

## Aplicación móvil para la identificación de variedades de *Manihot esculenta* Crantz cultivadas en Misiones mediante técnicas de deep learning

Javier Berger<sup>1</sup>, Alejandro Tamada<sup>2</sup>, and Rafael Feltan<sup>3</sup>

<sup>1</sup> Universidad Nacional de Misiones, Facultad de Ciencias Exactas, Químicas y Naturales  
Félix de Azara N° 1552, Posadas (3300), Misiones, Argentina  
javiberger@gmail.com

<sup>2</sup> Universidad Gastón Dachary,  
Salta N° 1912, Posadas (3300), Misiones, Argentina  
alejandrok86@gmail.com

<sup>3</sup> Instituto Nacional de Tecnología Agropecuaria, Agencia Extensión Rural Santo Pipó  
Avda. José de San Martín (3328) Santo Pipó Misiones, Argentina  
feltan.rafael@inta.gob.ar

**Resumen.** El cultivo de *Manihot esculenta* Crantz, conocida popularmente en la provincia de Misiones como mandioca, es muy importante ya que el aporte de hidratos de carbono de sus raíces complementa la canasta familiar, asimismo el requerimiento por parte de la industria de la raíz de la mandioca se incrementa día a día gracias al uso de la fécula de mandioca en la elaboración de productos aptos para celíacos. En Misiones se cultivan distintas variedades de mandioca, cada una de estas posee cualidades que la hacen aptas para distintos fines. A simple vista las plantas de mandioca son similares para todas las variedades, pero los expertos del Instituto Nacional de Tecnología Agropecuaria de Misiones se encuentran trabajando en la generación de un registro único de variedades que sirva como guía para los productores. En este trabajo se plantea el uso de técnicas de *deep learning* para identificar mediante una imagen de la hoja o del tallo de una planta de mandioca la variedad correspondiente. Para esto se desarrolló una aplicación móvil utilizando el modelo de aprendizaje por transferencia MobileNet con Tensorflow, mediante la misma se logró clasificar de manera correcta el 92 % de las imágenes de tallos y el 81 % de imágenes de hojas de mandioca.

### 1 Introducción

La mandioca (*Manihot esculenta* Crantz) es un arbusto perenne originario de América Tropical que se cultiva en varias regiones de África, América y Asia, se adapta a suelos pobres y ácidos, es tolerante a sequías y constituye el alimento principal para trecientos millones de personas [1]. En Argentina, específicamente en la región noreste (NEA), comprendida por las provincias de Chaco, Corrientes, Formosa y Misiones se concentra la producción de mandioca del país, con una superficie implantada que alcanza las 40.000 ha.

La provincia de Misiones es la principal productora de mandioca de Argentina, en la misma se concentra el 62,5 % de la superficie implantada del país [2]. Este cultivo posee un valor comercial importante ya que las raíces, ricas en almidón, forman parte de muchas de las recetas que se consumen diariamente en las mesas familiares misioneras. Por otra parte, las hojas y ramas se utilizan como alimento económico para el consumo animal, principalmente ganado. Asimismo, las raíces se utilizan en la industria como materia prima para la extracción de fécula de mandioca o almidón, ingrediente principal de la tradicional chipa misionera y producto fundamental en recetas de alimentos aptos para celíacos por la ausencia de gluten [3].

Los diversos usos mencionados de la mandioca y la facilidad de producción provocaron que el cultivo de la misma se extienda a todos los departamentos de la provincia de Misiones, es así que con el correr de los años se distribuyeron entre productores distintas variedades o cultivares provenientes de otras regiones productoras sin conocer fehacientemente las cualidades de cada variedad. Entre los productores es habitual que las variedades se identifiquen mediante el nombre de las personas que las distribuyeron o por características fenotípicas de la planta como el tamaño y el color, ésta situación provoca que existan distintos nombres para identificar una misma variedad [4] [5].

La falta de identificación fehaciente de las variedades de mandioca provoca que se desconozcan datos importantes del cultivar como es la susceptibilidad a enfermedades, el ritmo de crecimiento, la concentración de almidón en las raíces, los rindes por hectáreas de cultivo, la calidad de las estacas o semillas y en relación al consumo humano el sabor, el aspecto y el tiempo de cocción de las raíces [4]. En este sentido, investigadores del Instituto Nacional de Tecnología Agropecuaria (INTA) se encuentran desarrollando un registro único de las variedades de mandioca cultivadas en Misiones que integra información genética y morfológica de las plantas [6]. Este registro es la base fundamental para asesorar a los productores sobre qué variedades cultivar en función del mercado al que destinan la producción.

La identificación de una variedad de mandioca se puede realizar mediante análisis morfológico en función de las formas de las distintas partes de la planta; fisiológico a partir de la forma de crecimiento; organoléptico a partir de información sensorial y; mediante análisis genético [6]. Entre las formas de identificación de cultivares la que habitualmente utilizan los productores es la morfológica, ésta requiere de suficiente experiencia para observar las características relevantes de las hojas, ramas y raíces que identifican a una variedad. La existencia de cultivares que tienen características semejantes y el uso de nombres duplicados para una misma variedad hacen que la tarea de identificación sea compleja, por estas razones es frecuente que los productores recorran varios kilómetros hasta las sedes del INTA con muestras de raíces, ramas y hojas con el objetivo de que un experto realice la identificación.

Los inconvenientes a la hora de identificar las variedades de un cultivo no se limitan sólo a la producción de mandioca, existen cientos de investigaciones que abordan el mismo problema, muchas de éstas son recientes, ya que en las mismas se utilizan sistemas de visión artificial que mediante el uso de imágenes de ciertas partes de las plantas permiten identificar con resultados excelentes las variedades de un cultivo. Ejemplos de esto son la clasificación de variedades de papa [7], de trigo [8], de cebada [9], de ciruelo japonés [10], de guaraná [11], de canola [12] y de flores de petunia [13]. En

relación al cultivo de mandioca existen distintos desarrollos que utilizan visión artificial, pero están destinados a la identificación de enfermedades, no a la identificación de variedades. Entre éstos se encuentra la aplicación de métodos de *deep learning* para detectar enfermedades en las hojas [14], el uso de dispositivos móviles para capturar imágenes de hojas y obtener un índice de severidad vinculado a distintas enfermedades mediante métodos de *machine learning* [15], el diagnóstico de la enfermedad del mosaico evaluando diferentes métodos de clasificación y analizando imágenes en función de las características de la forma y el color de hoja [16] y el reconocimiento de síntomas de la enfermedad mancha marrón en función del color basado en redes neuronales artificiales e imágenes de las hojas [17].

Los sistemas de visión artificial utilizados en las investigaciones mencionadas se encargan de la adquisición, el procesamiento y la clasificación de imágenes de cultivos que se adquieren mediante dispositivos ópticos, como cámaras digitales o escáneres y se procesan con el objetivo de extraer las características relevantes de las partes de la planta que permiten diferenciar las variedades. La identificación de las variedades, en función de las características relevantes de la planta, se puede realizar mediante distintas técnicas de inteligencia artificial, entre éstas, se destacan las redes neuronales artificiales que simulan el proceso de aprendizaje humano por lo que necesitan ser entrenadas con imágenes de ejemplo de las variedades para que, posteriormente, reconozca las características aprendidas en nuevas imágenes, generando sistemas de aprendizaje automático o *machine learning* [18]. La evolución del *machine learning* generó nuevos métodos de adquisición de conocimiento englobadas dentro del aprendizaje profundo o *deep learning*, estos métodos tienen la capacidad de identificar automáticamente las características discriminantes de las imágenes utilizando varias capas de redes neuronales artificiales [19].

En función de las dificultades mencionadas sobre la identificación de las variedades de mandioca cultivadas en Misiones y a partir de los excelentes resultados obtenidos en la identificación de variedades de otros cultivos utilizando sistemas de visión artificial se plantea en este trabajo el desarrollo de un prototipo de sistema de visión artificial que utilice técnicas de *deep learning* y se ejecute en dispositivos móviles para identificar las variedades de mandioca cultivadas en Misiones mediante fotografías de hojas y/o tallos capturadas con la cámara del móvil. El prototipo se constituye como una herramienta de cooperación para los expertos del INTA que se encuentran trabajando en el registro único de variedades de mandioca, además es una alternativa de identificación de bajo costo, fácil instalación, que no requiere de internet para funcionar y que permite a los productores identificar en segundos las variedades de mandioca que cultivan.

El artículo continúa con la sección 2 donde se describen las características relevantes de la planta de mandioca y las variedades cultivadas por los productores misioneros. En la sección 3 se introducen los conceptos relacionados con *deep learning* que son la base para el desarrollo del prototipo de sistema de visión artificial para la clasificación de las variedades de mandioca. En la sección 4 se detallan los recursos empleados, las pruebas que se realizaron de la solución propuesta y los resultados que se obtuvieron. En la última sección se resumen las conclusiones y se presentan propuestas de trabajos futuros.

## 2 Cultivo de mandioca en Misiones

El arbusto perenne que se observa en la Fig. 1 se denomina *Manihot esculenta* Crantz y se conoce con el nombre de mandioca en Argentina y Paraguay, en Brasil como macaxeira o aipim, en los países de América Central como yuca y en países de habla inglesa como cassava [4]. La mandioca se cultiva en regiones tropicales del mundo en las que se encuentran las condiciones ideales para su producción, que son: temperaturas anuales que oscilan entre 20 °C y 27 °C, precipitaciones anuales de entre 600 mm y 2000 mm y, suelos de diferentes tipos como los francos arenosos o arcillosos [1].



Fig. 1: Planta de mandioca. Fuente: [1]

La mandioca se propaga mediante las estacas-semillas que se obtienen de los tallos o ramas. En Misiones la recolección y almacenamiento de las ramas se realiza a partir el mes de junio cuando las plantas ya se encuentran sin hojas [20]. Finalizadas las heladas y en el período que comprende finales de agosto y finales de octubre se siembran las ramas almacenadas como estacas-semillas. La raíz de la mandioca se cosecha desde el mes de marzo hasta principios de agosto, la misma es rica en hidratos de carbono por lo que aporta energía al igual que el maíz, la caña de azúcar o el arroz, convirtiéndola en el alimento de consumo básico de más de trescientos millones de personas [1].

En Misiones se cultivan distintas variedades de mandioca, que según el cultivar se utilizan para consumo humano, elaboración industrial de fécula o consumo animal. En la Tabla 1, se observan las variedades identificadas por los expertos del INTA y que son objeto de estudio para este trabajo.

Tabla 1: Variedades de mandioca cultivadas en Misiones registradas por el INTA

Código	Nombre	Uso
1	Paraguaya Cerro Azul	Consumo humano
3	Ramaceda Chaco	Industria
6	Amarilla Marcelo	Industria
9	Amarilla Cerro Azul	Consumo humano
10	Amarilla Molina	Forraje, consumo animal
12	IAC 90	Industria
16	Rocha	Consumo humano
37	Verde Oliva	Consumo humano
40	Roja Pulpa Amarilla	Forraje, consumo animal

La forma habitual de identificación de las variedades de mandioca por parte de los productores misioneros es mediante la observación de las características morfológicas de las hojas y del tallo, esta tarea es compleja ya que requiere tener en cuenta la combinación de varias características. Las características diferenciadoras de las variedades que se deben observar en las hojas son el color de las mismas que puede ser verde, verde marrón o verde claro; la forma de los lóbulos que componen la lámina foliar que puede ser ovoide, elíptica, lanceolada, recta, pandurada o lineal pandurada y; el color del peciolo que puede ser rojo, rojo verdoso, verde rojizo y verde. Por otra parte, las características diferenciadoras de las variedades que se deben observar en el tallo o rama son el grosor del mismo y el color, que puede ser rojo claro, rojo oscuro, marrón, verde oscuro, verde claro o amarillo [21].

### 3 Deep Learning

El aprendizaje automático o *machine learning* es el subcampo dentro de la inteligencia artificial que mayor crecimiento alcanzó en los últimos años promovido por los avances obtenidos en el uso de técnicas de aprendizaje profundo o *deep learning* [19]. Estas técnicas impulsaron el desarrollo de soluciones de visión artificial a partir de la eficiencia en la clasificación y en la generación automática de características relevantes de las imágenes que posee la arquitectura de las redes profundas de convolución [22].

A los avances antes mencionados se sumó el lanzamiento de librerías destinadas al desarrollo de sistemas de visión artificial utilizando técnicas de *deep learning*. Entre éstas se destaca la librería de código abierto TensorFlow que fue liberada por Google en 2016 y es la misma que utiliza ésta compañía en la investigación y producción de sus soluciones vinculadas con inteligencia artificial [22].

La implementación de TensorFlow como núcleo de las principales soluciones de visión artificial, como la que se plantea en el presente trabajo, tiene como base la posibilidad de utilizar dicha librería con lenguajes de programación populares como Python y JavaScript [23]. Además, la arquitectura flexible de TensorFlow permite el uso de una única API para la implementación de clasificadores de imágenes con una o más CPU o GPU de escritorio, servidor o dispositivo móvil con sistema Android e iOS. Asimismo, en la plataforma de la librería se ofrecen tutoriales que explican paso a paso cómo realizar las instalaciones y configuraciones necesarias para la generación de clasificadores de imágenes.

La generación de un modelo de reconocimiento de imágenes de variedades de mandioca puede demandar hasta semanas de entrenamiento y requerir el uso de hardware con gran capacidad de cómputo tanto en CPU como GPU. Para acelerar este proceso y generar clasificadores de imágenes utilizando hardware estándar TensorFlow ofrece el uso del aprendizaje por transferencia, esta técnica reduce considerablemente el entrenamiento tomando un modelo completamente entrenado para un conjunto de categorías como ImageNet, y reentrenando los pesos existentes para las nuevas categorías de imágenes [22]. Los modelos más utilizados para aplicar aprendizaje por transferencia para la generación de clasificadores de imágenes son Inception y MobileNet. En investigaciones realizadas recientemente se demostró que para el desarrollo de aplicaciones móviles de clasificación de imágenes, como la que se plantea en este trabajo, se obtienen mejores resultados utilizando MobileNet [24] [25].

La arquitectura optimizada de MobileNet se compone de capas convoluciones separables en profundidad para construir redes de convolución livianas diseñadas con el fin de maximizar la precisión en función de los recursos limitados disponibles en dispositivos móviles [26]. En la implementación de las redes MobileNet se configura el tamaño relativo del modelo como fracción de la MobileNet mayor, este puede ser: 1.0, 0.75, 0.5 o 0.25 y la resolución de imagen de entrada, que puede ser: 128, 160, 192 o 224 px, teniendo en cuenta que a mayor resolución se requiere mayor tiempo de procesamiento a cambio de mejoras en la precisión de la clasificación de las imágenes.

#### 4 Solución propuesta

Las muestras de hojas y tallos de mandioca que se utilizaron en este trabajo fueron proporcionadas por expertos del INTA Misiones y corresponde a las nueve variedades de mandioca descritas en la Tabla 1. Los expertos del INTA clasificaron y rotularon las muestras que se fotografiaron según la variedad correspondiente.

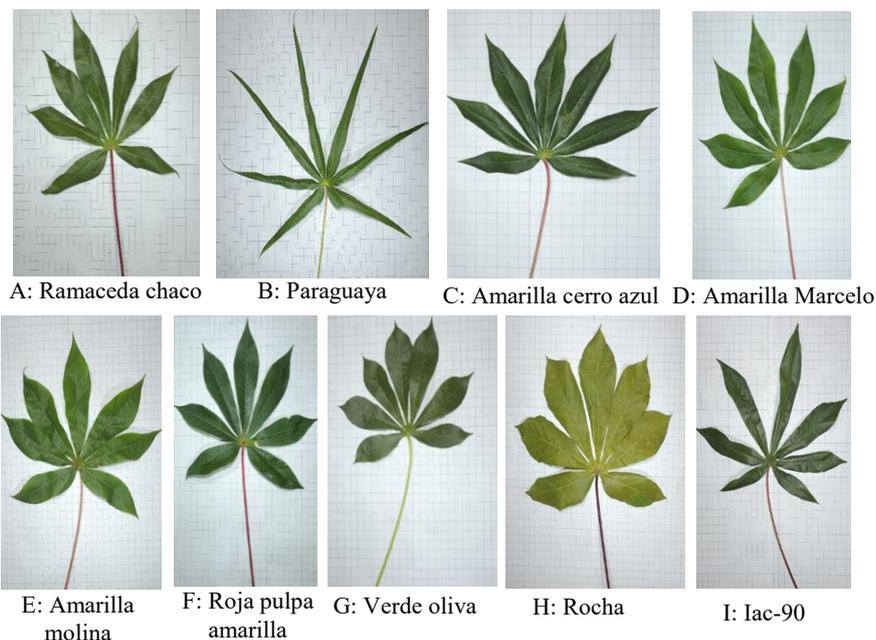
La configuración de captura de imágenes se conformó con tres elementos principales: una cámara digital, una fuente de iluminación artificial y una estructura que se utilizó para fijar la cámara y la fuente de iluminación. La estructura se construyó con 4 columnas de madera de 60 cm de alto, sus dimensiones se definieron en función de pruebas preliminares. Las imágenes se capturaron por medio de una cámara digital Nikon coolpix p510 de 16 Mpx, resolución de 4608 x 3456, zoom óptico de 2x y rango focal de 4.3-180 mm. La misma se colocó a 60 cm de las hojas y los tallos, como se observa en la Fig. 2.



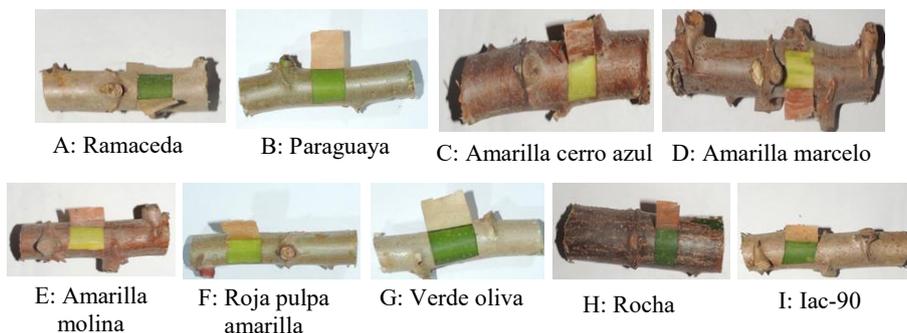
**Fig. 2:** Estructura para la toma de muestras. Fuente: Elaboración propia

Las hojas y tallos se iluminaron artificialmente mediante dos lámparas led de color blanco frío, con temperatura de color de 6000 K y potencia de 4 W. No se utilizó la fuente de luz artificial de la cámara, es decir flash, ya que la iluminación que esta provocaba sobre las hojas y tallos generaba sombras alrededor de las mismas. Las lámparas se colocaron en el extremo superior de dos columnas de la estructura y se direccionaron hacia el centro de la base de la misma, donde se colocaron las hojas y tallos sobre un fondo blanco. Esta disposición permitió que la iluminación sobre las hojas y tallos fuera homogénea, logrando uniformidad en las fotografías.

Las imágenes se almacenaron en formato *jpg* dentro de la memoria extraíble de la cámara, posteriormente se las transfirió a una computadora dentro de carpetas rotuladas con el nombre de la variedad. Con el fin de agilizar las posteriores operaciones se las redimensionó del tamaño original de 4608 x 3456 px a 640 x 480 px. No se aplicó ningún tipo de mejora de brillo, contraste, saturación u otra propiedad. Se obtuvieron 5400 imágenes en total, 2700 de hojas y 2700 de tallos, es decir 300 de cada una de las 9 variedades. En la Fig. 3 se aprecian ejemplos de las hojas correspondientes a las nueve variedades en estudio, en tanto que en la Fig. 4 se aprecian ejemplos de tallos de las mismas nueve variedades.



**Fig. 3:** Ejemplos hojas de las nueve variedades de mandioca. Fuente: elaboración propia



**Fig. 4:** Ejemplos tallos de las nueve variedades de mandioca. Fuente: elaboración propia

Las 2700 imágenes de tallos se dividieron en dos conjuntos, el de entrenamiento y el de evaluación. El conjunto de entrenamiento se conformó con 1800 imágenes divididas en nueve carpetas rotuladas como “Paraguay Cerro Azul”, “Ramaceda Chaco”, “Amarilla Marcelo”, “Amarilla Cerro Azul”, “Amarilla Molina”, “IAC 90”, “Rocha”, “Verde Oliva”, “Roja Pulpa Amarilla”, en cada una de éstas se colocaron 200 imágenes del grupo de estudio correspondiente. El conjunto de evaluación se conformó con las 900 imágenes restantes, 100 imágenes de cada grupo de estudio. La misma distribución se utilizó para las 2700 imágenes de hojas.

Para reentrenar el modelo de clasificación de imágenes se utilizó Tensorflow 1.7 con Python 3.5.5. En función de los resultados obtenidos en otras investigaciones [24] [25] se optó por el modelo de aprendizaje por transferencia MobileNet, ya que con el mismo se obtienen mejores prestaciones en cuanto a tiempos de respuesta y porcentajes de aciertos utilizando dispositivos móviles. Para evaluar la capacidad de clasificación de MobileNet en función de sus características configurables se utilizó MobileNet 1.0 con imágenes de 224 px y MobileNet 0.5 con imágenes de 224 px tanto para las imágenes de hojas como para las de tallos. El software necesario para reentrenar se instaló en una notebook con procesador i5-3230M de 2.6 GHz, 8 GB de RAM DDR3, SSD 240 GB y Windows 10 64 bits.

El reentrenamiento de los modelos con las imágenes de los tallos de mandioca se realizó en 300 iteraciones. Con la configuración MobileNet 1.0 e imágenes de 224 px se obtuvo un archivo del modelo de 16,3 MB en 210 s de entrenamiento, en tanto que con la configuración MobileNet 0.5 e imágenes de 224 px se obtuvo un archivo del modelo de 5,24 MB en 142 s de entrenamiento.

Los dos modelos reentrenados se evaluaron con las imágenes del conjunto de evaluación en la notebook anteriormente descripta. Para el modelo generado con la configuración MobileNet 1.0 e imágenes de 224 px se obtuvo 96 % de clasificaciones correctas con una velocidad de predicción promedio por imagen de tallo de 810 ms. En tanto que para el modelo generado con la configuración MobileNet 0.5 e imágenes de 224 px se obtuvo 94 % de clasificaciones correctas con una velocidad de predicción promedio por imagen de tallo de 350 ms.

En función de los resultados obtenidos en la clasificación se seleccionó MobileNet 1.0 ya que si bien demora en promedio 460 ms más por imagen de tallo que MobileNet 0.5, obtiene 2 % más de clasificaciones correctas con una diferencia despreciable de tiempo y tamaño de archivo. Definido el modelo que mejor se ajusta a la clasificación de tallos de mandioca se procedió a la adaptación del mismo para la ejecución en dispositivos móviles, recordando que éstos poseen limitaciones importantes, por lo que se deben considerar todos aquellos procesamientos previos tendientes a reducir el modelo. Para optimizar el modelo se lo adaptó para que sólo realice operaciones de inferencia, ya que las de entrenamiento no son necesarias en el dispositivo. Mediante el proceso de optimización se logró reducir 28 KB.

A partir del modelo optimizado se generó un APK de 37,3 MB mediante el proyecto Tfmoblie de Android Studio, provisto por Tensorflow. El APK se instaló en un LG G4 H815 equipado con un Qualcomm MSM8992 Snapdragon 808 de 6 núcleos, 4 núcleos de 1.4 GHz Cortex-A53 y 2 núcleos de 1.8 GHz Cortex-A57, 3 GB de RAM y Android Marshmallow.

Con la aplicación funcionando en el dispositivo móvil se evaluó el modelo seleccionado utilizando las imágenes del conjunto de evaluación. Como se observa en la Fig. 5, en la parte inferior de la aplicación se encuentra la imagen en tiempo real que captura la cámara del móvil y en la parte superior el nombre de la variedad de mandioca reconocida junto al valor de clasificación, siendo 1.0 el máximo y 0 el mínimo. Se obtuvo 92 % de clasificaciones correctas, con un promedio de 1150 ms de respuesta por imagen, es decir 340 ms más y 4 % de clasificaciones correctas menos que usando el modelo de clasificación en la notebook.



**Fig. 5:** Clasificación de tallos de mandioca mediante aplicación móvil

Por otra parte, el reentrenamiento de los modelos con las imágenes de las hojas de mandioca se realizó en 1500 iteraciones. Con la configuración MobileNet 1.0 e imágenes de 224 px se obtuvo un archivo del modelo de 16,5 MB en 320 s de entrenamiento, en tanto que con la configuración MobileNet 0.5 e imágenes de 224 px se obtuvo un archivo del modelo de 5,4 MB en 210 s de entrenamiento.

Los dos modelos reentrenados se evaluaron con las imágenes del conjunto de evaluación en la notebook anteriormente descrita. Para el modelo generado con la configuración MobileNet 1.0 e imágenes de 224 px se obtuvo 86 % de clasificaciones correctas con una velocidad de predicción promedio de 850 ms por imagen de hoja. En tanto que para el modelo generado con la configuración MobileNet 0.5 e imágenes de 224 px se obtuvo 74 % de clasificaciones correctas con una velocidad de predicción promedio de 375 ms por imagen de hoja.

En función de los resultados obtenidos en la clasificación se seleccionó MobileNet 1.0 ya que si bien demora en promedio 475 ms más por imagen de hoja que MobileNet 0.5 obtiene 12 % más de clasificaciones correctas con una diferencia despreciable de tiempo y tamaño de archivo. Definido el modelo que mejor se ajusta a la clasificación de hojas de mandioca se procedió a la adaptación del mismo para la ejecución en dispositivos móviles. Para optimizar el modelo, al igual que para el de tallos, se lo adaptó para que sólo realice operaciones de inferencia. Mediante el proceso de optimización se logró reducir 36 KB.

A partir del modelo optimizado se generó un APK de 37,8 MB mediante el proyecto TFmobile de Android Studio. El APK se instaló en el mismo dispositivo utilizado para el modelo de tallos, un LG G4.

Con la aplicación funcionando en el dispositivo móvil se evaluó el modelo seleccionado utilizando las imágenes del conjunto de evaluación. Como se observa en la Fig. 6, en la parte inferior de la aplicación se encuentra la imagen en tiempo real de la hoja que captura la cámara del móvil y en la parte superior el nombre de la variedad de mandioca reconocida junto al valor de clasificación, siendo 1.0 el máximo y 0 el mínimo. Se obtuvo 81 % de clasificaciones correctas, con un promedio de 1210 ms de respuesta por imagen, es decir 360 ms más y 5 % menos de clasificaciones correctas que usando el modelo de clasificación en la notebook



Fig. 6: Clasificación de hojas de mandioca mediante aplicación móvil

## 5 Conclusiones

Los resultados obtenidos en las pruebas realizadas utilizando distintas configuraciones para el modelo de aprendizaje por transferencia MobileNet con las imágenes de tallos de mandioca como así también con las imágenes de hojas de mandioca de las nueve variedades identificadas por el INTA Misiones y cultivadas en la citada provincia, permitieron establecer que mediante el uso de un sistema de visión artificial instalado en un dispositivo móvil es posible identificar las diferentes variedades de mandioca cultivadas en Misiones con un porcentaje mayor al 90 %.

Se observó que con la configuración del modelo MobileNet de tamaño 1.0 e imágenes de 224 px se obtuvieron mejores resultados tanto para las hojas como para los tallos de mandioca que con el modelo MobileNet con tamaño 0.5 e imágenes de 224 px. Asimismo, se observó que con MobileNet 1.0 se generan archivos de modelo de mayor tamaño y el tiempo de predicción es mayor que con MobileNet 0.5 pero que estos valores son despreciables a la hora seleccionar el modelo ya que por la diferencia de tiempo y tamaño de archivo se obtienen mayores porcentajes de clasificaciones correctas.

Se comprobó que mediante el uso de imágenes de los tallos de la mandioca se logra identificar con mayor porcentaje de aciertos las variedades cultivadas que con las imágenes de las hojas. Es así que con el dispositivo móvil se obtuvo 92 % de clasificaciones correctas para los tallos y 81 % para las hojas de la mandioca, es decir un 11 % más de aciertos. Es importante destacar que los tallos se encuentran disponibles durante todas

las estaciones del año, en tanto que las hojas solamente durante un período de tiempo, lo que permite utilizar la aplicación en cualquiera de las temporadas para identificar las variedades de mandioca.

El prototipo de aplicación móvil desarrollada mediante el uso de técnicas de *deep learning* permite que tanto los productores como los expertos del INTA cuenten con una herramienta de apoyo, que no requiere de conexión a internet para funcionar, para la identificación de las variedades cultivadas y, además, coopera con la generación del registro único de variedades de mandioca en Misiones. Como trabajo futuro, se plantea la digitalización de más muestras de hojas y tallos con fondos heterogéneos, como así también la posibilidad de obtener muestras que provengan de otras provincias productoras. Asimismo, con el reciente lanzamiento de Tensorflow 2.0 se evaluarán otros modelos para intentar incrementar el porcentaje de aciertos para imágenes de tallos y hojas.

## Referencias

- [1] O. A. Uset, «Cuadernillo Producción de Mandioca y sus usos,» INTA EEA Montecarlo, pp. 1-22, 2008.
- [2] V. Lombardi, «AGENCIA DE NOTICIAS TECNOLÓGICAS Y CIENTÍFICAS.,» 19 octubre 2017. [En línea]. Available: <http://www.unsam.edu.ar/tss/mandioca-multiuso>. [Último acceso: 12/02/2019].
- [3] O. A. Uset, «Mandioca, mucho más que chipa,» Producir, vol. XXI, n° 236, pp. 18-26, 2011.
- [4] R. Feltan, A. Villasanti y A. Pedawer, «La Mandioca - Tecnología en Alimentos para la Economía Social,» UBA, CABA, 2016.
- [5] M. Shindoi, «Evaluación de variedades de mandioca (Manihot esculenta Crantz) en Colonia Benítez, Chaco,» INTA, Colonia Benítez, Chaco, 2003.
- [6] M. Dominguez Muñoz, «Instituto Nacional de Tecnología Agropecuaria (INTA),» 17 febrero 2017. [En línea]. Available: <https://inta.gob.ar/videos/inta-protege-las-variedades-de-mandioca>. [Último acceso: 12 febrero 2019].
- [7] Y. Z. Calvo Ccallo y C. D. Cardoso Cusihualpa, Análisis de métodos de visión computacional y Machine Learning para la clasificación de imágenes de variedades de papa nativa, Cusco: Universidad Nacional de San Antonio Abad del Cusco, 2018.
- [8] J. Redolfi, D. González Dondo, J. Pucheta y L. Canali, «Clasificación de variedades de semillas de trigo usando visión por computadora,» de VIII Congreso Argentino de AgroInformática, CABA, 2016.
- [9] P. M. Szczypiński, A. Klepaczko y P. Zapotoczny, «Identifying barley varieties by computer vision,» Computers and Electronics in Agriculture, vol. 110, pp. 1-8, 2015.
- [10] F. Chávez, B. Rodríguez-Puerta, F. J. Rodríguez-Díaz y R. M. Luque-Baena, «Detección de variedad y estado de maduración del ciruelo japonés utilizando imágenes hiperespectrales y aprendizaje profundo,» de XVIII Conferencia de la Asociación Española para la Inteligencia Artificial, Granada, 2018.

- [11] A. De Lima Sousa y M. F. Alves Salame, «Classificação de Guaranazeiros Através do Padrão de Venação e Formato de Foliolos Utilizando Aprendizagem de Máquina,» *Anales de Computer on the Beach*, pp. 676-685, 2019.
- [12] F. Kurtulmuş y H. Ünal, «Discriminating rapeseed varieties using computer vision and machine learning,» *Expert Systems with Applications*, vol. 42, n° 4, pp. 1880-1891, 2015.
- [13] M. Castillo Loanza, «Evaluación del desempeño de dos modelos de redes neuronales artificiales para clasificar flores de petunia spp con base en color,» *COP*, México, 2013.
- [14] A. Ramcharan, K. Baranowski, P. McCloskey, B. Ahmed, J. Legg y D. P. Hughes, «Deep Learning for Image-Based Cassava Disease Detection,» *Frontiers in plant science*, n° 8, p. 1852, 2017.
- [15] E. Mwebaze y O. Godliver, «Machine learning for plant disease incidence and severity measurements from leaf images,» de *15th IEEE International Conference on Machine Learning and Applications (ICMLA)*, 2016.
- [16] J. R. Aduwo, E. Mwebaze «Automated vision-based diagnosis of Cassava Mosaic Disease,» de *Industrial Conference on Data Mining-Workshops*, New York, NY, 2010.
- [17] W. Abdullakasm, K. Powbunthorn, J. Unartngam y T. Takigama, «An images analysis technique for recognition of brown leaf spot disease in cassava,» *Tarım Makinaları Bilimi Dergisi*, vol. 7, n° 2, p. 165–169, 2011.
- [18] R. Flórez López y J. M. Fernández, *Las Redes Neuronales Artificiales*, Madrid: Netbiblo, 2008.
- [19] Y. Lecun, Y. Bengio «Deep learning,» *Nature*, vol. 521, n° 7553, p. 436, 2015.
- [20] R. Pletsch, «Mandioca - Serie técnica N°1 de Pequeños Productores,» *INTA*, pp. 1-30, 2004.
- [21] B. Ospina; H. Ceballos, *La yuca en el 3er milenio: Sistemas Modernos de produccion, procesamiento, utilizacion y comercializacion*, Colombia: CIAT, 2002.
- [22] M. Abadi, P. Barham, J. Chen, Z. Chen, A. Davis, J. Dean y M. Kudlur, «TensorFlow: A System for Large-Scale Machine Learning,» *12 th Symposium on Operating Systems Design and Implementation*, vol. 16, pp. 265 - 283, 2016.
- [23] Google, «TensorFlow,» [En línea]. Available: <https://www.tensorflow.org>. [Último acceso: 2019].
- [24] A. gnatov, R. Timofte, W. Chou, K. Wang, M. Wu, T. Hartley y L. Van Gool, «Ai benchmark: Running deep neural networks on android smartphones,» de *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018.
- [25] J. Berger, C. Preussler y J. P. Agostini, «Identificación de síntomas de Huanglongbing en hojas de cítricos mediante técnicas de deep learning,» *Congreso Argentino de AgroInformática*, pp. 90-103, 2018.
- [26] A. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto y H. Adam, «MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications,» *arXiv:1704.04861*, 2017.