

Segmentasi Pohon Individual dari Data Point Cloud Hasil Pengukuran Mobile Laser Scanner (MLS)

Mohamad Bagas Setiawan*

Departemen Teknik Geodesi, Fakultas Teknik, Universitas Gadjah Mada, Indonesia

Received: 20/05/2026 Accepted: 28/06/2026

Abstract

Urban trees provide various ecosystem benefits, including carbon sequestration, urban heat island mitigation, and air quality improvement. Accurate tree inventory is important for sustainable urban tree management. This study presents individual tree segmentation from point cloud data acquired using a handheld Mobile Laser Scanner (MLS). Individual tree segmentation was performed using the TreeIso plugin in Cloud Compare. Three parameter scenarios were evaluated on 52 manually digitized reference trees. The results show that Scenario 3, with the highest parameter values ($K_1=20$, $K_2=40$, $\lambda_1=10$, $\lambda_2=40$, $\rho_{zmax}=2$, $w=2$), achieved the best performance with a precision of 0.61, recall of 0.83, and F1-score of 0.70. All scenarios exhibited over-segmentation, attributed to high point cloud density and occlusion effects during scanning. The relationship between parameter values and accuracy was non-linear, higher parameter values did not consistently improve recall but proved effective in increasing precision. This study demonstrates that TreeIso can reduce processing time from 24 hours of manual segmentation to only a few minutes, providing practical guidance for the application of MLS point cloud data in urban tree inventory.

Keywords: individual tree segmentation, mobile laser scanner, point cloud, TreeIso, urban tree

Abstrak

Pohon di perkotaan menyediakan berbagai manfaat ekosistem termasuk penyerapan karbon, mitigasi efek *urban heat island*, dan peningkatan kualitas udara. Inventarisasi pohon yang akurat menjadi sangat penting dalam pengelolaan pohon di perkotaan secara berkelanjutan. Penelitian ini menyajikan segmentasi pohon individual dari data *point cloud* yang diakuisisi menggunakan *Mobile Laser Scanner* (MLS) berbasis *handheld*. Segmentasi pohon individual dilakukan menggunakan *plugin* TreeIso pada perangkat lunak *CloudCompare*. Tiga skenario variasi parameter diuji dan dibandingkan terhadap 52 pohon referensi hasil digitasi manual. Hasil evaluasi menunjukkan bahwa Skenario 3 dengan nilai parameter tertinggi ($K_1=20$, $K_2=40$, $\lambda_1=10$, $\lambda_2=40$, $\rho_{zmax}=2$, $w=2$) menghasilkan hasil terbaik dengan *precision* 0,61, *recall* 0,83, dan F1-score 0,70. Seluruh skenario menunjukkan kondisi *over-segmentation* yang disebabkan oleh kepadatan *point cloud* dan efek oklusi pada proses pemindaian. Hubungan antara nilai parameter dan akurasi tidak bersifat linear, di mana nilai parameter yang lebih tinggi tidak selalu menghasilkan *recall* yang lebih baik, namun terbukti efektif dalam meningkatkan *precision*. Penelitian ini menunjukkan bahwa proses segmentasi dengan TreeIso mampu mempersingkat waktu pengerjaan dari 24 jam pada segmentasi manual menjadi hanya beberapa menit, dan memberikan panduan praktis dalam pemanfaatan data *point cloud* MLS untuk inventarisasi pohon perkotaan.

Kata kunci: mobile laser scanner, point cloud, pohon perkotaan, segmentasi pohon individual, TreeIso

* **Corresponding Author:** mohamad.bagas.s@ugm.ac.id

PENDAHULUAN

Pohon di perkotaan memberikan beragam manfaat ekologis dan sosial, mulai dari penyerapan karbon dioksida (CO₂), pengurangan efek *urban heat island*, peningkatan kualitas udara, hingga estetika (Gillerot et al., 2024; He et al., 2024; Xu et al., 2025). Berbagai penelitian menunjukkan bahwa keberadaan pohon di kawasan perkotaan mampu menurunkan suhu permukaan dan meningkatkan kenyamanan bagi masyarakat (He et al., 2024). Hal tersebut menjadikan inventarisasi pohon perkotaan yang akurat sebagai kebutuhan yang penting. Inventarisasi pohon perkotaan tidak hanya untuk keperluan perencanaan kota, namun juga dapat dimanfaatkan untuk pemantauan kesehatan pohon, estimasi biomassa, dan perhitungan cadangan karbon (Amir et al., 2024; Jayasooriya et al., 2024; Vonderach & Akontz, 2023).

Inventarisasi pohon secara konvensional memerlukan pengukuran lapangan manual yang membutuhkan banyak waktu, tenaga, serta biaya, serta memiliki keterbatasan dalam cakupan area dan konsistensi pengukuran. Perkembangan teknologi *Light Detection and Ranging* (LiDAR) telah terbukti mampu menjadi solusi alternatif untuk melakukan inventarisasi pohon secara otomatis dan masif (Cabo et al., 2018; Lovell et al., 2011; Xu et al., 2025). Sistem LiDAR mampu menghasilkan data berupa *point cloud* dengan densitas yang tinggi dan presisi, sehingga memungkinkan ekstraksi berbagai parameter pohon seperti tinggi pohon, diameter tajuk, hingga diameter batang dengan tingkat kedetailan yang tinggi (Stal et al., 2021).

Mobile Laser Scanner (MLS) berbasis *handheld* merupakan salah satu perangkat LiDAR yang semakin populer. Perangkat ini menawarkan fleksibilitas dalam proses akuisisi data, sehingga cocok digunakan di lingkungan seperti area perkotaan yang kompleks (De Blasiis et al., 2020; Holvoet et al., 2025; Xu et al., 2025). Berbeda dengan *Terrestrial Laser Scanner* (TLS) yang statis, MLS memungkinkan pengguna melakukan pengukuran dengan cakupan area yang lebih luas dalam waktu yang relatif lebih singkat dan menghasilkan densitas titik yang lebih tinggi (Bauwens et al., 2016; Kükenbrink et al., 2025; Ryding et al., 2015; Stal et al., 2021). Teknologi MLS memanfaatkan algoritma *Simultaneous Localization and Mapping* (SLAM) untuk secara *real-time* menggabungkan data *point cloud* dari sensor LiDAR dan mengestimasi posisi sensor secara otomatis tanpa memerlukan perangkat GPS eksternal, sehingga dapat dioperasikan bahkan di bawah tutupan pohon yang rapat (Huang, 2021).

Segmentasi pohon individual (*individual tree segmentation*) merupakan salah satu tahapan penting dalam proses analisis data *point cloud* yang bertujuan untuk memisahkan dan mengidentifikasi setiap pohon secara individual dari keseluruhan data *point cloud*. Tahapan ini merupakan prasyarat sebelum data *point cloud* dapat digunakan untuk ekstraksi parameter pohon. Berbagai macam algoritma segmentasi pohon telah dikembangkan, di antaranya pendekatan berbasis *Local Maxima* pada *Canopy Height Model* (CHM), *region growing*, *watershed segmentation*, hingga *deep learning* (Grishin et al., 2023; Lai et al., 2025; Ma et al., 2020; Mohd Zaki et al., 2020; Yang et al., 2020, 2024). Namun, algoritma tersebut memerlukan konfigurasi perangkat lunak yang kompleks dan kurang ramah pengguna.

3D *Graph-based Individual Tree Isolation* (TreeIso) merupakan algoritma segmentasi pohon yang dikembangkan oleh Xi & Hopkinson (2022) dan diimplementasikan sebagai *plugin* pada perangkat lunak *open source CloudCompare*. Algoritma ini bekerja secara langsung pada data *point cloud* tanpa memerlukan konversi ke format raster terlebih dahulu. TreeIso menggunakan pendekatan *progressive segmentation* berbasis *graph-based clustering* yang terdiri atas tiga tahapan berurutan yaitu segmentasi inisiasi, segmentasi *intermediate*, dan segmentasi final (Xi & Hopkinson, 2022). Pendekatan ini diklaim efektif dalam memisahkan individu pohon bahkan dalam kondisi pepohonan yang saling tumpang tindih (Xi & Hopkinson, 2022).

Penelitian ini bertujuan untuk melakukan segmentasi pohon individual menggunakan *plugin* TreeIso pada perangkat lunak *CloudCompare* dari data *point cloud* yang dihasilkan dari pengukuran MLS berbasis *handheld*. Selain itu, penelitian ini secara khusus menganalisis sensitivitas dan pengaruh variasi parameter TreeIso terhadap kualitas segmentasi. Hasil penelitian ini diharapkan dapat menjadi acuan praktis dalam memanfaatkan data *point cloud* untuk melakukan inventarisasi pohon secara efisien.

DATA DAN METODE

Lokasi Penelitian dan Data

Penelitian ini dilakukan di area Taman Arsitektur, Geodesi, dan Sipil (AGS), Fakultas Teknik, Universitas Gadjah Mada (UGM), Indonesia (Gambar 1). Lokasi ini dipilih karena memiliki keragaman jenis dan struktur pohon yang saling berdekatan. Karakteristik ini menjadikan lokasi ini menarik sekaligus menantang bagi algoritma segmentasi pohon individual.


Data yang digunakan adalah data pengukuran MLS berbasis *handheld* yang diukur pada bulan Maret 2026. Instrumen yang digunakan adalah FJD Trion P1 yang merupakan perangkat MLS berbasis SLAM dengan panjang gelombang 905 nm. Spesifikasi teknis alat ini meliputi maksimum *scanning range* 70 meter untuk objek dengan reflektivitas 80%, *field of view* (FOV) 360° horizontal dan 59° vertikal, dengan kecepatan akuisisi 200.000 titik per detik. Data validasi diperoleh dari hasil digitasi manual *point cloud* secara langsung pada tampilan tiga dimensi di perangkat lunak *CloudCompare*, di mana setiap pohon diidentifikasi dan diberi label unik secara individual.



Gambar 1. Lokasi penelitian

Alur Penelitian

Alur penelitian disusun secara sistematis melalui empat tahap utama. Tahap pertama adalah akuisisi dan pemeriksaan data mentah, yang meliputi pengukuran lapangan menggunakan MLS berbasis *handheld* FJD Trion P1 dan pemeriksaan kelengkapan serta kualitas data hasil pengukuran. Tahap kedua adalah *pre-processing* data *point cloud*, yang mencakup proses penghilangan *noise* menggunakan *Statistical Outlier Removal* (SOR) Filter (Rusu & Cousins, 2011) dan pemisahan titik tanah menggunakan *Cloth Simulation Filter* (CSF) (Zhang et al., 2016). Tahap ketiga adalah segmentasi pohon individual menggunakan algoritma *TreeIso* dengan tiga skenario variasi parameter. Tahap terakhir adalah validasi dan evaluasi akurasi hasil segmentasi terhadap data referensi manual menggunakan metrik *precision*, *recall*, dan F1-score. Gambar 2 menunjukkan diagram alir penelitian yang dilaksanakan pada penelitian ini.



Gambar 2. Diagram alir penelitian

Pre-processing Data Point Cloud

Sebelum data *point cloud* dapat digunakan sebagai masukan segmentasi, perlu dilakukan serangkaian proses *pre-processing* untuk meningkatkan kualitas data. *Pre-processing* pada penelitian ini terdiri dari dua tahap utama, yaitu penghilangan *noise* dan pemisahan titik tanah. Tahap pertama adalah menghilangkan *noise* menggunakan fungsi SOR Filter di perangkat lunak *CloudCompare*. Algoritma SOR bekerja dengan menghitung jarak rata-rata setiap titik ke sejumlah k tetangga terdekatnya, kemudian membandingkan nilai tersebut dengan distribusi jarak rata-rata secara keseluruhan. Titik yang memiliki jarak rata-rata melampaui *threshold* tertentu yang ditentukan oleh perkalian simpangan baku dengan koefisien pengali akan dianggap sebagai *outlier*. Penelitian ini menggunakan parameter k -nearest neighbors = 6 dan koefisien pengali simpangan baku = 1.

Tahap kedua adalah pemisahan titik tanah dan non-tanah menggunakan *Cloth Simulation Filter* (CSF) (Zhang et al., 2016) yang tersedia pula sebagai *plugin* di *CloudCompare*. Parameter yang digunakan adalah *cloth resolution* = 0,5 meter yang menentukan resolusi virtual *cloth* dan secara langsung memengaruhi kemampuan algoritma dalam mengikuti variasi relief tanah; *class threshold* = 0,2 meter yang merupakan batas jarak maksimum suatu titik dari virtual *cloth* untuk diklasifikasikan sebagai titik tanah; serta *iteration* = 500 yang menentukan jumlah iterasi simulasi. Titik non-tanah hasil CSF kemudian digunakan sebagai masukan utama untuk proses segmentasi pohon individual, sehingga algoritma segmentasi tidak terganggu oleh keberadaan titik-titik tanah.

Segmentasi Pohon Individual dengan TreeIso

Segmentasi pohon individual dilakukan menggunakan *plugin* TreeIso (Xi & Hopkinson, 2022) pada perangkat lunak *CloudCompare*. Data masukan yang digunakan dalam proses ini adalah *point cloud* non-tanah hasil *pre-processing*. TreeIso merupakan algoritma segmentasi pohon individual berbasis graf tiga dimensi yang bekerja langsung pada data *point cloud* tanpa memerlukan konversi ke dalam format raster. Algoritma ini dikembangkan untuk mengisolasi pohon individual melalui pendekatan bertahap, sehingga proses segmentasi tidak hanya mempertimbangkan kedekatan spasial antar titik, tetapi juga mempertimbangkan hubungan geometris antar segmen. Secara umum, TreeIso terdiri atas tiga tahap utama, yaitu segmentasi inisiasi, segmentasi intermediate, dan segmentasi final.

Tahap pertama adalah segmentasi inisiasi. Pada tahap ini, seluruh *point cloud* dibagi menjadi sejumlah segmen kecil menggunakan pendekatan *graph-based clustering*. Algoritma ini membangun graf ketetanggaan dengan menghubungkan setiap titik terhadap sejumlah K_1 tetangga terdekatnya. Hubungan

antar titik atau *edges* diberi bobot berdasarkan kedekatan spasial dan kesamaan karakteristik geometri titik. Selanjutnya, proses pemisahan dan pengelompokan titik dilakukan melalui pendekatan *graph cut* yang dipengaruhi oleh parameter regularisasi (λ_1). Nilai K_1 menentukan jumlah tetangga terdekat yang digunakan dalam pembentukan graf pada tahap segmentasi inisiasi. Parameter ini berperan dalam membangun hubungan lokal antar titik sebelum proses pemisahan segmen dilakukan. Sementara itu, λ_1 berperan sebagai parameter regularisasi yang memengaruhi proses pemisahan dan penggabungan titik pada tahap segmentasi inisiasi. Nilai λ_1 yang lebih tinggi meningkatkan kecenderungan algoritma untuk mempertahankan titik-titik dengan karakteristik geometris serupa dalam satu segmen awal.

Tahap selanjutnya adalah segmentasi intermediate. Pada tahap ini, segmen-segmen kecil hasil segmentasi inisiasi digabungkan menjadi segmen yang lebih besar berdasarkan hubungan spasial dan kemiripan karakteristik geometris antar segmen. Proses penggabungan ini dikendalikan oleh parameter K_2 dan λ_2 . Parameter K_2 menentukan jumlah tetangga terdekat antar segmen yang dipertimbangkan dalam proses penggabungan, sedangkan λ_2 berperan sebagai parameter regularisasi yang memengaruhi kecenderungan penggabungan atau pemisahan segmen pada tahap segmentasi antara. Dengan demikian, tahap segmentasi intermediate berfungsi untuk memperluas segmen awal menjadi kandidat pohon individual yang lebih stabil sebelum batas akhir setiap pohon ditentukan.

Kemudian dilakukan segmentasi final yang bertujuan untuk memfinalisasi batas-batas pohon individual dengan mempertimbangkan hubungan vertikal dan geometri antar segmen. Dua parameter utama yang digunakan pada tahap ini adalah ρ_{zmax} dan w . Parameter ρ_{zmax} merepresentasikan rasio antara perbedaan elevasi dan panjang segmen, sedangkan parameter w merupakan faktor pembobotan vertikal dalam perhitungan jarak antar segmen. Kedua parameter ini digunakan karena pohon memiliki struktur vertikal yang dominan, terutama pada batang, cabang, dan tajuk. Oleh karena itu, pengaturan ρ_{zmax} dan w dapat memengaruhi kemampuan algoritma dalam mempertahankan kesinambungan struktur pohon atau, sebaliknya, memecah satu individu pohon menjadi beberapa segmen.

Penelitian ini mengevaluasi pengaruh variasi parameter TreeIso terhadap hasil segmentasi dengan menerapkan tiga skenario parameter sebagaimana disajikan pada Tabel 1. Pemilihan skenario parameter mengacu pada struktur parameter TreeIso yang dijelaskan oleh Xi & Hopkinson (2022), yaitu parameter ketetanggaan, regularisasi, dan finalisasi segmen. Pada algoritma TreeIso, parameter-parameter tersebut berperan dalam menentukan bagaimana titik dan segmen saling dihubungkan, digabungkan, serta dipisahkan menjadi pohon individual. Oleh karena itu, perubahan nilai parameter perlu dievaluasi ketika TreeIso diterapkan pada data dengan karakteristik yang berbeda. Pada penelitian ini, Skenario 1 menggunakan nilai parameter dasar yang tersedia pada *plugin* TreeIso sebagai baseline, sehingga hasil segmentasi dari parameter awal dapat dibandingkan dengan hasil segmentasi dari skenario parameter yang lebih besar.

Skenario 2 dan Skenario 3 disusun dengan meningkatkan nilai parameter utama TreeIso secara bertahap dari baseline. Peningkatan nilai K_1 dan K_2 digunakan untuk mengevaluasi pengaruh jumlah hubungan ketetanggaan dalam pembentukan dan penggabungan segmen. Peningkatan λ_1 dan λ_2 digunakan untuk mengevaluasi pengaruh regularisasi terhadap proses pemisahan dan penggabungan titik atau segmen pada tahapan segmentasi menggunakan TreeIso. Sementara itu, peningkatan ρ_{zmax} dan w digunakan untuk mengevaluasi pengaruh komponen vertikal dalam mempertahankan kesinambungan struktur pohon. Pertimbangan ini penting karena data MLS berbasis *handheld* pada area urban memiliki karakteristik yang kompleks, seperti kepadatan titik, variasi jarak pemindaian, oklusi, diskontinuitas *point cloud*, serta kedekatan antar objek vegetasi (Luo et al., 2021; Wang et al., 2023).

Setiap skenario dijalankan pada data set yang sama agar perubahan hasil segmentasi dapat dibandingkan secara konsisten. Hasil dari setiap skenario kemudian disimpan sebagai *point cloud* terpisah dengan atribut label yang menunjukkan ID pohon hasil segmentasi. Perbandingan ketiga skenario tersebut digunakan untuk mengevaluasi jumlah pohon terdeteksi, waktu pemrosesan, *precision*, *recall*, *F1-score*, serta kecenderungan terjadinya *over-segmentation* dan *under-segmentation*.

Tabel 1. Skenario variasi parameter TreeIso

Parameter		Skenario 1 (baseline)	Skenario 2	Skenario 3
K_1	(jumlah tetangga – tahap 1)	5	10	20
K_2	(jumlah tetangga – tahap 2)	10	20	40
λ_1	(regularisasi – tahap 1)	1	5	10
λ_2	(regularisasi – tahap 2)	10	20	40
ρ_{zmax}	(rasio perbedaan elevasi dan panjang segmen – tahap 3)	0,5	1	2
w	(vertical weight – tahap 3)	0,5	1	2

Validasi dan Evaluasi Akurasi

Akurasi deteksi pohon dievaluasi menggunakan tiga metrik utama, yaitu *precision*, *recall*, dan *F1-score*. Pencocokan antara pohon hasil segmentasi dan referensi dilakukan berdasarkan pendekatan *one-to-one matching*, di mana setiap pohon hasil segmentasi dipasangkan dengan referensi yang memiliki tumpang tindih *point cloud* terbesar. Pohon yang berhasil dipasangkan dihitung sebagai *True Positive* (TP), pohon referensi yang tidak memiliki pasangan dihitung sebagai *False Negative* (FN), dan pohon hasil segmentasi yang tidak memiliki pasangan dihitung sebagai *False Positive* (FP). Kemudian tiga metrik utama dihitung berdasarkan nilai-nilai yang diperoleh dari perbandingan tersebut dengan rumus sebagai berikut.

$$Precision = TP / (TP + FP) \quad (1)$$

$$Recall = TP / (TP + FN) \quad (2)$$


$$F1-score = 2 \times (Precision \times Recall) / (Precision + Recall) \quad (3)$$

HASIL DAN PEMBAHASAN

Point Cloud Hasil Akuisisi

Akuisisi data menggunakan MLS berbasis *handheld* FJD Trion P1 menghasilkan *point cloud* sebanyak 37.218.430 titik, sebagaimana ditunjukkan pada Gambar 3a. Pada tahap inspeksi awal, teridentifikasi sejumlah titik *noise* yang terisolasi dan menyimpang dari permukaan objek. Titik-titik tersebut merupakan artefak yang umum dijumpai pada data LiDAR dan perlu dihilangkan karena dapat memengaruhi kualitas segmentasi.

Setelah proses *noise filtering* menggunakan algoritma SOR, jumlah titik berkurang sekitar 11% dari total data awal menjadi 33.125.757 titik (Gambar 3b). Pengurangan jumlah titik ini menunjukkan bahwa data mentah hasil pengukuran MLS berbasis *handheld* masih mengandung *noise* yang perlu dihilangkan sebelum digunakan pada tahap analisis berikutnya. Selanjutnya, proses pemisahan titik tanah dan non-tanah menggunakan CSF menghasilkan 7.324.674 titik tanah (Gambar 3c) dan 25.801.083 titik non-tanah (Gambar 3d). Titik tanah merepresentasikan permukaan jalan, trotoar, dan area terbuka di kawasan taman, sedangkan titik non-tanah merepresentasikan vegetasi, bangunan, infrastruktur, dan objek lain di atas permukaan tanah. Data titik non-tanah kemudian disegmentasi secara manual pada tampilan tiga dimensi di *CloudCompare*. Proses segmentasi manual tersebut memerlukan waktu selama 24 jam dan menghasilkan 52 pohon referensi yang digunakan sebagai data pembanding dalam evaluasi akurasi segmentasi otomatis.



Gambar 3. (a) *Point cloud* hasil pengukuran (b) *Point cloud* hasil proses *noise filtering* (c) Titik *ground* (d) Titik *non-ground*

Hasil Segmentasi Pohon Individual


Proses segmentasi TreeIso dijalankan pada ketiga skenario dan menghasilkan label segmen untuk setiap titik *point cloud* masukan. Rekapitulasi waktu pemrosesan masing-masing tahap untuk ketiga skenario disajikan pada Tabel 2.

Tabel 2. Waktu pemrosesan setiap tahap TreeIso

Tahap Pemrosesan	Skenario 1 (<i>baseline</i>)	Skenario 2	Skenario 3
Inisiasi	13 detik	23 detik	55 detik
<i>Intermediate</i>	11 detik	20 detik	42 detik
Final	15 detik	13 detik	11 detik
Total	39 detik	56 detik	108 detik

Berdasarkan Tabel 2, waktu pemrosesan pada tahap inisiasi dan intermediate meningkat seiring dengan peningkatan nilai parameter. Pada tahap inisiasi, waktu pemrosesan meningkat dari 13 detik pada Skenario 1 menjadi 55 detik pada Skenario 3. Pada tahap intermediate, waktu pemrosesan meningkat dari 11 detik menjadi 42 detik. Peningkatan ini dapat dikaitkan dengan bertambahnya jumlah hubungan ketetanggaan (K_1 dan K_2) dan parameter regularisasi (λ_1 dan λ_2) yang dipertimbangkan dalam pembentukan serta penggabungan segmen. Sebaliknya, tahap final menunjukkan waktu pemrosesan yang lebih singkat pada Skenario 3 dibandingkan dua skenario lainnya. Pola ini mengindikasikan bahwa perubahan parameter pada tahap awal dapat memengaruhi jumlah dan karakteristik kandidat segmen yang diproses pada tahap final. Secara keseluruhan, Skenario 3 memerlukan waktu pemrosesan terlama, yaitu 108 detik, atau lebih dari dua kali waktu pemrosesan Skenario 1.


Hasil segmentasi visual dari ketiga skenario beserta referensinya ditunjukkan pada Gambar 4. Segmentasi manual menghasilkan 52 pohon, sedangkan hasil segmentasi otomatis menghasilkan jumlah pohon yang lebih besar pada seluruh skenario. Skenario 1 menghasilkan 78 pohon, Skenario 2 menghasilkan 88 pohon, dan Skenario 3 menghasilkan 71 pohon. Perbedaan jumlah tersebut menunjukkan adanya kecenderungan *over-segmentation*, yaitu kondisi ketika satu individu pohon terpecah menjadi lebih dari satu segmen.




Gambar 4. Hasil segmentasi (a) manual (b) skenario 1 (c) skenario 2 (d) skenario 3

Fenomena *over-segmentation* ini dapat dilihat pada Gambar 5b dan Gambar 5c untuk Skenario 1 dan Skenario 2, serta Gambar 6b untuk Skenario 3. Kondisi *over-segmentation* muncul pada bagian pohon yang memiliki celah atau diskontinuitas *point cloud* akibat oklusi selama proses pemindaian. Ketika sebagian batang, cabang, atau tajuk tidak terekam secara utuh, hubungan spasial antar bagian pohon menjadi terputus. Akibatnya, algoritma dapat menginterpretasikan bagian-bagian tersebut sebagai objek atau segmen yang berbeda. Kondisi ini lebih mudah terjadi pada lingkungan taman perkotaan karena pohon berada dekat dengan objek lain, seperti bangunan, tiang, pagar, semak, atau tajuk pohon lain yang saling berdekatan.

Hasil segmentasi menunjukkan bahwa peningkatan nilai parameter tidak selalu menghasilkan jumlah pohon terdeteksi yang lebih mendekati data referensi. Skenario 2 menghasilkan 88 pohon terdeteksi, yaitu jumlah tertinggi di antara ketiga skenario, meskipun nilai parameternya lebih besar daripada Skenario 1. Jumlah tersebut jauh melebihi 52 pohon referensi dan menunjukkan bahwa Skenario 2 memiliki kecenderungan *over-segmentation* yang paling tinggi. Fenomena ini juga dapat diamati secara visual pada Gambar 5c, di mana satu individu pohon tampak terpecah menjadi beberapa segmen. Sebaliknya, Skenario 3 menghasilkan 71 pohon terdeteksi, yaitu jumlah yang paling mendekati data referensi dibandingkan Skenario 1 dan Skenario 2. Hasil ini menunjukkan bahwa kualitas segmentasi tidak hanya dipengaruhi oleh peningkatan nilai parameter, tetapi juga oleh kesesuaian kombinasi parameter dengan karakteristik *point cloud*. Pada data ini, kombinasi parameter pada Skenario 3 menghasilkan segmentasi yang lebih baik karena mampu menekan jumlah segmen berlebih dibandingkan dua skenario lainnya.



Gambar 5. Contoh detail hasil segmentasi (a) manual (b) skenario 1
(c) skenario 2 (d) skenario 3



Gambar 6. Contoh detail hasil segmentasi (a) manual (b) skenario 3

Evaluasi Akurasi Segmentasi

Evaluasi akurasi dilakukan menggunakan metode *one-to-one matching* antara pohon hasil segmentasi otomatis dan pohon referensi manual. Setiap pohon hasil segmentasi otomatis dipasangkan dengan pohon referensi yang memiliki tingkat tumpang tindih terbesar. Pohon hasil segmentasi yang berhasil dipasangkan dengan pohon referensi dihitung sebagai *true positive* (TP), pohon referensi yang tidak memiliki pasangan dihitung sebagai *false negative* (FN), sedangkan pohon hasil segmentasi otomatis yang tidak memiliki pasangan dihitung sebagai *false positive* (FP). Rekapitulasi hasil evaluasi ketiga skenario disajikan pada Tabel 3.

Tabel 3. Rekapitulasi hasil evaluasi akurasi segmentasi

Metrik Evaluasi	Skenario 1 (<i>baseline</i>)	Skenario 2	Skenario 3
Referensi	52 pohon	52 pohon	52 pohon
Pohon Otomatis Terdeteksi	78 pohon	88 pohon	71 pohon
<i>True Positive</i> (TP)	42	45	43
<i>False Negative</i> (FN)	10	7	9
<i>False Positive</i> (FP)	36	43	28
<i>Precision</i>	0,54	0,51	0,61
<i>Recall</i>	0,81	0,87	0,83
<i>F1-score</i>	0,65	0,64	0,70

Berdasarkan Tabel 3, Skenario 2 menghasilkan nilai *recall* tertinggi, yaitu 0,87, dengan 45 TP dan 7 FN. Nilai *recall* yang tinggi menunjukkan bahwa sebagian besar pohon referensi berhasil terdeteksi. Namun, Skenario 2 juga menghasilkan jumlah FP tertinggi, yaitu 43 segmen. Kondisi ini menunjukkan bahwa peningkatan jumlah pohon yang terdeteksi pada Skenario 2 tidak selalu menunjukkan segmentasi yang lebih baik, karena sebagian hasil deteksi merupakan segmen tambahan akibat *over-segmentation*. Akibatnya, *precision* pada Skenario 2 menjadi yang terendah, yaitu 0,51.

Skenario 3 menghasilkan kinerja terbaik berdasarkan F1-score, yaitu 0,70, dengan *precision* 0,61 dan *recall* 0,83. Meskipun jumlah pohon otomatis pada Skenario 3 masih lebih besar daripada jumlah pohon referensi, yaitu 71 pohon dibandingkan 52 pohon, skenario ini menghasilkan FP paling rendah dibandingkan dua skenario lainnya. Hal ini menunjukkan bahwa Skenario 3 mampu memberikan keseimbangan yang lebih baik antara kemampuan mendeteksi pohon referensi dan kemampuan menekan segmen tambahan. Dengan demikian, Skenario 3 dipilih sebagai skenario terbaik pada data ini karena menghasilkan kombinasi *precision* dan *recall* yang paling seimbang.

Jika dibandingkan dengan studi awal TreeIso, hasil penelitian ini menunjukkan performa yang cukup relevan dari sisi kemampuan deteksi, meskipun belum sepenuhnya sebanding dari sisi metrik evaluasi. Xi & Hopkinson (2022) melaporkan bahwa TreeIso mampu mencapai *detection rate* rata-rata sebesar 86% pada data *terrestrial laser scanning* (TLS). Pada penelitian ini, Skenario 3 menghasilkan *recall* sebesar 0,83. Nilai tersebut menunjukkan bahwa sebagian besar pohon referensi berhasil terdeteksi dan relatif mendekati *detection rate* yang dilaporkan pada studi awal TreeIso. Namun, penelitian Xi & Hopkinson (2022) juga menggunakan *mean Intersection-over-Union* (mIoU) untuk menilai kesesuaian spasial antara pohon hasil segmentasi dan pohon referensi, sedangkan penelitian ini menggunakan *precision*, *recall*, dan F1-score. Oleh karena itu, F1-score pada penelitian ini tidak dapat dibandingkan secara langsung dengan nilai mIoU pada studi awal TreeIso karena kedua metrik tersebut mengukur aspek akurasi yang berbeda.

Jika dibandingkan dengan studi berbasis *mobile laser scanning* (MLS) pada lingkungan urban, nilai F1-score sebesar 0,70 pada penelitian ini menunjukkan performa yang cukup memadai dalam konteks data MLS berbasis *handheld* pada lingkungan taman perkotaan, tetapi belum optimal. Yang et al. (2025), misalnya, melaporkan F1-score sebesar 81,9%, *precision* sebesar 86,3%, dan *recall* sebesar 78,5% untuk deteksi pohon tepi jalan menggunakan sistem MLS. Dibandingkan dengan studi tersebut, *recall* pada penelitian ini relatif tinggi, tetapi *precision* masih lebih rendah. Perbedaan ini menunjukkan bahwa TreeIso pada data penelitian ini mampu mendeteksi sebagian besar pohon referensi, tetapi masih menghasilkan *false positive* yang relatif tinggi, yang mengindikasikan adanya *over-segmentation*.

Kecenderungan *over-segmentation* pada penelitian ini dapat dikaitkan dengan karakteristik data MLS berbasis *handheld* dan kondisi lingkungan taman perkotaan. Data MLS berbasis *handheld* diperoleh melalui pemindaian bergerak sehingga memiliki variasi jarak sensor, perubahan sudut pandang, serta potensi oklusi pada bagian batang, cabang, dan tajuk. Oklusi tersebut dapat menyebabkan diskontinuitas *point cloud*, sehingga satu individu pohon dapat terpecah menjadi beberapa segmen. Selain itu, keberadaan objek non-vegetasi di sekitar pohon, seperti bangunan, tiang, pagar, dan elemen lanskap lain, dapat menambah kompleksitas proses segmentasi. Oleh karena itu, F1-score sebesar 0,70 pada Skenario 3 menunjukkan bahwa TreeIso berpotensi digunakan untuk segmentasi pohon individual dari data MLS

berbasis *handheld*, tetapi masih memerlukan penyesuaian parameter dan kemungkinan *post-processing* untuk mengurangi *over-segmentation* dan meningkatkan *precision*.

KESIMPULAN

Penelitian ini menunjukkan bahwa TreeIso dapat digunakan untuk melakukan segmentasi pohon individual dari data *point cloud* MLS berbasis *handheld* pada lingkungan taman perkotaan. Dari tiga skenario parameter yang diuji, Skenario 3 memberikan hasil paling seimbang antara kemampuan mendeteksi pohon referensi dan menekan segmen tambahan. Temuan ini menunjukkan bahwa pemilihan kombinasi parameter berperan penting dalam meningkatkan kualitas segmentasi, terutama pada data *point cloud* dengan karakteristik kompleks.

Kontribusi penelitian ini adalah memberikan evaluasi awal mengenai penerapan dan pengaruh variasi parameter TreeIso pada data MLS berbasis *handheld* untuk inventarisasi pohon perkotaan. Secara praktis, pendekatan ini dapat mempercepat proses segmentasi dibandingkan digitasi manual, sehingga berpotensi mendukung inventarisasi pohon yang lebih efisien. Namun, hasil segmentasi masih dipengaruhi oleh oklusi, diskontinuitas *point cloud*, dan tajuk yang berdekatan. Penelitian lanjutan disarankan untuk menguji variasi parameter yang lebih rinci, menerapkan strategi akuisisi multi-arah, serta mengembangkan *post-processing* untuk mengurangi *over-segmentation*.

DAFTAR PUSTAKA

- Amir, A. F., Meor Razali, M. A. Z., Yeok, F. S., Khozaei, F., & Borhan, R. (2024). ESTIMATION OF CARBON STORAGE AND SEQUESTRATION OF IPOH URBAN TREES FOR VOLUNTARY CARBON MARKET. PLANNING MALAYSIA, 22. <https://doi.org/10.21837/pm.v22i34.1630>
- Bauwens, S., Bartholomeus, H., Calders, K., & Lejeune, P. (2016). Forest inventory with terrestrial LiDAR: A comparison of static and hand-held mobile laser scanning. *Forests*, 7(6). <https://doi.org/10.3390/f7060127>
- Cabo, C., Ordóñez, C., López-Sánchez, C. A., & Armesto, J. (2018). Automatic dendrometry: Tree detection, tree height and diameter estimation using terrestrial laser scanning. *International Journal of Applied Earth Observation and Geoinformation*, 69(March), 164–174. <https://doi.org/10.1016/j.jag.2018.01.011>
- De Blasiis, M. R., Di Benedetto, A., & Fiani, M. (2020). Mobile laser scanning data for the evaluation of pavement surface distress. *Remote Sensing*, 12(6). <https://doi.org/10.3390/rs12060942>
- Gillerot, L., Landuyt, D., De Frenne, P., Muys, B., & Verheyen, K. (2024). Urban tree canopies drive human heat stress mitigation. *Urban Forestry and Urban Greening*, 92. <https://doi.org/10.1016/j.ufug.2023.128192>
- Grishin, I. A., Krutov, T. Y., Kanev, A. I., & Terekhov, V. I. (2023). Individual Tree Segmentation Quality Evaluation Using Deep Learning Models LiDAR Based. *Optical Memory and Neural Networks (Information Optics)*, 32, S270–S276. <https://doi.org/10.3103/S1060992X23060061>
- He, T., Hu, Y., Guo, A., Chen, Y., Yang, J., Li, M., & Zhang, M. (2024). Quantifying the impact of urban trees on land surface temperature in global cities. *ISPRS Journal of Photogrammetry and Remote Sensing*, 210, 69–79. <https://doi.org/10.1016/j.isprsjprs.2024.03.007>
- Holvoet, J., Eichhorn, M. P., Giannetti, F., Kükenbrink, D., Liang, X., Mokroš, M., Novotný, J., Pitkänen, T. P., Puliti, S., Skudnik, M., Stereńczak, K., Terryn, L., Vega, C., & Torresan, C. (2025). Terrestrial and mobile laser scanning for national forest inventories: From theory to implementation. *Remote Sensing of Environment*, 329(August 2024). <https://doi.org/10.1016/j.rse.2025.114947>
- Huang, L. (2021). Review on LiDAR-based SLAM Techniques. 2021 International Conference on Signal Processing and Machine Learning (CONF-SPML), 163–168. <https://doi.org/10.1109/CONF-SPML54095.2021.00040>

- Jayasooriya, V. M., Sirimanne, A. P., Silva, R. M., & Muthukumaran, S. (2024). Role of Urban Trees in Enhancing the Thermal Comfort of Rapidly Urbanizing Cities: An Analysis of Tropical Asian Tree Species Based on Physiological Equivalent Temperature (PET). *Arboriculture & Urban Forestry*, 50(5), 326–345. <https://doi.org/10.48044/jauf.2024.014>
- Kükenbrink, D., Marty, M., Rehush, N., Abegg, M., & Ginzler, C. (2025). Evaluating the potential of handheld mobile laser scanning for an operational inclusion in a national forest inventory – A Swiss case study. *Remote Sensing of Environment*, 321. <https://doi.org/10.1016/j.rse.2025.114685>
- Lai, G., Cao, M., Zhou, C., Liu, L., Zhong, X., Guo, Z., & Ouyang, X. (2025). Extracting Individual Tree Positions in Closed-Canopy Stands Using a Multi-Source Local Maxima Method. *Forests*, 16(2). <https://doi.org/10.3390/f16020262>
- Lovell, J. L., Jupp, D. L. B., Newnham, G. J., & Culvenor, D. S. (2011). Measuring tree stem diameters using intensity profiles from ground-based scanning lidar from a fixed viewpoint. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(1), 46–55. <https://doi.org/10.1016/j.isprsjprs.2010.08.006>
- Luo, H., Khoshelham, K., Chen, C., & He, H. (2021). Individual tree extraction from urban mobile laser scanning point clouds using deep pointwise direction embedding. *ISPRS Journal of Photogrammetry and Remote Sensing*, 175, 326–339. <https://doi.org/10.1016/j.isprsjprs.2021.03.002>
- Ma, Z., Pang, Y., Wang, D., Liang, X., Chen, B., Lu, H., Weinacker, H., & Koch, B. (2020). Individual tree crown segmentation of a larch plantation using airborne laser scanning data based on region growing and canopy morphology features. *Remote Sensing*, 12(7). <https://doi.org/10.3390/rs12071078>
- Mohd Zaki, N. A., Rajuli, M. F., Latif, Z. A., Suratman, M. N., Omar, H., Norashikin, S., Zainal, M. Z., & Talib, N. (2020). Analysis of Canopy Height Model (CHM) Extraction using Quick Terrain Modeller (QTM) for Tropical Forest Area. *IOP Conference Series: Earth and Environmental Science*, 540(1). <https://doi.org/10.1088/1755-1315/540/1/012045>
- Rusu, R. B., & Cousins, S. (2011). 3D is here: Point Cloud Library (PCL). 2011 IEEE International Conference on Robotics and Automation, 1–4. <https://doi.org/10.1109/ICRA.2011.5980567>
- Ryding, J., Williams, E., Smith, M. J., & Eichhorn, M. P. (2015). Assessing handheld mobile laser scanners for forest surveys. *Remote Sensing*, 7(1), 1095–1111. <https://doi.org/10.3390/rs70101095>
- Stal, C., Verbeurgt, J., De Sloover, L., & De Wulf, A. (2021). Assessment of handheld mobile terrestrial laser scanning for estimating tree parameters. *Journal of Forestry Research*, 32(4), 1503–1513. <https://doi.org/10.1007/s11676-020-01214-7>
- Vonderach, C., & Akontz, A. (2023). Learning from Forest Trees: Improving Urban Tree Biomass Functions. *Forests*, 14(7), 1473. <https://doi.org/10.3390/f14071473>
- Wang, P., Tang, Y., Liao, Z., Yan, Y., Dai, L., Liu, S., & Jiang, T. (2023). Road-Side Individual Tree Segmentation from Urban MLS Point Clouds Using Metric Learning. *Remote Sensing*, 15(8). <https://doi.org/10.3390/rs15081992>
- Xi, Z., & Hopkinson, C. (2022). 3D Graph-Based Individual-Tree Isolation (Treeiso) from Terrestrial Laser Scanning Point Clouds. *Remote Sensing*, 14(23). <https://doi.org/10.3390/rs14236116>
- Xu, M., Zhong, X., & Zhong, R. (2025). A method for automatic extraction and individual segmentation of urban street trees from laser point clouds. *Optics and Laser Technology*, 180. <https://doi.org/10.1016/j.optlastec.2024.111431>
- Yang, J., Gan, R., Luo, B., Wang, A., Shi, S., & Du, L. (2024). An Improved Method for Individual Tree Segmentation in Complex Urban Scenes Based on Using Multispectral LiDAR by Deep Learning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 6561–6576. <https://doi.org/10.1109/JSTARS.2024.3373395>
- Yang, J., Kang, Z., Cheng, S., Yang, Z., & Akwensi, P. H. (2020). An Individual Tree Segmentation Method Based on Watershed Algorithm and Three-Dimensional Spatial Distribution Analysis from Airborne

LiDAR Point Clouds. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 1055–1067. <https://doi.org/10.1109/JSTARS.2020.2979369>

Yang, T., Ryu, Y., Kwon, R., Choi, C., Zhong, Z., Nam, Y., & Jo, S. (2025). Mapping carbon stock and growth of individual street trees using LiDAR-camera fusion-based mobile mapping system. *Remote Sensing of Environment*, 328. <https://doi.org/10.1016/j.rse.2025.114895>

Zhang, W., Qi, J., Wan, P., Wang, H., Xie, D., Wang, X., & Yan, G. (2016). An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sensing*, 8(6). <https://doi.org/10.3390/rs8060501>