

ANALISIS PERHITUNGAN JUMLAH POHON KELAPA SAWIT BERDASARKAN ALGORITMA *CANOPY HEIGHT MODEL* (CHM) DAN *LOCAL MAXIMA* (LM)

Kharisma Srinarta^{*)}, Yudo Prasetyo, Firman Hadi

Departemen Teknik Geodesi Fakultas Teknik Universitas Diponegoro
Jl. Prof. Sudarto, SH, Tembalang, Semarang Telp.(024)76480785, 76480788

*Email: kharismasrinarta@students.undip.ac.id

ABSTRAK

Berdasarkan Buku Statistik Perkebunan Unggulan Nasional 2019-2020 yang dikeluarkan oleh Direktorat Jenderal Perkebunan, disebutkan bahwa Indonesia adalah peringkat 1 dalam ekspor sawit dunia dan luas areal perkebunan sawit dunia. Sejak tahun 1980, produksi kelapa sawit dalam bentuk *crude palm oil* (CPO) terus mengalami peningkatan sebesar 11,8 % tiap tahunnya. Oleh karena itu, diperlukan suatu cara untuk mempermudah dalam proses manajemen perkebunan kelapa sawit supaya hasil produksi terus meningkat, salah satu caranya adalah dengan melakukan perhitungan pohon kelapa sawit secara otomatis. Tujuan dari penelitian ini adalah untuk mengetahui pemanfaatan dari *Canopy Height Model* (CHM) dengan metode *Local Maxima* (LM) dalam hal perhitungan pohon secara otomatis dengan memanfaatkan 2 parameter *Sliding Window Size* (SWS) yaitu SWS 3x3 dan SWS 5x5.

Objek penelitian dibagi menjadi 3 kelas berdasarkan dengan kerapatan pohon per hektar, dimana ada kelas optimal (120-150 pohon/ha), kelas tidak optimal (sedang = 60-119 pohon/ha) dan kelas tidak optimal (jarang = 1-59 pohon/ha). Hasilnya diperoleh bahwa pemanfaatan CHM dengan metode LM dapat mendeteksi pohon kelapa sawit otomatis dan memberikan hasil *overall accuracy* yang tinggi untuk 2 kelas. Kelas optimal memiliki rata-rata *overall accuracy* sebesar 0,943 untuk SWS 3x3 dan 0,926 untuk SWS 5x5. Pada kelas tidak optimal (sedang), rata-rata *overall accuracy*-nya adalah 0,845 untuk SWS 3x3 dan 0,852 untuk SWS 5x5. Pada kelas tidak optimal (jarang) didapatkan *overall accuracy* yang rendah yaitu 0,670 untuk SWS 3x3 dan 0,706 untuk SWS 5x5. Oleh karena itu dilakukan perhitungan dengan metode *thresholding* khusus untuk kelas tidak optimal (jarang), dan didapatkan *overall accuracy* sebesar 0,919. Pada penelitian ini, komisi *error* banyak disebabkan oleh banyaknya rumput/semak dan omisi *error* disebabkan oleh pohon yang terpotong batas plot dan pohon dengan diameter kecil/ketinggian rendah.

Kata Kunci: Pohon Kelapa Sawit, *Canopy Height Model*, *Local maxima*, *Sliding Window Size*.

ABSTRACT

Based on the 2019-2020 National Leading Plantation Statistics Book issued by the Directorate General of Plantation, it is stated that Indonesia is ranked 1st in world palm oil exports and the world's oil palm plantation area. Since 1980, the production of palm oil in the form of crude palm oil (CPO) has continued to increase by 11.8% per year. Therefore, we need a way to simplify the process of managing oil palm plantations so that production results continue to increase, one way is to calculate oil palm trees automatically. The purpose of this study was to determine the utilization of the *Canopy Height Model* (CHM) with the *Local maxima* (LM) method in terms of automatic tree calculations by utilizing 2 *Sliding Window Size* (SWS) parameters, namely SWS 3x3 and SWS 5x5.

The research object is divided into 3 classes based on tree density per hectare, where there is an optimal class (120-150 trees/ha), a non-optimal class (medium = 60-119 trees/ha) and a non-optimal class (rare = 1-59 trees). /Ha). The result shows that the use of CHM with the LM method can detect oil palm trees automatically and gives high overall accuracy for 2 classes. The optimal class has an average overall accuracy of 0.943 for SWS 3x3 and 0.926 for SWS 5x5. In the non-optimal (medium) class, the average overall accuracy is 0.845 for SWS 3x3 and 0.852 for SWS 5x5. In the non-optimal class (rare) the overall accuracy is low, it is 0.670 for SWS 3x3 and 0.706 for SWS 5x5. Therefore, calculations were carried out using a special *thresholding* method for classes that were not optimal (rare), and the overall accuracy was obtained at 0.919. In this study, the error commission was mostly caused by the abundance of grass/shrubs and the error omission was caused by trees that were cut off by plot boundaries and trees with small diameters/low heights.

Keywords : Palm Oil Tree, *Canopy Height Model*, *Local maxima*, *Sliding Window Size*.

*) Penulis Penanggung Jawab

I. Pendahuluan

I.1 Latar Belakang

Sektor pertanian terus mengalami peningkatan seperti yang terjadi pada kuartal 2 dan 3 tahun 2020. Pada triwulan II Produk Domestik Bruto (PDB) sektor pertanian meningkat 16,24% dan pada triwulan III meningkat 2,15%. Berdasarkan data Badan Pusat Statistik (BPS), tercatat ekspor perkebunan pada periode Januari-Oktober 2020 sebesar 359,5 Triliun Rupiah atau naik 11,6% dibandingkan periode yang sama di tahun 2019. Berdasarkan nilai tersebut, subsektor perkebunan menjadi penyumbang terbesar ekspor di sektor pertanian dengan kontribusi sebesar 90,92%. Hal tersebut terjadi karena permintaan akan ekspor produk perkebunan seperti kelapa sawit, kakao, dan karet terus meningkat. Hal ini dapat mengisyaratkan bahwa subsektor perkebunan memiliki kontribusi yang kuat terhadap perekonomian nasional (Ditjenbun, 2020).

Menurut catatan Gabungan Pengusaha Kelapa Sawit Indonesia (GAPKI), pada tahun 2020, nilai sumbangan ekspor minyak kelapa sawit mencapai 260,167 triliun. Tenaga kerja yang terserap di industri sawit juga tidak sedikit, ada sekitar 4,6 juta orang yang dipekerjakan oleh pengusaha bidang kelapa sawit (Wiyanto, 2020). Melihat dari seberapa besar manfaat subsektor perkebunan khususnya kelapa sawit di Indonesia, perlu adanya Pengembangan komoditas-komoditas perkebunan strategis dengan memanfaatkan berbagai macam teknologi yang sudah tersedia demi mendukung Gerakan Peningkatan Produksi, Nilai Tambah dan Daya Saing Perkebunan (GRASIDA) yang dicanangkan Kementerian Pertanian (Ditjenbun, 2020). Salah satu permasalahan dalam pengelolaan perkebunan kelapa sawit adalah sulitnya manajemen sumber daya perkebunan yang besar dan akan memakan waktu lama jika dilakukan dengan cara konvensional seperti digitasi manual dari data foto udara.

Salah satu teknologi yang sangat efektif dalam sektor perkebunan adalah teknologi penginderaan jauh. Seperti yang ada dalam penelitian (Mohan, dkk., 2017), penelitian ini menggunakan *canopy height model* hasil dari pengukuran UAV untuk melakukan IDT (*Individual detection tree*) dengan menggunakan metode *local maxima* dan mencoba beberapa *sliding window size*, pengolahan dilakukan menggunakan CHM yang sudah di *filtering* dan yang belum di *filtering*, hasilnya adalah CHM yang sudah di *filtering* dengan ukuran SWS 3x3 dan 5x5 memiliki *overall accuracy* yang terbaik yaitu 0,86.

Penelitian (Wulder, Niemann, dan Goodenough, 2000) mengungkapkan bahwa beberapa tahun terakhir, UAV banyak digunakan dalam sektor perkebunan karena dapat menghasilkan foto udara resolusi tinggi dan memungkinkan menciptakan model 3D dengan biaya yang masuk akal. Hal ini sangat memungkinkan untuk dilakukannya analisis perkebunan secara berkala dan inventarisasi kebun. Model 3D yang didapat dari pengolahan foto udara dapat diolah menjadi *Digital Terrain Model (DTM)* dan *Digital Surface Model (DSM)* yang kemudian dapat menghasilkan *Canopy Height*

Model (CHM). CHM dapat digunakan untuk mendeteksi puncak pohon secara individu dengan metode *local maxima*. Pada penelitian ini juga menguji beberapa macam ukuran *sliding window* dan didapatkan bahwa ukuran 3x3 piksel menghasilkan akurasi yang lebih baik daripada ukuran *sliding window* yang lebih besar (5x5 dan 7x7).

Penelitian ini diharapkan dapat memberikan akurasi yang mendekati antara hasil perhitungan pohon otomatis dan hasil perhitungan pohon secara digitasi manual. Pada penelitian (Oliveira, dkk., 2011) dengan menggunakan *sliding window size* 5x5, hanya menghasilkan *error* sebanyak 599 pohon (3,42%) dari total 17390 pohon. Pada penelitian (Kattenborn, dkk., 2014), pendeteksian pohon dilakukan dengan mencari lokal maksima dari nDSM dibantu oleh *filter* gaussian, yang menghasilkan akurasi sebesar 86,1% untuk seluruh area studi dan 98,2 % dari area studi dengan kerapatan pohon tinggi.

Jumlah pohon yang terdeteksi dapat digunakan sebagai bahan analisis untuk biaya budidaya seperti jumlah pupuk dan pestisida, serta dapat digunakan dalam memperkirakan hasil panen. Hal ini dapat meningkatkan produktivitas dari perkebunan kelapa sawit yang ada di Indonesia dan secara tidak langsung akan meningkatkan taraf kesejahteraan masyarakat.

I.2 Rumusan Masalah

Rumusan masalah berdasarkan latar belakang dalam penelitian ini yaitu:

1. Bagaimana analisis hasil dari otomatisasi perhitungan pohon kelapa sawit berdasarkan metode *canopy height model* dan *local maxima* serta variasi dari *sliding window size* 3x3 dan 5x5?
2. Bagaimana analisis akurasi dari hasil perhitungan otomatis terhadap perhitungan secara manual dari PT Hanuraba Sawit Kencana?

I.3 Tujuan Penelitian dan Manfaat Penelitian

1. Tujuan
 - Tujuan dari penelitian ini adalah:
 - a. Mengetahui analisis hasil dari otomatisasi perhitungan pohon kelapa sawit berdasarkan metode *canopy height model* dan *local maxima* serta variasi dari *sliding window* 3x3 dan 5x5
 - b. Mengetahui analisis validasi akurasi dari hasil perhitungan otomatis terhadap perhitungan secara manual dari PT Hanuraba Sawit Kencana
2. Manfaat dari penelitian ini adalah:
 - a. Aspek Keilmuan
 - Ikut serta berkontribusi dalam keberagaman riset mengenai penginderaan jauh di Indonesia dan aplikasinya di bidang perkebunan yaitu perhitungan pohon secara otomatis
 - b. Aspek kerekayasaan
 - Hasil penelitian ini kedepannya dapat dijadikan sebagai referensi dalam peningkatan kualitas manajemen perkebunan.

I.4 Batasan Masalah

Penelitian ini memiliki batasan yang diharapkan tidak terlalu luas dan fokus pada tujuan tertentu. Batasan penelitian ini adalah:

1. Penelitian ini menjelaskan mengenai perhitungan otomatis pohon kelapa sawit PT Hanuraba Sawit Kencana berdasarkan data foto udara tahun 2017.
2. *Canopy height model* (CHM) didapatkan dari mengurangi data DSM dengan DTM, dimana data DSM dan DTM sudah tersedia dan didapatkan dari PT Hanuraba Sawit Kencana berdasarkan pengolahan foto udara tahun 2017. Akurasi dari DSM dan DTM nya adalah 1 m.
3. Area penelitian dibagi menjadi 2 berdasarkan jumlah pohon per hektar yaitu plot dengan kelas optimal (120-150 pohon/ha) dan plot dengan kelas tidak optimal (1-119 pohon/ha), plot dengan kelas tidak optimal akan dibagi menjadi 2 lagi yaitu kelas jarang (1-59 pohon/ha) dan sedang (60-119 pohon/ha). Sehingga ada 3 kelas.
4. Plot sampel memiliki luas 1 hektar dan akan memilih masing-masing 5 plot dari ketiga kelas yang ada
5. Menggunakan plugin *tree density calculator* pada QGIS untuk mengidentifikasi pohon, dengan parameter *sliding window* 3x3 dan 5x5.
6. Luaran berupa hasil perhitungan jumlah pohon secara individu berdasarkan data *shapefile point* yang dihasilkan dan peta dari foto udara perkebunan kelapa sawit beserta *shapefile* titik pohon hasil dari perhitungan otomatis dan *shapefile* mahkota pohon hasil dari digitasi manual.
7. Validasi dilakukan dengan data sekunder, yaitu membandingkan jumlah pohon yang didapatkan dari perhitungan otomatis dengan digitasi manual oleh PT Hanuraba Sawit Kencana. Pohon akan dianggap benar terdeteksi jika hasil *point* deteksi masih berada di area *shapefile* mahkota pohon.

II. Tinjauan Pustaka

II.1 Perkebunan Kelapa Sawit

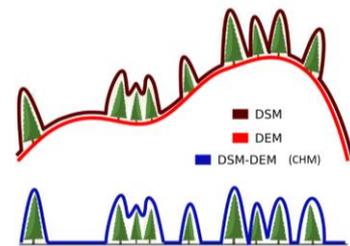
Berdasarkan Undang-Undang Nomor 18 Tahun 2004, perkebunan adalah segala kegiatan yang mengusahakan tanaman tertentu melalui tanah dan/atau media tumbuh yang lain dalam suatu ekosistem, mengolah dan memasarkan barang dan jasa hasil tanaman tersebut dengan bantuan ilmu pengetahuan dan teknologi, permodalan, serta manajemen untuk mewujudkan kesejahteraan bagi pelaku usaha perkebunan dan masyarakat.

Berdasarkan buku statistik perkebunan unggulan nasional 2019-2020 yang dikeluarkan oleh Ditjenbun, disebutkan bahwa Indonesia adalah peringkat 1 dalam ekspor sawit dunia dan luas areal perkebunan sawit dunia. Sejak tahun 1980, produksi kelapa sawit dalam bentuk CPO terus mengalami peningkatan sebesar 11,8 % tiap tahunnya.

Selain itu, menurut (Susila, 2004), Industri berbasis kelapa sawit mempunyai kontribusi signifikan terhadap kesejahteraan rumah tangga yang berasal dari usaha kelapa sawit dan menurut (Prasetya, dkk., 2016), adanya perkebunan kelapa sawit akan membuat masyarakat sekitar memperoleh berbagai fasilitas sosial yang diberikan oleh pengelola perkebunan.

II.2 Canopy Height Model (CHM)

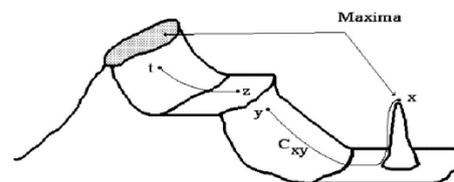
Keluaran dari proses fotogrametri adalah kumpulan data berupa kumpulan *point cloud* terinterpolasi yang berisi informasi spektral, *point cloud* ini dapat digunakan untuk membuat model permukaan digital yang berfungsi sebagai data untuk membuat *canopy height model* (CHM) (Okojie, dkk., 2020). CHM adalah model permukaan yang mewakili elevasi vegetasi di atas permukaan tanah, biasanya digunakan untuk mengekstraksi atau memperkirakan parameter hutan (Hao, Zhen, Li, dan Zhao, 2019). Untuk membuat CHM, *Digital Surface Model* (DSM) dinormalisasi menggunakan *Digital Terrain Model* (DTM) dari area yang diinginkan, yaitu $DSM - DTM = CHM$ (Okojie, dkk., 2020).



Gambar II-1 *Canopy Height Model* (Carvalho, dkk., 2019)

II.3 Local maxima

Local maxima atau *Local Maximum* sering juga disebut sebagai *local peak* atau puncak lokal, *Local maxima* akan menjadi nilai fungsi pada suatu titik dalam interval tertentu di mana nilai-nilai fungsi di dekat titik itu selalu lebih kecil dari nilai fungsi pada titik itu (Cuemath, 2013). Gambar II-2 menunjukkan ilustrasi dari *local maxima*.



Gambar II-2 Ilustrasi *Local Maxima* (Beucher, 2014)

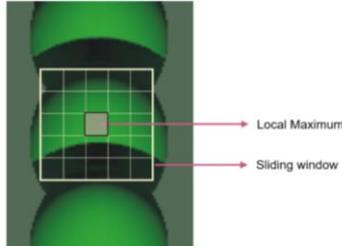
II.4 Sliding Window Size (SWS)

Sliding window size merupakan parameter yang terdapat di *plugin tree density calculator* QGIS. *Sliding window size* adalah ukuran jendela untuk mencari *local maxima*, seperti yang ditunjukkan dalam Gambar II-3 Konsep *Tree Density Calculator* (Crabbé, dkk., 2020). Nilai *sliding window* dapat bervariasi sesuai dengan kebutuhan, tetapi didalam QGIS sendiri nilai default-nya adalah 5x5 piksel. Pemilihan ukuran SWS yang sesuai adalah hal yang penting. Ukuran SWS yang besar menyebabkan kesalahan omisi di mana pohon tidak akan terdeteksi. Sebaliknya, ukuran jendela yang kecil menghasilkan kesalahan komisi dimana area bukan pohon akan dideteksi sebagai pohon (Mansour dan Chockalingam, 2020)

II.5 Tree density Plugin

Tree density plugin adalah salah satu *plugin open source* yang ada pada *software* QGIS. Konsep dari *tree density calculator* ditunjukkan pada Gambar II-2 dimana

puncak pohon merupakan bagian paling terang dalam suatu citra. *Tree density calculator* akan menggunakan parameter *sliding window* untuk mencari lokasi, dan *tree density calculator* akan memeriksa apakah titik tengah *sliding window* adalah bagian piksel yang paling terang, jika iya maka piksel tersebut akan ditandai sebagai *local maxima* dan teridentifikasi sebagai pohon.



Gambar II-3 Konsep *Tree Density Calculator* (Crabbé, dkk., 2020)

II.6 Otsu Thresholding

Penggunaan metode otsu thresholding dilakukan karena hasil *overall* akurasi dari plot kelas tidak optimal (jarang) kurang memuaskan, oleh karena itu diberikan metode lain supaya hasil *overall* akurasi lebih tinggi. Konsep Otsu *thresholding* pertama kali diperkenalkan oleh Nobuyuki Otsu pada tahun 1979 untuk pengelompokan citra biner berdasarkan bentuk histogram secara otomatis, mengasumsikan bahwa citra berisi dua kelas dasar dengan bentuk histogram bimodal (*foreground* dan *background*). Tujuan dari metode Otsu membagi histogram citra keabuan kedalam dua daerah yang berbeda secara otomatis tanpa membutuhkan bantuan user. Metode Otsu merupakan metode populer diantara semua metode *thresholding* dan metode terbaik dalam mendapatkan nilai *threshold* secara otomatis (Ambarwati, Pasarella, dan Sutarno, 2016).

II.7 Uji Akurasi

Akurasi perhitungan jumlah pohon dinilai dengan membandingkan hasil perhitungan pohon yang telah dilakukan sebelumnya dengan metode digitasi manual dengan hasil deteksi pohon secara otomatis. Untuk setiap pohon yang diketahui, satu puncak yang terdeteksi dalam batas mahkota pohon dipilih untuk mewakili pohon dan sisanya. Kesalahan komisi dihitung ketika titik hasil deteksi mengidentifikasi objek diluar dari mahkota pohon. Kesalahan omisi dihitung ketika tidak ada titik yang terdeteksi dalam batas mahkota pohon yang diketahui (Pouliot, dkk., 2002). Berdasarkan (Yun, et al., 2021). akurasi perhitungan pohon secara otomatis dihitung dengan persamaan:

$$r = \frac{TP}{(TP+FN)} \dots\dots\dots II-1$$

$$p = \frac{TP}{(TP+FP)} \dots\dots\dots II-2$$

$$f = 2 \times \frac{(r \times p)}{(r+p)} \dots\dots\dots II-3$$

Keterangan:
 TP (*True Positive*) = Jumlah pohon yang terdeteksi dengan benar

FN (*False Negative*) = Jumlah pohon yang tidak terdeteksi (*Omisi error*)

FP (*False Positive*) = Jumlah pohon yang terdeteksi padahal tidak ada di lapangan (*Komisi error*)

r (*Recall*) = *Tree detection rate*

p (*Precision*) = Ketepatan dalam deteksi pohon

f = *Overall accuracy*

III. Metodologi Penelitian

Metodologi dalam penelitian meliputi peralatan penelitian, data penelitian dan diagram alir penelitian serta tahapannya.

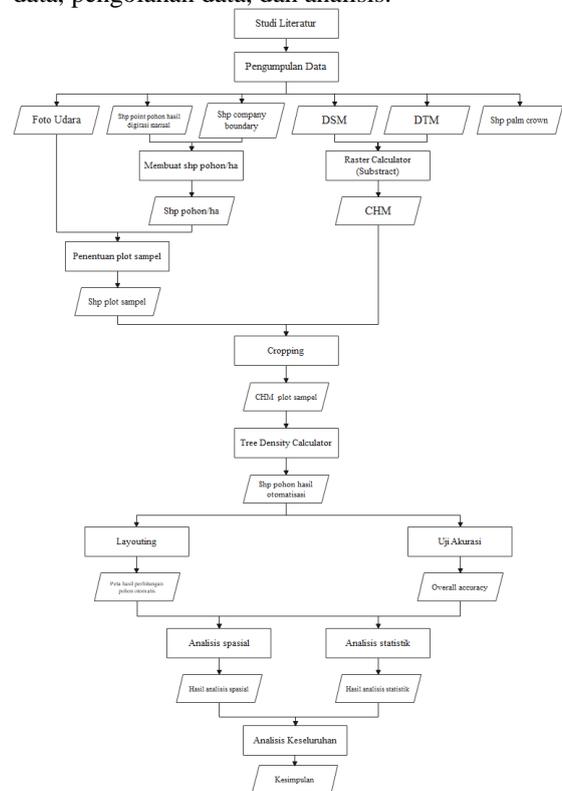
III.1 Peralatan dan Data Penelitian

Alat dan data penelitian yang dibutuhkan dalam penelitian sebagai berikut:

1. Peralatan Penelitian
 - a. Laptop Dell Inspiron, intel core i7 gen 8, RAM 8gb, HD 2 TB.
 - b. Microsoft Office 2016
 - c. QGIS 3.16.8 Hannover
 - d. ImageJ
2. Data Penelitian
 - a. Foto udara PT Hanuraba Sawit Kencana 2017
 - b. DSM PT Hanuraba Sawit Kencana 2017
 - c. DTM PT Hanuraba Sawit Kencana 2017
 - d. *Shapefile* pohon kelapa sawit hasil digitasi manual
 - e. *Shapefile* mahkota pohon kelapa sawit

III.2 Diagram alir penelitian

Berdasarkan pada Gambar III-1 penelitian terbagi menjadi beberapa tahapan yaitu persiapan, pengumpulan data, pengolahan data, dan analisis.



Gambar III-1 Diagram Alir Penelitian Pada tahapan persiapan meliputi studi literatur, studi pendahuluan serta persiapan peralatan dan bahan

yang akan digunakan dalam penelitian. Tahapan pengumpulan data dilakukan untuk data sekunder. Data penelitian dapat dilihat pada subbab III.1.

Tahapan pengolahan dimulai dengan membuat shp pohon per hektar di seluruh area foto udara, setelah itu menentukan plot sampel yang akan digunakan dalam penelitian. Plot sampel yang dipilih berjumlah 5 plot per tiap kelas dengan ukuran 100 m x 100 m. Setelah itu dilakukan proses pembuatan CHM dengan cara mengurangi data DSM dengan DTM. Lalu CHM di potong sesuai dengan shp plot sampel yang sudah dibuat sebelumnya. CHM masing-masing plot sampel kemudian diolah dengan cara dilakukan *filtering* terlebih dahulu dengan menggunakan Gaussian *filtering*, lalu diolah dengan menggunakan *tree density plugin* pada aplikasi QGIS untuk mendeteksi pohon, pada proses ini dilakukan 2 kali pengolahan menggunakan parameter yang berbeda yaitu SWS 3x3 dan SWS 5x5. Setelah proses tersebut, didapatkan hasil yang mengecewakan pada kelas tidak optimal (jarang), oleh karena itu penulis mencoba mengolahnya dengan metode lain yaitu *otsu thresholding*. Pengolahan ini dilakukan dengan *software ImageJ* yang merupakan *software open source*. Caranya adalah memasukkan CHM plot sampel tidak optimal (jarang), lalu dilakukan *subtract background*, *pan sharpening*, dan *otsu thresholding*. Hasilnya adalah suatu citra biner yang harus diolah lanjutan dengan QGIS dengan cara *raster to polygon* lalu *centroids* untuk mendapatkan shp *point* terdeteksi. Setelah itu dilakukan uji akurasi dengan cara *overlay* dengan shp mahkota pohon, jika *point* deteksi pohon ada didalam shp mahkota pohon maka pohon itu terdeteksi (*true positive*), jika shp *point* pohon ada di luar shp mahkota pohon maka itu adalah kesalahan mendeteksi objek bukan pohon sebagai pohon (komisi *error/false positive*) dan jika shp mahkota pohon tidak ada shp *point* pohonnya maka pohon itu tidak terdeteksi (*true negative/omisi error*).

Tahapan setelah pengolahan data adalah proses analisis. Pada tahapan ini akan dilakukan analisis terhadap shp *point* yang dihasilkan. Akan dianalisis mengapa bisa terjadi komisi error seperti banyaknya rumput/semak. Mengapa bisa terjadi omisi error seperti pohon yang berdiameter kecil dan rendah. Juga dilakukan analisis mengenai nilai *rate detection*, presisi, dan *overall accuracy* nya.

IV. Hasil dan Pembahasan

IV.1 Analisis Hasil Perhitungan Pohon Otomatis

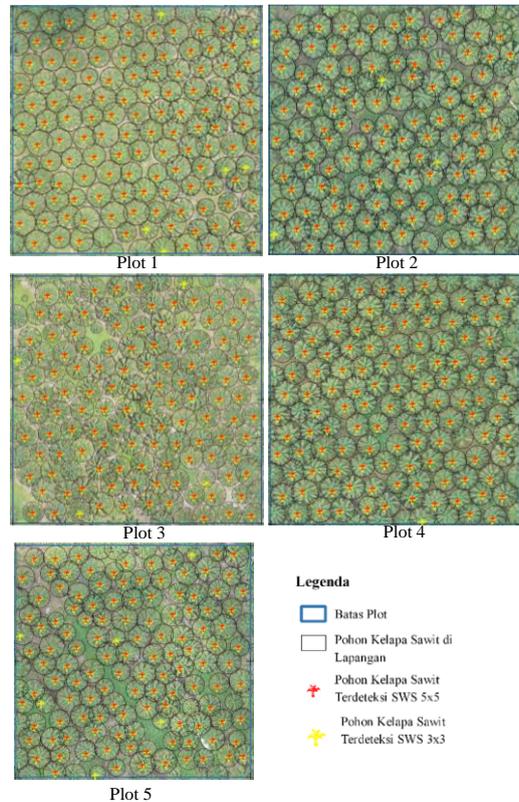
IV.1.1 Kelas Optimal

Berdasarkan Gambar IV-1, informasi yang ditemukan adalah:

1. Semua plot tidak memiliki komisi *error* karena kerapatan pohon yang tinggi
2. SWS 3x3 mendeteksi objek lebih banyak dan semua objek tersebut benar merupakan pohon
3. Sebagian besar kesalahan omisi *error* dihasilkan oleh pohon yang berada di tepi sehingga pohon tersebut terpotong oleh batas plot dan tidak utuh saat dilakukan pemrosesan. Pada SWS 3x3 sebanyak 82,4% dan pada SWS 5x5 sebanyak

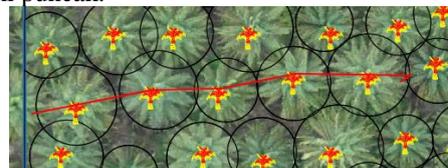
74,5% kesalahan omisi *error* berasal dari pohon yang berada di tepi.

4. Selain karena pohon yang berada di tepi batas plot, omisi *error* juga bisa terjadi karena pohon yang diameternya kecil, tingginya rendah, maupun pohon yang terlalu bertempelan satu sama lain.

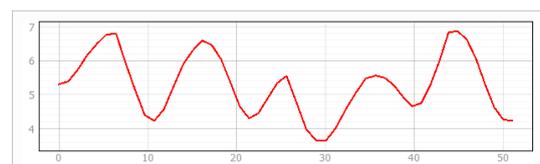


Gambar IV-1 Hasil Deteksi Pohon pada Kelas Optimal

Gambar IV-2 merupakan pohon yang terdeteksi pada plot 2, jika ditarik garis profil pada kelima pohon tersebut maka akan menghasilkan *profile graph* seperti pada Gambar IV-3. terlihat bahwa semua pohon tersebut terdeteksi karena mereka adalah *local maxima* atau memiliki puncak.

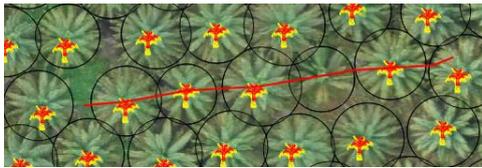


Gambar IV-2 Contoh True Positive Kelas Optimal

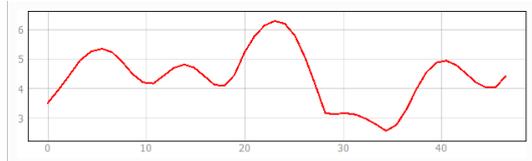


Gambar IV-3 Profile Graph Contoh True Positive Kelas Optimal

Pada Gambar IV-4, terdapat 1 omisi *error* (pohon yang tidak terdeteksi). Jika dilihat dari profile graphnya pada Gambar IV-5, benar saja pohon tersebut tidak terdeteksi karena dia tidak memiliki puncak.



Gambar IV-4 Contoh Omisi Error Kelas Optimal

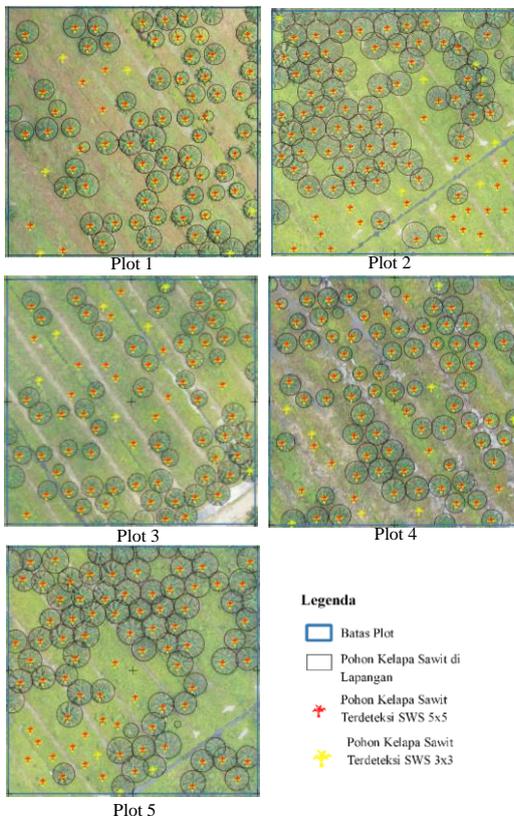


Gambar IV-5 Profile Graph Contoh Omisi Error Kelas Optimal

IV.1.2 Kelas Tidak Optimal (Sedang)

Berdasarkan Gambar IV-6, dapat diambil informasi berupa:

1. Banyak terdapat komisi *error*, terutama pada daerah ditumbuhi rumput maupun semak. Hal ini karena seluruh plot memiliki *background* rumput dan semak yang cukup tebal.
2. Sama seperti kategori optimal, omisi *error* pada kategori ini banyak yang terdeteksi pada bagian tepi dimana pohon terpotong oleh batas plot
3. SWS 3x3 memberikan komisi *error* yang lebih banyak tetapi omisi *error* yang lebih sedikit, berbanding terbalik dengan SWS 5x5.



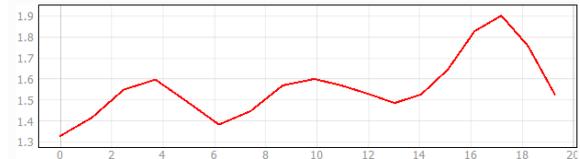
Gambar IV-6 Hasil Deteksi Pohon pada Kelas Tidak Optimal (Sedang)

Gambar IV-7 Menunjukkan komisi *error* yang ada pada plot 2 kelas tidak optimal (sedang). Komisi

error tersebut berada pada rerumputan, jika dilihat *profile graph* nya pada Gambar IV-8, rumput tersebut memiliki ketinggian yang lebih dibanding sekitarnya sehingga membentuk *local maxima*, hal inilah yang menyebabkan rumput tersebut terdeteksi sebagai pohon

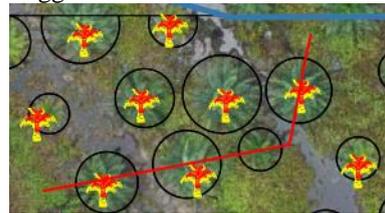


Gambar IV-7 Contoh Komisi Error Kelas Tidak Optimal (Sedang)

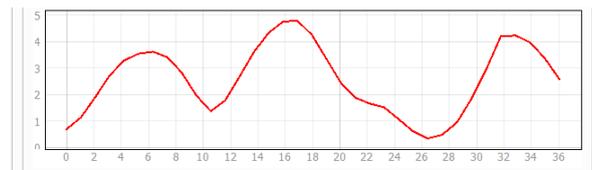


Gambar IV-8 Profile Graph Contoh Komisi Error Kelas Tidak Optimal (Sedang)

Gambar IV-9 Menunjukkan omisi *error* yang ada pada kelas tidak optimal (sedang), pohon yang tidak terdeteksi itu memiliki ukuran yang lebih kecil dibanding pohon lain. Jika dilihat *profile graph* nya pada Gambar IV-10, terlihat bahwa pohon tersebut tidak memiliki puncak sehingga ia tidak terdeteksi.



Gambar IV-9 Contoh Omisi Error Kelas Tidak Optimal (Sedang)

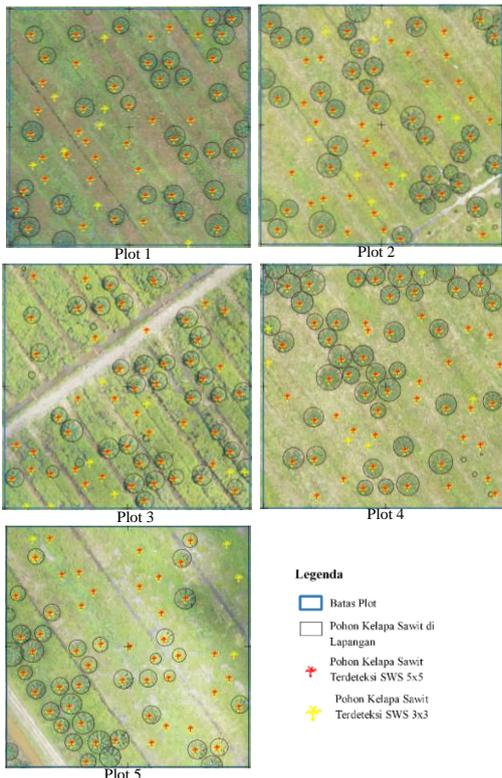


Gambar IV-10 Profile Graph Contoh Omisi Error Kelas Tidak Optimal (Sedang)

IV.1.3 Kelas Tidak Optimal (Jarang)

Berdasarkan Gambar IV-11, diperoleh informasi berupa :

1. Jumlah komisi *error* sangat banyak karena banyaknya rumput dan semak dan lebih sedikit pohon
2. Omisi *error* terjadi karena pohon ada di tepi gambar sehingga terpotong batas plot dan pohon yang memiliki ukuran kecil
3. Mengubah SWS dari 5x5 ke SWS 3x3 hanya berpengaruh kecil terhadap nilai *overall accuracy*, hal ini hanya akan menambah komisi *error* semakin banyak dan hanya memperbaiki sedikit omisi *error*
4. Kelas ini memiliki *overall accuracy* yang paling rendah

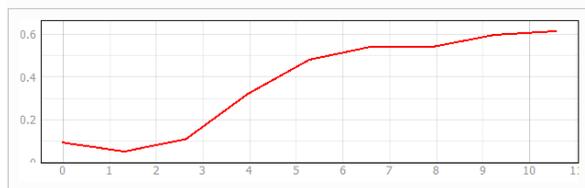


Gambar IV-11 Hasil Deteksi Pohon pada Kelas Tidak Optimal (Jarang)

Gambar IV-12 merupakan omisi *error* pada kelas tidak optimal (jarang), dua buah omisi *error* tersebut merupakan pohon dengan ukuran yang sangat kecil, jika dilihat pada profile graphnya pada Gambar IV-13, 2 pohon tersebut tidak memiliki puncak dan memiliki ketinggian < 0,6 m.



Gambar IV-12 Contoh Omisi *Error* Kelas Tidak Optimal (Jarang)

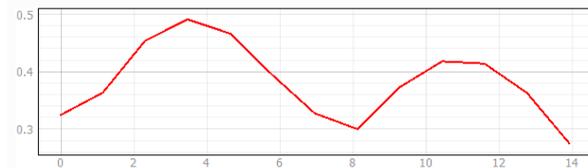


Gambar IV-13 *Profile Graph* Contoh Omisi *Error* Kelas Tidak Optimal (Jarang)

Gambar IV-14 merupakan komisi *error* yang ada pada kelas tidak optimal (jarang), komisi *error* yang ada pada kelas ini sangat banyak dan semuanya terjadi pada rumput/semak. Seperti yang dapat dilihat pada *profile graph* di Gambar IV-15, 2 buah komisi *error* tersebut membentuk puncak sehingga terdeteksi sebagai pohon.



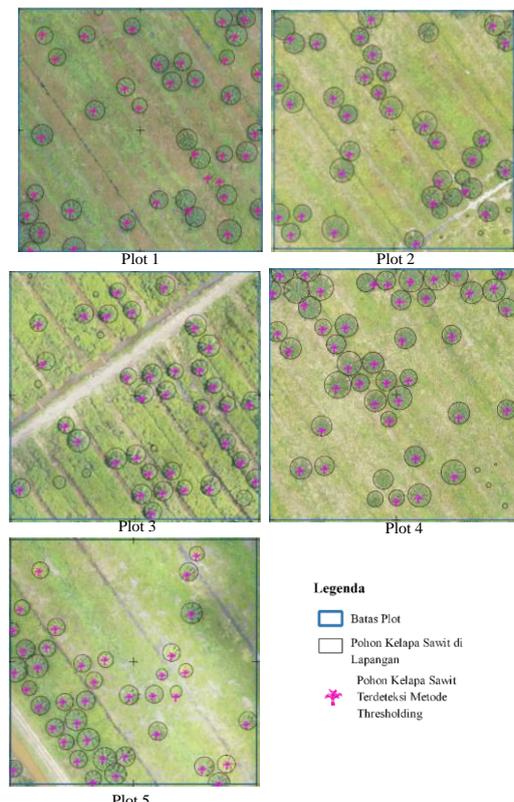
Gambar IV-14 Contoh Komisi *Error* Kelas Tidak Optimal (Jarang)



Gambar IV-15 *Profile Graph* Contoh Komisi *Error* Kelas Tidak Optimal (Sedang)

Selanjutnya adalah hasil dari perhitungan pohon otomatis dengan metode Otsu Thresholding pada software ImageJ. Berdasarkan Gambar IV-16 yang merupakan hasil thresholding, dapat diambil informasi berupa

1. Dalam melakukan perhitungan pohon, metode *thresholding* hanya cocok digunakan jika pohon memiliki jarak satu sama lain dan tidak bertempelan
2. Pohon dengan diameter kecil dan ketinggian rendah tidak terdeteksi
3. Pohon yang menempel satu sama lain akan terdeteksi sebagai satu pohon
4. Metode ini dapat menekan angka komisi *error* yang sangat banyak dihasilkan pada metode *local maxima*



Gambar IV-16 Hasil Deteksi Pohon pada Kelas Tidak Optimal (Jarang) Metode *Thresholding*

IV.2 Analisis Uji Akurasi Perhitungan Pohon Otomatis

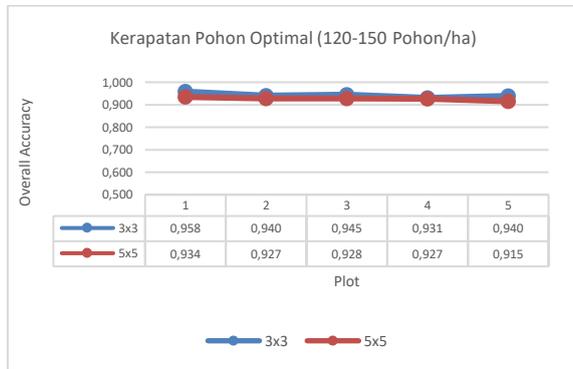
IV.2.1 Kelas Optimal

Tabel IV-1 Menunjukkan detail jumlah deteksi, kesalahan, dan akurasi pada plot optimal. Dapat dilihat bahwa seluruh plot memiliki 0 komisi *error* sehingga presisi deteksinya adalah 100%.

Tabel IV-1 Tabel Akurasi Plot Optimal

	Plot 1		Plot 2		Plot 3		Plot 4		Plot 5	
	3x3	5x5								
Density (Tree/Ha)	138 Pohon/Ha		133 Pohon/Ha		134 Pohon/Ha		139 Pohon/Ha		141 Pohon/Ha	
Jumlah pohon terdeteksi	127	121	118	115	120	116	121	120	125	119
TP	127	121	118	115	120	116	121	120	125	119
FP	0	0	0	0	0	0	0	0	0	0
FN	11	17	15	18	14	18	18	19	16	22
r	0,92	0,88	0,89	0,86	0,90	0,87	0,87	0,86	0,89	0,84
p	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
f	0,96	0,93	0,94	0,93	0,94	0,93	0,93	0,93	0,94	0,92

Gambar IV-17 menunjukkan *overall accuracy* dari plot pada kelas optimal, dapat dilihat bahwa garis sangat berhimpitan yang berarti nilai *overall accuracy* ada di angka yang stabil. Rata-rata *overall accuracy* untuk SWS 3x3 adalah 0,943 dan rata-rata untuk SWS 5x5 adalah 0,926.



Gambar IV-17 Grafik Overall Accuracy Kelas Optimal

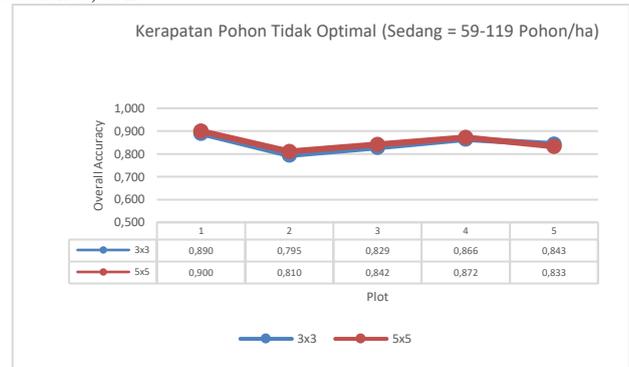
IV.2.2 Kelas Tidak Optimal (Sedang)

Tabel IV-2 menunjukkan detail deteksi, kesalahan, dan akurasi dari plot pada kelas tidak optimal (Sedang). Pada kelas ini ditemukan lumayan banyak omisi *error* maupun komisi *error*, dimana omisi *error* SWS 5x5 akan lebih banyak daripada SWS 3x3 tetapi komisi *error* SWS 3x3 akan lebih banyak daripada SWS 5x5.

Tabel IV-2 Tabel Akurasi Plot Tidak Optimal (Sedang)

	Plot 1		Plot 2		Plot 3		Plot 4		Plot 5	
	3x3	5x5								
Density (Tree/Ha)	72 Pohon/Ha		74 Pohon/Ha		64 Pohon/Ha		81 Pohon/Ha		78 Pohon/Ha	
Jumlah pohon terdeteksi	74	68	87	79	76	69	83	75	81	78
TP	65	63	64	62	58	56	71	68	67	65
FP	9	5	23	17	18	13	12	7	14	13
FN	7	9	10	12	6	8	10	13	11	13
r	0,90	0,88	0,86	0,84	0,91	0,88	0,88	0,84	0,86	0,83
p	0,88	0,93	0,74	0,78	0,76	0,81	0,86	0,91	0,83	0,83
f	0,89	0,90	0,80	0,81	0,83	0,84	0,87	0,87	0,84	0,83

Gambar IV-18 Grafik *Overall Accuracy* Kelas Tidak Optimal (Sedang) grafik *overall accuracy* untuk kelas ini, garis saling berhimpitan yang menunjukkan nilai *overall accuracy* ada di angka yang stabil. Rata-rata *overall accuracy* untuk SWS 3x3 adalah 0,845 dan untuk SWS 5x5 adalah 0,852.



Gambar IV-18 Grafik Overall Accuracy Kelas Tidak Optimal (Sedang)

IV.2.3 Kelas Tidak Optimal (Jarang)

Berdasarkan Tabel IV-3, pada kelas ini memiliki sangat banyak komisi *error* sehingga nilai presisi deteksinya cukup rendah.

Tabel IV-3 Tabel Akurasi Plot Tidak Optimal (Jarang)

	Plot 1		Plot 2		Plot 3		Plot 4		Plot 5	
	3x3	5x5								
Density (Tree/Ha)	37 Pohon/Ha		41 Pohon/Ha		42 Pohon/Ha		49 Pohon/Ha		39 Pohon/Ha	
Jumlah pohon terdeteksi	58	50	65	57	62	54	64	58	54	50
TP	31	31	31	31	36	35	39	37	34	34
FP (komisi error)	27	19	34	26	26	19	25	21	20	16
FN	6	6	10	10	6	7	10	12	5	5
r	0,84	0,84	0,76	0,76	0,86	0,83	0,80	0,76	0,87	0,87
p	0,53	0,62	0,48	0,54	0,58	0,65	0,61	0,64	0,63	0,68
f	0,65	0,71	0,58	0,63	0,69	0,73	0,69	0,69	0,73	0,76

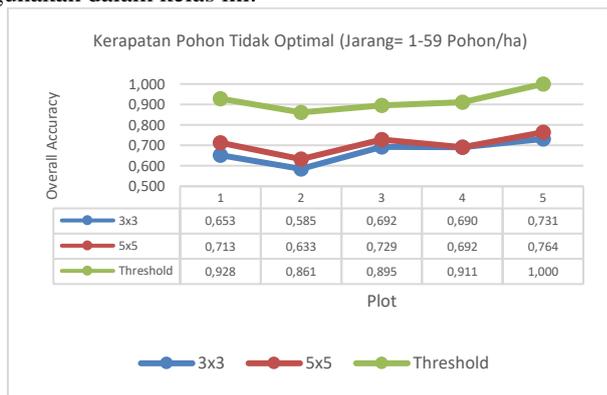
Berdasarkan Tabel IV-4, nilai komisi *error* dan omisi *error* berkurang sangat banyak dibanding metode *local maxima*, bahkan pada plot 5 tidak ditemukan sama

sekali omisi *error* maupun komisi *error* sehingga *overall accuracy*-nya 1,00 atau 100%.

Tabel IV-4 Tabel Akurasi Plot Tidak Optimal (Jarang)
Metode *Thresholding*

	Plot				
	1	2	3	4	5
Density (Tree/Ha)	37	41	42	49	39
Jumlah pohon terdeteksi	36	31	34	41	39
TP	32	31	34	41	39
FP	2	0	0	0	0
FN	3	10	8	8	0
r	0,91	0,76	0,81	0,84	1,00
p	0,94	1,00	1,00	1,00	1,00
f	0,93	0,86	0,89	0,91	1,00

Berdasarkan Gambar IV-19, *overall accuracy* dari metode *thresholding* meningkat sangat jauh dibandingkan dengan metode *local maxima* dimana rata-rata *overall accuracy* dari metode *thresholding* adalah 0,919 sedangkan *overall accuracy* metode *local maxima* SWS 3x3 adalah 0,670 dan untuk SWS 5x5 adalah 0,706. Dapat disimpulkan bahwa metode *local maxima* tidak cocok digunakan dalam kelas ini.



Gambar IV-19 Grafik *Overall Accuracy* Kelas Tidak Optimal (Jarang)

IV.3 Simpulan

Berdasarkan hasil dan pembahasan dari penelitian ini dapat disimpulkan sebagai berikut.

1. Pada kelas optimal, komisi *error* tidak ditemukan karena jarak pohon yang rapat, SWS 3x3 memberikan hasil yang lebih baik daripada SWS 5x5 karena SWS 3x3 akan mendeteksi lebih banyak pohon. Pada kelas tidak optimal (sedang), SWS 3x3 akan menghasilkan komisi *error* yang lebih banyak daripada SWS 5x5 tapi SWS 5x5 akan menghasilkan omisi *error* yang lebih banyak. SWS 5x5 memberikan hasil yang sedikit lebih baik daripada SWS 3x3. Pada kelas tidak optimal (jarang), terdapat sangat banyak komisi *error* karena minimnya pohon dan banyak rumput/semak yang ada, sehingga SWS 5x5 akan memberikan hasil yang lebih baik daripada SWS 3x3, pada kelas ini juga dilakukan perhitungan pohon dengan metode *thresholding* yang akan menekan sangat banyak jumlah komisi *error*

maupun omisi *error* sehingga memberikan hasil yang lebih baik.

2. Metode perhitungan pohon kelapa sawit secara otomatis berbasis CHM dan *local maxima* dapat menghitung pohon dengan akurasi yang baik. Pada kelas optimal, rata-rata *overall accuracy* yang didapatkan adalah 0,943 untuk SWS 3x3 dan 0,926 untuk SWS 5x5. Pada kelas tidak optimal (sedang), rata-rata *overall accuracy*-nya adalah 0,845 untuk SWS 3x3 dan 0,852 untuk SWS 5x5. Pada kelas tidak optimal (jarang) didapatkan *overall accuracy* yang rendah yaitu 0,670 untuk SWS 3x3 an 0,706 untuk SWS 5x5. Oleh karena itu dilakukan perhitungan dengan metode *thresholding* khusus untuk kelas tidak optimal (jarang), dan didapatkan *overall accuracy* sebesar 0,919.

IV.4 Saran

Berikut saran yang dapat diperhatikan bagi penelitian selanjutnya agar penelitian kedepannya dapat terlaksana dengan baik yaitu:

1. Memilih lebih banyak plot untuk dijadikan sampel
2. Menggunakan ukuran plot sampel dengan ukuran yang lebih bervariasi
3. Menggunakan data dengan resolusi spasial yang tinggi
4. Memotong batas plot sesuai dengan bentuk pohon sehingga tidak ada pohon dibagian tepi yang terpotong

DAFTAR PUSTAKA

Allorerung, D., Syakir, M., Poeloengan, Z., Syafaruddin, & Rumini, W. (2010). *Budidaya Kelapa Sawit*. Bogor: Aska Media.

Ambarwati, A., Pasarella, R., & Sutarno. (2016). Segmentasi Citra Digital Menggunakan Thresholding Otsu untuk Analisa Perbandingan Deteksi Tepi. *Annual Research Seminar*, 216-226.

Beucher, S. (2014). Maxima and Minima: A Review. *Mines Paristech Journal*, 1-13.

Cuemath. (2013). *Maxima and Minima*. Retrieved from <https://www.cuemath.com/calculus/maxima-and-minima/>

Ditjenbun. (2020). *Kementerian Pertanian Direktorat Jenderal Perkebunan*. Retrieved from Peluang Ekspor Perkebunan Masih Bertahan: <http://ditjenbun.pertanian.go.id/peluang-ekspor-perkebunan-masih-bertahan/>

Hao, Y., Zhen, Z., Li, F., & Zhao, Y. (2019). A graph-based progressive morphological filtering (GPMF) method for generating canopy height models using ALS data. *International Journal of Applied Earth Observation and Geoinformation*, 84-96.

Republik Indonesia. (2004). *Undang-Undang Nomor 18 Tahun 2004 Tentang Perkebunan*. Kementerian Pertanian.

Kattenborn, T., Sperlich, M., Bataua, K., & Koch, B. (2014). Automatic Single Palm Tree Detection In Plantations Using Uav-Based Photogrammetric

- Point Clouds. *Remote Sensing and Spatial Information Sciences*, 139-144.
- Mohan, M., Silva, C. A., Klauberg, C., Jat, P., Catts, G., Cardil, A., . . . Dia, M. (2017). Individual Tree Detection from Unmanned Aerial Vehicle (UAV) Derived Canopy Height Model in Vehicle (UAV) Derived Canopy Height Model in. *Journal Forest*, 1-17.
- Okojie, J. A., Okojie, L. O., Effiom, A. E., & Odia, B. E. (2020). Relative canopy height modelling precision from UAV and ALS datasets for forest tree height estimation. *Journal Remote Sensing Applications: Society and Environment*, 2352-9385.
- Oliveira, L. T., Carvalho, L. M., Ferreira, M. Z., Oliveira, T. C., & Junior, F. W. (2011). Application Of Lidar To Forest Inventory For Tree Count In Stands Of Eucalyptus sp . *Application of LIDAR to forest inventory*, 175-184.
- Pouliot, D., King, D., Bell, F., & Pitt, D. (2002). Automated tree crown detection and delineation in high-resolution digital camera imagery of coniferous forest regeneration. *Remote Sensing of Environment*, 322-334.
- Praselia, H., Annisa, N., Ariffin, Muhaimin, A. W., & Soemarno. (2016). Nilai Ekonomi, Lingkungan, dan Sosial dari Perkebunan Kelapa Sawit Swadaya di Kabupaten Seruyan, Kalimantan Tengah, Indonesia. *Jurnal Teknik Lingkungan*, 71-77.
- Susila, W. (2004). Contribution Of Oil Palm Industry To Economic Growth And Poverty Alleviation In Indonesia. *Jurnal Litbang Pertanian*, 107-114.
- Wiyanto. (2020). Retrieved from Informasi Manfaat Sawit Bagi Perekonomian: <https://www.industry.co.id/read/61493/informasi-manfaat-sawit-bagi-perekonomian>
- Wulder, M., Niemann, K. O., & Goodenough, D. G. (2000). Local Maximum Filtering for the Extraction of Tree Locations and Basal Area from High Spatial Resolution Imagery. *Journal Remote Sensing of Environment*, 103-114.
- Yun, T., Jiang, K., Li, G., Eichhorn, M. P., Fan, J., Liu, F., . . . Cao, L. (2021). Individual tree crown segmentation from airborne LiDAR data using a novel Gaussian filter and energy function minimization-based approach. *Journal Remote Sensing of Environment*.