

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

<https://doi.org/10.35381/i.p.v7i13.4781>

Evaluación de desplazamiento medio adaptativo tridimensional y modelo de corona en segmentación arbórea con LiDAR

Assessment of three-dimensional adaptive mean shift and crown model in individual tree segmentation with LiDAR

Eduardo Alejandro Tusa-Jumbo

eduardo.tusa@unach.edu.ec

Universidad Nacional del Chimborazo, Riobamba, Chimborazo
Ecuador

<https://orcid.org/0000-0002-9408-5134>

Tania Calle-Jimenez

tania.calle@epn.edu.ec

Escuela Politécnica Nacional, Quito, Pichincha
Ecuador

<https://orcid.org/0000-0003-0871-6954>

Recibido: 12 de marzo 2025

Revisado: 23 de abril 2025

Aprobado: 22 de junio 2025

Publicado: 01 de julio 2025

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

RESUMEN

Este trabajo tuvo como objetivo evaluar el desplazamiento medio adaptativo tridimensional con un modelo de corona para la segmentación de árboles individuales a partir de datos LiDAR obtenidos con vehículos aéreos no tripulados. Se empleó un conjunto de datos abierto y se aplicó una exploración de parámetros basada en coeficientes alométricos bajo un modelo elipsoidal. Los árboles detectados se emparejaron con puntos de inventario mediante criterios de distancia y se midieron métricas de exactitud, exhaustividad, equilibrio y error en la localización. El análisis por parcelas reveló diferencias según el tipo de bosque: las masas caducifolias resultaron más complejas, las coníferas alcanzaron detecciones casi completas con falsos positivos y las masas mixtas lograron el mejor equilibrio. Se concluyó que el método fue eficaz y reproducible, aunque dependiente de la parametrización.

Descriptor: Aprendizaje automático; inventario forestal; evaluación de tecnologías. (Tesoro UNESCO).

ABSTRACT

This study aimed to evaluate the three-dimensional adaptive mean shift with a crown model for individual tree segmentation using LiDAR data collected by unmanned aerial vehicles. An open dataset was employed, and a parameter exploration based on allometric coefficients under an ellipsoidal model was conducted. Detected trees were matched with inventory points using distance-based criteria, and performance was measured through accuracy, recall, balance, and localization error. The results showed that trees at larger scales offered high completeness but low x due to over-segmentation, while smaller scales reversed this relationship. Plot-level analysis revealed differences by forest type: deciduous stands were more challenging due to irregular crowns, coniferous stands achieved nearly complete detection but produced false positives, and mixed stands offered the best balance. It was concluded that the method was effective and reproducible, although sensitive to parameterization.

Descriptors: Machine learning; forest inventories; technology assessment. (UNESCO Thesaurus)

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

INTRODUCCIÓN

La segmentación de árboles individuales a partir de datos de Light Detection and Ranging (LiDAR) se ha consolidado como un eje central del monitoreo y la gestión forestal contemporáneos. La delimitación precisa de copas permite derivar atributos estructurales clave que sostienen inventarios, estimaciones de biomasa, evaluaciones ecológicas y decisiones de manejo sostenible (Ferraz et al., 2016; Crowther et al., 2015). Frente a los elevados costos y las restricciones espaciales de los levantamientos de campo, LiDAR ofrece nubes de puntos tridimensionales de alta resolución que habilitan análisis a nivel de árbol, incluso en territorios con relieve complejo y doseles estratificados (Jakubowski et al., 2013; Aubry-Kientz et al., 2019).

Durante las dos últimas décadas se han desarrollado numerosos métodos de segmentación. Los enfoques tradicionales basados en modelos de altura de copa (CHM), como filtros de máximos locales, cuencas de drenaje y crecimiento de regiones, exhiben resultados aceptables en coníferas, pero su desempeño decae en bosques heterogéneos y multilaminares por su sensibilidad a parámetros y su dependencia de proyecciones bidimensionales (Jakubowski et al., 2013). Alternativas como la agrupación por densidad (p. ej., DBSCAN) o los modelos geométricos de directividad de ramas mejoran la delineación en ciertos contextos, aunque siguen condicionadas por la sintonía de parámetros y por subrendimiento en copas densas y entrelazadas (Comesaña-Cebral et al., 2021; Yang et al., 2024).

Los avances recientes en aprendizaje profundo han transformado la investigación al operar directamente sobre nubes de puntos con arquitecturas como PointNet, PointNet++ y detectores basados en CNN, alcanzando mayores F1 y robustez en bosques complejos al aprender rasgos locales y globales de datos no estructurados (Qi et al., 2017; You et al., 2023). No obstante, estos enfoques requieren grandes conjuntos anotados y recursos de cómputo significativos, y aún enfrentan dificultades en copas muy superpuestas, un reto transversal en ITS (Henrich et al., 2024).

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

Para mitigar estas limitaciones, han surgido métodos híbridos que integran detección de troncos, imágenes espectrales o LiDAR multivista, reduciendo sobre- y subsegmentación y reportando F1 elevados en ambientes frondosos y urbanos (Deng et al., 2024; Yu et al., 2024; Hua et al., 2022). Sin embargo, su complejidad y dependencia de datos multimodales restringen su escalabilidad. En paralelo, los algoritmos de desplazamiento medio adaptativo (AMS3D) ajustan de manera automática el ancho de banda del núcleo según la estructura local del dosel, aumentando la automatización y eficiencia, aunque con limitaciones para detectar el sotobosque (Hu et al., 2017; Chen et al., 2018; Hui et al., 2021).

Una refinación adicional consiste en modelar la forma de la copa mediante relaciones alométricas e integrar núcleos elipsoidales o superelipsoidales que alinean la segmentación con la morfología arbórea, mejorando la exhaustividad y el índice de Jaccard —en especial en coníferas— y produciendo límites de copa más realistas (Xiao et al., 2019; Tusa et al., 2021). Pese a estos avances, gran parte de los estudios se apoyan en datos regionales o propietarios, lo que limita la reproducibilidad y la validación intersitio; a diferencia de otros ámbitos de teledetección donde plataformas abiertas han favorecido ejercicios reproducibles, como el mapeo de NDVI en Ecuador (Álvarez Mendoza et al., 2024). En ITS, los anchos de banda adaptativos y los modelos de copa han sido escasamente evaluados en conjuntos de referencia abiertos.

Por tanto, el objetivo es evaluar el desplazamiento medio adaptativo tridimensional con un modelo de corona para la segmentación de árboles individuales a partir de datos LiDAR obtenidos con vehículos aéreos no tripulados

MÉTODOS

La metodología propuesta operacionaliza el algoritmo de desplazamiento medio adaptativo tridimensional (AMS3D) con modelo de forma de copa para la segmentación de copas individuales de árboles (ITC, por sus siglas en inglés). El diseño integra el preprocesamiento de datos LiDAR, la estimación adaptativa del perfil del núcleo, la

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

calibración de parámetros basada en relaciones alométricas y la evaluación cuantitativa frente a inventarios de referencia. Este flujo de trabajo se fundamenta en los avances recientes en segmentación mediante desplazamiento medio adaptativo (Hu et al., 2017; Yan et al., 2020; Lei et al., 2022) y en modelos sensibles a la forma de la copa (Xiao et al., 2016; Tusa et al., 2021). La Figura 1 resume el flujo metodológico de la presente investigación y se describe a continuación.

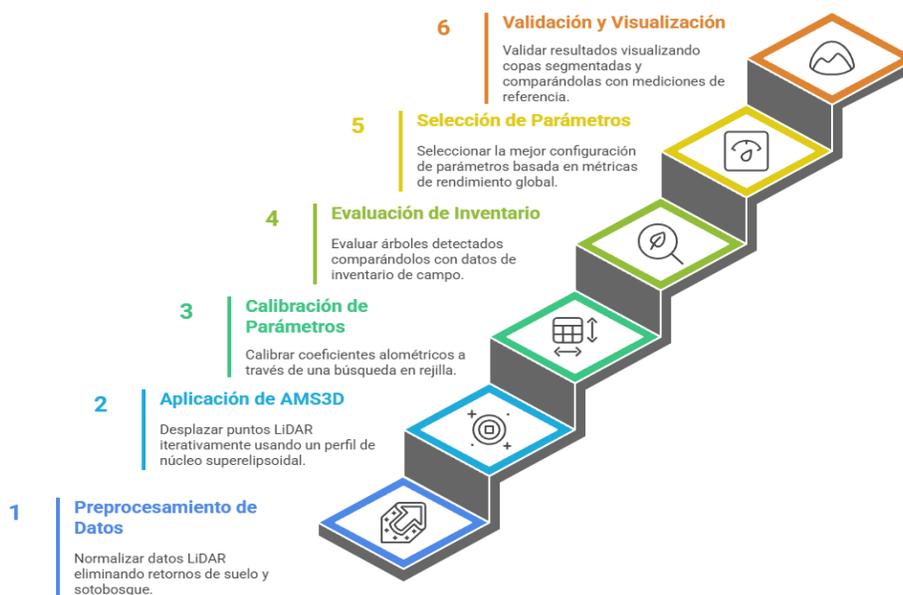


Figura 1. Flujo de trabajo de la metodología AMS3D con modelo de forma de copa.
Elaboración: Los autores.

1. Preprocesamiento de datos LiDAR

Las nubes de puntos LiDAR brutas fueron normalizadas eliminando retornos de suelo y sotobosque por debajo de 1.5 m, siguiendo la práctica común para evitar la influencia de arbustos y vegetación herbácea (Kandare et al., 2016). La elevación del terreno se modeló y se sustrajo, produciendo alturas normalizadas que garantizaron la consistencia entre parcelas de estudio y ofrecieron datos estandarizados para la segmentación.

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

2. AMS3D con modelo de copa

Cada punto LiDAR $x_i = (X_i, Y_i, Z_i)$ fue desplazado de manera iterativa hacia un modo local de densidad empleando un perfil de núcleo superelipsoidal (SE) con exponente $n = 1.5$. Esta configuración fue seleccionada porque ofreció el mejor compromiso entre la exhaustividad (*recall*) y el índice de Jaccard en parcelas de coníferas, de acuerdo con lo reportado por Tusa et al. (2021). Por ello, en este estudio no se realizó comparación con el núcleo cilíndrico.

Los parámetros iniciales del núcleo se definieron como:

$$r_k = m_1 Z_i \quad [1]$$

$$a_k = \frac{1}{2} m_2 Z_i \quad [2]$$

donde m_1 y m_2 son coeficientes alométricos, y Z_i corresponde a la altura normalizada del punto x_i . El proceso iterativo calculó el vector de desplazamiento medio hasta cumplir el criterio de convergencia $\Delta u < 10^{-7}$. La medida de convergencia Δu se definió como la distancia euclidiana entre estimaciones sucesivas del modo.

Cuando no se alcanzaba la convergencia, el ancho de banda del núcleo se ajustaba mediante el modelo elipsoidal de copa, estimando los parámetros de la misma:

$$a_t = \frac{1}{2} (h_{max} + h_{min}) \quad [3]$$

$$r_t = (h_{max})^\alpha \quad [4]$$

donde h_{max} es la altura máxima de los puntos dentro del vecindario cilíndrico de x_i , y h_{min} corresponde al umbral inferior de altura (1.5 m) utilizado para eliminar la vegetación de sotobosque. El parámetro a_t representa el semieje mayor en dirección vertical (profundidad de copa), mientras que r_t denota el radio estimado de la copa derivado de la relación alométrica con la altura del árbol.

El exponente alométrico α se obtuvo igualando el radio del perfil del núcleo con el radio de la copa a media altura:

$$\alpha = \frac{\log(m_1 a_t)}{\log(h_{max})} \quad [5]$$

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

Finalmente, el radio elipsoidal del núcleo se actualizó mediante:

$$r_{ke} = \frac{r_t}{a_t} \sqrt{2a_t Z_i - Z_i^2} \quad [6]$$

lo cual restringe el tamaño del núcleo de acuerdo con la geometría del elipsoide ajustado. En este estudio no se aplicó el modelo híbrido de copa propuesto por Ferraz (2016) y Tusa et al. (2021), que combina radios cilíndricos y elipsoidales ($r_{kh} = \min(r_{kc}, r_{ke})$), ya que se consideró que el modelo elipsoidal con $n = 1.5$ era suficiente para las condiciones experimentales.

3. Calibración de parámetros alométricos

Los coeficientes alométricos se calibraron mediante una búsqueda en rejilla sobre intervalos derivados de regresiones lineales entre altura y dimensiones de la copa. Esta calibración empírica exploró múltiples configuraciones por parcela, siguiendo las estrategias adaptativas planteadas por Hu et al. (2017) y Yan et al. (2020).

4. Evaluación frente a inventario de referencia

Los árboles detectados se emparejan con los árboles del inventario de campo utilizando la distancia euclidiana entre las copas. A partir de los pares coincidentes, se calcularon las métricas estándar:

$$\text{Exhaustividad} = \frac{TP}{N_R} \quad [7]$$

$$\text{Precisión} = \frac{TP}{N_D} \quad [8]$$

$$F1 = \frac{2 \cdot \text{Exhaustividad} \cdot \text{Precisión}}{\text{Exhaustividad} + \text{Precisión}} \quad [9]$$

donde T_p corresponde al número de verdaderos positivos, N_R al número de árboles de referencia y N_D al número de detecciones.

5. Selección global de parámetros

Dado que los parámetros óptimos pueden variar entre parcelas, los resultados se agregaron globalmente para identificar la mejor configuración de coeficientes. La selección priorizó maximizar el F1-score global y, en caso de empates, se consideraron

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

criterios adicionales como mayor número de verdaderos positivos, menor número de falsos positivos, mayor Exhaustividad y Precisión.

6. Validación y visualización:

La configuración global seleccionada se validó mediante la visualización cualitativa de las copas segmentadas y la comparación cuantitativa con mediciones de referencia. Las detecciones fueron proyectadas en el plano xy , ajustadas a formas elipsoidales y evaluadas por su plausibilidad ecológica. Esta etapa confirmó la capacidad de AMS3D con modelo de copa para capturar la variabilidad estructural en bosques con doseles complejos.

RESULTADOS

La evaluación experimental de este estudio se realizó utilizando el conjunto de datos abierto publicado por Dubrovin et al. (2024), disponible públicamente en Kaggle (<https://www.kaggle.com/datasets/sentinel3734/tree-detection-lidar-rgb/data>). Este recurso integra un inventario de campo detallado con nubes de puntos LiDAR adquiridas mediante vehículos aéreos no tripulados (UAV) y ortofotos RGB de alta resolución en bosques mixtos y densos.

El área de estudio se ubica en Perm Krai, Rusia, aproximadamente a 90 km al este del centro administrativo regional. El bosque se caracteriza por su estructura mixta y densa, con un dosel complejo e irregular. El levantamiento de campo comprende 3600 árboles distribuidos en 10 parcelas rectangulares de 100×50 m (0.5 ha cada una), con un área total de 5 ha. Todos los árboles están georreferenciados en el sistema de coordenadas UTM 40N (EPSG:32640). Para cada individuo se registró la especie y el diámetro a la altura del pecho (DAP), medido con calibradores a 1.3 m del suelo en dos direcciones perpendiculares y promediado. Aproximadamente el 20 % de los árboles cuentan con altura medida y el 10 % con edad determinada mediante núcleos de crecimiento. El inventario incluye siete especies arbóreas, distribuidas casi equitativamente entre coníferas y caducifolias: abeto, abedul, abeto blanco, álamo, tilo, aliso y sauce.

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

El levantamiento LiDAR aéreo se realizó en julio de 2021 bajo condiciones de follaje completo (leaf-on) empleando un sensor AGM-MS3 (frecuencia de adquisición de 640 kHz, alcance de 300 m). El UAV mantuvo una altitud promedio de vuelo de 150 m sobre el terreno, siguiendo el modelo de elevación SRTM. La precisión espacial de las nubes de puntos fue de 3–5 cm. El preprocesamiento incluyó eliminación de duplicados (umbral: 1 mm), filtrado de ruido y clasificación de puntos de terreno, lo que permitió normalizar las alturas. La densidad promedio en las nubes de puntos alcanzó 37 puntos/m².

La Tabla 1 resume las principales características de las 10 parcelas, incluyendo el número de árboles, el tipo de dosel dominante y la densidad promedio de puntos. Este conjunto de datos resulta especialmente adecuado para la evaluación comparativa de algoritmos de segmentación de árboles individuales, al combinar una referencia confiable de campo con información remota multimodal densa.

Tabla 1.

Resumen de las 10 parcelas forestales incluidas en el conjunto de datos.

Parcela	Número de árboles	Tipo dominante	Densidad de puntos (pts/m ²)
1	420	Caducifolio	31.7
2	365	Caducifolio	47.9
3	332	Caducifolio	40.3
4	261	Conífero	33.5
5	208	Conífero	14.2
6	290	Conífero	39.1
7	408	Caducifolio	41.9
8	341	Conífero	35.5
9	490	Mixto	38.2
10	485	Mixto	36.8
Total	3600	--	--

Elaboración: Adaptado de Dubrovin et al. (2024).

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

Este conjunto de datos resulta especialmente adecuado para la evaluación comparativa de algoritmos de segmentación de árboles individuales, ya que combina una referencia confiable obtenida mediante mediciones de campo con datos de teledetección multimodal de alta densidad.

La Tabla 2 sintetiza el rendimiento de segmentación obtenido al explorar una malla de parámetros de 3x3 para los coeficientes alométricos m_1 y m_2 , siguiendo la metodología propuesta por Tusa et al. (2021). Este diseño experimental respondió a la ausencia de mediciones de referencia de dimensiones de copa en los datos de campo disponibles, lo que impidió una calibración directa de las relaciones alométricas.

Tabla 2.

Resultados globales de la segmentación de árboles según combinaciones de parámetros (m_1, m_2).

m_1	m_2	N_D	TP	FD	<i>Exhaustividad</i>	<i>Precisión</i>	<i>F1 – score</i>
0.131	0.143	13757	3050	10707	0.847	0.222	0.351
0.131	0.786	12891	2835	10056	0.787	0.22	0.344
0.131	0.969	12905	2795	10110	0.776	0.217	0.339
0.025	0.143	2889	914	1975	0.254	0.316	0.282
0.025	0.969	2841	893	1948	0.248	0.314	0.277
0.025	0.786	2850	885	1965	0.246	0.311	0.274
0.316	0.143	20558	2972	17586	0.825	0.145	0.246
0.316	0.969	19193	2743	16450	0.762	0.143	0.241
0.316	0.786	19038	2703	16335	0.75	0.142	0.239

Nota: N_D : Árboles detectados; TP : Verdaderos positivos; FD : Falsas detecciones; *Exhaustividad*: proporción de árboles de referencia correctamente detectados; *Precisión*: proporción de árboles detectados que son correctos; *F1-score*: media armónica de *Precisión* y *Exhaustividad*; $N_R = 3600$.

Elaboración: Los autores.

La Tabla 3 detalla los resultados de segmentación obtenidos por parcela, los cuales pueden interpretarse en el contexto de la composición forestal. En términos generales, los resultados revelan contrastes significativos entre rodales caducifolios, coníferos y

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

mixtos, lo que resalta la influencia de la estructura del dosel en el equilibrio entre *exhaustividad* y *precisión*.

Tabla 3.

Resultados de segmentación por parcela.

<i>Plot</i>	<i>Exhaustividad</i>	<i>Precisión</i>	<i>F1 – score</i>	<i>Distancia</i>
1	0.657	0.381	0.483	1.454
2	0.86	0.22	0.35	1.212
3	0.861	0.205	0.332	1.235
4	0.939	0.151	0.261	1.12
5	0.99	0.115	0.207	0.895
6	0.89	0.191	0.314	1.238
7	0.85	0.273	0.413	1.279
8	0.93	0.212	0.345	1.091
9	0.791	0.3	0.435	1.249
10	0.846	0.297	0.439	1.164

Elaboración: Los autores.

La Figura 2 ilustra el mejor resultado de segmentación, correspondiente a la Parcela 1, que alcanzó el F1 más alto (0.483). Este caso ejemplifica el equilibrio más favorable entre *exhaustividad* y *precisión* en todo el conjunto, confirmando que el núcleo AMS3D puede delinear eficazmente las copas dominantes en condiciones favorables, particularmente en rodales caducifolios con densidad de puntos moderada.

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

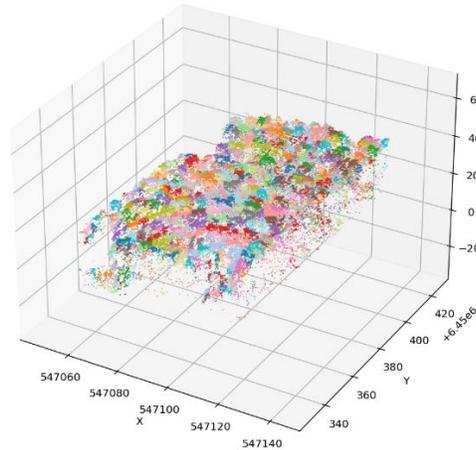


Figura 2. Ejemplo de la mejor parcela segmentada obtenida con la combinación de parámetros seleccionada (m_1, m_2).

Elaboración: Los autores.

DISCUSIÓN

Los resultados de la Tabla 3 ponen de manifiesto varias fortalezas del enfoque. En primer lugar, las parametrizaciones con $m_1 = 0.131$ mostraron valores de *exhaustividad* consistentemente altos (0.776–0.847), lo que confirma la robustez del perfil de núcleo AMS3D para detectar una gran proporción de árboles de referencia. En particular, la configuración $m_1 = 0.131$ y $m_2 = 0.143$ logró el mejor equilibrio entre tasa de detección y exactitud espacial, alcanzando una *exhaustividad* de 0.847 y un F1-score de 0.351. Estos hallazgos corroboran estudios previos sobre la adaptabilidad de los anchos de banda del *mean shift* a la geometría de las copas en rodales dominados por coníferas (Hu et al., 2017; Yan et al., 2020; Lei et al., 2022).

No obstante, emergen limitaciones relevantes. La *exhaustividad* alta se logra a costa de una baja precisión (≈ 0.22), reflejando numerosos falsos positivos. Los anchos de banda pequeños ($m_1 = 0.025$) reducen drásticamente la *exhaustividad*, mientras que valores mayores ($m_1 = 0.316$) incrementan los falsos positivos y disminuyen la precisión por debajo de 0.15. Estos resultados subrayan el compromiso inherente en la segmentación

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

mean shift: maximizar la *exhaustividad*, tiende a causar sobresegmentación, mientras que priorizar la precisión reduce la exhaustividad (Xiao et al., 2019).

En síntesis, la malla de parámetros ilustra la sensibilidad del algoritmo AMS3D frente a la elección de coeficientes alométricos. Su principal fortaleza radica en la capacidad de detección robusta (*exhaustividad* alta), pero su limitación es la sobresegmentación sistemática y la baja precisión, especialmente en rodales estructuralmente complejos con copas superpuestas.

Sobre los resultados descritos en la Tabla 3, en las parcelas caducifolias (1, 2, 3 y 7), la *exhaustividad* varió entre 0.657 y 0.861, mientras que la *precisión* permaneció modesta (0.205–0.381). La parcela 1 alcanzó el equilibrio más favorable ($F1 = 0.483$), en contraste con las parcelas 2 y 3, que presentaron precisiones muy bajas pese a altos valores de *exhaustividad*. Este patrón refleja la irregularidad de las copas y el solapamiento de ramas en especies de hoja ancha, que incrementan las detecciones falsas. En la parcela 7, con la mayor densidad de árboles dentro de las caducifolias, se alcanzó un $F1$ de 0.413, lo que sugiere que la mayor densidad de copas proporciona máximos locales más consistentes, aunque con cierta sobresegmentación.

Los rodales de coníferas (parcelas 4, 5, 6 y 8) exhibieron los valores más altos de *exhaustividad*, destacando la parcela 5 con 0.990. Sin embargo, ello se acompañó de una *precisión* muy baja (0.115) y el menor $F1$ -score del conjunto (0.207). Esta marcada asimetría indica que, aunque las copas dominantes fueron detectadas de manera confiable, el algoritmo tendió a sobresegmentar copas cónicas bajo parámetros de núcleo fijos. Las parcelas 4, 6 y 8 mostraron un comportamiento similar: *exhaustividad* elevada (0.890–0.939) pero *precisión* menor al 0.21.

En los rodales mixtos (parcelas 9 y 10), el algoritmo alcanzó los resultados más equilibrados, con $F1$ -scores de 0.435–0.439 y precisiones cercanas al 0.30, manteniendo *exhaustividad* entre 0.791 y 0.846. La heterogeneidad de especies parece mitigar sesgos sistemáticos: las copas caducifolias reducen la fragmentación excesiva de coníferas,

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

mientras que las copas de coníferas incrementan la completitud, produciendo un compromiso más estable entre errores de omisión y comisión.

En cuanto a la exactitud posicional, los errores medios en distancia XY oscilaron entre 0.895 m y 1.454 m. Las parcelas caducifolias presentaron desviaciones mayores, como en el caso de la parcela 1 (1.454 m), asociadas a la geometría irregular de las copas. Por el contrario, las parcelas de coníferas, particularmente la parcela 5 (0.895 m), registraron menores errores debido a la simetría de sus copas. Los rodales mixtos se situaron en un rango intermedio (1.164–1.249 m).

En síntesis, los rodales caducifolios evidencian los desafíos que plantean las copas irregulares, los coníferos logran elevados niveles de detección con baja precisión, y los rodales mixtos ofrecen el mejor compromiso. Estos hallazgos confirman que la composición forestal influye directamente en el desempeño de la segmentación y refuerzan la necesidad de modelos adaptativos de forma de copa para reducir falsas detecciones en rodales homogéneos (Hu et al., 2017; Tusa et al., 2021; Yan et al., 2020).

CONCLUSIONES

Este estudio evaluó el algoritmo *Adaptive Mean Shift 3D* (AMS3D) con modelado de forma de copa para la segmentación de árboles individuales a partir de datos LiDAR. Los experimentos demostraron que el método fue altamente efectivo en la detección de árboles de referencia, con valores de *recall* consistentemente superiores a 0.75 en la mayoría de las parametrizaciones. Esta fortaleza fue particularmente evidente en rodales de coníferas y mixtos, donde las copas simétricas o heterogéneas facilitaron una identificación robusta de los ápices. No obstante, la precisión se mantuvo baja en todas las parcelas debido a la sobresegmentación sistemática, especialmente en rodales homogéneos de coníferas donde el algoritmo tendió a dividir en exceso las copas. Las parcelas caducifolias evidenciaron la dificultad adicional de las geometrías irregulares y las copas superpuestas, mientras que los rodales mixtos alcanzaron el equilibrio más estable entre errores de omisión y comisión.

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

Estos hallazgos confirman el potencial del AMS3D con núcleos informados, a la vez que subrayan su sensibilidad frente a la elección de los parámetros alométricos. Futuros trabajos deberían explorar estrategias para automatizar la estimación de m_1 y m_2 , mediante segmentaciones bidimensionales preliminares de modelos de altura de copa, reduciendo así el ajuste manual. Otra dirección es la integración de datos multimodales, en particular la información RGB disponible en el conjunto de datos, con el fin de mejorar la delimitación de los límites de copa. Finalmente, se recomienda realizar estudios comparativos con enfoques de aprendizaje profundo, dado que estos métodos pueden aprovechar información estructural más rica, aunque requieren delineaciones de copa más coherentes. Tales extensiones contribuirán a potenciar el uso de AMS3D en inventarios forestales y aplicaciones ecológicas.

FINANCIAMIENTO

No monetario.

AGRADECIMIENTO

Expreso mi más sincero agradecimiento al Programa de Maestría en Matemática Aplicada, Mención Matemática Computacional, de la Universidad Nacional de Chimborazo, por brindarme la oportunidad de formarme académicamente y desarrollar esta investigación en un entorno de excelencia académica y científica.

REFERENCIAS CONSULTADAS

Álvarez Mendoza, C. I., Mollocana, J. G., y Gualotuna, D. (2024). Mapping of NDVI in Ecuador during the last 20 years using the Google Earth Engine cloud geospatial tool. En M. V. García, C. Gordón-Gallegos, A. Salazar-Ramírez & C. Nuñez (Eds.), *Proceedings of the International Conference on Computer Science, Electronics and Industrial Engineering (CSEI 2023)*. Springer Nature. https://doi.org/10.1007/978-3-031-70981-4_1

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

- Aubry Kientz, M., Dutrieux, R., Ferraz, A., Saatchi, S., Hamraz, H., Williams, J., Coomes, D., Piboule, A., y Vincent, G. (2019). A comparative assessment of the performance of individual tree crowns delineation algorithms from ALS data in tropical forests. *Remote Sensing*, 11(9), 1086. <https://doi.org/10.3390/rs11091086>
- Chen, W., Hu, X., Chen, W., Hong, Y., y Yang, M. (2018). Airborne LiDAR remote sensing for individual tree forest inventory using trunk detection-aided mean shift clustering techniques. *Remote Sensing*, 10(7), 1078. <https://doi.org/10.3390/rs10071078>
- Comesaña Cebral, L., Martínez Sánchez, J., Lorenzo, H., & Arias, P. (2021). Individual tree segmentation method based on mobile backpack LiDAR point clouds. *Sensors*, 21(18), 6007. <https://doi.org/10.3390/s21186007>
- Crowther, T. W., Glick, H. B., Covey, K. R., Bettigole, C., Maynard, D. S., Thomas, S. M., Bradford, M. A. (2015). Mapping tree density at a global scale. *Nature*, 525(7568), 201–205. <https://doi.org/10.1038/nature14967>
- Deng, S., Jing, S., & Zhao, H. (2024). A hybrid method for individual tree detection in broadleaf forests based on UAV-LiDAR data and multistage 3D structure analysis. *Forests*, 15(6), 1043. <https://doi.org/10.3390/f15061043>
- Dubrovin, I., Fortin, C., & Kedrov, A. (2024). An open dataset for individual tree detection in UAV LiDAR point clouds and RGB orthophotos in dense mixed forests. *Scientific Reports*, 14(1), 72669. <https://doi.org/10.1038/s41598-024-72669-5>
- Ferraz, A., Saatchi, S., Mallet, C., & Meyer, V. (2016). Lidar detection of individual tree size in tropical forests. *Remote Sensing of Environment*, 183, 318–333. <https://doi.org/10.1016/j.rse.2016.05.028>
- Henrich, J., van Delden, J., Seidel, D., Kneib, T., & Ecker, A. S. (2024). TreeLearn: A deep learning method for segmenting individual trees from ground-based LiDAR forest point clouds. *Ecological Informatics*, 84, 102888. <https://doi.org/10.1016/j.ecoinf.2024.102888>
- Hua, Z., Xu, S., & Liu, Y. (2022). Individual tree segmentation from side-view LiDAR point clouds of street trees using Shadow-Cut. *Remote Sensing*, 14(22), 5742. <https://doi.org/10.3390/rs14225742>
- Hu, X., Chen, W., & Xu, W. (2017). Adaptive mean shift-based identification of individual trees using airborne LiDAR data. *Remote Sensing*, 9(2), 148. <https://doi.org/10.3390/rs9020148>

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

- Hui, Z., Li, N., Xia, Y., Cheng, P., & He, Y. (2021). Individual tree extraction from UAV LiDAR point clouds based on self-adaptive mean shift segmentation. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, V(1), 25–30. <https://doi.org/10.5194/isprs-annals-V-1-2021-25-2021>
- Jakubowski, M. K., Li, W., Guo, Q., & Kelly, M. (2013). Delineating individual trees from lidar data: A comparison of vector- and raster-based segmentation approaches. *Remote Sensing*, 5(9), 4163–4186. <https://doi.org/10.3390/rs5094163>
- Kandare, K., Ørka, H. O., Chan, J. C. W., & Dalponte, M. (2016). Effects of forest structure and airborne laser scanning point cloud density on 3D delineation of individual tree crowns. *European Journal of Remote Sensing*, 49(1), 337–359. <https://doi.org/10.5721/EuJRS20164919>
- Lei, L., Yin, T., Chai, G., Li, Y., Wang, Y., Jia, X., & Zhang, X. (2022). A novel algorithm of individual tree crowns segmentation considering three-dimensional canopy attributes using UAV oblique photos. *International Journal of Applied Earth Observation and Geoinformation*, 112, 102893. <https://doi.org/10.1016/j.jag.2022.102893>
- Qi, C. R., Su, H., Mo, K., & Guibas, L. J. (2017). *PointNet: Deep learning on point sets for 3D classification and segmentation*. En Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (pp. 77–85). IEEE. <https://doi.org/10.1109/CVPR.2017.16>
- Tusa, E., Monnet, J. M., Barre, J. B., Dalla Mura, M., Dalponte, M., & Chanussot, J. (2021). Individual tree segmentation based on mean shift and crown shape model for temperate forest. *IEEE Geoscience and Remote Sensing Letters*, 18(12), 2052–2056. <https://doi.org/10.1109/LGRS.2020.3012718>
- Xiao, W., Zaforemska, A., Smigaj, M., Wang, Y., & Gaulton, R. (2019). Mean shift segmentation assessment for individual forest tree delineation from airborne LiDAR data. *Remote Sensing*, 11(11), 1263. <https://doi.org/10.3390/rs11111263>
- Xiao, W., Xu, S., Oude Elberink, S., & Vosselman, G. (2016). Individual tree crown modeling and change detection from airborne LiDAR data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(8), 3467–3477. <https://doi.org/10.1109/JSTARS.2016.2541780>

Eduardo Alejandro Tusa-Jumbo; Tania Calle-Jiménez

- Yang, Z., Su, Y., Li, W., Cheng, K., Guan, H., Ren, Y., Hu, T., Xu, G., & Guo, Q. (2024). Segmenting individual trees from terrestrial LiDAR data using tree branch directivity. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 956–969. <https://doi.org/10.1109/JSTARS.2023.3334014>
- Yan, W., Guan, H., Cao, L., Yu, Y., Li, C., & Lu, J. Y. (2020). A self-adaptive mean shift tree-segmentation method using UAV LiDAR data. *Remote Sensing*, 12(3), 515. <https://doi.org/10.3390/rs12030515>
- You, H., Liu, Y., Lei, P., Qin, Z., & You, Q. (2023). Segmentation of individual mangrove trees using UAV-based LiDAR data. *Ecological Informatics*, 77, 102200. <https://doi.org/10.1016/j.ecoinf.2023.102200>
- Yu, J., Lei, L., & Li, Z. (2024). Individual tree segmentation based on seed points detected by an adaptive crown shaped algorithm using UAV-LiDAR data. *Remote Sensing*, 16(5), 825. <https://doi.org/10.3390/rs16050825>
- Zhu, L. (2024). *GeoSep-PointNet++: A 3D point cloud semantic segmentation algorithm based on geometric information enhancement and feature separation encoding*. En Proceedings of the 2024 IEEE 4th International Conference on Information Technology, Big Data and Artificial Intelligence (ICIBA) (pp. 1514–1519). IEEE. <https://doi.org/10.1109/ICIBA62489.2024.10869004>