando redes neuronales se muestra en la Tabla 6.

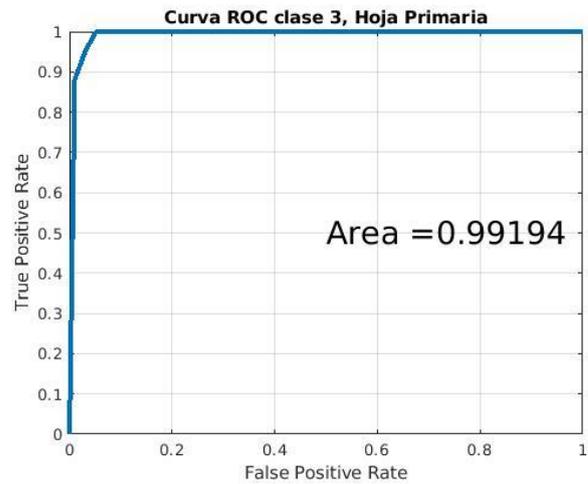


Fig. 7. Área bajo la curva ROC de la clase Hoja primaria.

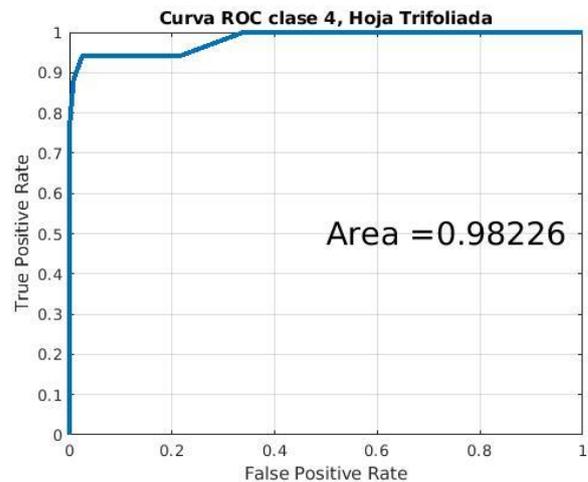


Fig. 8. Área bajo la curva ROC de la clase Hoja trifoliada.

Tabla 6. Matriz de confusión.

-	Clase 1	Clase 2	Clase 3	Clase 4
Clase 1	97.06%	2.94%	0.00%	0.00%
Clase 2	18.18%	72.73%	9.09%	0.00%
Clase 3	0.00%	2.38%	95.24%	2.38%
Clase 4	0.00%	0.00%	11.76%	88.24%

### 5 Conclusiones y trabajo futuro

Se presentó un método para la clasificación de las etapas de crecimiento de plantas de frijol basado en la obtención de características a partir de una segmentación de la imagen. Se implementó una metodología para encontrar los umbrales de color adecuados al plantear el problema como uno de optimización.

Se comprueba la efectividad de la propuesta al obtener una segmentación correcta de cada planta respecto al fondo en las imágenes y, al producir con las imágenes segmentadas un RMSE menor al reportado en otros trabajos.

Es importante mencionar que, si la umbralización es adecuada y por lo tanto las características extraídas de las imágenes son descriptivas de la clase, el desempeño de estrategias de clasificación avanzadas será adecuado. En la Tabla 3 se aprecia que una máquina de soporte vectorial cuadrática y un árbol de clasificación se desempeñan casi tan bien como la red neuronal propuesta ya que la umbralización y por tanto las características de las imágenes son óptimas.

La base de datos posee un desequilibrio considerable, al tener, por mencionar un caso, casi cinco veces más imágenes de la etapa de germinación que de la etapa de emergencia. Si bien este desequilibrio es intrínseco al proceso de crecimiento de la planta de frijol, ya que el número de días que dura cada etapa es distinto, dificulta el análisis objetivo de los resultados.

Tanto en la Tabla 4 como en la matriz de confusión, se puede apreciar que, aunque la exactitud en general es alta, sólo el 72.73% de las imágenes de frijol en etapa de emergencia se clasificaron como tal, sin embargo, el RMSE (que se utilizó como aptitud para encontrar los umbrales) es pequeño ya que el total de imágenes en esta clase es mucho menor a otras y por lo tanto contribuyen menos al error total.

Una alternativa para atenuar el desequilibrio en bases de datos en el futuro, es utilizar alguna estrategia para trabajar con datos desbalanceados, como el incremento en la penalización de las clases minoritarias, la modificación del dataset (por ejemplo, con muestras artificiales) o el uso de las estrategias conocidas como *Balanced Ensemble Methods* o métodos de ensamble balanceado.

Queda como trabajo futuro el utilizar como función de aptitud alguna métrica distinta al RMSE, cómo la exactitud o alguna función multiobjetivo que tome en cuenta otros factores o pueda llegar a producir una matriz de confusión más simétrica (por ejemplo, el promedio del TPR de todas las clases).

## Referencias

- Balbin, J.R., Del Valle, C. D., Lopez V. J. L. G. y Quiambao, R. F., "Grading and Profiling of Coffee Beans for International Standards Using Integrated Image Processing Algorithms and Back-Propagation Neural Network," 2020 IEEE 12th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM), Manila, Philippines, 2020, pp. 1-6, doi: 10.1109/HNICEM51456.2020.9400086.
- Correa P., Bautista P., Lopez M., Villaseñor M., García C., Rostro-Gonzalez H y Perez-Pinal F.J., "An Approach of Beans Plant Development Classification Using Fuzzy Logic", Journal of Sensors. 2019. 10. doi: <https://doi.org/10.1155/2019/4232536>.
- Cui X., "Design and Experiment of Control System for Intelligent Agriculture based on Arduino," 2020 IEEE 9th Joint International Information Technology and Artificial Intelligence Conference (ITAIC), Chongqing, China, 2020, pp. 2297-2300, doi: 10.1109/ITAIC49862.2020.9338949.
- Fernández C., "Etapas de desarrollo de la planta de frijol común (Phaseolus vulgaris L.)", Centro Internacional de Agricultura Tropical, CIAT, Cali, Colombia, 1986.
- Hassanzadeh A., Murphy S. P., Pethybridge S. J., van Aardt J. y Zhang F., "Toward Maturity Assessment of SNAP Bean Crops: A Best-Case Greenhouse Scenario," IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium, Waikoloa, HI, USA, 2020, pp. 5278-5281, doi: 10.1109/IGARSS39084.2020.9323202.
- Instituto Nacional de Estadística y Geografía, "National Survey of Household Income and Expenditure (ENIGH). 2020 New series", 2020 <https://en.www.inegi.org.mx/programas/enigh/nc/2020/>
- Khare T y Phadke A., "Automated Crop Field Surveillance Using Computer Vision", IEEE International Conference on Distributed Computing, 2020, doi: <https://doi.org/10.48550/arXiv.2101.11217>
- Liu T., Li F., Li Y., Yang X., Wang Y. y Zhang J., "Precision agriculture technology improves yield and economic benefits of wheat in China: Evidence from a meta-analysis". Journal of Cleaner Production, 2021, 279, 123693. <https://doi.org/10.1016/j.jclepro.2020.123693>
- Oña Oña A.J., Grijalva F., Proaño K., Acuña B. y García M., "Classification of Fresh Cocoa Beans with Pulp Based on Computer Vision," 2020 IEEE ANDESCON, Quito, Ecuador, 2020, pp. 1-6, doi: 10.1109/ANDESCON50619.2020.9272188.
- Qing J., "Study of a Cleaning Intelligent Control System for Rice and Wheat Combine Harvester," 2020 IEEE International Conference on Artificial Intelligence and Information Systems (ICAIS), Dalian, China, 2020, pp. 400-406, doi: 10.1109/ICAIS49377.2020.9194934.
- Rangarajan R., Mishra A., "Precision agriculture adoption and farm profitability: Evidence from apple farmers in India". Agricultural Systems, 2020, 181, 102812. <https://doi.org/10.1016/j.agsy.2020.102812>
- Servicio de Información Agroalimentaria y Pesquera, "Estadística de la producción agrícola de 2020" <http://infosiap.siap.gob.mx/gobmx/datosAbiertos.php>
- Toskova A., Toskov B., Uhr Z. y Doukovska L., "Recognition of Wheat Pests," 2020 IEEE 10th International Conference on Intelligent Systems (IS), Varna, Bulgaria, 2020, pp. 276-280, doi: 10.1109/IS48319.2020.9200148.
- Wu M. Y. y Ke C. K., "Development and Application of Intelligent Agricultural Planting Technology - The Case of Tea," 2020 International Symposium on Computer, Consumer and Control (IS3C), Taichung City, Taiwan, 2020, pp. 43-44, doi: 10.1109/IS3C50286.2020.00018.

Balbin, J.R., Del Valle, C. D., Lopez V. J. L. G. y Quiambao, R. F., "Grading and Profiling of Coffee Beans for International Standards Using Integrated Image Processing Algorithms and Back-Propagation Neural Network," 2020 IEEE 12th International Conference on Humanoid, Nanotechnology,