El análisis de imagen como herramienta para la cuantificación del número de árboles y La fracción de cabida cubierta en sistemas agrosilvopastorales

Beneficiarios asociados:
JUNTA DE ANDALUCIA
CONSEJERÍA DE AGRICULTURA, PESCA Y DESARROLLO RURAL
Agencia de Gestión Agraria y Pesquera
Instituto de Investigación y Formación Agraria y Pesquera
CONSEJERÍA DE AGRICULTURA, PESCA Y DESARROLLO RURAL
Agencia de Medio Ambiente y Agua
CONSEJERÍA DE MEDIO AMBIENTE Y ORDENACIÓN DEL TERRITORIO

ÍNDICE

1 Introducción ***3***

2 Generalidades del procesamiento y análisis de imágenes digitales ***3***

3 Análisis de imagen, sensores remotos y aplicaciones agroforestales ***7***

3.1 Identificación de copas de árboles mediante datos de sensores remotos **7**

3.1.1 Tipos de imágenes 8

3.1.2 Tipos de condiciones agroforestales 11

3.1.3 Preprocesamiento y mejora de la imagen 12

3.1.4 Algoritmos de detección y delineación de árboles 14

3.1.5 Métodos de evaluación de la exactitud y la precisión 15

3.1.6 Reflexiones finales 17

4 Referencias bibliográficas ***18***

EL ANÁLISIS DE IMAGEN COMO HERRAMIENTA PARA LA CUANTIFICACIÓN DEL NÚMERO DE ÁRBOLES Y LA FRACCIÓN DE CABIDA CUBIERTA EN SISTEMAS AGROSILVOPASTORALES

Elvira Fernández de Ahumada y Cristina Martínez Ruedas

1 INTRODUCCIÓN

Los requisitos de monitoreo ambiental, los objetivos de conservación, la ordenación del territorio o la gestión de los recursos naturales orientados al ecosistema, por nombrar sólo algunos *drivers*, han obligado con una urgencia considerable a la puesta en marcha y desarrollo de soluciones operativas que puedan extraer información tangible de los datos de teledetección. Los "caballos de batalla" de la generación de datos satelitales, como los satélites Landsat y SPOT, o los instrumentos ASTER y MODIS, han sido claves, y lo siguen siendo, en estudios mundiales y regionales sobre biodiversidad, conservación de la naturaleza, seguridad alimentaria, impacto de la deforestación y otros campos de aplicación. Con la creciente resolución espacial de los sensores IKONOS (lanzados en 1999), QuickBird (2001), OrbView (2003), o el primer satélite comercial con una resolución de menos de medio metro (Worldview-1, 0,44 m pancromática) lanzado a finales de 2007, las aplicaciones se han extendido a nuevos ámbitos como la seguridad, detección de vehículos y otras aplicaciones urbanas que se han desarrollado rápidamente en términos tanto de número como de sofisticación. Todo esto ha provocado que haya una cantidad cada vez mayor de datos que se producen en una gama cada vez más amplia de resoluciones espaciales, espectrales, radiométricas y temporales.

Este documento, por el interés que supone para el proyecto LIFE bioDehesa, presenta una revisión de los trabajos realizados en el ámbito de los sensores remotos y el análisis de los datos proporcionados por dichos sensores para la identificación y el conteo de árboles, así como la estima del tamaño de las copas. La detección y delimitación automática de coronas de árboles individuales a partir de imágenes de sensores remotos supone un tema interesante para el análisis de imágenes, ya que la extracción de árboles en condiciones agroforestales complicadas no es una tarea trivial. Además, estos estudios permiten proporcionar parámetros significativos tales como la densidad del árbol, la composición de las especies, el análisis de las condiciones de salud, etc., facilitando así la eficiencia en el manejo y la gestión agroforestal.

El documento presenta en primer lugar un capítulo dedicado al procesamiento y análisis de imagen de forma general. En el siguiente capítulo, se aborda la revisión centrada en el análisis de imagen procedente de sensores remotos y su aplicación al inventariado y monitoreo agroforestal.

2 GENERALIDADES DEL PROCESAMIENTO Y ANÁLISIS DE IMÁGENES DIGITALES

El procesamiento y análisis de imágenes digitales nace en el momento en que se dispone de recursos tecnológicos para captar y manipular grandes cantidades de información espacial en forma de matrices de valores. Esta distinción sitúa al procesamiento y análisis de imágenes digitales como una tecnología asociada a las Ciencias de la Computación y por tanto cabe pensar de ella como una proyección del término Visión Artificial dentro del ámbito de la Inteligencia Artificial.

Así, aparecen los conceptos de **técnicas para el procesamiento de imágenes digitales** como el conjunto de todas aquellas técnicas asociadas a la captura, codificación y representación de las imágenes que no introducen sobre las mismas ningún tipo de interpretación, y **técnicas para el análisis de imágenes digitales**, técnicas de visión por computador o visión mediante robot como acepciones que se refieren a aquellas técnicas que tratan de extraer la información presente en la imagen con el fin último de hacer una interpretación de la escena representada por dicha imagen.

Durante los años ochenta las **técnicas de análisis de imágenes** se desarrollaron de forma vertiginosa como consecuencia de la gran cantidad de aplicaciones que aparecieron y la madurez alcanzada en el diseño de arquitecturas de computadores. Las mayores contribuciones se han centrado en el desarrollo de algoritmos para la detección de características (bordes, líneas, texturas) que ayudan a definir lo que Marr (1982) llamó el esbozo primitivo, así como en el desarrollo de técnicas globales de segmentación de una imagen en regiones. A este último respecto cabe destacar aquellas aproximaciones que introdujeron la información de contexto en los procesos de clasificación y segmentación (Besag, 1986; Cross y Jain, 1983; Geman y Geman, 1984).

Para el estudio de las técnicas de análisis de imagen, su contenido puede dividirse en tres niveles. El primero, aborda los procesos de más bajo nivel, utilizando operaciones de pre-procesado para reducir ruido, mejorar el contraste o adecuar el tamaño de la imagen. El segundo nivel se centra en la segmentación y detección de objetos y, por último, tiene lugar un proceso de alto nivel donde se contextualiza la información obtenida en la fase anterior para proceder a la clasificación de las imágenes.

En el proceso de primer nivel, pre-procesado, se realiza un **suavizado de la señal**, a través de **algoritmos de reducción de ruido**. Las técnicas utilizadas dependen de las fuentes de ruido, es por ello que existen diversos métodos que se adecúan a las necesidades de las señales.

Los métodos tradicionales eliminan el ruido en el dominio del espacio, a través de filtros lineales, filtro de **Wiener o de Media**, o no lineales, filtro de la **mediana**. Estas técnicas son efectivas para maximizar la ratio señal/ruido, y es por ello que no son eficaces cuando ambas señales se solapan.

En el dominio de la frecuencia, se emplean técnicas de filtrado de paso bajo utilizando la **Transformada Rápida de Fourier** (*Fast Fourier Transform* FFT). Estos métodos son óptimos cuando las componentes de frecuencia del ruido difieren de las de la señal. En algunas ocasiones, su utilización puede producir frecuencias artificiales.

Los últimos estudios se centran en el dominio de Wavelet y el empleo de filtros adaptativos ya que se genera un nivel óptimo del umbral para la eliminación del ruido. Un estudio más detallado de las distintas técnicas de ruido puede consultarse en Motwani et al. (2004).

Para la eliminación de valores atípicos, derivados de la saturación de los píxeles, ya sea por exceso o por defecto, se utilizan filtros de mediana. Este tipo de ruido es conocido como **ruido de sal y pimienta**.

El **realce o aumento de contraste** es otro aspecto de relevancia en el pre-procesado. Consiste en aplicar algoritmos para eliminar la falta de iluminación uniforme o aumentar el contraste en los objetos, con el objetivo de mejorar el proceso de segmentación en etapas posteriores, facilitando las tareas de partición y detección de objetos. Las principales técnicas utilizadas son:

- La adecuación del rango dinámico
- Ecualización del histograma

- Realzado en el dominio de la frecuencia a través de algoritmos de paso de alta *unsharp masking* que realzan los bordes y objetos (Polesel et al., 2000).

El histograma proporciona información estadística de la imagen, indicando la distribución de los niveles de gris de la misma. El contraste es la dispersión de dichos niveles, es por ello que, una imagen con poco contraste tiene un histograma muy concentrado. La adecuación del rango dinámico, aumentando la dispersión de los niveles de gris incrementará el contraste de la imagen. De la misma manera que cualquier otra función de densidad probabilística, su ecualización maximiza la explotación de la información, para ello se emplean técnicas adaptativas de ecualización del histograma (Stark, 2000).

Otro proceso importante es la interpolación, presente en el escalado de la imagen. Cuando el escalado de la imagen supone un incremento de tamaño, se debe de realizar un remuestreo de la imagen. Existen numerosas técnicas para realizar dicha interpolación: lineales, cuadráticas, de vecindades, cúbicas, interpolaciones Gaussianas o basadas en la transformada de Fourier, las cuales se encuentran descritas en Lehmann et al. (1999).

El resultado del pre-procesado, es otra imagen optimizada para el proceso de segmentación.

Segmentar una imagen consiste en dividirla en partes homogéneas a partir de contornos, conectividad, textura o distorsión para luego discriminar unas regiones de otras. Se podría diferenciar dos tipos de segmentaciones: las completas, cuyo principal objetivo es encontrar regiones disyuntas correspondientes a los objetos, y parciales, las cuales no tienen que estar relacionadas directamente con la obtención de objetos.

Los algoritmos de segmentación de imágenes monocromáticas se basan en alguna de las siguientes características:

- Discontinuidad en los tonos de grises: detección de bordes
- Similaridad: técnicas de umbralización
- Conectividad: basados en el cambio de píxeles adyacentes. Técnicas de crecimiento por regiones.

No existen métodos generales para la segmentación, cada aplicación requiere técnicas específicas. En el artículo *"Image segmentation techniques"* (Haralick y Shapiro, 1985) se realiza una descripción de los principales métodos de segmentación, los cuales se describen a continuación:

- **Umbralización**: La umbralización (*thresholding*) es un método que busca segmentar imágenes escalares creando una partición binaria de las intensidades de las imágenes. La umbralización es una técnica efectiva para obtener la segmentación de imágenes donde estructuras diferentes tienen intensidades contrastantes u otras características diferenciables. La partición usualmente es generada interactivamente, pero también existen métodos automáticos (Bala y Baxi, 2013). Estas técnicas se basan en la búsqueda de los valles entre los distintos conjuntos de objetos homogéneos presentes en la imagen, a través de una percepción global de la misma. En Sahoo et al. (1988) se provee un recorrido por las técnicas de umbralización.
- **Técnicas de crecimiento por regiones**: Esta técnica se basa en la extracción de regiones de la imagen conectadas bajo un cierto criterio de homogeneidad, proximidad, textura. Parten de una o varias semillas, máximos o mínimos de la imagen.
- **Clustering o agrupamiento**: Un algoritmo de agrupamiento común es el algoritmo de las k-means o algoritmo ISODATA. Este algoritmo agrupa datos calculando iterativamente la media

de la intensidad para cada clase y segmentando la imagen mediante la clasificación de cada píxel en la clase con la media más cercana.

- **Detección de bordes** (Davis, 1975): Estas técnicas se basan en la búsqueda de discontinuidades en la imagen. Los principales métodos utilizados son:
    - Filtro Lapaciano más operadores de umbral
    - Filtros Canny:
        - Suavizado de la imagen a través de filtros gaussianos
        - Estimación del gradiente para cada uno de los píxeles y las direcciones de los bordes
        - Búsqueda de máximos locales de los gradientes
    - Sobel: Basados en las derivadas parciales
    - Prewitt: Técnicas de gradiente
- **Técnicas basadas en modelos**: Se basan en introducir información general de la imagen a partir de transformadas, un ejemplo es la transformada de Hough (Srihari y Govindaraju, 1989).

En el trabajo de Pal y Pal (1993), se describen otras técnicas basadas en lógica difusa, pero que no resultan adecuadas en entornos ruidosos. Es por ello que algunas de esas técnicas han sido utilizadas con modelos de campos aleatorios de Markov, los cuales son robustos frente al ruido (Barbu, 2009). En esta misma línea se han realizado modificaciones del algoritmo k-means, antes descrito, basadas en lógica difusa (Ahmed et al., 2002) cuyos resultados son más eficientes.

El resultado de la segmentación son máscaras con las distintas zonas de interés. En estas zonas se obtendrán y definirán los descriptores para la fase de la clasificación.

El último proceso del análisis de imagen es la **clasificación**. Tras la segmentación, determinados espacios homogéneos de características y contextos definidos por las máscaras podrán tener contenido semántico o no. La clasificación determina qué elementos tienen contenido semántico, así como su interpretación. En los procesos de clasificación, hay dos fases, una primera de determinación de las clases, y la segunda donde se realiza la adjudicación de cada uno de los objetos detectados en la segmentación a las clases previamente definidas.

Existen dos tipos de clasificaciones, la **no supervisada**, en la cual no se establece ninguna clase *a priori*, aunque sí se determina el número de clases, y se utilizan distintas algoritmias para la clasificación automática. Por el contrario, en la **clasificación supervisada**, se realiza una definición previa de las clases, que servirán para generar signaturas espectrales de cada una de las clases. Estas clases se llaman informacionales y deben ser lo más homogéneas posibles.

Para la asignación de los píxeles a cada una de las clases se pueden utilizar distintas técnicas (Lu y Weng, 2007):

- <u>Técnicas no estadísticas</u>: basadas en mínimos cuadrados, paralelepípedos.
- <u>Métodos estadísticos clásicos</u>: técnicas de máxima proximidad.
- <u>Algoritmos basados en inteligencia artificial</u>: clasificación contextual, lógica difusa, redes neuronales, árboles de decisión.

Existen determinados métodos de segmentación, como por ejemplo los campos aleatorios de Markov, que extraen información para contextualizar regiones de la imagen, o técnicas de Clustering de k-means, que se pueden considerar también métodos de clasificación, concretamente el k-means sería un método automático de clasificación no supervisado.

3 ANÁLISIS DE IMAGEN, SENSORES REMOTOS Y APLICACIONES AGROFORESTALES

Las imágenes procedentes de sensores remotos deben convertirse en información tangible que pueda utilizarse conjuntamente con otros sets de datos, a menudo dentro de los Sistemas de Información Geográfica (SIG), ampliamente utilizados. Mientras los tamaños de píxeles permanecieron mayores que, o en el mejor de los casos, de tamaño similar a los objetos de interés, se hizo hincapié en el análisis por píxel, o incluso en el análisis de subpíxeles. Sin embargo, con resoluciones espaciales crecientes, se han seguido caminos alternativos orientados a derivar objetos formados por varios píxeles. El desarrollo de métodos basados en objetos tiene como objetivo delinear objetos fácilmente utilizables de las imágenes y, al mismo tiempo, combinar el procesamiento de imágenes y las funcionalidades SIG para utilizar la información espectral y contextual de una manera integradora. El enfoque más común utilizado para construir objetos es la segmentación de imágenes, que se remonta a los años setenta. Alrededor del año 2000, el SIG y el procesamiento de imágenes comenzaron a crecer rápidamente a través del análisis de imágenes basado en objetos (OBIA o GEOBIA para el análisis de imágenes basadas en objetos geoespaciales). El paradigma de píxeles está comenzando a mostrar grietas y los métodos OBIA están haciendo progresos considerables hacia un flujo de trabajo de extracción de información espacialmente explícito, tal como se requiere para la planificación espacial, así como para muchos programas de monitoreo.

A continuación, se presenta un recorrido por diferentes trabajos científicos que han abordado la detección de objetos, en concreto, de copas de árboles de diversas especies con el fin de planificación, inventariado o monitoreo agroforestal, haciendo uso de imágenes aéreas y satelitales de distintas resoluciones y utilizando distintos algoritmos para el procesado de las mismas.

3.1 Identificación de copas de árboles mediante datos de sensores remotos

La detección y delineación de copas de árboles individuales de forma automatizada utilizando datos de sensores remotos tiene un papel cada vez más importante en el monitoreo eficiente, preciso y completo de las zonas agroforestales, resultando clave en los procesos de toma de decisiones de la gestión agroforestal.

Desde mediados del siglo XX, las fotografías aéreas se han aplicado al inventario y al análisis de zonas agroforestales (Alemdag, 1986; Pitt et al., 1993), y aunque tales fuentes de datos crearon nuevas oportunidades y mejoraron la eficiencia de las mediciones de campo, la interpretación visual de esos datos siguió siendo costosa y laboriosa. Es por ello que los algoritmos semi y totalmente automáticos para detectar y delimitar coronas de árboles individuales y otros elementos ecológicos a partir de imágenes de sensores remotos juegan actualmente un papel crítico en el inventario agroforestal moderno en términos de obtener información oportuna, exacta, completa y económica. En esta línea el desarrollo experimentado en el campo de la teledetección ha permitido que tanto los sensores aerotransportados como los sensores satelitales pueden adquirir imágenes digitales de alta resolución espacial (por debajo del metro) de manera precisa y económica. Asimismo, el progreso en los sistemas informáticos modernos ha facilitado el análisis de imágenes digitales para el reconocimiento automático de características de objetos específicos. Por tanto, todo ello está proporcionando fuentes viables de datos y oportunidades para la interpretación automática de sistemas agroforestales.

La investigación sobre la detección automática de árboles mediante análisis de imágenes digitales se remonta a mediados de los 80, en primer lugar, a partir de imágenes aéreas y satelitales de

sensores pasivos, posteriormente, a partir de datos derivados de sensores activos, y más recientemente de la integración de múltiples fuentes de datos (Hyyppä et al., 2008, Ke y Quackenbush, 2011). Uno de los primeros algoritmos fue presentado por Pinz (1991, 1999a, 1999b) que utilizando el Sistema de Visión Experto pudo localizar el centro de una copa y estimar su radio buscando máximos de brillo locales en imágenes aéreas pre-tratadas mediante suavizado y con un tamaño de píxel de 10 cm. A mediados de la década de los noventa, Gougeon (1995a) presentó un algoritmo para delinear copas de coníferas, siguiendo valles de sombras entre copas de árboles usando imágenes aéreas digitales con ground sampled distance (GSD) de 36 cm. En el mismo período, se aplicó el análisis de múltiples escalas en imágenes de mayor resolución para estimar el área de la copa de árboles (Brandtberg 1998, 1999a, 1999b) y se introdujeron técnicas basadas en modelos de *matching templates* para reconocer árboles individuales (Pollock 1996). Posteriormente, se introdujeron otros algoritmos de segmentación de imágenes tales como *growing region* y *watershed segmentation* en la detección de árboles y en la delimitación de las copas. Gougeon y Leckie (2003) dividieron estos enfoques en tres categorías según la información extraída: detección de la ubicación de los árboles; detección de ubicación del árbol y parametrización de la dimensión de la copa; y la delineación completa de la copa. Estas categorías tienen en común que, para la mayoría de los métodos, la detección de la copa es un paso previo a la delineación de la corona y su exactitud afecta en gran medida a la delimitación de la copa. Sin embargo, dichos métodos son diferentes en términos de los algoritmos utilizados, las condiciones específicas del área de estudio, los tipos de imágenes en los que se aplican y la exactitud de los métodos de evaluación considerados.

En los últimos años, han tenido una gran expansión los dispositivos de detección remota activos que emiten energía y posteriormente reciben porciones de la energía reflejada desde el objeto de estudio, pudiendo capturar directamente la estructura vertical de la copa de los árboles y proporcionando un input de altura. Las imágenes LiDAR (*Laser Imaging Detection and Ranging*), en particular, han sido ampliamente utilizadas y aplicadas para el análisis de inventario agroforestal (Fransson et al., 2000, Holmgren y Persson 2004). Dado que un elevado muestreo de puntos LiDAR proporciona una estructura vertical detallada de las copas de los árboles, diferentes autores han utilizado mediciones de LiDAR para estimar la altura media, el volumen de tronco y la biomasa aérea de árboles (Næsset 2002, Goboakken y Næsset 2005, Maltamo et al. 2006) o para extraer información individual sobre el diámetro de la copa y la altura del árbol (Brandtberg et al., 2003, Holmgren y Persson 2004, Chen et al., 2006). Otros estudios también han integrado LiDAR e imágenes aéreas de alta resolución espacial para el análisis de árboles individuales, ya que LiDAR proporciona información precisa de la altura del árbol y las imágenes ópticas proporcionan información espacial y espectral detallada. Si bien LiDAR se ha convertido en una fuente de datos prometedora y está mostrando una presencia cada vez mayor en la literatura, las aplicaciones existentes en el análisis de la copa de árbol siguen dominadas por las imágenes ópticas porque el uso de datos LiDAR puede resultar prohibitivo en cuanto al coste. En base a esto, y a la necesidad de restringir el alcance dentro de las limitaciones prácticas, la discusión de este documento se centra en los métodos relacionados con imágenes aéreas y satelitales procedentes de sensores pasivos.

3.1.1 Tipos de imágenes

Las imágenes aéreas han sido durante mucho tiempo la fuente de información más común para el inventario forestal (Kangas y Maltamo 2006), por lo que la investigación sobre detección y delineación de árboles individuales está dominada por estudios que han utilizado imágenes aéreas

(Gougeon 1995a, Larsen 1997, Brandtberg 1998, Wang et al., 2004). Dos sensores frecuentemente utilizados fueron el Compact Airborne Spectrographic Imager (CASI), capaz de adquirir imágenes multiespectrales desde el visible (VIS) al infrarrojo cercano (NIR) (Anger et al., 1994), y el Multi-detector Electro-optical (MEIS-II), con una resolución espacial de media a alta para hasta ocho bandas espectrales (Gougeon 1995a, 1995b, Pollock 1996, 1999, Gougeon y Leckie 1999, Gougeon 2000, Wang et al., 2004, Bunting y Lucas 2006). Con la notable mejora en la resolución espacial de las imágenes satélite durante la última década, los investigadores han comenzado a explorar la utilización de dichos datos. La creciente disponibilidad de datos de satélites de alta resolución espacial - por ejemplo, IKONOS, QuickBird, WorldView y OrbView - ofrece un campo más amplio de actuación en comparación con las fotografías aéreas (Gougeon y Leckie 2003). Esta disponibilidad también ha llevado a un aumento del número de archivos de imágenes y a una disminución de su coste. Gougeon y Leckie (2006) utilizaron imágenes pancromáticas de IKONOS con resolución de suelo de 1 m para la delineación individual de árboles y lograron resultados prometedores (error promedio de 15% en el número de árboles) dentro de un bosque de coníferas de edad uniforme. Igualmente, con imágenes pancromáticas de IKONOS, Zhou et al. (2010) obtuvieron resultados prometedores en la detección de árboles en la Guyana francesa en zonas de mangle de elevada biomasa. Kim y Muller (2011) utilizaron imágenes de IKONOS para detectar árboles y edificios en zonas urbanas, obteniendo errores en torno al 10%. Las imágenes de satélite de QuickBird, con 0,61 m de GSD en modo pancromático y 2,44 m de GSD en modo multiespectral, también se han utilizado en investigaciones preliminares de detección y delineación de corona de árbol por Ke y Quackenbush (2007). Daliakopoulos et al. (2009) señalan un uso satisfactorio de imágenes Quickbird (0,7 x 0,7 m) para la detección de distintos usos del suelo y el tamaño de árboles (olivos y cítricos) en un rango específico. Por su parte, González et al. (2010) utilizaron imágenes Quickbird para cuantificar el secuestro de carbono en bosques de secuoya de California y en bosques de Sierra Nevada, a partir de la detección de árboles y la estima del diámetro de su copa, con resultados mejorables debido a un número elevado de errores de omisión. Shurikin et al. (2013) con imágenes Quickbird (0,61 m) realizaron conteo de árboles, obteniendo diferencias en los errores dependiendo de la densidad (zonas más densas errores en torno al 46 %, zonas menos densas errores en torno al 27%). Años más tarde, estos autores mejoraron los resultados (errores del 22%) en zonas de regenerado donde llevaron a cabo una buena identificación de solapes de copas (Shurinkin et al., 2016). Uddin et al. (2015) obtuvieron buenos resultados para planificación haciendo uso de imágenes Quickbird e IKONOS para detectar cambios en el número de árboles en Nepal. En la zona tropical de sabana arbolada, destaca el trabajo de Gomes y Maillard (2014) con imágenes de WorldView con las que obtuvieron un porcentaje de árboles correctamente identificados entre 65 y 90%.

Los últimos desarrollos en vehículos aéreos no tripulados (VAN) y los sistemas de detección asociados a los mismos han hecho que estas plataformas resulten cada vez más atractivas para el ámbito de la teledetección y sus aplicaciones agroforestales. La gran cantidad de detalles espaciales contenidos en estas imágenes abre la puerta para aplicaciones avanzadas de monitoreo. Hung et al. (2012) en su aproximación a la detección de objetos con imágenes de drones para el monitoreo y mapeo de explotaciones agroganaderas en Australia, hicieron uso de información geométrica y de apariencia (forma y sombra del árbol) además de información espectral y con un algoritmo en dos etapas obtuvieron resultados prometedores. Por su parte, Katternborn et al. (2014) aprovecharon el alto potencial de las nubes de puntos fotogramétricos basadas en VAN para la detección de un solo árbol usando algoritmos de vertido. Este enfoque fue ajustado y mejorado para una aplicación en plantaciones de palmeras que dio como resultados porcentajes del 86,1% de árboles correctamente clasificados en toda el área de estudio y valores del 98,2% en zonas de mayor densidad de palmeras.

Malek et al. (2014), a partir de una imagen de VAN adquirida en una explotación de palmeras, extrajeron un conjunto de puntos clave utilizando el algoritmo SIFT (transformación de características invariantes en escala), para después analizar esos puntos clave con un clasificador de máquina de aprendizaje extremo (ELM) entrenado *a priori* sobre un conjunto de puntos clave palmera/no palmera. Los resultados experimentales obtenidos en imágenes de VAN con 3,5 cm de resolución espacial y adquiridos en dos explotaciones diferentes confirmaron las capacidades prometedoras de estas plataformas. Yilmaz et al. (2016) desarrollaron en el lenguaje de programación MATLAB una metodología de detección de árboles basada en objetos para determinar la posición de cada árbol. El algoritmo utiliza el modelo de altura de copa, que se calcula a partir del modelo digital del terreno y del modelo digital de superficie generados mediante la nube de puntos extraída de las imágenes tomadas de un VAN. Los resultados mostraron que la metodología de detección de árboles desarrollada detectó más del 70% de los árboles con éxito. Nevalainen et al. (2017) realizaron un estudio en once sitios de prueba con 4151 árboles de referencia de varias especies de árboles y etapas de desarrollo utilizando un VAN equipado con una cámara hiperespectral y una cámara RGB, en condiciones climáticas muy variables. Las nubes de puntos densos se midieron fotogramétricamente mediante la coincidencia automática de imágenes utilizando imágenes RGB de alta resolución con un intervalo de 5 cm. Las características espectrales se obtuvieron a partir de los bloques de imágenes hiperespectrales, cuya gran variación radiométrica se compensó utilizando un nuevo enfoque basado en el ajuste del bloque radiométrico con el apoyo de observaciones de irradiancia en vuelo. Las características de nubes de puntos espectrales y 3D se usaron en el experimento de clasificación con varios clasificadores. Los mejores resultados dieron una precisión de 95%. Demir (2017) utilizó una GoProHero conectada a un pequeño VAN para capturar imágenes de una pequeña área cubierta por pinos. Generó un modelo digital de superficie mediante coincidencia de imágenes (*image matching*). El modelo de elevación que representa la superficie del terreno, un modelo digital de terreno, se extrajo del modelo de superficie digital utilizando el filtrado morfológico. Los árboles individuales se extrajeron analizando el flujo de elevación en el modelo de elevación digital ya que la elevación alcanzó el valor más alto en los picos de los árboles en comparación con los píxeles de elevación vecinos. La calidad de los resultados se evaluó mediante la comparación con los datos de referencia para la corrección del número estimado de árboles. Las alturas de los árboles se calcularon y evaluaron con datos de campo. Los resultados mostraron un 80% de corrección. Por su parte, Mohan et al. (2017) evaluaron la aplicabilidad de cámaras de bajo consumo asociadas a VANs y el algoritmo de estructura de movimiento (SfM) para la detección automática de árboles individuales usando un algoritmo basado en máximos locales en modelos de altura de copa derivados de VAN. El número de árboles se contó manualmente utilizando como referencia el ortomosaico derivado de VAN. Se contaron un total de 367 árboles de referencia y el algoritmo detectó 312 árboles, resultando en una precisión superior al 85%: el algoritmo no detectó 55 árboles (errores de omisión), y falsamente detectó 46 árboles (errores de comisión).

Los métodos existentes para la detección y delimitación de la copa de los árboles generalmente aíslan los árboles individualmente basándose en la distinción entre el brillo de las copas y el fondo. Esta distinción depende en gran medida de la relación entre la resolución espacial de la imagen y el tamaño de la copa. Las imágenes de muy alta resolución (por ejemplo, 5-15 cm GSD) pueden proporcionar demasiados detalles para copas maduras: las ramas y las sombras de las ramas, son propensas a causar una gran variación dentro de la copa del árbol de forma que copas individuales pueden ser divididas en varias. Sin embargo, a medida que disminuye la resolución, la distinción entre el área de la copa y el fondo también disminuye, especialmente para las copas de árboles pequeños, por lo que los bordes de la copa se hacen menos detectables. Ke y Quackenbush (2011) estudiaron la resolución espacial

más utilizada para la detección de copas y obtuvieron que ésta era la de 51-70 cm de GSD. Esto tiene su explicación en el uso extensivo de imágenes CASI con 60 cm de GSD. La principal ventaja de los datos CASI es que proporcionan entre 6 y 14 bandas multiespectrales, incluyendo bandas en el rojo y en el infrarrojo cercano, que son longitudes de onda críticas para la identificación de las características de la vegetación. Además, este rango de resolución espacial fue apropiado, ya que muchos de los métodos fueron probados en bosques maduros de coníferas, con un diámetro de copa de alrededor de 6-10 m, de modo que aproximadamente 10x10 píxeles representan un solo árbol con un ratio de diámetro de corona y tamaño de píxel de alrededor de 10:1. Sin embargo, para un bosque regenerado, incluso la detección visual de árboles jóvenes resulta problemática. Gougeon y Leckie (1999) encontraron que su método de seguimiento del valle y el método basado en reglas no podían encontrar árboles menores de cinco años usando datos MEIS-II de 30 cm de GSD. También encontraron que los datos de CASI de 60 cm no permitían detectar árboles individuales en coníferas de 20 años de edad, con errores en torno al 50-75%, causados en gran parte por grupos de árboles identificados como un solo árbol (Leckie et al., 2003b). Gougeon y Leckie (2006) re-muestrearon imágenes IKONOS de 1 m de GSD para crear pixeles de 50 cm para delineación de coníferas con diámetro de corona entre 2,5-4 m (ratio diámetro de corona y tamaño de píxel de alrededor de 5:1 a 8:1). Las imágenes de resolución más fina (por ejemplo, GSD menor de 30 cm) pueden facilitar la detección de árboles pequeños en bosques regenerados, pero el análisis de tales imágenes requiere más tiempo de cálculo y la variación de brillo dentro de las copas más grandes conduce frecuentemente a grandes errores de comisión. Existen varios estudios en los que se ha recurrido al análisis de imágenes a escala múltiple (por ejemplo, Brandtberg 1998, 1999a, 1999b) o métodos de suavizado óptico para mitigar estos problemas (por ejemplo, Pouliot y King 2005). La relación entre la resolución de la imagen y el tamaño de la copa de árbol es fundamental para el desarrollo de algoritmos, así como para la exactitud resultante. Pouliot et al. (2002) examinaron la influencia del tamaño de los píxeles sobre la exactitud en la delineación de las coronas de coníferas de entre 6 y 10 años. Encontraron que la relación óptima entre el diámetro de la copa y el tamaño del píxel era de 15:1.

3.1.2 Tipos de condiciones agroforestales

Con el objetivo de realizar un inventario agroforestal automatizado, se han realizado investigaciones sobre la detección y delimitación de árboles individuales en diferentes tipos de zonas agroforestales, incluyendo bosques naturales (por ejemplo, Bunting y Lucas 2006), plantaciones, huertos (Kay et al., 1998) e incluso bosques urbanos (Sheng 2000, Sheng et al., 2001). La mayoría de las investigaciones se centraron en bosques de coníferas, aunque algunos estudios (por ejemplo, Pollock 1996, Brandtberg 1998, Leckie y Gougeon 1999, Bunting y Lucas 2006, Gougeon y Leckie 2006) trabajaron en áreas con bosque mixto. Muy pocos artículos se centran en bosques de hoja caduca, por ejemplo, Walsworth y King (1999a, 1999b) en álamos, Korpela et al. (2006) en abedules y Ke y Quackenbush (2007) en arces. Muchos menos estudios se han centrado en zonas templadas, destacando Neto y Miranda (2009) y Falk et al. (2014) que realizaron conteo de cítricos con imágenes Quickbird y fotografía aérea, respectivamente, Abbasi y Riyahi Bakhtyari (2012) que usaron banda pancromática de Quickbird para delineación de copas de *Quercus persica*, Martínez de Salazar et al (s.f.) que realizaron conteo de olivos y Castillejo et al. (2010) que estimaron la fracción de cabida cubierta en ecosistemas de dehesa. En zonas tropicales son también escasos los trabajos (Zhou et al. 2010). Hay dos razones principales por las que la mayoría de la investigación se ha centrado en bosques de coníferas. En primer lugar, se realizaron muchos estudios en regiones de mayor latitud norte, donde los bosques de coníferas son los recursos forestales dominantes. Por ejemplo, Gougeon y Leckie (2003)

y Pouliot et al. (2002, 2005) consideraron bosques canadienses, mientras que Brandtberg (1998, 1999a, 1999b) estudió bosques suecos. En segundo lugar, la mayoría de los métodos se han basado en la suposición de que las copas de los árboles tienen una forma cónica de manera que aparecen con forma circular en imágenes bidimensionales, y siendo la zona alta de la copa la que presenta mayores niveles de reflectancia dentro de la copa. Las características de este patrón de reflectancia se utilizaron sustancialmente en la detección de árboles y métodos de delineación. Las copas de forma irregular que se observan comúnmente en especies de hoja caduca hacen que el patrón de reflectancia sea más difícil de reconocer. Por ejemplo, los arces maduros pueden tener un diámetro de corona mayor de 12 m (Lassoie et al., 1996) y la forma no cónica puede causar una variación significativa del brillo dentro de la copa en imágenes de alta resolución espacial. Tal variación puede conducir a errores de comisión donde múltiples copas de árboles son identificadas erróneamente como una misma copa (Ke y Quackenbush 2007). Warner et al. (1999) introdujeron el análisis de textura para mejorar la delimitación de las copas de árboles de hoja caduca, pero no aportaron resultados cuantitativos. Por su parte, Ke y Quackenbush (2008) obtuvieron valores de precisión en torno al 30-40% de precisión al aplicar segmentación *watershed* a un bosque de arces.

Independientemente del algoritmo utilizado, distintos estudios señalan que la exactitud en la detección y delineación de la copa de los árboles era mayor para los rodales puros, de edad homogénea y uniformemente espaciados (Pouliot et al., 2005, Gougeon y Leckie 2006). Esto puede atribuirse al hecho de que es más probable que los árboles con edad y especie similares tengan altura uniforme, así como el tamaño y la forma de la copa, dando lugar a un patrón de reflectancia similar en la misma imagen, lo cual es una característica favorable para cualquier técnica de análisis de imagen. Sin embargo, estas condiciones forestales sólo pueden ocurrir en las plantaciones forestales manejadas. No se puede esperar el mismo resultado para los bosques cultivados naturalmente.

3.1.3 Preprocesamiento y mejora de la imagen

El objetivo del preprocesamiento en el contexto de la detección y delimitación de la copa de árboles es similar a la mayoría de las aplicaciones teledetección. Esto incluye la eliminación del ruido de imagen debido a la adquisición de datos y la mejora de la distinción entre los objetos a detectar (es decir, las copas de árbol) y el fondo (es decir, el área sombreada). Otro objetivo del preprocesamiento es enmascarar áreas contaminadas o irrelevantes (por ejemplo, nubes y no bosques, respectivamente).

Para los datos de imágenes multiespectrales, el preprocesamiento también implica seleccionar la banda de imagen más apropiada (Gougeon y Leckie 2003). La banda NIR se utilizó con frecuencia para la detección y delineación de la copa de los árboles debido a su sensibilidad a las diferencias de vegetación. Quackenbush et al. (2000) utilizaron el promedio de las bandas de NIR y del rojo, así como la raíz cuadrada de la suma de estas dos bandas, pero encontraron poca diferencia en los resultados en comparación con el uso de la banda NIR solamente. Para aplicaciones que utilizan imágenes de color natural, se seleccionó generalmente la banda del verde (por ejemplo, Pitkänen 2001, Gougeon y Leckie 2003). Para imágenes de mayor resolución espectral, se utilizaron técnicas de transformación de imagen para seleccionar la banda más relevante. Wang et al. (2004) aplicó un análisis de componentes principales a los datos CASI de ocho bandas y analizó la imagen de la primera componente, que contiene la mayor variación. Bunting y Lucas (2006) encontraron que el uso del ratio entre la banda roja más al borde y la banda roja, o entre diferentes bandas en el borde rojo, permitió una mejor detección de la copa de árboles y definición de los límites. Pouliot et al. (2002) señalaron que la diferencia absoluta entre el NIR y las bandas rojas ayudó a reducir la respuesta espectral de los píxeles

del suelo y de los píxeles que no tenían apex en imágenes de muy alta resolución (5 cm). Por su parte, Daliakopoulos et al. (2009) obtuvieron mejoras en el conteo mediante una combinación de la banda roja y el NDVI con un método de detección basado en el Laplaciano de Gauss.

La topografía puede causar problemas al trabajar con la delineación de la copa de los árboles. Las imágenes adquiridas en diferentes áreas topográficas necesitan ortorrectificación para que las posiciones de las copas de los árboles sean comparables con las mediciones en el suelo (Uuttera et al., 1998). Al igual que con tales efectos topográficos, las imágenes de teledetección también están influenciadas por efectos radiométricos. La radiación medida por el mismo sensor sobre el mismo objeto varía debido a cambios en factores tales como iluminación de escena, condición atmosférica y ángulos de visión. El impacto de estos factores depende de la plataforma. Por ejemplo, la geometría de la vista está más sujeta a cambios en las imágenes aéreas, mientras que los efectos atmosféricos causan un impacto significativo en la mayoría de las imágenes de satélite. Leckie et al. (1995) desarrollaron un método empírico para corregir el efecto de la reflectancia bidireccional modelando la variación de radiancia a lo largo de las imágenes. El método fue ampliamente utilizado en la investigación de Gougeon y Leckie (por ejemplo, Leckie et al., 2003a, 2004, Gougeon y Leckie 2006). Cuando se trataba de terreno plano o áreas de estudio pequeñas, las correcciones topográficas se ignoraban.

El suavizado de imágenes se ha aplicado a menudo después de la corrección geométrica y radiométrica con el fin de aliviar el ruido de la imagen causado por el sistema de sensores. Gougeon (1995a, 1995b) utilizaron un filtro de 3 x 3 de media para suavizar las imágenes MEIS. Pouliot et al. (2002, 2005) y Wang et al. (2004) aplicaron un filtro de suavizado gaussiano, que conserva características de borde mejor que un filtro medio. Para imágenes de muy alta resolución espacial, el suavizado de imágenes también puede reducir el ruido causado por ramas pequeñas y sus sombras dentro de una copa.

Brandtberg (1998, 1999a) usó núcleos gaussianos isotrópicos para reducir los detalles innecesarios y preservar las características de la copa, utilizando kernels isotrópicos de diferentes tamaños para copas de árboles de diferentes tamaños. Para resoluciones más groseras, el suavizado de la imagen puede tener un impacto negativo al difuminar el borde entre el área de la corona y el fondo.

Numerosos estudios han encontrado que hay una influencia directa del tamaño de los píxeles sobre el proceso de detección y delineación. Por lo tanto, muchos estudios remuestrean las imágenes a un tamaño de píxel apropiado. Por ejemplo, Gougeon y Leckie (2006) encontraron que la resolución de 1 m de GSD en imágenes IKONOS pancromáticas era demasiado grosera para detectar el regenerado y remuestrearon las imágenes en píxeles de 50 cm utilizando un algoritmo de convolución cúbica. El algoritmo de convolución cúbica cambió las intensidades de la imagen y mejoró la diferencia entre las copas de los árboles y las sombras. Para el trabajo presentado por Gougeon y Leckie (2006), el valor de intensidad en sí mismo no era la característica de interés de la imagen, sino las diferencias de intensidad. En otros estudios, las imágenes de resolución espacial muy alta se remuestrearon a mayores tamaños de píxeles para facilitar el procesamiento. Por ejemplo, Brandtberg (1998, 1999a) remuestreó imágenes con 7,5 cm de GSD en píxeles de 10 cm utilizando interpolación bilineal.

En todos los estudios evaluados, la extracción de áreas forestales de la imagen se realizó antes de los procedimientos de detección y delimitación, de modo que los algoritmos sólo se aplicaron en las regiones cubiertas por copas y su área sombreada. Además, las áreas no forestales, como el suelo, el arbusto o el material herbáceo, frecuentemente se representan como píxeles brillantes y por lo tanto

pueden ser falsamente detectadas como coronas de árboles. Por lo tanto, generar una máscara sobre el objeto de interés siempre es un paso crítico de preprocesamiento. La forma más común de separar áreas forestales y no forestales es con el umbral en una sola banda (por ejemplo, la banda NIR) o en una imagen transformada en la intensidad de saturación. Sin embargo, este enfoque frecuentemente no define los tipos de vegetación no forestales. Como alternativa, se ha utilizado la clasificación de imágenes utilizando los algoritmos de máxima verosimilitud supervisada (Pouliot y King 2005) o no supervisados (Pouliot et al., 2005). Ke y Quackenbush (2007) extrajeron áreas forestales en imágenes multiespectrales de QuickBird con alta precisión usando una clasificación orientada a objeto basada en reglas.

3.1.4 Algoritmos de detección y delineación de árboles

Durante las últimas dos décadas, se ha desarrollado una amplia variedad de algoritmos de detección y delineación de copas de árboles. Las características de un método particular pueden afectar en gran medida los resultados de la detección y delineación de la copa de los árboles y, por lo tanto, para una aplicación específica, pueden afectar a descriptores tales como el recuento de árboles, densidad forestal y composición de especies. Incluso en el mismo entorno, diferentes enfoques pueden dar resultados diferentes. Por lo tanto, la selección de un algoritmo apropiado tiene una importancia considerable.

Los algoritmos pueden considerarse de dos categorías según su propósito: algoritmos de detección de árboles y algoritmos de delineación de copas. Gougeon y Leckie (2003) también reconocen que algunos estudios proporcionan información de la dimensión de la copa en lugar de su contorno y, por lo tanto, consideran la combinación de detección de árboles y parametrización de la dimensión de la copa como una categoría separada. Sin embargo, en la literatura revisada, estas categorías suelen estar entrelazadas. Aunque hay algunos estudios que implican sólo la detección de árboles (por ejemplo, Pouliot y King 2005), muchos estudios combinaron la detección de árboles y la delineación de copas en los que la detección era necesaria antes de la delineación de la copa (por ejemplo, Sheng et al., 2001, Culvenor 2002, Wang et al. 2004). Algunos incluso consideran que la detección es equivalente a la delineación de árboles, es decir, se detectaron árboles individuales una vez que se delinearon las coronas (por ejemplo, Gougeon 1995a). Aquí, definimos la detección de árboles como aquellos procesos que tratan de encontrar las copas de los árboles o de localizar árboles, y la delineación como la definición automática de los contornos del árbol-copa. Desde este punto de vista, la detección de árboles puede servir no sólo como una meta en sí misma, sino también como un paso de preprocesamiento necesario antes de la delineación del árbol o la determinación de su dimensión.

La visión tridimensional de imágenes de alta resolución espacial sobre regiones boscosas de densidad moderada o alta se describe a menudo como si se tratara de una estructura espacial montañosa. Para árboles con estructura cónica, los picos brillantes de la imagen corresponden a las partes altas de las copas de los árboles debido al mayor nivel de iluminación solar. La reflectancia disminuye hacia los límites de la copa, y los píxeles más oscuros que rodean el área brillante corresponden al área sombreada de las copas de árbol vecinas o del efecto de reflectancia bidireccional. Por lo tanto, el problema de detectar copas de árbol se convierte en el problema de encontrar picos brillantes en la imagen, es decir, encontrar el píxel con el máximo valor de brillo entre los píxeles circundantes. Por su parte, el problema de delimitar los límites de la copa se convierte en el problema de delinear los valles oscuros. Los métodos de detección de árboles que se encuentran en la

literatura generalmente se pueden agrupar en cuatro categorías: filtrado máximo local (*local maximum filter*), binarización de imágenes (*image binarization*), análisis de escala (*scale analysis*) y concordancia de plantillas (*matching template*). El primero de estos métodos es el más frecuentemente utilizado. Los métodos de delineación de árboles se agrupan ampliamente en tres categorías: el seguimiento del valle (*valley following*), el crecimiento de la región (*region growing*) y la segmentación de la cuenca (*watershed segmentation*), siendo el primero de estos el más utilizado.

3.1.5 Métodos de evaluación de la exactitud y la precisión

Al igual que existe variedad en cuanto a los algoritmos de detección y delineación de árboles, también es amplia la gama de métodos de evaluación aplicados (Pouliot et al., 2005). Los métodos de evaluación han diferido en cuanto a las fuentes de datos de referencia, así como en los procedimientos seguidos. La evaluación de los resultados en la detección de árboles se ha centrado principalmente en determinar la proporción de árboles detectados correctamente, mientras que la evaluación de la delineación de árboles y copas entra a determinar cómo de bien los árboles delimitados representan las copas de los árboles reales. En esta sección, discutiremos primero métodos de adquisición de datos de referencia, y posteriormente discutiremos métodos de evaluación de exactitud tanto para la detección de árboles como para la delineación de copas.

3.1.5.1 Datos de referencia

La evaluación cuantitativa de la detección y delimitación automatizada de árboles implica comparar la localización estimada de los árboles o los límites de la corona con los datos de referencia. Dos fuentes de datos de referencia son las más citadas en la literatura: interpretación visual de las imágenes utilizadas en el análisis y recolección de datos en el campo. En la mayoría de los estudios, los datos de referencia se recogieron mediante la interpretación visual de las imágenes de entrada debido a la viabilidad de tal enfoque. En la investigación de Gougeon (1995a), los datos de referencia fueron obtenidos por dos intérpretes que cuentan visualmente árboles en una pantalla de ordenador que muestra la imagen. El estudio encontró que un intérprete principiante subestimó los recuentos de árboles en comparación con los datos de campo, mientras que un intérprete con más experiencia estimó los recuentos de árboles más cercanos a los recuentos reales de árboles. Pollock (1999), Brandtberg (1998, 1999a), Larsen (1999) y Erikson (2003) también utilizaron la detección visual de las copas de los árboles como datos de referencia. Wang et al. (2004) utilizaron datos de referencia adquiridos por tres intérpretes que delimitaban visualmente las coronas individuales de los árboles en las imágenes de entrada, con el promedio de los tres recuentos de árboles utilizado como recuento de árboles de referencia. Las copas de árbol estimadas automáticamente se superpusieron sobre las copas obtenidas visualmente para evaluar la precisión. Sin embargo, Wang et al. (2004) encontraron que la interpretación visual tenía limitaciones en la detección de árboles pequeños y los árboles que se agrupaban en una forma circular. Lamar et al. (2005) también encontraron que para las imágenes a gran escala era difícil delinear manualmente las copas de árboles de forma irregular debido a la influencia del fondo. Por tanto, aplicaron la segmentación espectral a la imagen original para separar la vegetación de otros tipos de cobertura de suelo, y se realizó una delimitación manual en la imagen segmentada.

La recogida de datos de referencia mediante mediciones de campo se ha considerado menos práctica debido al coste que supone, pero generalmente proporciona información más exacta y completa en comparación con la interpretación visual. La información típica recogida durante la

investigación de terreno incluye la ubicación del árbol y la dimensión de la copa en las direcciones N-S y E-W (Pitkänen 2001, Bunting y Lucas 2006). Leckie et al. (2003b) registraron la ubicación de los árboles, así como la especie, altura, diámetro a la altura del pecho y diámetro de la copa en dos direcciones para cada árbol en la parcela de campo. Marcaron manualmente los contornos de los árboles y luego transfirieron los contornos a la imagen como polígonos. Leckie et al. (2003b) usaron estos polígonos como referencia de terreno para comparación con las coronas de árboles automáticamente delimitadas.

3.1.5.2 Evaluación de la exactitud y precisión

Para la detección de árboles individuales, los métodos de evaluación de la exactitud incluyen tanto la evaluación a nivel de parcela (*plot-level*) como la evaluación individual de los árboles (Lamar et al., 2005). La exactitud a nivel de parcela refleja la proporción agregada de árboles detectados correctamente. Esto se calcula comparando el número total de árboles detectados con el recuento de referencia, y se ha utilizado ampliamente (Gougeon 1995a, Gougeon y Leckie 1999, Wang et al., 2004, Gougeon y Leckie 2006). Sin embargo, este método no proporciona información acerca de la exactitud en la localización de los árboles y puede ser engañosa debido a errores de comisión y omisión difuminados por la agregación (Lamar et al., 2005).

La evaluación detallada de la exactitud examina la correspondencia entre los árboles detectados y las copas de los árboles de los datos de referencia. Pouliot et al. (2002) y Pouliot y King (2005) aplicaron un Índice (AI) para representar la exactitud global, donde o y c son el número de errores de omisión y comisión, respectivamente, y n es el recuento de árboles de referencia. Los errores de comisión ocurren cuando una copa de referencia es detectada como múltiples copas, o donde copas de árbol fueron detectadas erróneamente. Los errores de omisión ocurren cuando una copa de referencia no es detectada.

$$AI\ \% = (n-(o+c))/n \times 100$$

Algunos investigadores (Gougeon 1995a, Brandtberg 1998) examinaron la evaluación de exactitud con un mayor nivel de especificidad, aportando las relaciones entre el número de copas detectado y el real en una matriz de confusión. Por ejemplo, 1:0 significaba que se detectó un árbol donde no había árbol de referencia, 1:1 significaba correspondencia uno a uno y 1:2 significaba que dos árboles de referencia se detectaron como un árbol. Si los datos de referencia proporcionaban la posición de la copa, también se podía evaluar el error de distancia en la posición detectada de la copa (Larsen 1999). Hay autores como Pitkänen (2001) y Pouliot et al. (2005) que consideraron una copa detectada dentro de cierta distancia de la posición de referencia como una detección precisa.

Para la delineación de la copa arbórea, la evaluación completa supone la evaluación de la exactitud de detección, y el grado con el que los árboles delimitados coinciden con las copas de referencia. Pouliot et al. (2002) analizaron la exactitud de delineación comparando el diámetro de la copa del árbol delineado con el diámetro de la copa medido en el suelo en una zona forestal bien espaciada. Sin embargo, esta comparación no es siempre fiable si la forma del árbol-copa delineada es triangular, debido al desplazamiento del relieve en una imagen con un gran ángulo de visión, o si una copa de árbol fue parcialmente oscurecida desde la visión del sensor (Bunting y Lucas 2006). Lamar et al. (2005) introdujeron la exactitud del usuario y la exactitud del productor. Con la correspondencia 1:1 definida cuando la superficie de solape entre la copa de referencia y la copa delineada automáticamente es mayor del 50%, la exactitud del usuario hace referencia al número total de coronas delineadas y la exactitud del productor al número total de coronas de referencia. Wang et al.

(2004) realizaron la evaluación de exactitud basándose en píxeles, comparando el número de píxeles que contenían a los árboles (o no árboles) delineados con el número real de píxeles de los árboles (o no árboles) de referencia. Sin embargo, esta evaluación agregada no podía contemplar errores de comisión y omisión.

3.1.6 Reflexiones finales

En las dos últimas décadas, se han desarrollado varios algoritmos semiautomáticos y totalmente automáticos para la detección de árboles individuales y la delimitación de coronas. Sin embargo, incluso si un método es el mejor para una aplicación específica, puede no ser óptimo para otras situaciones. Por ejemplo, muchos enfoques que funcionaron bien para un tipo de árbol han demostrado una menor precisión para árboles de otro tipo, particularmente con alta variación en cuanto al espaciamiento, edad o tamaño de los árboles, o cuando las copas tienen un alto grado de superposición o solape (Larsen et al. 2011, Zhen et al. 2015). Es difícil evaluar la exactitud de los resultados porque no hay un procedimiento estandarizado de evaluación de la exactitud (Ke y Quackenbush, 2011), lo que hace más difícil comparar algoritmos a menos que múltiples enfoques se prueben en una sola área de estudio utilizando la misma métrica de exactitud (Kaartinen et al., 2012). Sin embargo, los investigadores han tenido generalmente mayores éxitos en la implementación de algoritmos en zonas de árboles con espaciamiento, edad y tamaño uniformes (Ke y Quackenbush, 2011).

Aunque se han conseguido logros significativos en estudios anteriores, la investigación aún se está desarrollando. Una limitación en la mejora de la precisión y aplicabilidad de los algoritmos es que la mayoría de los algoritmos no hacen uso de la estructura de la corona representada por la covarianza espacial de los valores de píxeles (ya sea brillo o altura) (Clark et al., 2005). Además, la mayoría de los algoritmos se centran en las características de los árboles individuales e ignoran los procesos ecológicos como la competencia entre los árboles. Los estudios se beneficiarían de la integración de las técnicas tradicionales y los procesos ecológicos (por ejemplo, la competencia de los árboles) y otros métodos que manejan el solapamiento de copas (Zhen et al. 2015, Lu et al., 2014). Otra limitación es que pocos enfoques aprovechan al máximo la información contenida en los datos de sensores remotos, por ejemplo, utilizando sólo una banda de imágenes multi-espectrales (Horváth et al., 2009) o sólo la altura de la copa modelo derivada de datos LiDAR (Lin et al., 2011). Durante la preparación o el procesamiento de datos se descartan o se descuidan cantidades importantes de información. La integración de datos multiespectrales y datos LiDAR se utiliza comúnmente para mejorar la clasificación de especies arbóreas (Heinzel y Koch, 2012) y la fusión de datos pasivos y activos de detección remota puede reducir errores de comisión y omisión en los resultados (Zhen et al., 2014). Además de aprovechar al máximo los múltiples tipos de datos, los estudios también pueden beneficiarse de la aplicación de datos procedentes de plataformas novedosas, tales como vehículos aéreos no tripulados (VAN) y la exploración por láser basada en telefonía móvil que proporcionan ventajas espaciales y temporales (Díaz-Varela et al., 2015; Holopainen et al., 2013; Wu et al., 2013).

El futuro de la delimitación y detección de copas de árboles incluye el desarrollo de algoritmos adecuados para diferentes tipos de imágenes y diferentes condiciones agroforestales. Los algoritmos pueden combinar las capacidades de los algoritmos existentes, aprovechando el patrón de reflectancia de la copa de árbol, así como las características de tamaño, forma o color de la copa, y utilizando conocimiento experto del bosque para delinear coronas de árboles de diferentes tamaños y densidades.

El uso de imágenes estereoscópicas con muy alta resolución también ha recibido bastante atención en los últimos años. El modelo digital del terreno producido por dichas imágenes tiene un gran potencial para obtener información a nivel de árbol individual (Hirschmugl et al., 2007). La investigación futura y presente también incluye la obtención exacta de parámetros tales como estimaciones de volumen de árboles, composición de especies e información fitosanitaria del árbol individual, que permitan mejorar el inventario y el análisis automático agroforestal.

4 REFERENCIAS BIBLIOGRÁFICAS

Abbasi M. y Riyahi Bakhtyari H.R. 2012. Extraction of forest stands parameters from aster data in open forest. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XXXIX-B4, 2012 XXII ISPRS Congress, 25 August – 01 September 2012, Melbourne, Australia

Ahmed, M. N., Yamany S.M.; Mohamed N.; Farag A.A.; Moriarty T. 2002, A modified fuzzy c-means algorithm for bias field estimation and segmentation of MRI data. IEEE transactions on medical imaging 21.3 193-199.

Alemdag, I.S. Estimating oven–dry mass of trembling aspen and white birch using measurements from aerial photographs. Can. J. Remote Sens. 1986, 16, 163–165.

Anger, C.D., Mah, S. and Babey, S.K., 1994, Technological enhancements to the Compact Airborne Spectrographic Imager (CASI). En Proceedings of the 1st International Airborne Remote Sensing Conference and Exhibition, 11–15 September, Strasbourg, France (Ann Arbor, MI: ERIM International), pp. 205–213.

Barbu, A. 2009. Learning real-time MRF inference for image denoising. Computer Vision and Pattern Recognition, CVPR 2009. IEEE Conference on. IEEE, 2009.

Besag J., Dirty Pictures, Royal Statistical Society B, 1986.

Brandtberg, T., 1998, Automated delineation of individual tree crowns in high spatial resolution aerial images by multiple-scale analysis. Machine Vision and Applications, 11, pp. 64–73.

Brandtberg, T., 1999a, An algorithm for delineation of individual tree crown in high spatial resolution aerial imagers using curved edge segments at multiple scales. En D.A. Hill and D.G. Leckie (Eds), Proceedings of the International Forum on Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry, 10–12 February, Victoria, BC, Canada (Victoria, Canada: Canadian Forest Service, Pacific Forestry Centre), pp. 41–54.

Brandtberg, T., 1999b, Automatic individual tree based analysis of high spatial resolution aerial images on naturally regenerated boreal forests. Canadian Journal of Forest Research, 29, pp. 1464–1478.

Brandtberg, T.,Warner, T., Landenberg, R. y MCgraw, J., 2003, Detection and analysis of individual leaf-off tree crowns in small footprint, high sampling density LiDAR data from the eastern deciduous forest in North America. Remote Sensing of Environment, 85, pp. 290–303.

Bunting, P. y Lucas, R.M., 2006, The delineation of tree crowns in Australian mixed species forests using hyperspectral Compact Airborne Spectrographic Imager (CASI) data. Remote Sensing of Environment, 101, pp. 230–248.

Castillejo-González, I.L., Medina Guerrero, J.M., García-Ferrer Porras, A., Mesas-Carrascosa, F.J. y Sánchez de la Orden, M. 2010, Utilización de imágenes de satélite de alta resolución espacial en la determinación de la fracción de cabida cubierta en sistemas adehesados. En: Ojeda, J., Pita, M.F. y Vallejo, I. (Eds.), Tecnologías de la Información Geográfica: La Información Geográfica al servicio de los ciudadanos. Secretariado de Publicaciones de la Universidad de Sevilla. Sevilla. Pp. 62-71.

Chen, Q., Baldocchi, D., Gong, P. and Kelly, M., 2006, Isolating individual trees in a Savanna woodland using small footprint LiDAR data. Photogrammetric Engineering and Remote Sensing, 72, pp. 923–932.

Clark, M.L.; Roberts, D.A.; Clark, D.B. 2005, Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scales. Remote Sens. Environ. 96, 375–398.

Cross G. y Jain A.K, 1983, Markov Random Fields texture Models, IEEE Trans. on PAMI, pp. 25-39.

Culvenor, D.S., 2002, TIDA: an algorithm for the delineation of tree crowns in high spatial resolution remotely sensed imagery. Computers and Geosciences, 28, pp. 33–44.

Daliakopoulos, I.N., Grillakis, E.G., Koutroulis, A.G., Tsanis, I.K. 2009, Tree crown detection on multispectral VHR satellite imagery Photogrammetric Engineering and Remote Sensing, 75 (10), pp. 1201-1211.

Davis, L. S. 1975, A survey of edge detection techniques. Computer graphics and image processing 4.3 248-270.

Demir, N. 2017, Using UAVs for detection of trees from digital surface models, Journal of Forestry Research, pp. 1-9. Artículo en prensa.

Díaz-Varela, R.A.; Rosa, R.; León, L.; Zarco-Tejada, J. 2015, High-resolution airborne UAV imagery to assess Olive tree crown parameters using 3D photo reconstruction: Application in breeding trials. Remote Sens. 7, 4213–4232.

Erikson, M., 2003, Segmentation of individual tree crowns in colour aerial photographs using region growing supported by fuzzy rules. Canadian Journal of Forest Research, 33, pp. 1557–1563.

Falk, D. y Campos A.N. 2014. Algoritmo semiautomático para el conteo de árboles en plantaciones forestales mediante el uso de imágenes aéreas. 6º Congreso Argentino de Agroinformática. 43 JAIIO – CAI 2014, 186-194.

Fransson, J.E.S., Walter, F. y Ulander, L.M.H., 2000. Estimation of forest parameters using CARABAS-II VHF SAR data. IEEE Transaction of Geoscience and Remote Sensing, 38, pp. 720–727.

Geman D. y Geman S, 1984, Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images, IEEE Trans. on PAMI, pp. 721-741.

Gobakken, T. and Næsset, E., 2005, Weibull and percentile models for LiDAR-based estimation of basal area distribution. Scandinavian Journal of Forest Research, 20, pp. 490–502.

Gomes, M.F., Maillard, P. 2014, Integration of Marked Point Processes and Template Matching for the identification of individual tree crowns in an urban and a wooded savanna environment in Brazil Proceedings of SPIE - The International Society for Optical Engineering, 9245, art. no. 92450X

Gonzalez, P., Asner, G.P., Battles, J.J., Lefsky, M.A., Waring, K.M., Palace, M. 2010, Forest carbon densities and uncertainties from Lidar, QuickBird, and field measurements in California Remote Sensing of Environment, 114 (7), pp. 1561-1575.

Gougeon, F.A., 1995a, A crown-following approach to the automatic delineation of individual tree crowns in high spatial resolution aerial images. Canadian Journal of Remote Sensing, 21, pp. 274–284.

Gougeon, F.A. y Leckie, D.G., 1999, Forest regeneration: individual tree crown detection techniques for density and stocking assessment. In D.A. Hill and D.G. Leckie (Eds.), Proceedings of the International Forum on Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry, 10–12 February, Victoria, BC, Canada, (Victoria, Canada: Canadian Forest Service, Pacific Forestry Centre), pp. 169–178.

Gougeon, F.A. y Leckie, D.G., 2003, Forest information extraction from high spatial resolution images using an individual tree crown approach. Information Report BC–X–396, Natural Resources Canada, Canadian Forest Service, Pacific Forestry Centre (Victoria, Canada: Pacific Forestry Centre).

Gougeon, F.A. y Leckie, D.G., 2006, The individual tree crown approach applied to IKONOS images of a coniferous plantation area. Photogrammetric Engineering and Remote Sensing, 72, pp. 1287–1297.

Haralick, Robert M., y Linda G. Shapiro. 1985, Image segmentation techniques. Computer vision, graphics, and image processing 29.1 100-132.

Hirschmugl, M., Ofner, M., Raggan, J. y Schardt, M., 2007. Single tree detection in very high resolution remote sensing data. Remote Sensing of Environment, 110, pp. 533–544.

Holmgren, J. y Persson, A., 2004, Identifying species of individual trees using airborne laser scanner. Remote Sensing of Environment, 90, pp. 415–423.

Holopainen, M.; Kankare, V.; Vastaranta, M.; Liang, X.; Lin, Y.; Vaaja, M.; Yu, X.; Hyyppä, J.; Hyyppä, H.; Kaartinen, H.; et al. 2013, Tree mapping using airborne, terrestrial and mobile laser scanning–A case study in a heterogeneous urban forest. Urban For. Urban Green. 12, 546–553.

Horváth, P.; Jermyn, I.H.; Kato, Z.; Zerubia, J. 2009, A higher-order active contour model of a “gas of circles” and its application to tree crown extraction. Pattern Recogn. 42, 699–709.

Hung, C., Bryson, M., Sukkarieh, S. 2012, Multi-class predictive template for tree crown detection, ISPRS Journal of Photogrammetry and Remote Sensing, 68 (1), pp. 170-183.

Hyyppä, J.; Hyyppä, H.; Leckie, D.; Gougeon, F.; Yu, X.; Maltamo, M. Review of methods of small-footprint airborne laser scanning for extracting forest inventory data in boreal forests. Int. J. Remote Sens. 2008, 29, 1339–1366.

Kaartinen, H.; Hyyppä, J.; Yu, X.; Vastaranta, M.; Hyyppä, H. 2012, An international comparison of individual tree detection and extraction using airborne laser scanning. Remote Sens. 4, 950–974.

Kangas, A. y Maltamo, M., 2006, Forest Inventory: Methodology and Applications (Managing Forest Ecosystem) (The Netherlands: Springer).

Kattenborn, T., Sperlich, M., Bataua, K., Koch, B. 2014, Automatic single palm tree detection in plantations using UAV-based photogrammetric point clouds (2014) International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, 40 (3), pp. 139-144

Kay, S., Leo, O. y Peedell, S., 1998, Computer-assisted recognition of olive trees in digital imagery, Space Applications Institute, JRC of the European Commission. Available online at: http://agrifish.jrc.it/Documents/Olivine/COMPUTER-ASSISTED%20 RECOGNITION%20OT%20OT.htm

Ke, Y. y Quackenbush, L.J., 2007, Forest species classification and tree crown delineation using QuickBird imagery. In Proceedings of the 2007 ASPRS Annual Conference, 7–11 May, Tampa, FL (Bethesda, MD: American Society for Photogrammetry and Remote Sensing).

Ke, Y. y Quackenbush, L.J., 2008, Comparison of individual tree crown detection and delineation methods, In Proceedings of the 2008 ASPRS Annual Conference, 28 April–2 May, Portland, OR (Bethesda, MD: American Society for Photogrammetry and Remote Sensing).

Ke, Y. y Quackenbush, L.J. 2011. A review of methods for automatic individual tree crown detection and delineation from passive remote sensing. Int. J. Remote Sens., 32, 4725–4747.

Kim, J., Muller, J.-P. 2011, Tree and building detection in dense urban environments using automated processing of IKONOS image and LiDAR data, International Journal of Remote Sensing, 32 (8), pp. 2245-2273.

Korpela, I.S., Anttila, P. y Pitkänen, J., 2006, The performance of a local maxima method for detecting individual tree tops in aerial photographs. International Journal of Remote Sensing, 27, pp. 1159–1175.

Lamar, W.R., Mcgraw, J.B. y Warner, T.A., 2005, Multitemporal censusing of a population of eastern hemlock (Tsuga canadensis L.) from remotely sensed imagery using an automated segmentation and reconciliation procedure. Remote Sensing of Environment, 94, pp. 133–143.

Larsen, M., 1997, Crown modeling to find tree top positions in aerial photographs. In Proceedings of the 3rd International Airborne Remote Sensing Conference and Exhibition, 7–10 July, Copenhagen, Denmark (Ann Arbor, MI: ERIM International), pp. 428–435.

Larsen, M., 1999, Finding an optimal match window for spruce top detection based on an optical tree model. In D.A. Hill and D.G. Leckie (Eds), Proceedings of the International Forum on Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry, 10–12 February, Victoria, BC, Canada (Victoria, Canada: Pacific Forestry Centre, Canadian Forest Service), pp. 55–63.

Larsen, M.; Eriksson, M.; Descombes, X.; Perrin, G.; Brandtberg, T.; Gougeon, F.A. 2011, Comparison of six individual tree crown detection algorithms evaluated under varying forest conditions. Int. J. Remote Sens. 32, 5827–5852.

Lassoie, J.P., Luzadis, V.A. y Grover, D.W., 1996, Forest Trees of the Northeast (Ithaca, NY: Cornell Cooperative Extension).

Leckie, D.G., Gougeon, F.A., Hill, D., QUinn, R., Armstrong, L. y Shreenan, R., 2003a, Combined high density LiDAR and multispectral imagery for individual tree crown analysis. Canadian Journal of Remote Sensing, 29, pp. 633–649.

Leckie, D.G., Gougeon, F.A., Walsworth, N. y Paradine, D., 2003b, Stand delineation and composition estimation using semi-automated individual tree crown analysis. Remote Sensing of Environment, 85, pp. 355–369.

Lehmann, Thomas Martin, Claudia Gonner, y Klaus Spitzer. 1999, Survey: Interpolation methods in medical image processing. IEEE transactions on medical imaging 18.11 1049-1075.

Lin, C.; Thomson, G.; Lo, C.; Yang, M. 2011, A multi-level morphological active contour algorithm for delineating tree crowns in mountainous forest. Photogramm. Eng. Remote. Sens. 77, 241–249.

Lu, D., y Weng Q. 2007, A survey of image classification methods and techniques for improving classification performance. International journal of Remote sensing 28.5 823-870.

Lu, X.; Guo, Q.; Li, W.; Flanagan, J. 2014, A bottom-up approach to segment individual deciduous trees using leaf-off LiDAR point cloud data. ISPRS J. Photogramm. 94, 1–12.

Malek, S., Bazi, Y., Alajlan, N., AlHichri, H., Melgani, F. 2014, Efficient framework for palm tree detection in UAV images, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 7 (12), pp. 4692-4703.

Maltamo, M., Eerikä Inen, K., Packalen, P. y Hyyppä, J., 2006, Estimation of stem volume using laser scanning-based canopy height metrics. Forestry, 79, pp. 217–229.

Martínez de Salazar, E., Fernández J.A., Jaramillo, M.A., Morillo J., y Rodríguez M.C. Análisis de plantaciones arbóreas con programas de tratamiento de imagen. http://intranet.ceautomatica.es/old/actividades/jornadas/XXI/documentos/ja00_052/JA00_052.pdf accedido en Julio 2017.

Marr D, 1982, Vision - A Computational Investigation into the Human Representation and Processing of Visual Information.

Mohan, M., Silva, C.A., Klauberg, C., Jat, P., Catts, G., Cardil, A., Hudak, A.T., Dia, M. 2017, Individual tree detection from unmanned aerial vehicle (UAV) derived canopy height model in an open canopy mixed conifer forest, Forests, 8 (9), 340

Motwani, M C., Gadiya, M.C., Motwani, R.C. y Harris, F.C., 2004. Survey of image denoising techniques. Proceedings of GSPX.

Næsset, E., 2002, Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. Remote Sensing of Environment, 80, pp. 88–99.

Neto, J. C. y Miranda J.I. 2009. Orange tree counting and canopy diameter estimation with genetic algorithm. ISHS Acta Horticulturae 824: International Symposium on Application of Precision Agriculture for Fruits and Vegetables.

Nevalainen, O., Honkavaara, E., Tuominen, S., Viljanen, N., Hakala, T., Yu, X., Hyyppä, J., Saari, H., Pölönen, I., Imai, N.N., Tommaselli, A.M.G., 2017, Individual tree detection and classification with UAV-Based photogrammetric point clouds and hyperspectral imaging, Remote Sensing, 9 (3), 185.

Pal, N. R., y S. K. Pal. A review on image segmentation techniques. Pattern recognition 26.9 (1993): 1277-1294.

Pinz, A., 1991, A computer vision system for recognition of trees in aerial photographs. In Proceedings of the International Association of Pattern Recognition Workshop, 14–15 June, College Park, MD (Washington, DC: NASA), pp. 111–124.

Pinz, A., 1999a, Australian Forest Inventory System. In D.A. Hill and D.G. Leckie (Eds), Proceedings of the International Forum on Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry, 10–12 February, Victoria, BC, Canada (Victoria, Canada: Pacific Forestry Centre, Canadian Forest Service), pp. 375–381.

Pinz, A., 1999b, Tree isolation and species classification. In D.A. Hill and D.G. Leckie (Eds), Proceedings of the International Forum on Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry, 10–12 February, Victoria, BC, Canada (Victoria, Canada: Pacific Forestry Centre, Canadian Forest Service), pp. 127–139.

Pitkänen, J., 2001, Individual tree detection in digital aerial images by combining locally adaptive binarization and local maxima methods. Canadian Journal of Forest Research, 31, pp. 832–844.

Pitt, D.G.; Glover, G.R. 1993, Large–scale 35–mm aerial photographs for assessment of vegetation–management research plots in eastern Canada. Can. J. For. Res. 23, 2159–2169.

Polesel, Andrea, Giovanni Ramponi, y V. John Mathews. 2000, Image enhancement via adaptive unsharp masking. IEEE transactions on image processing 9:3, 505-510.

Pollock, R.J., 1996, The automatic recognition of individual trees in aerial images of forests based on a synthetic tree crown model. PhD dissertation, University of British Columbia, Vancouver, Canada.

Pollock, R.J., 1999, Individual tree recognition based on a synthetic tree crown image model. In D.A. Hill and D.G. Leckie (Eds), Proceedings of the International Forum on Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry, 10–12 February, Victoria, BC, Canada (Victoria, Canada: Pacific Forestry Centre, Canadian Forest Service), pp. 25–34.

Pouliot, D.A. y King, D.J., 2005, Approaches for optimal automated individual tree crown detection in regenerating coniferous forests. Canadian Journal of Remote Sensing, 31, pp. 255–267.

Pouliot, D.A., King, D.J., Bell, F.W. y Pitt, D.G., 2002, Automated tree crown detection and delineation in high-resolution digital camera imagery of coniferous forest regeneration. Remote Sensing of Environment, 82, pp. 322–334.

Sahoo, Prasanna K., S. A. K. C. Soltani, and Andrew KC Wong. 1988, A survey of thresholding techniques. Computer vision, graphics, and image processing 41.2 233-260.

Sheng, Y., 2000, Model-based conifer crown surface reconstruction from multi-ocular highresolution aerial imagery. PhD dissertation, University of California, Berkeley.

Sheng, Y.,Gong, P. y Biging, G.S., 2001, Model-based conifer crown surface reconstruction from high-resolution aerial images. Photogrammetric Engineering and Remote Sensing, 67, pp. 957–965.

Skurikhin, A.N., Garrity, S.R., McDowell, N.G., Cai, D.M. 2013, Automated tree crown detection and size estimation using multi-scale analysis of high-resolution satellite imagery Remote Sensing Letters, 4 (5), pp. 465-474.

Skurikhin, A.N., McDowell, N.G., Middleton, R.S. 2016 Unsupervised individual tree crown detection in high-resolution satellite imagery. Journal of Applied Remote Sensing 10(1), 010501

Srihari, S. N., y Govindaraju V. 1989, Analysis of textual images using the Hough transform. Machine vision and Applications 2.3 141-153.

Stark, J. Alex. 2000, Adaptive image contrast enhancement using generalizations of histogram equalization. IEEE Transactions on image processing 9.5 889-896.

Uddin, K., Gilani, H., Murthy, M.S.R., Kotru, R., Qamer, F.M. 2015, Forest Condition Monitoring Using Very-High-Resolution Satellite Imagery in a Remote Mountain Watershed in Nepal Mountain Research and Development, 35 (3), pp. 264-277.

Uuttera, J., Haara, A., Tokola, T. y Maltamo, M., 1998, Determination of the spatial distribution of trees from digital aerial photographs. Forest Ecology and Management, 110, pp. 275–282.

Vala, HJ & Baxi, Astha. 2013, A review on Otsu image segmentation algorithm". International Journal of Advanced Research in Computer Engineering \& Technology (IJARCET). 2 (2): 387.

Walsworth, N.A. y King, D.J., 1999a, Image modelling of forest changes associated with acid mine drainage. Computers and Geosciences, 25, pp. 567–580.

Walsworth, N.A. y King, D.J., 1999b, Comparison of two tree apex delineation techniques. In D.A. Hill and D.G. Leckie (Eds), Proceedings of the International Forum on Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry, 10–12 February, Victoria, BC, Canada (Victoria, Canada: Pacific Forestry Centre, Canadian Forest Service), pp. 93–104.

Wang, L., Gong, P. and Biging, G.S., 2004, Individual tree-crown delineation and treetop detection in high-spatial-resolution aerial imagery. Photogrammetric Engineering and Remote Sensing, 70, pp. 351–357.

Warner, T.A., Lee, J.Y. y MCgraw, J.B., 1999, Delineation and identification of individual trees in the eastern deciduous forest. In D.A. Hill and D.G. Leckie (Eds), Proceedings of the International Forum on Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry, 10–12 February, Victoria, BC, Canada (Victoria, Canada: Pacific Forestry Centre, Canadian Forest Service), pp. 81–92.

Wu, B.; Yu, B.; Yue, W.; Shu, S.; Tan, W.; Hu, C.; Huang, Y.; Wu, J.; Liu, H. 2013, A voxel-based method for automated identification and morphological parameters estimation of individual street trees from mobile laser scanning data. Remote Sens. 5, 581–611.

Yilmaz, V., Serifoglu, C., Gungor, O. 2016, Determining stand parameters from uas-based point clouds, International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, 2016-January, pp. 413-416.

Zhen, Z.; Quackenbush, L.J.; Zhang, L. 2014, Impact of tree-oriented growth order in marker-controlled region growing for individual tree crown delineation using airborne laser scanner (ALS) data. Remote Sens. 6, 555–579.

Zhen, Z.; Quackenbush, L.J.; Stehman, S.V.; Zhang, L. 2015, Agent-based region growing for individual tree crown delineation from airborne laser scanning (ALS) data. Int. J. Remote Sens. 36, 1965–1993.

Zhou, J., Proisy, C., Descombes, X., Hedhli, I., Barbier, N., Zerubia, J., Gastellu-Etchegorry, J.P., Couteron, P. 2010, Tree crown detection in high resolution optical and LiDAR images of tropical forest Proceedings of SPIE - The International Society for Optical Engineering, 7824, art. no. 78240Q