



Ciencia Latina
Internacional

Ciencia Latina Revista Científica Multidisciplinar, Ciudad de México, México.
ISSN 2707-2207 / ISSN 2707-2215 (en línea), septiembre-octubre 2024,
Volumen 8, Número 5.

https://doi.org/10.37811/cl_rcm.v8i5

RECONOCIMIENTO DE FLORES ENDÉMICAS DE LA REGIÓN DE MISANTLA A TRAVÉS DE UNA RED NEURONAL CONVOLUCIONAL USANDO APRENDIZAJE POR TRANSFERENCIA

**RECOGNITION OF ENDEMIC FLOWERS FROM THE
MISANTLA REGION THROUGH A CONVOLUTIONAL
NEURAL NETWORK USING TRANSFER LEARNING**

Galdino Martínez Flores

Tecnológico Nacional de México Campus Instituto Tecnológico Superior de Misantla - México

Irahan Otoniel José Guzmán

Tecnológico Nacional de México Campus Instituto Tecnológico Superior de Misantla - México

Guadalupe Guendulay Escalante

Tecnológico Nacional de México Campus Instituto Tecnológico Superior de Misantla - México

Adrian Basilio López

Tecnológico Nacional de México Campus Instituto Tecnológico Superior de Misantla - México

DOI: https://doi.org/10.37811/cl_rcm.v8i6.15136

Reconocimiento de flores endémicas de la región de Misantla a través de una red neuronal convolucional usando aprendizaje por transferencia

Galdino Martínez Flores¹gmartinezf@itsm.edu.mx<https://orcid.org/0000-0003-4981-8631>Tecnológico Nacional de México Campus
Instituto Tecnológico Superior de Misantla
México**Irahan Otoniel José Guzmán**iojoseg@itsm.edu.mx<https://orcid.org/0000-0001-5336-0198>Tecnológico Nacional de México Campus
Instituto Tecnológico Superior de Misantla
México**Guadalupe Guendulay Escalante**gguendulaye@itsm.edu.mx<https://orcid.org/0009-0008-5626-5741>Tecnológico Nacional de México Campus
Instituto Tecnológico Superior de Misantla
México**Adrian Basilio López**182t0420@itsm.edu.mx<https://orcid.org/0009-0008-8596-8809>Tecnológico Nacional de México Campus
Instituto Tecnológico Superior de Misantla
México

RESUMEN

Las redes neuronales convolucionales (CNN) extraen características relevantes de imágenes para clasificarlas y asignarlas a categorías predefinidas. Se emplea en áreas como la medicina, la seguridad, transporte, sector agrícola, entre otras. En esta investigación se propone desarrollar una aplicación móvil que identifique de manera automática flores endémicas de la región de Misantla mediante estrategias de aprendizaje por transferencia de redes neuronales convolucionales (CNN). Este trabajo es de gran importancia principalmente para el sector turístico y educación básica de esta región del estado de Veracruz. Se reutiliza una fuente de datos (dataset) de flores denominada Flowers Dataset de la plataforma en línea Kaggle y se complementan con imágenes de flores de la región, para que puedan ayudarnos a cumplir con los objetivos de este trabajo de investigación. Los resultados muestran que el modelo obtiene una exactitud variable dependiendo de ciertos elementos que influyen en la calidad de la imagen principalmente condiciones ambientales, algunas pruebas alcanzaron el 88 por ciento como mínimo y el 99 por ciento como máximo.

Palabras clave: aprendizaje por transferencia, redes neuronales convolucionales, aprendizaje automático, reconocimiento de patrones

¹ Autor principal

Correspondencia: gmartinezf@itsm.edu.mx

Recognition of endemic flowers from the Misantla region through a convolutional neural network using transfer learning

ABSTRACT

Convolutional neural networks (CNN) extract relevant features from images to classify them and assign them to predefined categories. It is used in areas such as medicine, security, transportation, agriculture, among others. In this research we propose to develop a mobile application that automatically identifies endemic flowers of the Misantla region using convolutional neural network (CNN) transfer learning strategies. This work is of great importance mainly for the tourism sector and basic education in this region of the state of Veracruz. A dataset of flowers called Flowers Dataset from the online platform Kaggle is reused and complemented with images of flowers from the region, so that they can help us to fulfill the objectives of this research work. The results show that the model obtains a variable accuracy depending on certain elements that influence the quality of the image, mainly environmental conditions, some tests reached 88 percent as a minimum and 99 percent as a maximum.

Keywords: transfer learning, convolutional neural networks, machine learning, pattern recognition

*Artículo recibido 19 octubre 2024
Aceptado para publicación: 28 noviembre 2024*



INTRODUCCIÓN

La inteligencia artificial en diversos sectores es cada vez más utilizada. En el sector agrícola destacan principalmente los sistemas de reconocimiento a través de visión artificial. En la revisión bibliográfica se han encontrado investigaciones para reconocimiento de frutos, cereales, flores, tipos de bosques, árboles entre otros. Estas investigaciones emplean principalmente redes neuronales artificiales y principalmente redes neuronales convolucionales que se basan en aprendizaje por transferencia, debido a que han dado mejores resultados para el reconocimiento de patrones.

T. Saitoh and T. Kaneko (2000), en su investigación denominada "reconocimiento automático de flores silvestres a través de una red neuronal". Eligieron 17 características por cada tipo de flor; 8 de flor y 9 de hojas de la flor. A cada tipo de flor se le tomó una foto frontal y una foto a la hoja. Recopilaron 20 pares de fotografías de 16 flores silvestres. Obtuvieron una tasa de reconocimiento del 95% con las 17 características descubrieron que cuatro características de las flores y dos características de las hojas pueden producir 96% de precisión.

Yang, C. C. et al. (2000) desarrollaron un trabajo de investigación cuyo objetivo fue diferenciar plantas de maíz jóvenes de la maleza de un cultivo mediante imágenes. Utilizaron una base de datos de 40 imágenes de maíz y 40 imágenes de maleza para entrenamiento y 20 imágenes para prueba de eficiencia de la Red Neuronal Artificial. Alcanzaron una tasa del 100% para reconocer plantas de maíz y un 80% para reconocer maleza. Concluyen que un sistema de reconocimiento de malezas puede usarse en la fumigación precisa de herbicidas en campos agrícolas.

Savakar, D. G., & Anami, B. S. (2009) en su trabajo de investigación para reconocer y clasificar cereales, frutas y flores comestibles mediante visión artificial, proponen un clasificador basado en Back Propagation Neural Network (BPNN). Extraen características como el color, la textura y características morfológicas para reconocer y clasificar los diferentes productos agrícolas/hortícolas. Los resultados muestran que mediante la textura la BPNN obtiene mejores resultados. Esto debido a que las precisiones promedio aumentaron al 94,1%, 84,0% y 90,1% para los cereales alimentarios, los mangos y las flores de jazmín, respectivamente.

En el 2016, Morales, V. A., Rodríguez, L. A., Ortega, L. & Mejía, J. M. desarrollaron una aplicación móvil que identifica plantas cetáceas de la región de Chihuahua. Aplican diversas operaciones de

preprocesamiento de la imagen para adquirir ciertas características de ella. El sistema de reconocimiento tiene un 90 por ciento de precisión cuando la fotografía abarca una parte de la flor, un 60 por ciento cuando la fotografía abarca la flor completa y un 20 por ciento de efectividad cuando la foto es tomada a un metro de distancia.

Y. Liu et al. (2016) desarrollaron un proyecto cuyo objetivo era clasificar flores mediante una CNN. Utilizaron imágenes de la base de datos Oxford-102 que contiene 102 especies de flores con un total de 8189 cada especie contiene entre 20 y 200 imágenes. Su modelo logra una precisión de clasificación del 84,02 por ciento.

Gavai, N.R. et al. (2017) utilizaron una Red Neuronal convolucional (CNN) para clasificar flores basándose en el modelo MobileNet. Emplearon el Dataset Oxford de 102 especies de imágenes. Cada especie contiene de 40 a 258 imágenes. Concluyen que CNN MobileNet son optimizadas al ser pequeñas y eficientes pero comprometen la precisión del modelo.

En el proyecto “Sistema de reconocimiento de especies de flores usando CNN y aprendizaje por transferencia”, se observa que, una CNN combinado con el enfoque de transferencia de ganancias como extractor de características supera a toda la extracción de características artesanal métodos como patrón binario local (LBP), estadísticas de canal de color, histogramas de color, textura Haralick, momentos Hu y Momentos Zernike (Gogul, I., & Kumar, V. S., 2017).

H. S. Abdullahi et al. (2017) diseñaron una red neuronal convolucional para identificar plantas sanas, parcialmente sanas y enfermas. Se utilizó un Dataset de 1922 imágenes de los cuales 861 eran de plantas sanas, 478 de plantas parcialmente sanas y 578 de enfermas. Los resultados experimentales en el modelo desarrollado arrojaron resultados con una precisión promedio del 99.58 por ciento.

V.D. Prasad et al. (2017) desarrollaron varias redes neuronales convolucionales (CNN) para clasificar flores mediante imágenes. Utilizaron un dataset de 9500 imágenes para la experimentación misma que fue subdividida en cuatro partes. Diseñaron y probaron varias arquitecturas de CNN con el objetivo de encontrar mejores porcentajes de reconocimiento. El mejor modelo alcanzó un 97.78 por ciento de efectividad.

Wu, Y. et al. (2018), crean un modelo de clasificación usando una red neuronal convolucional (CNN) y aprendizaje por transferencia, reutilizan la base de datos de imágenes de flores Oxford-17. Emplearon

los modelos VGG-16, VGG-19, Inception-v3 y ResNet50 para comparar el modelo de inicialización de red con el modelo de aprendizaje por transferencia. Los resultados muestran que el aprendizaje por transferencia puede evitar eficazmente que las redes convolucionales profundas sean propensas a problemas óptimos locales y problemas de sobreajuste.

Muñoz Villalobos, I., & Bolt, A. (2022) desarrollaron una aplicación móvil que clasifica flora nativa chilena mediante una red neuronal convolucional. El modelo de reconocimiento diseñado es capaz de clasificar especies correctamente con un 95 por ciento de probabilidad. Utilizaron un dataset de 6775 imágenes de muestra. En su trabajo mencionan que el porcentaje de precisión alcanzado coincide con lo mencionado en el estado del arte sobre visión artificial.

Khaoula Labrighli et al. (2022) realizaron una revisión bibliográfica sobre identificación automatizada de especies de plantas mediante inteligencia artificial. Revisaron 37 artículos de los cuales 15 utilizaron aprendizaje automático y 22 investigaciones se basados en Deep learning. El principal resultado de esta síntesis es que el rendimiento de los modelos avanzados de aprendizaje profundo se está acercando a la experiencia humana más avanzada. Sin embargo, mencionan que quedan varios desafíos fundamentales a resolver para lograr el diseño de un sistema de este tipo de manera eficiente.

Campos-Leal, Juan A. et al. (2023) diseñaron varios modelos de redes neuronales artificiales para clasificar especies de plantas. Algunos modelos fueron diseñados desde cero por ellos y otros utilizan estrategias de aprendizaje por transferencia. Los dataset de imágenes utilizados fueron Oxford 102 Flower donde contiene especies de plantas en su hábitat natural y un subconjunto de PlantCLEF2020 como un conjunto de especies de plantas en un ambiente controlado. El primero contiene 8,189 imágenes de flores que corresponden a 102 especies de plantas que pueden ser encontradas en Reino Unido y el segundo contiene 10 especies de plantas con 100 imágenes por cada especie sumando un total de 1000. Finalmente concluyen que los modelos que utilizan estrategias de aprendizaje por transferencia obtiene mejores desempeños que aquellos modelos entrenados desde cero.

Vega-López, Inés et al. (2023) en su trabajo de investigación construyeron un modelo de clasificación a partir de la arquitectura de Inception-v4 usando un conjunto de datos de vegetación nativa de México. Destaca la creación de una base de datos de 17 900 imágenes de 202 especies flora nativa de México. En concreto, se evaluó Inception-v4 y se contrastó su desempeño contra AlexNet, VGG-16 y VGG-19.

Los resultados experimentales fueron ratificados con el método de validación cruzada de k-iteraciones. Los resultados experimentales muestran que las estrategias de aprendizaje por transferencia y el aumento de datos mejoran sustancialmente el desempeño de modelos basados en el aprendizaje profundo. En particular, para Inception-v4 con una tasa de aciertos de 86.97 y 94.39 %.

Finalmente se observa, que se existe la oportunidad de crear una base de datos de flores endémicas de la región de Misantla y una aplicación móvil para el reconocimiento automático de ellas.

METODOLOGÍA

Modelo

La plataforma de entrenamiento utilizada para entrenar el clasificador de imágenes personalizado es la máquina de enseñanza con Google, Teachable Machine (Teachable Machine, 2017). Esta es una plataforma utilizada para el proceso de entrenamiento de aprendizaje profundo.

Requerimientos


- Conjunto de datos de imágenes agrupados en diferentes clases.
- Android Studio 3.2 + (instalado en una máquina Linux, Mac o Windows).
- Dispositivo Android en modo desarrollador con depuración USB habilitada.
- Un cable USB (para conectar el dispositivo Android a la computadora).

Procedimiento

En la figura 1 se muestra la metodología utilizada.

1. Cargar el dataset de entrenamiento.
2. Entrenar el modelo de red neuronal.
3. Exportar el modelo en el formato seleccionado.
4. Asignar metadatos y descargar el modelo.


Figura 1. Metodología Clasificador Flores



Cargar el dataset de entrenamiento


En este proyecto se reutilizó Flowers Dataset. Éste contiene cinco tipos de flores entre ellas margaritas, diente de león, rosas, girasoles y tulipanes (Sparsh Gupta, 2020). El conjunto de datos de entrenamiento se complementó con imágenes de flores capturadas en la región de Misantla. Figura 2.

Figura 2. Dataset flores



Se clasifican las flores en carpetas de acuerdo con el tipo de flor. En Teachable Machine se cargan las imágenes, asignándoles una etiqueta que corresponde al nombre de la flor que corresponda como se muestra en la figura 3.

Figura 3. Flores etiquetadas




Más imágenes de flores significa mejores resultados en la clasificación, es importante que cada imagen de flor se encuentre almacenada en la carpeta del tipo de flor que le corresponda, en caso contrario se pueden generar errores en la clasificación.

Entrenar el modelo de red neuronal


En la figura 4 se observa la configuración de la red neuronal convolucional, se pueden ajustar los hiperparámetros número de épocas, tamaño del lote y Tasa de aprendizaje.

Figura 4. Configuración modelo



Se verifican los resultados del entrenamiento, en la figura 5 se presenta un ejemplo de este proceso.

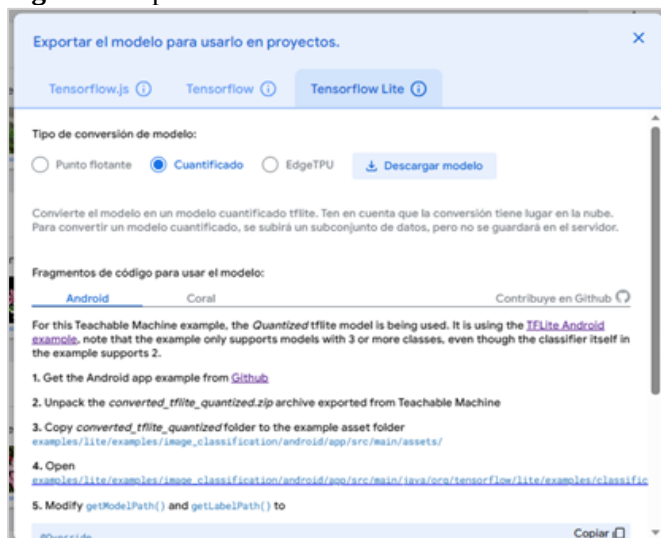
Figura 5. Vista previa de entrenamiento



Exportar el modelo en el formato seleccionado convolucional.

Después de comprobar que los resultados fueron óptimos, se exporta el modelo. Es necesario que el modelo se exporte como TensorFlow Lite y de tipo Cuantificado para que funcione en un entorno de aplicación móvil, en la figura 6 se observan la elección de estas opciones.

Figura 6 Exportación del modelo



Asignación de metadatos y descarga del modelo.

Dentro del modelo las clases se agregan los metadatos de todos los modelos de la aplicación de clasificación de imágenes de muestra. Agregar metadatos al modelo TFLite para adjuntar las clases y demás información necesaria.

Este procedimiento se realiza dentro de un documento de Colab de Google.

Paso 1) Crear una carpeta en google drive con metadatos con nombre

Cree otra carpeta llamada model_with_metadata dentro de la carpeta de metadatos.

Paso 2) Montar la unidad y navegar a la carpeta de metadatos

```
#mount drive
```

```
%cd ..
```

```
from google.colab import drive
```

```
drive.mount('/content/gdrive')
```

```
# this creates a symbolic link so that now the path /content/gdrive/My\ Drive/ is equal to /mydrive
```

```
!ln -s /content/gdrive/My\ Drive/ /mydrive
```

```
# list the contents of /mydrive
```

```
!ls /mydrive
```

```
#Navigate to /mydrive/metadata
```

```
%cd /mydrive/metadata
```

Paso 3) Cargar los siguientes 3 archivos a la carpeta de metadatos

1. metadata_writer_for_image_classifier.py

2. model.tflite & all other models

3. labels.txt

Paso 4) instalar el soporte tflite.

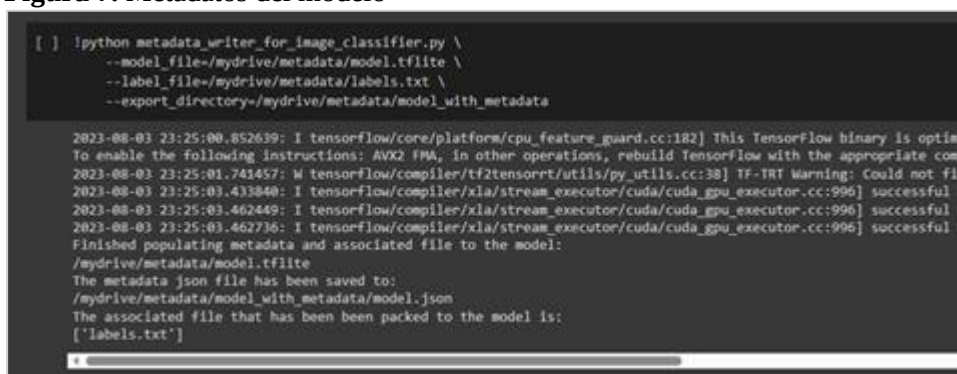
pip install tflite-support

Paso 5) finalmente, se ejecuta el script de python usando el siguiente comando.

```
!python metadata_writer_for_image_classifier.py \
--model_file=/mydrive/metadata/model.tflite \
--label_file=/mydrive/metadata/labels.txt \
--export_directory=/mydrive/metadata/model_with_metadata
```

El modelo TFLite con metadatos se crea dentro de la carpeta model_with_metadata junto con el archivo .json. El resultado de la asignación de metadatos al modelo se observa en la figura 7:

Figura 7. Metadatos del modelo



```
[ ] !python metadata_writer_for_image_classifier.py \
--model_file=/mydrive/metadata/model.tflite \
--label_file=/mydrive/metadata/labels.txt \
--export_directory=/mydrive/metadata/model_with_metadata

2023-08-03 23:25:00.852639: I tensorflow/core/platform/cpu_feature_guard.cc:182] This TensorFlow binary is optimized
To enable the following instructions: AVX2 FMA, in other operations, rebuild TensorFlow with the appropriate compiler flags
2023-08-03 23:25:01.741457: W tensorflow/compiler/tf2tensorrt/utils/py_utils.cc:38] TF-TRT Warning: Could not find TensorRT
2023-08-03 23:25:03.433848: I tensorflow/compiler/xla/stream_executor/cuda/cuda_gpu_executor.cc:996] successful
2023-08-03 23:25:03.462449: I tensorflow/compiler/xla/stream_executor/cuda/cuda_gpu_executor.cc:996] successful
2023-08-03 23:25:03.462736: I tensorflow/compiler/xla/stream_executor/cuda/cuda_gpu_executor.cc:996] successful
Finished populating metadata and associated file to the model:
/mydrive/metadata/model.tflite
The metadata json file has been saved to:
/mydrive/metadata/model_with_metadata/model.json
The associated file that has been packed to the model is:
['labels.txt']
```


Para integrar el proyecto de Android / Kotlin en Android Studio se realiza lo siguiente. Se descarga la aplicación de muestra que proporciona TensorFlow para la clasificación de imágenes, se puede elegir entre la versión de Java o de Kotlin.

Se copia el modelo de TFLite generado con metadatos dentro de la carpeta de assets del proyecto como se muestra en la figura 8.

La ruta es la siguiente:

(nombre_proyecto)\app\src\main\assets

Figura 8. Integración del proyecto



Nombre	Fecha de modificación	Tipo
efficientnet-lite0.tflite	03/08/2023 01:42 p. m.	Archiv
efficientnet-lite1.tflite	03/08/2023 01:43 p. m.	Archiv
efficientnet-lite2.tflite	03/08/2023 01:43 p. m.	Archiv
mobilenetv1.tflite	03/08/2023 01:42 p. m.	Archiv
model.tflite	03/08/2023 05:25 p. m.	Archiv

Las figuras 9 y figura 10 se presenta el modelo en el proyecto de Android:

Figura 9. Modelo Android




Figura 10. Modelo Android

```
val modelName :String =
    when (currentModel) {
        MY_CUSTOM_MODEL -> "model.tflite"
        MODEL_MOBILENETV1 -> "mobilenetv1.tflite"
        //MODEL_EFFICIENTNETV0 -> "efficientnet-lite0.tflite"
        //MODEL_EFFICIENTNETV1 -> "efficientnet-lite1.tflite"
        //MODEL_EFFICIENTNETV2 -> "efficientnet-lite2.tflite"
        else -> "mobilenetv1.tflite"
    }
```

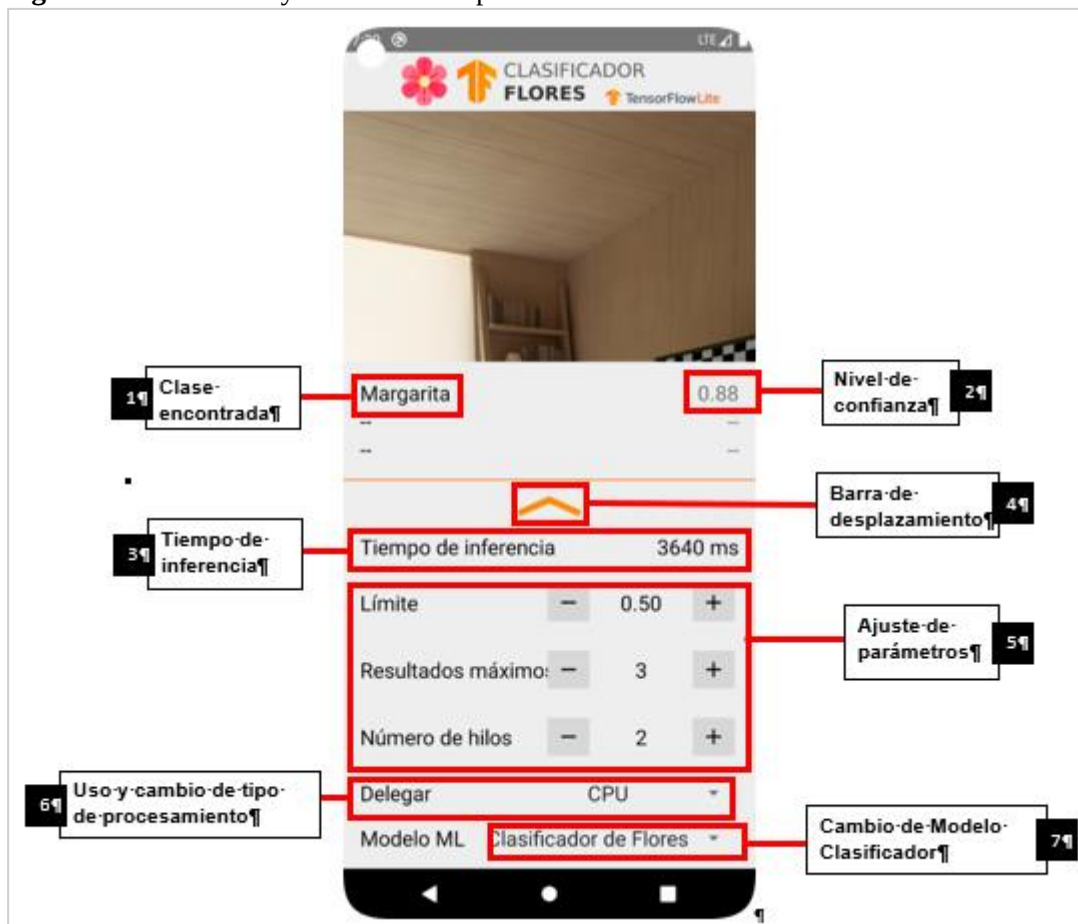
Finalmente se importa el modelo desde el dispositivo para su instalación y uso.

RESULTADOS

Esta versión es para dispositivos Android, no consume recursos de red o internet. La aplicación solicita conceder los permisos de acceso a la cámara, una vez autorizado todos estos se muestra la interfaz principal Figura 11 con todas las funciones que ayudan a ajustar el modelo y los resultados que pueden obtener y visualizar.

Se detallan las características de la aplicación para su configuración y manipulación:

Figura 11. Parámetros y detalles de la aplicación



Descripción de las características de la aplicación que el usuario puede configurar:

1. **Clase encontrada:** Corresponde al tipo de clase o de “Flor” que el modelo de TensorFlow logró identificar en base a lo que capta la cámara del dispositivo.
2. **Nivel de confianza:** Indica el nivel de precisión o de certeza sobre la clase que encontró. Ejemplo: 0.88 = 88% de precisión, certeza o confianza de que la clase que corresponde a la flor de “Margarita” es acertada.
3. **Tiempo de inferencia:** Corresponde al tiempo de respuesta que tarda en dar la aplicación, desde que capta la imagen con la cámara hasta que el modelo identifica la clase y devuelve el resultado. El tiempo de inferencia varía de la capacidad de procesamiento del dispositivo.
4. **Barra de desplazamiento:** Muestra o oculta las opciones y parámetros de la aplicación de TensorFlow, deslizando la pestaña hacia arriba o abajo.
5. **Ajuste de parámetros:** En este apartado tenemos 3 parámetros que nos permiten ajustar los resultados que obtenemos del modelo.

- **Límite:** Es posible limitar el nivel de confianza del modelo, en este caso para el modelo que se usa no influye.
 - **Resultados máximos:** Corresponde al número de resultados que queremos obtener por parte del modelo, en este caso el modelo solo da como resultado un resultado a la vez por clasificación.
 - **Números de hilos:** Corresponde a los hilos de procesamiento para obtener mayores resultados o asignar un mayor o menor procesamiento al modelo.
6. **Delegar:** Dependiendo las características de hardware del equipo es posible elegir que procesamiento usar para aplicación, si da uso al CPU o a la GPU del equipo si es que cuenta con uno, teniendo en cuenta que se ejecuta desde un dispositivo móvil la aplicación. De ser el caso se usará la GPU y si esta no es compatible con la aplicación se mostrará un mensaje de advertencia.
7. **Modelo ML:** Para TensorFlow Lite en dispositivos móviles, es posible cargar más de un modelo que nos podría brindar diferentes tipos de reconocimientos, análisis y resultados. En este caso se encuentran los modelos por defecto más el modelo del clasificador de flores.

CONCLUSIONES

La utilización de la tecnología para reconocimiento de patrones es un tema de la inteligencia artificial y el aprendizaje automático muy utilizado y con excelentes resultados, sin embargo, aplicarla para reconocer flores endémicas de la región de Misantla es una oportunidad para diseñar herramientas que fomenten el conocimiento de esta área. El resultado de este trabajo de investigación es una aplicación móvil para el sistema operativo Android. Se utilizó La plataforma Teachable Machine de Google para entrenar el clasificador mediante aprendizaje profundo. Los modelos preentrenados ayudan a mejorar los porcentajes de exactitud para clasificar correctamente. El modelo de clasificación de flores generado en esta investigación alcanzó un porcentaje de clasificación del 99 por ciento. Esta herramienta es útil y de gran impacto en turistas que visitan esta región así como niños estudiando la educación preescolar y primaria para conocer las plantas que florecen en esta zona geográfica. Finalmente es importante mencionar que como trabajo futuro se debe integrar la base de datos de todas las flores endémicas de la región de Misantla, Veracruz, México.

REFERENCIAS BIBLIOGRÁFICAS

- Campos-Leal, Juan A & Vega-López, Inés & Beltrán-Gutiérrez, Gerardo & López Arellano, José & Rendón, Arturo. (2023). La inteligencia artificial como apoyo en la identificación de especies de plantas.
- Gavai, N.R., Jakhade, Y.A., Tribhuvan, S.A., & Bhattad, R. (2017). MobileNets for flower classification using TensorFlow. *2017 International Conference on Big Data, IoT and Data Science (BIGDATA)*, 154-158. <https://doi.org/10.1109/BIGDATA.2017.8336590>
- Gogul, I., & Kumar, V. S. (2017). Flower species recognition system using convolution neural networks and transfer learning. *2017 Fourth International Conference on Signal Processing, Communication and Networking (ICSCN)*. doi:10.1109/icscn.2017.8085675.
- H. S. Abdullahi et al. (2017). "Convolution neural network in precision agriculture for plant image recognition and classification". *2017 Seventh International Conference on Innovative Computing Technology (INTECH)*, Luton, UK, pp. 1-3, doi: 10.1109/INTECH.2017.8102436.
- Khaoula Labrighli, Chouaib Moujahdi, Jalal El Oualidi and Laila Rhazi, "Artificial Intelligence for Automated Plant Species Identification: A Review" *International Journal of Advanced Computer Science and Applications (IJACSA)*, 13(10), 2022.
<http://dx.doi.org/10.14569/IJACSA.2022.0131097>
- Maria-Elena Nilsback and Andrew Zisserman (2008). Automated Flower Classification over a Large Number of Classes. *Indian Conference on Computer Vision, Graphics and Image Processing*.
<https://www.robots.ox.ac.uk/~vgg/publications/2008/Nilsback08/nilsback08.pdf>
- Morales, V. A., Rodríguez, L. A., Ortega, L. & Mejía, J. M. (2016). Aplicación móvil para la identificación de plantas semidesérticas ubicadas en el norte del estado de Chihuahua. Tesis de Licenciatura. Universidad Autónoma de Ciudad Juárez. <http://hdl.handle.net/20.500.11961/2885>.
- Muñoz Villalobos, I., & Bolt, A. (2022). Diseño y desarrollo de aplicación móvil para la clasificación de flora nativa chilena utilizando redes neuronales convolucionales. *AtoZ: novas práticas em informação e conhecimento*, 11, 1 - 13. doi: <http://dx.doi.org/10.5380/atoz.v11i0.81419>
- Sparsh Gupta (2020). Flowers Dataset. [Dataset]. <https://www.kaggle.com/datasets/imsparsh/flowers-dataset/data>



- Savakar, D. G., & Anami, B. S. (2009). Recognition and Classification of Food Grains, Fruits and Flowers Using Machine Vision. *International Journal of Food Engineering*, 5(4). doi:10.2202/1556-3758.1673.
- Teachable Machine (2017). Prepara a un ordenador para que reconozca tus imágenes, sonidos y posturas. Recuperado en 04 de agosto de 2023 de <https://teachablemachine.withgoogle.com/>.
- T. Saitoh and T. Kaneko, "Automatic recognition of wild flowers," *Proceedings 15th International Conference on Pattern Recognition. ICPR-2000, Barcelona, Spain, 2000*, pp. 507-510 vol.2, doi: 10.1109/ICPR.2000.906123.
- Vega-López, Inés & Vega-Aviña, Rito & Delgado-Vargas, Francisco & Zuriel, Ernesto & Morales-Casas, & Díaz-Gaxiola, Eduardo & Campos-Leal, Juan A & Berger-Castro, José & Beltrán-Gutiérrez, Gerardo & Rendón, Arturo. (2023). Identificación de especies de plantas de la flora mexicana utilizando aprendizaje por transferencia a través de Inception-v4. 14. 22-37.
- V.D. Prasad, M., JwalaLakshamma, B., Hari Chandana, A., Komali, K., V.N. Manoja, M., Rajesh Kumar, P., Raghava Prasad, C., Inthiyaz, S., & Sasi Kiran, P. (2017). An efficient classification of flower images with convolutional neural networks. *International Journal of Engineering & Technology*, 7(1.1), 384-391. <https://doi.org/10.14419/ijet.v7i1.1.9857>.
- Wu, Y., Qin, X., Pan, Y., & Yuan, C. (2018). Convolution Neural Network based Transfer Learning for Classification of Flowers. 2018 IEEE 3rd International Conference on Signal and Image Processing (ICSIP). doi:10.1109/siprocess.2018.8600536.
- Yang, C. C., Prasher, S. O., Landry, J. A., & DiTommaso, A. (2000). Application of artificial neural networks in image recognition and classification of crop and weeds. *Canadian agricultural engineering*, 42(3), 147-152. https://library.csbe-scgab.ca/docs/journal/42/42_3_147_raw.pdf.
- Y. Liu, F. Tang, D. Zhou, Y. Meng and W. Dong, "Flower classification via convolutional neural network," 2016 IEEE International Conference on Functional-Structural Plant Growth Modeling, Simulation, Visualization and Applications (FSPMA), Qingdao, China, 2016, pp. 110-116, doi: 10.1109/FSPMA.2016.7818296.