



**Detección de individuos y grupos de palmas de cera (*Ceroxylon sp*) en imágenes  
satelitales de alta resolución, mediante herramientas de Aprendizaje Profundo en  
ArcGIS Pro**

**JUAN PABLO RAMOS PATIÑO**

Código: 11792012724

**CRISTIAN FERNANDO VECINO SALCEDO**

Código: 11792012544

**Universidad Antonio Nariño**

Especialización en Sistemas de Información Geográfica

Facultad de Ingeniería Ambiental y Civil

Bogotá D.C, Colombia

2022



**Detección de individuos y grupos de palmas de cera (*Ceroxylon sp*) en imágenes  
satelitales de alta resolución, mediante herramientas de Aprendizaje Profundo en  
ArcGIS Pro**

**JUAN PABLO RAMOS PATIÑO**

**CRISTIAN FERNANDO VECINO SALCEDO**

Proyecto de grado presentado como requisito parcial para optar al título de:  
**Especialista en Sistemas de Información Geográfica**

Director:

Andrés Felipe Carvajal Vanegas, Dr.

**Universidad Antonio Nariño**

Especialización en Sistemas de Información Geográfica

Facultad de Ingeniería Ambiental y Civil

Bogotá D.C, Colombia

2022



## **Agradecimientos**

Se agradece al grupo de Servicios Geoespaciales de la Autoridad Nacional de Licencias Ambientales (ANLA), adscrita al Ministerio de Ambiente y Desarrollo Sostenible; quienes suministraron el acceso a las imágenes satelitales WorldView-2 y 3 de alta resolución, disponibles en la plataforma AGIL-SAT, y usadas para la realización de este trabajo.

## Contenido

	Pág.
<b>Preliminares.....</b>	<b>III</b>
<b>Resumen.....</b>	<b>7</b>
<b>Abstract.....</b>	<b>8</b>
<b>Introducción .....</b>	<b>9</b>
<b>2. Marco Teórico y Estado del Conocimiento .....</b>	<b>12</b>
<b>2.1 Las Palmas de Cera Andinas .....</b>	<b>12</b>
<i>2.1.1 Distribución geográfica en Colombia .....</i>	<i>13</i>
<i>2.1.2 Amenazas y estado de conservación .....</i>	<i>16</i>
<b>2.2 Área de Estudio .....</b>	<b>18</b>
<i>2.2.1 Fisiografía .....</i>	<i>19</i>
<i>2.2.2 Biogeografía.....</i>	<i>21</i>
<b>2.3 Aprendizaje Máquina (<i>Machine Learning</i>) .....</b>	<b>23</b>
<i>2.3.1 Aprendizaje Profundo (<i>Deep Learning</i>) .....</i>	<i>23</i>
<i>2.3.2 Redes Neuronales Artificiales y RNC.....</i>	<i>25</i>
<i>2.3.2 Modelo de detección de objetos RetinaNet .....</i>	<i>27</i>
<b>3. Objetivos .....</b>	<b>30</b>
<b>3.1 Objetivo General.....</b>	<b>30</b>
<b>3.2 Objetivos Específicos .....</b>	<b>30</b>
<b>4. Metodología .....</b>	<b>31</b>
<b>4.1 Librerías de Aprendizaje Profundo para ArcGIS Pro.....</b>	<b>33</b>

<b>4.2</b>	Detección de Objetos en ArcGIS Pro .....	33
4.2.1	<i>Preparación de los datos de entrenamiento</i> .....	34
4.2.2	<i>Entrenamiento del modelo</i> .....	38
4.2.3	<i>Validación y optimización del modelo (zona de entrenamiento)</i> .....	42
<b>5.</b>	<b>Resultados y Discusión</b> .....	<b>45</b>
5.1	Modelo para Detección de Palmas de Cera .....	45
5.2	Zona de Validación (Valle de Cocora, Quindío).....	49
5.3	Zona de Implementación (veredas Alto de Toche - La Ceja, Tolima).....	53
	<b>Conclusiones</b> .....	<b>57</b>
	<b>Recomendaciones</b> .....	<b>59</b>
	<b>Referencias</b> .....	<b>60</b>

## Lista de Siglas

Siglas	Término
ANLA	Autoridad Nacional de Licencias Ambientales
ESRI	<i>Environmental Systems Research Institute</i> (proveedor de Software)
GPU	<i>Graphics Processing Unit</i> (Unidad de Procesamiento Gráfico)
IAvH	Instituto Alexander von Humboldt
IDEAM	Instituto de Hidrología, Meteorología y Estudios Ambientales
IGAC	Instituto Geográfico Agustín Codazzi
MADS	Ministerio de Ambiente y Desarrollo Sostenible
ML	<i>Machine Learning</i> (Aprendizaje Máquina)
RNC	Redes Neuronales Convolucionales
SIG	Sistemas de Información Geográfica
UAN	Universidad Antonio Nariño
UICN	Unión Internacional para la Conservación de la Naturaleza
UNAL	Universidad Nacional de Colombia
USGS	United States Geological Survey
XML	Extensible Markup Language

## Resumen

Se llevó a cabo el entrenamiento de un modelo basado en Aprendizaje Profundo (o *Deep Learning*) y redes neuronales convolucionales de tipo RetinaNet, para la detección de individuos y grupos de palmas de cera (*Ceroxylon sp*) en imágenes satelitales de alta resolución, utilizando las herramientas disponibles para detección de objetos en ArcGIS Pro. El modelo se generó a partir de una primera fase de entrenamiento con toma de muestras realizada sobre un sector de palmas aisladas y palmares identificados visualmente en la zona del valle de Cocora en Salento, departamento del Quindío; luego de realizar la validación del modelo en la totalidad de esta zona y optimizar los parámetros de entrenamiento y detección, se realizó la identificación automática de palmas de cera en la zona de implementación, correspondiente a la zona de las veredas de Alto de Toche y La Ceja, en los municipios de Ibagué y Cajamarca, departamento de Tolima; obteniendo una puntuación de precisión media de modelamiento de 0,74, y un porcentaje menor al 2% de individuos omitidos y falsas detecciones en áreas de pastos, y mayores a 30% en áreas de cobertura boscosa.

Palabras clave: Palma de cera, aprendizaje profundo, redes neuronales convolucionales, detección de objetos, sensores remotos.

## Abstract

It was carried out the training of a model based on Deep Learning and RetinaNet-type convolutional neural networks, for detection of individuals and groups of wax palms (*Ceroxylon sp*) in high-resolution satellite images, using the tools available for object detection in ArcGIS Pro. The model was generated from a first training phase with sampling accomplished on a sector of isolated palms and visually identified palm groves in the zone of the Cocora valley in Salento, department of Quindío; subsequently, and then carry out the model validation in the entire zone and optimizing the training and detection parameters, automatic identification of wax palms was performed in the implementation zone, corresponding to Alto de Toche and La Ceja jurisdiction, municipalities of Ibagué and Cajamarca, department of Tolima; obtaining an average modelling precision score of 0.74, and a percentage of less than 2% of omitted individuals and false detections in pasture areas, and greater than 30% in areas of forest cover.

Keywords: Wax palm, deep learning, convolutional neural networks, object detection, remote sensing.

## Introducción

El género *Ceroxylon* agrupa un total de 18 especies de palmas de cera que se distribuyen en bosques de los Andes desde Venezuela hasta Bolivia (Henderson, Galeano & Bernal, 1995); entre éstas, en Colombia la más representativa por su abundancia, longevidad y altura, es la palma de cera del Quindío (*Ceroxylon quindiuense*), declarada árbol nacional en el año 1985, y que se encuentra listada en la Resolución 1912 del Ministerio de Ambiente y Desarrollo Sostenible (MADS, 2017), dentro de las especies amenazadas de la diversidad biológica colombiana, con categoría UICN ‘En Peligro (EN)’; esto de acuerdo con Galeano & Bernal (2005) y Castillo et al. (2020), debido a que su hábitat se ha visto reducido por la ganadería extensiva, las quemadas y la parcelación de tierras asociada al turismo; y porque una fracción muy importante de palmas de cera se encuentra en zonas de pastos arbolados, donde no logran renovarse y reproducirse por la continua exposición a la radiación solar y al ganado que se alimenta de los brotes.

Así mismo, se tiene que las poblaciones de palmas de cera más abundantes del país, se encuentran principalmente en zonas de bosques fragmentados de las cuencas de los ríos Tohecito, Anaime y Cucuana, en la vertiente oriental de la cordillera Central del departamento de Tolima y que no se encuentran debidamente protegidas por el Estado. Es de resaltar, que las palmas de cera más que una atracción turística o un componente paisajístico, son un grupo de especies clave en los ecosistemas donde se encuentran, ya que sus frutos alimentan a una gran cantidad de insectos, aves y mamíferos (Bernal et al., 2015).

Dada la importancia de las palmas de cera para el país, entidades como el Ministerio de Ambiente y Desarrollo Sostenible, corporaciones regionales, universidades y el Instituto Alexander von Humbolt (IAvH); han adelantado en los últimos años diferentes investigaciones botánicas, ecológicas y geográficas que han brindado importantes aportes al conocimiento base de este grupo de especies en Colombia y a través de los cuales, ya se han formulado planes para su conservación, manejo y uso sostenible. En este contexto, y en el estudio del estado de las poblaciones, su extensión y distribución espacial, aún hace falta aprovechar de mejor manera insumos como las imágenes satelitales de alta resolución; cuyo uso en ocasiones ha sido restringido, en parte por su costo, así como por la disponibilidad de imágenes sin nubosidad en las zonas de la cordillera Central donde se encuentran las poblaciones más abundantes.

No obstante, contando con la disponibilidad de imágenes satelitales de alta resolución WorldView-2 y 3 previamente seleccionadas para varias zonas del país, cuyo acceso fue facilitado por la ANLA a través de la plataforma AGIL-SAT (proveedor Digital Globe Inc.), y teniendo acceso completo a las herramientas de análisis espacial de ArcGIS Pro mediante el licenciamiento suministrado por la Universidad Antonio Nariño (UAN); el presente trabajo buscó implementar las herramientas de identificación de objetos basadas en Aprendizaje Profundo (o *Deep Learning*) proporcionadas por ESRI, generando un modelo para la detección automática de individuos y grupos de palma de cera en imágenes satelitales de alta resolución, a través de una primera fase de entrenamiento y validación con muestras sobre un sector de palmas aisladas y palmares en la zona del valle de Cocora en Salento, (Quindío), y una segunda fase de implementación en la zona de las veredas de Alto de Toche

- La Ceja (Tolima), con el objeto de identificar núcleos de palmas de cera, su extensión y distribución espacial, y realizar una estimación de sus poblaciones.

Si bien aún sigue pareciendo complicado el programar o automatizar ciertas tareas de análisis con estas herramientas de Aprendizaje Profundo; la plataforma ArcGIS Pro, siendo uno de los programas SIG más potentes y de uso más extendido dentro del ámbito geoespacial; actualmente ofrece varias herramientas de uso sencillo y que configuran una solución completa para entrenar y generar modelos con múltiples aplicaciones para facilitar la automatización y mejorar la precisión en la ejecución de tareas de análisis en imágenes de sensores remotos, como son: la identificación y/o localización de objetos, clasificación de coberturas, segmentación, agrupamiento y detección de cambios, entre otras.

En este sentido, el presente trabajo también busca evaluar una metodología general basada en ArcGIS Pro, para la detección de otros objetos en imágenes satelitales de alta resolución espacial usando herramientas de Aprendizaje Profundo y redes neuronales convolucionales (RNC).

## 2. Marco Teórico y Estado del Conocimiento

### 2.1 Las Palmas de Cera Andinas

De acuerdo con Gomez (2021), las palmas de cera de los Andes son una maravilla botánica por su impresionante altura y el espectáculo paisajístico que exhiben sus poblaciones; lo cual ha fascinado desde el siglo XIX a exploradores como Alexander von Humbolt y Aimé Bonpland, quienes en 1807 las dieron a conocer a la ciencia en su libro *Plantas Equinociales*, gracias al viaje que emprendieron por antiguo paso del Quindío.

Las palmas de cera pertenecen a la familia *Arecaceae*, la cual se divide en cinco subfamilias una de estas es *Ceroxyloideae*, dentro de la cual existe la tribu *Ceroxyleae*, conformada por cuatro géneros; las palmas colombianas pertenecen al género *Ceroxylon*, propuesto por Bonpland y abarca un total de 18 especies distribuidas en los Andes entre los 1.000 hasta los 3.800 m.s.n.m, desde la cordillera de la Costa en Venezuela, las tres cordilleras en Colombia, incluida la Sierra Nevada de Santa Marta y los Andes del Ecuador y Perú, hasta el extremo sur en Bolivia (Henderson, Galeano y Bernal, 1995); de estas en Colombia se encuentran siete especies, varias de las cuales son únicas.

No obstante, es la denominada palma de cera del Quindío (*Ceroxylon quindiuense*), la más representativa en el país dada su predominancia en los bosques andinos de la cordillera Central y porque además se considera la palma más elevada del mundo, siendo muy destacada dentro del paisaje y llegando a vivir hasta 250 años; razones estas por las que desde 1949 el botánico Armando Dugand del Instituto de Ciencias Naturales de la Universidad Nacional de Colombia (UNAL), propuso esta especie como árbol nacional de Colombia, el cual sería adoptado oficialmente mediante la Ley 61 de 1985.

*Ceroxylon quinduense* hace parte de una rama de tres especies muy relacionadas, como lo son la *C. ceriferum*, que se encuentran en el norte de Colombia y de Venezuela y la *C. ventricosum* que crece en Ecuador, el norte de Perú y en el sur de Colombia (Sanín & Galeano, 2011). Aunque las tres especies tienen un gran parentesco, se pueden distinguir por algunas características morfológicas, Sanín (2013) y Gomez (2021), plantean que su gran similitud genética sugiere que podría tratarse de una misma especie que ha ido cambiando de acuerdo con las condiciones de sus respectivos sitios geográficos.

En su etapa adulta, la palma de cera *Ceroxylon quinduense* tiene entre 14 y 20 hojas pinnadas de aproximadamente 4 m de largo, posee flores blancas pequeñas y frutos esféricos de 1.8 y 2 cm de diámetro y color rojizo a naranja de acuerdo con su estado de madurez; un tallo con un diámetro de 35 cm y una altura promedio entre los 20 a 40 m, pudiendo alcanzar hasta los 65 m. Estas palmas se hallan principalmente en áreas de bosque húmedo montano y montano bajo, pero se reportan en altura de hasta 3.800 m.s.n.m., siendo capaces de soportar temperaturas de hasta 1°C y sequías prolongadas (Jaramillo & Alzate, 2022).

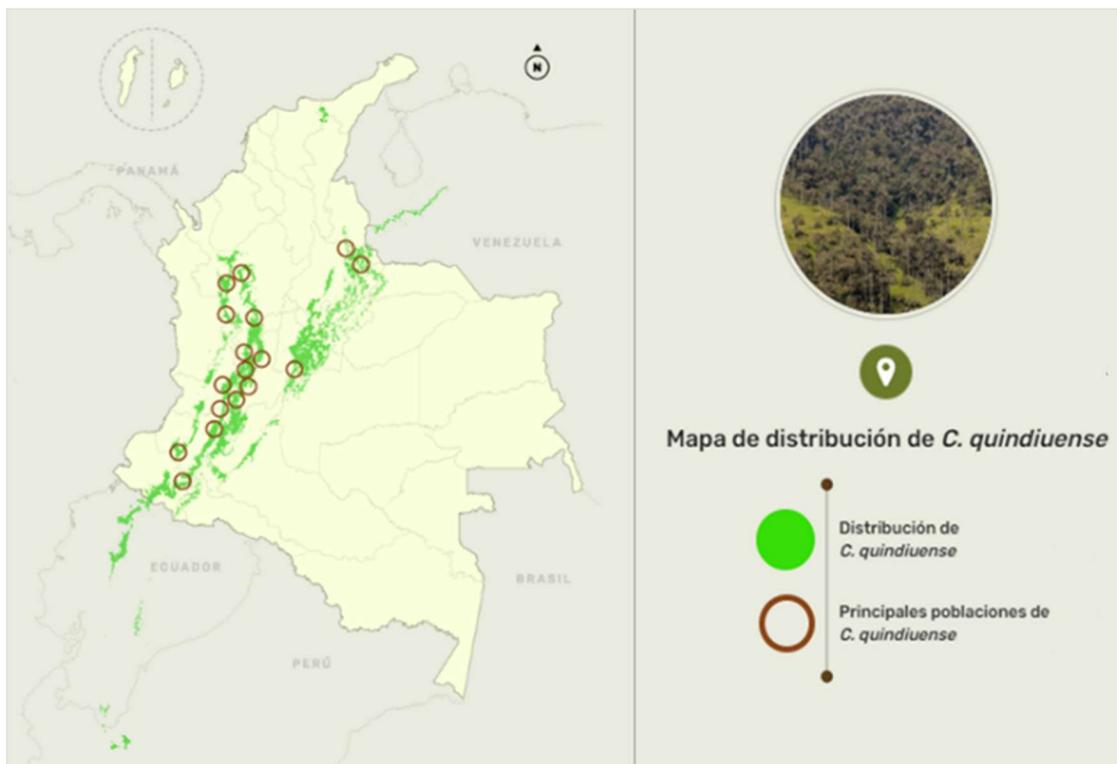
### *2.1.1 Distribución geográfica en Colombia*

De acuerdo con Castillo et al. (2020) en Colombia las palmas de cera se distribuyen principalmente sobre la cordillera Central, en zonas con diverso grado de intervención correspondientes a coberturas de bosques densos altos, bosques fragmentados y zonas de pastos arbolados en mosaico con espacios naturales, presentes desde el municipio de Yarumal (3° 43' N), departamento de Antioquia, hasta el municipio de El Cerrito en el departamento de Valle del Cauca (6° 57' N), pasando por los departamentos de Caldas, Risaralda, Quindío y Tolima, con predominancia en la franja de altitud de 2.200 hasta los

2.900 m.s.n.m. donde se encuentran las poblaciones más abundantes. Al norte del país se reporta en algunos sectores de la Sierra Nevada de Santa Marta, mientras que en la cordillera Oriental es posible encontrar palmas de cera en grupos pequeños y aislados especialmente en la serranía de los Yariguíes, la cuchilla del Ramo en límites entre Santander y Norte de Santander y en algunas zonas cálidas al occidente de Cundinamarca (*C. sasaimae*); ya en la cordillera Occidental se encuentran principalmente en la zona entre el municipio de Urrao y los farallones de Citará; y al sur, se cuenta con algunas poblaciones de palmas aisladas al occidente de Cali, llegando hasta el nudo de los Pastos en el departamento de Nariño, donde es reemplazada gradualmente por la especie *C. ventricosum*. Ver Figura 1.

### Figura 1

*Mapa de distribución general de Ceroxylon quindiuense y principales núcleos de población en los Andes de Colombia.*



Fuente: Modificado de Castillo et al. (2020) - IAvH.

De igual forma, el MADS en su Plan de Conservación, Manejo y Uso Sostenible de la Palma de Cera (Bernal et al., 2015), establecen siete núcleos de principales de población principales de palmas de cera en la cordillera Central y de interés para su conservación que son: 1) veredas de Alto de Toche - La Ceja, entre los municipios de Ibagué y Cajamarca, Tolima, con un estimado de cercano a los 200.000 mil individuos adultos, siendo la región en el país con las poblaciones más importantes y con el mayor grado de conservación; 2) valle de Cocora, municipio de Salento (Quindío), con una cantidad de apenas 2.000 a 4.000 palmas, pero muy destacada como foco de turismo; 3) cuenca del río Anaime (Cajamarca, Tolima), con aproximadamente 10.000 individuos; 4) cuenca del río Cucuana (Roncesvalles, Tolima) entre 20.000 a 50.000 mil; 5) La Samaria - San Félix (Salamina, Caldas) con unas 1.000 palmas; 6) corregimiento de Tenerife (El Cerrito, Valle del Cauca), con un poco menos de 500 palmas y 7) Altiplano Norte (San José de la Montaña, Belmira, Santa Rosa de Osos y Yarumal, Antioquia), con poblaciones que pueden oscilar entre los 1.500 a 2.000 individuos.

De acuerdo con Sanín (2013), los dos flancos de la cordillera Central han desempeñado el papel de receptoras de migrantes de las poblaciones de palmas de cera y de confluencia de las mismas, de acuerdo los resultados de modelación de la migración histórica de ocho poblaciones; por su parte Gomez (2021), menciona que en la cordillera Central es posible encontrar cuatro especies de palmas de cera *Ceroxylon quindiuense*, *C. vogelianum*, *C. parvifrons* y *C. alpinum* (esta última sinónima de *C. andicola* y *C. ferrugineum*).

En cuanto a la distribución geográfica de las palmas de cera, de acuerdo con Bernal & Sanín (2013), estas se ubican principalmente sobre suelos originados a partir de depósitos

volcánicos; que además de las condiciones geomorfológicas, altitudinales y climáticas predominantes en la cordillera Central, ofrecen condiciones óptimas para la multiplicación y dispersión de las palmas del género *Ceroxylon*.

### 2.1.2 Amenazas y estado de conservación

La Ley 61 de 1985 del Congreso declaró la palma de cera del Quindío como árbol nacional y símbolo patrio, convirtiéndola así en la única planta colombiana expresamente protegida a nivel individual por una ley de la República. No obstante, si bien esta norma contempla el establecimiento de parques nacionales o santuarios para la protección de la especie, y aunque también algunas zonas de la cordillera Central donde se encuentran las palmas de cera, corresponden a zonas de Reserva Forestal Central (Ley Segunda de 1959); en la actualidad, dentro del territorio nacional aún no ha sido posible la creación de una o más áreas de categoría pública, para la conservación y/o preservación específica de las palmas de cera (Bernal et al., 2015).

De otra parte, de acuerdo con la Resolución 1912 de 2017 del Ministerio de Ambiente y Desarrollo Sostenible, que estableció las especies amenazadas de la diversidad biológica de Colombia, incluyó a las especies *Ceroxylon quindiuense*, *C. ventricosum*, *C. ceriferum*, *C. sasaimae* y *C. alpinum*, dentro de la categoría UICN ‘En Peligro (EN)’ y que comprende aquellas enfrentando muy alto riesgo de extinción; y en categoría ‘Vulnerable (VU)’ con alto riesgo de extinción a *Ceroxylon parvifrons* y *C. vogelianum*; esto de acuerdo con Castillo et al. (2020) quienes reportan, que aunque existen palmares abundantes en la cordillera Central en áreas como las cuencas de los ríos Tohecito, Anaime y Cucuana, se estima que su hábitat se ha visto en más de un 50% en los últimos 200 años, especialmente por la ganadería extensiva, las quemadas y la parcelación de tierras asociada al turismo; y

porque una fracción muy importante de palmas de cera se encuentra en zonas de potreros, donde no logran renovarse y reproducirse por la continua exposición a la radiación solar y al ganado que se alimenta de los brotes.

En décadas anteriores, en el país también se hacía un aprovechamiento desmedido y destrucción de las palmas de cera para hacer ramos y usarlos en ceremonias de Semana Santa; así mismo, la cera de la palma también se utilizaba para fabricar velas que eran comercializados en los mercados locales. Así mismo, de acuerdo con Galeano & Bernal (2005), a finales de los años 80 se identificó una enfermedad que estuvo afectando esta especie, los síntomas se basaban en secamiento gradual de las hojas hasta la muerte de la palma. Esta afección se identificó a lo largo de la cordillera Central y se estima que llegó a perjudicar más de un 40% de la población de palmas del país.

Si bien la conservación de las palmas de cera se ha venido enfocando más desde la óptica de su atractivo turístico o de lo imponentes o espectaculares que son los paisajes que conforman, estas especies también poseen un papel muy importante en los ecosistemas donde se encuentran ya que sus frutos alimentan a una gran cantidad de insectos, aves y mamíferos. De acuerdo con Jaramillo & Alzate (2022), *Ceroxylon quindiuense* y *C. alpinum* albergan y son lugar de alimentación de varias especies de loros considerados en peligro de extinción en Colombia como *Conurus icterotis* y *Ognorhynchus icterotis*, mejor conocidos loros o pericos orejiamarillos, donde además construyen sus nidos. La preservación de las especies encontradas en el país también garantiza una variedad genética más amplia que contribuye a hacerlas más resilientes a amenazas constante como la aparición de nuevas plagas, enfermedades y al cambio climático (Bernal & Sanín, 2013).

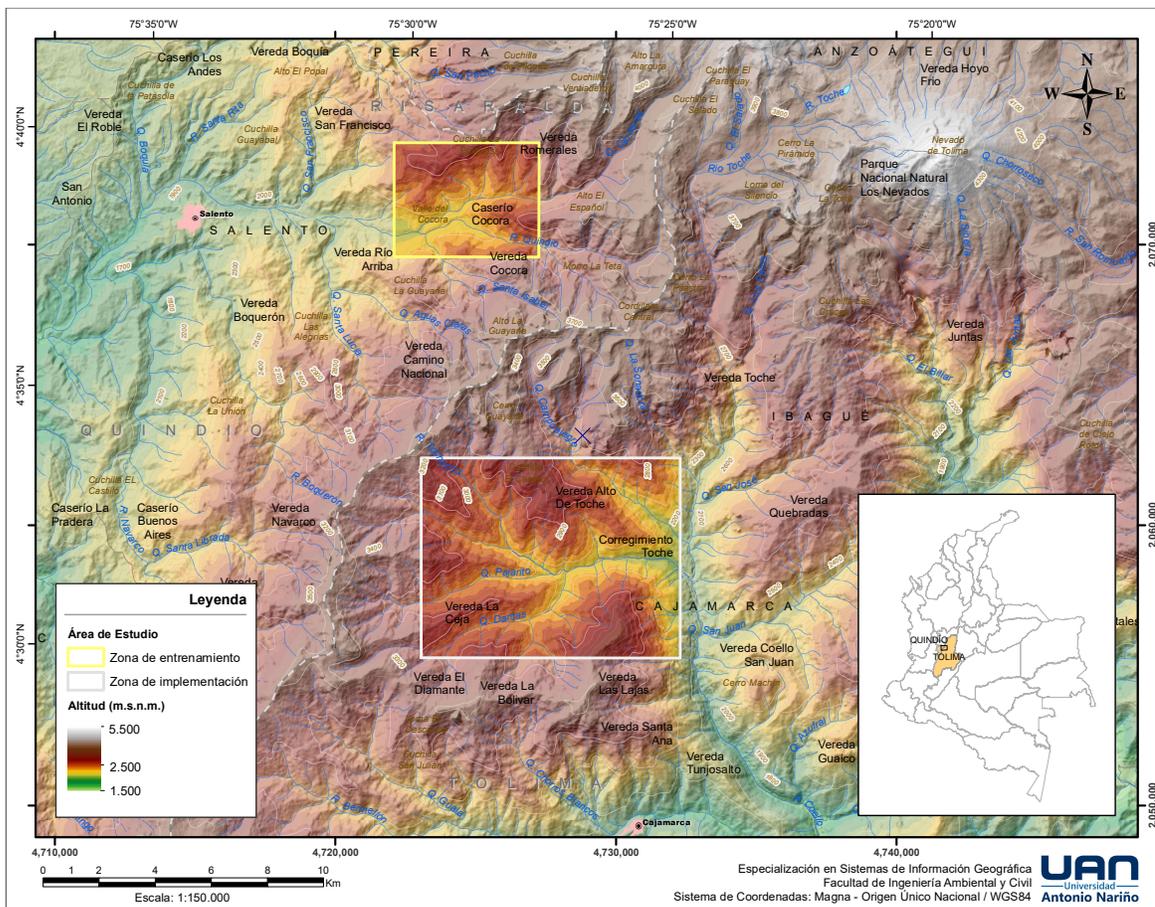
De esta forma, urge en el país que en zonas tan representativas y con poblaciones tan abundantes de palmas de cera, como las de las veredas de Alto de Toche y La Ceja (Tolima) y otros importantes núcleos de población dentro de la cordillera Central, que las autoridades ambientales apliquen el mandato de la Ley 61 de 1985 y efectúen la creación de una o varias áreas protegidas; incluyendo medidas como compra de predios, apoyo al registro de reservas privadas, programas de conservación, restauración de bosques y siembra de palmas, reconversión de actividades ganaderas, proyectos productivos y turismo sostenible, investigación científica, y mayor participación de comunidades y articulación con las autoridades e instituciones ambientales (Castillo et al., 2020).

## 2.2 Área de Estudio

Para el presente trabajo se tomaron dos (2) áreas de estudio en concordancia con las fases planteadas para llevar a cabo la generación y optimización del modelo, y su posterior ejecución a modo de producción (Figura 2). De esta forma, para la **fase de entrenamiento** se tomó la zona del valle de Cocora en el municipio de Salento, departamento de Quindío (en un recuadro total de 2.200 ha), siendo esta una de las áreas con una de las poblaciones más reconocidas de palmas de cera en el país; y en segunda lugar, para la **fase de implementación** la zona correspondiente a las veredas de Alto de Toche - La Ceja, Cajamarca e Ibagué, departamento de Tolima (6.500 ha), y que de acuerdo con Castillo et al. (2020), constituye la región con la población actual más abundante de palmas de cera en el país. Cabe mencionar que ambas zonas son aledañas y comparten casi completamente los mismos aspectos fisiográficos, ubicándose aproximadamente en la franja tropical entre los 4° 30' a 4° 40' N y los 75° 25' a 75° 30' W, ambas en altitudes entre 2.200 a 2.800 m.s.n.m.

Figura 2

*Áreas de Estudio. a) Fase de entrenamiento, valle del Cocorá, departamento de Quindío y b) Fase de implementación, veredas Alto de Toche - La Ceja, departamento de Tolima.*



Fuente: Elaboración propia. Cartografía base IGAC (2017), altitud SRTM (USGS, 2010).

### 2.2.1 Fisiografía

Las áreas de estudio se encuentran ubicadas sobre la cordillera Central de Colombia e involucra las vertientes occidental (en la zona de entrenamiento) y oriental (en la zona de implementación), ambas en piso térmico frío, con una temperatura media anual de 12 a 18°C y una precipitación media entre 2.500 a 2.800 mm/año, en régimen bimodal y con un primer pico de lluvia entre los meses de abril y mayo, y un segundo, entre octubre y noviembre y clima frío húmedo, en zona de vida de Bosque Húmedo Montano (bh-M) (IDEAM, 2022a).

De acuerdo con el Instituto Geográfico Agustín Codazzi (IGAC, 2004a y 2004b), el paisaje dominante corresponde a montaña, con relieve de tipo denudacional fuertemente quebrado a escarpado, conformado principalmente por filas y vigas caracterizadas por presentar crestas longitudinales inclinadas con pendientes largas mayores de 50%, y relieve de tipo agradacional, con presencia de algunos vallecitos angostos localizados a lo largo de los ríos y quebradas presentes en el paisaje de montaña, hasta combinarse con el paisaje de piedemonte en las partes más bajas; en especial en la región del valle de Cocora y que corresponde realmente al cauce geomorfológico de las quebradas Cardenas y San José, y su confluencia con el río Quindío. Ver Figura 3.

### **Figura 3**

*Paisaje de montaña en clima frío húmedo con relieve fuertemente quebrado a escarpado, con pendientes largas, en la zona del valle de Cocorá.*



Fuente: IAvH (2020).

En estas áreas el material parental está constituido principalmente por depósitos espesos de cenizas y arenas volcánicas y en algunos sectores escarpados por rocas metamórficas (esquistos del Complejo de Cajamarca), que según Rojas et al. (2018), han dado origen a suelos de tipo Andisol (en consociación de *Alic Hapludands* - 70% e *Hydric Hapludands* - 30%) de espesor profundo a superficial, mediana fertilidad, texturas franco arcillosas y franco arcilloso arenosas, buena estabilidad estructural, bien a moderadamente bien drenados, fuerte a moderadamente ácidos y fijadores de fósforo, y que de acuerdo con el IGAC (2004a), presentan erosión moderada ocasionada principalmente por el sobrepastoreo, y fenómenos de reptación, escurrimiento difuso y deslizamientos.

De acuerdo con Rodríguez et al. (2017), la zona se encuentra dentro la unidad biótica denominada ‘Orobioma Andino Cordillera Central’, en un sector donde la vegetación natural ha sido transformada en un porcentaje importante, especialmente en las zonas más bajas y menos escarpadas, donde las tierras son usadas principalmente para ganadería extensiva y agricultura de subsistencia.

### 2.2.2 Biogeografía

a) *Zona de entrenamiento / validación (valle de Cocora, Quindío)*: El valle de Cocora se encuentra en la vereda Cocora a 11 km del centro poblado del municipio de Salento en el departamento de Quindío, dentro de las cuencas de las quebradas Cárdenas y San José, en un área con predominio de coberturas (en su orden), de pastos enmalezados, pastos arbolados, mosaico de pastos con espacios naturales, bosques fragmentados y bosques densos altos de tierra firme (IDEAM, 2022b). La mayor cantidad de palmas de cera en esta zona se presentan aisladas o formando palmares pequeños, que están concentrados en un sector de unas 600 ha, de las cuales 360 ha corresponden a áreas de pastos.

Según estimaciones presentadas por Castillo et al. (2020), la población de palmas de cera en esta localidad se estima entre los 2.000 a 4.000 individuos adultos; allí las palmas se encuentran bien conservadas y no se observan enfermedades fitosanitarias, la tasa de mortalidad es baja y recae principalmente sobre las más antiguas (mayores a 100 años de edad) y que ya cumplido su ciclo de vida. Si bien el área no posee un número de palmas tan importante como el que se encuentran en las áreas de las veredas de Alto de Toche - La Ceja, Roncesvalles o de las cuencas del río Anaimé y Cucuana, es una región importante por el reconocimiento internacional que tienen sus paisajes de palma de cera.

*b) Zona de implementación (veredas de Alto de Toche - La Ceja, Tolima):* Esta zona se encuentra al occidente del departamento del Tolima en las veredas de Alto de Toche, en el municipio de Ibagué y La Ceja en el municipio de Cajamarca, e incluye un sector menos importante correspondiente a las veredas La Bolívar y Las Lajas; los núcleos más numerosos de población se encuentran principalmente sobre la cuenca del río Tohecito y en la cual, se presenta un mayor predominio de coberturas boscosas y de espacios naturales en comparación con la zona del valle de Cocora; por lo que las palmas de cera se conservan en mejor estado, formando palmares de alta densidad al interior de los bosques densos y bosque densos fragmentados, y mostrando una proporción de palmas aisladas más baja en las zonas de pastos. Castillo et al. (2020), estiman que la mayor concentración de palmas abarca un área con una extensión aproximada de 4.500 ha.

De otra parte, Bernal et al. (2015) calculan que la densidad de palmas de cera adultas en dicha áreas de bosque puede oscilar entre las 290 a 840 palmas/ha, por lo que se estima que la población de palmas en esta localidad, podría superar los 200.000 individuos adultos; siendo en consecuencia, la zona del país con las poblaciones más importantes.

## 2.3 Aprendizaje Máquina (*Machine Learning*)

De acuerdo con Bobadilla (2021), el Aprendizaje Máquina o (en inglés *Machine Learning*) es un campo de la Inteligencia Artificial (IA), orientado al desarrollo de modelos que procesan datos estructurados capaces de emular las funciones cognitivas humanas. De manera simple, es un proceso informático con capacidad de “aprender” y de “predecir” a partir de un conjunto de datos; otorgando a los computadores la capacidad de resolver problemas o realizar tareas tradicionalmente reservadas para los humanos.

### 2.3.1 Aprendizaje Profundo (*Deep Learning*)

El Aprendizaje Profundo (en inglés *Deep Learning*), también conocido como Aprendizaje Jerárquico, constituye una de las ramas del Aprendizaje Máquina que abarca varios métodos para el aprendizaje automático, a través del análisis de datos o la asimilación de representaciones de estos; principalmente mediante el uso de redes neuronales artificiales que se componen de un gran número de capas ocultas conformado diferentes niveles jerárquicos y que corresponden a diferentes niveles de abstracción (Boldrini, 2021). Según lo expuesto por autores como Bagnato (2020) y Garcia-Olalla (2019), en los niveles más superficiales las redes neuronales son capaces de clasificar y seleccionar las características más generales de los datos y luego enviar esta información a los siguientes niveles, donde sucesivamente se combinan, pudiendo establecer gradualmente características más específicas o resolver problemas más complejos.

En el área del Aprendizaje Profundo aplicado a la visión artificial, se tiene a las redes neuronales convolucionales (RNC), como la arquitectura de uso más extendido y con la cual se vienen consiguiendo los mejores resultados (Bobadilla, 2021). Trabajos realizados en el

país en los últimos años, como los desarrollados por Gamarra y Rios (2018) para reconocimiento de objetos en imágenes, Valdés & Baquero (2019) en detección de viviendas sin servicio de energía, y Diaz & Barragan (2020) en el monitoreo de cultivos, muestran el alto potencial que ofrecen estos métodos, para realizar análisis y obtener información de imágenes de sensores remotos de forma automática.

De igual manera, Lenhardt (2022), presenta en el sitio educativo de ESRI ([learn.arcgis.com](https://learn.arcgis.com)), un tutorial donde se lleva a cabo la identificación de individuos de palma cocotera en imágenes aéreas de alta resolución en la localidad de Kolovai, archipiélago de Tonga, utilizando únicamente el entorno y las herramientas de Aprendizaje Profundo disponibles en ArcGIS Pro; y el cual fue de mucho apoyo para el presente trabajo.

La implementación de estos modelos de Aprendizaje Profundo en la identificación de objetos o entidades en imágenes, implica muchos de los mismos pasos que realizan en los métodos tradicionales de clasificación supervisada (ESRI, 2022a); antes de ejecutar un algoritmo de Aprendizaje Profundo primero se debe llevar a cabo una fase de entrenamiento, donde se deben seleccionar e incorporar un número importante de muestras tipo o ejemplos de los objetos a identificar, para que el modelo aprenda a reconocerlos y se puedan obtener resultados precisos. En este sentido, cabe mencionar que actualmente ya se tienen aplicaciones o implementación de métodos soportados parcial o completamente en modelos pre-entrenados sobre extensas bases de datos de imágenes como ImageNet, o que se distribuyen para realizar ciertas tareas de clasificación o detección, como los que se encuentran en la biblioteca Living Atlas de ESRI o el repositorio de complementos de QGIS, y que pueden ser usados de forma directa o reentrenados para fines más específicos.

### 2.3.2 *Redes Neuronales Artificiales y RNC*

Si bien, los computadores permiten implementar algoritmos para resolver problemas de manera directa, existe una importante limitación cuando un problema no admite una definición algorítmica. Varios autores como Boldrini (2021), Matich (2001) y Kohonen (1982), plantean que las redes neuronales artificiales, son capaces de emular las neuronas biológicas con entradas y salidas interconectadas y agrupadas en diferentes niveles que se denominan capas, conformando un sistema que a través de entrenamiento y con la información interna que se procesa dentro de la red neuronal (usualmente utilizando funciones no lineares para clasificar los datos), es capaz de ajustar sus pesos, nodos e interconexiones, para que la respuesta de la capa de salida final se ajuste a los datos conocidos; con lo cual, se suministra un medio para resolver problemas que comúnmente se resuelven mediante ‘experiencia’ y que no pueden expresarse a través de un algoritmo.

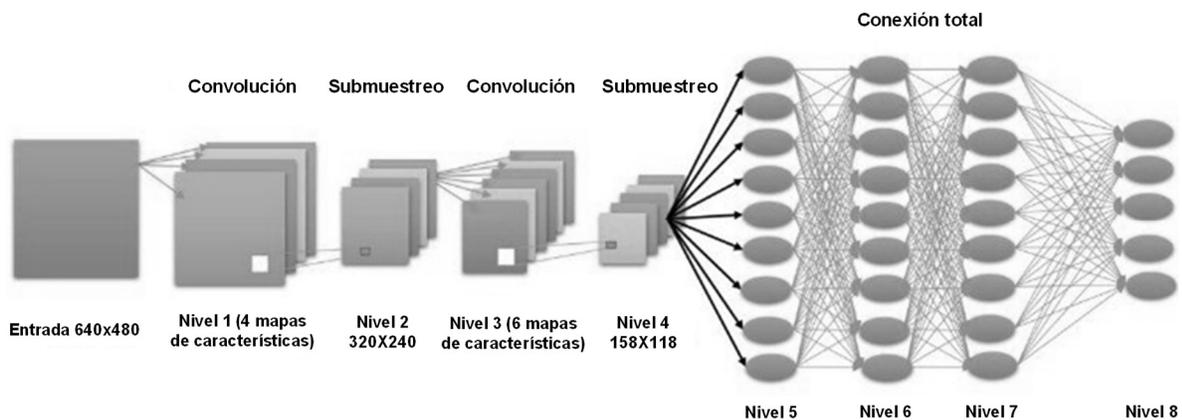
De esta forma y tal como lo expresa García-Olalla (2019), para el caso de generar una red neuronal que sea capaz de detectar determinadas entidades u objetos en cualquier imagen, se debe suministrar un número elevado de muestras para realizar el entrenamiento; así, la red neuronal será capaz de ajustar sus parámetros para responder a diferentes imágenes y detectar los objetos de interés, ya que podrá clasificar diferentes características o patrones asociados a estos.

Ahora bien, tal como lo plantea Boldirini (2021), y dado que a mayor número de capas intermedias o cuanto más grande sea una red neuronal, pueden generarse más niveles de abstracción que lleven a obtener mejores resultados, pero generando al mismo tiempo una mayor demanda de recursos computacionales; en el área del Aprendizaje Profundo aplicado a la visión artificial, se vienen implementando de manera generalizada un tipo de

redes neuronales denominadas convolucionales (RNC), que de acuerdo con Bagnato (2020), son un tipo de red neuronal donde se aplican sucesivas convoluciones (recalculo de píxeles cercanos contra una matriz llamada *kernel*), que generan nuevas subimágenes y forman una gran cantidad de capas de neuronas intermedias u ocultas, permitiendo establecer características en los píxeles de entrada mediante funciones de clasificación, conectándose a su vez con neuronas de reducción por muestreo (*pooling*), que disminuyen la complejidad y el tamaño de las imágenes haciendo más eficiente su procesamiento.

#### Figura 4

*Estructura de una red neuronal convolucional (RNC).*



Fuente: Modificado de Contreras (2016).

Adicionalmente, Silva & Freire (2019) y Contreras (2016), plantean que las redes neuronales convolucionales también contienen capas especializadas y con una jerarquía que busca emular el funcionamiento del cortex visual del ojo humano; esto quiere decir, que las primeras capas detectan características generales mientras que las capas más profundas se especializan para reconocer atributos más puntuales. En la Figura 4 se presenta el funcionamiento de una RNC típica, donde se tiene una imagen de entrada que se procesa

mediante sucesivas convoluciones (kernels) y submuestreos que generan nuevas capas con dimensionalidad reducida, y donde se empieza detectando características como líneas, aristas y curvas desde los píxeles que la componen (niveles 1 a 4); estas salidas intermedias luego se van adicionando en las capas sucesivas a manera de mapas de características o píxeles (*feature maps*) extrayendo atributos cada vez más específicos, hasta formar una red neuronal multicapa completamente interconectada (niveles 5 a 7), y que puede realizar el reconocimiento de un objeto en la capa de salida final (nivel 8).

### 2.3.2 Modelo de detección de objetos RetinaNet

RetinaNet es un tipo de arquitectura de redes neuronales convolucionales, que ha demostrado tener buenos resultados en la detección de objetos densos y de pequeña escala, en imágenes satelitales y aéreas (ESRI, 2022b). De acuerdo con Lin et al. (2017) y la interpretación dada por Boruah (2021), esta se compone de cuatro componentes:

a) *ResNet*: es la capa residual de una red previamente entrenada en la base de datos ImageNet para la clasificación de imágenes, y de la que se ha eliminado la capa final interconectada.

b) *Red Piramidal de Características (o Feature Pyramid Network - FPN)*: está conformada por una red convolucional ascendente en la que se calculan mapas de características a múltiples escalas, otra red descendente que aumenta las muestras de los mapas de características de los niveles superiores de la pirámide y conexiones laterales para fusionarse con las capas del mismo tamaño espacial de la red ascendente.

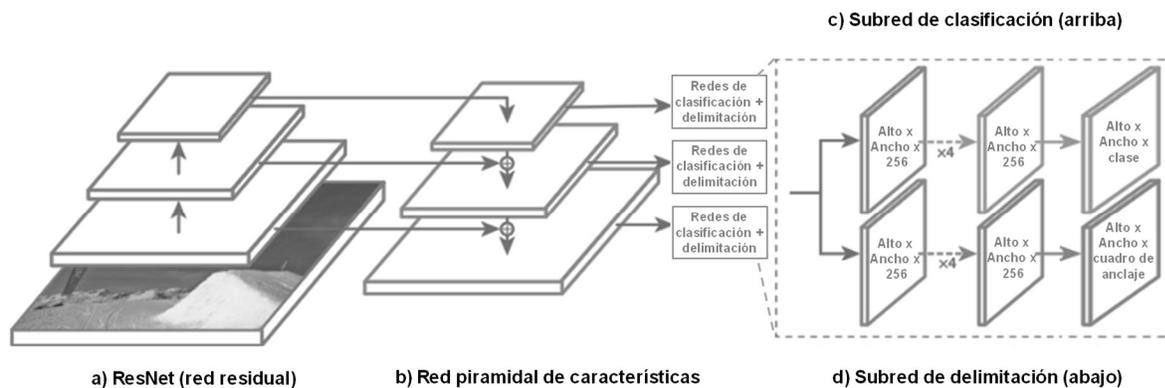
c) *Subred de clasificación*: es una red que calcula la probabilidad de que un objeto esté presente en una ubicación espacial para el área que rodea un objeto detectado

denominados cuadros delimitadores (o *bounding boxes*); las características se identifican en las capas intermedias, clasificando los datos mediante funciones sigmoideas.

d) *Subred de delimitación*: opera en paralelo con la subred de clasificación realizando una regresión del desplazamiento de los cuadros delimitadores de los objetos detectados, desde los cuadros de anclaje (o *anchor boxes*), que son los recuadros de detección predefinidos.

### Figura 5

*Arquitectura del modelo RetinaNet.*



Fuente: Modificado de Lin et al. (2017).

Adicional a lo anterior, ESRI (2022b) menciona que el modelo RetinaNet posee una mejora denominada *Focal Loss* (o Pérdida Focal) que permite contrarrestar el desequilibrio de clases que producen las imágenes con gran variedad de elementos, como es el caso de las imágenes satelitales o aéreas, unido a la alta densidad de cuadros de anclaje (posibles ubicaciones de objetos) que generan las múltiples capas piramidales. La implementación del *Focal Loss* reduce la contribución de las detecciones de alta probabilidad (ejemplos fáciles), que hacen que el modelo tienda a descartar objetos de difícil detección, al tiempo que enfoca

el aprendizaje en corregir los ejemplos mal clasificados, otorgándole así mayor flexibilidad al modelo para identificar objetos pequeños, sobrepuestos o que se presentan visualmente confusos (Lin et al., 2017). No obstante, si bien estas características representan mejores resultados; en general, también implican mayores tiempos de procesamiento.

En la implementación del modelo RetinaNet para la detección de objetos desde ArcGIS Pro, la capa de final de salida corresponde a la clase de objeto detectado, un valor de confianza (*Confidence*) o función de pérdida respecto a las imágenes de entrenamiento (ESRI, 2022a) y cuadros delimitadores ajustados (en formato *shapefile*), que permiten establecer su ubicación geográfica y para ciertos casos, un aproximado de su superficie.

### 3. Objetivos

#### 3.1 Objetivo General

Generar un modelo para la detección automática de individuos y grupos de palmas de cera (*Ceroxylon sp*) en imágenes satelitales de alta resolución, usando las herramientas de detección de objetos basadas en Aprendizaje Profundo, disponibles en ArcGIS Pro.

#### 3.2 Objetivos Específicos

1. Ejecutar la fase de entrenamiento con toma de muestras sobre un sector de palmas aisladas y palmares identificados visualmente en la zona del valle de Cocora, departamento de Quindío.

2. Realizar la validación y ajuste del modelo generado ejecutándolo en la totalidad de la zona del valle de Cocora, evaluando su nivel de precisión en diferentes escenarios e identificando el efecto de los parámetros de entrenamiento y detección disponibles en ArcGIS Pro.

3. Aplicar el modelo en la zona de Alto de Toche - La Ceja, departamento del Tolima, para la identificación de núcleos de palmas de cera, su extensión y distribución espacial, y la estimación de sus poblaciones.

#### 4. Metodología

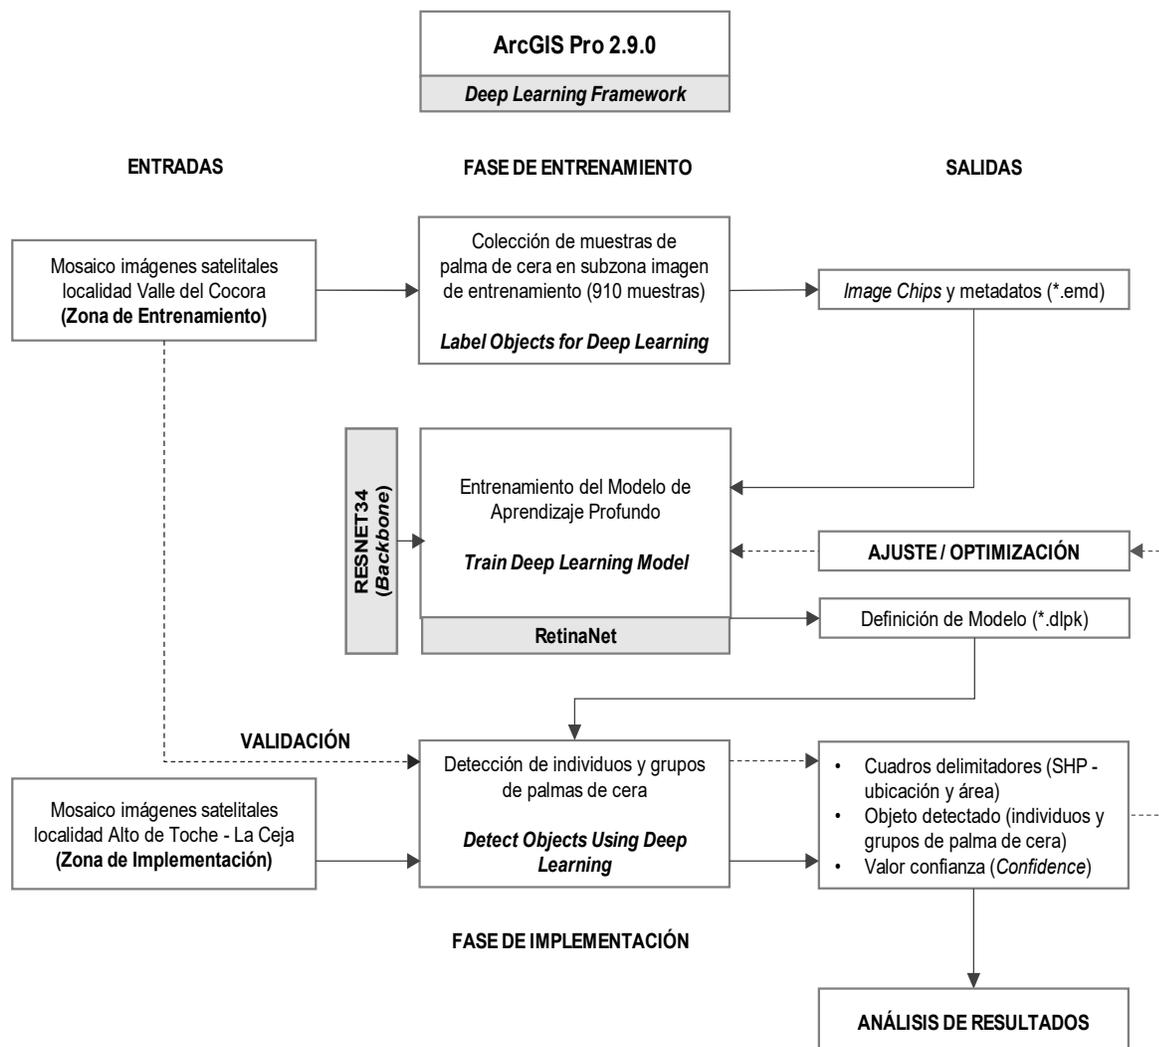
Para la detección automática de individuos y grupos palmas de cera (*Ceroxylon sp*), en imágenes satelitales de alta resolución, se utilizaron las herramientas de detección de objetos con Aprendizaje Profundo disponibles en ArcGIS Pro 2.9 y el *Deep Learning Framework* (o marco de trabajo) integrable al entorno de ESRI, para la generación de un modelo basado en redes neuronales convolucionales con arquitectura RetinaNet; entrenado mediante muestreo y etiquetado de palmas de cera aisladas y de palmares, en un sector representativo de la zona del valle de Cocora (Quindío), a partir de un mosaico de imágenes satelitales de alta resolución WorldView-2 y 3 de septiembre de 2018 a febrero de 2020 (0,3 m/pixel) y utilizando las herramientas: *Label Objects For Deep Learning* (etiquetado de objetos para Aprendizaje Profundo) y *Train Deep Learning Model* (entrenar modelo de Aprendizaje Profundo).

Posteriormente con el primer modelo generado, se procedió a realizar la detección de palmas y palmares de cera en toda la zona del Valle de Cocora, usando la totalidad de la imagen usada para la fase de entrenamiento del modelo, con el objeto de validar los resultados entregados y realizar pruebas con los diferentes parámetros de detección disponibles, mediante la herramienta *Detect Objects using Deep Learning* (detección de objetos usando Aprendizaje Profundo). Adicional a lo anterior, con el fin de observar el efecto en los resultados e identificar posibles ajustes, se generaron otros modelos de prueba, donde también se evaluó el efecto de los parámetros de entrenamiento disponibles. Una vez evaluados los resultados obtenidos a partir del uso de diferentes valores en los parámetros de entrenamiento y detección, se fueron optimizando gradualmente los resultados obtenidos

por el modelo, respecto a la detección de palmas de cera en el mosaico de imágenes de la zona del valle de Cocora. Al final, se consolidó un único modelo y se fijó un conjunto de valores optimizados para los parámetros de detección a aplicarse durante la fase de implementación (Figura 6).

**Figura 6**

*Esquema general. Entrenamiento de modelo para detección de palmas de cera basado en RNC de tipo RetinaNet, validación, ajuste e implementación sobre ArcGIS Pro.*



Fuente: Elaboración propia.

De esta forma, y con el modelo validado y optimizado para la detección automática de individuos y grupos de palmas de cera, se procedió a su ejecución en la zona de implementación de las veredas de Alto de Toche - La Ceja, y sobre mosaico de imágenes satelitales de alta resolución (0,3 m/pixel), WorldView-2 y 3 de diciembre de 2019 a febrero de 2020.

#### 4.1 Librerías de Aprendizaje Profundo para ArcGIS Pro

La ejecución de las herramientas de Aprendizaje Profundo disponibles en ArcGIS Pro, requieren de la instalación del *Deep Learning Framework* que contiene las librerías y una amplia colección de herramientas y componentes tales como PyTorch, Tensorflow y Fast.ai, entre otras; las cuales se encuentran disponibles en un repositorio de libre acceso en el sitio web de GitHub.com (<https://github.com/Esri/deep-learning-frameworks/>). De acuerdo con ESRI (2022c), para garantizar el funcionamiento de este marco de trabajo, es importante que la versión del paquete sea compatible; en este sentido, el entrenamiento y la ejecución del presente modelo se desarrolló completamente usando la versión apta para la plataforma ArcGIS Pro 2.9.0.

#### 4.2 Detección de Objetos en ArcGIS Pro

El flujo de trabajo para llevar a cabo esta tarea se resume en los siguientes pasos: 1) Preparación de los datos de entrenamiento, 2) Entrenamiento del modelo y 3) Ejecución y pruebas del modelo.

#### 4.2.1 Preparación de los datos de entrenamiento

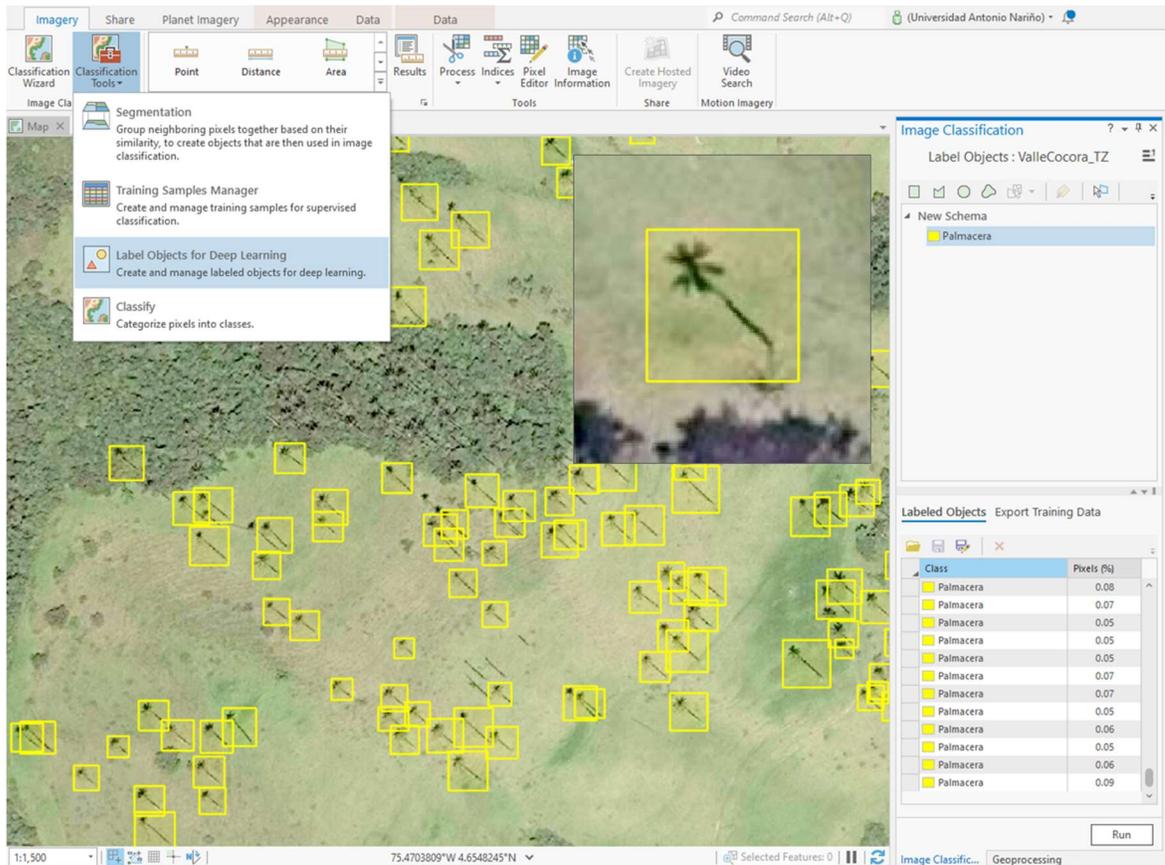
Para este paso, inicialmente es importante disponer de imágenes que contengan ejemplos representativos del objeto a detectar. Por esta razón, se seleccionaron imágenes de satélite de alta resolución de la zona del Valle de Cocora en el municipio de Salento, (Quindío), destacada por tener una abundancia importante de palmas de cera adultas, que servirán como muestras para suministrar la información visual requerida para el entrenamiento del modelo de Aprendizaje Profundo.

Una vez cargada la imagen de la zona de entrenamiento en ArcGIS Pro, el proceso de toma de muestras se lleva a cabo mediante la herramienta *Label Objects for Deep Learning* (o etiquetado de objetos para Aprendizaje Profundo), la cual se despliega desde el botón *Classification Tools* (pestaña *Imagery*). Esta dispone un panel que permite administrar las clases, la colección de muestras y exportar los datos de entrenamiento (Figura 7).

En el caso de las muestras para el entrenamiento del modelo de detección propuesto, vale mencionar una particularidad muy importante con respecto a la apariencia de las palmas de cera en las imágenes satelitales de alta resolución revisadas; y es que dada su gran altura (entre 30 y hasta 65 metros) y la delgadez de su tronco (con apenas 0,3 a máximo 0,5 metros de diámetro o DAP), este tipo de palmas difícilmente logran capturarse o verse de forma ortogonal dentro de las imágenes, dadas también las variaciones en el ángulo de observación de los satélites al alejarse de su plano focal y la topografía fuertemente inclinada que predomina en las zonas donde se encuentran los principales núcleos de población; de esta forma, las palmas se proyectan sobre el terreno y en las vistas de dos dimensiones, como si aparentaran estar “acostadas en diagonal” y algunas veces con sombras prominentes que pueden generar confusión al momento de realizar su detección o identificación.

**Figura 7**

*Proceso de toma de muestras de palmas de cera de ejemplo, en imagen satelital de entrenamiento mediante la herramienta Label Objects for Deep Learning.*



Fuente: Elaboración propia.

No obstante, esta característica también resulta ventajosa dentro del proceso de entrenamiento del modelo, dado que se convierte en un importante rasgo distintivo de este tipo de palmas dentro de las imágenes satelitales; lo cual facilita el proceso de aprendizaje de la red neuronal y el establecimiento de un patrón particular que permita lograr la identificación correcta del objeto en diferentes contextos.

De igual manera, las palmas de cera observadas en las imágenes satelitales no solo presentan amplia variedad en altura, grosor y tamaño de la corona; en los sitios con las

poblaciones más abundantes también suelen presentarse sobrepuestas formando palmares de densidad variable o también en asocio con vegetación de bosque denso alto o bosques fragmentados sobresaliendo del estrato arbóreo, mientras que en las áreas más intervenidas, suelen encontrarse aisladas y rodeadas por pastos o formando grupos pequeños y de menor densidad; en ese sentido, y para lograr capturar adecuadamente esta variedad y contar con un número suficiente de ejemplos que permitiera un entrenamiento avanzado del modelo, se conformó un conjunto de 910 muestras repartidas en los diferentes escenarios mencionados (frente a 600 usadas por Lenhardt, 2022), consistentes en recuadros de imágenes de la corona y tronco de las palmas de aproximadamente 15 x 15 metros (~60 x 60 píxeles), limitadas a un solo sector de 164 ha correspondiente a la cuenca de la quebrada San Narciso, sobre un área total de 2.540 ha para la zona de entrenamiento y validación del valle de Cocora.

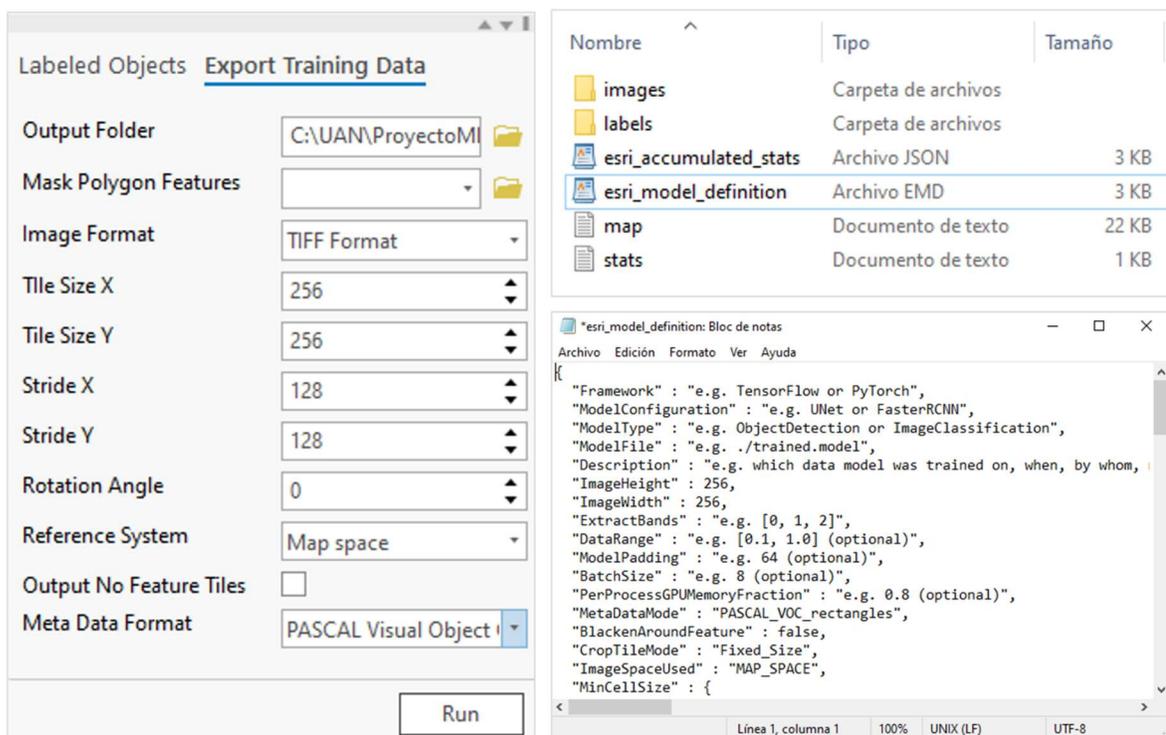
Los recuadros de las muestras se mantuvieron con un ángulo aproximado de 0 a 5° respecto al eje cartográfico norte; esto teniendo en cuenta, que el proceso de detección se lleva a cabo con una malla de cuadros de anclaje (*anchor boxes*), que no presenta rotación respecto al sistema de coordenadas. Cabe anotar que en el proceso de recopilación de muestras pueden adicionarse archivos de shapefile existentes de tipo polígono, usando la opción *Load Training Samples*.

Una vez establecidas las muestras, se debe proceder a la exportación de los datos de entrenamiento accediendo al panel *Export Training Data*, que dentro de sus parámetros adicional a la imagen satelital de entrada y de acuerdo con las recomendaciones dadas por el ESRI (2022d), se introdujo un *Tile Size* (X, Y - tamaño de las imágenes de los sitios de muestra) con valor de 256 píxeles y *Stride* (X, Y - distancia de desplazamiento para la siguiente imagen de los sitios de muestra) de 128 píxeles, lo cual, debe tener en concordancia

con el tamaño promedio de los objetos a detectar y su contexto; igualmente para el formato de metadatos se usó el tipo PASCAL Visual Object Classes y formato de imagen por defecto (TIFF). Ver Figura 8.

### Figura 8

*Exportación de datos de entrenamiento (image chips), usando panel Export Training Data y salidas del proceso.*



Fuente: Elaboración propia.

La salida de este proceso es una carpeta con pequeñas imágenes de los sitios muestra (también denominadas *image chips*), otra con los *labels* o etiquetas en formato XML, un archivo de metadatos y parámetros ('esri\_model\_definition.emd') y otro archivo con estadísticas ('esri\_accumulated\_stats.json').

#### 4.2.2 Entrenamiento del modelo

Este paso se llevó a cabo mediante la herramienta de geoprocésamiento *Train Deep Learning Model*; que como lo indica su nombre, permite generar un modelo basado en Aprendizaje Profundo usando como datos de entrada (o *Input Training Data*), la colección de muestras (en forma de *image chips y labels*) que fueron dispuestas para el proceso de entrenamiento mediante de la función *Export Training Data*; el acceso a esta función se puede realizar llamándola directamente desde la casilla de búsqueda *Command Search* de o accediendo al grupo de herramientas de *Image Analyst Tools > Deep Learning* de ArcGIS Pro. En el panel desplegado se pueden modificar los diferentes parámetros de entrenamiento y escoger entre varios tipos de modelos o arquitecturas de Aprendizaje Profundo para la detección de objetos y la clasificación de rasters.

En la fase de aprendizaje del modelo propuesto en este trabajo, se utilizaron redes neuronales convolucionales de tipo RetinaNet, que, a pesar de ser más demandantes en tiempo de procesamiento, tienden a ofrecer resultados más precisos o ajustados frente a los que ofrecen métodos como *Single-Shot Detector - SSD* (o Detector de Disparo Único), el cual es sugerido por defecto al desplegar la herramienta y recomendado por Lenhardt (2022) para la detección de palmas cocoteras en imágenes aéreas. Sin embargo, para el presente modelo e implementación en la detección de individuos y grupos de palmas de cera, dada la menor resolución de las imágenes satelitales disponibles, una mayor variedad de escenarios, tamaños y disposición en terreno de las palmas, y teniendo en cuenta los resultados de algunas pruebas preliminares que se realizaron con ambos métodos; se decidió llevar a cabo el entrenamiento del modelo final usando la arquitectura RetinaNet; este tipo o método de

modelamiento se selecciona en la casilla *Model Type* de la pestaña de parámetros. Los demás parámetros disponibles para ajustar en esta fase son:

- *Epochs*, que corresponde al número máximo de épocas o iteraciones hacia adelante y hacia atrás de todas las muestras de entrenamiento a través de la red neuronal, donde se tomó un valor 100 de acuerdo con lo aplicado por Lendhart (2022).

- *Batch Size*, o tamaño del lote de procesamiento, que es número de muestras de entrenamiento a ser procesadas al mismo tiempo y que depende del hardware, número de procesadores o GPU disponible, utilizando un valor 16 (2 por cada núcleo o procesador).

- *Scales*, número y proporción de capas piramidales para las que cada celda se escalará hacia arriba o hacia abajo; se tomaron los valores predeterminados 1; 0,79 y 0,63.

- *Ratio*, relación de aspecto de los cuadros de anclaje de 1,2; 1,1; 1; 0,9 y 0,8, dado que el marco del objeto a detectar suele presentarse cuadrado o ligeramente alargado.

- *Chip Size*, valor igual al tamaño de las imágenes de los sitios de muestra o *image chips*, 256.

En la sección de parámetros avanzados, como *backbone* o red residual se utilizó la ResNet-34, la cual se compone de una red de 34 capas pre-entrenada con más de 1 millón de imágenes de la base de datos ImageNet (Ruiz, 2018). De otra parte, de acuerdo con lo recomendado por Lenhardt (2022), se dejó un valor por defecto de 10% para el porcentaje de validación, y el cual especifica la cantidad de muestras de entrenamiento que se utilizan para validar el modelo durante el aprendizaje; así mismo, se deshabilitó la casilla que indica detener el proceso de entrenamiento cuando la curva de aprendizaje comienza a aplanarse, teniendo en cuenta que esta opción puede llevar a una terminación prematura o incompleta del proceso de entrenamiento (Figura 9).

Figura 9

Parámetros de entrenamiento del modelo de detección de individuos y grupos de palmas de cera, mediante la herramienta Train Deep Learning Model y salidas del proceso.

The screenshot shows the 'Train Deep Learning Model' tool in the Geoprocessing environment. The tool's parameters are configured as follows:

- Input Training Data:** imagechips\_pc
- Output Model:** DetectorPalmaCera\_v0
- Max Epochs:** 100
- Model Parameters:**
  - Model Type:** RetinaNet (Object detection)
  - Batch Size:** 16
- Model Arguments:**

Name	Value
scales	1, 0.79, 0.63
ratios	1.2, 1.1, 1, 0.9, 0.8
chip_size	256
resize_to	
monitor	valid_loss
- Advanced:**
  - Learning Rate:**
  - Backbone Model:** ResNet-34
  - Pre-trained Model:**
  - Validation %:** 10
  - Stop when model stops improving
  - Freeze Model

The output files are listed in the following table:

Nombre	Tipo	Tamaño
ModelCharacteristics	Carpeta de archivos	
DetectorPalmaCera_v0.dlpk	Archivo DLPK	133,144 KB
DetectorPalmaCera_v0	Archivo EMD	2 KB
DetectorPalmaCera_v0.pth	Archivo PTH	142,489 KB
model_metrics	Microsoft Edge H...	617 KB

The JSON configuration for the model is shown in the 'DetectorPalmaCera\_v0: Bloc de notas' window:

```
{
  "Framework": "arcgis.learn.models._inferencing",
  "InferenceFunction": "[Functions]System\\DeepLearning\\ArcGISLearn\\A",
  "ModelConfiguration": "_RetinaNet_Inferencing",
  "ModelType": "ObjectDetection",
  "ExtractBands": [
    0,
    1,
    2
  ],
  "ModelParameters": {
    "scales": [
      1,
      0.79,
      0.63,
    ],
    "ratios": [
      1.2,
      1.1,
      1,
      0.9,
      0.8
    ],
    "backbone": "resnet34",
    "backend": "pytorch"
  },
  "Classes": [
    {
      "Value": 1,
      "Name": "Palmacera",
      "Color": [
        38,
        221,
        212
      ]
    }
  ]
}
```

Fuente: Elaboración propia.

De esta forma, y manteniendo los demás parámetros de la herramienta con sus valores por defecto o vacíos, se ejecutó el entrenamiento del modelo de Aprendizaje Profundo para la detección de individuos o grupos de palma de cera en imágenes de alta resolución usando el método RetinaNet, una colección de *image chips* equivalente a 910 muestras y 100 épocas de aprendizaje; lo cual tomó aproximadamente 11 horas, utilizando un equipo portátil con procesador i7 de 10<sup>a</sup> generación (8 núcleos) y sin disponer de una unidad de procesamiento gráfico (GPU) dedicada.

El paquete de Aprendizaje Profundo de salida (\*.dlpk - *deep learning package*), contiene el paquete de definición con el modelo entrenado y un script (\*.pth) de PyTorch (paquete Python de código abierto para aplicaciones de Aprendizaje Máquina basado en la librería Torch). Adicional a lo anterior, el resultado de la herramienta incluye un archivo denominado 'model\_metric.html', que contiene información sobre el modelo generado, en aspectos como tasa de aprendizaje (o *learning rate*, que se ajusta automáticamente en un valor óptimo mediante la subrutina 'lr\_find()') y entendida esta, como la magnitud de cambio o actualización de los pesos del modelo en la retropropagación de datos por la red neuronal durante el proceso de entrenamiento (Li, 2021); función de pérdida de entrenamiento y validación (*training and validation loss*), que indica que tanto se ajusta el modelo a los datos de entrenamiento y a los datos de validación (Paraschiv, 2020); y la puntuación media de precisión (*accuracy*), referida al porcentaje de detecciones correctas del modelo, a partir de los resultados obtenidos con las muestras de validación interna.

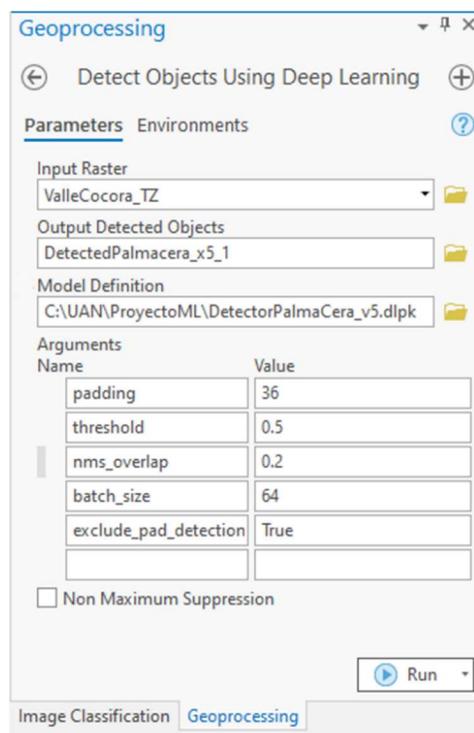
Cabe reiterar, que este proceso de entrenamiento se soporta completamente en el *Deep Learning Framework* instalado y específicamente en el componente PyTorch, los cuales deben ser compatibles con la versión de ArcGIS Pro instalada (2.9.0). En este punto, algunos fallos al momento de ejecutar la herramienta mostraron, de acuerdo a lo expuesto el foro de usuarios de la comunidad de ESRI – Machine Learning Tools, de marzo de 2021 (<https://community.esri.com/t5/arcgis-pro-questions/failed-to-execute-quot-train-deep-learning-model/td-p/1035847>), dan cuenta que aún existen algunos conflictos entre el marco de trabajo y los sistemas configurados en idioma Español, dado el uso de la coma para la separación de decimales, por lo que a la fecha sería necesario o recomendable establecer el formato de datos de EE.UU (separación de decimales con punto).

### 4.2.3 Validación y optimización del modelo (zona de entrenamiento)

Mediante la herramienta *Detect Objects Using Deep Learning* (detección de objetos usando Aprendizaje Profundo) disponible en el grupo de herramientas de *Image Analyst Tools*, se realizó la ejecución del modelo entrenado en el paso anterior para la detección de individuos y grupos de palmas de cera sobre las imágenes satelitales de entrada (*Input Raster*), y definición dada en el paquete ‘DetectorPalmaCera\_v5.dlpk’ (*Model Definition*). Este proceso generó como salida un archivo shapefile (*Output Detect Objects*), donde las entidades corresponden a los recuadros delimitadores de los objetos identificados y una tabla de atributos con el valor de confianza y área asociada a cada elemento. Ver Figura 10.

**Figura 10**

*Parámetros de detección para la validación y ajuste del modelo generado a través de la herramienta Detect Objects Using Deep Learning Model y salidas del proceso.*



Fuente: Elaboración propia.

Sin embargo, de acuerdo con Lenhardt (2022), la detección de objetos es un proceso que comunmente requiere de multiples pruebas con los parámetros del modelo para alcanzar los mejores resultados. Para testear estos parametros rapidamente, se pueden hacer pruebas de detección de palmas de cera en una pequeña sección de la imagen, para posteriormente y luego de identificar valores optimos para los parámetros, proceder a su ejecución sobre la totalidad de la imagen o pasar a implementarlo en otras escenas o zonas de interes, que en este caso corresponde a la zona de las veredas de Alto de Toche - La Ceja (Tolima), como área de implementación; posterior a la validación y ajuste del modelo sobre la imagen de la zona del valle de Cocorá. Dentro de los parámetros incluidos en el proceso de detección a ser ajustados se tienen:

- *Padding*, que adiciona un borde adicional de pixeles alrededor de la imagen, que según Lenhardt (2022), ayuda a reducir la perdida de información de los pixeles con bordes validos y por el submuestreo de las imágenes; se hicieron pruebas con los valores 12, 24, 36 y 48, encontrándose los mejores resultados con un valor de 36.

- *Threshold*, es un valor entre, que establece el nivel de confianza aceptable para etiquetar un objeto o sector de la imagen de entrada como una palma o grupo de palmas, en este caso se mantuvo un valor equilibrado de 0.5; observe que entre menor sea el nivel de confianza establecido, el modelo logra identificar una mayor cantidad de palmas o grupos de palmas pero al tiempo aumenta la cantidad de objetos mal identificados o confundidos visualmente, disminuyendo la precisión del resultado; mientras que con un valor o un nivel de confianza muy alta, si bien la precisión aumenta, a cambio se terminan excluyendo una importante cantidad de palmas de cera o grupos de estas, a considerarse validas dentro de la identificación.

- *Non maximum suppression (nms) overlap*: este valor especifica la relación máxima de área a permitir entre dos cuadros delimitadores que se superponen al identificar objetos igualmente superpuestos o muy cercanos; se probaron valores entre 0,1 y cada 0,1 hasta 0,9; al final se decidió conservar un valor para este parametro de 0,2; observe que si el valor de superposición es alto, el modelo tiende a favorecer la detección de un mayor número de objetos que se presenten superpuestos; como es el caso de los individuos en palmares o grupos de palmas de alta densidad, sin embargo esto tambien termina generar un importante aumento de las detecciones duplicadas. De otra parte si el valor de superposición es bajo, el modelo tiende a separar bien los individuos aislados y a identificar los palmares como un solo elemento; si bien esto limita la obtención de inventario completo de los individuos observables, esto tambien resulta conveniente para un mapeo mas exacto de la distribución de las poblaciones de palma, siendo este un aspecto que será discutido dentro del siguiente capítulo de análisis de resultados, como una de las limitaciones mas importantes observadas con las herramientas de identificación de objetos aplicadas a la detección de individuos de palma de cera u otras especies arbóreas.

Los parametros restantes (*batch size* y *exclude pad detections*), no se mostraron relevantes durante las pruebas de ajuste y optimización del modelo, y se mantuvieron con sus valores por defecto tanto en el tratamiento de la imagen de validación (totalidad zona valle de Cocorá) como en la imagen de implementación (zona veredas de Alto de Toche - La Ceja), y cuyos resultados se analizan en el siguiente capítulo.

## 5. Resultados y Discusión

### 5.1 Modelo para Detección de Palmas de Cera

La parte más extensa del presente trabajo consistió en la preparación de los datos, la recolección de las muestras con imágenes de palmas de cera, y el entrenamiento y optimización del modelo; una vez que estos pasos fueron completados, el modelo generado puede utilizarse para detectar individuos y grupos de palmas de cera en las diferentes imágenes satelitales de alta resolución que le sean suministradas.

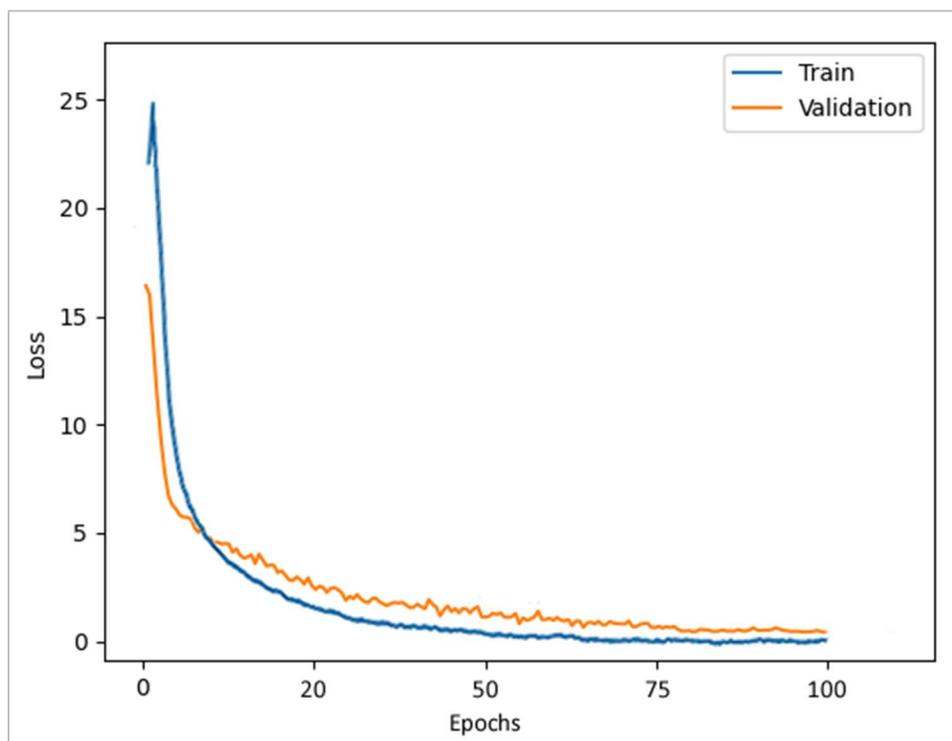
Sin embargo, antes de pasar al análisis de los resultados de detección alcanzados por el modelo tanto en la zona de validación (valle de Cocora, Quindío), como en la zona de implementación (veredas Alto de Toche - La Ceja, Tolima); se presentan los resultados obtenidos respecto al propio entrenamiento del modelo en su versión final (paquete \*.dlpk); en aspectos como la tasa de aprendizaje (o *learning rate*), función de pérdida de entrenamiento y validación (*training and validation loss*), y la puntuación media de precisión (*accuracy*), entregados como salida de la herramienta *Train Deep Learning Model*, en el archivo 'model\_metrics.html' y que dan cuenta de la calidad del proceso de aprendizaje y de la precisión estimada alcanzada por el mismo, en la ejecución de la tarea para la cual fue entrenado.

a) *Learning Rate* = Slice ( $2,75e^{-5}$ ;  $2,75e^{-4}$ ). Es la tasa de aprendizaje mínima y máxima calculada automáticamente para las diferentes capas de la red neuronal, siendo  $2,75e^{-5}$  la tasa de aprendizaje aplicada en la capa residual inferior o *backbone* (características más generales) y  $2,75e^{-4}$  para la capa final (salida); las capas intermedias tuvieron una tasa de aprendizaje entre  $2,75e^{-5}$  y  $2,75e^{-4}$  (progreso lineal).

b) *Training / Validation Loss*. Entendido como el error del modelo al entrenar un conjunto de datos, refleja que tanto se ajusta su resultado a los datos de entrenamiento y validación (Paraschiv, 2020); valores disminuyendo, tendientes a cero y estabilizándose a medida que aumenta el número de épocas o de iteraciones a través de la red neuronal, señalan que la diferencia en la identificación de palmas de cera nuevas, frente a las palmas de cera del conjunto de las muestras de entrenamiento y validación presenta cada vez menos diferencias; indicando que el modelo está ‘aprendiendo’ a realizar la tarea (Figura 11, Tabla 1). De acuerdo con los parámetros de entrenamiento establecidos, la pérdida de validación se calculó para un 10% del total de las muestras utilizadas.

### Figura 11

Gráfica de función de pérdida entrenamiento y validación, entregada en el archivo ‘*model\_metrics.html*’, resultado del entrenamiento del modelo (versión final, optimizada).



Fuente: Generado por ArcGIS Pro.

**Tabla 1**

*Datos tabulados para la función de pérdida entrenamiento y validación; entregados en el archivo training\_validation\_loss.json, para las primeras 20 y últimas 5 épocas.*

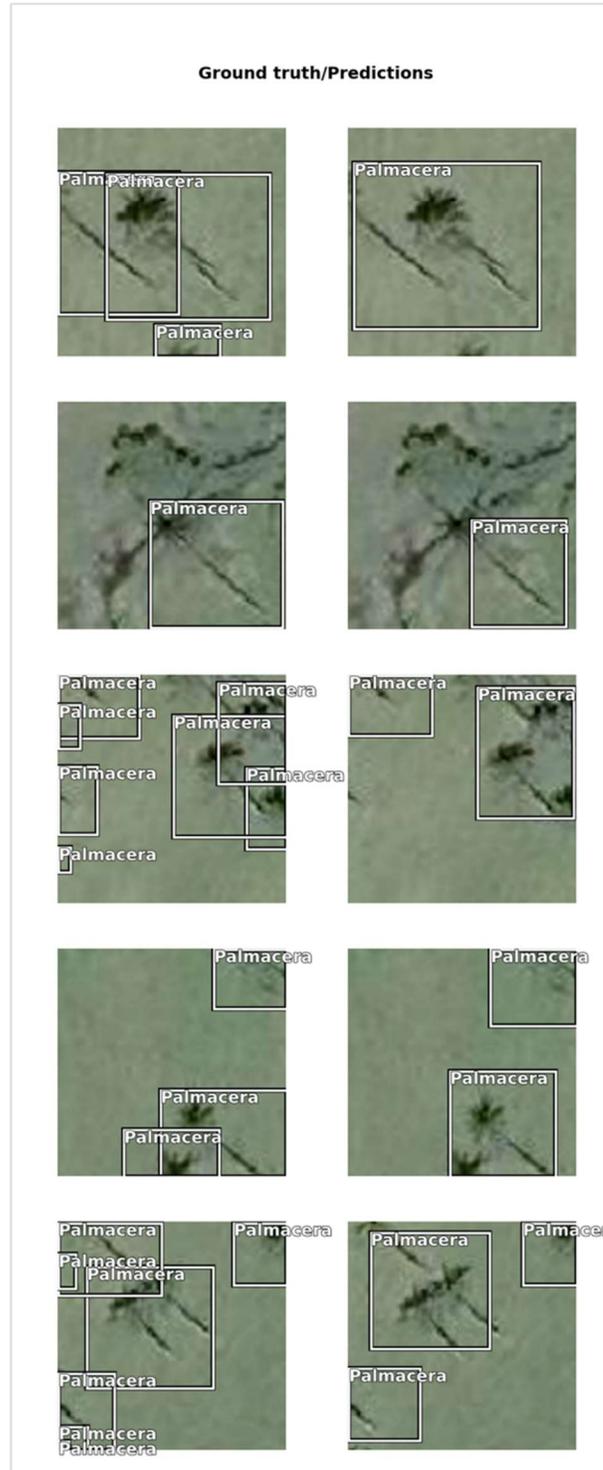
Epoch	training_loss	validation_loss	accuracy
1	16,40241	22,10096	0
2	14,65841	23,45150	0,01323
3	12,28597	24,83486	0,12265
4	10,25169	16,69431	0,20243
5	8,68386	9,42947	0,22510
6	7,46700	8,20649	0,25594
7	6,63598	7,33681	0,28540
8	6,10776	6,17045	0,33177
9	5,79504	3,43205	0,34897
10	5,52647	3,30611	0,38351
11	5,20900	3,23939	0,37005
12	4,95041	3,19945	0,37359
13	4,87580	3,13576	0,35320
14	4,64435	2,98197	0,35440
15	4,28496	2,89017	0,38084
16	4,15730	2,93296	0,37224
17	3,93564	2,77425	0,46672
18	3,75833	2,73089	0,39104
19	3,66847	2,62847	0,43854
20	3,57621	2,59684	0,45704
96	0,73850	0,91640	0,75887
97	0,72227	0,90796	0,72211
98	0,71868	0,90737	0,70123
99	0,67865	0,92375	0,77447
100	0,68952	0,85204	0,78001

Fuente: Adaptado de archivo generado por ArcGIS Pro

c) *Accuracy* = 0,74. Corresponde a la puntuación media de precisión del modelo, estimada a partir de las muestras de validación y calculada automáticamente por la herramienta *Train Deep Learning Model*, a partir de la comparación de los resultados de identificación entre las muestras de entrenamiento (*ground truth*) y las detecciones del modelo (*predictions*)(Figura 12).

**Figura 12**

*Muestra de chips de imagen comparando muestras de entrenamiento y detecciones generadas por el modelo, entregada en el archivo 'model\_metrics.html'.*



Fuente: Generado por ArcGIS Pro.

En este punto, cabe mencionar que durante la evaluación de los parámetros de entrenamiento; adicional al uso de redes neuronales convolucionales de tipo RetinaNet, también se realizaron pruebas de detección con algunos modelos entrenados mediante redes del tipo *Single-Shot Detector - SSD* y en la que el modelo es capaz de detectar entidades dentro de la imagen en una sola pasada; no obstante, si bien el proceso de entrenamiento del modelo y ejecución del mismo se lograba de forma más rápida; las funciones de pérdida de entrenamiento y validación obtenidas presentaban valores muy altos que señalaban dificultad para modelar los datos de entrada, lo que generaba una identificación poco satisfactoria de las palmas en la imagen de validación, con muchos individuos válidos ignorados, otros repetidos, cuadros delimitadores fuera de sitio y mayores dificultades para identificar zonas de palmares o con individuos sobrepuestos.

## 5.2 Zona de Validación (Valle de Cocora, Quindío)

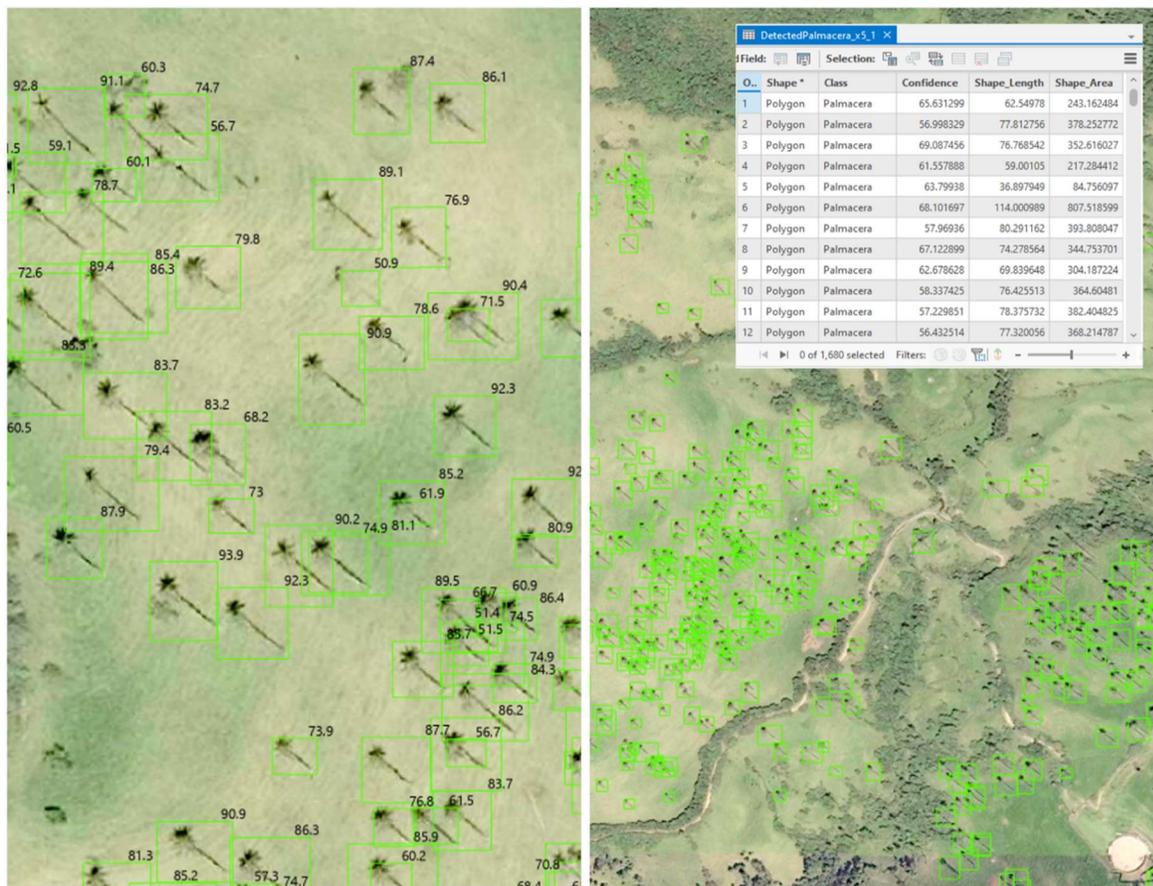
Teniendo en cuenta que el modelo entrenado dispone de diferentes parámetros de detección que debieron ser ajustados para mejorar sus resultados, tal como se explicó en la metodología general del presente trabajo; a continuación, se presentan los resultados de detección de individuos y grupos de palmas de cera, obtenidos para la versión final de modelo y con parámetros optimizados, en la zona de validación correspondiente al valle de Cocora, en Salento (Quindío). (Figura 14).

Se obtuvo un total de 1.680 recuadros representando individuos y grupos de palmas de cera, con una confianza media en la detección calculada por el modelo de 74.1% y que representan una extensión neta ocupada de 35,1 ha; lo cual, con base en una densidad aproximada de 70 palmas/ha en los sectores de mayor concentración y una relación entre individuos y grupos detectados de 0.7 (con un factor promedio de 2.5 individuos por cada

palmar identificado), se puede estimar la población total de palmas de cera en esta zona del país en unos 2.500 a 2.800 individuos adultos; esto redondeando a la centena e incluyendo un 15% de incertidumbre de palmas mezcladas en zona de bosque fragmentado y otras que por su posición en el terreno, tamaño o sobreposición, no pudieron ser detectadas mediante el modelo, dada su dificultad para diferenciarse en las imágenes disponibles; incluso cuando se hace identificación directa sobre la imagen, mediante interpretación visual.

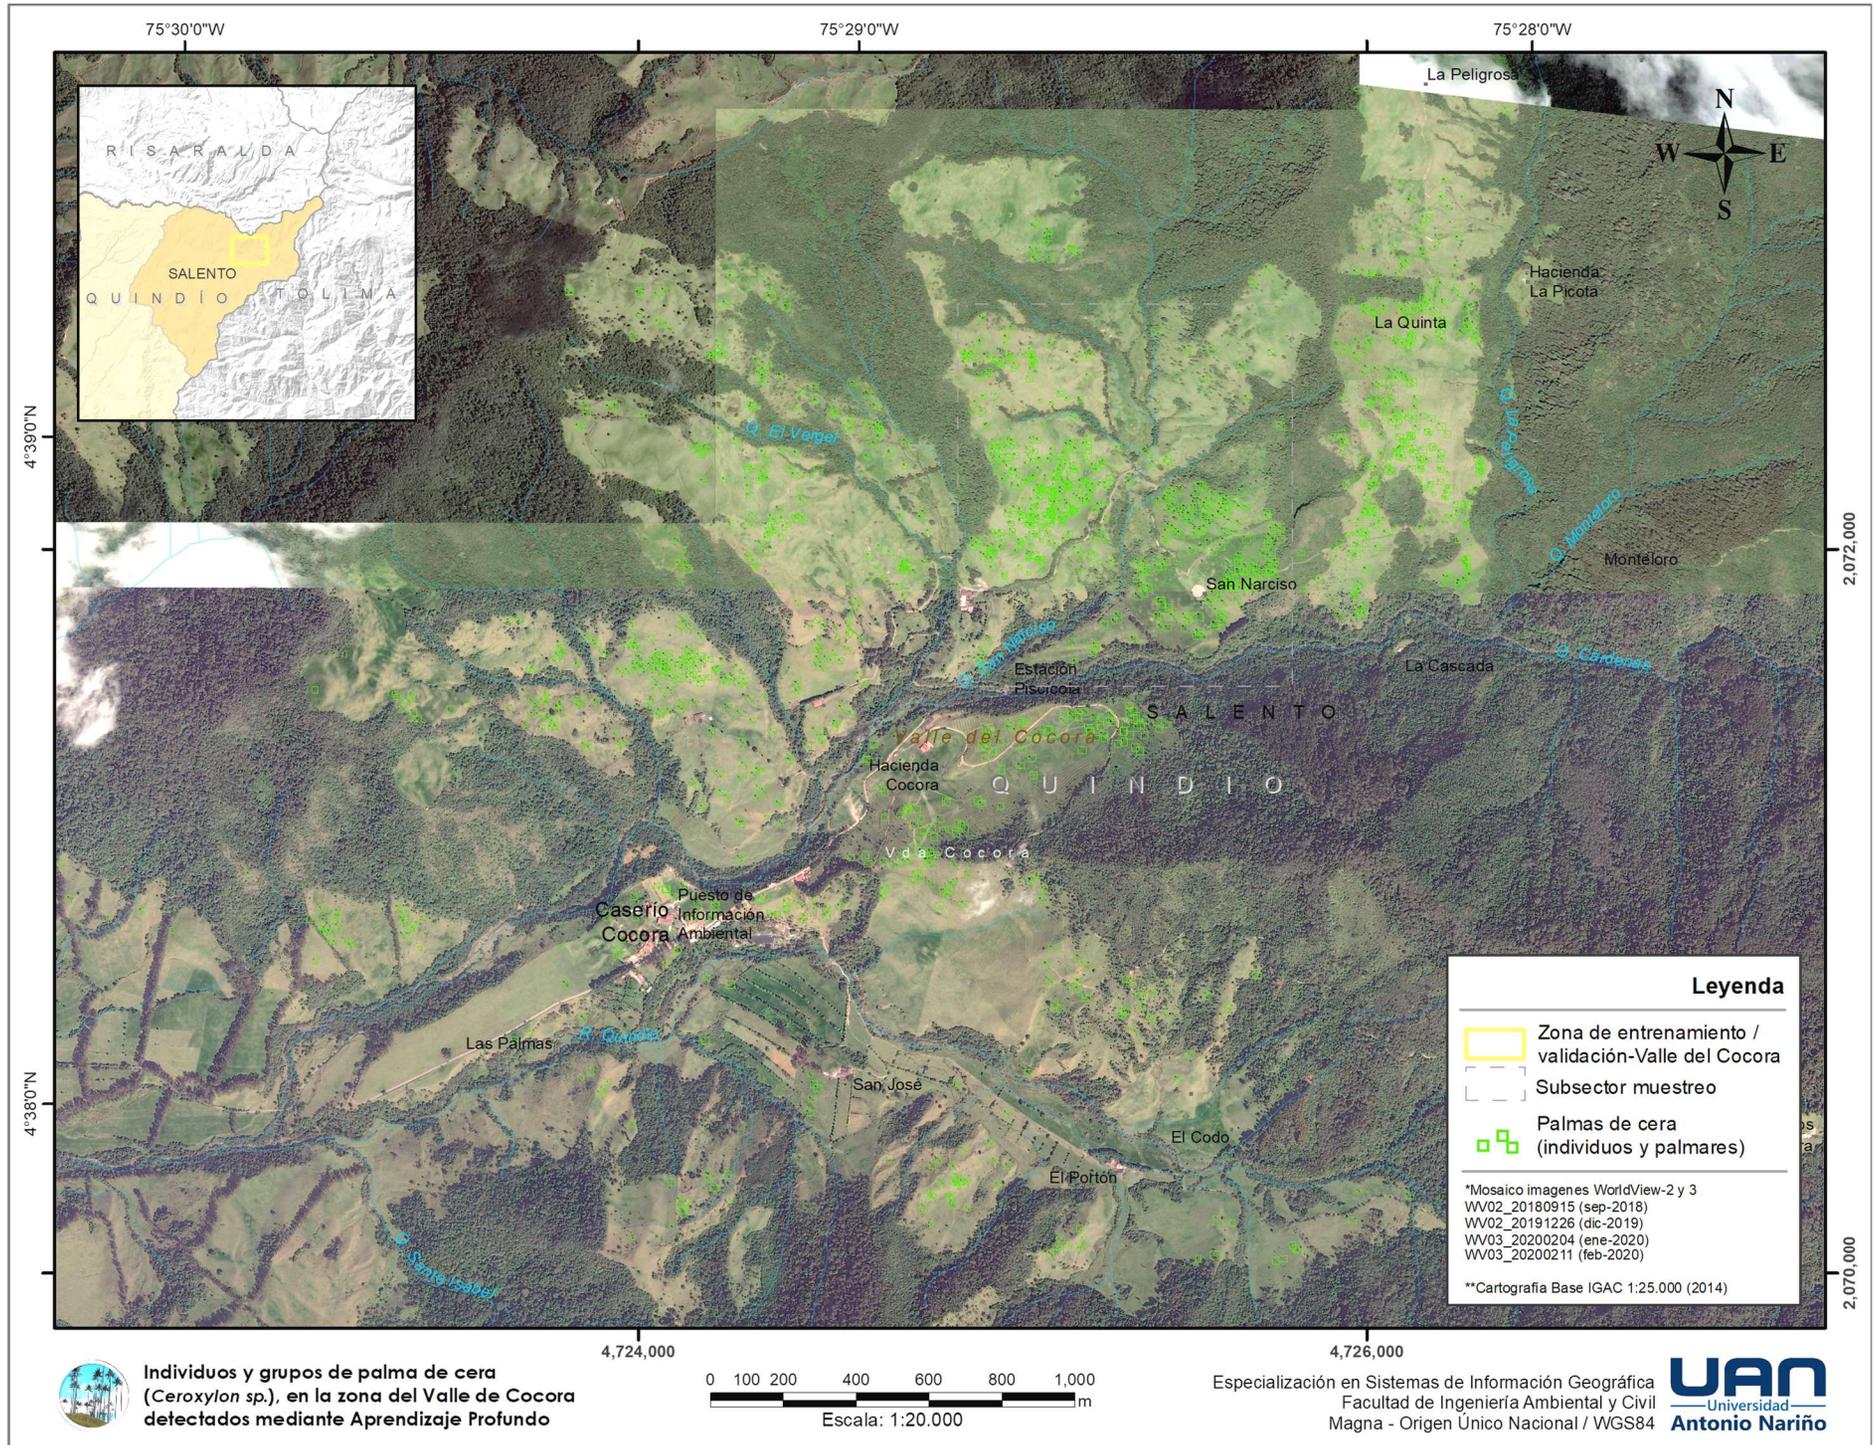
### Figura 13

*Muestra de resultados de detección de individuos y grupos de palmas de cera (Ceroxylon sp.) mediante modelo basado en Aprendizaje Profundo, en sector del valle de Cocora.*



Fuente: Elaboración propia, Mosaico imágenes WorldView-2 y 3 (sep-2018 a feb-2020).

**Figura 14.** Individuos y grupos de palma de cera (*Ceroxylon sp.*), en la zona del Valle de Cocora detectados mediante Aprendizaje Profundo.



Fuente: Elaboración propia (datos, ver Leyenda).

Los resultados obtenidos al ejecutar el modelo entrenado para la detección de individuos y grupos de palmas de cera en la totalidad de la zona del Valle de Cocora, en general mostraron una buena precisión, y confirman la capacidad del modelo para identificar núcleos de palmas de cera, establecer su extensión y distribución espacial, y realizar una estimación de sus poblaciones; en especial para los individuos localizados en zonas de pastos, donde las densidades son menores y su presencia contrasta claramente con las cobertura del suelo.

Si bien en estas zonas de pastos se pudieron observar algunos individuos omitidos y que serían fácilmente identificables mediante interpretación directa (en una proporción menor al 2%); algunos de estos pasaban a ser detectados al modificar el parámetro *padding* o *nms overlap*, lo que evidencia limitaciones que se encuentran más asociadas a la distancia entre los recuadros de detección, que con un entrenamiento insuficiente del modelo.

De otra parte, se observó cierta restricción para separar o detectar individuos presentes en grupos de palmares en sectores con una alta densidad de palmas de cera, dada la sobreposición que se presenta entre estos, resultando confuso incluso para la interpretación visual directa. Adicional a lo anterior, en zonas de cobertura boscosa y en donde algunas de estas palmas logran sobresalir del estrato arbóreo superior; la cantidad de individuos omitidos tiende a ser mucho mayor, dado que en muchas imágenes no se logran observar claramente los troncos y también existe dificultad para diferenciar la corona de las palmas al encontrarse esta mezclada con diferentes especies de árboles. Sin embargo, ambos aspectos podrían subsanarse disponiendo de imágenes de mayor resolución (áreas o tipo dron) y realizando un entrenamiento más específico sobre estas.

Algunas de estas limitaciones también son mencionadas en trabajos como los desarrollados por Valdés & Baquero (2019), en la detección de viviendas sin servicio de energía y por Lenhardt (2022), en la detección de palmas cocoteras; donde se reporta que los resultados obtenidos por este tipo de modelos basados en Aprendizaje Profundo, no son completamente exactos y están restringidos por las limitaciones inherentes a las imágenes satelitales, como son la nubosidad, el ocultamiento topográfico y la sobreposición o confusión con otros objetos cercanos.

### **5.3 Zona de Implementación (veredas Alto de Toche - La Ceja, Tolima)**

La última versión del modelo ajustado en la zona de validación, se ejecutó para la detección de individuos y grupos de palmas de cera, sobre la zona de implementación correspondiente a las veredas de Alto de Toche y La Ceja (municipios de Ibagué y Cajamarca, Tolima); aplicando un conjunto fijo de parámetros previamente optimizados, con el objeto evaluar la capacidad del modelo para identificar núcleos de palmas de cera, establecer su extensión y distribución espacial, y realizar una estimación de sus poblaciones a partir de un mosaico de imágenes satelitales WorldView-2 y 3 (entre diciembre de 2019 y febrero de 2020); correspondientes a una región con un contexto espacial diferente, al que se había manejado en la zona de entrenamiento.

En total se obtuvieron 52.842 recuadros de individuos y grupos de palmas de cera detectados por el modelo (Figura 15), con una confianza media en la detección de 68.6% y que representan una extensión neta ocupada de 431,4 ha; que para una densidad aproximada de 300 palmas/ha en los sectores de mayor concentración de esta localidad y una relación entre individuos y grupos detectados de 0,7 (con un factor promedio de 5 individuos por cada palmar identificado), e incluyendo un 30% de incertidumbre de palmas mezcladas y

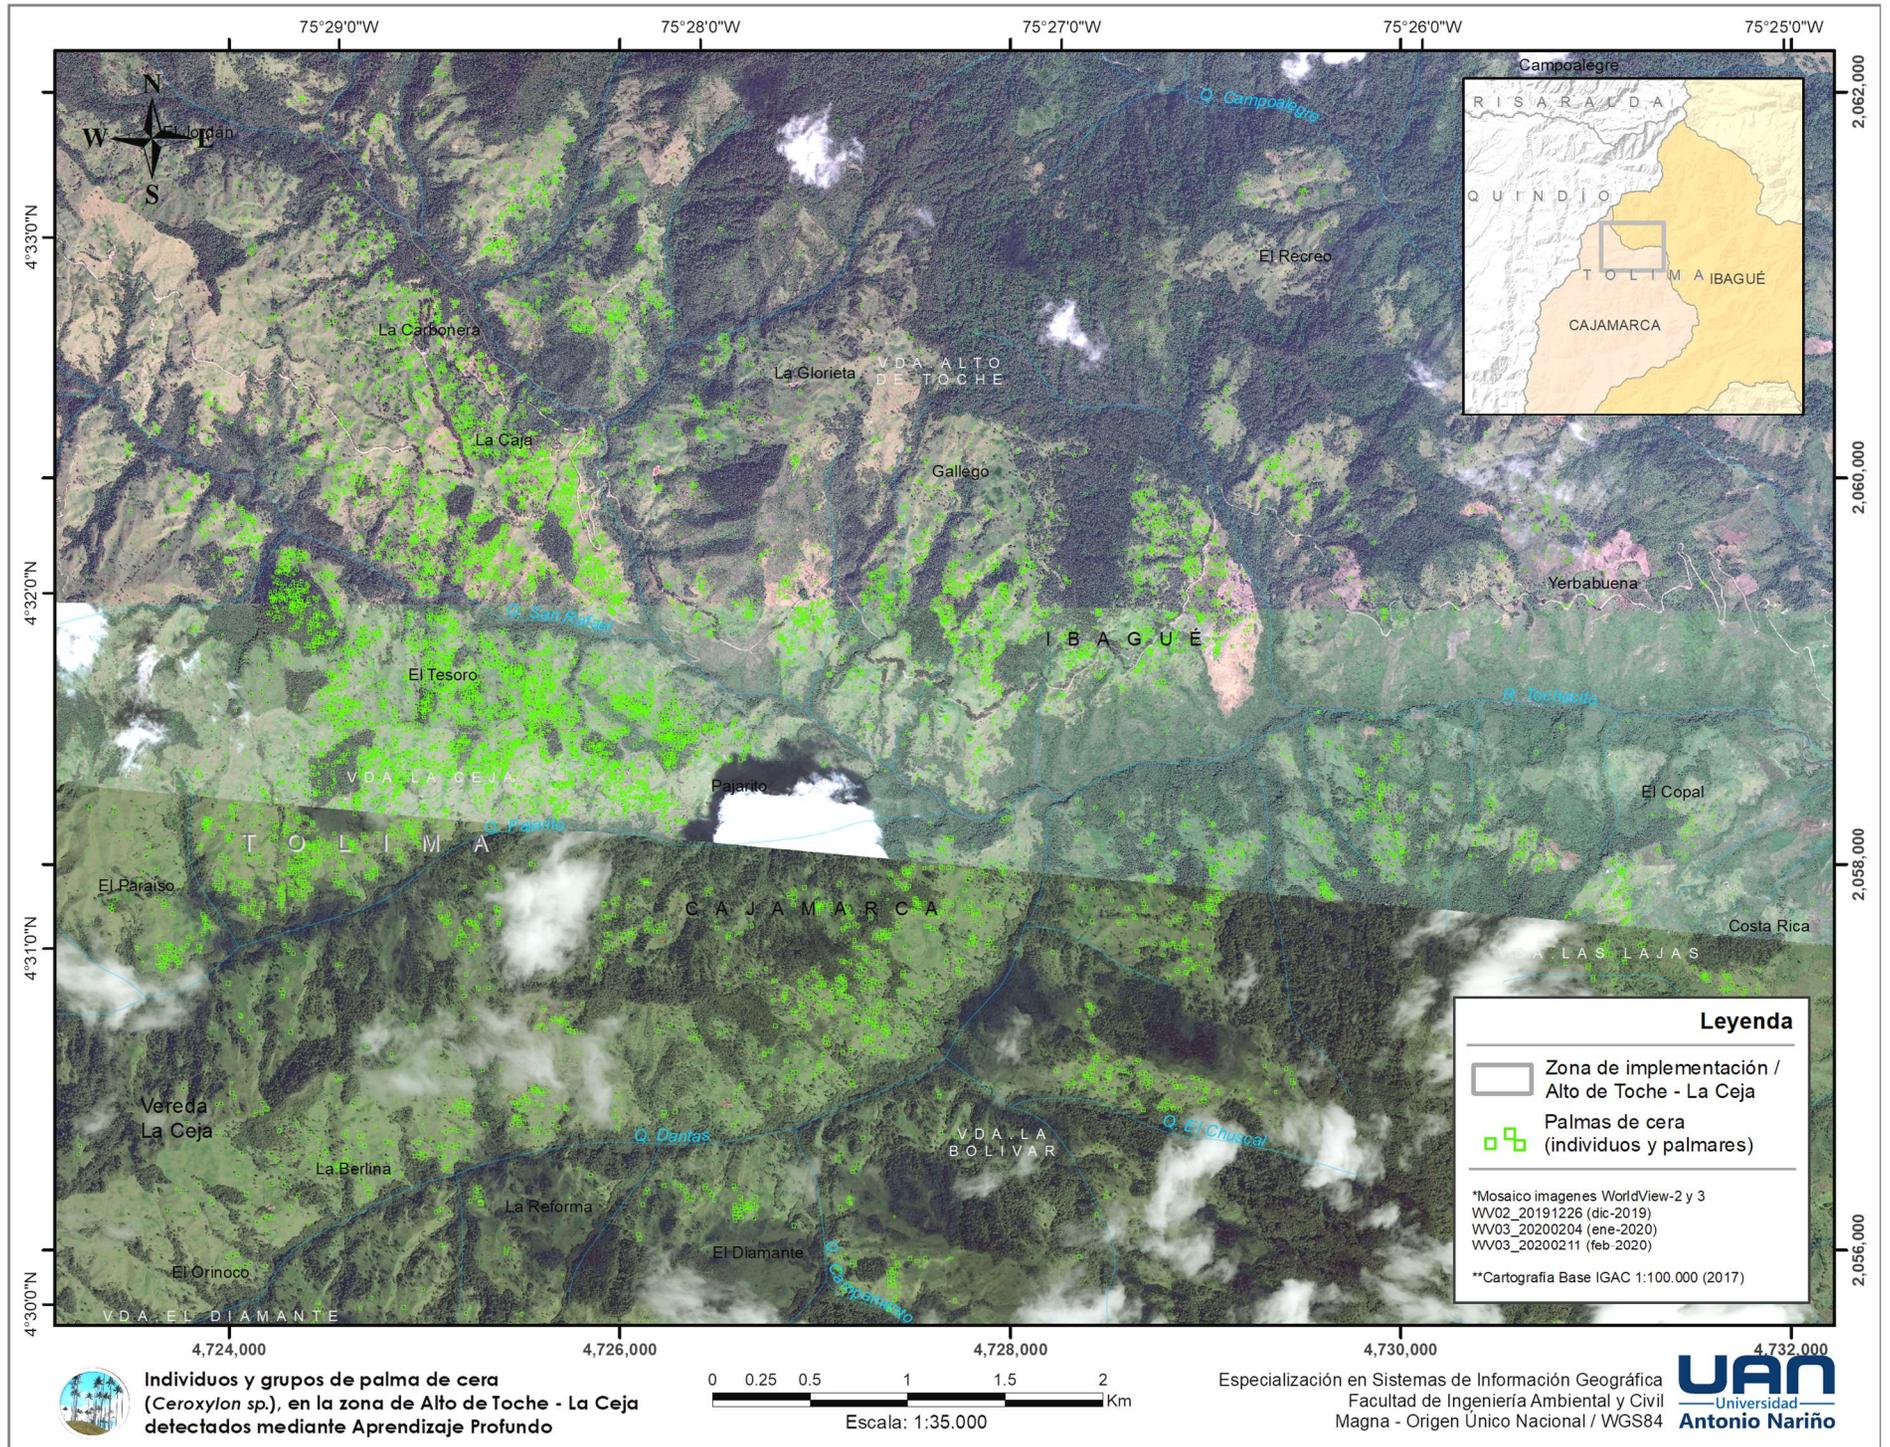
formando palmares de alta densidad en áreas de cobertura boscosa presentes en una alta proporción y por otras limitaciones presentes en el mosaico de imágenes satelitales utilizadas para zona, presentando algunos sectores sin información por la presencia de nubes y distorsión de píxeles por efecto de la ortorectificación; se obtuvo un estimado de 130.000 a 175.000 individuos (redondeando al millar), de población total de palmas de cera adultas en la zona de las veredas de Alto de Toche y La Ceja (Tolima).

Si bien en esta zona los resultados del modelo se vieron restringidos para la separación e identificación de palmas de cera especialmente en las áreas de cobertura boscosa; éste demostró tener un comportamiento adecuado para detectar individuos y palmares en zonas con baja densidad de palmas, presentes en diferentes localidades u otros contextos espaciales, demostrando el potencial del modelo entrenado para identificar automáticamente núcleos de palmas de cera, estimar sus poblaciones y mapear su distribución espacial, contando con imágenes satelitales de otras zonas o localidades del país que pueden ser de interés para la conservación de las palmas de cera.

Vale mencionar que las poblaciones estimadas en este trabajo, en comparación con las cantidades reportadas en estudios previos, como los realizados por el MADS en su Plan de Conservación, Manejo y Uso Sostenible de la Palma de Cera (Bernal et al., 2015), así como con las reportadas por el IAvH (Castillo et al, 2020); reflejan que existe cierto grado de sobreestimación de las poblaciones reales de palmas de cera en estos núcleos, dado que el recuento de individuos y la ponderación de los palmares detectados dentro de las imágenes de satélite utilizadas, tanto en la zona del valle del Cocora como en la de Alto de Toche - La Ceja, se encuentran dentro de los rangos de población más bajos estimados previamente para estas zonas.

Por otra parte, la metodología implementada para el presente trabajo, basada completamente en la plataforma ArcGIS Pro, así como el conocimiento de las diferentes herramientas utilizadas y la teoría de los modelos de Aprendizaje Profundo; permite que estas sean aplicadas en otras tareas de detección de objetos o fenómenos puntuales sobre el terreno, o para automatizar ciertos procesos y realizar análisis cartográficos a escala de producción.

**Figura 15.** Individuos y grupos de palma de cera (*Ceroxylon sp.*), en zona de Alto de Toche - La Ceja detectados mediante Aprendizaje Profundo.



Fuente: Elaboración propia (datos, ver Leyenda).

## Conclusiones

1. Los resultados obtenidos en la ejecución del modelo de Aprendizaje Profundo generado, sobre imágenes satelitales de alta resolución correspondientes a las zonas del Valle de Cocora y de las veredas de Alto de Toche - La Ceja, si bien no son totalmente exactos, existiendo un porcentaje menor al 2% de individuos omitidos y falsas detecciones de objetos visualmente similares en áreas de pastos y mayores al 30% en áreas de cobertura boscosa; en general mostraron una buena precisión, con una confianza media en la detección de 74,1 y 68,6, para las zonas de entrenamiento e implementación respectivamente, confirmando su capacidad para identificar núcleos de palmas de cera, establecer su extensión y distribución espacial, y ofrecer datos para estimar sus poblaciones en diferentes localidades.

2. Las poblaciones de palmas de cera en la zona del valle de Cocora (Salento, Quindío), se estimaron en unos 2.500 a 2.800 individuos adultos y una extensión neta de 35,1 ha (equivalentes al área de los recuadros de detección unidos), mientras que para la zona de las veredas de Alto de Toche - La Ceja (Ibagué y Cajamarca, Tolima), se estimó un total de 130.000 a 175.000 individuos adultos y un área neta ocupada de 431,4 ha; encontrándose estos números, dentro de los rangos de población más bajos estimados previamente para estas zonas en otros estudios.

3. La identificación de individuos de palmas de cera y otras especies forestales en imágenes satelitales de alta resolución, presenta dificultades inherentes a la forma como estos se disponen en el terreno; factores como la presencia de grupos de palmas o árboles en

altas densidades generando sobreposición y el ocultamiento de algunos individuos por la presencia de estratos arbóreos más altos, dificultan tanto la implementación de modelos de Aprendizaje Profundo, como la misma interpretación directa sobre las imágenes.

4. La detección automática de objetos basada en métodos de Aprendizaje Profundo y redes neuronales convolucionales - RNC, se apoya en la identificación de los patrones que puede presentar un determinado elemento o fenómeno en el terreno; por lo tanto, se observa que el entrenamiento y la identificación de objetos tiene una aplicación limitada en imágenes de media y baja resolución, pues estas no ofrecen suficientes detalles para establecer y reconocer dichos patrones; en este sentido, el uso de imágenes de mayor resolución (aéreas o tipo dron), pueden resolver algunas de las limitaciones encontradas para detectar correctamente las palmas de cera en áreas de cobertura boscosa y alta densidad de individuos.

5. Los métodos de Aprendizaje Profundo disponibles para la detección de objetos en ArcGIS Pro, requieren de un entrenamiento robusto que puede lograrse integrando un alto número de muestras y de iteraciones a la red neuronal (*epochs*); sin embargo, el proceso requiere también de un significativo número de pruebas y evaluación del efecto de los diferentes parámetros de entrenamiento y detección disponibles, de manera que se puedan ajustar y optimizar los modelos generados, para obtener los mejores resultados posibles.

## Recomendaciones

1. Para la implementación y entrenamiento de modelos de Aprendizaje Profundo que automaticen diferentes tareas cartográficas, es deseable disponer de potentes recursos de hardware y Unidades de Procesamiento Gráfico (o GPU) dedicadas; pues de esta forma, se reducen los tiempos de entrenamiento, siendo posible procesar un mayor número de datos y así, mejorar la precisión de las tareas modeladas.

2. Dado que las herramientas de detección de objetos que usan Aprendizaje Profundo, no se muestran especialmente sensibles a la resolución radiométrica de las imágenes de entrada y se basan más en el reconocimiento de formas y patrones; los procesos de entrenamiento e implementación pueden verse optimizados con el uso de imágenes de 3 bandas (RGB) en 8 bits o incluso imágenes de una sola banda (B/N) y con formatos de imagen comprimidos como el JP2, JPG o PNG, sin verse afectados de manera significativa la precisión y los resultados obtenidos con este tipo de modelos.

## Referencias

- Bernal, R., Galeano, G. & Sanín M. (2015). Plan de conservación, manejo y uso sostenible de la palma de cera del Quindío (*Ceroxylon quindiuense*), Árbol Nacional de Colombia. Ministerio de Ambiente y Desarrollo Sostenible - Universidad Nacional de Colombia. 70 p. <https://doi.org/10.13140/RG.2.1.3674.4409>
- Bernal, R. & Sanín. M. (2013). Los palmares de *Ceroxylon quindiuense* (Arecaceae) en el valle de Cocora, Quindío: perspectivas de un ícono escénico de Colombia. Colombia Forestal Vol 16 (1): 67-79.  
<https://doi.org/10.14483/udistrital.jour.colomb.for.2013.1.a05>
- Bagnato (2020). Aprende Machine Learning en español: teoría + práctica Python. 350 p.  
<https://www.coursehero.com/file/73480574/aprende-machine-learningpdf/>
- Bobadilla. J. (2021). Machine Learning y Deep Learning usando Python, Scikit y Keras. Ediciones de la U. 293 p.  
<https://es.scribd.com/book/510866088/Machine-Learning-y-Deep-Learning-Usando-Python-Scikit-y-Keras>
- Boldrini, N. (2021). Deep Learning, qué es el aprendizaje profundo, cómo funciona y cuáles son los casos de aplicación.  
<https://www.innovaciondigital360.com/i-a/deep-learning-que-es-el-aprendizaje-profundo-como-funciona-y-cuales-son-los-casos-de-aplicacion/>
- Boruah, P. (2021). *RetinaNet: The beauty of Focal Loss*. Towards Data Science.  
<https://towardsdatascience.com/retinanet-the-beauty-of-focal-loss-e9ab132f2981>

- Castillo, L., Bernal, R., Matallana, C. Waldrón, T., Martínez, B., Garcia, H., Parra, J., Sanin, M., Carvajal, C., Poveda, F. & Zuluaga A. (2020). Tohecito: una oportunidad de conservación de nuestro árbol nacional, en IAvH. *Biodiversidad, Reporte de estado y tendencias de la biodiversidad continental de Colombia. Capítulo 4, Oportunidades de gestión de la biodiversidad territorial*. Instituto Alexander von Humboldt. <http://reporte.humboldt.org.co/biodiversidad/2020/cap4/406/>
- Contreras, S. (2016). Aplicación de Deep Learning en robótica móvil para exploración y reconocimiento de objetos basados en imágenes. Ingeniería de Sistemas y Computación. Universidad de los Andes. 44 p.  
<https://repositorio.uniandes.edu.co/handle/1992/18454>
- Diaz, D. & Barragan, A. (2020). Interpretación de imágenes de satélite con técnicas de Machine Learning para el monitoreo de cultivos: Universidad de Los Andes. Facultad de Ingeniería. 22 p. <https://repositorio.uniandes.edu.co/handle/1992/51505>
- ESRI (2002a). Aprendizaje profundo en ArcGIS Pro. Documentación - ArcGIS Pro.  
<https://pro.arcgis.com/es/pro-app/latest/help/analysis/deep-learning/deep-learning-in-arcgis-pro.htm>
- ESRI (2022b). *How RetinaNet works?* Documentación - ArcGIS API for Python.  
<https://developers.arcgis.com/python/guide/how-retinanet-works/>
- ESRI (2022c). *Install deep learning frameworks for ArcGIS*. Documentación - ArcGIS Pro.  
<https://pro.arcgis.com/en/pro-app/latest/help/analysis/deep-learning/install-deep-learning-frameworks.htm>

ESRI (2022d) *Train Deep Learning model (Image Analyst)*. Documentación - ArcGIS Pro.

<https://pro.arcgis.com/es/pro-app/latest/tool-reference/image-analyst/train-deep-learning-model.htm>

Galeano, G. & Bernal, R. (2005). Palmas (familia *Arecaceae* o *Palmae*) en: E. Calderón, Galeano, G. & García N. *Libro Rojo de Plantas de Colombia, Volumen 2: Palmas, Frailejones y Zamia* (pp 59-253). Ministerio de Ambiente, Vivienda y Desarrollo Territorial - Instituto Alexander von Humboldt - Instituto de Ciencias Naturales.

<http://www.humboldt.org.co/es/i2d/item/277-libro-rojo-de-plantas-de-colombia-vol-2-palmas-frailejones-y-zamias-serie-libros-rojos-de-especies-amenazadas>

Gamarra, C. & Rios, M. (2018). Aplicación de técnicas de aprendizaje profundo para la clasificación y reconocimiento de objetos en imágenes. Universidad Santo Tomas. Facultad de Ingeniería Electrónica. 66 p.

<https://repository.usta.edu.co/handle/11634/10680>

Garcia-Olalla, O. (2019). Redes Neuronales artificiales: qué son y cómo se entrenan.

<https://www.xeridia.com/blog/redes-neuronales-artificiales-que-son-y-como-se-entrenan-parte-i>

Gómez, A. (2021). Las palmas de cera. Boletín El Palmicultor, 589 (Marzo), 23-24.

<https://publicaciones.fedepalma.org/index.php/palmicultor/article/view/13438>

Henderson, A., Galeano G. & Bernal, R. (1995). *Field guide to the palms of the Americas*. Princeton University Press. 352 p.

[https://books.google.com.co/books/about/Field\\_Guide\\_to\\_the\\_Palms\\_of\\_the\\_Americas.html?id=zZ2flHoGLtcC](https://books.google.com.co/books/about/Field_Guide_to_the_Palms_of_the_Americas.html?id=zZ2flHoGLtcC)

- IDEAM (2022a). Atlas climatológico de Colombia 1981 - 2010. Sistema de Información Nacional Ambiental. <http://atlas.ideam.gov.co/visorAtlasClimatologico.html>
- IDEAM (2022b). Mapas de coberturas de la tierra línea base 2010 - 2012. Sistema de Información Nacional Ambiental.  
<http://www.ideam.gov.co/web/ecosistemas/coberturas-nacionales>
- IGAC (2004a). Estudio general de suelos y zonificación de tierras del departamento del Tolima. Memoria técnica, tomos I a III. Instituto Geográfico Agustín Codazzi - Subdirección de Agrología.
- IGAC (2004b). Estudio general de suelos y zonificación de tierras del departamento del Quindío. Memoria técnica, tomos I y II. Instituto Geográfico Agustín Codazzi - Subdirección de Agrología.
- Jaramillo G. & Alzate, J. (2022). Palmas de cera (género *Ceroxylon*). iNaturalist Colombia - California Academy of Sciences - National Geographic Society.  
<https://colombia.inaturalist.org/taxa/126851-Ceroxylon>
- Kohonen, T. (1982). *Self-organized formation of topologically correct feature maps*. Biol. Cybern. 43, 59–69. <https://link.springer.com/article/10.1007/BF00337288>
- Lenhardt, J. (2022). *Use deep learning to assess palm tree health*. Learn ArcGIS – ESRI Training Lessons.  
<https://learn.arcgis.com/en/projects/use-deep-learning-to-assess-palm-tree-health/>
- Li, K. (2021). *How to choose a learning rate scheduler for neural networks*. Neptune Blog.  
<https://neptune.ai/blog/how-to-choose-a-learning-rate-scheduler>
- Lin, T., Goyal, P., Girshick, R. & He, K. (2017). *Focal Loss for Dense Object Detection*. Facebook AI Research. 10 p. <https://doi.org/10.48550/arXiv.1708.02002>

- MADS (2017). Resolución 1912. Por la cual se establece el listado de las especies silvestres amenazadas de la diversidad biológica colombiana continental y marino costera.
- Matich, D. (2001). Redes neuronales: conceptos básicos y aplicaciones. Universidad Tecnológica Nacional - Facultad Regional Rosario. Departamento de Ingeniería Química. 55 p.  
[https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5\\_anio/orientadora1/monograias/matich-redesneuronales.pdf](https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monograias/matich-redesneuronales.pdf)
- Paraschiv, E. (2020). *What is a Learning Curve in Machine Learning?*. Baeldung Computer Science. <https://www.baeldung.com/cs/learning-curve-ml>
- Rodríguez, N., Armenteras, D., Morales, M. y M. Romero (2006) Ecosistemas de los Andes colombianos. Instituto Alexander von Humboldt. 154p.  
[https://www.researchgate.net/publication/236173774\\_Ecosistemas\\_de\\_los\\_andes\\_Colombianos](https://www.researchgate.net/publication/236173774_Ecosistemas_de_los_andes_Colombianos)
- Rojas, S., Andrade, H. & Segura, M. (2018). Los suelos del paisaje alto-andino de Santa Isabel (Tolima, Colombia) ¿son sumideros de carbono orgánico?. *Revista UDCA Actualidad & Divulgación Científica*, 21(1), 51–59.  
<https://doi.org/10.31910/rudca.v21.n1.2018.662>
- Ruiz, P. (2018). *Understanding and visualizing ResNets*. Towards Data Science.  
<https://towardsdatascience.com/understanding-and-visualizing-resnets-442284831be8>
- Sanín, M. (2013). Estudios ecológicos y evolutivos en *Ceroxylon* (Palmae: Ceroxyloideae). Tesis de Doctorado, Universidad Nacional de Colombia. 267 p.  
<https://repositorio.unal.edu.co/handle/unal/21941>

- Sanín, M. & Galeano, G. (2011). *A revision of the Andean wax palms, Ceroxylon (Areaceae)*. Phytotaxa 34: 1-64. <https://doi.org/10.11646/phytotaxa.34.1.1>
- Silva S. & Freire E. (2019). Intro a las redes neuronales convolucionales. Bootcamp AI. <https://bootcampai.medium.com/redes-neuronales-convolucionales-5e0ce960caf8>
- Valdés, L. & Baquero, J. (2019). *Deep Learning* aplicado a imágenes satelitales como herramienta de detección de viviendas sin servicio de energía en el caserío Media Luna-Uribia-Guajira. Universidad Distrital Francisco Jose de Caldas. Facultad de Ingenieria. 127 p. <https://repository.udistrital.edu.co/handle/11349/16030>