

Evaluación de parámetros de segmentación en OBIA para la clasificación de coberturas del suelo a partir de imágenes VANT

Susana I. Hinojosa-Espinoza^{ORCID}, José L. Gallardo-Salazar^{ORCID}, Félix J.C. Hinojosa-Espinoza^{ORCID}, Arnulfo Meléndez-Soto^{ORCID}*

Facultad de Ciencias Forestales - UJED. Río Papaloapan y Blvd. Durango S/N, Col. Valle del Sur. C.P. 34120. Durango, Durango, México.

Resumen: Los Vehículos Aéreos No Tripulados (VANT) han otorgado un nuevo auge a la teledetección y a las técnicas de clasificación de imágenes debido al alto nivel de detalle entre otros factores. El análisis de imágenes basado en objetos (OBIA) puede mejorar la precisión en la clasificación a diferencia de la basada en píxeles, especialmente en imágenes de alta resolución. La aplicación de OBIA para la clasificación de imágenes consta de tres etapas i.e., segmentación, definición de clases y polígonos de entrenamiento y clasificación. No obstante, en la etapa de segmentación es necesario definir los parámetros: radio espacial (RE), radio de rango (RR) y tamaño mínimo de la región (TMR). Los cuales, pese a su relevancia, suelen ser ajustados de manera visual, lo que conlleva a una interpretación subjetiva. Por lo anterior, es de suma importancia generar conocimiento enfocado a evaluar las combinaciones de estos parámetros. Este estudio describe el uso del algoritmo de segmentación de desplazamiento medio, seguido del clasificador *Random Forest* mediante el software Orfeo Toolbox. Se consideró un ortomosaico multispectral derivado de VANT para generar un mapa de cobertura de suelo sub-urbano en la localidad El Pueblito, Durango, México. El objetivo principal fue evaluar la eficiencia y calidad de segmentación de nueve combinaciones de parámetros anteriormente reportadas en estudios científicos. Ello en términos de número de polígonos generados, tiempo de procesamiento, medidas de discrepancia de segmentación y métricas de precisión de la clasificación. Los resultados obtenidos lograron evidenciar la importancia de ajustar los parámetros de entrada en los algoritmos de segmentación. La mejor combinación fue RE=5, RR=7 y TMR=250, con un índice Kappa de 0,90 y el menor tiempo de procesamiento. Por otro lado, el RR presentó un grado de asociación fuerte e inversamente proporcional con las métricas de precisión de clasificación.

Palabras clave: algoritmo de segmentación de desplazamiento medio, análisis de imágenes orientado a objetos, índice Kappa, *Random Forest*, vehículos aéreos no tripulados.

Evaluation of segmentation parameters in OBIA for classification of land covers from UAV images

Abstract: Unmanned Aerial Vehicles (UAVs) have given a new boost to remote sensing and image classification techniques due to the high level of detail among other factors. Object-based image analysis (OBIA) could improve classification accuracy unlike to pixel-based, especially in high-resolution images. OBIA application for image classification consists of three stages i.e., segmentation, class definition and training polygons, and

To cite this article: Hinojosa-Espinoza, S.I., Gallardo-Salazar, J.L., Hinojosa-Espinoza, F.J.C., Meléndez-Soto, A. 2021. Evaluation of segmentation parameters in OBIA for classification of land covers from UAV images. *Revista de Teledetección*, 58, 89-103. <https://doi.org/10.4995/raet.2021.14782>

* Corresponding author: a.melendez@ujed.mx

classification. However, defining the parameters: spatial radius (SR), range radius (RR) and minimum region size (MR) is necessary during the segmentation stage. Despite their relevance, they are usually visually adjusted, which leads to a subjective interpretation. Therefore, it is of utmost importance to generate knowledge focused on evaluating combinations of these parameters. This study describes the use of the mean-shift segmentation algorithm followed by *Random Forest* classifier using Orfeo Toolbox software. It was considered a multispectral orthomosaic derived from UAV to generate a suburban map land cover in town of El Pueblito, Durango, Mexico. The main aim was to evaluate efficiency and segmentation quality of nine parameter combinations previously reported in scientific studies. This in terms of number generated polygons, processing time, discrepancy measures for segmentation and classification accuracy metrics. Results evidenced the importance of calibrating the input parameters in the segmentation algorithms. Best combination was RE=5, RR=7 and TMR=250, with a Kappa index of 0.90 and shortest processing time. On the other hand, RR showed a strong and inversely proportional degree of association regarding the classification accuracy metrics .

Key words: Kappa index, mean-shift segmentation algorithm, object-based image analysis, Random Forest, Unmanned Aerial Vehicles.

1. Introducción

La teledetección es la principal disciplina científica para la observación, análisis e interpretación de fenómenos terrestres y atmosféricos (Chuvieco, 2020). Sus fuentes de información son imágenes obtenidas con sensores montados en plataformas satélites, aeronaves (Jara et al., 2019; Zaraza-Aguilera y Manrique-Chacón, 2019) o los recién surgidos Vehículos Aéreos No Tripulados (VANT) (Colomina y Molina, 2014; Gallardo-Salazar et al., 2020). Estos últimos han demostrado ciertas ventajas respecto a las plataformas tradicionales debido a una mayor resolución espacial, bajos costos y flexibilidad operativa (Matese et al., 2015). Además, los VANT pueden generar información complementaria a la derivada de satélites para resolver problemas específicos (Dash et al., 2018).

Uno de los principales objetivos de la teledetección es la clasificación de imágenes para generar cartografía de la cobertura de la tierra (Abburu y Golla, 2015; Dhingra y Kumar, 2019; Enderle y Weih Jr, 2005; Jain y Tomar, 2013), lo cual implica agrupar los píxeles de la imagen con propiedades similares en una misma clase, de aquí la importancia de buscar mejores técnicas de clasificación de imágenes (Li et al., 2014; Lu y Weng, 2007; Smits et al., 1999). En consecuencia, han surgido diferentes enfoques para la clasificación de imágenes: los basados

en píxeles (Hasmadi et al., 2009; Khatami et al., 2016) y el análisis de imágenes basado en objetos (OBIA) (Blaschke, 2010; Hossain y Chen, 2019).

Como una reciente tendencia, usar OBIA para la clasificación de imágenes capturadas con VANT se ha convertido en una herramienta indispensable en la planificación y gestión del territorio. Esto es debido a que genera información clave, oportuna y precisa para la toma de decisiones en diferentes ámbitos (Farfaglia et al., 2015; Mafanya et al., 2017; Mangiameli et al., 2018).

Diversos estudios aplican técnicas de clasificación a imágenes de alta resolución provenientes de VANT. Se han utilizado para monitoreo y gestión ambiental, mediante el estudio de la degradación de la vegetación (Ballari et al., 2016); en la evaluación de daños posteriores a desastres naturales como medida urgente para el rescate y asistencia (Kakooei y Baleghi, 2017; Li et al., 2017); desarrollo de cartografía precisa, rápida y detallada de deslizamientos de tierras (Comert et al., 2019) y detección de los efectos geomorfológicos de inundaciones en inmediaciones de ríos (Langhammer y Vacková, 2018).

Diversas investigaciones afirman que los procedimientos OBIA superan a los basados en píxeles (Ramadhan Kete et al., 2019; Ye et al.,

2018), al ser un método exitoso de clasificación especialmente en imágenes de alta resolución (De Castro et al., 2018; De Luca et al., 2019). Su principal característica es que se enfoca a segmentos (objetos), es decir, grupos de píxeles homogéneos y contiguos en el espacio y en el espectro electromagnético (Geneletti y Gorte, 2003; Torres-Sánchez et al., 2015). En general, el proceso de OBIA se divide en dos etapas principales: segmentación y clasificación (Blaschke, 2010; Silalahi et al., 2018). Para realizar la segmentación se toman en cuenta parámetros como radio espacial (RE), radio de rango (RR) y tamaño mínimo de la región (TMR) (Vu, 2012). Se ha demostrado que estos parámetros influyen en el rendimiento y calidad de la segmentación (Michel et al., 2015; Silalahi et al., 2018; Teodoro y Araujo, 2016).

De manera que la etapa más crítica en OBIA es la segmentación. La mayoría de los algoritmos disponibles deben ser ajustados por el usuario, lo que significa una tarea altamente subjetiva que generalmente se logra mediante interpretación visual. Por lo anterior, es de suma importancia generar conocimiento enfocado a evaluar las combinaciones de parámetros configurables en los algoritmos de segmentación. En específico,

en este estudio se describe el uso del algoritmo de segmentación de desplazamiento medio seguido del clasificador de *Random Forest* en Orfeo Toolbox 7.1 (OTB 7.1). Tiene por objetivo evaluar la eficiencia y calidad de nueve combinaciones de parámetros de segmentación (RE, RR y TMR) reportados en estudios científicos. Ello en términos de número de polígonos generados, tiempo de procesamiento, medidas de discrepancia de segmentación y métricas de precisión de la clasificación de coberturas del suelo. Lo anterior para el caso específico de un ortomosaico generado con VANT en la localidad de El Pueblito, Durango, México.

2. Metodología

2.1. Área de estudio

El área sobrevolada con el VANT para generar el ortomosaico es la localidad El Pueblito, situada al margen del río Tunal en el suroeste de la ciudad de Victoria de Durango, Durango, México ($23^{\circ}58'07,51''$ N, $104^{\circ}43'06,34''$ O) (Figura 1). La vegetación presente en la zona es: sauces (*Salix* sp.) álamos (*Populus* sp.), ahuehuetes (*Taxodium* sp.), huizaches (*Acacia* sp.) y mezquites (*Prosopis* sp.) (Villanueva Díaz et al., 2013). El clima es

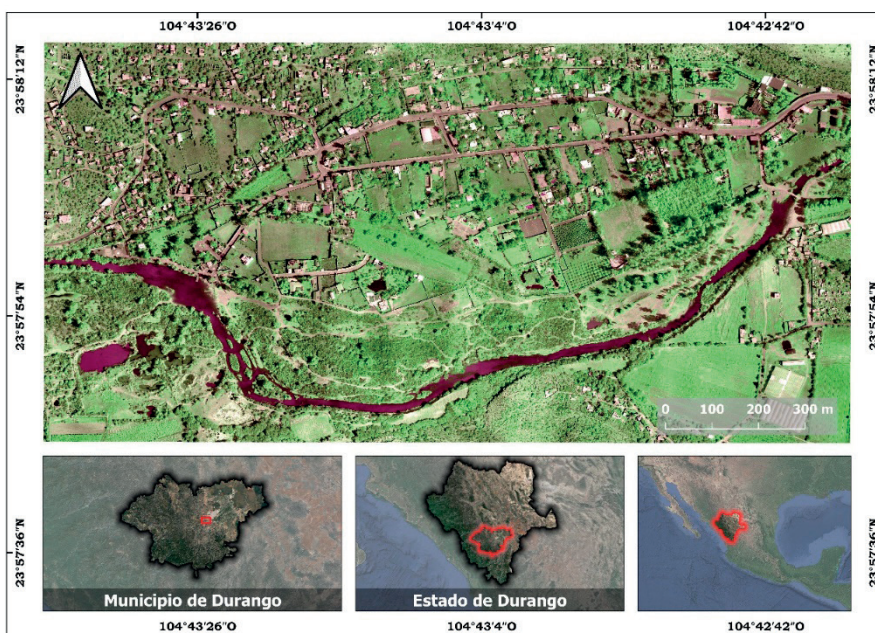


Figura 1. Localización del área de estudio.

semiárido-templado con temperaturas que oscilan entre 24,66 °C y 9,37 °C y una precipitación media anual de 576 mm (Inzunza-López et al., 2011).

2.2. Adquisición de imágenes

El 18 de septiembre de 2019, se realizó un vuelo con un VANT de ala fija, marca SenseFly modelo e-bee. El VANT se integró con una cámara multispectral modelo Canon PowerShot S110 con distancia focal de 5,2 mm y resolución de 4048×3048 píxeles. Esta cámara captura imágenes en las bandas: rojo (625 nm), verde (500 nm) e infrarrojo cercano (850 nm) (Brooke y Clutterbuck, 2020). Se configuró un plan de vuelo fotogramétrico con la aplicación eMotion Ag (www.sensefly.com/es/software/emotion-ag/, consultado el 10 de septiembre de 2020) a una altura de 122 m, para cubrir una superficie total de vuelo de 222 hectáreas. Derivado de ello se capturaron en total 659 imágenes.

2.3. Procesamiento de datos del VANT

A partir de las 659 imágenes, se aplicaron procedimientos fotogramétricos y de visión computacional mediante el software OpenDroneMap (www.opendronemap.org, consultado el 10 de septiembre de 2020). Este software utiliza técnicas de Structure from Motion y Multi-View Stereo en la que se identifican características comunes en imágenes con alto porcentaje de traslape. Posteriormente, genera una nube de puntos 3D a partir de la cual interpola un Modelo Digital de Superficie (MDS), que a su vez se utiliza para ortorrectificar cada imagen (Burdziakowski, 2017). Finalmente, las 659 imágenes resultaron unidas en un ortomosaico multispectral que posee una extensión de 161,8 ha (rectángulo de 1,733×934 m) y una distancia de muestra del suelo (GSD, por sus siglas en inglés) de 10 cm.

Con la finalidad de mejorar el procedimiento de segmentación y clasificación, se siguió la metodología basada en la combinación de información espectral y semántica descrita por De Luca et al. (2019). Mediante el uso del software QGIS (www.qgis.org, consultado el 10 de septiembre de 2020), se realizó un proceso de apilamiento de capas (*layerstack*) que fusionó las bandas: rojo, verde e infrarrojo cercano, NDVI (índice de vegetación de diferencia normalizada),

NDWI (índice de agua de diferencia normalizada) y MDS (modelo digital de superficie) para obtener un ortomosaico final con seis bandas. Esta etapa fue necesaria porque el procedimiento de segmentación requiere una sola imagen ráster como datos de entrada.

2.4. Segmentación

La primera etapa de OBIA es la segmentación. La cual consiste en la creación de grupos de píxeles homogéneos y contiguos tomando en cuenta la información espectral y espacial (i.e., tamaño, color, textura, forma, contexto, posición y adyacencia a otros píxeles); su resultado es un archivo vectorial en el que cada polígono representa un objeto (De Luca et al., 2019; Torres-Sánchez et al., 2015). Actualmente, es posible segmentar imágenes de alta resolución con diversos softwares. El más utilizado es eCognition (algoritmo de segmentación multiresolución), el cual es un software comercial. Algunas alternativas de código abierto disponibles son GRASS (algoritmo de desplazamiento medio y de crecimiento de regiones) y el software OTB (Sideris et al., 2020).

Este proceso se llevó a cabo en OTB 7.1 (www.orfeo-toolbox.org, consultado el 10 de septiembre de 2020), el cual permite ejecutar una segmentación de alto rendimiento mediante el uso del algoritmo de desplazamiento medio. Este es un método de agrupamiento no paramétrico e iterativo que ha demostrado el uso óptimo de la memoria y los procesadores, al ser diseñado específicamente para imágenes de alta resolución (De Luca et al., 2019; Michel et al., 2015; Teodoro y Araujo, 2016; Vu, 2012). Este algoritmo involucra dos fases principales: 1) define una ventana tomando en cuenta el RE, para agrupar a todos los píxeles dentro de la ventana definida con valores inferiores al RR y calcula la media correspondiente; 2) desplaza el centro de la ventana hacia la media con repetición del algoritmo hasta que converge. Finalmente, se eliminan las regiones con valores más bajos que el TMR (Raissouni et al., 2015).

Al realizar la segmentación se tomaron en cuenta los siguientes parámetros: 1) RE i.e., la distancia espacial entre clases e indica el tamaño de la ventana para crear segmentos u objetos tomando

como base el promedio de los píxeles analizados (dado en número de píxeles); 2) RR i.e., la variabilidad espectral entre clases para agrupar una cantidad de píxeles en un solo segmento u objeto. Por lo general, se utiliza la distancia euclidiana para medir las distancias entre píxeles de cada firma espectral (dado en niveles digitales) y 3) TMR i.e., tamaño mínimo del número de píxeles que forman un objeto, los segmentos que tienen un número de píxeles por debajo del establecido en este parámetro se fusionan con el segmento más cercano que tenga la misma firma espectral (Dongping et al., 2012; Raissouni et al., 2015).

Se analizaron nueve combinaciones de parámetros de segmentación reportadas en estudios científicos previos (Tabla 1). Los cuales utilizaron el algoritmo de desplazamiento medio y/o modificaciones de este. Como se muestra en la Tabla 2, las condiciones de los estudios (i.e., características de las imágenes y cobertura de suelo) son similares a las presentes en esta investigación.

Tabla 1. Combinación de parámetros de segmentación.

Estudio	RE	RR	TMR	Combinación
De Luca et al. (2019)	5	7	250	5-7-250
	5	30,5	124	5-30,5-124
Raissouni et al. (2015)	17	19,5	1700	17-19,5-1700
	10	40,52	503	10-40,52-503
Silalahi et al. (2018)	10	10	50	10-10-50
Teodoro y Araujo (2016)	15	15	500	15-15-500
Michel et al. (2015)	10	50	50	10-50-50
Benarchid y Raissouni (2014)	13	34,5	312	13-34,5-312
	8	23	207	8-23-207

RE: Radio espacial (píxel), RR: Radio de rango (ND), TMR: Tamaño mínimo de la región (píxel).

2.5. Definición de clases y polígonos de referencia

La definición de clases de cobertura terrestre depende estrictamente del objetivo del proyecto. En este estudio se distinguieron las diferentes coberturas del suelo en un área sub-urbana con vegetación y presencia de cuerpos de agua. Para ello, las imágenes de alta resolución adquiridas por VANT brindan la capacidad de distinguir árboles, arbustos y vegetación herbácea. Con base en lo anterior, se establecieron ocho clases dentro del área de estudio: edificaciones, zona agrícola, herbáceas, árboles y arbustos, calles, cuerpos de agua, suelo desnudo y sombras (ver “clases” del material suplementario: <https://bit.ly/3mhQk2c>). La inclusión de la clase sombras obedece a que algunos autores afirman que podría ayudar a distinguir entre clases predefinidas y mejorar la precisión de la clasificación (Belgiu et al., 2014).

Posteriormente, se realizó un estudio exploratorio en campo para poder elegir los polígonos de referencia. Para lograr una representación estadística consistente en cada clase de cobertura, se eligió un número total de polígonos de entrenamiento superior al 2% en términos de superficie del total de área de estudio (Congalton y Green, 2009). La distribución entre clases de cobertura se atendió de acuerdo con la importancia relativa de cada clase (ver “clases” del material suplementario: <https://bit.ly/3mhQk2c>). Así mismo, en congruencia con Ma et al., (2015) se respetó un esquema de muestreo adecuado en términos económicos y de tiempo para obtener un nivel aceptable de precisión cartográfica.

Tabla 2. Algoritmos, clases de cobertura y características de las imágenes.

Estudio	Algoritmo	Clases de cobertura	Imágenes
De Luca et al. (2019)	Desplazamiento medio a gran escala	Bosque	VANT Resolución: 5 cm
Raissouni et al. (2015)	Media-desplazada con estimador de Parámetros de Segmentación	Rural, industrial y residencial	Imagen satelital Resolución: 50 cm
Silalahi et al. (2018)	Desplazamiento medio	Bosque	VANT Resolución: 10 cm
Teodoro y Araujo (2016)	Desplazamiento medio	Urbana	VANT Resolución: 4 cm
Michel et al. (2015)	Desplazamiento medio modificado	Agrícola, bosque y urbana	Imagen satelital Resolución: 41 cm
Benarchid y Raissouni (2014)	Media-desplazada con estimador de Parámetros de Segmentación	Urbana y rural	Imagen satelital Resolución: 50 cm

De acuerdo con De Luca et al. (2019), los polígonos de referencia se seleccionaron manualmente mediante interpretación en pantalla, teniendo en cuenta una distribución aleatoria. Con el propósito de verificar la adecuada selección de polígonos de referencia se analizó el comportamiento de las distintas clases de cobertura de suelo mediante su firma espectral (ver “firmas espectrales” del material suplementario: <https://bit.ly/3mhQk2c>).

Por lo tanto, la selección de muestras es importante en los métodos de clasificación supervisados. Antes de entrenar el modelo, fue necesario dividir los polígonos de referencia en polígonos de entrenamiento y validación. En estudios donde se utilizaron imágenes multiespectrales de alta resolución y algoritmos de clasificación como *Random Forest* (Adelabu et al., 2015; Lyons et al., 2018), se recomienda elegir de manera aleatoria polígonos de entrenamiento y validación en una proporción de 80 y 20% respectivamente.

2.6. Clasificación

Existen varios algoritmos de aprendizaje automático de clasificación orientados a objetos implementados en OTB. En el presente estudio se probó el método *Random Forest* debido a su robustez y eficiencia. Este algoritmo es ampliamente recomendado como uno de los métodos de clasificación supervisada más adecuado para OBIA (De Luca et al., 2019; Li et al., 2016; Ma et al., 2017).

Random Forest es un conjunto de varios árboles independientes de clasificación y regresión (CART, por sus siglas en inglés) y se puede definir como en la Ecuación 1:

$$\{h(x, \theta_k), k=1,2,\dots,i,\dots\} \quad (1)$$

dónde h representa el clasificador de bosque aleatorio, x es la variable de entrada y $\{\theta_k\}$ representa las variables predictoras aleatorias distribuidas de forma idéntica e independiente que se utilizan para generar cada árbol CART (Feng et al., 2015). La respuesta final de *Random Forest* se calcula en función de la salida de todos los árboles de decisión involucrados. Para obtener resultados óptimos en la clasificación con el software OTB 7.1, se siguió lo propuesto por Immitzer et al. (2016) y Trisasonkko et al. (2017) quienes recomiendan usar 100 como número máximo de árboles. En conjunto

con los siguientes parámetros: profundidad máxima del árbol (5), número mínimo de muestras en cada nodo (10), suficiencia de precisión (error OOB) (0,01) y tamaño del subconjunto de características seleccionado al azar en cada nodo del árbol (0) el cual indica la raíz cuadrada del número de variables a probar en cada nodo (Cutler et al., 2007).

2.7. Evaluación de la eficiencia, calidad de segmentación y precisión de clasificación

Para evaluar la eficiencia de la segmentación, se registró el tiempo de procesamiento de la segmentación para las nueve combinaciones por medio del informe de resultados (log) de OTB 7.1. Posteriormente se ingresaron los archivos vectoriales resultantes al software libre QGIS (www.qgis.org, consultado el 10 de septiembre de 2020) para calcular el número total de polígonos generados.

Se evaluó la calidad de la segmentación mediante el método cuantitativo descrito por Nenmaoui et al., (2017). Este método se basa en las discrepancias entre polígonos de referencia y los segmentos de imagen correspondientes. Se utilizaron tres medidas de discrepancia: potencial de error de segmentación (PSE), relación de número de segmentos (NSR) y distancia Euclidiana 2 (ED2).

PSE se refiere a las discrepancias geométricas y se define como el cociente entre el área *under-segment* y el área total de los polígonos de referencia. NSR describe la discrepancia aritmética y se calcula con la diferencia absoluta del número de polígonos de referencia y el número de segmentos correspondientes, dividido por el número de polígonos de referencia. Por su parte, el ED2 es un índice compuesto, que considera tanto discrepancias geométricas como aritméticas (Ecuación 2):

$$ED2 = \sqrt{(PSE)^2 + (NSR)^2} \quad (2)$$

dónde, ED2 es la distancia Euclidiana 2, PSE es potencial de error de segmentación y NSR es la relación de número de segmentos.

Finalmente, para verificar la precisión de la clasificación de las combinaciones con el algoritmo *Random Forest*, se utilizó la matriz de confusión

a partir de los puntos de validación. El índice Kappa, la precisión general (OA), la precisión del productor (PA) y la precisión del usuario (UA) se derivaron de la matriz de confusión.

Desde los años 80s, el índice Kappa ha sido utilizado para expresar la precisión de una clasificación de imágenes para producir mapas temáticos (Congalton y Mead, 1983; Rosenfield y Fitzpatrick-Lins, 1986). En la actualidad, esta métrica sigue vigente y se utiliza para evaluar la calidad de la clasificación con imágenes de alta resolución generadas con VANT (Al-Najjar et al., 2019; Carvajal-Ramírez et al., 2019; Dash et al., 2017; Feng et al., 2015; Gao et al., 2018).

Por último, se realizó un análisis de correlación de Pearson para identificar relación entre los parámetros de segmentación (RE, RR y TMR) y el número de polígonos generados, tiempo de procesamiento y métricas de precisión de la clasificación (índice Kappa y OA). El análisis de los datos se llevó a cabo con el software libre y de código abierto R (<http://www.r-project.org>, consultado el 10 de septiembre de 2020).

3. Resultados y discusión

Todos los procesos para evaluar las nueve combinaciones se realizaron en una workstation con dos procesadores Intel Xeon®, CPU E5-2630 a 2,30 GHz con 12 núcleos y 64 GB de memoria RAM. La Tabla 3 muestra el número de polígonos generados y el tiempo de procesamiento de la

Tabla 3. Número de polígonos y tiempo de procesamiento en las combinaciones de los parámetros durante el proceso de segmentación.

Combinación	Número de polígonos	Tiempo de procesamiento (h)
5-7-250	219.943	2,67
5-30,5-124	77.809	1,17
17-19,5-1700	20.993	2,22
10-40,52-503	20.160	0,92
10-10-50	763.256	4,70
15-15-500	77.512	2,65
10-50-50	51.899	1,10
13-34,5-312	42.154	1,47
8-23-207	107.648	1,70

segmentación que indican el rendimiento para las combinaciones analizadas.

La Figura 2 contrasta el número de polígonos generados por las combinaciones en el proceso de segmentación, los cuales oscilaron entre 763.256 y 20.160. Ello puede ser evidencia de la gran influencia que representa la combinación de parámetros en los resultados de esta primera fase del análisis OBIA. Las combinaciones 10-10-50, 5-7-250 y 8-23-207 produjeron el mayor número de polígonos con 763.256, 219.943 y 107.648 respectivamente. Michel et al. (2015) reportaron entre 53.000 y 171.000 segmentos generados con una sola combinación estudiada (10-10-50) y con imágenes de diferente resolución espacial; De Luca et al. (2019) mencionan que el número de segmentos obtenidos se evaluaron mediante interpretación visual superponiéndolos sobre el




Figura 2. Comparación visual de las combinaciones analizadas para la estimación de la precisión de la segmentación.

ortomosaico, sin embargo, no implicó un análisis cuantitativo. En contraste, Silalahi et al. (2018) y Teodoro y Araujo (2016) no reportan el número de segmentos producidos, esto pudo deberse a que sus investigaciones se enfocaron principalmente en las métricas de precisión de la clasificación posterior al proceso de segmentación.

El tiempo de procesamiento osciló entre 0,92 y 4,70 h para las nueve combinaciones analizadas (Tabla 3). Se observó que las combinaciones 10-10-50, 5-7-250 y 15-15-500 presentaron el mayor tiempo de procesamiento con 4,7, 2,67 y 2,65 h respectivamente. A pesar de ser evidente que existe una relación positiva y directamente proporcional entre el tiempo de procesamiento y el número de segmentos generados, esta relación no se comporta de manera similar en las combinaciones donde el TMR se configuró con altos valores (i.e., 17-19,5-1700 y 15-15-500). Michel et al. (2015) reportaron para la combinación 10-50-50, tiempos de procesamiento de 5,25 h. Sin duda, la generación de grandes volúmenes de información por los VANT implica un gran desafío en las técnicas de procesamiento de imágenes. Teodoro y Araujo (2014) reportaron durante el proceso de segmentación, varios problemas relacionados con cierres inesperados del software y pérdidas de respuesta, lo que llevó a un tiempo de procesamiento superior a 60 h. Para superar las limitaciones de memoria, reducir el tiempo y optimizar el proceso de segmentación, algunos autores proponen la segmentación controlada por mosaicos, la delimitación de regiones de interés y la inclusión de la unidad de procesamiento de gráficos (GPU) (Michel et al., 2015; Teodoro y Araujo, 2016).

De igual forma, la Figura 2 muestra la influencia de los parámetros RE y RR en el tamaño de los segmentos. La cantidad y tamaño de estos podría indicar un exceso (*over-segmentation*) o una baja segmentación (*under-segmentation*). Por ello, se evaluó la calidad de la segmentación mediante las discrepancias entre los polígonos de referencia y los segmentos de imagen correspondientes. Se calcularon los valores de NSR, PSE y ED2 para las nueve combinaciones estudiadas (Tabla 4). De acuerdo con el trabajo de Liu et al., (2012), valores de ED2 cercanos a cero indican una correspondencia ideal (combinaciones 5-7-250 y 10-10-50), tanto geoméricamente (PSE)

Tabla 4. Valores de PSE, NSR y ED2 para las combinaciones de parámetros de segmentación analizadas.

Combinación	PSE	NSR	ED2
5-7-250	0,08	0,37	0,37
5-30,5-124	7,24	0,47	7,25
17-19,5-1700	1,34	0,42	1,40
10-40,52-503	11,45	0,50	11,46
10-10-50	0,53	0,25	0,61
15-15-500	0,68	0,35	0,77
10-50-50	0,90	0,47	1,02
13-34,5-312	2,41	0,47	1,02
8-23-207	13,22	0,57	13,23

como aritméticamente (NSR), del conjunto de objetos de referencia digitalizados manualmente. Por otro lado, valores muy grandes de ED2 (combinaciones 8-23-207 y 10-40,52-503) indican que hay discrepancias geométricas importantes, discrepancias aritméticas, o ambas cosas.

En la Figura 3 se observan las métricas de precisión para las nueve combinaciones examinadas. El índice Kappa osciló entre 0,51 y 0,90, mientras que el OA se ubicó entre 0,58 y 0,91. Las métricas mejoraron considerablemente, lo que resalta la importancia de la combinación de los parámetros de entrada en los algoritmos de segmentación. De manera general, los parámetros son seleccionados mediante interpretación visual (De Luca et al., 2019; Raissouni et al., 2015) por lo tanto, la definición de las combinaciones óptimas es una tarea de suma importancia y hace trascendente el presente trabajo.

Utilizando las combinaciones 10-10-50 y 5-7-250 se obtuvieron los mejores resultados, ambas con un índice Kappa de 0,90 y un OA de 0,91. Sin embargo, la combinación 5-7-250 reportó 43% menos tiempo de procesamiento (Figura 3). Por otra parte, la combinación 10-50-50 tuvo el índice Kappa y OA más bajos con 0,51 y 0,58 respectivamente. Para mayor detalle, las matrices de confusión resultantes para las nueve combinaciones de segmentación estudiadas se pueden consultar en “matrices de confusión” del material suplementario <https://bit.ly/3mhQk2c>.

Comparativamente, los resultados del índice Kappa obtenidos de las combinaciones 5-7-250 y 10-10-50 pueden considerarse excelentes de acuerdo con la escala propuesta por Monserud y Leemans (1992). Sin embargo, debe tomarse en cuenta que en esa época la resolución de las




Figura 3. Métricas de precisión en la clasificación supervisada y tiempo de procesamiento de la segmentación para las combinaciones de parámetros.

imágenes era mucho menor. Silalahi et al. (2018) probaron 27 combinaciones de parámetros para segmentación con algoritmo de segmentación de desplazamiento medio en OTB 1,24. A pesar del bajo rendimiento obtenido en la segmentación y clasificación, todas las combinaciones fueron evaluadas. Por ejemplo, algunas combinaciones pueden presentar artefactos extraños en los resultados de la segmentación y clasificación (Figura 4).

Concluyeron que la combinación 10-10-50 tuvo mayor precisión con un OA de 0,76 e índice Kappa de 0,55. Ello difiere de nuestros resultados para esa misma combinación (i.e., 0,91 y 0,90) posiblemente atribuible a que el objetivo del trabajo estuvo enfocado a detectar la copa de *Nypa fruticans*. Los trabajos realizados por De Luca et al. (2019) y Teodoro y Araujo (2014) presentan condiciones similares a las de esta investigación. En consecuencia, reportan un índice Kappa de 0,92 a 0,97 en bosques de alcornoque y un índice Kappa de 0,81 para un área sub-urbana, respectivamente.

La Figura 5 muestra el grado de asociación de cada uno de los parámetros de segmentación estudiados (i.e., RE, RR y TMR) respecto a las métricas de precisión. Es importante resaltar que

el RR presentó un grado de asociación fuerte e inversamente proporcional con el índice Kappa y con el OA ($r = -0,94$, $p < 0,001$). Resultados coincidentes fueron reportados por Apriyanto et al. (2019), quienes señalan que a diferencia del RE y el TMR, el RR es el parámetro que marca una diferencia significativa en la precisión de la segmentación.

Lo anterior se reafirma en las combinaciones 5-7-250 y 10-10-50. En contraste, la combinación 10-50-50, presentó el RR más elevado y menor grado de precisión en la clasificación. Resultados similares han sido reportados por Raissouni et al. (2015) quienes analizaron cuatro tipos de coberturas de suelo (residencial densa, industrial, residencial y rural) con un RR de 64,80, 19,15, 40,52 y 30,50, respectivamente. Los mejores resultados de precisión se obtuvieron en las coberturas segmentadas con menor valor para este parámetro. De Luca et al. (2019) probaron de manera visual diferentes valores de RR y TMR para mejorar el proceso de segmentación. Utilizaron valores de RR de 5 a 30 y obtuvieron mayor precisión y alto índice Kappa con un valor de 7. Afirman que para imágenes de alta resolución derivadas de VANT es preferible usar valores de RR bajos. Por otro lado, Silalahi et al. (2018)




Figura 4. Resultados de clasificación en una fracción del ortomosaico para cada combinación de parámetros de segmentación.

analizaron 27 combinaciones de parámetros para segmentación. Obtuvieron el mayor índice Kappa con valores de RR relativamente bajos (i.e., 10-10-50, 5-10-50, 5-20-50 y 15-10-50). En concordancia, Teodoro y Araujo (2016) indican que la segmentación que obtuvo mejores resultados después de probar varias combinaciones, es la que incluye un RR de 15.

Es importante destacar que el valor de los parámetros para una segmentación de calidad dependerá de las características de la superficie

a analizar. Es decir, no siempre con valores bajos en RR resultará en buenas métricas de precisión de la clasificación. Por ejemplo, en el estudio de De Luca et al. (2019) indican que para identificar polígonos pequeños durante el proceso de segmentación funcionó un RR bajo y valores superiores a este conducirían a una segmentación insuficiente. Por otro lado, Michel et al. (2015) señalan que para segmentar objetos alargados y homogéneos un RR alto puede conducir a una mejor delimitación.




Figura 5. Correlaciones de Pearson entre parámetros analizados, tiempo de procesamiento, número de polígonos y métricas de precisión.

4. Conclusiones

El análisis OBIA realizado mediante Orfeo Toolbox 7.1 con el algoritmo de desplazamiento medio, en imágenes VANT resultó ser adecuado para la clasificación de cobertura de suelo de área sub-urbana con vegetación y presencia de cuerpos de agua. Los experimentos realizados con las nueve combinaciones de parámetros de segmentación (RE, RR y TMR) destacaron la importancia de su configuración en los algoritmos de segmentación, debido a su influencia en las métricas de precisión de la clasificación.

El parámetro RR influyó de manera directa e inversamente proporcional a las métricas de precisión. La combinación 5-7-250, fue la que ofreció mayor eficiencia en términos de calidad de la clasificación (i.e., índice Kappa de 0,90 y un

OA de 0,91) y menor tiempo de procesamiento. Esto es válido para una cobertura de suelo similar a las del área del presente estudio. Los resultados pueden proporcionar herramientas útiles para mejorar la calidad y eficiencia de clasificaciones de cobertura de suelo basadas en OBIA aplicadas a investigaciones científicas.

Agradecimientos

Se agradece al Consejo Nacional de Ciencia y Tecnología (Conacyt) por el financiamiento otorgado a la primera autora para la realización de sus estudios de maestría, así como al programa de Maestría en Geomática Aplicada a Recursos Forestales y Ambientales de la Facultad de Ciencias Forestales de la UJED.

Referencias

- Abburu, S., Golla, S.B. 2015. Satellite image classification methods and techniques: A review. *International Journal of Computer Applications*, 119(8), 20-25. <https://doi.org/10.5120/21088-3779>
- Adelabu, S., Mutanga, O., Adam, E. 2015. Testing the reliability and stability of the internal accuracy assessment of random forest for classifying tree defoliation levels using different validation methods. *Geocarto International*, 30(7), 810-821. <https://doi.org/10.1080/10106049.2014.997303>
- Al-Najjar, H.A.H., Kalantar, B., Pradhan, B., Saeidi, V., Halin, A.A., Ueda, N., Mansor, S. 2019. Land Cover Classification from fused DSM and UAV Images Using Convolutional Neural Networks. *Remote Sensing*, 11(12), 1461. <https://doi.org/10.3390/rs11121461>
- Apriyanto, D., Jaya, I.N., Puspaningsih, N. 2019. Examining the object-based and pixel-based image analyses for developing stand volume estimator model. *Indonesian Journal of Electrical Engineering and Computer Science*, 15(3), 1586-1596. <https://doi.org/10.11591/ijeecs.v15.i3.pp1586-1596>
- Ballari, D., Orellana, D., Acosta, E., Espinoza, A., Morocho, V. 2016. UAV monitoring for environmental management in Galapagos Islands. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, 41, 1105-1111. <https://doi.org/10.5194/isprsarchives-XLI-B1-1105-2016>
- Belgiu, M., Drăguț, L., Strobl, J. 2014. Quantitative evaluation of variations in rule-based classifications of land cover in urban neighbourhoods using WorldView-2 imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 87, 205-215. <https://doi.org/10.1016/j.isprsjprs.2013.11.007>
- Benarchid, O., Raissouni, N. 2014. Mean-shift Segmentation Parameters Estimator (MSPE): A new tool for Very High Spatial Resolution satellite images. *International Conference on Multimedia Computing and Systems -Proceedings*, 357-361. <https://doi.org/10.1109/ICMCS.2014.6911184>
- Blaschke, T. 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2-16. <https://doi.org/10.1016/j.isprsjprs.2009.06.004>
- Brooke, C., Clutterbuck, B. 2020. Mapping Heterogeneous Buried Archaeological Features Using Multisensor Data from Unmanned Aerial Vehicles. *Remote Sensing*, 12(1), 41. <https://doi.org/10.3390/rs12010041>
- Burdziakowski, P. 2017. Evaluation of Open Drone Map Toolkit for Geodetic Grade Aerial Drone Mapping – Case Study. En: *Proceedings International Multidisciplinary Scientific GeoConference-SGEM 2017*, Gdańska, Polonia. 29 Junio-5 Julio. pp. 101-110. <https://doi.org/10.5593/sgem2017/23/S10.013>
- Carvajal-Ramírez, F., Marques da Silva, J.R., Agüera-Vega, F., Martínez-Carricondo, P., Serrano, J., Moral, F.J. 2019. Evaluation of Fire Severity Indices Based on Pre- and Post-Fire Multispectral Imagery Sensed from UAV. *Remote Sensing*, 11(9), 993. <https://doi.org/10.3390/rs11090993>
- Chuvieco, E. 2020. Revisión histórica y perspectivas de futuro de la Teledetección: desde el ERTS hasta los Sentinels. *Mapping*, 29(200), 30-32.
- Colomina, I., Molina, P. 2014. Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 92(2014), 79-97. <https://doi.org/10.1016/j.isprsjprs.2014.02.013>
- Comert, R., Avdan, U., Gorum, T., Nefeslioglu, H.A. 2019. Mapping of shallow landslides with object-based image analysis from unmanned aerial vehicle data. *Engineering Geology*, 260(2019), 105264. <https://doi.org/10.1016/j.enggeo.2019.105264>
- Congalton, R.G., Mead, R.A. 1983. A quantitative method to test for consistency and correctness in photointerpretation. *Photogrammetric Engineering and Remote Sensing*, 49(1), 69-74.
- Congalton, R.G., Green, K. 2009. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*; Second CRC Press Taylor & Francis Group: Boca Raton, FL, USA, Volume 48.
- Cutler, D.R., Edwards Jr, T.C., Beard, K.H., Cutler, A., Hess, K.T., Gibson, J., Lawler, J.J. 2007. Random forests for classification in ecology. *Ecology*, 88(11), 2783-2792. <https://doi.org/10.1890/07-0539.1>
- Dash, J.P., Pearse, G.D., Watt, M.S. 2018. UAV Multispectral Imagery Can Complement Satellite Data for Monitoring Forest Health. *Remote Sensing*, 10(8), 1216. <https://doi.org/10.3390/rs10081216>
- Dash, J.P., Watt, M.S., Pearse, G.D., Heaphy, M., Dungey, H.S. 2017. Assessing very high resolution UAV imagery for monitoring forest health during a simulated disease outbreak. *ISPRS Journal of Photogrammetry and Remote Sensing*, 131(2017), 1-14. <https://doi.org/10.1016/j.isprsjprs.2017.07.007>

- De Castro, A.I., Torres-Sánchez, J., Peña, J.M., Jiménez-Brenes, F.M., Csillik, O., López-Granados, F. 2018. An Automatic Random Forest-OBIA Algorithm for Early Weed Mapping between and within Crop Rows Using UAV Imagery. *Remote Sensing*, 10(2), 285. <https://doi.org/10.3390/rs10020285>
- De Luca, G., N. Silva, J.M., Cerasoli, S., Araújo, J., Campos, J., Di Fazio, S., Modica, G. 2019. Object-Based Land Cover Classification of Cork Oak Woodlands using UAV Imagery and Orfeo ToolBox. *Remote Sensing*, 11(10), 1238. <https://doi.org/10.3390/rs11101238>
- Dhingra, S., Kumar, D. 2019. A review of remotely sensed satellite image classification. *International Journal of Electrical & Computer Engineering*, 9(3), 1720-1731. <https://doi.org/10.11591/ijece.v9i3.pp.1720-1731>
- Dongping M., Tianyu C., Hongyue., Longxiang L., Cheng Q., Jinyang D., 2012. Semivariogram-Based Spatial Bandwidth Selection for Remote Sensing Image Segmentation With Mean-Shift Algorithm. *IEEE Geoscience and Remote Sensing Letters*, 9(5), 813-817. <https://doi.org/10.1109/lgrs.2011.2182604>
- Enderle, D.I.M., Weih Jr, R.C. 2005. Integrating supervised and unsupervised classification methods to develop a more accurate land cover classification. *Journal of the Arkansas Academy of Science*, 59(1), 65-73.
- Farfaglia, S., Lollino, G., Iaquina, M., Sale, I., Catella, P., Martino, M., Chiesa, S. 2015. The use of UAV to monitor and manage the territory: perspectives from the SMAT project. En *Engineering Geology for Society and Territory-Volume 5* (pp. 691-695). Springer, Cham. https://doi.org/10.1007/978-3-319-09048-1_134
- Feng, Q., Liu, J., Gong, J. 2015. UAV Remote Sensing for Urban Vegetation Mapping Using Random Forest and Texture Analysis. *Remote Sensing*, 7(1), 1074-1094. <https://doi.org/10.3390/rs70101074>
- Gallardo-Salazar, J., Pompa-García, M., Aguirre-Salado, C., López-Serrano, P., Meléndez-Soto, A. 2020. Drones: tecnología con futuro promisorio en la gestión forestal. *Revista Mexicana de Ciencias Forestales*, 11(61), 28-50. <https://doi.org/10.29298/rmcf.v11i61.794>
- Gao, J., Liao, W., Nuytens, D., Lootens, P., Vangeyer, J., Pižurica, A., He, Y., Pieters, J.G. 2018. Fusion of pixel and object-based features for weed mapping using unmanned aerial vehicle imagery. *International Journal of Applied Earth Observation and Geoinformation*, 67(2018), 43-53. <https://doi.org/10.1016/j.jag.2017.12.012>
- Geneletti, D., Gorte, B.G.H. 2003. A method for object-oriented land cover classification combining Landsat TM data and aerial photographs. *International Journal of Remote Sensing*, 24(6), 1273-1286. <https://doi.org/10.1080/01431160210144499>
- Hasmadi, M., Pakhriazad, H.Z., Shahrin, M.F. 2009. Evaluating supervised and unsupervised techniques for land cover mapping using remote sensing data. *Geografia: Malaysian Journal of Society and Space*, 5(1), 1-10.
- Hossain, M.D., Chen, D. 2019. Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective. *ISPRS Journal of Photogrammetry and Remote Sensing*, 150(2019), 115-134. <https://doi.org/10.1016/j.isprsjprs.2019.02.009>
- Immitzer, M., Vuolo, F., Atzberger, C. 2016. First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe. *Remote Sensing*, 8(3), 166. <https://doi.org/10.3390/rs8030166>
- Inzunza-López, J.O., López-Ariza, B., Valdez-Cepeda, R.D., Mendoza, B., Sánchez-Cohen, I., García-Herrera, G. 2011. La variación de las temperaturas extremas en la ‘Comarca Lagunera’ y cercanías. *Revista Chapingo Serie Ciencias Forestales y del Ambiente*, 17(2011), 45-61. <https://doi.org/10.5154/r.rchscfa.2010.09.071>
- Jain, M., Tomar, P.S. 2013. Review of image classification methods and techniques. *International Journal of Engineering Research and Technology*, 2(8), 852-858.
- Jara, C., Delegido, J., Ayala, J., Lozano, P., Armas, A., Flores, V. 2019. Estudio de bofedales en los Andes ecuatorianos a través de la comparación de imágenes Landsat-8 y Sentinel-2. *Revista de Teledetección*, 53(2019), 45-57. <https://doi.org/10.4995/raet.2019.11715>
- Kakooei, M., Baleghi, Y. 2017. Fusion of satellite, aircraft, and UAV data for automatic disaster damage assessment. *International Journal of Remote Sensing*, 38(8-10), 2511-2534. <https://doi.org/10.1080/01431161.2017.1294780>
- Khatami, R., Mountrakis, G., Stehman, S.V. 2016. A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: General guidelines for practitioners and future research. *Remote Sensing of Environment*, 177(2016), 89-100. <https://doi.org/10.1016/j.rse.2016.02.028>

- Langhammer, J., Vacková, T. 2018. Detection and Mapping of the Geomorphic Effects of Flooding Using UAV Photogrammetry. *Pure and Applied Geophysics*, 175(9), 3223-3245. <https://doi.org/10.1007/s00024-018-1874-1>
- Li, M., Ma, L., Blaschke, T., Cheng, L., Tiede, D. 2016. A systematic comparison of different object-based classification techniques using high spatial resolution imagery in agricultural environments. *International Journal of Applied Earth Observation and Geoinformation*, 49(2016), 87-98. <https://doi.org/10.1016/j.jag.2016.01.011>
- Li, M., Zang, S., Zhang, B., Li, S., Wu, C. 2014. A Review of Remote Sensing Image Classification Techniques: the Role of Spatio-contextual Information. *European Journal of Remote Sensing*, 47(1), 389-411. <https://doi.org/10.5721/EuJRS20144723>
- Li, S., Tang, H., Huang, X., Mao, T., Niu, X. 2017. Automated Detection of Buildings from Heterogeneous VHR Satellite Images for Rapid Response to Natural Disasters. *Remote Sensing*, 9(11), 1177. <https://doi.org/10.3390/rs9111177>
- Liu, Y., Biana, L., Menga, Y., Wanga, H., Zhanga, S., Yanga, Y., Shaoa, X., Wang, B., 2012. Discrepancy measures for selecting optimal combination of parameter values in object-based image analysis. *ISPRS Journal of Photogrammetry and Remote Sensing*, 68(2012), 144-156. <https://doi.org/10.1016/j.isprsjprs.2012.01.007>
- Lu, D., Weng, Q. 2007. A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28(5), 823-870. <https://doi.org/10.1080/01431160600746456>
- Lyons, M.B., Keith, D.A., Phinn, S.R., Mason, T.J., Elith, J. 2018. A comparison of resampling methods for remote sensing classification and accuracy assessment. *Remote Sensing of Environment*, 208(2018), 145-153. <https://doi.org/10.1016/j.rse.2018.02.026>
- Ma, L., Cheng, L., Li, M., Liu, Y., Ma, X. 2015. Training set size, scale, and features in Geographic Object-Based Image Analysis of very high resolution unmanned aerial vehicle imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 102(2015), 14-27. <https://doi.org/10.1016/j.isprsjprs.2014.12.026>
- Ma, L., Li, M., Ma, X., Cheng, L., Du, P., Liu, Y. 2017. A review of supervised object-based land-cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130(2017), 277-293. <https://doi.org/10.1016/j.isprsjprs.2017.06.001>
- Mafanya, M., Tsele, P., Botai, J., Manyama, P., Swart, B., Monate, T. 2017. Evaluating pixel and object based image classification techniques for mapping plant invasions from UAV derived aerial imagery: *Harrisia pomanensis* as a case study. *ISPRS Journal of Photogrammetry and Remote Sensing*, 129(2017), 1-11. <https://doi.org/10.1016/j.isprsjprs.2017.04.009>
- Mangiameli, M., Mussumeci, G., Candiano, A. 2018. A low cost methodology for multispectral image classification. En *Computational Science and Its Applications-ICCSA 2018* (pp. 263–280). Springer, Cham. https://doi.org/10.1007/978-3-319-95174-4_22
- Matese, A., Toscano, P., Di Gennaro, S.F., Genesio, L., Vaccari, F.P., Primicerio, J., Belli, C., Zaldei, A., Bianconi, R., Gioli, B. 2015. Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture. *Remote Sensing*, 7(3), 2971-2990. <https://doi.org/10.3390/rs70302971>
- Michel, J., Youssefi, D., Grizonnet, M. 2015. Stable Mean-Shift Algorithm and Its Application to the Segmentation of Arbitrarily Large Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*, 53(2), 952-964. <https://doi.org/10.1109/TGRS.2014.2330857>
- Monserud, R.A., Leemans, R. 1992. Comparing global vegetation maps with the Kappa statistic. *Ecological Modelling*, 62(4), 275-293. [https://doi.org/10.1016/0304-3800\(92\)90003-W](https://doi.org/10.1016/0304-3800(92)90003-W)
- Nenmaoui, A., Torres, M.Á.A., Novelli, A., Marín, M.C.V., Torres, F.J.A., Betlej, M., Cichón, P. 2017. Mapeado de invernaderos mediante teledetección orientada a objetos: relación entre la calidad de la segmentación y precisión de la clasificación. *Revista Mapping*, 26(181), 4-13. ISSN: 1131-9100
- Raissouni, N., Benarchid, O., Sobrino, J., Ayyan, A. 2015. Aplicación del Estimador de Parámetros de Segmentación por Media-desplazada (EPSM) a las imágenes de satélite de muy alta resolución espacial: Tetuán (Marruecos). *Revista de Teledetección*, 43(2015), 91-96. <https://doi.org/10.4995/raet.2015.3511>
- Ramadhan Kete, S.C., Suprihatin, Tarigan, S.D., Effendi, H. 2019. Land use classification based on object and pixel using Landsat 8 OLI in Kendari City, Southeast Sulawesi Province, Indonesia. *IOP Conference Series: Earth and Environmental Science*, 284(2019), 012019. <https://doi.org/10.1088/1755-1315/284/1/012019>

- Rosenfield, G.H., Fitzpatrick-Lins, K. 1986. A coefficient of agreement as a measure of thematic classification accuracy. *Photogrammetric Engineering and Remote Sensing*, 52(2), 223-227.
- Sideris, K., Colson, D., Lightfoot, P., Heeley, L., Robinson, P. 2020. Review of image segmentation algorithms for analysing Sentinel-2 data over large geographical areas. *JNCC Report No. 655*. Peterborough, ISSN 0963-8091.
- Silalahi, R., Jaya, I.N., Tiryana, T., Mulia, F. 2018. Assessing the Crown Closure of Nypa on UAV Images using Mean-Shift Segmentation Algorithm. *Indonesian Journal of Electrical Engineering and Computer Science*, 9(3), 722-730. <https://doi.org/10.11591/ijeecs.v9.i3.pp722-730>
- Smits, P.C., Dellepiane, S.G., Schowengerdt, R.A. 1999. Quality assessment of image classification algorithms for land-cover mapping: A review and a proposal for a cost-based approach. *International Journal of Remote Sensing*, 20(8), 1461-1486. <https://doi.org/10.1080/014311699212560>
- Teodoro, A.C., Araujo, R. 2014. Exploration of the OBIA methods available in SPRING non-commercial software to UAV data processing. En: *Proceedings SPIE 9245, Earth Resources and Environmental Remote Sensing/GIS Applications V*. Amsterdam, Netherlands, 10 de Octubre. <https://doi.org/10.1117/12.2066468>
- Teodoro, A.C., Araujo, R. 2016. Comparison of performance of object-based image analysis techniques available in open source software (Spring and Orfeo Toolbox/Monteverdi) considering very high spatial resolution data. *Journal of Applied Remote Sensing*, 10(1), 1-22. <https://doi.org/10.1117/1.JRS.10.016011>
- Torres-Sánchez, J., López-Granados, F., Peña, J.M. 2015. An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops. *Computers and Electronics in Agriculture*, 114(2015), 43-52. <https://doi.org/10.1016/j.compag.2015.03.019>
- Trisasongko, B.H., Panuju, D.R., Paull, D.J., Jia, X., Griffin, A.L. 2017. Comparing six pixel-wise classifiers for tropical rural land cover mapping using four forms of fully polarimetric SAR data. *International Journal of Remote Sensing*, 38(11), 3274-3293. <https://doi.org/10.1080/01431161.2017.1292072>
- Villanueva Díaz, J., Stahle, D.W., Cerano Paredes, J., Estrada Ávalos, J., Constante García, V. 2013. Respuesta hidrológica del sabino en bosques de galería del Río San Pedro Mezquital, Durango. *Revista Mexicana de Ciencias Forestales*, 4(20), 9-19. <https://doi.org/10.29298/rmcf.v4i20.366>
- Vu, T.T. 2012. Object-based remote sensing image analysis with OSGeo tools. En: *Proceedings FOSS4G Southeast Asia 2012*, Johor Bahru, Malaysia. 18-19 Julio. pp. 79-84.
- Ye, S., Pontius, R.G., Rakshit, R. 2018. A review of accuracy assessment for object-based image analysis: From per-pixel to per-polygon approaches. *ISPRS Journal of Photogrammetry and Remote Sensing*, 141(2018), 137-147. <https://doi.org/10.1016/j.isprsjprs.2018.04.002>
- Zaraza-Aguilera, M.A., Manrique-Chacón, L.M. 2019. Generación de datos de cambio de coberturas vegetales en la sabana de Bogotá mediante el uso de series temporales con imágenes Landsat e imágenes sintéticas MODIS-Landsat entre los años 2007 y 2013. *Revista de Teledetección*, 54(2019), 41-58. <https://doi.org/10.4995/raet.2019.12280>