

Identification of *Huanglongbing* symptoms in citrus leaves by deep learning techniques

Identificación de síntomas de *Huanglongbing* en hojas de cítricos mediante técnicas de deep learning

Javier Berger¹, César Preussler², and Juan Pedro Agostini²

¹Comité Ejecutivo de Desarrollo e Innovación Tecnológica,
Félix de Azara N° 1890, Posadas (3300), Misiones, Argentina
javiberger@gmail.com

² Instituto Nacional de Tecnología Agropecuaria, Estación Experimental Agropecuaria Montecarlo, El Libertador N° 2472, Montecarlo (3384), Misiones, Argentina
{preussler.cesar, agostini.juanpedro}@inta.gob.ar

Abstract. Artificial vision systems allow automating tasks that require trained personnel to identify relevant characteristics of certain objects. This paper describes the development of a mobile application that uses deep learning techniques to identify symptoms of *Huanglongbing* and nutritional deficiencies in citrus tree leaves. The transfer learning models Inception and MobileNet using Tensorflow and Python were evaluated. A mobile application was created for Android that managed to correctly classify 89% of the sheet images of an evaluation set using the MobileNet model. The application generated will improve the identification of symptoms in leaves of citrus trees during monitoring in citrus plantations.

Keywords: Deep Learning, Transfer Learning, Mobile Application, Huanglongbing, Citrus.

Resumen. Los sistemas de visión artificial permiten automatizar tareas que requieren de personal entrenado para la identificación de características relevantes de determinados objetos. En este trabajo se describe el desarrollo de una aplicación móvil que utiliza técnicas de deep learning para identificar síntomas de *Huanglongbing* y carencias nutricionales en hojas de árboles cítricos. Se evaluaron los modelos de aprendizaje por transferencia MobileNet e Inception utilizando Tensorflow y Python. Se generó una aplicación móvil para Android que logró clasificar correctamente el 89 % de las imágenes de hojas de un conjunto de evaluación utilizando el modelo MobileNet. La aplicación generada permitirá mejorar la identificación de síntomas en hojas de árboles cítricos durante los monitoreos realizados en plantaciones citrícolas.

Palabras claves: Aprendizaje Profundo, Aprendizaje por Transferencia, Aplicaciones Móviles, Huanglongbing, Cítricos.

1 Introducción

En Argentina la citricultura es una de las actividades frutícolas más importantes, el país se posiciona a nivel mundial como el octavo productor de cítricos y el primer exportador de limones. En la campaña 2015/2016 se produjeron 3.281.320 toneladas de frutas en 132.346 hectáreas de cultivo ubicadas 60 % en el noroeste y 40 % en el noreste argentino [1]. En el mencionado período el sector generó un mercado de más de mil millones de dólares, brindando 100.000 puestos directos de trabajo a lo largo de toda la cadena productiva [2].

La actividad citrícola requiere, como otras actividades, el monitoreo permanente de las plantaciones en busca de indicios de enfermedades que pongan en riesgo la producción. Entre las amenazas que afectan a los cítricos se destaca el *Huanglongbing* (HLB), caracterizada, a nivel mundial, como la enfermedad de mayor gravedad ya que, hasta la fecha, no existe producto o método que recupere un árbol afectado por la misma. Esto implica que al confirmarse la presencia de HLB en un árbol cítrico el mismo se debe eliminar, inmediatamente, para evitar la propagación de la enfermedad. El primer caso registrado de HLB en el mundo se remonta a 1919 en China, actualmente está presente en países de África, América, Asia y Oceanía [3].

La situación del HLB en Argentina es alarmante. En 2007 se confirmó la presencia de casos positivos de HLB en estados de Brasil limítrofes con provincias argentinas. Esto provocó que los organismos de protección vegetal y representantes de la industria citrícola argentina impulsaran la creación del Programa Nacional de Prevención del HLB (PNPHLB). En junio de 2012 monitores del PNPHLB identificaron en árboles cítricos de traspatio ubicados en Andresito, provincia de Misiones el primer caso positivo de HLB en Argentina [4]. Para agosto de 2018 ya se detectaron casos positivos en seis provincias argentinas, la mayoría en árboles de traspatio o arbolado urbano [5].

El daño que ocasiona el HLB en las plantaciones, sumado a la rapidez con la que se propaga, cuando no se toman las medidas de control necesarias, requiere que se realicen, periódicamente, exploraciones visuales en busca del insecto vector y de síntomas característicos en ramas, hojas y frutos de árboles cítricos. La identificación temprana de indicios de HLB es la principal tarea dentro de las estrategias de monitoreo y control, realizadas por el PNPHLB con el objetivo de evitar el ingreso y/o proliferación de la enfermedad. Asimismo, la extensión de cultivos y el difícil acceso a ciertas zonas productoras, conlleva a que los citricultores se conviertan en los principales observadores de síntomas.

Los monitores observan, principalmente, las hojas de los árboles ya que en las mismas se aprecian los síntomas más relevantes asociados al HLB, como ser el moteado asimétrico difuso en el haz o cara superior de la hoja, que se manifiesta con manchas verdes y amarillas sin bordes definidos, distribuidas de manera diferente a uno y otro lado de la nervadura central, además del engrosamiento y aclaración de las nervaduras [6]. Estos síntomas se confunden, habitualmente, con los indicios de deficiencias nutricionales de los cítricos, según se explica en [7]. Además, se pueden confundir con síntomas de gomosis y clorosis variegada de los cítricos.

Los citricultores y monitores que participan en las constantes barridas de monitoreo de las plantaciones no siempre cuentan con el entrenamiento visual suficiente para diferenciar los síntomas de HLB de los indicios de deficiencias nutricionales. Además, la selección de hojas sintomáticas puede variar por factores que influyen habitualmente en las inspecciones basadas en operadores humanos, como la falta de homogeneidad en los criterios de inspección y el cansancio relacionado a la realización de tareas repetitivas por un tiempo prolongado [8]. Estos problemas provocan que se extraigan muestras de hojas irrelevantes, lo que implica que los laboratorios de diagnóstico especializado estén desbordados y que las tareas de análisis se ralenticen, ya que el examen de una sola muestra requiere cuatro horas de trabajo intensivo. Investigaciones realizadas por el Departamento de Entomología, Fitopatología y Zootología Agrícola de la Universidad de San Pablo Brasil, indican que las muestras obtenidas por los inspectores visuales se corresponden, solamente, en un 47 % con síntomas de HLB [9].

La automatización de la inspección visual para la clasificación de objetos es una tecnología que se expande, día a día, en el sector agroindustrial. Entre las razones de la expansión se encuentra el avance de los sistemas de visión artificial, que integran diferentes técnicas de procesamiento digital de imágenes (PDI) y métodos de clasificación. Ejemplos de automatizaciones exitosas son: la selección de granos de café [10], la clasificación de flores [11], la clasificación de gajos de mandarina [12], la determinación del nivel de maduración de cítricos [12] y, específicamente, la clasificación de hojas [13] [14] [15] [16]. Por medio de los sistemas de visión artificial se realiza la adquisición, procesamiento y clasificación de imágenes que se adquieren mediante cámaras digitales o escáneres y se procesan digitalmente con el objetivo de segmentar las regiones de interés y extraer los descriptores visuales que definen los objetos a clasificar. Los descriptores se definen en función de las características discriminantes de los objetos, por ejemplo: color, forma, textura [17]. La clasificación de imágenes, en función de los descriptores, se puede realizar mediante distintas técnicas de inteligencia artificial, entre éstas, se destacan las redes neuronales artificiales (RNA), en los trabajos [10] [11] [12] [13] [14] [15] [16] se destaca la capacidad de clasificación de las mismas. Estos clasificadores, simulan el proceso de aprendizaje humano, es decir, que necesitan ser entrenados con imágenes de ejemplo para que, posteriormente, reconozcan las características aprendidas en nuevas imágenes, generando sistemas de aprendizaje automático o *machine learning* (ML) [18]. La evolución del ML generó nuevos métodos de adquisición de conocimiento englobadas dentro del aprendizaje profundo o *deep learning* (DL), estos métodos tienen la capacidad de identificar automáticamente las características discriminantes de las imágenes utilizando varias capas de RNA [19].

En [20] se describen distintas investigaciones que presentan alternativas innovadoras para la identificación de HLB con diferentes niveles de eficiencia, entre estas se encuentran los trabajos [21] [22] [23] en los que se desarrolla un sensor de visión utilizando una cámara monocroma, LED de alta potencia y filtros polarizadores para identificar la concentración de almidón en las hojas, síntoma característico del HLB, con las imágenes obtenidas con este sensor y utilizando RNA lograron una precisión de detección que oscila entre 95.5 % y 98.5 %. En [24] los investigadores proponen un método de identificación de enfermedades cítricas, entre las que se encuentra

HLB, mediante la obtención de características relacionadas con el color, la textura y la geometría de las regiones de interés segmentadas en imágenes de hojas y frutos; la selección de atributos relevantes se realiza con el análisis de componentes principales (PCA) y la clasificación con máquinas de vectores de soporte multiclase (M-SVM) y se obtiene entre 89% y 97 % de precisión en función del conjunto de imágenes utilizadas. En [25] se propone un método de detección de HLB basado en el procesamiento de imágenes de espectro visible, extrayendo información de textura e histograma de las imágenes para utilizarlas como descriptores y clasificando con vector de costo-soporte (C-SVC), así se obtuvo 91.93 % de clasificaciones correctas.

En función de las dificultades que implica la identificación de síntomas de HLB y la diferenciación de los mismos con indicios de carencias nutricionales en hojas de árboles cítricos y, a partir de los avances de los métodos de clasificación utilizando técnicas de DL y PDI se plantea en este trabajo el desarrollo de una aplicación para dispositivos móviles que clasifique en tiempo real hojas con síntomas de HLB y deficiencias nutricionales utilizando fotografías obtenidas mediante la cámara del móvil. A diferencia de los trabajos expuestos anteriormente, en esta investigación se utilizan dispositivos y cámaras convencionales de bajo costo y técnicas de DL que definen automáticamente las características discriminantes de las hojas. La aplicación ofrece una alternativa de bajo costo, fácil instalación y uso a productores y organismos de control para auxiliarse en la toma de decisión para la extracción de muestras de hojas durante el monitoreo de plantaciones, colaborando así con la producción citrícola nacional en busca de mantener un status sanitario adecuado.

Este trabajo está organizado en 5 secciones. En la segunda sección se describen los principales aspectos de la enfermedad *Huanglongbing* haciendo énfasis en la identificación visual de los síntomas en las hojas de árboles cítricos. En la tercera sección, se refieren las características generales del uso de modelos de *Deep Learning* para la clasificación de imágenes utilizando dispositivos móviles. En la cuarta sección se presenta la solución propuesta detallando los materiales y métodos necesarios para el entrenamiento de los modelos de *Deep Learning* seleccionados, como así también los resultados obtenidos en las diferentes pruebas. Finalmente, en la quinta sección se presentan las conclusiones de este trabajo, identificando las ventajas y desventajas de cada uno de los modelos evaluados, como así también las facilidades que presenta la solución propuesta para la identificación de síntomas de *Huanglongbing*.

2 Huanglongbing

El patógeno asociado con el HLB es una bacteria localizada en los tubos del floema de tipo gram-negativa denominada *Candidatus Liberibacter* spp. [26]. Esta bacteria transita por el floema de la planta impidiendo la circulación de los nutrientes por el taponamiento de los vasos floemáticos, provocando síntomas similares a las deficiencias nutricionales [27]. Para que el HLB se disperse es necesario que exista la relación hospedante-vector-inóculo. Los hospedantes son todas las plantas pertenecientes a la familia *Rutaceae*, entre ellas los cítricos; los vectores son los psílidos *Diaphorina citri* y *Trioza erytreae*; el inóculo son las especies de bacterias dentro del género *Candidatus Liberibacter*. La

bacteria persistente que se reproduce dentro del insecto no se transmite a otras generaciones, de tal forma que la bacteria infecta al vector sin afectar los procesos fisiológicos del insecto, este al alimentarse de la planta transmite la enfermedad [28]. Además de los insectos vectores el HLB se transmite por material vegetal de propagación, como ser yemas infectadas; no se transmite por frutos ni por semillas, ya que produce el aborto del embrión [29].

2.1 Sintomatología característica

La identificación temprana de síntomas de HLB en los árboles cítricos se considera un factor clave, ya que permite ejecutar rápidamente medidas de control para evitar la propagación de la enfermedad [30]. Los indicios de HLB se pueden observar en ramas, frutos y hojas de un árbol cítrico, estos síntomas son similares para los distintos agentes infecciosos, como así también para las distintas especies de cítricos [31]. Inicialmente, se observa amarillamiento de brotes sectorizados, si la enfermedad avanza se observa caída de hojas y frutos junto a la muerte de las ramas y, finalmente, la muerte del árbol.

Las hojas son el principal punto de observación de síntomas de HLB, las mismas presentan una coloración amarilla pálida con áreas color verde, irregularidades o moteados, manchas asimétricas en relación a la nervadura central, engrosamiento y aclaración de las nervaduras [32], estos indicios se aprecian en las hojas de la Fig. 1.



Fig. 1. Síntomas de HLB en hojas. Fuente: SENASA & [32]

Los síntomas visibles en las hojas de los árboles cítricos afectados por HLB son similares a las características que se observan en las hojas de las plantas con carencias nutricionales y afectadas por gomosis o clorosis variegada de los cítricos. Estas similitudes implican que para lograr identificar correctamente a que afección corresponden los síntomas, se realice un diagnóstico diferencial basado en el análisis foliar [7].

2.2 Diagnóstico diferencial de síntomas en hojas

El diagnóstico diferencial se utiliza para reconocer enfermedades que presentan indicios similares. Mediante éste se busca identificar inequívocamente una enfermedad

y tomar las medidas específicas que permitan controlarla. La técnica más extendida para el diagnóstico de enfermedades en un árbol cítrico es el análisis foliar [33].

Las hojas de los árboles cítricos son muy sensibles a los cambios de composición del medio nutritivo, por esta razón, en las mismas se observan indicios característicos que permiten obtener información del estado del árbol. El análisis foliar requiere que las muestras que se extraen sean representativas del estado de la plantación. La interpretación del análisis foliar se realiza comparando los resultados obtenidos con los valores foliares estándar previamente establecidos para cada elemento.

El análisis foliar requiere el conocimiento de la morfología de la hoja para identificar las zonas en las que se aprecian los síntomas. En la

Fig. 2 se observan las principales partes de la hoja; el limbo es la lámina constituida por la parte superior denominada haz, la parte inferior envés y las nervaduras que son los vasos conductores que componen el tejido vascular de la planta, el extremo superior del limbo es el ápice, en tanto que, el extremo inferior se denomina base, la parte que une el limbo con la rama se denomina pecíolo.




Fig. 2. Principales partes de una hoja. Fuente: Elaboración propia.

La deficiencia nutricional indica que el elemento carente no alcanza en el tejido la concentración suficiente para el normal desarrollo de las funciones fisiológicas o procesos metabólicos en el que éste está implicado. Estas disfunciones producen síntomas en diversos sectores de la planta, específicamente las hojas, en las mismas se aprecian patrones que permiten diagnosticar visualmente el estado carencial de la planta. Al efectuar un análisis foliar se pueden identificar visualmente carencias de boro, cobre, fósforo, hierro, manganeso, magnesio, molibdeno, nitrógeno, potasio o zinc. Entre éstas las que presentan mayor similitud de síntomas con el HLB son las de magnesio y zinc [33].

La carencia de magnesio se manifiesta por el amarillamiento del limbo de la hoja, excepto en una zona ubicada a ambos lados de la nervadura central, como se aprecia en la Fig. 3, esta región permanece verde y se ensancha partiendo del ápice de la hoja hasta la base, formando un área triangular característica de este estado deficitario.

La deficiencia de zinc se manifiesta con el amarillamiento del limbo de las hojas en la zona ubicada entre las nervaduras secundarias, como se observa en la Fig. 3, mientras que el tejido adjunto a la nervadura principal y secundaria permanece verde, dándole un aspecto atigrado. Adicionalmente, los árboles cítricos con carencias elevadas de zinc presentan hojas de tamaño pequeño, con forma estrecha y puntiaguda.

La presencia de regiones moteadas en el haz del limbo foliar es el denominador común tanto para las carencias nutricionales como para los síntomas de HLB. La clave para identificar la correspondencia de síntomas se encuentra en la distribución de las manchas. Al observar la Fig. 3, con carencia de magnesio, se aprecia que la concentración de moteado es mayor del centro hacia la base de la hoja, en tanto que para la carencia de zinc, se aprecia que la concentración de moteado se encuentra del centro hacia el ápice de la hoja.



Fig. 3. Deficiencias nutricionales. Fuente: Laboratorio INTA Montecarlo

Otro aspecto diferenciador relacionado a la distribución de las manchas es la simetría de las mismas. Las hojas con síntomas de HLB presentan una distribución de manchas asimétricas, mientras que las hojas con carencias nutricionales, muestran una distribución de manchas simétricas en función de la nervadura central. Además, la nervadura central aporta otra característica importante, las hojas con síntomas de HLB presentan la nervadura engrosada de color amarillenta, en tanto que en las hojas con carencias nutricionales la nervadura central se mantiene verde.

Los síntomas de HLB en las hojas también se pueden confundir con otras enfermedades, como la gomosis y la clorosis variegada de los cítricos [34]. A diferencia de los casos de carencias nutricionales, en los árboles afectados por estas enfermedades se aprecian indicios característicos en otros sectores de las plantas, esto constituye una ventaja para los monitores a la hora de realizar el diagnóstico diferencial.

2.3 Monitoreo y control

El control del HLB se realiza de forma preventiva y se basa en dos principios fitopatológicos establecidos, el control del vector y la erradicación de las fuentes de inóculo de *Candidatus liberibacter* sobre las cuales el vector se infecta. Mediante el seguimiento que se realizó en regiones afectadas por HLB se apreció que luego de detectar los vectores en una región, la enfermedad ya se encuentra en zonas cercanas, por esta razón, en zonas libres de HLB, pero con presencia de vector, se deben establecer procedimientos para la detección temprana de la enfermedad. Para esto, se requiere conocer los síntomas de HLB y contrastarlos con indicios de carencias minerales [7].

El monitoreo requiere de experiencia y entrenamiento visual, ya que, los síntomas de HLB se confunden, habitualmente, con deficiencias nutricionales [35]. La falta de expertos en la identificación de esta enfermedad, sumado a las extensiones de cultivos que se

recorren, provoca que en los monitoreos participen productores, viveristas e inclusive personal del PNPHLB que no cuenta con el entrenamiento visual suficiente. Esto genera que los monitores utilicen, como se observa en la Fig. 4, imágenes de muestra con síntomas de la enfermedad para contrastar los indicios de las hojas del árbol cítrico que se está monitoreando con la imagen de muestra. Si bien la utilización de estas imágenes permite reducir confusiones en la identificación de síntomas, aún llegan a los laboratorios de análisis hojas que, para los expertos del INTA, presentan síntomas evidentes de carencias nutricionales.



Fig. 4. Monitoreo utilizando imágenes de muestra

Las muestras de material vegetal sospechoso y vectores extraídos por los monitores del PNPHLB, productores, empresas y cooperativas citricolas se envían a los laboratorios de referencia, donde personal especializado en genética procesa las hojas en busca de la bacteria vinculada al HLB siguiendo el protocolo descrito en [36]. El resultado para una sola muestra se obtiene después de cuatro horas de trabajo intenso mediante el análisis del ácido desoxirribonucleico de las hojas con la técnica molecular de la reacción en cadena de la polimerasa (PCR). Si el resultado del análisis de una muestra resulta positivo para HLB los responsables del laboratorio deben informar, de manera urgente, a los organismos de control para que se inicien las tareas de erradicación del árbol afectado.

2.3 Distribución en Argentina

El primer positivo de HLB en América se reportó en San Pablo, Brasil en 2004, transcurridos tres años se reportaron positivos en estados de Brasil limítrofes con Argentina, lo que provocó que representantes de la industria citrícola y de instituciones oficiales implementen el Programa Nacional de Prevención del HLB (PNPHLB).

En 2012, los monitores del PNPHLB detectaron en árboles cítricos de traspaso ubicados en la localidad de Andresito, provincia de Misiones, límite con el Estado de Paraná, Brasil, el primer positivo de HLB en Argentina [4]. Con el correr de los años se detectaron nuevos árboles positivos en distintas zonas de Misiones; en 2013, en El Soberbio y Colonia Aurora, localidades limítrofes con el Estado de Rio Grande del Sur, Brasil y distantes a 200 Km de Andresito. En 2015, en Wanda, Puerto Iguazú, Colonia Delicia, Eldorado y Piray, cercanas a la frontera con Paraguay. En 2016, se detectaron los primeros positivos en plantaciones comerciales ubicadas en Eldorado, Apóstoles y Leandro N. Alem [4]. La presencia de HLB en Misiones afectó severamente al sector citrícola provincial, entre 2006 y 2016, tanto la superficie plantada como la producción disminu-

yeron un 30%; mientras que sólo en el período 2015 – 2016 cayó 4,7 % la producción sin que variara la superficie cultivada [37].

Con el correr de los años el HLB avanzó hacia otras provincias de Argentina. Para agosto de 2018, como se observa en la Fig. 5, ya se reportaron positivos de HLB en árboles de la provincia de Misiones, Corrientes, Entre Ríos, Formosa, Chaco y Santiago del Estero y presencia del vector en Santa Fe, Salta y Jujuy [5].




Fig. 5. Distribución del HLB en Argentina. Fuente: [5]

Desde la creación del PNPHLB hasta agosto de 2018 se monitorearon 288.332 sitios y se analizaron, en los laboratorios de referencia, un total de 12.064 muestras de material vegetal con síntomas sospechosos de HLB y 30.353 muestras del insecto vector, alcanzando un total de 312 árboles con diagnóstico positivo para la enfermedad [5].

3 Deep Learning

El aprendizaje automático o *machine learning* (ML) es la rama de la inteligencia artificial (IA) dedicada al estudio de agentes que aprenden, basados en experiencia, para realizar determinadas tareas con niveles de precisión que se asemejan al humano. El objetivo de todo proceso de ML es utilizar evidencia conocida para crear una hipótesis y dar una respuesta a nuevas situaciones no conocidas [38].

En ML, se adquiere el conocimiento a través del análisis y la manipulación de datos, usando estrategias basadas en teorías matemáticas como las redes neuronales artificiales (RNA) que son modelos matemáticos con capacidad para adaptar su comportamiento en respuesta a ejemplos tomados del medio, inspirándose en la construcción del cerebro y las neuronas biológicas. Sus componentes son procesadores simples que funcionan de forma paralela y distribuida, almacenan y utilizan el conocimiento adquirido de la experiencia para responder a nuevos ejemplos [39].

En el campo de la visión artificial los últimos avances están relacionados con las técnicas de aprendizaje profundo o *deep learning* (DL) y el uso de un conjunto de

arquitecturas de RNA previamente entrenadas. DL es la actividad de adquisición de conocimiento automática mediante máquinas que utiliza varios niveles para la extracción de características. La gran ventaja de las técnicas de DL es que no requiere de una definición manual de los aspectos relevantes que identifican a los patrones buscados. En una imagen, por ejemplo se logra generar, automáticamente las características relevantes manipulando datos crudos, lo que permite que RNA con varios niveles de neuronas aprendan a representar características mediante la construcción automática de descriptores de alto nivel y a través del uso de una gran cantidad de niveles jerárquicos de extractores, sin la necesidad de indicarles cuáles son.

Las arquitecturas más utilizadas en DL son la red profunda de convolución, red de creencias profundas y redes recurrentes de memoria corta y larga [19]. Entre éstas, se destacan por su eficiencia las convolucionales, estas forman parte del núcleo de las soluciones actuales más avanzadas de visión por computador [40]. Una red neuronal convolucional o *convolutional neural network* (CNN) se compone de una capa de entrada, una de salida y varias capas ocultas, las neuronas que la conforman tienen parámetros en forma de pesos y sesgos que se pueden aprender. La principal característica diferenciadora de las CNN es que hacen suposición explícita de que las entradas son imágenes, esto permite codificar algunas propiedades en la arquitectura para identificar objetos específicos en las imágenes [41]. Además, las CNN son computacionalmente más eficientes que modelos anteriores de RNA ya que utilizan operaciones de agrupamiento y convolución especialmente dedicadas al intercambio de parámetros, mediante esto se logra que los modelos de CNN se puedan ejecutar en cualquier dispositivo, lo que hace que sean más atractivos para el desarrollo de aplicaciones móviles.

Entre las librerías para desarrollar soluciones de DL se destaca Tensorflow [42], por ser de código abierto y por ser utilizada tanto en la investigación como en la producción de soluciones de Google. Tensorflow se utiliza para cálculo numérico mediante programación de grafos de flujo de datos, los nodos en el grafo representan operaciones matemáticas, mientras que las conexiones representan los conjuntos de datos multidimensionales o tensores. Permite construir y entrenar RNA para detectar correlaciones y descifrar patrones. La arquitectura flexible de Tensorflow permite la implementación de clasificadores con una o más unidades centrales de procesamiento (CPU) o unidades de procesamiento gráfico (GPU) de escritorio, servidor o dispositivo móvil mediante una única interfaz de programación de aplicaciones (API).

Los modelos actuales de reconocimiento poseen millones de parámetros y puede llevar días entrenarlos completamente desde cero, inclusive utilizando mucha potencia de cómputo. Para acelerar este proceso Tensorflow ofrece el aprendizaje por transferencia, esta técnica permite reducir considerablemente el entrenamiento tomando el conocimiento adquirido al resolver un problema y aplicándolo a un problema diferente pero relacionado, es decir se toma un modelo completamente entrenado para un conjunto de categorías como ImageNet, y se reentrenan los pesos existentes para las nuevas categorías [42].

Tensorflow dispone de varios modelos previamente entrenados para aplicar aprendizaje por transferencia, entre los que se encuentran Inception y MobileNet. Inception extrae las características generales de las imágenes de entrada utilizando una CNN y

las clasifica en función de esas características con capas totalmente conectadas. MobileNet se basa en una arquitectura optimizada que utiliza convoluciones separables en profundidad para construir CNN profundas y livianas diseñadas para maximizar la precisión en función de los recursos disponibles en móviles [43].

4 Solución propuesta

Las hojas que se utilizaron en este trabajo fueron proporcionadas por el Laboratorio de Diagnóstico Molecular de la EEA Montecarlo del INTA y correspondían a diferentes especies de naranja, mandarina, limón y pomelo. Los expertos del INTA indicaron la sintomatología que presentaba cada hoja que se digitalizó y, además, suministraron los resultados obtenidos por PCR para dichas hojas.

La configuración de captura se conformó con 3 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 25 centímetros de alto, las dimensiones de la misma se definieron en función de pruebas preliminares y de la estructura utilizada otras investigaciones [14]. Las imágenes se capturaron mediante una cámara digital Panasonic modelo DMC-F2 de 10 Megapíxeles con resolución máxima de 3648 x 2736 píxeles, zoom óptico de 5 x, rango focal de 28 - 140 mm y sensor de carga acoplada de 1/2.5". La misma se montó en la parte central de la estructura, ubicándose a 90 grados y a 20 centímetros de la hoja, como se observa en la Fig. 6.



Fig. 6. Estructura para la toma de muestras. Fuente: Elaboración propia

Las hojas se iluminaron artificialmente con 4 lámparas de led de color blanco frío, temperatura color de 6000 Kelvin y potencia de 4 Watt. No se utilizó la fuente de luz artificial de la cámara, es decir flash, ya que la iluminación que este provocaba sobre las hojas generaba sombras alrededor de las mismas. Las lámparas se colocaron en el extremo superior de cada una de las columnas de la estructura y se direccionaron hacia el centro de la base de la misma, donde se colocaron las hojas sobre un fondo

blanco. Esta disposición permitió que la iluminación sobre las hojas fuera homogénea, logrando uniformidad en las fotografías.

Las hojas se ubicaron en el centro de la base de la estructura con el haz del limbo foliar en dirección a la lente de la cámara y el ápice orientado hacia arriba. 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 número de identificación de la muestra. Con el fin de agilizar las posteriores operaciones se las redimensionó del tamaño original de 3648 x 2736 píxeles a 640 x 480 píxeles. No se aplicó ningún tipo de mejora de brillo, contraste, saturación u otra propiedad. Se obtuvieron 1200 imágenes diferentes, 300 correspondían a hojas asintomáticas, 300 a carencia de magnesio, 300 a carencia de zinc y 300 a hojas con síntomas de HLB. En la Fig. 7 se aprecian ejemplos de los grupos de estudio.




Fig. 7. Hojas con síntomas. (A) hojas asintomáticas, (B) hojas con carencia de magnesio, (C) hojas con carencia de zinc y (D) hojas con síntomas de HLB. Fuente: EEA Montecarlo INTA

Las 1200 imágenes de hojas digitalizadas se dividieron en dos conjuntos: el de entrenamiento y el de evaluación. El conjunto de entrenamiento se conformó con 800 imágenes divididas en cuatro carpetas rotuladas como Asintomática, Magnesio, Zinc y HLB, en cada una de éstas se colocaron 200 imágenes del grupo de estudio correspondiente. El conjunto de evaluación se conformó con las 400 imágenes restantes, 100 imágenes de cada grupo de estudio.

Para generar el modelo de clasificación de imágenes se utilizó Tensorflow con Python aplicando la técnica de aprendizaje por transferencia. Para esto se seleccionaron los modelos Inception versión 3 y MobileNet versión 0.5. Para reentrenar los modelos seleccionados se instaló el software necesario en una notebook con procesador i5-3230M de 2.6 GHz, tarjeta gráfica integrada Intel HD 4000, 4 GB de RAM DDR3, SSD 240 GB y sistema operativo Windows 10 versión de 64 bits.

Utilizando las 800 imágenes de entrenamiento se realizó el reentrenamiento de ambos modelos aplicando 500 iteraciones. El tiempo de reentrenamiento de Inception fue de 294

segundos y generó un archivo del modelo de 83,3 MB, en tanto que el tiempo para MobileNet fue de 77 segundos y generó un archivo de 5,23 MB.

Los modelos obtenidos en el reentrenamiento se evaluaron con las imágenes del conjunto de evaluación utilizando la notebook anteriormente mencionada. Para MobileNet se obtuvo 92,25 % de clasificaciones correctas, con una velocidad de predicción promedio por hoja de 380 milisegundos. En tanto que con Inception se obtuvo 91,25 % de clasificaciones correctas con una velocidad de predicción promedio por hoja de 1570 milisegundos. En la Tabla 1 se observa la matriz de confusión para la clasificación.

Tabla 1. Matriz de confusión

	Modelo MobileNet				Modelo Inception			
	Asintomática	Magnesio	Zinc	HLB	Asintomática	Magnesio	Zinc	HLB
Asintomática	96	1	3	0	98	0	2	0
Magnesio	0	89	7	4	1	87	5	7
Zinc	1	6	92	1	1	5	91	3
HLB	0	5	3	92	0	6	5	89

El porcentaje de clasificaciones correctas que se obtuvo con los modelos ejecutados en la notebook habilitó la continuidad de la siguiente etapa del trabajo, que consistió en la adaptación de los modelos para ejecutarlos en dispositivos móviles. Los dispositivos móviles tienen limitaciones importantes, por lo que se debe considerar cualquier procesamiento previo para reducir los modelos.

En éste trabajo se realizó la optimización de las operaciones de los modelos adaptándolos sólo para operaciones de inferencia, ya que las de entrenamiento no son necesarias en el dispositivo. La optimización para MobileNet se realizó en 5 segundos reduciendo el modelo de 5,23 MB a 5,20 MB en tanto que en Inception se realizó en 154 segundos reduciendo el modelo de 83,3 MB a 83,1 MB.

Para generar la aplicación móvil destinada a identificar los síntomas en las hojas a campo se utilizó como base el proyecto TFmobile de Android Studio, provisto por Tensorflow [44]. Mediante el mismo se crearon dos proyectos, uno para cada modelo reentrenado, y se obtuvieron dos paquetes de aplicación Android o *Android Application Package* (APK) para instalar en dispositivos móviles con el sistema Android. El APK que contenía el modelo para MobileNet tenía un tamaño de 26,9 MB y el de Inception 99,5 MB.

Los APK obtenidos se instalaron en un dispositivo móvil marca LG modelo G4 versión H815 con sistema Android Marshmallow equipado con un procesador 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, cámara con 16 MP de resolución del sensor, 1/2,6'' de tamaño del sensor y apertura f/1,8.

Con los APK instalados en el LG G4 se evaluó la capacidad de clasificación de las imágenes utilizando el dispositivo móvil y las 400 fotografías del conjunto de evaluación. Para esto, se ejecutó la aplicación en el móvil y se le presentó en tiempo real, como se aprecia en la Fig. 8, las imágenes de las hojas desde la pantalla de la no-

tebook. Se presenta el nombre del síntoma (hlb: *Huanglongbing*, mg: carencia de Magnesio, zn: carencia de Zinc, sana: asintomática) El valor que se aprecia junto al nombre del síntoma corresponde al porcentaje de semejanza con que el modelo clasificó la hoja. En las Fig. 8 A y B se observan ejemplos de clasificaciones obtenidas mediante MobileNet, en tanto que en las Fig. 8 C y D se aprecian las mismas hojas clasificadas mediante Inception. Se observó que para MobileNet el tiempo promedio de respuesta fue de 1 segundo en tanto que con Inception fue de 3 segundos.




Fig. 8. Identificación de síntomas con aplicación móvil.

En función de la clasificación obtenida con el dispositivo móvil se conformó la matriz de confusión que se observa en la Tabla 2. Para MobileNet se obtuvo 90,75 % de clasificaciones correctas, con una velocidad de predicción promedio por hoja de 850 milisegundos. En tanto que con Inception se obtuvo 90,5 % de clasificaciones correctas con una velocidad de predicción promedio por hoja de 2750 milisegundos.

Tabla 2. Matriz de confusión para dispositivo móvil

	Modelo MobileNet				Modelo Inception			
	Asintomática	Magnesio	Zinc	HLB	Asintomática	Magnesio	Zinc	HLB
Asintomática	93	3	4	0	97	1	2	0
Magnesio	0	88	8	4	1	86	6	7
Zinc	1	5	92	2	1	5	91	3
HLB	1	5	4	90	0	7	5	88

En función de los resultados obtenidos en la clasificación de las imágenes obtenidas en el laboratorio de la EEA Montecarlo del INTA, en los que se obtuvo más del 90 % de clasificaciones correctas para los dos modelos se planteó la posibilidad de evaluar la aplicación móvil, pero utilizando imágenes que no tuvieran fondo uniforme y que correspondieran a hojas de árboles de otra región simulando las condiciones con las que se enfrentan los monitores a campo. Para esto se conformó un nuevo conjunto de evaluación constituido por 200 imágenes de hojas, 50 por cada grupo de estudio, orientadas en diferentes direcciones y con fondo heterogéneo, como se observa en la Fig. 9. Las imágenes se descargaron de distintas publicaciones científicas, entre las cuales se encuentra las del herbario virtual de la cátedra de fitopatología de la Facultad de Agronomía de la Universidad de Buenos Aires donde se muestran

fotografías con las características de los síntomas de HLB y de deficiencias nutricionales.

Para la nueva evaluación, se ejecutó la aplicación para cada modelo en el dispositivo móvil y se le presentó en tiempo real, las imágenes de las hojas desde la pantalla de la notebook. Las Fig. 9 A y B corresponden a ejemplos de clasificaciones obtenidas utilizando el modelo MobileNet, en tanto que las Fig. 9 C y D corresponden a la clasificación obtenida utilizando el modelo Inception.




Fig. 9. Identificación de síntomas con fondo heterogéneo.

En función de los resultados obtenidos para las 200 imágenes de hoja se conformó la matriz de confusión de la Tabla 3. Para MobileNet se obtuvo 89 % de clasificaciones correctas, con una velocidad de predicción promedio por hoja de 1150 milisegundos. En tanto que con Inception se obtuvo 87,5 % de clasificaciones correctas con una velocidad de predicción promedio por hoja de 3200 milisegundos.

Tabla 3. Matriz de confusión para dispositivo móvil y fondo heterogéneo.

	Modelo MobileNet				Modelo Inception			
	Asintomática	Magnesio	Zinc	HLB	Asintomática	Magnesio	Zinc	HLB
Asintomática	45	2	3	0	47	2	1	0
Magnesio	0	44	2	4	0	43	3	4
Zinc	0	5	43	2	0	5	42	3
HLB	0	3	1	46	0	5	2	43

5 Conclusiones

Los resultados obtenidos en las diferentes pruebas de clasificación de imágenes de hojas de árboles cítricos con síntomas de HLB, carencia de magnesio, deficiencia de zinc y asintomáticas demostraron que con la ayuda de un dispositivo móvil dotado con una aplicación que utilice técnicas de *deep learning*, específicamente redes neuronales convolucionales, se puede identificar y clasificar los síntomas mencionados con un 89 % de aciertos, para el caso del modelo MobileNet. Si bien el porcentaje de aciertos

es entre 9 % y 3 % menor que los obtenidos en otros trabajos, sigue siendo superior al promedio de clasificaciones obtenidas por los monitores. Por otra parte, a diferencia de otras propuestas, la solución aquí planteada se ajusta a dispositivos móviles convencionales lo que permite implementarla rápidamente sin invertir gran cantidad de recursos.

Se observó que MobileNet se ajusta mejor a la clasificación requerida que Inception ya que, con MobileNet se logró mayor porcentaje de clasificaciones correctas, menor tiempo de respuesta y menor tamaño de archivo, lo que se traduce en una aplicación de menor tamaño. Además, se comprobó que las reducciones realizadas en los modelos creados en la notebook no tuvieron gran impacto cuando se utilizaron en el móvil. La diferencia en el porcentaje de clasificaciones correctas fue del 1,5% para MobileNet y 0,75 % para Inception.

Se verificó la potencialidad de los modelos a la hora de clasificar hojas con diferentes orientaciones y con fondo heterogéneo. Es importante recordar que los modelos se reentrenaron con imágenes de fondo homogéneo y con una única orientación. Como trabajo futuro, se plantea el uso de una arquitectura distribuida para el procesamiento de imágenes y la incorporación de imágenes de hojas con distinta orientación y fondo, de ésta manera se estima que el porcentaje de clasificaciones correctas se incrementará.

La aplicación móvil generada en este trabajo permite a los monitores del PNPHLB y a los productores tener información en tiempo real para la toma de decisiones en relación a la extracción de muestras. La misma no requiere de conexión a ninguna red para funcionar, lo que permite recorrer las plantaciones de cualquier latitud y de esta manera cooperar con el sector citrícola para mantener el status sanitario de la región.

Referencias

- [1] FEDERCITRUS, «La Actividad Citrícola Argentina 2017,» 2017.
- [2] INTA, «Cítricos Argentinos,» *INTA Informa*, n° 165, pp. 1-4, 2016.
- [3] J. Bové, «Huanglongbing: a destructive, newly-emerging, century-old disease of citrus,» *Journal of Plant Pathology*, vol. 88, n° 1, pp. 7-37, 2006.
- [4] J. P. Agostini, «HLB en Argentina: nueva enfermedad en cítricos,» de *Presentación de resultados de Investigación y Desarrollo Tecnológico en Citricultura*, Montevideo, Uruguay, 2017.
- [5] SENASA, «Análisis Epidemiológico del HLB en Argentina,» SENASA, Buenos Aires, 2018.
- [6] C. Paredes y M. Pantoja, «Diferencias en la manifestación de síntomas asociados a la enfermedad Huanglongbing (HLB),» *CitriFrut*, vol. 32, n° 2, pp. 36-41, 2015.
- [7] J. P. Agostini, «Huanglongbing (ex greening),» *Citrusmisiones*, vol. 34, Marzo 2011.
- [8] V. Davidson, C. Terrence y R. Joanne, «Fuzzy methods for automated

- inspection of food products,» *18th International Conference of the North American*, pp. 909-913, 1999.
- [9] J. Belasque y A. Bergamin, «Base científica para a erradicação de plantas sintomáticas e assintomáticas de Huanglongbing visando o controle efetivo da doença,» *Tropical Plant Pathology*, vol. 34, nº 3, pp. 137-145, 2009.
 - [10] G. Daza, L. Sanchez y J. Suarez, «Selección de características orientada a sistemas de reconocimiento de granos maduros de café,» *Scientia et Technica*, vol. XIII, nº 35, pp. 139-144, 2007.
 - [11] 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.
 - [12] B. Al-Hadithi, M. Rueda y J. Muro, «Interfaz visual para el prototipado rapido de clasificadores de gajos de mandarina basados en redes neuronales,» Universidad Alfonso X El Sabio, Madrid, España, 2006.
 - [13] J. González Romero, «Medición de parámetros y características geométricas en especies de hojas mediante procesamiento de imágenes y redes neuronales,» Universidad Autónoma de Querétaro, Querétaro, México, 2012.
 - [14] R. Pydipati, T. F. Burks y W. S. Lee, «Statistical and neural network classifiers for citrus disease detection using machine vision,» vol. 48, nº 5, 2005.
 - [15] S. Sankaran y R. Ehsani, «Detection of Huanglongbing Disease in Citrus Using Fluorescence Spectroscopy,» vol. 55, nº 1, pp. 313-320, 2012.
 - [16] C. B. Wetterich, R. Kumar, S. Sankaran, J. Belasque Junior, R. Ehsani y L. G. Marcassa, «A Comparative Study on Application of Computer Vision and Fluorescence Imaging Spectroscopy for Detection of Huanglongbing Citrus Disease in the USA and Brazil,» 2013.
 - [17] F. Rodríguez Díaz y M. Berenguel Soria, Control y robótica en agricultura, Almería: Universidad Almería, 2005.
 - [18] R. Flórez López y J. M. Fernández, Las Redes Neuronales Artificiales, Madrid: Netbiblo, 2008.
 - [19] Y. Lecun, Y. Bengio y G. Hinton, «Deep learning,» *Nature*, vol. 521, nº 7553, p. 436, 2015.
 - [20] J. J. Garza-Saldaña, S. Varela-Fuentes y W. Gómez-Flores, «Métodos para la detección presuntiva de Huanglongbing,» *CienciaUAT*, vol. 11, nº 2, pp. 93-104, 2017.
 - [21] A. Pourreza, W. S. Lee, R. Ehsani, J. Schueller y E. Ravenh, «An optimum method for real-time in-field detection of Huanglongbing disease using a vision sensor,» *Computers and Electronics in Agriculture*, vol. 110, pp. 221-232, 2015.
 - [22] A. Pourreza, W. S. Lee, E. Etxeberria y Y. Zhang, «Identification of Citrus Huanglongbing Disease at the Pre-Symptomatic Stage Using Polarized

- Imaging Technique,» *IFAC*, vol. 49, n° 16, pp. 110-115, 2016.
- [23] A. Pourreza, W. S. Lee, E. Etcheberria y A. Banerjee, «An evaluation of a vision-based sensor performance in Huanglongbing disease identification,» *Biosystems Engineering*, vol. 130, pp. 13-22, 2015.
 - [24] M. Sharif, M. A. Khan, Z. Iqbal, M. F. Azam, I. U. Lali y M. Y. Javed, «Detection and classification of citrus diseases in agriculture based on optimized weighted segmentation and feature selection,» *Computers and Electronics in Agriculture*, vol. 150, pp. 220-234, 2018.
 - [25] X. Deng, Y. Lan, T. Hong y J. Chen, «Citrus greening detection using visible spectrum imaging and C-SVC,» *Computers and Electronics in Agriculture*, vol. 130, pp. 177-183, 2016.
 - [26] A. Acton, *Issues in Biological and Life Sciences Research*, ScholarlyEditions, 2011.
 - [27] J. V. Da Graça, «Citrus Greening Disease,» *Annual Review of Phytopathology*, vol. 29, n° 1, 1991.
 - [28] S. N. Mondal y J. P. Agostini, «Factors Affecting Pycnidium Production of *Diaporthe citri* on Detached Citrus Twigs,» *Plant Disease*, vol. 88, n° 4, pp. 379-382, 2004.
 - [29] INTA EEA YUTO, «HLB (huanglongbing ó ex greening),» *Plagas y enfermedades*, vol. 1, n° 7, 2010.
 - [30] J. P. Agostini, «Evolución de la citricultura misionera,» *Citrusmisiones*, vol. 16, pp. 3-8, 1987.
 - [31] J. P. Agostini, «Citricos: El HLB y su prevención,» *RIA*, vol. 37, p. 677, 2011.
 - [32] M. Polek, *Citrus Bacterial Canker Disease and Huanglongbing (Citrus Greening)*, California: UCANR Publications, 2007.
 - [33] F. Legaz, M. D. Serna y E. Primo, «Sintomatologías de las deficiencias y excesos minerales en los cítricos,» n° 5, 1996.
 - [34] J. P. Agostini, «Manejo integrado de enfermedades de los frutales cítricos,» de *Arboles frutales. Ecofisiología, cultivo y aprovechamiento*, Buenos Aires, Facultad de Agronomía, UBA, 2007, pp. 474-511.
 - [35] Y. Outi y J. P. Agostini, «Manejo de la contingencia fitosanitaria HLB y monitoreos de detección precoz en Argentina,» de *VII Congreso Argentino de Citricultura. Citricultura asociativa y sustentable*, Puerto Iguazú, Argentina, INTA, 2013, pp. S4-11.
 - [36] R. Haelterman y N. Costa, «Métodos de diagnóstico para Huanglongbing *Candidatus Liberibacter*,» de *Procedimientos empleados en la identificación de organismos fitopatógenos*, Córdoba, Córdoba: INTA, 2009.
 - [37] Ministerio de Hacienda de la Nación. , «Informes Productivos Provinciales (Misiones),» CABA, Argentina, 2018.
 - [38] T. Mitchell, *Machine Learning*, McGraw-Hill, 1997.

- [39] S. Haykin, Neural Networks, Delhi: Pearson Prentice Hall, 1999.
- [40] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens y Z. Wojna, «Rethinking the Inception Architecture for Computer Vision,» *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 2818-2826, 2016.
- [41] J. Torres, Deep Learning, Introducción práctica con Keras, Barcelona: Lulu.com, 2018.
- [42] M. ABADI, «TensorFlow: A System for Large-Scale Machine Learning,» *OSDI*, vol. 16, pp. 265 - 283, 2016.
- [43] 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.
- [44] Google, «Tensorflow,» [En línea]. Available: <https://www.tensorflow.org/>