



2025 | **16-20**
GIJÓN | **JUNIO**

9º CONGRESO FORESTAL ESPAÑOL

9CFE-1658

Actas del Noveno Congreso Forestal Español
Edita: **Sociedad Española de Ciencias Forestales. 2025.**
ISBN: **978-84-941695-7-1**

Organiza





Mejorando la descripción automática de fustes mediante estimación robusta de diámetros a partir de datos LiDAR

GARCÍA PASCUAL, B. (1,2), MARTÍN CORTÉS, C. (3), ACUNA, M. (2), KÄRHÄ, K. (1), LOPATIN, E. (2), VÄÄTÄINEN, K. (2), HOLMSTRÖM, E. (2).

(1) Facultad de Ciencias Forestales, Universidad de Finlandia Oriental (UEF).

(2) Unidad de Tecnología Forestal y de la Madera (MEPU), Centro de Recursos Naturales de Finlandia (Luke).

(3) Unidad mixta de investigación (JRU) CTFC - AGROTECNIO.

Resumen

La estimación precisa de diámetros a partir de datos LiDAR permite caracterizar el volumen y la forma de los fustes sin necesidad de aplicar métodos destructivos. Para ello, se ajustan círculos a diferentes alturas del fuste mediante métodos estadísticos. No obstante, estos métodos son susceptibles a la presencia de ruido en la nube de puntos, normalmente causado por la presencia de obstáculos, fenómenos meteorológicos, o por errores en las mediciones láser. Esto reduce la viabilidad de su aplicación a nubes de puntos obtenidas mediante sensores de bajo coste, cuyos datos suelen ser menos precisos y más ruidosos.

En el presente trabajo se describe un nuevo método capaz de estimar con precisión diámetros a diferentes alturas a partir de nubes de puntos ruidosas, incompletas o con presencia de ramas y follaje. Para ello, se han utilizado métodos estadísticos robustos y simulación Monte Carlo para filtrar la nube de puntos. Además, se han utilizado las estimaciones más fiables para corregir de manera iterativa los diámetros adyacentes. De este modo, se han obtenido estimaciones precisas aun cuando la calidad de los datos dificulta el uso de otros métodos, haciendo más viable la aplicación de escáneres láser móvil (MLS) de bajo coste para caracterizar fustes de manera automática.

Palabras clave

Caracterización de fustes, escáner láser móvil, estimación de diámetros, perfil de fuste.

1. Introducción

El desarrollo de la tecnología LiDAR (acrónimo del inglés, *Light Detection and Ranging*) ha permitido efectuar inventarios forestales sin necesidad de efectuar mediciones manuales (LIANG et al., 2016). Estos inventarios se efectúan típicamente detectando los árboles en la nube de puntos y ajustando círculos regularmente a lo largo de cada fuste. Esto último permite estimar no solo el volumen de cada árbol, sino también la forma del fuste y su ecuación de perfil (OLOFSSON y HOLMGREN, 2016; PRENDES et al., 2021; NURUNNABI et al., 2024). Por ejemplo, PRENDES et al. (2022) emplearon datos LiDAR obtenidos mediante TLS (acrónimo del inglés *Terrestrial Laser Scanning*) para estimar la curvatura del fuste en diferentes tramos para así optimizar el tronzado de fuste.

La aparición de sensores láser móviles (MLS) de bajo coste ha facilitado el escaneo de grandes superficies, permitiendo realizar inventarios forestales en zonas amplias de manera rápida y semiautomática. No obstante, los sensores MLS suelen generar nubes de puntos menos precisas y más ruidosas (BIENERT et al., 2018). Además, la presencia de ramas, arbustos, así como las condiciones meteorológicas, pueden generar ruido adicional o nubes de puntos incompletas, donde parte del tronco permanece ocluido (WILKES et al., 2017). Esto hace necesario el uso de métodos de estimación de diámetros capaces de lidiar con el



ruido y la oclusión.

El método más simple es el de optimización por mínimos cuadrados, algoritmo que utilizan autores como HENNING & RADTKE (2006). No obstante, existen otros métodos más resilientes a la presencia de ruido. Por ejemplo, TROTCHTA et al. (2017) emplean una versión aleatorizada de la transformada de Hough (XU & OJA, 1993) para estimar diámetros. En cuanto a LAINO et al. (2024), emplearon el algoritmo DBSCAN para eliminar ruido cuando el ajuste por mínimos cuadrados resulta deficiente. Finalmente, NURUNNABI et al. (2024) recurren al uso de métodos estadísticos robustos y de simulación Monte Carlo para ignorar el ruido durante el ajuste de círculos.

Aun con todo, estos métodos siguen siendo susceptibles al ruido y a la oclusión de los fustes. Esto provoca que ofrezcan estimaciones poco precisas cuando las secciones analizadas son de baja calidad. No obstante, resulta plausible pensar que una buena estimación sirva para corregir otra errónea cuando estas son adyacentes. Esto se debe a que cualquier fuste varía en forma y en diámetro gradualmente con la altura. Por tanto, dada una distancia entre secciones suficientemente pequeña, tanto el diámetro como el centro de los círculos ajustados debiera ser similar.

Así pues, en este trabajo se presenta un nuevo algoritmo de ajuste de círculos que parte de esta intuición para mejorar el método desarrollado por NURUNNABI et al. (2024). De este modo, esperamos contribuir al desarrollo de herramientas capaces de lidiar de manera efectiva con el ruido y los datos incompletos.

2. Objetivos

El presente trabajo tiene como objetivo principal desarrollar y validar un nuevo algoritmo de ajuste de círculos capaz de corregir estimaciones inexactas a partir de la información disponible en secciones adyacentes del fuste. Este propósito se desglosa en los siguientes objetivos específicos:

1. Integrar la hipótesis de continuidad en la forma del fuste para corregir errores de estimación en secciones con datos deficientes.
2. Evaluar la precisión y robustez del método propuesto frente a los enfoques anteriormente descritos en escenarios con diferentes niveles de ruido y oclusión.

3. Metodología

Datos empleados

Para la presente investigación se emplearon datos provenientes de la base de datos abierta TreeScope (CHENG et al., 2023). En particular, se trabajó con el grupo de datos denominado “VAT-0723M”, que contiene 75 ejemplares de *Pinus taeda* L. escaneados con el sensor LiDAR Ouster OS0-128 rev7. Este dispositivo se usó para captar información 3D de manera continua mientras se desplazaba alrededor del árbol, generando nubes de puntos de alta densidad. Para cada ejemplar, los autores midieron el diámetro a 1,37 m de altura, es decir, diámetro a la altura del pecho (DAP), y generaron nubes de puntos individuales.

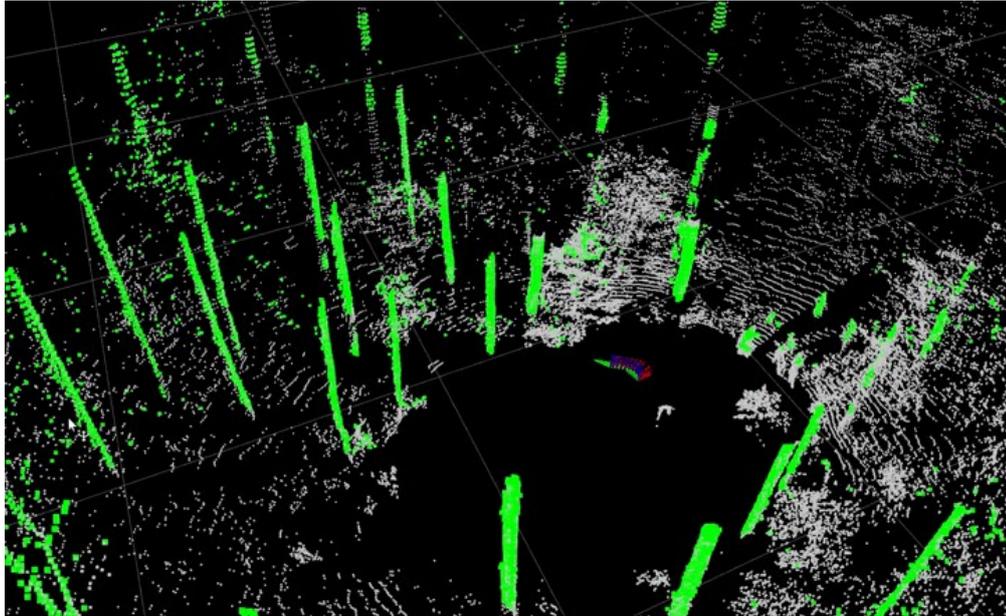


Figura 1. Fotograma LiDAR empleado en la generación de la base de datos TreeScope; los puntos verdes se corresponden con fustes. Fuente: CHENG et al. (2023).

Durante la revisión preliminar de la calidad de las nubes, se identificó que el archivo “VAT-0723M-03_tree50” presentaba un nivel de ruido y pérdida de datos tal que resultaba imposible identificar el fuste. Por tanto, se decidió eliminar del análisis, mientras que el resto de las nubes se conservaron.

Preprocesamiento de las nubes de puntos

Con el fin de estandarizar la orientación de las nubes de puntos, se empleó un análisis de componentes principales (PCA, por sus siglas en inglés). Este procedimiento permite determinar el eje principal del tronco y alinear la nube de tal manera que el eje vertical (Z) coincida con la dirección del fuste.

Como punto de referencia, se extrajo una primera sección a la altura 1,37 m (DAP). Para ello se consideró un espesor de 7 cm; esto es, 3,5 cm por encima y por debajo de la marca de 1,37 m. Esta sección se proyectó entonces en el plano XY con el objeto de ajustar círculos e inferir el centro y el diámetro del tronco. Adicionalmente, para caracterizar la forma completa del fuste, se dividió la nube en cortes transversales cada 3,5 cm de altura, manteniendo el mismo espesor de 7 cm. De esta manera se obtuvo una serie de secciones a lo largo del fuste, generando un perfil detallado del tronco.

Algoritmo de corrección iterativa

El método propuesto se basa en el algoritmo descrito por NURUNNABI et al. (2024), de ahora en adelante denominado HyperRLTS. Este algoritmo inicia seleccionando tres puntos aleatorios de la nube para definir un círculo. Este paso se repite 69 veces, siguiendo las directrices de NURUNNABI et al. (2015). A continuación, para cada círculo generado, se calcula la distancia de todos los puntos de la nube a su perímetro y se ordenan dichos puntos en función de esa distancia. Seguidamente, se toma el 50% de los puntos más próximos al perímetro y, mediante el método Hyper (KANATANI y RANGARAJAN, 2011), se efectúa un ajuste adicional del círculo. Finalmente, de entre todos los círculos ensayados, se selecciona aquel que arroja el menor error cuadrático medio al ser evaluado sobre



ese 50% de los puntos más cercanos.

Nuestro método difiere del anterior en que añade un módulo de corrección iterativa para secciones contiguas, partiendo de la hipótesis de que el fuste cambia gradualmente en diámetro y posición del centro. Para ello, se aplica una ventana deslizante que abarca 10 secciones contiguas, ajustando un círculo en cada sección mediante HyperRLTS. Seguidamente, se identifica el subconjunto de secciones cuya variabilidad en el ajuste de círculos sea mínima, ya que se asume que estos datos son de mejor calidad. La variabilidad del grupo se determina ajustando tres modelos de regresión lineal para estimar las coordenadas X e Y, así como el radio, en función de la altura. Tras esto, el error cuadrático relativo de estos modelos se promedia como sigue:

$$Err_{CR} = \frac{1}{M} \sum_{m=1}^M \frac{1}{N} \sum_{i=1}^N \frac{y_{m,i} - \hat{y}_{m,i}}{y_{m,i} + \bar{y}_m}^2$$

Donde M es el número de modelos, m es el modelo que relaciona una de las variables con la altura, $y_{m,i}$ es el valor de referencia para el modelo m y la muestra i , $\hat{y}_{m,i}$ es la predicción del modelo m para la muestra i y \bar{y}_m es el promedio de los valores de referencia para el modelo m .

Entonces, se localizan valores anómalos como aquellos con un valor mayor a 2,5 (para más información revítese NURUNNABI et al. (2015)). En caso de haberlos, se recurre de nuevo a tres modelos de regresión lineal para predecir la ubicación y el radio de los círculos en este grupo a partir de la altura. Estas predicciones sustituyen entonces los valores anómalos. El grupo resultante de 10 secciones se emplea entonces como referencia para corregir el resto de los círculos ajustados (véase la Figura 2).

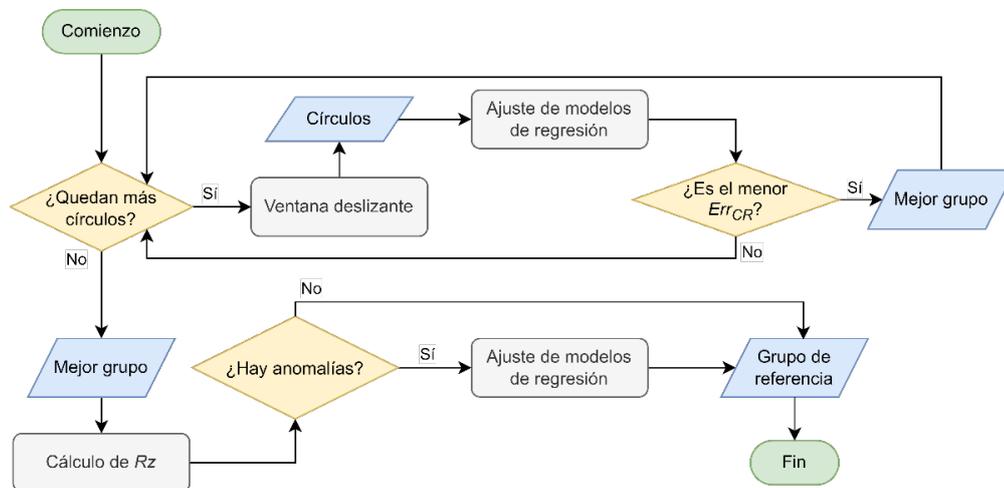


Figura 2. Diagrama de flujo que muestra el funcionamiento del algoritmo de identificación y corrección del grupo de círculos de referencia. Fuente: elaboración propia.

A continuación, se mide el grado de solape entre el último círculo perteneciente al grupo de referencia y el nuevo círculo ajustado. En caso de que el Índice de Jaccard (IoU) sea superior o igual a sea mayor de 0,75, se acepta el círculo como válido y se incorpora al grupo de referencia. Por el contrario, si el IoU no alcanza dicho umbral, se recorta la nube de puntos circularmente usando diferentes radios de corte, pero siempre partiendo del centro del último círculo del grupo de referencia. En cuanto al índice de Jaccard, este viene definido por la expresión:

$$IoU = SR \cap SASR \cup SA$$

Donde SR_{se} corresponde con la superficie del último círculo de referencia y SA_{se} corresponde con la superficie del círculo inmediatamente adyacente.

Cada uno de estos nuevos círculos se evalúa de manera iterativa mediante un procedimiento tipo Monte Carlo, donde se mide nuevamente el IoU con el círculo de referencia. Para ello, se sigue el mismo procedimiento que en HyperRLTS. Sin embargo, una vez ordenados los círculos por calidad del ajuste, se toma aquel cuyo IoU con el círculo de referencia resulta mayor de entre los cinco mejores círculos.

Además de esto, se incorporan secciones adyacentes de manera progresiva (hasta un máximo de 10 secciones) repitiendo en cada paso el procedimiento anterior. Esta estrategia permite integrar la información de otras partes del fuste en el ajuste de círculos y preservar la forma de este incluso en escenarios con oclusión. Finalmente, se toma como nueva referencia el círculo con el mayor IoU respecto del último círculo de referencia de entre todos los ajustados (véase Figura 3).

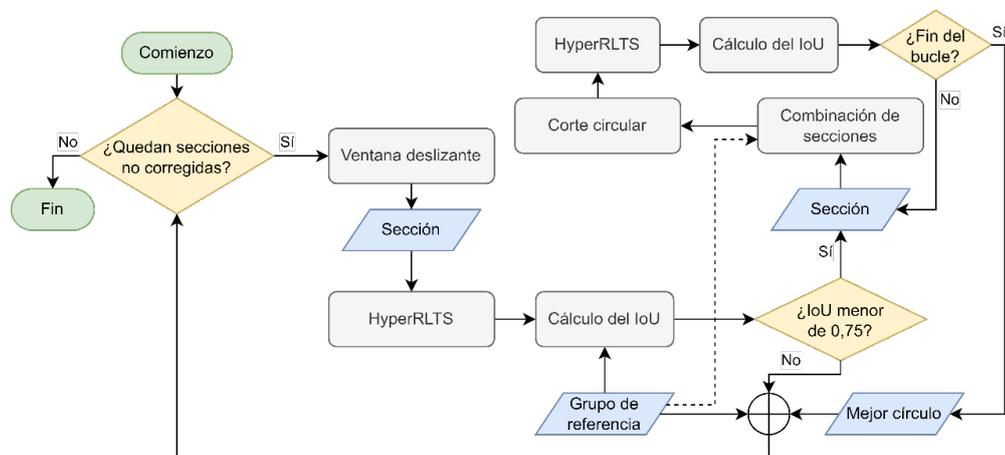


Figura 3. Diagrama de flujo que muestra el funcionamiento del módulo de corrección de ajustes errados. Fuente: elaboración propia.

Validación del método

Con el fin de validar nuestro algoritmo, lo comparamos con los métodos de ajuste de círculos por mínimos cuadrados (LS), de TROTCHTA et al. (2017) (RHT), de LAINO et al. (2024) (3DFin) y de NURUNNABI et al. (2024) (HyperRLTS). Estas predicciones sirvieron para estimar el DAP y así obtener la desviación respecto de los datos de referencia para cada método. Además, puesto que algunos algoritmos introducen aleatoriedad en el proceso, la validación se efectuó 40 veces tras lo cual se calculó el promedio de los errores obtenidos.

Por otra parte, cabe destacar que 3DFin es capaz de determinar si una predicción es satisfactoria basándose en el número de puntos incluidos dentro del círculo y en el número de puntos alrededor del perímetro. No obstante, en la presente comparativa se incluyeron todas las predicciones fuesen correctas o no.

4. Resultados

Los resultados obtenidos se presentan en la Tabla 1, donde se muestran los valores promedio y la desviación estándar (entre paréntesis) de las tres métricas de error consideradas: error (cm), error absoluto (cm) y error cuadrático medio (cm²). Estos valores corresponden a los métodos de mínimos cuadrados (LS),

transformada de Hough randomizada (RHT), 3DFin, HyperRLTS y la propuesta en este trabajo (“Nuestro”).

Tabla 1. Valores promedio del error (cm), error absoluto (cm) y error cuadrático (cm²) para los diversos métodos testados; desviación estándar entre paréntesis.

Método	Error	Error absoluto	Error cuadrático		
LS	10,13 (52,16)	11,34 (51,91)	2786,5 (22696,9)		
RHT	3,45 (14,70)	4,99 (14,25)	225,2 (1691,0)		
3DFin	0,97	(7,66)	4,53 (6,23)	58,8 (185,6)	
HyperRLTS	3,86 (10,82)	5,12 (10,27)	130,3 (740,1)		
Nuestro	1,57 (3,93)	2,94 (3,02)	17,7 (42,3)

Los resultados indican que el método LS exhibe el mayor error promedio (10,13 cm) y la mayor desviación estándar (52,16 cm), revelando estimaciones poco precisas y muy variables. Por su parte, RHT registra un error medio de 3,45 cm y un error absoluto de 4,99 cm, ambos considerablemente inferiores a los de LS, aunque todavía con desviaciones estándar elevadas (alrededor de 14 cm). En cuanto a 3DFin, sobresale por su error promedio relativamente bajo (0,97 cm), aunque el error absoluto (4,53 cm) evidencia algunas desviaciones. Su error cuadrático medio (58,8 cm²) sugiere un ajuste más estable frente al ruido que los métodos LS y RHT.

El método HyperRLTS muestra un error promedio de 3,86 cm y un error absoluto de 5,12 cm, con desviaciones estándar moderadas (entre 10 y 11 cm) y un error cuadrático medio de 130,3 cm², posicionándose entre RHT y 3DFin en cuanto a rendimiento. Finalmente, la propuesta presentada en este trabajo sobresale gracias a su bajo error promedio (1,57 cm) y error absoluto (2,94 cm), junto con desviaciones estándar significativamente menores (3,93 cm y 3,02 cm, respectivamente). Además, el error cuadrático medio (17,7 cm²) es el más bajo de todos los métodos analizados, lo que apunta a una gran coherencia en la detección y corrección de estimaciones anómalas.

Una representación gráfica de los resultados puede encontrarse en la Figura 4.

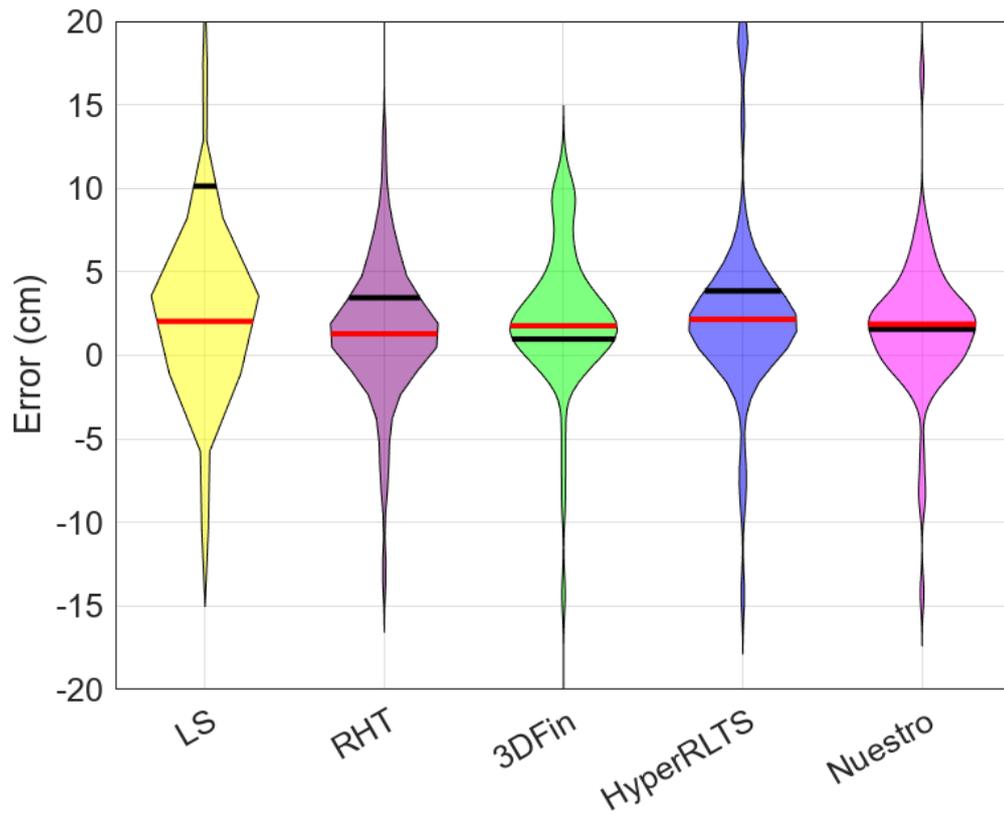


Figura 4. Diagrama de violín donde se muestra la distribución de los errores para cada método testado; la media del error representada con una barra horizontal negra, mientras que su mediana se representa con una barra horizontal roja. Fuente: elaboración propia.

Aunque no se pudo cuantificar la desviación de los centroides respecto del eje del tronco, los resultados se evaluaron visualmente. Como puede observarse en la Figura 5, nuestro método consiguió ofrecer una predicción acorde a la posición real del fuste aún en condiciones desfavorables. Otros métodos se ven fuertemente afectados por la presencia de ramas o sotobosque, así como por la oclusión parcial de la nube de puntos.

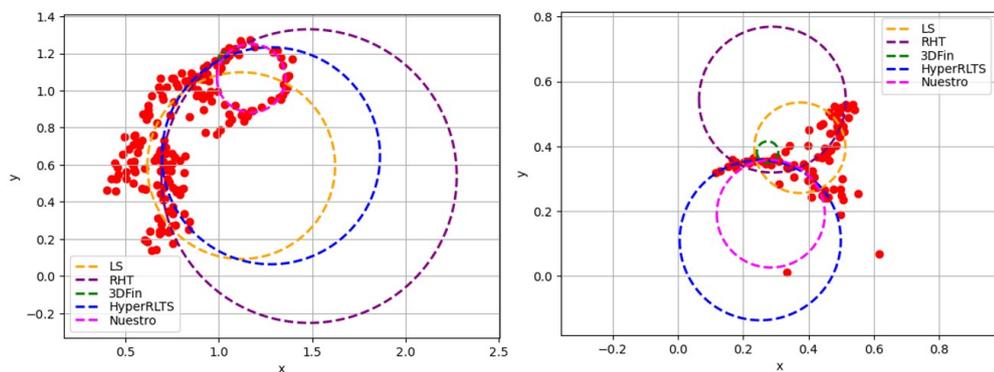


Figura 5. Ajuste de círculos empleando diversos métodos bajo presencia de ramas y arbustos (izquierda) y bajo condiciones de oclusión severa (derecha). Fuente: elaboración propia.

El ajuste de círculos a lo largo del fuste también se evaluó visualmente, dada la falta de datos de referencia. Un ejemplo de los resultados obtenidos se muestra en

la Figura 6. Como puede observarse, el error en la estimación del diámetro y de la ubicación de los círculos se acentúa en las zonas superiores e inferiores del fuste, donde las nube de puntos tienden a ser de menor calidad. Además, en los extremos superior e inferior del fuste, la oclusión provocó que el módulo de corrección iterativa fuese incapaz de ofrecer resultados fiables.

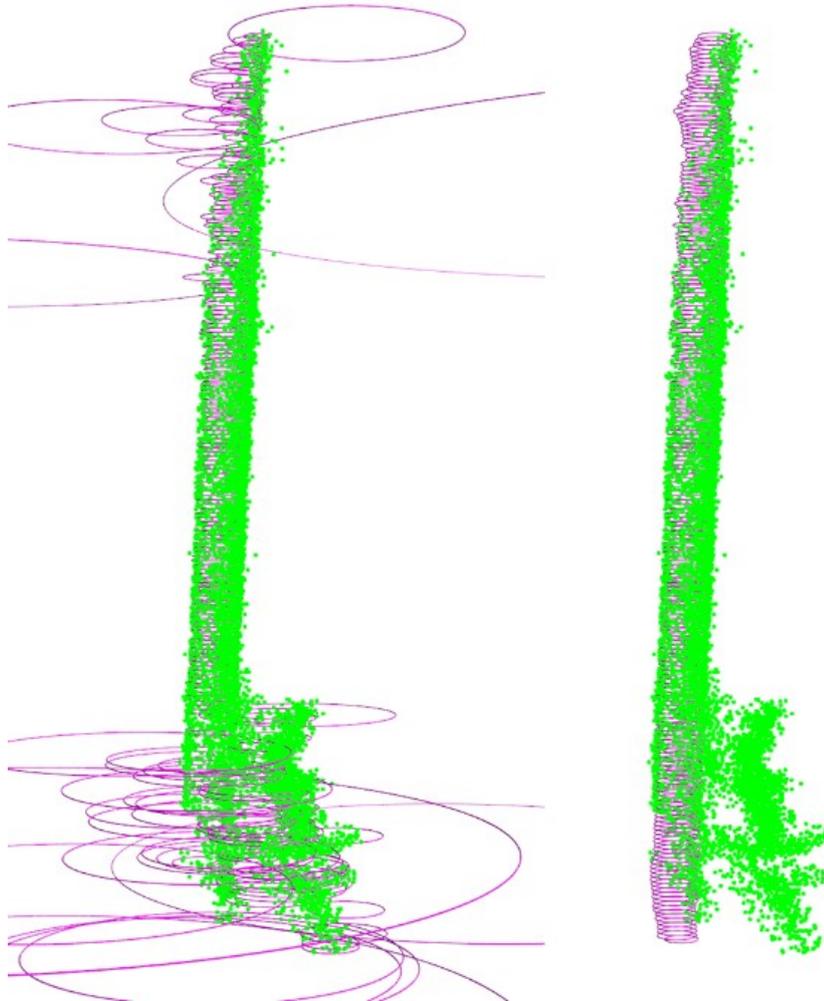


Figura 6. Resultado del ajuste de círculos a lo largo del fuste antes (izquierda) y después (derecha) de aplicar el módulo de corrección iterativa. Fuente: elaboración propia.

5. Discusión

La comparación de los distintos métodos revela que, aunque el algoritmo 3DFin obtiene el menor error promedio (véase Tabla 1), el método propuesto ofrece un rendimiento más consistente al mantener desviaciones estándar más bajas, así como un error absoluto y un error cuadrático medio menores. Esto se traduce en estimaciones más estables y menos sensibles a la presencia de ruido u oclusiones en la nube de puntos. Estos resultados se confirman tras comparar visualmente los métodos testados. Por ejemplo, en la Figura 5 (izquierda) se observa que la presencia de ramas y arbustos distorsiona las estimaciones de todos los métodos excepto el nuestro. De manera similar, la Figura 5 (derecha) muestra que en casos de oclusión severa la posición del círculo ajustado es errónea para la mayoría de los métodos, incluso si su diámetro es relativamente certero. Estos resultados



respaldan la hipótesis central de que una corrección iterativa sustentada en la continuidad del fuste permite corregir estimaciones erradas y mejorar la exactitud de los diámetros calculados. Sin embargo, es importante señalar que, si la región de referencia seleccionada contiene ajustes fallidos, o si la corrección de secciones posteriores no se realiza correctamente, se corre el riesgo de propagar dichos errores a lo largo del fuste.

Otro aspecto relevante de nuestro método es que el algoritmo de corrección iterativa puede emplearse reemplazando HyperRLTS por cualquier otro método de ajuste de círculos. La base del procedimiento radica en la hipótesis de continuidad y la corrección gradual de los errores, de modo que la herramienta para el ajuste del círculo puede adaptarse según convenga. Nuestro algoritmo también se puede beneficiar de procesos implementados en otros algoritmos. Por ejemplo, 3DFin hace uso de DBSCAN para eliminar parte del ruido antes de ajustar círculos. Además, este algoritmo es capaz de discriminar cuándo un ajuste es errado basándose en el número de puntos contenidos dentro del círculo y en la cantidad de puntos alrededor de su perímetro. Esto abre la posibilidad de mejorar el algoritmo, por lo que será testado en futuros trabajos.

Una importante limitación del presente estudio es la falta de información sobre la posición de los círculos a 1,37 m de altura. Esto es así porque, ocasionalmente, ciertos algoritmos pueden ofrecer diámetros similares a los reales, pero posiciones de los círculos desviadas (véase Figura 5, derecha). Además, la falta de valores de referencia para el resto del fuste impide demostrar con seguridad la capacidad del algoritmo para describir correctamente la forma del fuste. Por otro lado, la lógica subyacente al método propuesto sugiere que la mejora en la consistencia de los ajustes debiera mantenerse en otros tramos de este. En consecuencia, si bien no se cuenta con datos de referencia para comparar la exactitud en cotas superiores, los resultados obtenidos respaldan la idea de que la metodología propuesta ofrece un ajuste fidedigno de la forma del fuste, incluso en escenarios con ruido u oclusiones parciales. Un análisis visual de los resultados refuerza esta hipótesis, aun cuando estos puedan ser imprecisos en los extremos superior e inferior del fuste (véase la Figura 6). No obstante, dada la carencia de datos numéricos, dicha hipótesis debe ser validada en futuros trabajos.

Finalmente, la mayor desventaja del método propuesto es su elevado coste computacional. Esto es así por el reiterado uso de varios radios de corte, así como la combinación de un número creciente de secciones. En consecuencia, varios parámetros podrían ser modificados para aliviar este coste. Algunos ejemplos son el número de cortes efectuados, cuántas secciones se combinan o el umbral a partir del cual un círculo se considera válido. Así pues, en futuros estudios se evaluará la combinación de parámetros que ofrezca la menor complejidad computacional del algoritmo, así como modificaciones al mismo que permitan reducirla.

En cualquier caso, el presente trabajo tiene un impacto directo en aplicaciones que empleen datos obtenidos en tiempo real mediante MLS. Esto se debe a que los sensores MLS captan datos del fuste únicamente desde el ángulo desde el que miden, generando nubes con un alto grado de oclusión (WILKES et al., 2017). Además, estos sensores son, por el momento, la opción preferida para la automatización parcial de operaciones como la corta mediante cosechadoras forestales (FAITLI et al., 2024).

6. Conclusiones



En síntesis, el nuevo algoritmo de corrección iterativa basado en HyperRLTS ha demostrado su eficacia para estimar diámetros de forma precisa en nubes de puntos LiDAR, incluso en presencia de ruido y oclusiones parciales. Al aprovechar la continuidad natural del tronco y emplear un proceso de ajuste y validación iterativos, se reduce la susceptibilidad a estimaciones anómalas y se mejora la estabilidad de los resultados. Esto se traduce en un bajo error cuadrático medio y una menor desviación estándar frente a otros métodos, mostrando así un potencial significativo para su aplicación en inventarios forestales a una mayor escala.

Pese a estos hallazgos positivos, subsisten varios aspectos que exigen un estudio más profundo. Por un lado, la falta de referencias para alturas superiores a 1,37 m impide corroborar de manera concluyente la exactitud para otras partes del fuste. Por otro, la presencia de nubes de baja calidad puede obstaculizar seriamente la corrección iterativa, por lo que sería deseable contar con estrategias de limpieza de datos más avanzadas. Aun así, los resultados obtenidos sientan las bases para el desarrollo de nuevas metodologías de ajuste de círculos que tengan en cuenta la morfología natural de los troncos con miras a afianzar la robustez y versatilidad de las estimaciones en un contexto forestal real.

7. Agradecimientos

Los autores agradecen al Research Council of Finland y a su programa Flagship por la financiación parcial de este trabajo a través del proyecto UNITE.

8. Bibliografía

- BIENERT, A.; GEORGI, L.; KUNZ, M.; MAAS, H.G.; VON OHEIM, G. 2018. Comparison and Combination of Mobile and Terrestrial Laser Scanning for Natural Forest Inventories. *Forests* 9(7) 395.
- CHENG, D.; CLADERA, F.; PRABHU, A.; LIU, X.; ZHU, A.; GREEN, P.C.; EHSANI, R.; CHAUDHARI, P.; KUMAR, V. 2023. TreeScope: An Agricultural Robotics Dataset for LiDAR-Based Mapping of Trees in Forests and Orchards. *arXiv:2310.02162v1*.
- FAITLI, T.; HYYPPÄ, E.; HYYTI, H.; HAKALA, T.; KAARTINEN, H.; KUKKO, A.; MUHOJOKI, J.; HYYPPÄ, J. 2024. Integration of a Mobile Laser Scanning System with a Forest Harvester for Accurate Localization and Tree Stem Measurements. *Remote Sens.* 16(17) 3292.
- HENNING, J.; RADTKE, P. 2006. Detailed Stem Measurements of Standing Trees from Ground-Based Scanning Lidar. *For. Sci.* 52(1) 67 – 80.
- KANATANI, K.; RANGARAJAN, P. 2011. Hyper least squares fitting of circles and ellipses. *CSDA* 55 2197 – 2208.
- LAINO, D.; CABO, C.; PRENDES, C.; JANVIER, R.; ORDONEZ, C.; NIKONOVAS, T.; DOERR, S.; SANTIN, C. 2024. 3DFin: a software for automated 3D forest inventories from terrestrial point clouds. *Forestry* 97479 – 496.
- LIANG, X.; KANKARE, V.; HYYPPÄ, J.; WANG, Y.; KUKKO, A.; HAGGRÉN, H.; YU, X.; KAARTINEN, H.; JAAKKOLA, A.; GUAN, F.; HOLOPAINEN, M.; VASTARANTA, M. 2016. Terrestrial laser scanning in forest inventories. *ISPRS J. P&RS* 115 63 – 77.
- NURUNNABI, A.; WEST, G.; BELTON, D. 2015. Outlier detection and robust normal-curvature estimation in mobile laser scanning 3D point cloud data. *Pattern recognition* 48(4) 1404 – 1419.
- NURUNNABI, A.; TEFERLE, F.; NOVO, A.; BALADO, J.; IENTILUCCI, E. 2024. Derivation of Tree Stem Curve and Volume Using Point Clouds. *ISPRS Archives XLVIII-4/W11-2024*.



OLOFSSON, K.; HOLMGREN, J. 2016. Single Tree Stem Profile Detection Using Terrestrial Laser Scanner Data, Flatness Saliency Features and Curvature Properties. *Forests* 7(9) 207.

PRENDES, C.; CABO, C.; ORDOÑEZ, C.; MAJADA, J.; CANGA, E. 2021. An algorithm for the automatic parametrization of wood volume equations from Terrestrial Laser Scanning point clouds: application in *Pinus pinaster*. *GISci. Remote Sens.* 7 1130 – 1150.

PRENDES, C.; CANGA, E.; ORDOÑEZ, C.; MAJADA, J.; ACUNA, M.; CABO, C. 2022. Automatic Assessment of Individual Stem Shape Parameters in Forest Stands from TLS Point Clouds: Application in *Pinus pinaster*. *Forests* 13(3) 431.

TROCHTA, J.; KRŮČEK, M.; VRŠKA, T.; KRÁL, K. 2017. 3D Forest: An application for descriptions of three-dimensional forest structures using terrestrial LiDAR. *PLoS one* 12(5) 1 – 17.

WILKES, P.; LAU, A.; DISNEY, M.; CALDERS, K.; BURT, A.; DE TANAGO, J.G.; BARTHOLOMEUS, H.; BREDE, B.; HEROLD, M. 2017. Data acquisition considerations for Terrestrial Laser Scanning of forest plots. *Remote Sens. Environ.* 196 140 – 153.

XU, L.; OJA, E., 1993. Randomized Hough Transform (RHT): Basic mechanisms, algorithms, and computational complexities. *CVGIP: Image Understanding* 57(2) 131 – 154.