

Un acercamiento inicial al uso de modelos de clasificación para la identificación de variedades de agave en Oaxaca

DOI: 10.58299/UTP.261.C874

Idarh Matadamas

Instituto Politécnico Nacional
Centro Interdisciplinario de Investigación para el Desarrollo Integral Regional
Unidad Oaxaca. Laboratorio central.
idarhmatadamas@gmail.com
<https://orcid.org/0000-0001-9358-9763>

Teodulfo Aquino-Bolaños

Instituto Politécnico Nacional
Centro Interdisciplinario de Investigación para el Desarrollo Integral Regional
Unidad Oaxaca, Laboratorio central.
taquino@ipn.mx
<https://orcid.org/0000-0003-2917-8147>

Erik Zamora

Instituto Politécnico Nacional
Centro de Investigación en Computación.
Laboratorio de robótica y mecatrónica.
ezamorag@ipn.mx
<https://orcid.org/0000-0002-3682-8585>

Manuel de Jesús Melo Monterrey

Tecnológico Nacional de México.
Departamento de Ciencias Económico-Administrativas.
manuelmelo.m@gmail.com
<https://orcid.org/0009-0002-5994-1182>

Miriam Emily Avendaño Villegas

Tecnológico Nacional de México.
Departamento de Posgrado e Investigación
emilyavvi@gmail.com
<https://orcid.org/0000-0002-4871-8658>



Un acercamiento inicial al uso de modelos de clasificación para la identificación de variedades de agave en Oaxaca

An initial approach to the use of classification models for the identification of agave varieties in Oaxaca

Resumen

El agave tiene gran relevancia cultural, económica y social en México. Su importancia es notable en el estado de Oaxaca, donde se concentran diversas especies utilizadas en la producción de mezcal, alimentos y fibras. Este estudio presenta un análisis preliminar para la clasificación de tres variedades: *Agave angustifolia* Haw, *Agave rhodacantha* Trel y *Agave marmorata* Roezl, mediante una arquitectura de redes neuronales profundas ResNet-34. Se recolectaron 3,871 imágenes de plantas en tres parcelas de los Valles Centrales de Oaxaca. El entrenamiento del modelo durante 50 épocas mostró una alta precisión, recall y exactitud, alcanzando valores máximos de 99,87% en validación. Los resultados confirman la viabilidad de las redes neuronales profundas para la agricultura de precisión y constituyen una contribución al desarrollo de bases de datos multiclase de agave. Esto sirve como punto de partida para optimizar futuros modelos, fortalecer la producción y preservación de esta especie en la región.

Palabras clave: aprendizaje; clasificación; entrenamiento.

Abstract

Agave holds great cultural, economic, and social significance in Mexico. Its importance is especially notable in the state of Oaxaca, where various species are concentrated and used for the production of mezcal, food, and fibers. This study presents a preliminary analysis for the classification of three varieties: *Agave angustifolia* Haw, *Agave rhodacantha* Trel, and *Agave marmorata* Roezl, using a deep neural network architecture, ResNet-34. A total of 3,871 images of plants were collected from three plots in the Central Valleys of Oaxaca. The model was trained for 50 epochs, showing high precision, recall, and accuracy, reaching maximum validation values of 99.87%. The results confirm the feasibility of deep neural networks for precision agriculture and contribute to the development of multiclass agave databases. This serves as a starting point for optimizing future models and strengthening the production and preservation of this species in the region.

Keywords: classification; learning; training.

Introducción

El agave es una de las plantas de mayor relevancia cultural, económica y social en México. Su importancia es particularmente notable en el estado de Oaxaca, donde se concentra una amplia diversidad de especies y variedades. Estas se emplean en la producción de mezcal, alimentos, fibras y otros derivados (Mariles-Flores & Ortiz-Solorio, 2016). Sin embargo, la identificación y clasificación de estas variedades suele depender de criterios morfológicos observados manualmente. Este método puede generar sesgos y limitar la precisión del diagnóstico, especialmente cuando las diferencias entre especies son sutiles. Esto representa un reto cuando se trata de automatizar tareas de clasificación (Araujo et al., 2021).

El desarrollo de herramientas basadas en aprendizaje profundo y visión por computadora ofrece una alternativa innovadora para la clasificación automática de variedades vegetales a partir de imágenes. En estudios previos realizados por Srinivasan et al. (2025) se propone un método basado en aprendizaje profundo para la identificación de especies en plantas. La estrategia central utilizada se basó en redes neuronales convolucionales (CNNs). Para entrenar el modelo, se empleó un conjunto de imágenes amplio y diverso, que abarca distintas especies, fases de crecimiento y condiciones ambientales.

Mientras que GUO et al., (2025) utilizaron técnicas de aprendizaje profundo y aprendizaje por transferencia sobre un dataset de imágenes de plantas de cebada para comparar cinco modelos de deep learning. Se analizó el impacto de varios factores, como la resolución de las imágenes y la proporción de datos de entrenamiento y prueba, en la precisión de la clasificación. Los resultados mostraron que el modelo DenseNet alcanzó el mejor desempeño con un 96,02 % de precisión. Los modelos basados en transfer learning superaron a los entrenados desde cero, destacando EfficientNet-v2 con una precisión del 98,86 %. Adicionalmente, Naresh & Reddy, (2025) trabajaron sobre la detección y clasificación de enfermedades vegetales usando arquitecturas híbridas, logrando precisiones cercanas al 93.88 % y una especificidad superior al 93%.

En otro estudio realizado por Roy et al., (2024), los autores llevaron a cabo la clasificación de variedades de arroz mediante imágenes de la planta en diferentes etapas de crecimiento, con el objetivo de determinar el mejor algoritmo y la etapa más adecuada para la clasificación correcta. La etapa de maduración se identificó como la más adecuada para una clasificación correcta, entre las cuatro etapas evaluadas: estadio de encañado, 50 % de floración, estadio lechoso y maduración. La precisión de prueba de todos los algoritmos osciló entre 60% y 73%, siendo 73% el mejor usando VGG 16, un modelo de aprendizaje profundo.

Para el caso de Murugan et al., (2025) la propuesta consistió en uso del modelo InceptionV3 para la extracción de características de imágenes de plantas, complementado con algoritmos de support vector machine (SVM) y k-nearest neighbors (KNN) para la clasificación a nivel de especie. Este enfoque permitió no solo aprovechar la capacidad de generalización del deep learning, sino también integrar métodos tradicionales para mejorar el desempeño en conjuntos de datos diversos. En trabajos reportados en México, (Vega-López et al., 2023) presentaron un análisis de arquitecturas de redes neuronales convolucionales aplicadas a la clasificación de especies vegetales mexicanas mediante imágenes digitales. Para ello, se construyó un modelo de clasificación basado en la arquitectura Inception-v4, utilizando un dataset de flora nativa mexicana compuesto por 17,900 imágenes a color de 202 especies vegetales. Los resultados experimentales muestran que técnicas como el aprendizaje por transferencia y el aumento de datos mejoran significativamente el desempeño del modelo en la identificación de especies. En particular, la mejor precisión obtenida por Inception-v4 fue del 86,97 %.

El objetivo de este trabajo fue plantear un estudio inicial sobre la clasificación de imágenes de tres variedades de agave presentes en Oaxaca mediante la implementación de un modelo de redes neuronales profundas, ResNet-34, uno de los más utilizado en la literatura. La relevancia de este esfuerzo radica en que constituye un primer acercamiento que busca incentivar la alimentación y expansión de una base de datos multiclase, con el objetivo de robustecer futuros

entrenamientos de modelos y generar un repositorio representativo que capture la diversidad real de las plantas de agave en la región.

De esta manera, este capítulo busca ser una contribución inicial a la aplicación de tecnologías emergentes en el ámbito de la agricultura de precisión en el estado de Oaxaca, ofreciendo resultados preliminares que abren la posibilidad de investigaciones más amplias orientadas al fortalecimiento de la cadena de valor del agave-mezcal y a la preservación de su diversidad dentro del estado de Oaxaca.

Marco teórico

Agave

El género *Agave* está distribuido de forma natural en América. México alberga la mayor diversidad, con aproximadamente 150 de las 200 especies que componen este género. Oaxaca, Puebla, Sonora, Querétaro y Durango son los estados que cuentan con una mayor diversidad en el país (Mariles-Flores & Ortiz-Solorio, 2016). El *Agave* es una especie monocárpica que florece una vez en su vida y muere al finalizar este periodo. La planta se caracteriza por sus hojas gruesas y carnosas a las cuales se les denomina “pencas”, terminan con una punta en forma de espina. La fisiología y morfología de esta planta le permite crecer y cultivarse en terrenos pedregosos, calientes, erosionados y secos. Oaxaca es el estado con la mayor presencia de especies de agave, 58 de las cuales 13 se consideran endémicas, 25 de estas son utilizadas para la fabricación de mezcal, 8 cultivadas y 17 silvestres (Jiménez et al., 2019). Es una de las actividades económicas más importantes, lo cual genera una destacada derrama económica y la imagen cultural que brinda al estado (Mariles-Flores & Ortiz-Solorio, 2016).

Variedades de agave usados para el trabajo

Agave angustifolia Haw. Conocida como agave espadín, es una planta del género *Agave*, principalmente utilizado para la elaboración de mezcal. Está formada por rosetas cespitosas abiertas de 1.0 a 1.5 m de alto por 1.2 a 2.0 m de diámetro, los tallos pueden ir de 20 a 60 cm de largo. La forma de sus hojas maduras puede

variar de lineal a lanceoladas de 60 a 120 por 3.5 a 10 cm, de color verde a claro grisáceo; planas o cóncavas hacia el ápice, convexas hacia la base, estrechas, angostándose hacia la base y terminando en una espina apical de 1.5 a 3 cm de largo. El estado de Oaxaca aporta el 91.32% de la producción nacional (COMERCAM, 2023; Sánchez et al., 2020). Figura 1.



Figura 1. *Agave angustifolia* Haw (agave espadín).
Fuente: fotografía tomada por los autores.

Agave rhodacantha Trel. Conocida como agave mexicano, se encuentra formado por rosetas densas de 1.7 a 2.5 m de alto por 2.5 por 3.0 de diámetro. Hojas con un número mayor a 100 por roseta con dimensiones de 1.0 a 1.6 m de largo y 6.0 a 10.0 cm de ancho. Las hojas son rígidas, fibrosas, engrosadas hacia la base, de coloración verde a verde-glaucosa, de margen recto a ondulado. Dentada, con dientes de 0.7 a 1.0 cm de largo y 0.6 a 1.2 cm de ancho. Espina terminal de 2.0 a 3.0 cm de largo por 5.0 a 6.0 mm de diámetro, cónica y aplanada en el haz. Su uso principal es en la producción de mezcal (García-Mendoza y Franco-Martínez, 2018). Figura 2.



Figura 2. *Agave rhodacantha* Trel (agave mexicano)
Fuente: fotografía tomada por los autores.

Agave marmorata Roezl. conocido como agave tepeztate, se reconoce por rosetas de 1.5 a 2.0 m de alto por 1.5 a 2.5 m de diámetros. Con existencia de 16 a 20 por roseta, de color verde-amarillo de 1.0 a 1.3 m de largo, 0.2 a 0.3 m de ancho; frecuentemente onduladas, acanaladas y con el margen dentado. Espinas terminales cortas y robustas de 1.5 a 2.0 cm de largo, 4.0 a 8.0 mm de ancho. Es endémica de México, en Oaxaca puede encontrarse en los distritos de Coixtlahuaca, Huajuapán, Miahuatlán, Tlacolula y Yautepec principalmente. Es una especie utilizada en la producción de mezcal y en algunas áreas para la extracción de aguamiel (García-Mendoza y Franco-Martínez, 2018). Figura 3.



Figura 3. *Agave marmorata* Roezl (agave tepeztate)

Fuente: fotografía tomada por los autores.

ResNet-34

Las Redes Neuronales Convolucionales (CNN por sus siglas en inglés) permiten extraer diferentes niveles de características de las imágenes tratadas (Abiyev & Ma'aitah, 2018). En sus arquitecturas formadas por múltiples capas, cada una de estas permite refinar la representación de características de la imagen en niveles cada vez más abstracto, a esto se le conoce como Deep Learning (GoodFellow et al., 2016).

En años recientes, el Deep Learning ha tenido grandes avances en el análisis de imágenes y son ampliamente usadas en problemas de clasificación. Una de las arquitecturas es ResNet-34, una red neuronal convolucional que toma el nombre por el número total de capas que es de 34, figura 4. En cada una de estas capas se desarrolla la operación de convolución con kernel de tamaño 3×3 y cada capa tiene diferente número de filtros (64, 128, 256, 512), (He et al., 2015).




Figura 4. Arquitectura de ResNet-34. Tomada de (Tsai & Kleinman, 2022).
Fuente: elaboración propia.

Metodología

Sitios de colecta y variedades de agaves

Para la formación de la base de datos de imágenes digitales se realizaron visitas a tres parcelas localizadas en la región de los Valles Centrales de Oaxaca, cada una con diferentes variedades de agaves. Las ubicaciones son las siguientes:

Parcela 1. Ubicada en la población de Santiago Matatlán, dentro de la denominada “región del mezcal” en el distrito de Tlacolula, Oaxaca. Corresponde a una plantación de *Agave angustifolia* Haw de cuatro años de edad.

Parcela 2. Situada en la población de San Lorenzo Cacaotepec, distrito de ETLA, corresponde a una plantación de *Agave rhodacantha* Trel de cuatro años de edad.

Parcela 3. También en San Lorenzo Cacaotepec, distrito de ETLA, se localiza una plantación de *Agave marmorata* Roezl con una edad aproximada de tres años.

Base de datos

Las imágenes digitales de las plantas de agave se obtuvieron con una cámara digital Canon® Rebel T3i, directamente en las parcelas seleccionadas en un horario entre las 12:00 y las 13:30 h, bajo iluminación natural. Las dimensiones de las imágenes obtenidas es de 2,592 x 1,728 en espacio de color RGB y con la presencia de varias plantas en ella. La figura 5 presenta un ejemplo de las imágenes capturas inicialmente. El ángulo de captura fue un “ángulo normal” (lente de la cámara a la altura de los ojos del fotógrafo). Posteriormente las imágenes de las plantas individuales fueron recortadas de manera manual para obtener muestras de plantas de agave individuales.

Posterior a la captura de las imágenes, se identificaron las plantas de agave que aparecen en cada una de ellas, tomando como criterio de selección: toda aquella planta que total o parcialmente sea reconocible a primera vista. El proceso

de recorte de las muestras se realizó de manera manual, a través de rectángulos que delimitan la existencia de una planta de agave dentro de la imagen, de esta manera se obtuvieron un total de 3,871 muestras que presentan una planta individual de una de tres clases: espadín, mexicano o tepeztate. La tabla 1 muestra la distribución de imágenes en los conjuntos de entrenamiento y validación. En total, se recopilieron 3,871 imágenes, de las cuales 3,096 se destinaron al entrenamiento y a la validación, 80% y 20% respectivamente.



Figura 5. Ejemplo de imagen original tomada en la parcela de *A. marmorata*.
Fuente: fotografía tomada por los autores.

Tabla 1. Distribución de las muestras por conjunto en cada una de las clases: espadín, mexicano, tepeztate.

Conjunto	<i>A. angustifolia</i>	<i>A. rhodacantha</i>	<i>A. marmorata</i>	Total
Entrenamiento	634	728	1,734	3,096
Validación	151	179	445	775
Total	785	907	2,179	3,871

Fuente: elaboración propia.

Se observa que la variedad *Agave marmorata* concentra la mayor cantidad de muestras, 2,179 en total, mientras que *A. angustifolia* y *A. rhodacantha* se cuentan con 785 y 907 imágenes respectivamente. Esta diferencia refleja un desbalance en la base de datos, ya que *A. marmorata* representa más de la mitad del total de instancias, mientras que *A. angustifolia* constituye la clase minoritaria, figura 6. Dicho desbalance puede influir en el desempeño del modelo, favoreciendo la predicción de la clase mayoritaria.

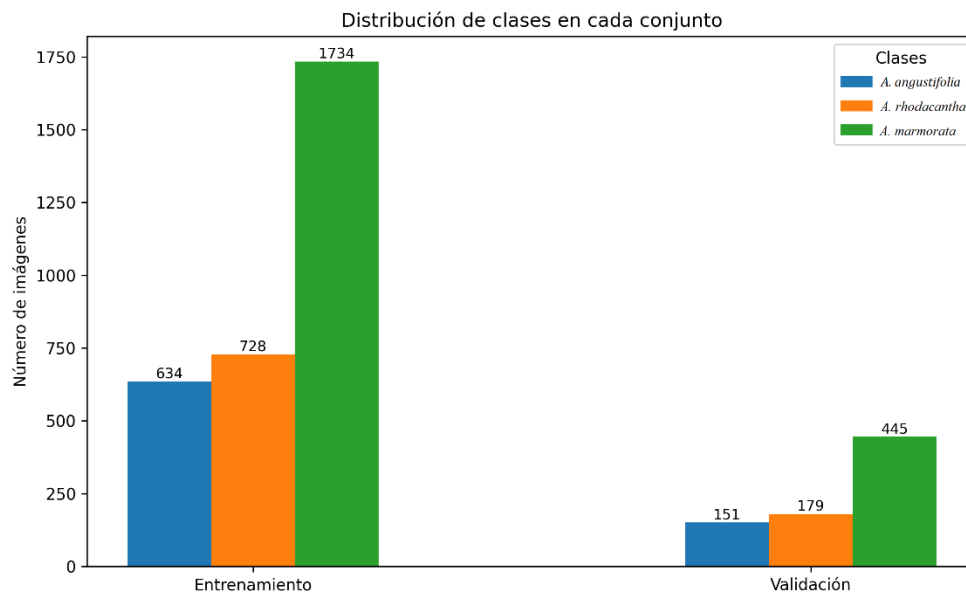


Figura 6. Distribución de muestras por clase en los conjuntos de entrenamiento y validación.
Fuente: elaboración propia.

Para mitigar el sesgo inducido por el desbalance en la distribución de clases, dado por la clase *A. marmorata*, se consideró el oversampling, que consiste en replicar o generar nuevas muestras de las clases minoritarias. En la literatura esta técnica ha demostrado ser una de las más robustas para contrarrestar el desbalance sin causar problemas adicionales (Buda et al., 2018; Joloudari et al., 2022; Yue & Wang, 2022). Se implementó el esquema de oversampling a través de transformaciones de aumento de datos (data augmentation). En cada iteración, las imágenes de las clases minoritarias fueron replicadas y sometidas a transformaciones aleatorias que incrementan la variabilidad visual sin alterar la clase original. Estas transformaciones incluyeron operaciones geométricas como volteo horizontal y rotación en pequeños ángulos, recortes aleatorios (random crop)

para simular variaciones de encuadre, y ajustes en parámetros de color como brillo, contraste y saturación. Figura 7.




Figura 7. Ejemplo de imágenes originales y los resultados después de las transformaciones aplicadas. a) *A. angustifolia* original; b) *A. angustifolia* con transformaciones; c) *A. rhodacantha* original; d) *A. rhodacantha* con transformaciones.

Fuente: fotografías tomadas por los autores.

Métricas de desempeño

Para evaluar la capacidad del modelo ResNet-34 en la tarea de clasificación de las tres variedades de agaves, se utilizaron métricas comunes en aprendizaje automático (Ferreira & Camacho, 2021; Hama et al., 2024; Mookkandi et al., 2025). La exactitud (Acc) que mide la proporción de clasificaciones correctas sobre el total, es un indicador general del rendimiento del modelo de clasificación. La precisión (Pr) representa el número de verdaderos positivos de un total de elementos identificados como positivos. El recall (Rc), representa la sensibilidad y brinda información de la cantidad de verdaderos positivos que el modelo clasificó en

función del número total de valores positivos. A partir de estas dos últimas métricas se obtiene el *F1-score*, que corresponde a la media armónica entre *Pr* y *Rc*, útil en escenarios con clases desbalanceadas, como la utilizada en este trabajo. Además, la matriz de confusión que permite visualizar de manera detallada el comportamiento del modelo en cada clase, mostrando aciertos y errores específicos. Estas métricas ofrecen una visión completa del desempeño del modelo, permitiendo identificar no solo su capacidad de clasificación, sino también su eficacia por categoría.

$$Acc = \frac{TP + TN}{TP + TN + FP + FN}$$

$$Pr = \frac{TP}{TP + FP}$$

$$Rc = \frac{TP}{TP + FN}$$

$$F1 - score = 2 \cdot \frac{Pr \cdot Rc}{Pr + Rc}$$

Donde:

TP (Verdaderos positivos): es el número de elementos clasificados correctamente como positivos.

TN (Verdaderos negativos): es el número de elementos que no presentan plantas de maguey y que el modelo clasificó como negativos de forma correcta.

FP (Falsos positivos): es el número de elementos clasificados como positivos de forma incorrecta.

FN (Falsos negativos): es el número de elementos clasificados incorrectamente como negativos.

Resultados

El entrenamiento del modelo se observa en figura 8. Se realizó durante 50 épocas y las métricas de fueron registradas para su análisis. En cuanto a la pérdida de entrenamiento (Train loss) disminuyó rápidamente desde un valor inicial de 0.1500 en la época 1 hasta valores cercanos a cero en las últimas iteraciones, alcanzando un $4.15e-05$, el valor más bajo del entrenamiento en la época 45. La pérdida durante la validación (Val loss) mostró inestabilidad al inicio del proceso, con un valor máximo de 0.1469 en la época 11, sin embargo, se comporta de manera favorable al final del mismo, obteniendo un valor mínimo de 0.0017 en la época 44.

La exactitud en el entrenamiento (Train acc) creció partiendo de un 94.9 % en la primera época hasta alcanzar el 100 % en varias ocasiones a partir de la época 19. En la validación (Val acc) alcanzó un 99.87 % desde el inicio y logro un valor máximo de 99.87 % en las épocas 12, 20, 33, 36, 43. La métrica de precisión, presentan altos durante la validación, alcanzando 0.983 desde la época 1 y alcanzando su máximo de 0.9996 en la época 40.

El recall mostró un comportamiento durante la validación (Val recall) similar al de la precisión, con valores iniciales de 0.992 en la época 1 y un valor máximo de 0.9993 en la época 39. La época 49 presentó también una caída significativa con un 0.916, mientras que durante el resto del entrenamiento el modelo mantuvo un alto nivel de sensibilidad.

La métrica F1 confirmó el equilibrio entre precisión y recall, iniciando en 0.988 en la primera época y alcanzando un valor máximo de 0.9986 en la época 44. De manera consistente, se mantuvo por encima de 0.995 desde la época 7, salvo la anomalía registrada en la época 49 con un valor de 0.8749.

Comportamiento de métricas durante el entrenamiento




Figura 8. Métricas de desempeño del ResNet34 durante el entrenamiento y la validación. Fuente: elaboración propia.

La matriz de confusión, del conjunto de validación, muestra un desempeño sobresaliente del modelo, con una clasificación correcta de 774 de las 775 muestras evaluadas. (figura 9). De las 151 instancias de la clase *A. angustifolia* y las 445 de *A. marmorata* fueron clasificadas sin errores, alcanzando una precisión y recall del 100 %. En la clase *A. rhodacantha*, de un total de 179 imágenes, únicamente una fue clasificada de manera incorrecta como *A. marmorata*, lo que representa un error mínimo de 0.56 %.

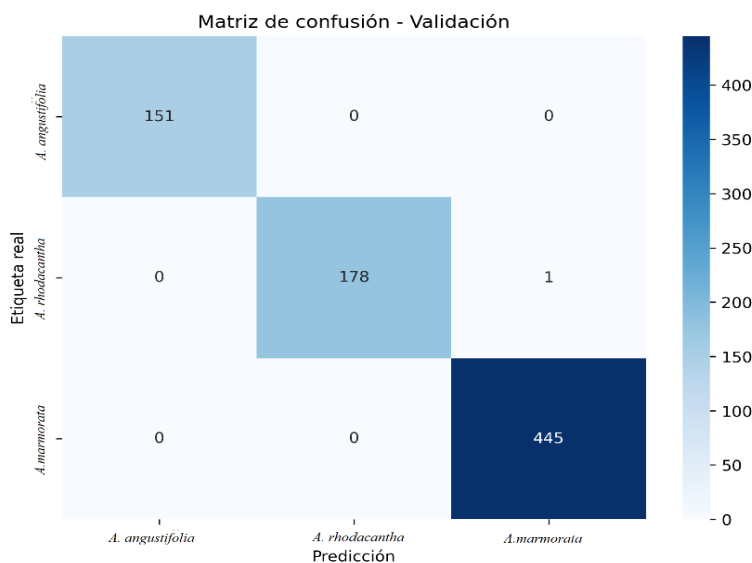


Figura 9. Matriz de confusión del conjunto de entrenamiento. Fuente: elaboración propia.

Discusión

Los resultados alcanzados por el modelo ResNet-34 presentan un desempeño satisfactorio en la clasificación de imágenes de agave, con métricas que superan en el 99 % en precisión, recall, F1 y exactitud. En bases de datos desbalanceadas es común observar una disminución en el desempeño del modelo (Buda et al., 2018). Esto debido a la complejidad de los datos, que en tareas de agricultura puede aumentar por a la presencia de brotes o enfermedades en determinadas clases, así como las variaciones estacionales que dificultan obtener imágenes bajo condiciones homogéneas (Miftahushudur et al., 2025).

Estudios comparativos muestran que ResNet-34 mantiene un rendimiento competitivo con bases de datos con una complejidad moderada (Bangalore et al., 2024), lo que lo hace adecuado para tareas con recursos limitados. Los resultados presentan a la arquitectura como una herramienta robusta para la identificación de variedades de agave. El comportamiento consistente de las métricas de entrenamiento y validación respalda la capacidad del modelo para generalizar adecuadamente los datos no vistos. Los resultados obtenidos en la matriz de confusión confirman la robustez del modelo para discriminar entre las tres variedades de agave, con un nivel de exactitud global del 99.87 % en el conjunto de validación, y respalda las métricas de precisión, recall y F1 superiores al 99 % obtenidas durante el entrenamiento.

La importancia de estos hallazgos refuerza la viabilidad de aplicar tecnologías emergentes en la agricultura de precisión en Oaxaca, en este caso en el cultivo del agave. Si bien el dataset utilizado aún presenta un desbalance entre clases, la implementación de técnicas de oversampling y permitió mitigar este sesgo.

Estos resultados no solo validan la aplicabilidad de las redes neuronales profundas en el ámbito agrícola, sino que también representan una contribución inicial al desarrollo de conjuntos de datos multiclase de agave en Oaxaca. Abriendo

las puertas a investigaciones posteriores orientadas a optimizar modelos de clasificación, generar bases de datos más representativas y apoyar el fortalecimiento de los procesos del agave en la región.

Conclusión

El presente estudio constituye un primer acercamiento a la aplicación de modelos de redes neuronales profundas en la identificación de imágenes de tres variedades de agave de Oaxaca. Los resultados obtenidos muestran que la arquitectura ResNet-34 alcanzó un desempeño sobresaliente, con métricas de precisión, recall y F1 superiores al 99% en la mayoría de las épocas de entrenamiento, lo que respalda su potencial como herramienta de apoyo en el ámbito de la agricultura de precisión.

A pesar de trabajar con una base de datos desbalanceada, la implementación de técnicas de oversampling permitió mitigar el sesgo hacia las clases mayoritarias y mejorar la capacidad de generalización del modelo. Sin embargo, existe la necesidad de ampliar y equilibrar la base de datos, logrando de este modo una representación más fiel a la variabilidad de las condiciones en campo, pero, sobre todo un aumento en la complejidad del problema de clasificación al tener un mayor número de variedades presentes.

Este trabajo busca sentar las bases para el desarrollo de un repositorio multiclase de agave, que sirva para futuros entrenamientos de modelos más complejos y robustos. Destacando el esfuerzo por impulsar la innovación en la cadena de valor del agave-mezcal en Oaxaca, contribuyendo a la modernización de las prácticas agrícolas mediante tecnologías emergentes. Esto no solo incrementa la competitividad y eficiencia de los productores locales, sino que también promueve la preservación de la biodiversidad y el aprovechamiento sostenible de los recursos naturales.

Referencias

- Abiyev, R. H., y Ma'aitah, M. K. S. (2018). Deep Convolutional Neural Networks for Chest Diseases Detection. *Journal of Healthcare Engineering*, 2018, 4168538. <https://doi.org/10.1155/2018/4168538>
- Araujo, V. M., Britto Jr., A. S., Oliveira, L. E. S., y Koerich, A. L. (2021). Two-View Fine-grained Classification of Plant Species. *arXiv*. <https://doi.org/10.48550/arXiv.2005.09110>
- Bangalore, S., Chitty-Venkata, K. T., Arya, K., y Somani, A. K. (2024). ConVision Benchmark: A Contemporary Framework to Benchmark CNN and ViT Models. *AI*, 5(3) 1132-1171.. <https://doi.org/10.3390/ai5030056>
- Buda, M., Maki, A., y Mazurowski, M. A. (2018). A systematic study of the class imbalance problem in convolutional neural networks. *Neural Networks*, 106 249-259.. <https://doi.org/10.1016/j.neunet.2018.07.011>
- COMERCAM. (2023, 17 de mayo). Informe Estadístico 2023. https://comercam-dom.org.mx/wp-content/uploads/2023/05/INFORME-2023_PUBLICO.pdf
- Ferreira, U. E. C., y Camacho, J. M. G. (2021). *Clasificador de red neuronal convolucional para identificar enfermedades del fruto de aguacate (Persea americana Mill.) a partir de imágenes digitales*. *Agrociencia*, 55(8), 695–709. <https://doi.org/10.47163/agrociencia.v55i8.2662>
- García-Mendoza, A. J., y Franco-Martínez, I. S. (2018). *Actualización de la información de las especies y subespecies de magueyes de Oaxaca, con énfasis en las especies mezcaleras: Informe final del Proyecto NE012 [Informe final]*. Instituto de Biología, Universidad Nacional Autónoma de México. <https://es.scribd.com/document/646988484/InfNE012>
- GoodFellow, I., Bengio, Y., y Courville, A. (2016). *Deep Learning*. MIT Press. <https://www.deeplearningbook.org/>
- Guo, W., Li, Y., Zhang, X., Wang, L., Zhang, J., y Xing, G. (2025). Research on classification methods of barley plants based on transfer learning. *INMATEH Agricultural Engineering*, 76(2), 776-785. <https://doi.org/10.35633/inmateh-76-66>
- Hama, H. M., Abdulsamad, T. Sh., y Omer, S. M. (2024). Houseplant leaf classification system based on deep learning algorithms. *Journal of Electrical Systems and Information Technology*, 11(18), 1-15. <https://doi.org/10.1186/s43067-024-00141-5>

- He, K., Zhang, X., Ren, S., y Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778. <https://doi.org/10.48550/arXiv.1512.03385>
- Joloudari, J. H., Marefat, A., Nematollahi, M. A., Oyelere, S. S., y Hussain, S. (2022). Effective Class-Imbalance learning based on SMOTE and Convolutional Neural Networks. *arXiv*. <https://doi.org/10.48550/arXiv.2209.00653>
- Martínez-Jiménez, R., Ruiz-Vega, J., Chávez-Caballero, M., Silva-Rivera, M. E., y Martínez-Bernabé, J. L. (2019). Agaves silvestres y cultivados empleados en la elaboración de mezcal en Sola de Vega, Oaxaca, México. *Revista Mexicana de Ciencias Agrícolas*, 10(6) 1403-1415. <https://doi.org/10.29312/remexca.v10i6.1824>
- Mariles-Flores, V., y Ortiz-Solorio, C. A. (2016). Las clases de tierras productoras de maguey mezcalero en la Soledad Salinas, Oaxaca. *Revista Mexicana de Ciencias Agrícolas*, 7(5) 1199-1210. <https://doi.org/10.29312/remexca.v7i5.246>
- Miftahushudur, T., Sahin, H. M., Grieve, B., y Yin, H. (2025). A Survey of Methods for Addressing Imbalance Data Problems in Agriculture Applications. *Remote Sensing*, 17(3), 1-31. <https://doi.org/10.3390/rs17030454>
- Mookkandi, K., Nath, M. K., Dash, S. S., Mishra, M., y Blange, R. (2025). A Robust Lightweight Vision Transformer for Classification of Crop Diseases. *AgriEngineering*, 7(8), 1-31. <https://doi.org/10.3390/agriengineering7080268>
- Murugan, T. K., Sekar, P., Tolani, K., Sachdeva, A., Jena, S. S., y Jha, A. K. (2025). InceptionFlora: Revolutionizing Plant Species Identification with AI and Deep Learning. En R. C. Poonia, S. Sharma, I. A. Hameed, y K. Upreti (Eds.), *Smart Cyber Physical Systems* (pp. 231-247). Springer Nature. https://doi.org/10.1007/978-981-96-2182-8_18
- Naresh, U., y Reddy, T. (2025). PlantNet: Adaptive DenseNet with Attention-Based Capsule Network for Classifying Plant Diseases with Segmentation Procedures in Agricultural Fields. *International Journal of Image and Graphics*. <https://doi.org/10.1142/S0219467827500653>
- Roy, A., Chakrabarty, S., Mandol, S., Das, S., Prasad, M., Bhowmick, K., Srivastava, S., y Kumar, A. (2024). Distinguishing rice varieties using plant image analysis by deep learning methods. *Indian Journal of Genetics and Plant Breeding*, 84 (4), 532-544. <https://doi.org/10.31742/ISGPB.84.4.3>

- Sánchez, A., Coronel-Lara, Z., Gutiérrez, A., Vargas, G., Coronado, M. L., y Esqueda, M. (2020). Aclimatación y trasplante de vitroplantas de *Agave angustifolia* Haw. En condiciones silvestres. *Revista Mexicana de Ciencias Agrícolas*, 11(7), 1593-1605. <https://doi.org/10.29312/remexca.v11i7.2403>
- Srinivasan, A., V, S., Krishna, S., Reddy, V., & Vengatesh, T. (2025). Deep Learning for Plant Species Classification. *Journal of Neonatal Surgery*, 14, 14-21. <https://doi.org/10.63682/jns.v14i15S.3437>
- Tsai, A., & Kleinman, P.K.(2022). Machine learning to identify distal tibial classic metaphyseal lesions of infant abuse: A pilot study. *Pediatric Radiology*, 52, 1095-1103.<https://doi.org/10.1007/s00247-022-05287-w>
- Vega-López, I., Vega-Aviña, R., Delgado-Vargas, F., Zuriel, E., Morales-Casas, Díaz-Gaxiola, E., Campos-Leal, J. A., Berger-Castro, J., Beltrán-Gutiérrez, G., & Rendón, A. (2023). *Identificación de especies de plantas de la flora mexicana utilizando aprendizaje por transferencia a través de Inception-v4*. 14, 22-37. <http://www.pistaseducativas.itc.mx/wp-content/uploads/2023/12/3-Morales-Casas-Z-E-et-al-22-37.pdf>
- Yue, S., y Wang, T. (2017). *Imbalanced malware images classification: A CNN based approach* (arXiv:1708.08042) [Prepublicación]. arXiv. <https://doi.org/10.48550/arXiv.1708.08042>



Certificado de evaluación

La Editorial UTP, con Registro Nacional de Instituciones y Empresas Científicas y Tecnológicas, por la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI) en México; **indexada en catálogos de calidad internacional**. Que, teniendo como **base fundamental el desarrollo del potencial humano**, es líder en el desarrollo y divulgación de producción científica, tecnológica y educativa con altos estándares de calidad en contextos locales, nacionales e internacionales, a través de publicaciones de artículos en revistas, libros, capítulos de libros, recursos educativos, conferencias y congresos.

CERTIFICA

Que el capítulo de libro titulado “ **Un acercamiento inicial al uso de modelos de clasificación para la identificación de variedades de agave en Oaxaca**” presentado por los autores **Idarh Matadamas, Teodulfo Aquino-Bolaños, Erik Zamora, Manuel de Jesús Melo Monterey y Miriam Emily Avendaño Villegas** ha sido sometido a un exhaustivo proceso de arbitraje por pares académicos, a través de criterios establecidos para investigaciones de alta calidad, siendo dictaminado como producto de investigación científica, tecnológica y/o educativa de alta calidad. Su publicación en el libro titulado “ **Innovación y creatividad: claves para el desarrollo regional**” estará disponible a partir del 9 de diciembre de 2025 en la Biblioteca digital de la Universidad Tecnocientífica del Pacífico.

Se extiende el presente certificado, a los 10 días del mes de noviembre del año 2025.

Transformando con Ciencias
Tepic, Nayarit; México


Dra. Ana Luisa Estrada Esquivel
Directora de la Editorial UTP
Universidad Tecnocientífica del Pacífico


César Alejandro González Guzmán
Coordinador de la Editorial UTP
Universidad Tecnocientífica del Pacífico



Calle 20 de Noviembre, 75 Pte. Col. Mololoa. Tepic, Nayarit, México. C.P. 63050
<https://editorial-utp.com.mx>. Correo electrónico: editorial_utp@tecnocientifica.com.mx. Teléfono: 311 101 01 03