

Informe técnico final de proyecto

Identificación automática de especies forestales maderables amenazadas de Costa Rica, mediante técnicas de visión artificial

Proyecto VIE 1370004

Agosto 16, 2020

Preparado por: Erick Mata Montero, Ph.D.
Coordinador del proyecto
Escuela de Computación, TEC

Tabla de contenidos

| | |
|---|----|
| 1. Código y título del proyecto. | 2 |
| 2. Autores y direcciones. | 2 |
| 3. Resumen | 2 |
| 4. Palabras claves | 3 |
| 5. Introducción | 3 |
| 5.1 Naturaleza y alcance del problema investigado | 4 |
| 5.2 Método de investigación y las razones por las cuales fue seleccionado | 6 |
| 5.3 Objetivos del trabajo | 8 |
| 6. Marco teórico | 9 |
| 7. Metodología | 12 |
| 7.1 Protocolo de recolección de muestras | 13 |
| 7.2 Conjunto de datos | 17 |
| 7.2.1 Aumento de datos (data augmentation) | 17 |
| 7.2.2 Conjuntos de datos de entrenamiento y validación | 18 |
| 7.3 Arquitectura de la CNN usada | 20 |
| 8. Resultados | 21 |
| 8.1 Publicaciones | 21 |
| 8.2 Resultados al desarrollar la aplicación Cocobolo | 27 |
| 8.3 Ampliación de la Xiloteca Víctor Rojas | 30 |
| 9. Discusión y conclusiones | 31 |
| 10. Recomendaciones | 32 |
| 11. Agradecimientos | 33 |
| 12. Referencias | 33 |
| 13. Apéndices | 38 |

1. Código y título del proyecto.

Proyecto VIE 1370004.

Identificación automática de especies forestales maderables amenazadas de Costa Rica mediante técnicas de visión artificial.

2. Autores y direcciones.

- Erick Mata Montero, Ph.D, Coordinador, emata@itcr.ac.cr.
- Geovanni Figueroa Mata, M.Sc., Candidato a Doctor en Ingeniería, investigador, gfigueroa@itcr.ac.cr.
- Dagoberto Arias Aguilar, Ph.D., investigador, darias@itcr.ac.cr.
- Juan Carlos Valverde Otárola, M.Sc., investigador, jcvalverde@itcr.ac.cr.
- Nelson Zamora Villalobos, Ing., investigador zmoravn@gmail.com.
- Jean Carlo Paniagua Bastos, estudiante de Ing. en Computación, paniagua.b.jean@gmail.com.
- Sharon López Aragón, estudiante de Diseño Industrial, slopeza07@gmail.com.

3. Resumen

(Indicar los objetivos principales y el alcance de la investigación; describir los métodos empleados; resumir los resultados; enunciar las conclusiones principales; máximo 250 palabras).

El objetivo general de este proyecto fue *“Diseñar e implementar un sistema que realice la identificación de especies forestales de manera automática, a partir de imágenes digitales de muestras macroscópicas de maderas”*.

Tanto el objetivo general como los cinco objetivos específicos y productos asociados fueron alcanzados en un 100%: 1. Seleccionar el conjunto de especies forestales maderables (muestras de 197 especies fueron recolectadas en el campo). 2.

Enriquecer la xiloteca institucional con nuevas muestras y una base de datos con sus correspondientes imágenes digitales (982 muestras recolectadas que se convirtieron en

982x4 muestras de xiloteca, y 27,930 fotos)¹. 3. Seleccionar las técnicas de visión artificial a usar (CNN profundas). 4. Implementar varios algoritmos para identificación de especies maderables (CNN y redes siamesas). 5. Finalmente, se desarrolló *Cocobolo*, una aplicación móvil para la identificación de especies maderables de Costa Rica.

Metodológicamente el proyecto ha sido innovador a nivel mundial. En el campo forestal, se demostró [1] la viabilidad de un nuevo protocolo no destructivo de recolecta con barrenos y un nuevo flujo de trabajo que ha enriquecido sustancialmente la xiloteca del TEC. En el campo informático, se innovó usando por primera vez especies nativas de CR, haciendo identificaciones con imágenes macroscópicas en lugar del tradicional enfoque con muestras microscópicas, y usando técnicas que son estado del arte como las redes siamesas.

Esta investigación ha demostrado conclusivamente mediante publicaciones *peer-reviewed* que las CNN son la mejor técnica para la identificación automática de árboles con imágenes de cortes macroscópicos de madera.

4. Palabras claves

Machine learning, deep learning, convolutional neural networks, computer vision, biodiversity informatics, xylotheque.

5. Introducción

Esta investigación generó siete artículos que ya fueron publicados en revistas o congresos con comité editorial y dos más que están en preparación (ver apéndices y resúmenes en Sección 8.1). Por esta razón presentamos este informe técnico de manera resumida enfatizando los resultados de precisión alcanzada en los experimentos para desarrollar la aplicación móvil denominada *Cocobolo* e indicamos las publicaciones en las que se puede encontrar el detalle sobre aspectos tales como naturaleza del problema, justificación, marco teórico, estado del arte, y otros experimentos, entre otros.

¹ El número de fotografías aumentará conforme se procesen en laboratorio las muestras que aún no han sido fotografiadas).

5.1 Naturaleza y alcance del problema investigado

A pesar de que Costa Rica ha logrado una relativa recuperación de su cobertura boscosa en los últimos 20 años, la explotación intensiva de los bosques desarrollada en el siglo XX disminuyó la población de muchas especies arbóreas [2], [3]. Las especies arbóreas más afectadas han sido las de potencial maderable, pues en muchos casos producen maderas preciosas de alta calidad, durabilidad y belleza. Costa Rica cuenta con más de 2.000 especies arbóreas, de las cuales 90 especies son catalogadas como amenazadas, 53 están en peligro de extinción y 30 se ubican en la categoría de peligro crítico [2], al punto que 18 de ellas han sido declaradas en veda total (Decreto ejecutivo No 25700-MINAE), lo cual evidencia la gravedad de la problemática.

La identificación de algunas especies arbóreas maderables es particularmente compleja y muchas veces constituye el único material disponible en pericias legales. Por esta razón, es deseable el desarrollo de métodos alternativos de identificación taxonómica con base en muestras de madera los cuales sean tan precisos y, preferiblemente, más simples que el proceso comúnmente usado por los expertos, por lo que la identificación correcta de especies forestales maderables es una necesidad urgente que vendría a apoyar la conservación y el manejo sostenible del recurso forestal.

Como indicamos en [4], el reconocimiento anatómico de maderas puede ser microscópico y/o macroscópico. El primero es mucho más confiable que el segundo, pero requiere de equipos y técnicas especiales las cuales no siempre están disponibles. Las características macroscópicas de la madera, son aquellas que se aprecian a simple vista o con ayuda de un aumento cercano al 60x². En la mayoría de los casos, este conjunto de características macroscópicas define inequívocamente cada especie, lo cual permite su identificación [5], [6].

² No existe consenso sobre el grado de magnificación después del cual una imagen se considera microscópica. Hemos optado por usar el umbral 60X, es decir 60x o menos es macroscópica.

Las características anatómicas son menos afectadas por las condiciones ecológicas y/o climáticas que las características morfológicas externas (e.g., corteza, hojas), por lo que tienen un grado mayor de valor diagnóstico en la identificación de especies, independientemente de su procedencia [7]. Por otro lado, las características macroscópicas primarias como la presencia o ausencia de poros, radios, vasos y fibras entre otras, son menos variables dentro de cada especie, por lo que son comúnmente usadas como elementos discriminadores.

El procedimiento que realiza usualmente un experto para la identificación de una especie de árbol maderable se basa en la observación de ciertas características macroscópicas de una muestra. Dicha muestra se obtiene al realizar tres cortes: transversal, tangencial y radial de la madera (Figura 1) y la observación se realiza preferiblemente mediante un lente con un aumento igual o mayor a 60x.

Para identificar la especie a la que corresponde una muestra no es necesario que ésta sea de gran tamaño, basta con que tenga dimensiones de aproximadamente 1 x 1 x 1 cm [9].

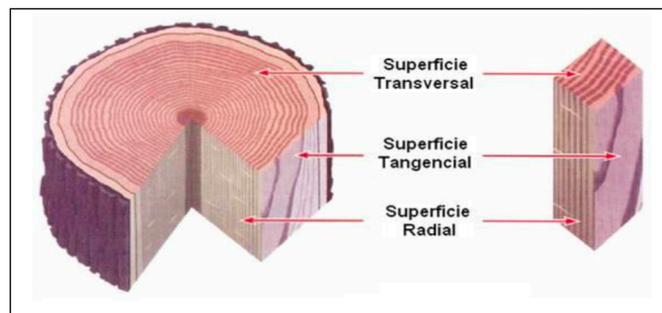


Fig. 1 Planos de corte usados en la identificación de especies de forestales (tomada de [8]).

Para exacerbar el problema de la identificación de especies de manera precisa y rápida, la cantidad de taxónomos especialistas ha disminuido sensiblemente en los últimos 30 años. Esta situación ha sido identificada y denominada oficialmente el GTI (Global Taxonomic Impediment) en la Conferencia de las Partes del Convenio de Biodiversidad CoP 5 en el

año 2000 en Kenia. Desde entonces se considera un serio obstáculo para la conservación de la biodiversidad, incluida la domesticada (agrícola y forestal).

A nivel mundial, iniciativas como el GBIF (Global Biodiversity Information Facility³), EOL (Encyclopedia of Life⁴), y iDigBio (Integrated Digitized Biocollections⁵), entre otras, han respondido al reto del GTI estableciendo plataformas para dar acceso gratuito y universal a sus bases de datos con lo cual los taxónomos pueden llevar a cabo su trabajo de análisis, identificación, clasificación, y descripción de especies más eficientemente. Sin embargo, estas bases de datos apoyan el enfoque tradicional de identificación por parte de taxónomos, sin automatización parcial ni mucho menos total a partir de imágenes de los organismos. A nivel de xilotecas, el panorama es aún más limitado, pues generalmente se cuenta con pocas muestras y en los casos en que haya bastantes, por razones de costo de las giras de campo, se toman varias muestras de un mismo individuo, lo cual, para aplicaciones de machine learning, introduce sesgos a la hora de entrenar los algoritmos, como lo demostraron Carranza-Rojas, Mata-Montero y Goëau en [10]. Además, falta digitalizar estas colecciones con protocolos estándar para aplicaciones informáticas. Esto implica que las xilotecas no solo deben digitalizar sus colecciones sino aumentar y diversificar el número y tipo de muestras recolectadas [4].

Con un enfoque pragmático, se planteó entonces confrontar el reto de llevar a cabo identificaciones precisas de especies arbóreas de CR apoyadas por algoritmos de machine learning basados en imágenes e implementado en una aplicación móvil.

5.2 Método de investigación y las razones por las cuales fue seleccionado

Al iniciar esta investigación, en 2017, algunas iniciativas que usan visión por computadora para la identificación de especies de plantas habían surgido. Esas iniciativas se describieron en la sección “Estado del Arte” de la propuesta de investigación que generó

³ <https://www.gbif.org>.

⁴ <https://eol.org>.

⁵ <https://www.idigbio.org>.

este proyecto. Aunque la mayoría se basa en imágenes de hojas y otros componentes de las plantas, no se había explorado entonces la identificación automática basada en cortes de madera. A nivel nacional, el Dr. Mata también había iniciado una primer investigación que derivó en la tesis de Doctorado en Ing. de José Mario Carranza Rojas [11] bajo la sombrilla del proyecto VIE 1370002 “Identificación de especies de plantas de Costa Rica utilizando visión por computadora“. En todos esos casos, el enfoque inicial fue el de técnicas de visión computacional basadas en machine learning y la extracción de características predefinidas de componentes de las plantas.

Dado que *deep learning* se perfilaba en el 2017 como un enfoque muy promisorio, se planteó como primer etapa de este proyecto el determinar si el enfoque metodológico debería basarse en la extracción de características predefinidas o más bien en el descubrimiento de esas características mediante un enfoque de aprendizaje supervisado con redes neutrales convolucionales (CNN).

En nuestra investigación sobre el estado del arte en técnicas de machine learning para clasificación automática de especies de árboles, quedó claro que el uso de *técnicas de aprendizaje supervisado* con CNN y deep learning eran el enfoque más adecuado y promisorio [12], [13]. La disponibilidad de algunos conjuntos de datos con imágenes digitales de cortes de madera en otros países, más el poder computacional que brindan las tarjetas gráficas (GPU) de bajo costo disponibles en la nube y en el CENAT lo hacen no solo viable sino deseable. Finalmente, dado que un objetivo de este proyecto es el desarrollo de una aplicación móvil, deep learning con CNN también es ideal porque la mayor demanda computacional se da en el entrenamiento, el cual se hace en computadoras de alto rendimiento, mientras que el *deployment* se hace en cualquier teléfono celular inteligente.

Con respecto a los conjuntos de datos utilizados, se planteó inicialmente utilizar como uno de los insumos fotos de las muestras en la xiloteca institucional que se complementarían con fotografías de muestras recolectas en el campo. Lamentablemente, la cantidad de muestras por especie en la xiloteca era muy baja y no existía trazabilidad para determinar

si las muestras de una misma especie correspondían a distintos individuos. Un requerimiento muy importante de las técnicas de deep learning es contar con cantidades de datos estadísticamente significativas, la mínima cantidad necesaria depende del dominio de aplicación. En nuestro caso, el número era desconocido, por lo cual debimos programar múltiples giras de campo (se realizaron 19) y aunque se recolectaron muestras de 197 especies, no todas han sido fotografiadas. Además, usamos solamente especies con muestras de al menos 5 individuos, lo cual redujo en número de especies usadas en el entrenamiento de la CNN a 75.

En vista del enorme reto de maximizar el número de muestras recolectadas, propusimos, experimentamos y demostramos que una nueva metodología, no destructiva, basada en la extracción de muestras con barreno en árboles en pie, puede ser usada para el desarrollo de estas aplicaciones. Consecuentemente, puede convertirse un nuevo flujo de trabajo para xilotecas modernas.

5.3 Objetivos del trabajo

Para este proyecto se definieron originalmente los siguientes objetivos.

Objetivo general:

Diseñar e implementar un sistema que realice la identificación de especies forestales de manera automática, a partir de imágenes digitales de muestras macroscópicas de maderas.

Objetivos específicos:

1. Seleccionar el conjunto de especies forestales maderables para la investigación.
2. Enriquecer la xiloteca Institucional con nuevas muestras y una base de datos con sus correspondientes imágenes digitales.
3. Seleccionar las técnicas de visión artificial, reconocimiento de patrones y clasificación que serán usadas.
4. Implementar varios algoritmos para identificación de especies maderables.

5. Promover la bioalfabetización, conservación y manejo sostenible del recurso forestal, por medio de una aplicación móvil para la identificación de especies maderables de Costa Rica.

6. Marco teórico

Los antecedentes al problema de clasificar (identificar) especies de árboles de manera automática a partir de fotos de cortes de madera, se presentaron en la propuesta de este proyecto. Un estado del arte para el año 2018 se presenta en el artículo "Automated Image-based Identification of Forest Species: Challenges and Opportunities for 21st Century Xylotheques," de Figueroa-Mata, Mata-Montero, Valverde-Otárola y Arias-Aguilar [4]. En el resto de esta sección brindamos en un resumen actualizado del estado del arte.

Desde el año 2012, cuando AlexNet — una arquitectura basada en deep learning — ganó por primera vez el prestigioso ImageNet Challenge (ILSVRC) [14], deep learning ha demostrado un éxito notable en distintos dominios de aplicación [15], [16], [17].

Una de estas áreas es la identificación de especies de árboles a partir de imágenes de su madera. Sin embargo, como indicamos anteriormente, el uso de imágenes de madera (cortes o corteza) en la identificación de especies de árboles no se ha utilizado tan ampliamente debido a que el proceso de adquisición de muestras e imágenes microscópicas de madera es complejo y costoso. Los siguientes párrafos describen los principales trabajos desarrollados en este tema a partir del año 2017.

En 2017, Kwon et al. [18] presentan seis modelos diferentes de CNN models (variantes de las arquitecturas LeNet Y MiniVGGNet) para identificar cinco especies de árboles de madera blanda nativas de Korea del Sur. Una cámara de teléfono celular fue usada para obtener imágenes macroscópicas de la madera. La mejor precisión obtenida fue de 99.3%, usando la arquitectura LeNet3. Si bien la precisión alcanzada es muy alta, la cantidad de especies es muy pequeña, comparada con la riqueza arbórea de Costa Rica, por ejemplo.

Posteriormente, en 2018, Ravindran et al. [19] proponen una variante del modelo VGG16 previamente entrenado con imágenes de ImageNet para identificar 10 especies de madera neotropicales de la familia Meliaceae. Probaron el modelo propuesto a nivel de especie y género, logrando una precisión del 87,4 % y 97,5 % respectivamente. El número de especies es ligeramente mayor pero es importante porque se concentraron en especies listadas en la lista de especies amenazadas de la convención CITES.

También en 2018, los autores de [20] proponen una pequeña arquitectura de CNN para identificar siete especies maderables comerciales de Perú. De cada imagen extraen parches de diferentes tamaños 32x32, 64x53 y 128x128, con los que forman 3 conjuntos de datos para sus experimentos. Se utilizó un microscopio digital portátil conectado a una computadora personal para obtener las imágenes de madera. La mejor precisión lograda es 94.05% para el conjunto de datos compuesto por los parches de 128x128 píxeles.

Oktaria et al. [21] publican en 2019 una comparación de cuatro arquitecturas CNN: Kayu30Net, AlexNet, ResNet y GoogNet en un conjunto de datos compuesto por imágenes de madera de 30 especies que se obtuvieron del Xylarium Bogoriense, Indonesia. Sin embargo, no especifican más detalles sobre la base de datos o el proceso de entrenamiento de los modelos, por ejemplo, si utilizan algún tipo de aprendizaje por transfer learning, por lo cual los resultados no son en nuestra opinión replicables.

Ese mismo año, Ravindran et al. [22] aplican un modelo ResNet34 que pre-entrenan con ImageNet para identificar 38 especies arbóreas de 15 géneros de interés comercial en Ghana. La precisión reportada es de 97.0% en pruebas de laboratorio y 72.0% en prueba en el campo.

También en 2019, Apolinario et al. [23] proponen una arquitectura CNN basada en bloques Inverted Residual Mottenecks (IRB) y capas convolucionales profundas que permiten la identificación de especies conocidas y el agrupamiento de aquellas que no lo son. En este sentido, la arquitectura propuesta es un algoritmo clasificador y de agrupamiento (clustering). Para sus experimentos utilizan dos bases de datos, la primera compuesta por

imágenes de 16 especies de madera de Perú y la segunda es la Base de Datos Macroscópica de Especies Forestales (FSD-M) compuesta por imágenes de 41 especies maderables de Brasil [24]. Las precisiones reportadas son superiores al 91% para las especies vistas y no vistas durante la fase de entrenamiento.

Otro resultado relevante publicado en 2019 es el trabajo de Yang et al. [25], quienes aplican transfer learning a un modelo VGG19 pre-entrenado con el conjunto de datos ImageNet. Luego, usan el modelo afinado para la clasificación de 25 especies maderables, alcanzando una precisión promedio de 93.63%. También aplican esta estrategia a los modelos InceptionV3 y VGG16, alcanzando también muy buenas precisiones: 92.41% y 92.72% respectivamente.

Este año 2020, dos publicaciones nos han parecido relevantes. Yusof et al. [26] reportan una precisión del 100% cuando aplican transfer learning y un modelo ResNet-50 a un conjunto de datos compuesto por 20 especies maderables tropicales. Por otro lado, en [27] los autores usan un modelo InceptionV4-ResNetV2 pre-entrenado con ImageNet para clasificar 10 especies maderables de Norteamérica. La precisión lograda es de 92.6%.

En resumen, la mayoría de los trabajos publicados recientemente sobre la identificación automática de especies arbóreas a partir de imágenes de madera comparten los siguientes aspectos:

1. Utilizan imágenes macroscópicas de madera, específicamente cortes transversales.
2. Aplican modelos deep learning la técnica del aprendizaje transfer learning para re-entrenar los modelos propuestos.
3. El número de especies consideradas es relativamente pequeño, no mayor a 40.
4. No está claro si en sus procesos de entrenamiento evitan el sesgo estadístico SSPB, que aumenta la precisión de manera ficticia, como lo reportaron Carranza-Rojas et al. en [10] como parte de su proyecto de investigación en el TEC en 2018. Esto es muy

importante porque las precisiones pueden estar entre un 10% y un 20% sesgadas a favor de altas precisiones.

Este proyecto de investigación ha contribuido a mejorar el estado del arte porque:

1. Demostró que deep learning es una técnica efectiva y con suficiente precisión para identificar especies de árboles neotropicales, las cuales no se habían estudiado antes.
2. Demostró que los cortes transversales son más discriminantes que los radiales y los tangenciales.
3. Demostró, que las técnicas de deep learning son lo suficientemente robustas para aplicarse también en la identificación de especies de árboles con conjuntos de datos de más de 40 especies.
4. Demostró que se puede evitar el sesgo estadístico SSPB y aún así obtener muy buena precisión con un conjunto de datos de 75 especies.
5. Demostró que las redes siamesas son una muy buena alternativa cuando se tienen pocos datos, en el dominio de identificaciones basadas en fotografías de hojas, lo cual sugiere que podría usarse con imágenes de muestras de xilotecas.
6. Demostró que se puede usar un método no destructivo de recolecta de muestras de madera en forma más rápida y que éstas se pueden usar para la identificación automática de especies, así como para estudiar sus características anatómicas.

7. Metodología

En esta sección describimos en forma general el enfoque metodológico usado durante el experimento global para probar el back-end de la aplicación móvil *Cocobolo* con el conjunto de datos disponible hasta el 15 de julio de 2020. Como a lo largo de los tres años del proyecto se realizaron múltiples experimentos con distintos sets de datos, es muy difícil dar los detalles en este informe. Los detalles metodológicos se deben consultar en las publicaciones asociadas a cada conjunto de experimentos y que se incluyen como

apéndices. En total se publicaron 5 artículos sobre aspectos computacionales, y está en preparación un sexto artículo que recaba los resultados globales del proyecto e incluye una descripción de la aplicación *Cocobolo*. Además, por haber generado un nuevo método de recolecta y procesamiento de muestras con barrenos, se escribió tres artículos sobre este tema, que es de carácter más forestal; dos ya fueron publicados y uno fue enviado pero no nos han comunicado su aceptación. El grupo investigador fue muy cuidadoso diseñando los experimentos y se aseguró de facilitar la replicabilidad de los mismos con detalladas descripciones en los trabajos publicados.

Uno de los problemas que enfrentan los investigadores cuando intentan aplicar técnicas de aprendizaje profundo a la identificación de especies de madera es la falta de bases de datos de imágenes macroscópicas. Quizás, la única base de datos de acceso abierto es la Base de datos de especies forestales - Macroscópica (FSD-M) del Laboratorio Visão Robótica e Imagem [28].

Por esto y dado que queremos probar nuestra investigación con especies de Costa Rica, recolectamos muestras de madera que especies nativas Costa Rica y las integramos a la Xiloteca Víctor Rojas del Instituto Tecnológico de Costa Rica.

7.1 Protocolo de recolección de muestras

Para recolectar y procesar las muestras de madera, así como para crear la base de datos, construimos un protocolo. Los siguientes párrafos resumen los protocolos usados, los cuales se detallan en [1].

Se recolectó muestras de madera en seis parcelas preestablecidas distribuidas a lo largo de la costa pacífica de Costa Rica en los siguientes lugares:

1. Estación experimental Horizontes.
2. Cañas.
3. Miramar.
4. Parque Nacional La Cangreja, Puriscal.

5. Los Mogos, Península de Osa.
6. San Juan

La ubicación de las parcelas se puede observar en la Figura 2.

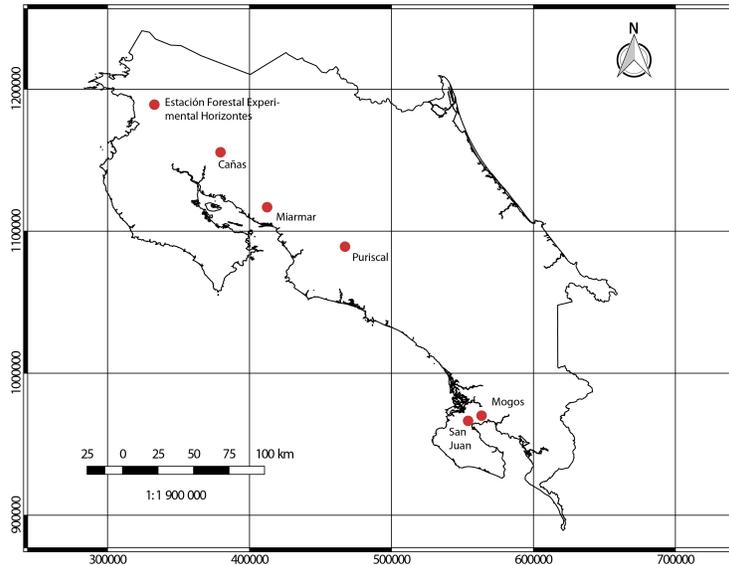


Fig.2 Ubicación de reserva forestales usadas para las recolectas.

El protocolo desarrollado para la extracción de muestras incluye los siguientes pasos que se ilustran en la Figura 3:

1. Selección y evaluación de la muestra de árbol. El ejemplar de árbol debe ser un árbol sano con un diámetro a la altura del pecho (DAP) mayor o igual a 20 cm. Se identifica la especie de árbol y se registran las características del árbol: especie, diámetro, número de espécimen de árbol, y ubicación. Finalmente, se toma una foto del árbol a 1 m. de distancia (ver Figura 3 (a)).
2. Selección y limpieza del punto de perforación. Se selecciona un lugar en el árbol, libre de ramas y deformidades. Se limpia un área de 5 cm², a 1 m. sobre el nivel del suelo y se quita la corteza (ver Figura 3 (b)).

3. Perforación del tronco. La perforación se realiza con un taladro de 20 voltios que funciona con batería. La sembradora está equipada con un cortador de media pulgada de diámetro y la profundidad de perforación es de aproximadamente 80 mm. El proceso de perforación no es destructivo y la curación del árbol toma de 6 a 10 meses. Una vez que se termina la perforación, el taladro se saca y la muestra queda expuesta (ver Figuras 3 (c) y 3 (d)).
4. Extracción de muestra. Se introduce un punzón para romper la base del cilindro y se extrae la muestra con unas pinzas de punta fina (v Figuras 3 (e) y 3 (f)).
5. Almacenamiento y conservación de muestras. La muestra se almacena en una bolsa de plástico sellada con 10 ml de agua con un 75% de alcohol. La muestra queda lista para ser llevada al laboratorio (Figura3 (h)).

El protocolo desarrollado para el procesamiento y tratamiento de muestras incluye los siguientes pasos:

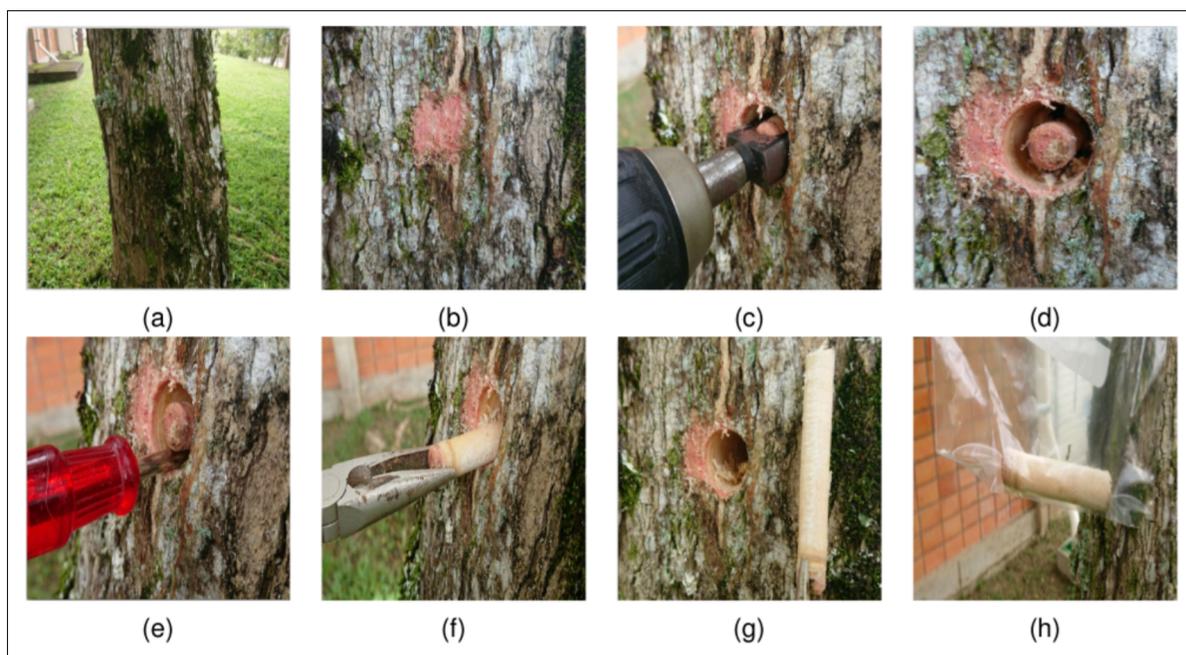


Fig. 3 Proceso de extracción de una muestra de madera.

1. Limpiado de la muestra. En el laboratorio, cada muestra de madera se limpia para eliminar restos de corteza y cambium, dejando solo albura y duramen. La muestra se mide y se pesa (ver Figura 4 (a)).
2. Seccionando la muestra. Cada muestra de madera se convierte en cuatro o cinco secciones cilíndricas utilizando una navaja de precisión (ver Figura 4 (b))
3. Corta de las secciones en cubos. Cada cara de cada sección cilíndrica se corta con una navaja de tungsteno para convertirla en un cubo (ver Figura 4 (c)).
4. Toma de fotografías. Cada cubo se fotografía dos veces, primero en estado fresco/verde, luego se somete a un proceso de secado de 24 a 72 horas a 104 C°, y nuevamente se fotografía en estado seco (ver Figura 4 (d)). Para cada cubo, se fotografía una cara transversal, una radial y una tangencial. Las fotografías se toman con un microscopio digital de bajo costo con un aumento de 50x - 200x y 5 megapíxeles, conectado a una computadora.
5. Registro de metadatos de cada cubo. Se registran metadatos como el lugar de extracción, # de identificación de la muestra, dimensiones, y peso, entre otros [1].

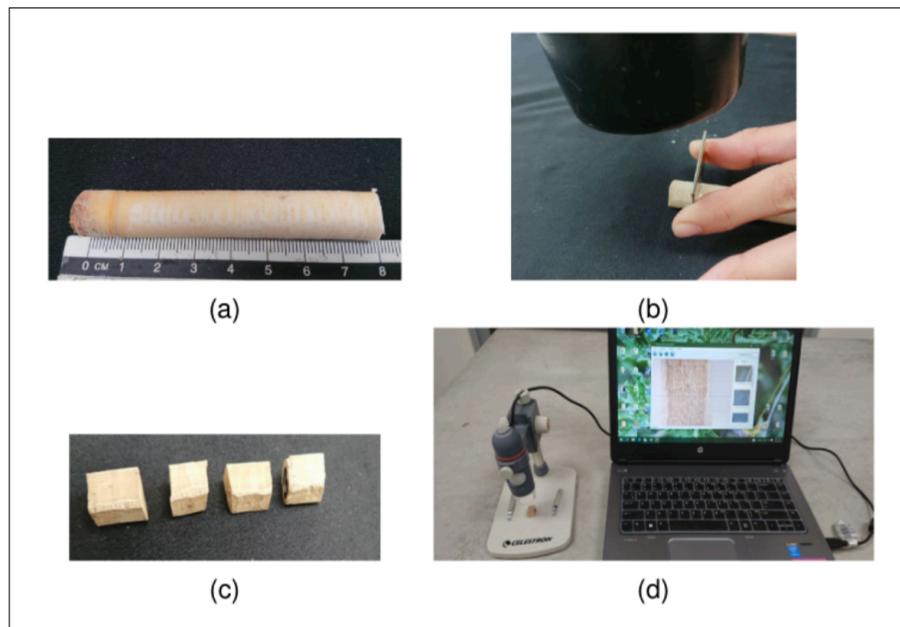


Fig. 4 Proceso de extracción de una muestra de madera.

7.2 Conjunto de datos

La base de datos de imágenes incluye fotografías de 146 especies de árboles de Costa Rica, correspondientes a 42 familias y 110 géneros. Incluye 3516 imágenes de cada una de las tres secciones, a saber, transversal, radial y tangencial y de cada una de y de cada sección dos fotos — en estado húmedo y seco — es decir, 21,096 imágenes. Cada imagen está en formato JPG sin comprimir y una resolución de 2,592x1,944 píxeles, aunque hay algunas imágenes de menor resolución. La lista completa de las 146 especies se presenta en la tabla del Anexo 1, que incluye el nombre científico y vernáculo, cuando éste existe. La Figura 5 muestra seis de las imágenes en la base de datos, con su nombre de familia y nombre científico.

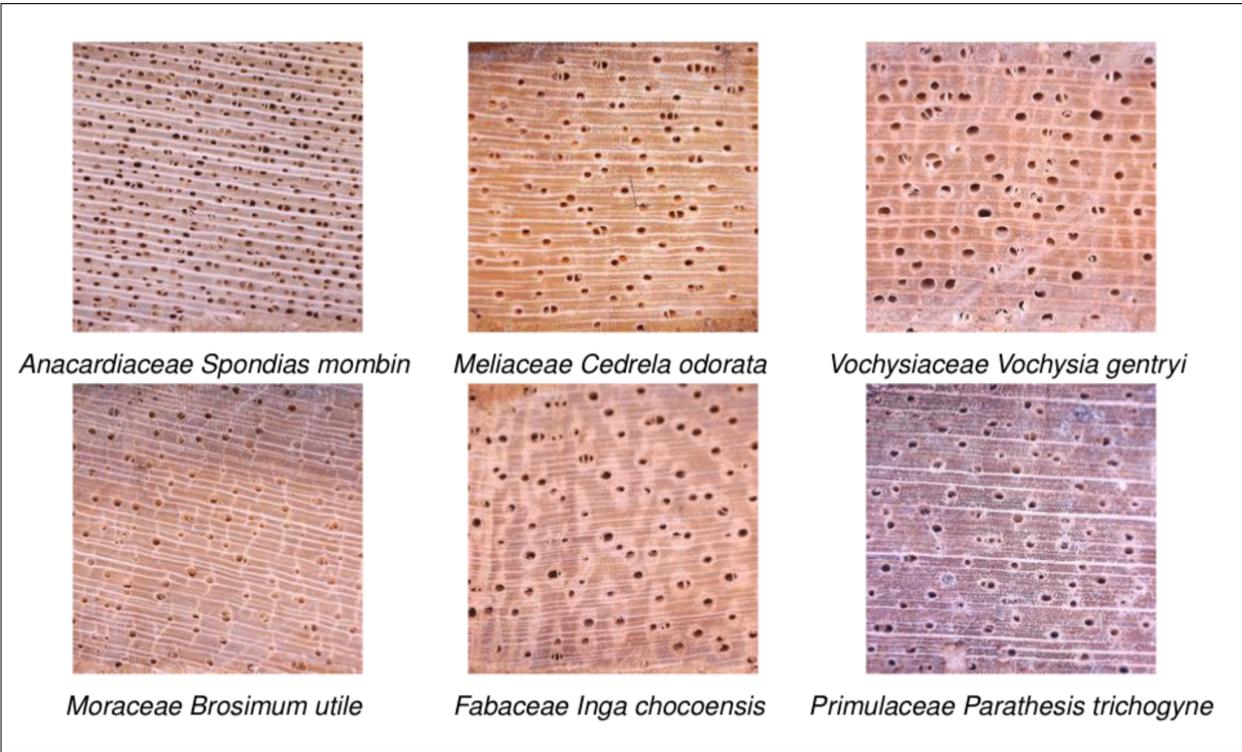


Fig. 5 Algunas imágenes en la base de datos.

7.2.1 Aumento de datos (data augmentation)

Los modelos de aprendizaje profundo regularmente implementan una etapa de aumento de datos para reducir el sobreajuste y mejorar el rendimiento en problemas con números de muestras desequilibrados en las diferentes clases [29], [30]. Debido a que la cantidad de imágenes que tenemos es pequeña para los enfoques de aprendizaje profundo, aplicamos dos técnicas de aumento de datos diferentes.

En primer lugar, dividimos cada imagen original en varias subimágenes que no se superponen y que están separadas por cuatro píxeles. Por ejemplo, si la resolución de la imagen original es 1,600x1,200 píxeles, podemos obtener 35 subimágenes de 224x224 píxeles. La Figura 6 ilustra esta técnica.

En segundo lugar, implementamos transformaciones como traslación, rotación, zoom, volteo horizontal, y volteo vertical. Para ello usamos la clase *ImageDataGenerator* de *Keras*, con los valores que se indican a continuación:

1. *rescale*: 1. / 255;
2. *height shift*: 0.2;
3. *height shift*: 0.2;
4. *horizontal flip*: Verdadero;
5. *vertical flip*: Verdadero;
6. *rotation*: 30;
7. *zoom*: 0.3.

7.2.2 Conjuntos de datos de entrenamiento y validación

Dado que el número de especímenes por especie en la base de datos varía de 3 a 20, decidimos seleccionar aquellas especies con más de 5 especímenes, lo cual reduce el número de especies a 75 (ver en la tabla del Apéndice 1 las especies destacadas en celdas celestes).

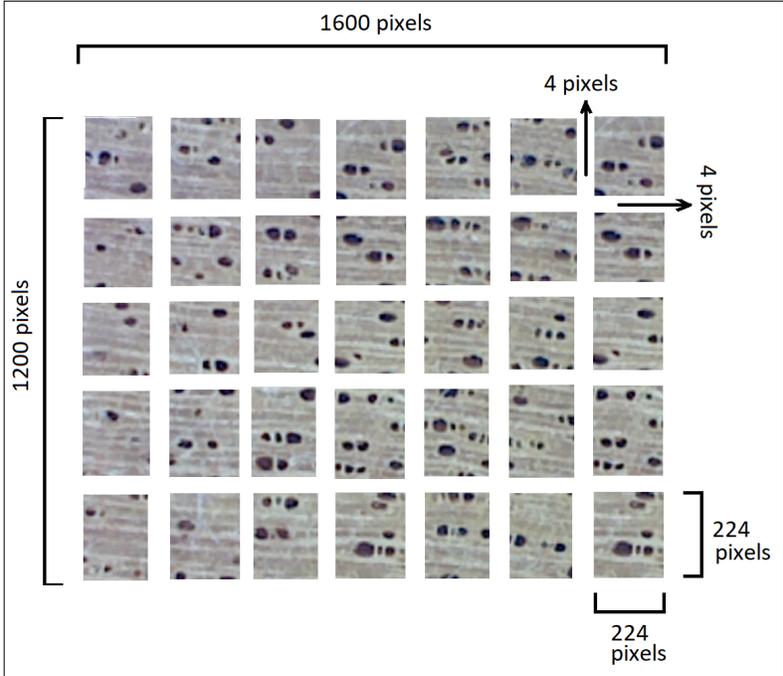


Fig. 6 División de una imagen en sub-imágenes (tomada de (Geovanni Figueroa-Mata et al. 2018b)).

Por otro lado, debido a que demostramos en esta investigación que las secciones transversales son más significativas al entrenar una red neuronal convolucional [31], seleccionamos estos planos de corte para entrenar nuestros modelos.

El conjunto de datos de imágenes para las 75 especies se dividió de la siguiente manera: 70 % para entrenamiento, 20 % para validación y 10 % para pruebas, esto da como resultado aproximadamente 1,712 imágenes para entrenamiento, 522 para validación y 426 para pruebas . Después de aplicar el aumento de datos de la división de imágenes, se obtienen 95,446 para entrenamiento, 29,109 para validación y 23,187 para pruebas.=

Al construir los conjuntos de entrenamiento, validación y prueba es muy importante evitar el sesgo conocido como Sesgo de Imagen de Muestras Mismo (SSPB) (descrito en detalle en [10]. Decimos que SSPB se evita (está ausente) si todas las imágenes del conjunto de datos original se distribuyen de modo que, para cada muestra S, todas sus imágenes se

utilicen exclusivamente en uno de los conjuntos de entrenamiento, validación o prueba. Nuestros conjuntos de datos para entrenamiento, validación y pruebas se han construido para que SSPB esté ausente. Eso genera precisiones más realistas aunque más bajas que las reportadas en la mayoría de las investigaciones, donde no evitan el sesgo y por lo tanto obtienen valores artificialmente altos.

7.3 Arquitectura de la CNN usada

Dado que el número de imágenes es demasiado pequeño para entrenar un modelo convolucional desde cero, aplicamos la técnica de transfer learning y re-entrenamiento (*fine-tuning* o *ajuste fino*) usando VGG16 como modelo base, previamente entrenado en el conjunto de datos de ImageNet.

Para lograr el ajuste fino, después de múltiples experimentos, eliminamos la capa Softmax del modelo base y la reemplazamos con la nuestra, agregando una capa de *Global Average Pooling* y dos capas densas como se muestra en la Figura 7. Además, congelamos los pesos de las primeras 10 capas para que permanezcan intactos durante todo el proceso de ajuste.

| | | |
|--|-------------|--------|
| global_average_pooling2d (Gl (None, 512) | | 0 |
| dense (Dense) | (None, 256) | 131328 |
| dropout (Dropout) | (None, 256) | 0 |
| dense_1 (Dense) | (None, 128) | 32896 |
| dropout_1 (Dropout) | (None, 128) | 0 |
| dense_2 (Dense) | (None, 75) | 9675 |
| ===== | | |
| Total params: 14,888,587 | | |
| Trainable params: 13,153,099 | | |
| Non-trainable params: 1,735,488 | | |

Fig. 7 Top layers del modelo.

8. Resultados

Los resultados de esta investigación van más allá de lo planteado inicialmente. Podemos clasificarlos como artículos (cada uno con resultados propios en cuanto a generación de nuevo conocimiento), una aplicación móvil probada pero aún no publicada, y desde el punto de vista de impacto un posicionamiento muy fuerte del TEC y de la Escuela de Computación y, en segunda instancia, de ing. Forestal y Matemática, en los campos Biodiversity Informatics y de Deep Learning para Identificación de Plantas, tanto por la cantidad de las publicaciones, como por que ya han sido citadas algunas de ellas. En la Subsección 8.1 presentamos los resúmenes de las publicaciones y en la Subsección 8.2 los resultados obtenidos con la versión actual de Cocobolo con la base de datos y metodología descrita en la Sección 7.

8.1 Publicaciones

Se publicó un total de 7 artículos en esta investigación, un octavo artículo ya se envió para publicación. En la propuesta se planteó la publicación de tres. Además, está en su fase final la tesis de Doctorado en Ingeniería del investigador Geovanni Figueroa y la estudiante Sharon López presentó exitosamente su trabajo final de graduación en la Escuela de Diseño Industrial; en él describe el diseño gráfico de la aplicación *Cocobolo*.

A continuación se presenta el título, número de citas recibidas (según Google Scholar) y el abstract de cada artículo que presenta, entre otras cosas, los resultados de esta investigación a lo largo de tres años. Los artículos se presentan en orden cronológico ascendente para apreciar la evolución gradual del proyecto y la profundización y especialización a través del tiempo.

1. G. Figueroa-Mata, E. Mata-Montero, J. C. Valverde-Otárola and D. Arias-Aguilar, "Automated Image-based Identification of Forest Species: Challenges and Opportunities for 21st Century Xylotheques," 2018 IEEE International Work Conference on Bioinspired Intelligence (IWOBI), San Carlos, 2018, pp. 1-8, doi: 10.1109/IWOBI.2018.8464206.

de citas: 6.

Abstract: The fast and accurate identification of forest species is fundamental to support their conservation, sustainable management, and, more specifically, the fight

against illegal logging. Traditionally, identifications are done by using dichotomous or polytomous keys based on physical characteristics of trees. However, these techniques are of little use when the trees have been cut, removed from their natural environment, and consequently there is only a partial subset of information on all those traits. In these cases, it may be possible to resort to the anatomical characteristics of the wood, which are less affected by environmental factors and therefore have a high diagnostic value in the identification. For some years now, computers have been used to support the identification processes through interactive keys and access to global repositories of digital images, among others. However, techniques based on machine learning have recently been developed and applied successfully to the identification of both plant and animal species. Consequently, automatic or semiautomatic techniques have been proposed to support botanists, taxonomists and non-experts in the species identification process. This article presents an overview of the use of these techniques as well as the current challenges and opportunities for the identification of forest species based on xylotheque samples.

2. Figueroa-Mata, Geovanni, et al. "Using Deep Convolutional Networks for Species Identification of Xylotheque Samples." 2018 IEEE International Work Conference on Bioinspired Intelligence (IWOB), 2018, doi:10.1109/iwobi.2018.8464216.

de citas: 5.

Abstract: Forest species identification is critical to scientifically support many environmental, commercial, forensic, archaeological, and paleontological activities. Therefore, it is very important to develop fast and accurate identification systems. We present a deep CNN for automated forest species identification based on macroscopic images of wood cuts. We first implement and study a modified version of the LeNet convolutional network, which is trained from scratch with a database of macroscopic images of 41 forest species of the Brazilian flora. With this network we achieve a top-1 accuracy of 93.6%. Additionally, we fine-tune the Resnet50 model with pre-trained weights on ImageNet to reach a top-1 accuracy of 98.03%, which improves previous published results of research on the same image database.

3. Mata-Montero, Erick, et al. "A Methodological Proposal for Collecting and Creating Macroscopic Photograph Collections of Tropical Woods with Potential for Use in Deep Learning." *Biodiversity Information Science and Standards*, vol. 2, 2018, doi:10.3897/biss.2.25260.

de citas: 2.

Abstract: Costa Rica is one of the countries with highest species biodiversity density in the world. More than 2,000 tree species have already been identified, many of which are used in the building, furniture, and packaging industries (Grayum et al. 2003). This rich diversity makes the correct identification of tree species very difficult. As a result, it is common to see in the national market that species are commercialized with mistaken

identifications, which makes quality control particularly challenging. In addition, because 90 timber tree species have been classified as “threatened” in Costa Rica, correct identifications are indispensable for law-enforcement.

The traditional system for tree species identification is based on macro and microscopic evaluations of the anatomy of the wood. It entails assessing anatomical features such as patterns of vessels, parenchymas, and fibers. Typically, 7.7 x 10 cm pieces of wood cuts are used to identify the tree species (Pan and Kudo 2011, Yusof et al. 2013). However, assessing these features is extremely difficult for taxonomists because properties of the wood can vary considerably due to environmental conditions and intra-specific genetic variability.

Deep learning techniques have recently been used to identify plant species (Carranza-Rojas et al. 2017a, Carranza-Rojas et al. 2017b) and are potentially useful to detect subtle differences in patterns of vessels, parenchyma, and other anatomical features of wood. However, it is necessary to have a large collection of macroscopic photographs of individuals from various parts of the country (Pan and Kudo 2011). As a first step in the application of deep learning techniques, we have defined a formal, standard protocol for collecting wood samples, physically processing them, taking pictures, performing data augmentation, and using metadata to provide the primary data necessary for deep learning applications. Unlike traditional xylotheque sampling methods that destroy trees or use wood from fallen trees, we propose a method that extracts small size samples with sufficient quality for anatomical characterization but does not affect the growth and survival of the individual.

This study has been developed in three forest permanent plots in Costa Rica, all of which are sites with historical growth data over the last 20 years. We have so far evaluated 40 species (10 individuals per species) with diameters greater than 20 cm. From each individual, a cylindrical sample of 12 mm diameter and 7.5 cm in length was extracted with a cordless drill. Each sample is then cut into five of 8 x 8 x 8 mm cubes and further processed to result in curated xylotheque samples, a dataset with all relevant metadata and original images, and a dataset with images obtained by performing data augmentation on the original images.

4. Mata-Montero, Erick, et al. “Deep Learning for Forest Species Identification Based on Macroscopic Images.” *Biodiversity Information Science and Standards*, vol. 2, 2018, doi:10.3897/biss.2.25261.

de citas: 0.

Abstract: The fast and accurate identification of forest species is critical to support their sustainable management, to combat illegal logging, and ultimately to conserve them. Traditionally, the anatomical identification of forest species is a manual process that requires a human expert with a high level of knowledge to observe and differentiate certain anatomical structures present in a wood sample (Wiedenhoeft (2011)).

In recent years, deep learning techniques have drastically improved the state of the art in many areas such as speech recognition, visual object recognition, and image and music information retrieval, among others (LeCun et al. (2015)). In the context of the automatic identification of plants, these techniques have recently been applied with great success (Carranza-Rojas et al. (2017)) and even mobile apps such as Pl@ntNet have been developed to identify a species from images captured on-the-fly (Joly et al. (2014)). In contrast to conventional machine learning techniques, deep learning techniques extract and learn by themselves the relevant features from large datasets.

One of the main limitations for the application of deep learning techniques to forest species identification is the lack of comprehensive datasets for the training and testing of convolutional neural network (CNN) models. For this work, we used a dataset developed at the Federal University of Parana (UFPR) in Curitiba, Brazil, that comprises 2939 images in JPG format without compression and a resolution of 3.264 x 2.448 pixels. It includes 41 different forest species of the Brazilian flora that were cataloged by the Laboratory of Wood Anatomy at UFPR (Paula Filho et al. (2014)). Due to the lack of comprehensive datasets world wide, this has become a benchmark dataset in previous research (Paula Filho et al. (2014), Hafemann et al. (2014)).

In this work, we propose and demonstrate the power of deep CNNs to identify forest species based on macroscopic images. We use a pre-trained model which is built from the resnet50 model and uses weights pre-trained on ImageNet. We apply fine-tuning by first truncating the top layer (softmax layer) of the pre-trained network and replacing it with a new softmax layer. Then we train again the model with the dataset of macroscopic images of species of the Brazilian flora used in (Hafemann et al. (2014), Paula Filho et al. (2014)).

Using the proposed model we achieve a top-1 98% accuracy which is better than the 95.77% reported in (Hafemann et al. (2014)) using the same data set. In addition, our result is slightly better than the reported in (Paula Filho et al. (2014)) of 97.77% which was obtained by combining several conventional techniques of computer vision.

5. G. Figueroa-Mata, E. Mata-Montero, J. C. Valverde-Otárola and D. Arias-Aguilar, "Evaluating the Significance of Cutting Planes of Wood Samples When Training CNNs for Forest Species Identification," 2018 IEEE 38th Central America and Panama Convention (CONCAPAN XXXVIII), San Salvador, 2018, pp. 1-5, doi: 10.1109/CONCAPAN.2018.8596406.

de citas: 1.

Abstract: With the goal of quantifying the importance of each of the cutting planes of wood samples in the training process of a convolutional neural network that identifies forest species based on images of those cutting planes, we propose a convolutional model that is trained from scratch with images of transverse, radial, and tangential sections of Costa Rican forest species wood samples. The best Top1-accuracy

achieved is 89.58% when the network is trained with transverse sections only. Because this is more than 20% better than the accuracy achieved when using any of the other two sections individually, we conclude that this is the most significant section of all three. This is consistent with current practice of experts, who prefer this cutting plane when conducting manual identifications based on anatomical features of wood samples.

6. Figueroa-Mata, Geovanni, and Erick Mata-Montero. "Using a Convolutional Siamese Network for Image-Based Plant Species Identification with Small Datasets." *Biomimetics*, vol. 5, no. 1, 2020, p. 8., doi:10.3390/biomimetics5010008.

de citas: 1.

Abstract: The application of deep learning techniques may prove difficult when datasets are small. Recently, techniques such as one-shot learning, few-shot learning, and Siamese networks have been proposed to address this problem. In this paper, we propose the use of a convolutional Siamese network (CSN) that learns a similarity metric that discriminates between plant species based on images of leaves. Once the CSN has learned the similarity function, its discriminatory power is generalized to classify not just new pictures of the species used during training but also entirely new species for which only a few images are available. This is achieved by exposing the network to pairs of similar and dissimilar observations and minimizing the Euclidean distance between similar pairs while simultaneously maximizing it between dissimilar pairs. We conducted experiments to study two different scenarios. In the first one, the CSN was trained and validated with datasets that comprise 5, 10, 15, 20, 25, and 30 pictures per species, extracted from the well-known FLAVIA dataset. Then, the trained model was tested with another dataset composed of 320 images (10 images per species) also from FLAVIA. The obtained accuracy was compared with the results of feeding the same training, validation, and testing datasets to a convolutional neural network (CNN) in order to determine if there is a threshold value t for dataset size that defines the intervals for which either the CSN or the CNN has better accuracy. In the second studied scenario, the accuracy of both the CSN and the CNN—both trained and validated with the same datasets extracted from FLAVIA—were compared when tested on a set of images of leaves of 20 Costa Rican tree species that are not represented in FLAVIA.

7. Valverde, JC; Arias, D; Mata, E; Figueroa, G; Zamora, N. (2020). Determinación de las condiciones fotográficas óptimas para la caracterización anatómica de diez especies maderables de Costa Rica. *Revista Cubana de Ciencias Forestales*, 8 (3).

de citas: 0.

Abstract: Hay una ausencia significativa de estudios en especies maderables tropicales que muestren la optimización en cantidad y dimensiones de fotografía de madera en estudios anatómicos. Este aspecto restringe la representatividad estadística en

estudios anatómicos en especies tropicales, de manera tal el estudio presentó como objetivo determinar la dimensiones y cantidad mínima de fotografías macroscópicas representables en especies tropicales y analizar la relación entre dimensiones fotográficas y características anatómicas. Para esto, se seleccionaron diez especies arbóreas, las cuales se colectaron de ocho a quince árboles por especie muestras cilíndricas de madera de 12,5 mm de diámetro y longitud de 75 mm, de cada muestra se generaron cinco cubos de 10 mm de cara, los cuales se secaron y fotografiaron en la cara transversal. Los resultados mostraron una variación de 19 a 35 fotografías como cantidad mínima por especie, siendo *Spondias mombin* la especie con mayor requerimiento de fotografías con 35, mientras *Caryocar costarricense* la especie con menor cantidad de fotografías mínimas, además la dimensión óptima común de fotografías fue de 1,25 x 1,25 mm, siendo *Peltogyne purpurea* la especie que se pudo trabajar con dimensiones todavía más bajas; la combinación de la cantidad de fotografías mínimas y la dimensión óptima permitió tener representatividades y reproducibilidades superiores al 90%. Finalmente, se encontró una correlación entre la dimensión de la imagen y el diámetro de vasos, encontrando conforme el diámetro de vasos es menor, es posible trabajar con fotografías de menor dimensión con una relación superior al 70%.

8. Valverde, JC; Arias, D; Mata, E; Figueroa, G; Zamora, N. (2020). Validación de un protocolo fotográfico digital para análisis macroscópico de la anatomía y colorimetría en madera de 10 especies arbóreas de Costa Rica.

de citas: 0. No se ha publicado.

Abstract: El proceso de digitalización de muestras de madera para su identificación y estudio ha tomado relevancia en la última década, por lo que es necesario considerar los aspectos fotográficos que generen representatividad de las imágenes con respecto a la muestra física. El presente estudio consistió en determinar las condiciones de luminosidad óptimas en fotografías macroscópicas para identificación de variables anatómicas y colorimétricas en especies arbóreas tropicales de Costa Rica. Se utilizaron diez especies maderables con no menos de 10 árboles muestreados, de cada individuo se extrajeron cinco cubos de madera de 10 mm de arista y se fotografiaron con un estereoscopio con un aumento de 20X bajo cuatro protocolos de luminosidad. En el proceso se evaluó la variación del color (bajo las coordenadas L^* , a^* y b^*), diferencial de color (ΔE^*) y chroma (ΔC^*), además de la densidad y diámetro de vasos. Los resultados mostraron que la luminosidad del 50% fue la que mostró la mayor similitud con la colorimetría de la madera, obteniendo valores de ΔE^* inferiores a 6 en todas las especies y valores de ΔC^* dentro del rango óptimo de 5 a 7. Con respecto a la parte anatómica, se dio el mismo comportamiento con las diez especies, encontrando que los tratamientos de luminosidad al 25 y 50% no mostraron diferencias significativas, mientras las luminosidades al 75 y 100% tendieron a subestimar los valores. De los resultados obtenidos se puede decir que el tratamiento luminosidad al 25% es poco efectivo por el oscurecimiento de la superficie, mientras

que las exposiciones al 75 y 100% tendieron a aclarar la superficie y subestimación de características anatómicas.

8.2 Resultados al desarrollar la aplicación Cocobolo

Cocobolo consta de un front end (ver descripción detallada en Apéndice que presenta el trabajo final de graduación de la carrera en Ing. en DI del TEC, de la estudiante Sharon López), que es la interfaz que se ejecuta en un celular con sistema operativo Android, y de un back end, que es la CNN que se entrenó según la descripción resumida en la Sección 7. Por lo tanto, para hacer identificaciones requiere que el usuario esté conectado a Internet.

El front end de *Cocobolo* fue diseñado siguiendo la metodología propuesta en [32] para el desarrollo de herramientas interactivas de software. Se usó *Figma*⁶ para el diseño gráfico y la herramienta *Ionic*⁷ versión 4.0 para general la aplicación. *Node.js*⁸ (versión 12.16.1) fue usado como un intermediario para el manejo de usuarios, consultar las base de datos y comunicación entre el front end y el back end. La creación y administración de las bases de datos de usuarios y de información textual y visual de especies se implementó en *MongoDB*⁹ 4.4. Finalmente, se usó *TensorFlow Serving* 2.0 para poner en producción la CNN entrenada y validada. El back-end corre bajo *Ubuntu* 18.04 y fue desarrollado usando *Keras* y *TensorFlow* 2.0.

Cocobolo permite identificar imágenes de cortes de madera almacenadas en la galería de su teléfono o usar la cámara para tomar una foto e identificarla inmediatamente. El proceso de identificación responde con un ranking que incluye las 3 especies más probables, cada una con su nombre científico, su nombre común y una imagen. El usuario también puede consultar información sobre las especies con las que se entrenó la CNN y compartir la identificación por correo electrónico o Whatsapp.

⁶ <https://www.figma.com>.

⁷ <https://ionicframework.com/docs>.

⁸ <https://nodejs.org/en/>.

⁹ <https://www.mongodb.com>.

La Figura 8 ilustra un caso de uso. Al escoger la opción “Identificar” se le presenta la pantalla de la Figura 8 (a) y el usuario puede escoger “Galería”, que es la galería de fotos en el celular y en el cual hay 8 fotos previamente guardadas (ver Figura 8 (b)). El usuario escoge, por ejemplo, la tercera foto de fila superior y Cocobolo le responde con el ranking en la pantalla de la Figura 8 (c). Cada foto de las especies en el ranking tiene un estimado de la probabilidad de acierto, nombre común, la familia, y nombre científico.

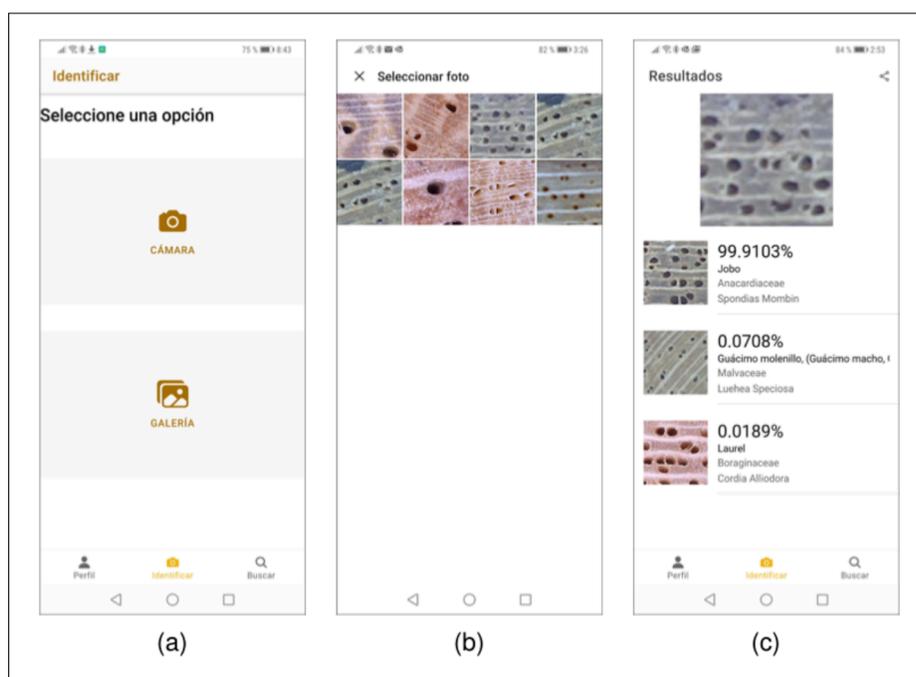


Fig. 8 Ejemplo de una identificación usando la galería.

Presentamos a continuación un breve análisis de los resultados alcanzados en el entrenamiento, validación y pruebas con las 75 especies de árboles. A través de los tres años de duración del proyecto hicimos pruebas con conjuntos de aproximadamente 20, 40, y ahora 75 especies. Obviamente, entre mayor sea el número de especies, menor tiende a ser la precisión en las identificaciones. No obstante los algoritmos de aprendizaje profundo han demostrado ser bastante escalables, por lo cual los resultados son bastante satisfactorios.

Se realizó varios experimentos con el modelo convolucional descrito en la sección 7.3. Diferentes valores para hiperparámetros como la tasa de aprendizaje y el tamaño del lote fueron también implementados y probados. Además, se experimentó con algunos optimizadores como *SGD*, *Adadelta*, *Adam* y *RMSprop*. El mejor resultado obtenido fue una precisión top-1 de 65,6% durante la fase de entrenamiento. Para ello utilizamos un optimizador *SGD* con una tasa de aprendizaje que se ajusta automáticamente en función del cambio de la precisión de validación. El modelo fue entrenado por 30 épocas como se muestra en la Figura 9.

En la fase de pruebas, se logró una precisión top-1 de 57.4% y precisión top-3 de 74.5%. Además, si se usa la regla de votación por mayoría (MVR), la precisión top-1 fue de 70.5%. En la regla de votación MVR, la especie predicha para una imagen es la especie que corresponde a la mayoría de las especies predichas para cada subimagen en la imagen (las que se ilustran en la Figura 6).

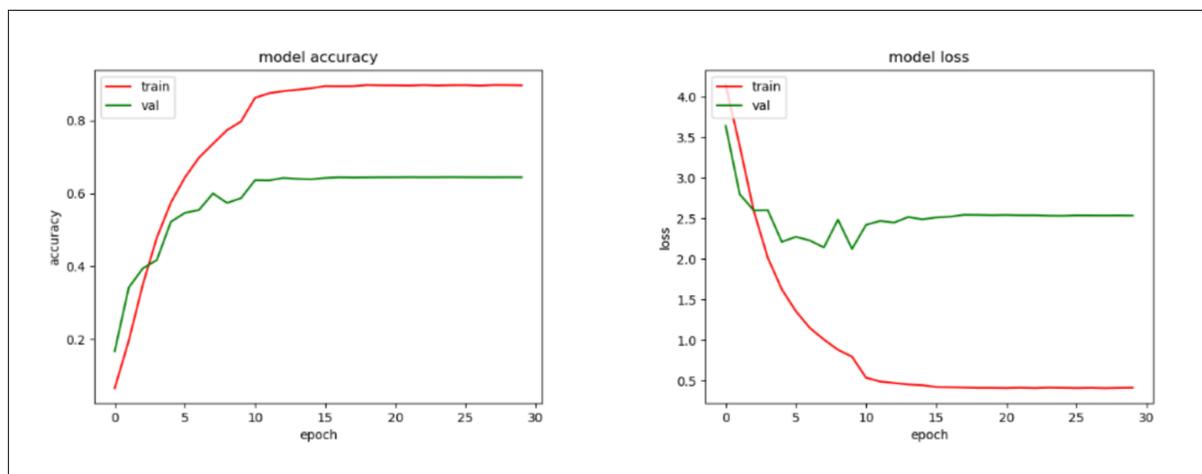


Fig. 9 Precisión en el entrenamiento y pérdidas en el modelo de CNN

De las 75 especies actualmente usadas, hay 5 que la CNN no puede identificar del todo: quizá la razón sea que sus imágenes son muy similares como podemos ver en la Figura 10.

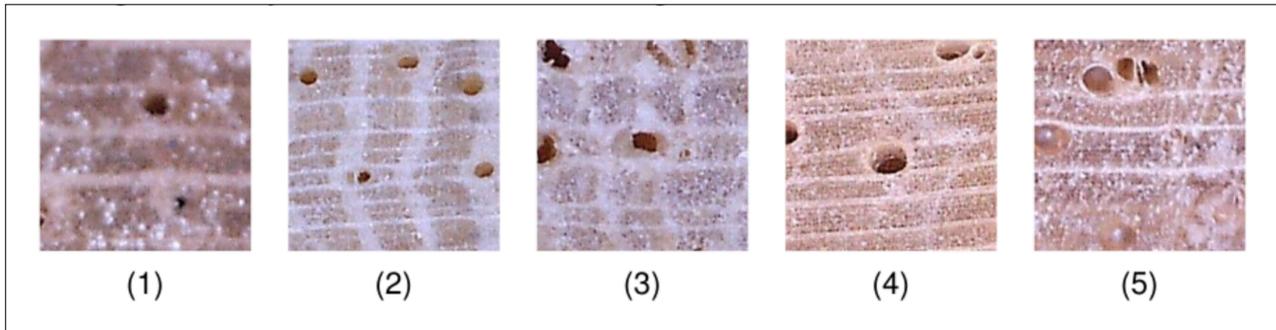


Fig. 10 Especies no identificadas por la CNN (precisión = 0).

8.3 Ampliación de la Xiloteca Víctor Rojas

El proceso de recolectar muestras, prepararlas para convertirlas en cubos, tomar fotografías y almacenarlas en la xiloteca ha sido un resultado fundamental de este proyecto. Se ha establecido protocolos y un flujo de trabajo innovador que es ampliamente conocido por al menos dos investigadores y varios estudiantes de la Escuela de Ing, Forestal del TEC, por lo cual puede ser parte del flujo de trabajo normal en la Xiloteca. Como resultado de las 19 giras realizadas, la Xiloteca cuenta en este momento con aproximadamente 982 muestras convertidas en aproximadamente 982x4 cubos, 27,900 fotografías y una herramienta para hacer identificación automática de 75 especies. Hasta donde sabemos, no existe en Latinoamérica otra xiloteca con tantas muestras, de este tipo, ni con una base de datos de imágenes tan completa, ni con una herramienta de identificación como *Cocobolo*. El número de especies representadas en la Xiloteca crecerá naturalmente sin necesidad de reprogramar la herramienta, basta con re-entrenarla con los nuevos datos de otras especies o con los datos adicionales de las especies actualmente representadas.

Otro resultado no planteado al inicio de este proyecto, es que pruebas preliminares demuestran que las muestras recolectadas con este nuevo método se pueden utilizar no

solo para entrenar algoritmos de aprendizaje de máquinas como *Cocobolo*, sino para la caracterización anatómica de especies maderables de Costa Rica, como se explica en las dos últimos artículos [33], [34] descritos en la sección 8.1.

9. Discusión y conclusiones

Los objetivos de este trabajo de investigación fueron ampliamente cubiertos y sobrepasados. Los resúmenes de las publicaciones presentados en la Sección 8.1, así como los resultados obtenidos al desarrollar la aplicación *Cocobolo* (Sección 8.2) y el número de muestras, cobertura taxonómica, base de datos fotográfica, protocolos y aplicaciones potenciales para el material agregado a la Xiloteca Víctor Rojas así lo demuestran.

El impacto académico de un trabajo de investigación normalmente se mide por el número de publicaciones y especialmente el número de citas. Lo primero es muy sencillo de calcular, en nuestro caso es 7 publicaciones. Lo segundo toma varios años para sopesarse debidamente. Sin embargo, se han logrado 15 citas en solo tres años según Google Scholar.

Adicionalmente, como fue mencionado al inicio de la Sección 8, este trabajo consolida el posicionamiento del TEC en actividades de Informática para la Conservación de la Biodiversidad, específicamente con respecto a identificación de especies forestales usando técnicas de deep learning, también al Programa de eScience y al grupo de investigación PARMA, a los cuales pertenecen los investigadores Figueroa y Mata.

Finalmente, queremos cerrar este informe subrayando que este proyecto ha sido la semilla de otras actividades que enriquecen el ecosistema de la investigación en Informática para la Conservación de la Biodiversidad en el TEC. Generó la tesis de Doctorado en Ingeniería del candidato a Doctor en Ingeniería Geovanni Figueroa; es la base de un proyecto de investigación que actualmente ejecutamos: “Descubriendo los rasgos usados por algoritmos de deep learning en la identificaciones de taxones de plantas”; y ha consolidado la colaboración internacional con colegas del prestigioso centros de

investigación CIRAD, en Francia, donde Mata y Figueroa han desarrollado pasantías de investigación en los últimos tres años.

10. Recomendaciones

Las siguientes son recomendaciones para trabajo futuro:

1. Dada la necesidad de usar grandes cantidades de datos para el desarrollo de algoritmos con el enfoque deep learning, debe continuarse la recolecta y procesamiento de muestras usando los protocolos definidos en este proyecto.
2. Nuevos enfoques como one-shot, zero-shot y few-shot learning deben explorarse para lidiar con los limitados conjuntos de datos de fotos existentes sobre muchas especies. En esta investigación se demostró que uno de ellos (redes siamesas) da muy buenos resultados cuando se usa con bases de datos de imágenes de hojas [35], está por verse si también se aplica a conjuntos de datos de imágenes de cortes de madera. Un estudiante del Programa de Maestría en Computación (Víctor Esteban Arce) está explorando ese enfoque para identificar árboles a partir de fotos de cortes de madera.
3. La capacidad explicativa del enfoque deep learning es casi cero. Los mapas de saliencia, CAM (Class Activation Maps) y redes de deconvolución pueden ser una manera de articular un discurso visual y textual que describe los caracteres diagnósticos usados por una CNN al hacer las clasificaciones. Una estudiante del Programa de Maestría en Computación (Ileana Montealegre) está explorando ese enfoque en el dominio de hojas de plantas pero debería ampliarse al dominio de fotos de cortes de madera.
4. Mantener en el flujo de trabajo regular de la Xiloteca Víctor Rojas la recolección y procesamiento de muestras con los nuevos protocolos para enriquecer la Xiloteca, la base de datos de imágenes y entrenar el software con muestras de mayor cobertura taxonómica, tal vez enfocándose en especies de interés comercial o amenazadas.

11. Agradecimientos

El equipo de investigadores agradece a la VIE el apoyo financiero para desarrollar este proyecto y el apoyo para asistir a congresos internacionales a presentar los resultados de este trabajo.

Agradecemos también a la Dirección de Posgrados y al Programa de Doctorado en Ingeniería por apoyar financieramente la pasantía del candidato a doctor Geovanni Figueroa en el CIRAD, Montpellier.

Además, agradecemos profundamente al Ing. Nelson Zamora por su apoyo en la recolecta de muestras para crear el conjunto de datos que enriqueció la xiloteca institucional y proveyó los datos para los experimentos.

Mención especial merecen los estudiantes Jean Carlo Paniagua, Sharon López, Monserrat Aguilar, Adriana Fallas, Devon Mora, y Óscar Ortega. Jean Carlo programó excelentemente el front end y middleware necesario para convertir la CNN en una herramienta de producción, con manejo de múltiples usuarios desde un servidor y la capacidad para actualizarse eficientemente cuando el back end se entrene con más datos. Sharon, por su parte convirtió los requerimientos de la aplicación en un diseño limpio, que facilita el uso de Cocobolo de manera intuitiva y eficiente y que fue debidamente validado con usuarios. Por su parte, Monserrat, Adriana, Devon y Óscar trabajaron meticulosamente en el procesamiento de las muestras que generó una colección de muestras en forma de cubos debidamente documentados con metadatos y sus respectivas fotografías. Sin el trabajo de este excelente grupo de estudiantes de Ing. en Computación, Diseño Industrial y Forestal, este proyecto no hubiera sido posible.

12. Referencias

[1] Mata-Montero, Erick, et al. "A Methodological Proposal for Collecting and Creating Macroscopic Photograph Collections of Tropical Woods with Potential for Use in Deep Learning." *Biodiversity Information Science and Standards*, vol. 2, 2018, doi:10.3897/biss.2.25260.

- [2] E. Corea Arias, E. Arnáez Serrano, I. Moreira González, R. Cordero Solórzano y M. Castillo Ugalde, *Recurso forestal amenazado: seis especies en peligro crítico de extinción en Costa Rica*, Cartago: Editorial Tecnológica de Costa Rica, 2014.
- [3] R. Quesada Monge, «Especies forestales vedadas y bajo otras categorías de protección,» *Kurú*, vol. 1, nº 2, pp. 1-5, 2004.
- [4] G. Figueroa-Mata, E. Mata-Montero, J. C. Valverde-Otárola and D. Arias-Aguilar, "Automated Image-based Identification of Forest Species: Challenges and Opportunities for 21st Century Xylotheques," 2018 IEEE International Work Conference on Bioinspired Intelligence (IWOBI), San Carlos, 2018, pp. 1-8, doi: 10.1109/IWOBI.2018.8464206.
- [5] J. E. Díaz Vaz, «Claves para la identificación de maderas de árboles nativos y cultivados de Chile,» *Bosque*, vol. 3, nº 1, pp. 15-25, 1979.
- [6] R. Moya Roque y A. Rodríguez, «Identificación Macroscópica de Árboles Maderables por el corte Transversal de la Corteza y la Madera,» de V Congreso Forestal Latinoamericano, Lima-Perú, 2011.
- [7] F. Kollmann, *Tecnología de la Madera y sus Aplicaciones*, vol. 1, Madrid: Instituto Forestal de Investigación y Experimentación y el servicio de la madera, 1959, p. 672.
- [8] M. Bravo Morales y N. Bravo Morales, «Monografías.com,» Diciembre 2009. [En línea]. Disponible: <http://www.monografias.com/trabajos75/manual-identificacion-maderas-forestales/manual-identificacion-maderas-forestales.shtml>. [Último acceso: Lunes Enero 2016].
- [9] M. Araya Montero y R. Moya Roque, «Claves de identificación macroscópica de la madera de 110 especies del Caribe Norte de Costa Rica,» *Revista Forestal Mesoamericana Kurú*, vol. 10, nº 24, pp. 34-52, 2013.
- [10] Carranza-Rojas, Jose, Erick Mata-Montero, and Herve Goeau (2018). "Hidden Biases in Automated Image-Based Plant Identification". In: 2018 IEEE International Work Conference on Bioinspired Intelligence (IWOBI), pp. 1–9. DOI:10.1109/IWOBI.2018.8464187.
- [11] Carranza-Rojas, José. "Towards Multi-Level Classification in Deep Plant Identification" Diciembre 2018. Doctorate in Engineering Thesis. Instituto Tecnológico de Costa Rica. Available at: <https://repositoriotec.tec.ac.cr/handle/2238/10341?locale-attribute=en>.
- [12] Figueroa-Mata, Geovanni, et al. "Using Deep Convolutional Networks for Species Identification of Xylotheque Samples." 2018 IEEE International Work Conference on Bioinspired Intelligence (IWOBI), 2018, doi:10.1109/iwobi.2018.8464216.

- [13] Mata-Montero, Erick, et al. "Deep Learning for Forest Species Identification Based on Macroscopic Images." *Biodiversity Information Science and Standards*, vol. 2, 2018, doi:10.3897/biss.2.25261.
- [14] Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E Hinton (2012). "ImageNet Classification with Deep Convolutional Neural Networks". In: *Advances in Neural Information Processing Systems 25*. Ed. by F. Pereira et al. Curran Associates, Inc., pp. 1097–1105. URL: <http://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf>.
- [15] Dargan, S. et al. (July 2019). "A Survey of Deep Learning and Its Applications: A New Paradigm to Machine Learning". In: *Archives of Computational Methods in Engineering*, pp. 1886–1784.
- [16] Sengupta, Saptarshi et al. (2019). "A Review of Deep Learning with Special Emphasis on Architectures, Applications and Recent Trends". arXiv: 1905.13294 [cs.LG].
- [17] Raghu, Maithra and Eric Schmidt (2020). "A Survey of Deep Learning for Scientific Discovery". arXiv: 2003.11755 [cs.LG].
- [18] Kwon, Ohkyung et al. (Jan. 2017). "Automatic wood species identification of Korean softwood based on convolutional neural networks". In: *Journal of the Korean Wood Science and Technology* 45, pp. 797–808. DOI:10.5658/WOOD.2017.45.6.797.
- [19] Ravindran, Prabu, Adriana Costa, et al. (Mar. 2018). "Classification of CITES-listed and other neotropical. Meliaceae wood images using convolutional neural networks". In: *Plant Methods* 1, pp. 790–800. DOI: 10.1016/j.neucom.2016.12.038.
- [20] Lainez, Marco Paul E. Apolinario, Samuel G. Huamán Bustamante, and Gabriel Clostre Orellana (2018). "Deep Learning Applied to Identification of Commercial Timber Species from Peru". In: *2018 IEEE XXV International Conference on Electronics, Electrical Engineering and Computing (INTERCON)*, pp. 1–4.
- [21] Oktaria, Anindita Safna, Esa Prakasa, and Efri Suhartono (2019). "Wood Species Identification using Convolutional Neural Network (CNN) Architectures on Macroscopic Images". In: *The Journal of Information Technology and Computer Science* 3.4.
- [22] Ravindran, Prabu, Emmanuel Ebanyenle, et al. (2019). "Image Based Identification of Ghanaian Timbers Using the XyloTron: Opportunities, Risks and Challenges". In: *33rd Conference on Neural Information Processing Systems (NeurIPS 2019)*.

[23] Apolinario, Marco, Daniel Paredes, and Samuel Huaman Bustamante (Dec. 2019). "Open Set Recognition of Timber Species Using Deep Learning for Embedded Systems". In: IEEE Latin America Transactions 17, pp. 2005–2012. DOI : 10.1109/TLA.2019.9011545.

[24] Filho, Pedro L. Paula et al. (2014). "Forest species recognition using macroscopic images". In: Mach. Vis. Appl. 25.4, pp. 1019–1031. DOI:10.1007/s00138-014-0592-7. URL: <http://dx.doi.org/10.1007/s00138-014-0592-7>.

[25] Yang, J. et al. (2019). "Application of Deep Learning in Wood Classification". In: 2019 IEEE International Conference on Computer Science and Educational Informatization (CSEI), pp. 124–129.

[26] Yusof, Rubiyah et al. (2020). "Transfer Learning Approach in Automatic Tropical Wood Recognition System". In: Computational and Experimental Simulations in Engineering . Ed. by Hiroshi Okada and Satya N. Atluri. Cham: Springer International Publishing, pp. 1225–1233.

[27] Verly Lopes DJ, Burgreen GW, Entsminger ED. (2020). "North American Hardwoods Identification Using Machine-Learning". In: Forests 3.11, p. 298.

[28] The Forest Species Database – Macroscopic (2020). URL: <http://web.inf.ufpr.br/vri/databases/forest-species-database-macroscopic/> (visited on 08/05/2020).

[29] Goodfellow, Ian, Yoshua Bengio, and Aaron Courville (2016). "Deep learning". MIT press.

[30] Wong, Sebastien C. et al. (2016). "Understanding data augmentation for classification: When to warp?" In: CoRR abs/1609.08764. arXiv: 1609.08764 . URL: <http://arxiv.org/abs/1609.08764>.

[31] G. Figueroa-Mata, E. Mata-Montero, J. C. Valverde-Otárola and D. Arias-Aguilar, "Evaluating the Significance of Cutting Planes of Wood Samples When Training CNNs for Forest Species Identification," 2018 IEEE 38th Central America and Panama Convention (CONCAPAN XXXVIII), San Salvador, 2018, pp. 1-5, doi: 10.1109/CONCAPAN.2018.8596406.

[32] Hernández-Castro, Franklin (2016). Usability cookbook: metodología para el análisis y diseño de aplicaciones. URL: <https://repositoriotec.tec.ac.cr/handle/2238/6776>.

[33] Valverde, JC; Arias, D; Mata, E; Figueroa, G; Zamora, N. (2020). Determinación de las condiciones fotográficas óptimas para caracterización anatómica de diez especies maderables de Costa Rica. Revista Cubana de Ciencias Forestales, 8 (3).

[34] Validación de un protocolo fotográfico digital para análisis macroscópico de la anatomía y colorimetría en madera de 10 especies arbóreas de Costa Rica. Sometido a publicación.

[35] Figueroa-Mata, Geovanni, and Erick Mata-Montero. "Using a Convolutional Siamese Network for Image-Based Plant Species Identification with Small Datasets." *Biomimetics*, vol. 5, no. 1, 2020, p. 8., doi:10.3390/biomimetics5010008.

13. Apéndices

1. Lista de especies para las que se recolectó al menos una muestra y ya tienen fotografías (las que tienen cinco o más muestras se muestran en celdas celestes).
2. Artículos publicados.
3. Diseño de la interfaz de la aplicación Cocobolo.