

ISBN No. 978-623-7525-42-4

PROSEDUR PEMBANGUNAN MODEL FENOLOGI KELAPA SAWIT BERBASIS PENGINDRAAN JAUH



Institut Teknologi Nasional

www.itenas.ac.id

Oleh :

Soni Darmawan, dkk.

 **penerbit** itenas

it's
good
start

PROSEDUR PEMBANGUNAN MODEL FENOLOGI KELAPA SAWIT
BERBASIS PENGINDRAAN JAUH

Penyusun:

1. Soni Darmawan
2. Ita Carolita
3. Agustan
4. Dede Dirgahayu
5. Widya Suyadini
6. Rika Hernawati
7. Dhimas Wiratmoko

Editor:

1. Ita Carolita
2. Dede Dirgahayu

Desain Sampul dan Isi:

1. Rika Hernawati
2. Della Meiralarasari

Cetakan I, 2021

ISBN: 978-623-7525-42-4

Diterbitkan Oleh: Institut Teknologi Nasional Bandung

Jl. PKH Mustofa no 23, Bandung, Jawa Barat, Indonesia. 40124.

Kata Pengantar

Indonesia merupakan penghasil minyak kelapa sawit terbesar di dunia yang saat ini arah pengembangan perkebunan kelapa sawit nasional adalah peningkatan produktivitas sawit. Fenologi sawit merupakan parameter kunci utama dalam perhitungan produktivitas. Buku ini berupa prosedur pembangunan model fenologi kelapa sawit berbasis teknologi pengindraan jauh. Sebelum membahas prosedur pembangunan model fenologi, terlebih dahulu buku ini membahas state of the art pembangunan model kelapa sawit di Indonesia dan dunia yang dilanjutkan dengan pengolahan citra untuk pembangunan model fenologi kelapa sawit diantaranya ; pemilihan data pengindraan jauh, pra pengolahan, penentuan training sample, penentuan model fenologi dan validasi.

Penyusun banyak mengucapkan terimakasih yang sebesar-besarnya kepada semua pihak yang terlibat dalam penyelesaian buku ini, dan mohon maaf bila ternyata masih banyak kekurangan yang ditemui.

Semoga Allah SWT membalas amal kebaikan kita semua, Aamiin.

Bandung, Juni 2021

Penyusun

Kata Pengantar

Alhamdulillah Puji dan Syukur buku **Prosedur Pembangunan Model Fenologi Kelapa Sawit Berbasis Penginderaan Jauh** telah selesai disusun. Buku ini merupakan bagian dari buku lainnya, buku lainnya adalah ***Model Fenologi Kelapa Sawit Berbasis Penginderaan Jauh*** dan **Informasi Tematik Umur Kelapa Sawit Penginderaan Jauh**. Buku buku ini hasil penelitian skema Prioritas Riset Nasional (PRN) bidang Penginderaan Jauh dimana hasil akhir dari PRN Penginderaan Jauh adalah platform antarmuka sistem pengamatan bumi *platyphus*. Platform antarmuka sistem pengamatan bumi *plathypus* diantaranya untuk daerah konservasi, kebencanaan, pencegahan pencemaran dan pemanfaatan sumber daya alam dimana pemanfaatan kawasan pertanian dan perkebunan salah satunya adalah kelapa sawit.

Seperti kita ketahui bahwa pemanfaatan teknologi penginderaan jauh sudah berkembang pesat dan hampir digunakan di segala aspek khususnya bidang pertanian dan perkebunan. Teknologi pengindraan jauh merupakan salah satu inovasi-teknologi yang dapat dimanfaatkan untuk perkebunan kelapa sawit, karena mampu memberikan informasi yang cepat, berulang, dan akurat pada area kelapa sawit yang luas. Teknologi pengindraan jauh dapat menunjang manajemen perkebunan kelapa sawit berkelanjutan dan membantu menyelesaikan beberapa masalah lingkungan misalnya, mendeteksi deforestasi, penyakit, kesehatan, masalah hama, estimasi pajak hingga meningkatkan

produktivitas. Hal utama untuk memantau produktivitas kelapa sawit adalah dengan mengidentifikasi umur atau fenologi kelapa sawit.

Buku **Prosedur Pembangunan Model Fenologi Kelapa Sawit Berbasis Penginderaan Jauh** berisi *state of the art* model fenologi kelapa sawit, pengolahan citra penginderaan jauh meliputi pemilihan data citra, praprocessing, penentuan training sample, dan penentuan model fenologi dan validasi. Buku ini sangat menarik dan berbeda dengan buku lainnya karena fokus berisi prosedur pembentukan model fenologi dari berbagai citra optis dan radar (Landsat, Sentinel dan Alos Palsar) dan cara validasinya.

Demikian pengantar dari saya semoga buku ini bermanfaat dan semoga terbit buku-buku lainnya berkaitan dengan Penginderaan Jauh.

Terimakasih

Jakarta, Juli 2021

Dr. M. Rokhis Khomarudin, M.Si.
Koordinator PRN INDERAJA

Daftar Isi

| | |
|---|------|
| Kata Pengantar | ii |
| Daftar Isi | v |
| DAFTAR GAMBAR | vii |
| DAFTAR TABEL | viii |
| BAB I. Pendahuluan | 1 |
| 1.1 Latar Belakang | 1 |
| 1.2 Maksud dan Tujuan | 4 |
| 1.3 Ruang Lingkup | 5 |
| BAB II. STATE-OF-THE ART MODEL FENOLOGI KELAPA SAWIT .. | 6 |
| BAB III. PENGOLAHAN CITRA..... | 14 |
| 3.1 Pemilihan Data Pengindraan Jauh | 14 |
| 3.2 Pra-Processing Citra Satelit | 15 |
| 3.2.1 Citra Satelit Landsat..... | 15 |
| 3.2.2 Citra Satelit ALOS PALSAR..... | 18 |
| 3.2.3 Citra Satelit Sentinel-1A..... | 21 |
| 3.3 Penentuan Training Sampel | 22 |
| 3.4 Penentuan Model Fenologi..... | 23 |
| 3.4.1 Model Fenologi Data Landsat..... | 26 |
| 3.4.2 Model Fenologi Data ALOS PALSAR 2 | 28 |

| | |
|--|----|
| 3.4.3 Model Fenologi Data Sentinel-1A..... | 30 |
| 3.5 Validasi | 36 |
| BAB IV. KESIMPULAN..... | 39 |
| DAFTAR PUSTAKA..... | 41 |

Daftar Gambar

| | |
|--|----|
| Gambar 3.1 Visualisasi Hasil NDVI untuk lokasi Asahan, Sumatera Utara | 18 |
| Gambar 3.2 Citra ALOS PALSAR 2 polarisasi (a) HH dan (b) HV | 19 |
| Gambar 3.3 Citra Sentinel-1A untuk daerah Asahan, Sumatera Utara. | 22 |
| Gambar 3.4 Training sampel blok tahun tanam kelapa sawit untuk perkebunan di Asahan, Sumatera Utara..... | 23 |
| Gambar 3.5 Model Fenologi untuk kelas kesesuaian lahan S1 | 26 |
| Gambar 3.6 Model Fenologi untuk kelas kesesuaian lahan S3 | 27 |
| Gambar 3.7 Model Fenologi untuk kelas kesesuaian lahan N..... | 27 |
| Gambar 3.8 ALOS PALSAR 2 polarisasi HH | 29 |
| Gambar 3.9 ALOS PALSAR 2 Polarisasi HV | 30 |
| Gambar 3.10 Model Fenologi untuk kelas kesesuaian lahan S1 polarisasi VV | 31 |
| Gambar 3.11 Model Fenologi untuk kelas kesesuaian lahan S1 polarisasi VH..... | 31 |
| Gambar 3.12 Model Fenologi untuk kelas kesesuaian lahan S3 polarisasi VV | 32 |
| Gambar 3.13 Model Fenologi untuk kelas kesesuaian lahan S3 polarisasi VH..... | 33 |
| Gambar 3.14 Model Fenologi untuk kelas kesesuaian lahan N polarisasi VV | 34 |
| Gambar 3.15 Model Fenologi untuk kelas kesesuaian lahan N polarisasi VH..... | 35 |

Daftar Tabel

| | |
|--|----|
| Tabel 3.1 Hasil Uji Akurasi pada Perkebunan Kelapa Sawit di Asahan, Sumatera Utara..... | 38 |
|--|----|

BAB I. Pendahuluan

1.1 Latar Belakang

Perkebunan kelapa sawit di Indonesia merupakan penghasil devisa terbesar, namun menurut Kementerian Pertanian Republik Indonesia (2019) hasil devisa yang diperoleh pada tahun 2019 mengalami penurunan hampir 12%, dimana penerimaan devisa ditahun 2018 mencapai US\$ 18,31 milyar sedangkan di tahun 2019 hanya mencapai US\$ 16,04 milyar. Hal tersebut menurut Direktorat Jenderal Perkebunan Kementrian Pertanian faktor utamanya adalah menurunnya produktivitas kelapa sawit dikarenakan banyaknya kelapa sawit tua dan terserang penyakit. Oleh karena itu, diperlukan peremajaan kelapa sawit untuk meningkatkan kembali produktivitas sawit nasional dan merujuk pada Instruksi Presiden Nomor 6 Tahun 2019 tentang Rencana Aksi Nasional Perkebunan Kelapa Sawit Berkelanjutan Tahun 2019-2024 dimana salah satu aksinya untuk meningkatkan kembali produktivitas sawit nasional adalah melalui penguatan data, penguatan koordinasi, dan infrastruktur.

Penguatan data, penguatan koordinasi, dan infrastruktur sangat diperlukan dalam manajemen perkebunan kelapa sawit yang merujuk pada kebijakan satu data. Sesuai dengan Peraturan Presiden Republik Indonesia Nomor 39 Tahun 2019, Satu Data Indonesia adalah kebijakan tata kelola data pemerintah untuk menghasilkan data yang akurat, mutakhir, terpadu, dan dapat dipertanggungjawabkan, serta mudah diakses dan dibagi

pakaikan antar instansi pusat dan daerah melalui pemenuhan standar data, metadata, interoperabilitas data, dan menggunakan kode referensi dan data induk.

Saat ini penguatan data merujuk pada penyelenggaraan informasi geospasial tematik (IGT) tutupan lahan perkebunan kelapa sawit yang dituangkan berdasarkan Keputusan Menteri Pertanian Republik Indonesia Nomor 833/KPTS/SR.020/M/12/2019, tentang penetapan luas tutupan kelapa sawit Indonesia tahun 2019, yaitu seluas 16.381.959 ha dengan sebaran lokasi spasial di seluruh wilayah Indonesia. Kepmen tersebut mewajibkan data tematik lainnya berdasarkan kepemilikan perkebunan rakyat (PR), perkebunan besar negara (PBN), dan perkebunan besar swasta (PBS); umur tanaman (tanaman belum menghasilkan/TBM, tanaman menghasilkan/TM, dan tanaman tidak menghasilkan/ tanaman rusak/TR), serta tumpang tindih dengan kawasan hutan.

Kesenjangan yang terjadi saat ini adalah pelaksanaan kebijakan kepmen tersebut hanya terfokus pada wilayah luas area perkebunan, sedangkan penguatan data kepemilikan perkebunan rakyat (PR), perkebunan besar negara (PBN), dan perkebunan besar swasta (PBS); umur tanaman (tanaman belum menghasilkan/TBM, tanaman menghasilkan/TM, dan tanaman tidak menghasilkan/ tanaman rusak/TR), tumpang tindih dengan kawasan hutan serta kesesuaian lahan perkebunan kelapa sawit dengan skala detail belum terselesaikan.

Pembangunan dan penyebaran informasi tutupan lahan telah diamanatkan dalam UU No. 4/2011 tentang Informasi Geospasial. Undang-undang ini dibentuk untuk menjamin ketersediaan dan akses informasi geospasial dan mendorong penggunaan informasi geospasial dalam kegiatan pemerintahan dan kehidupan sehari-hari masyarakat. Dalam pelaksanaannya perguruan tinggi merupakan salah satu mitra dalam penyelenggaraan Infrastruktur Data Spasial Nasional (IDSN) yang mendukung implementasi UU No. 4/2011. Selain itu UU No. 21/2013 tentang Keantariksaan mengamanatkan LAPAN untuk membuat standar dan prosedur dalam pengolahan data citra satelit termasuk untuk perkebunan kelapa sawit.

Salah satu teknologi yang menjanjikan untuk memenuhi informasi geospasial berkaitan dengan kelapa sawit adalah teknologi Penginderaan jauh. Teknologi penginderaan jauh telah banyak diterapkan di sektor pertanian dan kehutanan. Teknologi ini memberikan solusi yang tepat, terjangkau dan efisien untuk perencanaan, pemantauan, dan pengelolaan pertanian dan kehutanan. Menurut Henderson dan Lewis (2008), meskipun sensor optik dari spektrum elektromagnetik telah banyak digunakan dan memberikan manfaat yang besar. namun banyak juga upaya penggunaan sensor radar. Sensor gelombang radar menjadi pilihan yang menjanjikan dalam aplikasi penginderaan jauh karena penetrasi terhadap awan, kemampuan dalam memperoleh data dalam segala kondisi cuaca siang dan malam hal ini sulit dilakukan bila menggunakan sensor optis. Oleh karena itu sensor radar sangat cocok digunakan di iklim tropis seperti Indonesia yang hampir sepanjang bulannya tertutup awan.

Usia kelapa sawit merupakan parameter utama dalam pendugaan hasil. Usia kelapa sawit adalah satu dari variabel signifikan yang mempengaruhi produksi buah tandan [Y. Basiron, 2020 dan Tan dkk., 2013]. Informasi umur kelapa sawit merupakan indikator prediksi hasil yang baik karena mempengaruhi kualitas dan kuantitas tandan buah segar [Chemura, 2015]. Selain itu, informasi usia adalah penting untuk pertanian presisi untuk mengenali anomali di antara kelapa sawit dalam kelompok usia tertentu untuk merencanakan praktik pengelolaan kontra aktif dan mengoptimalkan pengelolaan sumber daya [Tan dkk., 2013 dan Mc Morrow, 2010]. Dalam kasus lain, informasi usia kelapa sawit diperlukan untuk estimasi pajak, waktu penanaman kembali, dan identifikasi penyakit kelapa sawit [Carolita, 2019]. Organisasi atau manajemen perkebunan menyukai data yang berguna untuk memaksimalkan produksi kelapa sawit, salah satu manfaat penting yang mempengaruhi [Tan dkk., 2013]. Menurut Tan dkk. (2013), mengumpulkan informasi usia pada pohon kelapa sawit memakan waktu dan biaya, terutama dalam skala besar atau regional. Umur pertumbuhan kelapa sawit mempengaruhi fisik dan lingkungan perkebunan kelapa sawit diri. Menurut Tan dkk. (2013) dan Chemura dkk. (2015), tinggi dan ukuran tajuk kelapa sawit memiliki korelasi yang kuat dengan usia.

1.2 Maksud dan Tujuan

Maksud dan tujuan dari buku ini adalah menguraikan pembangunan model umur pertumbuhan perkebunan kelapa sawit berbasis citra satelit penginderaan jauh untuk tata kelola

perkebunan kelapa sawit nasional berkelanjutan yang dapat dijadikan acuan standar pemetaan dan monitoring perkebunan kelapa sawit di Indonesia.

1.3 Ruang Lingkup

Buku ini fokus pada prosedur pembangunan model fenologi kelapa sawit berbasis pengindraan jauh. Pada Bab I berisikan latar belakang perlunya informasi fenologi kelapa sawit serta tujuan dan ruang lingkup. Bab II dibahas mengenai state of the art fenologi kelapa sawit serta model kelapa sawit berbasis kesesuaian lahan kelapa sawit. Bab III berisikan proses pembangunan model fenologi kelapa sawit mulai dari praprosesing, transformasi spektral, pembangunan model dan validasi. Di bagian akhir buku ini ditutup dengan Bab IV yang berisikan dengan kesimpulan dan trend penelitian selanjutnya.

BAB II. STATE-OF-THE ART MODEL FENOLOGI KELAPA SAWIT

Pengetahuan fenologi kelapa sawit sangat penting untuk pengelolaan perkebunan kelapa sawit. Fenologi sangat penting untuk informasi pohon yang akurat untuk tujuan ilmiah dan praktis karena berdampak pada produktivitas kelapa sawit.

Pengindraan jauh teknologi satelit menggunakan sensor optis dan radar telah berhasil digunakan dalam berbagai aplikasi yang terkait dengan studi sumber daya bumi dan pemantauan lingkungan. Beberapa manfaat dari teknik ini adalah efektivitas biaya, cakupan luas, akuisisi data dekat waktu nyata dan kemampuan perekaman berulang dengan waktu reguler. Pengindraan jauh memiliki potensi signifikan untuk membantu pemantauan kelapa sawit dan prediksi potensi perkebunan kelapa sawit. Menurut beberapa penelitian yang telah dilakukan di bidang pertanian dan perkebunan, teknologi pengindraan jauh mampu memberikan perkiraan hasil yang akurat dari penurunan hubungan antara karakter spekspektral dan indeks vegetasi dalam bentuk penutup kanopi dengan memanfaatkan pantulan gelombang visual merah, hijau, panjang gelombang biru dan inframerah.

Pengindraan jauh berpotensi mendukung secara signifikan dalam pemantauan kelapa sawit dan prediksi potensi perkebunan kelapa

sawit (Darmawan dkk., 2021). Beberapa penelitian di bidang pertanian dan perkebunan, khususnya di perkebunan kelapa sawit, menunjukkan bahwa teknologi pengindraan jauh mampu memberikan perkiraan kinerja yang akurat dari pembuatan hubungan antara karakteristik spektral dan indeks vegetasi berupa tutupan tajuk dengan menggunakan pantulan visual (Darmawan dkk., 2018).

Berbagai penelitian telah dilakukan dengan menggunakan pendekatan pengindraan jauh untuk memperkirakan umur kelapa sawit, yang dapat dikelompokkan menjadi dua kategori utama, yaitu model transfer radiasi dan model regresi statistik berbasis *machine learning* atau disebut sebagai *machine learning* statistik (Holloway dan Mengersen, 2018). Metode yang paling umum untuk memperkirakan fenologi adalah analisis regresi (Czernecki dkk., 2018).

Analisis regresi atau teknik statistik lainnya digunakan untuk menentukan korelasi atau hubungan antara dua variabel informasi (McMorrow, 2001). Penggunaan model regresi bertujuan untuk memahami bagaimana perubahan nilai prediktor dikaitkan dengan perubahan rata-rata perespons. Ada berbagai metodologi regresi berdasarkan jenis variabel respon, yaitu jenis model yang diperlukan untuk memberikan kecocokan yang memadai untuk data, dan metode estimasi seperti linier, linier berganda, dan non-linier (Rawlings dkk., 1990). Model regresi yang paling umum digunakan adalah linier sederhana dan linier berganda. Analisis regresi nonlinier biasanya digunakan untuk kumpulan data yang lebih rumit di mana variabel dependen dan independen menunjukkan hubungan nonlinier. Ada tiga tujuan

untuk menganalisis menggunakan regresi, diantaranya (Egwu Kalu, 2008):

1. Prediksi
2. Desain model
3. Penilaian parameter

Prosedur tersebut secara khusus digunakan untuk menganalisis hubungan antara fitur yang diekstraksi dan parameter biofisik yang diukur di lapangan (Darmawan dkk., 2021).

Dalam kasus fenologi kelapa sawit, banyak penelitian menghasilkan regresi linier dan non-linier, seperti Nordin dkk. (1996) menggunakan *The Airborne Synthetic Aperture Radar* (AIRSAR), Tan dkk. (2013), Avtar dkk. (2013), Darmawan dkk. (2016) dan Darmawan dkk. (2021) menggunakan ALOS PALSAR, hubungan antara umur dan parameter biofisik menunjukkan persamaan logaritma non-linier dengan $R^2 = 0,4$ sampai $0,8$. McMorow (2001) menggunakan Landsat dan Okarda dkk., (2018) menggunakan *Advanced Land Observing Satellite* (ALOS) (*Phased Array type L-band Synthetic Aperture Radar* (PALSAR), menunjukkan hubungan regresi linier antara usia dan persamaan indeks spektral dengan $R^2 = 0,7$. Di sisi lain, persamaan yang dihasilkan dari kuadrat non-linier dengan rata-rata $R^2 = 0,8$ menggunakan data optik dan SAR telah ditunjukkan oleh Tan dkk., (2013), Carolita dkk., (2017), Rizei dkk (2018), dan Darmawan dkk (2021) menggunakan Sentinel-1A.

Menggunakan Landsat TM, McMorow (1995) menemukan hubungan nonlinier negatif antara kecerahan Landsat TM dan umur kelapa sawit, yang menyiratkan bahwa semakin rendah nilai

reflektansi maka semakin muda umur kelapa sawit. Penelitian Carolita (2017) menggunakan SPOT-6 menemukan bahwa fluktuasi NDVI dapat menjelaskan perkembangan kelapa sawit dengan menggunakan model algoritma $y = -0,0004x^2 + 0,0107x + 0,3912$, dimana x adalah umur kelapa sawit dan Y adalah NDVI, dengan $R^2 = 0,657$. Jika dibandingkan dengan penggunaan citra Landsat 8 menggunakan metodologi analisis regresi, umur pohon kelapa sawit dapat dinilai dengan menggunakan indeks spektral NDVI dengan $R^2 = 0,85$. Selain itu, Chemura dkk. (2015) memperkirakan usia kelapa sawit di Ghana dengan menggabungkan data multispektral dari citra satelit resolusi tinggi WorldView-2 dengan pendekatan analitik regresi. Model usia kelapa sawit dapat dievaluasi dengan menggunakan hubungan antara usia dan *crown projection area* (CPA). Menurut temuannya, ada hubungan yang jelas antara usia dan CPA pada kelapa sawit di atas usia 13 tahun. Nordin (1996) menggunakan AIRSAR untuk melakukan korelasi dengan parameter biomassa. Penginderaan jauh radar dengan polarisasi yang berbeda (Horizontal (H) dan Vertikal (V)) digunakan untuk menguji umur kelapa sawit. Kedua investigasi yang menggunakan citra ALOS PALSAR menyimpulkan bahwa (1) HH secara statistik lebih terkait dengan usia kelapa sawit daripada HV, dan (2) nilai hamburan balik meningkat seiring usia karena peningkatan biomassa.

Shashikant dkk. (2012) menyelidiki hubungan antara backscatter radar dan data *aboveground biomass* (AGB) pada variasi umur menggunakan berbagai persamaan alometrik. Tan dkk. (2013) menggunakan pendekatan *gray-level co-occurrence matrix* (GLCM)

pada data ALOS PALSAR-2 untuk menentukan umur tanaman kelapa sawit. Pohl dan Loong, (2016) menyelidiki penggunaan interferometrik SAR (InSAR) dan membuat profil tinggi kelapa sawit pada tahun 2016. Data ini terbukti membantu dalam memetakan profil umur kelapa sawit. Mereka menggunakan model regresi linier untuk menentukan hubungan antara tinggi pohon dan umur kelapa sawit. Hubungan ini menghasilkan model empiris tinggi terhadap umur yang dapat digunakan untuk menghitung nilai umur dari ketinggian pohon kelapa sawit di Malaysia.

Hubungan antara umur dan hamburan balik pada tanah mineral dan lahan gambut berkorelasi kuat dengan HH, dan HV yang ditemukan oleh Okarda dkk., (2018). Selain itu, menurut Okarda, pentingnya hamburan balik dapat berguna untuk menganalisis tinggi dan umur pohon kelapa sawit. Carolita dkk., (2019) menghasilkan model regresi dengan nilai korelasi *backscatter* dari data SAR Sentinel-1A (band C-) dengan umur yang diperoleh dari data blok umur kelapa sawit. Pada data C-band, para peneliti menemukan bahwa pikselutupan pohon dianggap kelapa sawit jika perbedaan VV-VH lebih besar dari 7,4 dB dan hamburan balik VH kurang dari -13 dB (Miettinen dkk., 2015), dan panjang gelombang C-band telah berhasil digunakan untuk memprediksi fenologi (Teng dkk., 2015). Darmawan dkk. (2021) menggunakan data SAR dengan X-, C-, dan L-band untuk menyelidiki potensi karakteristik fenologi. Hasil penelitian menunjukkan bahwa yang paling potensial adalah C-band pada polarisasi VV dengan $R^2 = 0,85$.

Dalam pemodelan fenologi kelapa sawit berdasarkan model regresi tidak selalu mengikuti perilaku linier. Fenologi kelapa sawit biasanya memiliki tipe hubungan non-linier (Hilal dkk., 2020). Teknik pembelajaran mesin non-linier adalah jenis pendekatan regresi yang sangat efisien yang telah berhasil digunakan dalam analisis parameter biofisik. Menurut Frost (2020) regresi non-linier juga membutuhkan variabel dependen kontinu, tetapi memberikan fleksibilitas yang lebih besar untuk menyesuaikan kurva daripada regresi linier. Menurut Chong dkk., (2017) karakteristik fisik pohon juga telah terbukti menjadi indikator yang berpotensi dapat diandalkan untuk estimasi umur kelapa sawit. Kebanyakan model non-linier memiliki satu variabel independen kontinu, tetapi dimungkinkan untuk memiliki lebih dari satu (Frost, 2020). Menurut (Ali dkk., 2015) teknik tersebut dapat mempelajari dan memperkirakan pemetaan non-linier yang rumit sekalipun menggunakan metode pembelajaran mesin yang canggih dan informasi yang terkandung dalam rangkaian sampel perbandingan dan jaringan syaraf tiruan/*Analisis Neural Network* (ANN) adalah salah satu teknik yang sering digunakan di untuk teknik pengambilan parameter biofisik dan telah banyak digunakan pada berbagai aplikasi (Ali dkk., 2015).

Dalam dekade terakhir, analisis menggunakan kecerdasan buatan/ *Artificial Intelligent* (AI) untuk mengidentifikasi tutupan lahan kelapa sawit sedang marak digunakan. Analisis AI ini termasuk pengklasifikasi *Machine Learning* yang telah hadir sebagai metode yang akurat dan telah diadopsi secara luas untuk klasifikasi karena akurasi dan kinerjanya yang lebih baik dibandingkan dengan Linear regression (Maxwell dkk., 2018).

Teknik machine learning statistik ini, juga dikenal sebagai teknik empiris, adalah keadaan di mana hubungan statistik dibuat antara spektral band atau frekuensi yang digunakan dan variabel yang diukur (berbasis lapangan) tanpa harus menetapkan hubungan sebab akibat. Koneksi ini mungkin parametrik, semi-parametrik, atau nonparametrik (Holloway dan Mengersen, 2018). Yang termasuk regresi menggunakan *Machine Learning* (ML), diantaranya *Support Vector Regression* (SVR), *Random Forest* (RF), *Classification and Regression Tree* (CART), *Deep Learning*, *Artificial Neural Network* (ANN), dan algoritma ML lainnya. ML bertujuan untuk mendapatkan akurasi pengkelasan yang signifikan.

Untuk mengatasi masalah otomasi, studi yang lebih baru yaitu menggunakan *Deep Learning* (DL) dalam analisis perkebunan kelapa sawit terkomputerisasi. Misalnya, pendekatan DL diambil dalam deteksi dan penghitungan pohon kelapa sawit (Descals dkk., 2021). *Convolutional neural network* (CNN) merupakan model DL yang banyak digunakan. Beberapa studi telah berhasil menggunakan DL untuk klasifikasi dan pembuatan model pertumbuhan kelapa sawit. Li dkk., (2017) mengusulkan penggunaan DL untuk mendeteksi fenologi pada tanaman. Mereka menggunakan data dari hitungan manual untuk melatih dan meningkatkan kinerja sistem CNN (Li dkk., 2017). Juga Mubin dkk., (2019) menggunakan CNN untuk memisahkan pohon kelapa sawit muda dan dewasa.

Studi terbaru mengungkapkan ANN pada studi kelapa sawit, Hilal dkk. (2020) menunjukkan bahwa ANN adalah instrumen pemodelan signifikan yang memiliki potensi hebat untuk model prediksi optimasi dengan presisi tinggi di banyak bidang studi.

Semua model regresi dapat meningkatkan koefisien determinasi (R^2) yang lebih tinggi dari hubungan sedang (0,4) menjadi kuat (0,9). Selanjutnya, semua teknik *machine learning* tidak selalu menghasilkan presisi tinggi karena hasil yang baik bergantung pada pengaturan model pembelajaran mesin, sampel pelatihan, dan parameter input (Talukdar dkk., 2020).

BAB III. PENGOLAHAN CITRA

Secara umum, pengolahan citra satelit dirancang berdasarkan kebutuhan pengguna, resolusi spasial dari data penginderaan jauh yang dipilih, kompatibilitas dengan studi sebelumnya, pra-prosesing, algoritma model yang tersedia, dan batasan waktu. Kemudian pemilihan training sample yang digunakan biasanya dikumpulkan dari lapangan, atau dari foto udara dan citra satelit dengan resolusi spasial yang baik.

Pekerjaan pengolahan citra tersebut, tentunya harus dapat dilakukan secara informatif, lengkap, dan akurat (Jensen, 2014).

3.1 Pemilihan Data Penginderaan Jauh

Data penginderaan jauh, termasuk data sensor udara dan satelit sangat bervariasi pada pilihan resolusi spasial, radiometrik, spektral, dan temporal. Memahami kelebihan dan kekurangan berbagai jenis data sensor sangat penting untuk pemilihan data penginderaan jauh yang sesuai untuk model fenologi ini. Skala, resolusi citra, dan kebutuhan pengguna adalah faktor terpenting yang mempengaruhi pemilihan data penginderaan jauh. Kebutuhan pengguna menentukan sifat model dan seberapa luas wilayah studi yang akan dikaji, sehingga dapat memilih resolusi spasial yang sesuai (Lu dan Weng, 2007).

Kemudian faktor penting lainnya yang mempengaruhi pemilihan data sensor adalah kondisi atmosfer. Kondisi berawan yang sering

terjadi di daerah tropis yang lembab seringkali menjadi kendala untuk mendapatkan data sensor optik yang berkualitas tinggi. Oleh karena itu, berbagai jenis data radar berfungsi sebagai sumber data tambahan yang penting. Karena berbagai sumber data sensor sekarang sudah tersedia, untuk analisis citra pastinya memiliki lebih banyak pilihan data penginderaan jauh yang sesuai untuk studi tertentu. Kombinasi data multisensor dengan berbagai karakteristik citra biasanya bermanfaat untuk penelitian (Sarzynski dkk., 2020). Dalam situasi ini, kondisi ekonomi seringkali menjadi faktor penting yang mempengaruhi pemilihan data penginderaan jauh dan waktu, serta sumber daya yang dapat digunakan untuk prosedur model algoritma, sehingga nantinya akan mempengaruhi kualitas hasil model (Lu dan Weng, 2007).

3.2 Pra-Processing Citra Satelit

Pra-pemrosesan citra dapat mencakup deteksi dan pemulihan garis buruk, rektifikasi geometrik atau registrasi citra, kalibrasi radiometrik dan koreksi atmosfer, dan koreksi topografi (Lu dan Weng, 2007).

3.2.1 Citra Satelit Landsat

Pada penelitian ini digunakan data Landsat 8 sebagai data utama untuk melakukan proses atau pembuatan model fenologi kelapa sawit. *Landsat Data Continuity Mission* (LDCM) atau dikenal juga dengan nama Landsat 8 merupakan satelit generasi terbaru dari Program Landsat. Satelit Landsat 8 yang direncanakan mempunyai durasi misi selama 5 – 10 tahun ini, dilengkapi dua sensor yang merupakan hasil pengembangan dari sensor yang terdapat pada satelit-satelit pada Program Landsat sebelumnya.

Kedua sensor tersebut, yaitu *Sensor Operational Land Manager* (OLI) yang terdiri dari 9 band serta *Thermal InfraRed Sensors* (TIRS) yang terdiri dari 2 band.

Untuk pre-processing citra satelit landsat, terlebih dahulu citra dilakukan koreksi geometrik, dimana koreksi geometrik adalah proses pemodelan hubungan antara pencitraan dan sistem koordinat tanah (Jensen, 2014). Data citra dikoreksi ke sistem koordinat Universal Transverse Mercator (UTM) North dengan Zone sesuai lokasi atau bisa juga kedalam sistem proyeksi geografis dan datum WGS 84. Kesalahan *Root Mean Square* (RMS) untuk setiap hasil transformasi gambar adalah maksimal 0,5, yang artinya citra tersebut akurat hingga satu piksel (Jensen, 2014).

Kemudian melakukan koreksi radiometrik. Data koreksi radiometrik pengindraan jauh sering digunakan untuk mengurangi inkonsistensi yang dapat mempengaruhi pengukuran, analisis, dan interpretasi data citra (Al-doski dkk., 2013). Data Landsat terlebih dahulu ditransformasikan dari *digital number* (DN) menjadi nilai reflektansi. Penyesuaian *top of atmospheric* (ToA), termasuk refleksi ToA dan koreksi matahari, digunakan untuk mengoreksi data Landsat secara radiometrik (Hernawati dan Darmawan, 2018).

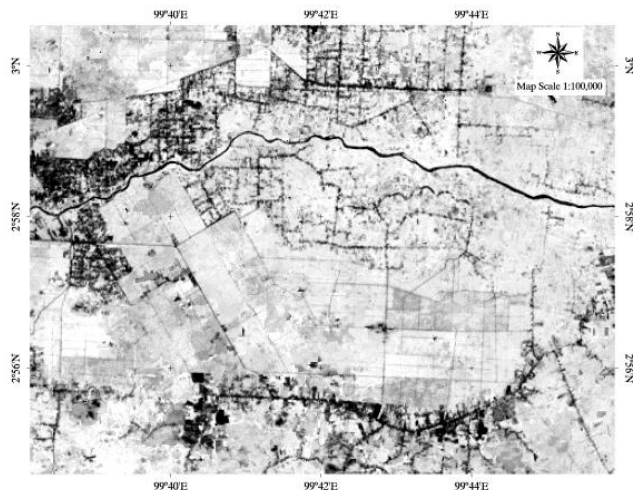
Perhitungan *Normalized Difference Vegetation Index* (NDVI) dapat dilakukan dengan cepat. Selain itu, NDVI sering digunakan di beberapa studi untuk memantau kekeringan, memperkirakan produksi pertanian, membantu memprediksi zona kebakaran, dan lainnya. Aplikasi pertanian, seperti pemantauan tanaman dapat mengintegrasikan NDVI untuk memfasilitasi pemantauan

tanaman dan memberikan presisi pada aplikasi pupuk dan irigasi, di antara aktivitas pengolahan lapangan lainnya, pada tahap pertumbuhan tertentu. NDVI lebih diminati untuk pemantauan vegetasi secara global karena membantu mengkompensasi perubahan kondisi pencahayaan, kemiringan permukaan, exposure, dan faktor eksternal lainnya.

NDVI adalah fungsi dari dua band. Band merah dan band inframerah-dekat, yang dapat diperkirakan menggunakan persamaan (1) di bawah ini (Crippen, 1990):

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (1)$$

Dimana ρ_{NIR} merupakan refleksi dalam spektrum infra merah dekat dan ρ_{RED} merupakan refleksi dalam rentang spektrum merah (Crippen, 1990). Indeks ini mendefinisikan nilai dari -1,0 hingga 1,0, pada dasarnya mewakili hijau daun, di mana nilai negatif mewakili dari awan, air, dan salju, dan nilai yang mendekati nol mewakili dari bebatuan dan tanah kosong (Hernawati dan Darmawan, 2018). Nilai fungsi NDVI yang sangat kecil (0,1 atau kurang) sesuai dengan area kosong bebatuan, pasir, atau salju. Nilai sedang (dari 0,2 hingga 0,3) mewakili semak dan padang rumput, sedangkan nilai besar (dari 0,6 hingga 0,8) menunjukkan hutan beriklim sedang dan tropis. Pemantauan untuk panen telah berhasil menggunakan NDVI untuk menunjukkan bagian ladang yang memiliki vegetasi lebat, sedang, atau jarang pada kondisi tertentu (Crippen, 1990).



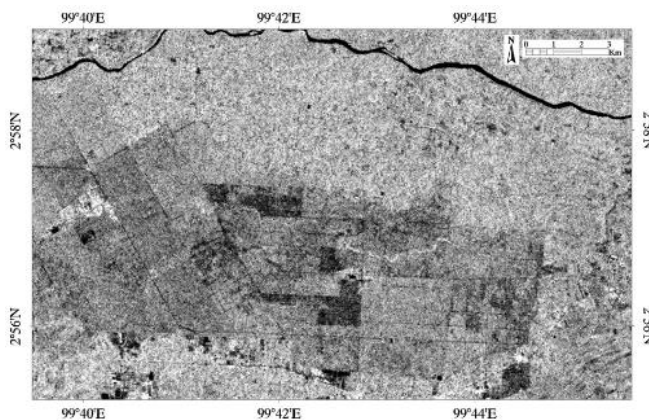
Gambar 3.1 Visualisasi Hasil NDVI untuk lokasi Asahan, Sumatera Utara

3.2.2 Citra Satelit ALOS PALSAR

Dalam pre-processing data radar, prosedur yang harus dilakukan adalah:

Speckle Filtering, merupakan masalah utama pada interpretasi pencitraan SAR dan klasifikasi adalah efek spekel yang disebabkan oleh interferensi koheren gelombang yang dipantulkan dari banyak pencar utama (Gebhardt dkk., 2012). Speckle muncul dalam pencitraan SAR sebagai derau granular karena gangguan gelombang yang dipantulkan dari banyak penghambur dasar (Lee dkk., 1994) Pemfilteran bintang adalah prosedur untuk meningkatkan kualitas gambar dengan mengurangi bintang. Filter Lee yang ditingkatkan dengan ukuran jendela 7×7 telah dipilih dalam penelitian ini untuk

meminimalkan efek spekel pada gambar (Lee dkk., 1994; Omar dkk., 2017), juga untuk menghilangkan noise di tepi dan area kontras tinggi tanpa kehilangan informasi (Amini dan Sri Sumantyo, 2011), karena penelitian sebelumnya menunjukkan pengurangan bintik pada data SAR menggunakan Filter Lee sebelum mengekstraksi nilai hamburan (Mohd Najib dkk., 2020). Menurut Lee dkk., (1994) Algoritma ini adalah algoritma terbaik untuk keperluan segmentasi tanaman.



Gambar 3.2 Citra ALOS PALSAR 2 polarisasi HH

Terrain Corecction, gambar yang diproses sebelumnya juga merupakan *terrain correction* untuk menghilangkan distorsi yang disebabkan oleh variasi topografi. Tujuan dari koreksi medan untuk pencitraan SAR adalah untuk meminimalkan efek geometri SAR (foreshortening, singgah, dan bayangan) terhadap citra radar (Najib dkk., 2020). Misi *Shuttle Radar Topography Mission* (SRTM) digunakan sebagai *Digital Elevation Model* (DEM) untuk memberikan informasi ketinggian menggunakan *Corecction Terrain Range-Doppler* (Hu dkk., 2018).

Kalibrasi Radiometrik, yakni kalibrasi nilai hamburan diperlukan untuk perbandingan antar citra radar yang diperoleh dengan sensor berbeda atau citra yang diperoleh dengan sensor yang sama jika diperoleh dalam mode berbeda atau diproses dengan prosesor berbeda (Faller dan Weber, 2007). Kalibrasi radiometrik menghasilkan sigma nihil (σ°) Proses kalibrasi radiometrik untuk X-band terlebih dahulu menghitung kecerahan radar β° dB (beta nol, seperti yang terkandung dalam dB) yang diturunkan dari faktor kalibrasi khusus polarisasi kS (dalam persamaan (2)) dan diubah dari angka digital (DN) ke sigma (σ°) menggunakan persamaan (2) (Gebhardt dkk., 2012):

$$\beta^\circ_{dB} = 10 \times \log_{10}(K_S DN^2) \quad (2)$$

Kalibrasi radiometrik terakhir dilakukan dengan menghitung sigma (σ°) menggunakan (3):

$$\sigma^\circ = \beta^\circ_{dB} + \log_{10}(\sin \theta_{loc}) \quad (3)$$

dimana θ_{loc} , merupakan sudut datang citra lokal, yang didefinisikan untuk empat sisi posisi sudut, berdasarkan interpolasi 2D melintasi dimensi citra yang dilakukan. Metode interpolasi yang diterapkan didasarkan pada triangulasi data Delaunay menggunakan algoritma (Barber dkk., 1996) Kesimpulannya, citra insiden lokal memiliki dimensi yang sama dengan citra adegan dan menghasilkan informasi tentang sudut datang setiap piksel (Gebhardt dkk., 2012).

DN harus diubah menjadi hamburan (yaitu, sinyal radar yang dipantulkan) yang dikenali sebagai *Normalized Radar Cross Section* (NRCS) dan dinyatakan dalam σ° dalam desibel (dB) (Omar dkk., 2017). Konversi intensitas hamburan HH (DNHH) dan

HV (DNHV) menjadi NRCS (yaitu σ° HH dan σ° HV) [28, 51] didasarkan pada studi Shimada (Shimada, 2011) ditunjukkan dalam rumus (4) dan (5):

$$\sigma^\circ_{HH} \text{ (dB)} = 10 \times \log_{10}(DN_{HH}^2) - CF \quad (4)$$

$$\sigma^\circ_{HV} \text{ (dB)} = 10 \times \log_{10}(DN_{HV}^2) - CF \quad (5)$$

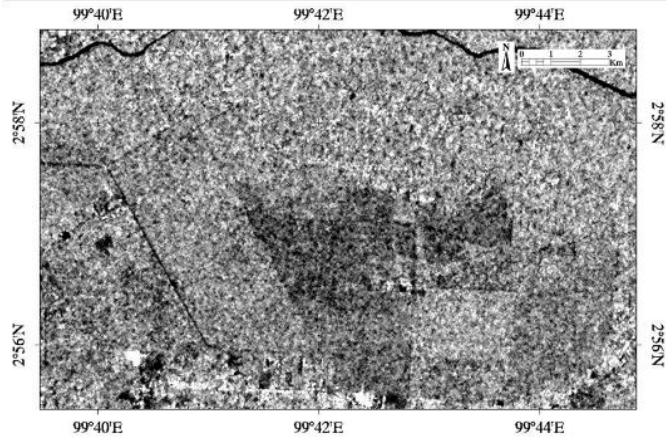
di mana σ° adalah koefisien hamburan dan CF adalah faktor kalibrasi. CF tergantung pada tanggal pemrosesan. Dalam penelitian ini, CF sama dengan -83.0 baik untuk HH dan HV (Darmawan dkk., 2016).

3.2.3 Citra Satelit Sentinel-1A

Sementara nilai hamburan C-band mengubah koefisien hamburan yang dikalibrasi gamma, produk C-band menggunakan tabel pencarian kalibrasi radiometrik (LUT) untuk melakukan kalibrasi (Kee dkk., 2018) Konversi penting dari amplitudo ke DN dan dari DN ke sigma nihil dilakukan secara otomatis pada *Sentinel Application Platform* (SNAP), dan setelah nilai nihil sigma diperoleh (Omar dkk., 2017) dan (Shimada, 2011), penghitungan hamburan (σ° dB) menggunakan rumus (6):

$$\sigma^\circ_{dB} = 10 \cdot \log_{10}[\gamma_i] \quad (6)$$

dimana γ_i adalah koefisien hamburan yang dikalibrasi gamma dari C-band (Kee dkk., 2018). L-band dibangun pada tipe data 16-bit, dan semua piksel memiliki *Digital Number* (DN) mulai dari 0 hingga 65.535 (Omar dkk., 2017).



Gambar 3.3 Citra Sentinel-1A untuk daerah Asahan, Sumatera Utara.

3.3 Penentuan Training Sampel

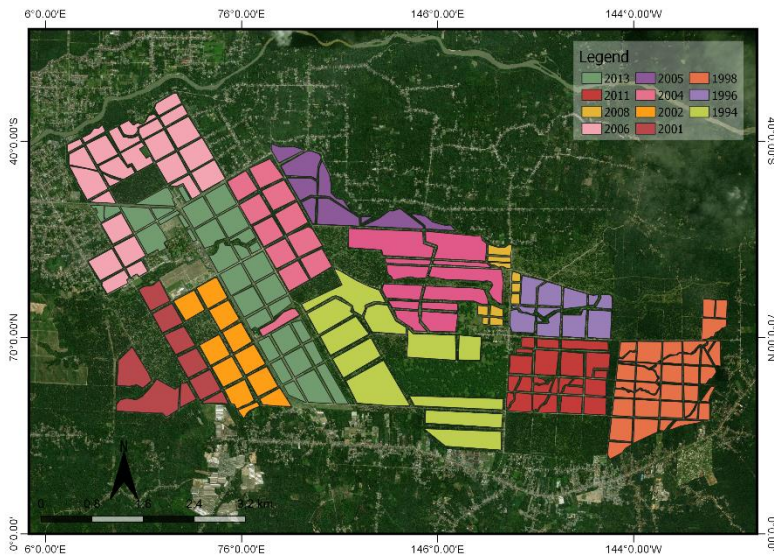
Dari citra yang telah dilakukan pra-prosesing selanjutnya dilakukan ekstraksi pengambilan sampel area atau sampel dari *region of interest* (ROI). Lalu pemilihan training sampel harus mempertimbangkan resolusi spasial dari data penginderaan jauh yang digunakan, ketersediaan data referensi lapangan, dan kompleksitas lanskap di wilayah studi (Lu dan Weng, 2007).

ROI dihitung untuk mengetahui karakteristik nilai spektral dengan umur tanaman sawit berupa nilai mean dan standar deviasi menggunakan algoritma sebagai berikut (persamaan (6) dan (7)) (Chan dkk., 1983):

$$\bar{x} = \frac{\sum_{j=1}^n x_j}{n} \quad (6)$$

$$s^2 = \frac{\sum_{j=1}^n (x_i - \bar{x})^2}{n - 1} \quad (7)$$

di mana n adalah jumlah sampel yang diambil, x_i adalah nilai sampel, \bar{x} adalah rata-rata sampel, dan s adalah simpangan baku.



Gambar 3.4 Training sampel blok tahun tanam kelapa sawit untuk perkebunan di Asahan, Sumatera Utara.

Pada penelitian ini, pengumpulan data lapangan dilakukan pada tahun 2020 yang mengumpulkan blok umur tanam kelapa sawit di wilayah studi (gambar 3.4). Di daerah penelitian ini, kami menggunakan 174 blok yang mewakili 11 varietas kelapa sawit yang berumur 0 sampai 25 tahun.

3.4 Penentuan Model Fenologi

Dalam menentukan model fenologi dilakukan analisis korelasi Pearson untuk melihat hubungan antara nilai spektral citra

dengan umur. Dalam pembangunan model ini, nilai spektral citra dari areal kelapa sawit bergantung pada struktur dan kepadatan pohon kelapa sawit, karena memiliki pola dan tekstur spektral citra yang berbeda (Darmawan dkk., 2016).

Metode regresi dapat diterapkan jika tujuannya adalah estimasi atau prediksi variabel respons berdasarkan sekumpulan kovariat. Ini mirip dengan metode klasifikasi, tetapi responnya berkelanjutan, bukan kategoris. Seperti metode klasifikasi, model regresi dikembangkan atau dilatih berdasarkan satu set variabel input yang responnya diketahui. Contoh regresi secara akurat memperkirakan atau memprediksi hasil panen berdasarkan variabel yang diekstraksi dari citra penginderaan jauh. Dalam hal ini, hasil panen adalah variabel kontinu, bukan kelas jenis tanaman yang dijelaskan (Holloway dan Mengersen, 2018).

Ada berbagai macam metode regresi, mulai dari regresi linier sederhana dan regresi logistik hingga metode populer saat ini, seperti jaringan saraf/ *Neural network*.

Misalnya, kategori metode *neural network* mencakup *artificial neural network*, *convolutional neural network*, dan *deep neural network* (Holloway dan Mengersen, 2018). Dari kategori tersebut, *convolutional neural network* dan *deep neural network* (*deep learning*) biasanya digunakan untuk aplikasi citra, seperti mengklasifikasikan citra satelit pada tingkat piksel untuk meningkatkan akurasi peta dan mengintegrasikan beberapa jenis data penginderaan jauh secara spektral untuk memantau perubahan permukaan tanah (Wang dkk., 2019) dan juga untuk memprediksi atau mengestimasi umur/ fenologi (Yalcin, 2018).

Hasil dari model estimasi umur ini dibangun dalam bentuk multi regresi dimana parameternya adalah rata-rata DN dari band spektral dan Indeks spektral data Landsat. Setiap parameter akan diuji secara empiris apakah berkorelasi dengan umur tanaman (McMorrow, 2001). Parameter yang mempunyai korelasi tinggi akan dipilih. Proses selanjutnya adalah uji korelasi antara parameter untuk mengeliminir sifat multikolinearitas antar parameter. Jika terjadi korelasi yang tinggi antar parameter akan dipilih salah satu dengan melihat korelasi terbesar parameter tersebut secara langsung dengan umur tanaman. Pengujian dilakukan untuk mencari hubungan regresi umur tanaman sawit dengan masing masing parameter dalam bentuk linier dan non linier.

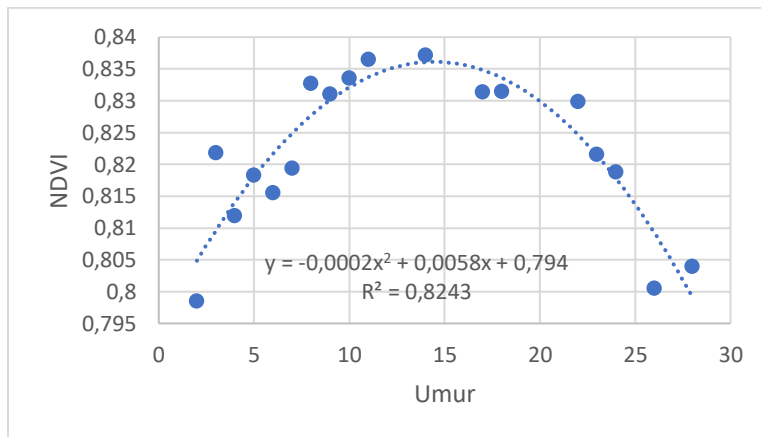
Metode Pearson mengasumsikan bahwa jika koefisiennya mirip dengan satu, itu menyiratkan korelasi yang kuat antara kedua variabel (Rawlings dkk., 1990).

$$\sqrt{R^2} = r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{[\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2]^{1/2}} \quad (8)$$

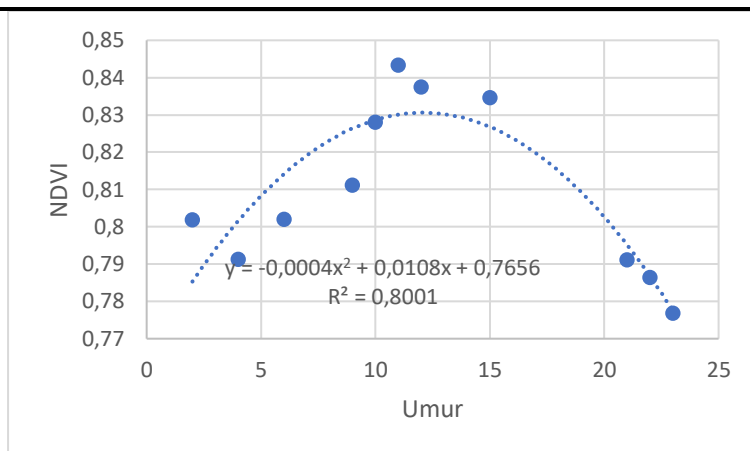
dimana \bar{x} adalah *mean* dari variabel X dan \bar{y} adalah *mean* dari variabel Y . Dalam penelitian ini variabel pertama adalah umur kelapa sawit, dan variabel kedua adalah nilai spektral citra. Koefisien determinasi (R^2) merupakan indikasi model regresi (Rawlings dkk., 1990). Nilai R^2 akan menunjukkan persentase variasi sebagai variabel model regresi (Cohen, 1949). Beberapa metode telah diusulkan untuk menafsirkan koefisien korelasi menjadi deskriptor seperti hubungan "lemah," "sedang," atau "kuat" (Schober dan Schwarte, 2018).

3.4.1 Model Fenologi Data Landsat

Model fenologi dengan menggunakan NDVI dengan kelas kesesuaian lahan S1 pada usia kelapa sawit 0-5 tahun nilai NDVI 0,795-0,81; pada usia 5-10 tahun sekitar 0,815-0,83, usia 10-15 dengan nilai NDVI 0,834-0,835; kemudian menurun di usia 15-20 sekitar 0,83; lalu usia 20-25 tahun sekitar 0,8. Model fenologi ini memiliki regresi polinomial $y = -0,0002x^2 + 0,0058x + 0,794$ dengan $R^2 = 0,8243$ (Gambar 3.5).

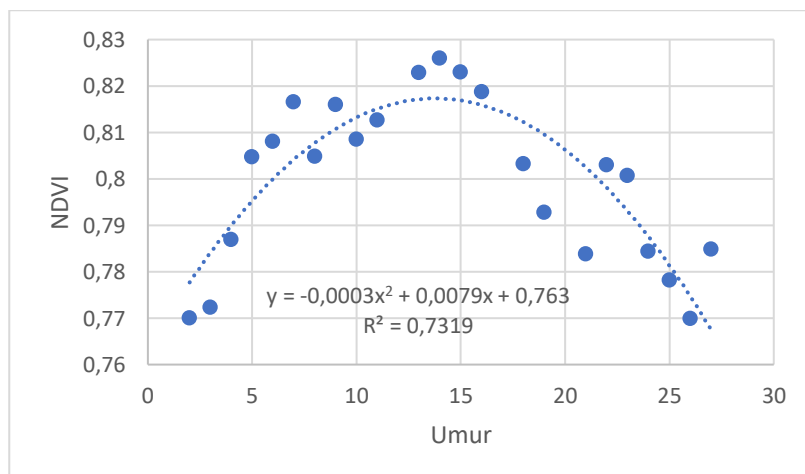


Gambar 3.5 Model Fenologi untuk kelas kesesuaian lahan S1



Gambar 3.6 Model Fenologi untuk kelas kesesuaian lahan S3

Model fenologi dengan menggunakan NDVI dengan kelas kesesuaian lahan S3 pada usia kelapa sawit 0-5 tahun nilai NDVI 0,795-0,8; pada usia 5-10 tahun sekitar 0,81-0,83; usia 10-15 dengan nilai NDVI sekitar 0,84, kemudian menurun di usia 15-20 sekitar 0,839, lalu usia 20-25 tahun sekitar 0,79-0,78. Model fenologi ini memiliki regresi polinomial $y = -0,0004x^2 + 0,0108x + 0,7656$ dengan $R^2 = 0,8001$ (Gambar 3.6).



Gambar 3.7 Model Fenologi untuk kelas kesesuaian lahan N

Model fenologi dengan menggunakan NDVI dengan kelas kesesuaian lahan S3 pada usia kelapa sawit 0-5 tahun nilai NDVI 0,77-0,79; pada usia 5-10 tahun sekitar 0,8-0,81; usia 10-15 dengan nilai NDVI sekitar 0,815-0,82; kemudian menurun di usia 15-20 sekitar 0,81, lalu usia 20-25 tahun sekitar 0,78-0,77. Model fenologi ini memiliki regresi polinomial $y = -0,0003x^2 + 0,0079x + 0,763$ dengan $R^2 = 0,7319$ (Gambar 3.7).

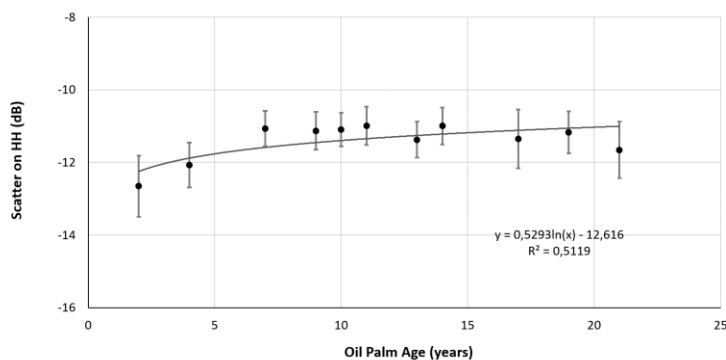
Menurut Carolita dkk., (2019), pada model fenologi menggunakan NDVI terjadi peningkatan di usia 10-15 tahun. Peningkatan ini disebabkan karena daun kelapa sawit semakin banyak dan rapat sehingga klorofilnya meningkat. Selanjutnya setelah bertambah umurnya setelah umur 15 tahun, maka nilai NDVI semakin menurun karena pada umur tersebut daun kelapa sawit mulai berkurang kehijauannya dan karena panjang daun (dari posisi tegak lurus dengan tanah) sudah menurun. Kemudian menurut (Chong dkk., 2017) dengan menggunakan sensor penginderaan jauh, peningkatan *Leaf Area Indeks* (LAI) pada kelapa sawit menunjukkan peningkatan proporsional dalam reflektifitas spektral atau NDVI selama tahap pertumbuhan awal, tetapi hanya sedikit atau tidak ada peningkatan setelah mencapai tutupan kanopinya rapat karena saturasi dari sensor. Selain itu, masih menurut Chong dkk, Indeks vegetasi seperti NDVI mampu mendeteksi biofisik kelapa sawit seperti tingkat klorofil, LAI, percabangan, dan lainnya.

3.4.2 Model Fenologi Data ALOS PALSAR 2

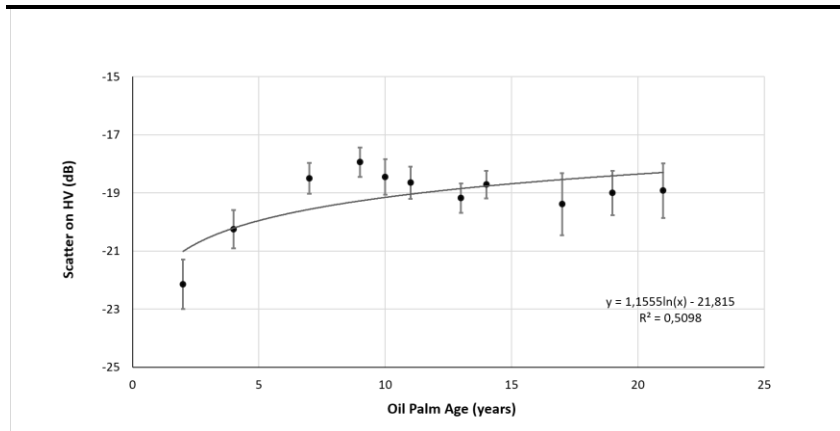
Untuk data ALOS PALSAR 2, model hamburan tanaman kelapa sawit berbasis L-band dengan polarisasi HH dan HV. Pada

polarisasi HH, nilai dimulai pada usia 0-5 tahun sekitar -12,6 dB, pada usia 5-10 tahun sekitar -11 dB, pada usia 10-15 tahun sekitar -11,3 dB, pada usia 15-20 tahun sekitar -11,5 dB, dan pada usia 20-25 tahun sekitar -11,9 dB (Gambar 3.7). Model hamburan memiliki regresi logaritmik $y = 0,5293\ln(x) - 12,616$ dengan R^2 adalah 0,51.

Pada polarisasi HV, nilainya dimulai pada usia 0-5 tahun sekitar -22 dB, pada usia 5-10 tahun sekitar -18 dB, pada usia 10-15 tahun sekitar -19 dB, pada usia 15-20 tahun sekitar -18,9 dB, dan pada usia 20-25 tahun sekitar -18,5 dB (Gambar 3.8). Model hamburan memiliki regresi logaritmik $y = 1,1555\ln(x) - 21,815$ dengan R^2 adalah 0,50.



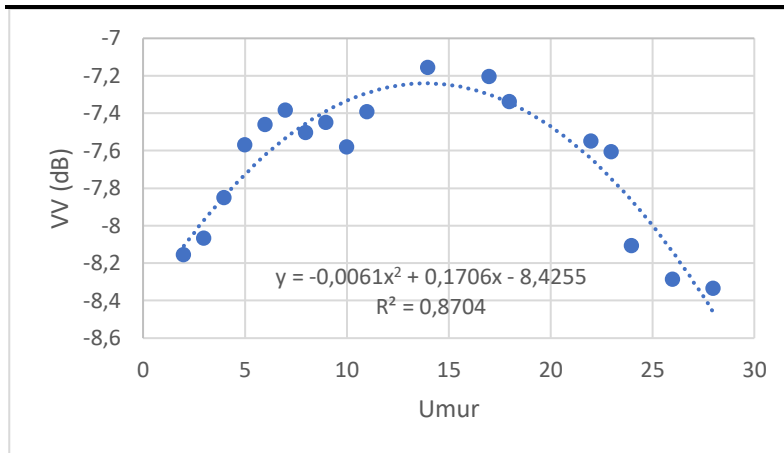
Gambar 3.8 ALOS PALSAR 2 polarisasi HH



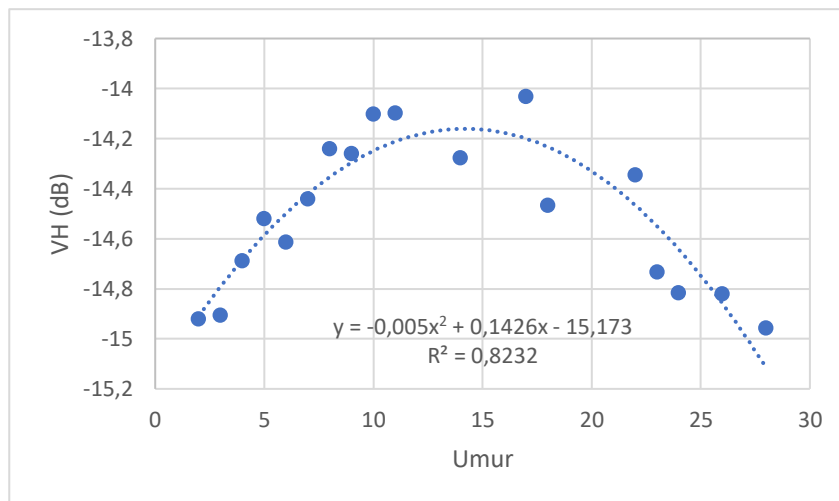
Gambar 3.9 ALOS PALSAR 2 Polarisasi HV

3.4.3 Model Fenologi Data Sentinel-1A

Pada polarisasi VV dengan kesesuaian lahan S1, nilainya dimulai pada usia 0-5 tahun sekitar -8,2 dB, pada usia 5-10 tahun sekitar -7,6 dB, pada usia 10-15 tahun sekitar -7,2 dB, pada usia 15-20 tahun sekitar -7,4 dB, dan pada usia 20-25 tahun sekitar -8,2 dB (Gambar 3.10). Model hamburan memiliki regresi polinomial polinomial $y = -0,0061x^2 + 0,1706x - 8,4255$ dengan $R^2 = 0,8704$.



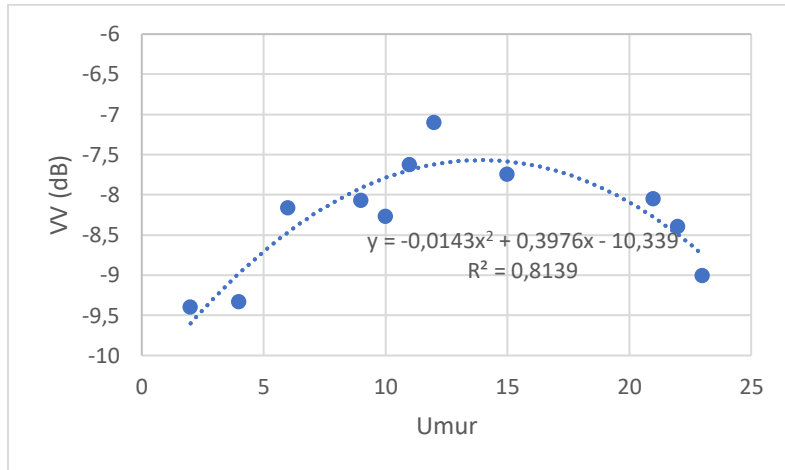
Gambar 3.10 Model Fenologi untuk kelas kesesuaian lahan S1
polarisasi VV



Gambar 3.11 Model Fenologi untuk kelas kesesuaian lahan S1
polarisasi VH

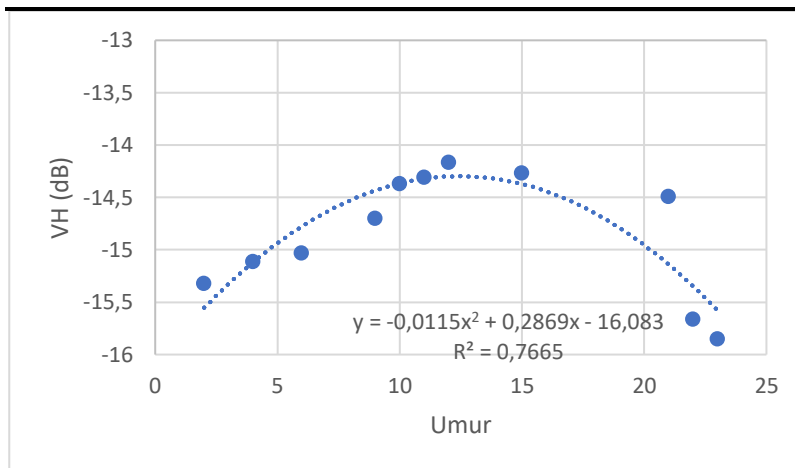
Pada polarisasi VH dengan kesesuaian lahan S1, nilainya dimulai pada usia 0-5 tahun sekitar -14,5 dB, pada usia 5-10 tahun sekitar -14,45 dB, pada usia 10-15 tahun sekitar -14,2 dB, pada usia 15-20 tahun sekitar -14,5 dB, dan pada usia 20-30 tahun sekitar -15 dB

(Gambar 3.11). Model hamburan memiliki regresi polinomial polinomial $y = -0,005x^2 + 0,1426x - 15,173$ dengan $R^2 = 0,8232$.



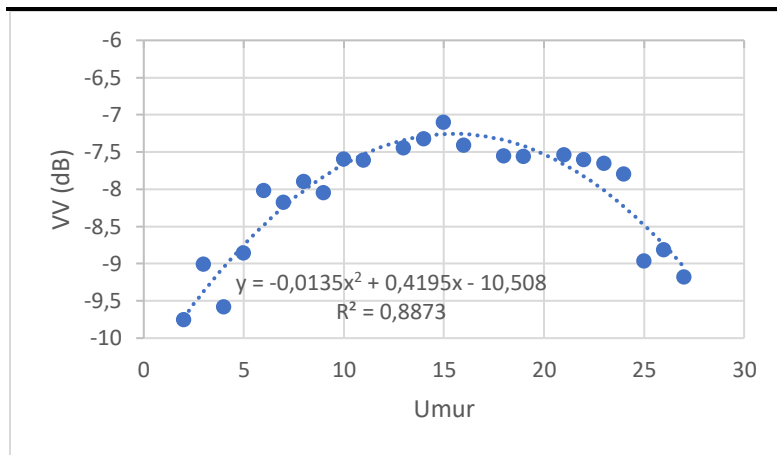
Gambar 3.12 Model Fenologi untuk kelas kesesuaian lahan S3 polarisasi VV

Pada polarisasi VV dengan kesesuaian lahan S3, nilainya dimulai pada usia 0-5 tahun sekitar -9,5 dB, pada usia 5-10 tahun sekitar -8 dB, pada usia 10-15 tahun sekitar -7 dB, pada usia 15-20 tahun sekitar -7,5 dB, dan pada usia 20-25 tahun sekitar -8,5 dB (Gambar 3.12). Model hamburan memiliki regresi polinomial polinomial $y = -0,0143x^2 + 0,3976x - 10,339$ dengan $R^2 = 0,8139$.



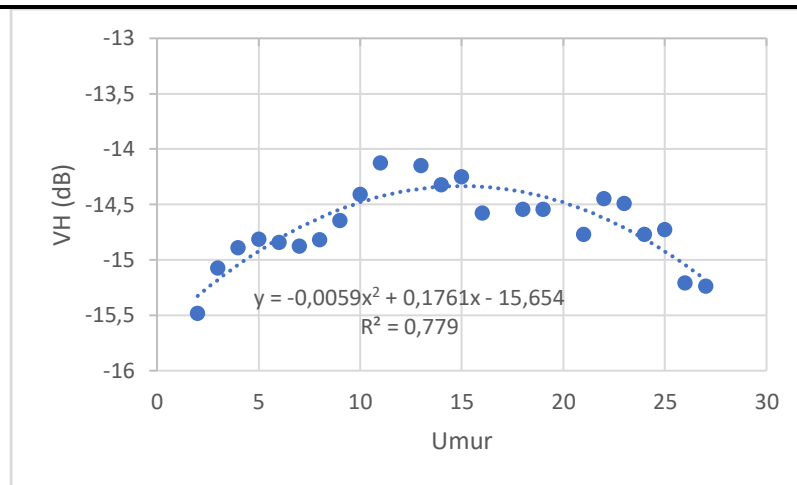
*Gambar 3.13 Model Fenologi untuk kelas kesesuaian lahan S3 polarisasi
VH*

Pada polarisasi VH dengan kesesuaian lahan S3, memiliki nilai pada usia 0-5 tahun sekitar -15,1 dB, pada usia 5-10 tahun sekitar -14,5 dB, pada usia 10-15 tahun sekitar -14 dB, pada usia 15-20 tahun sekitar -14,3 dB, dan pada usia 20-25 tahun sekitar -15,5 dB (Gambar 3.13). Model hamburan memiliki regresi polinomial polinomial $y = -0,0115x^2 + 0,2869x - 16,083$ dengan $R^2 = 0,7665$.



Gambar 3.14 Model Fenologi untuk kelas kesesuaian lahan N
polarisasi VV

Pada polarisasi VV dengan kesesuaian lahan N, nilainya dimulai pada usia 0-5 tahun sekitar -10 dB, pada usia 5-10 tahun sekitar -8 dB, pada usia 10-15 tahun sekitar -7 dB, pada usia 15-20 tahun sekitar -7,5 dB, dan pada usia 20-30 tahun sekitar -9 dB (Gambar 3.14). Model hamburan memiliki regresi polinomial polinomial $y = -0,0135x^2 + 0,4195x - 10,508$ dengan $R^2 = 0,8873$.



Gambar 3.15 Model Fenologi untuk kelas kesesuaian lahan N
polarisasi VH

Pada polarisasi VH dengan kesesuaian lahan N, nilainya dimulai pada usia 0-5 tahun sekitar -15,5 dB, pada usia 5-10 tahun sekitar -14,5 dB, pada usia 10-15 tahun sekitar -14,1 dB, pada usia 15-20 tahun sekitar -14,51 dB, dan pada usia 20-30 tahun sekitar -15,3 dB (Gambar 3.15). Model hamburan memiliki regresi polinomial polinomial $y = -0,0059x^2 + 0,1761x - 15,654$ dengan $R^2 = 0,779$.

Untuk data SAR ada dua kategori karakteristik yang signifikan untuk menentukan nilai hamburan SAR adalah sensor dan karakteristik target (Flores-Anderson dkk., 2019). Kategori sensor meliputi frekuensi/panjang gelombang SAR, polarisasi sinyal SAR yang ditransmisikan dan diterima, sudut datang berkas radar yang berinteraksi dengan tanah, dan posisi sensor mencari (Flores-Anderson dkk., 2019). Menurut Henderson dan Lewis, (2008) pengaruh karakteristik target bervariasi dengan (1) jenis vegetasi, (2) struktur tegakan, dan (3) komposisi tajuk.

Karakteristik hamburan vegetasi hutan dipengaruhi oleh ketebalan volume, kerapatan partikel komponen (atau hamburan), distribusi ukuran partikel komponen, distribusi bentuk partikel komponen, distribusi orientasi partikel komponen, dan sifat dielektrik dari partikel komponen (Reiche dkk., 2018). Sangat penting untuk mengetahui polarisasi dari mana gambar SAR diperoleh karena sinyal pada polarisasi yang berbeda berinteraksi secara berbeda dengan objek di darat, yang mempengaruhi kecerahan radar yang direkam dalam saluran polarisasi tertentu (van der Sanden, 1997). Untuk mempermudah, diasumsikan bahwa pemandangan alam dapat digambarkan sebagai kombinasi dari tiga jenis penghambur: (1) penghambur permukaan kasar, (2) penghambur bouncing ganda, dan (3) penghambur volume (Arii dkk., 2010).

3.5 Validasi

Untuk memvalidasi dan mengevaluasi hasil model yang diterapkan maka diperlukan data sekunder seperti data lapangan untuk mengetahui keakuratan model tersebut. Evaluasi temuan klasifikasi merupakan langkah penting dalam operasi klasifikasi. Berbagai metodologi, mulai dari tinjauan kualitatif berdasarkan pengetahuan ahli hingga penilaian akurasi kuantitatif berdasarkan prosedur pengambilan sampel, dapat digunakan. Cihlar dkk. (1998) memberikan enam kriteria untuk mengevaluasi efektivitas metode klasifikasi: akurasi, pengulangan, *robustness*, kapasitas untuk sepenuhnya memanfaatkan isi informasi data, aplikasi yang sama, dan objektifitas (Lu dan Weng, 2007).

Sebelum melakukan evaluasi akurasi hasil model klasifikasi, perlu dipahami asal-usul kesalahan/error. Selain kesalahan dari klasifikasi itu sendiri, sumber kesalahan lainnya, seperti kesalahan posisi akibat registrasi, kesalahan interpretasi, dan kualitas sampel pelatihan atau pengujian yang buruk, semuanya mempengaruhi akurasi klasifikasi. Dalam proses penilaian akurasi, umumnya diasumsikan bahwa perbedaan antara hasil model dan data referensi disebabkan oleh kesalahan klasifikasi (Stehman dan Czaplewski, 1998). Pendekatan matriks kesalahan adalah yang paling banyak digunakan dalam penilaian akurasi (Foody, 2002). Untuk menghasilkan matriks kesalahan dengan benar, kita harus mempertimbangkan faktor-faktor berikut: (1) pengumpulan data referensi, (2) skema klasifikasi, (3) skema sampling, (4) autokorelasi spasial, dan (5) ukuran sampel dan unit sampel (Congalton, 2001). Setelah pembuatan matriks kesalahan, elemen penilaian akurasi penting lainnya, seperti akurasi keseluruhan/*overall accuracy*, *omission error*, *commission error*, dan *kappa coefficient* dapat ditentukan (Congalton, 2001; Foody, 2004). Koefisien Kappa adalah ukuran kesepakatan statistik keseluruhan matriks kesalahan yang memperhitungkan faktor non-diagonal. Analisis Kappa secara luas diakui sebagai alat yang kuat untuk menganalisis matriks kesalahan tunggal dan mengevaluasi perbedaan antara matriks kesalahan yang berbeda (Congalton, 2001; Foody, 2002).

Tabel 3.1 Hasil Uji Akurasi pada Perkebunan Kelapa Sawit
di Asahan, Sumatera Utara

| Uji Akurasi | | | Total |
|--------------------|---------------------|---------------------|-------|
| Kelas Umur | Tahun tanam (ha) | Hasil model (ha) | |
| Sudah Menghasilkan | 1455,45006 | 1141,075269 | 78% |

BAB IV. KESIMPULAN

Produksi minyak sawit dunia meningkat pesat dalam 20 tahun terakhir, terutama di Indonesia dan Malaysia. Sebagai produsen terbesar, pengelolaan perkebunan kelapa sawit yang baik sangatlah penting, perluasan perkebunan juga harus terencana dengan baik, karena keberadaannya tidak boleh mempengaruhi lingkungan sekitar. Hal tersebut menyebabkan penanaman kelapa sawit menjadi hal yang tidak bisa dihindarkan karena didorong adanya permintaan nabati yang terus meningkat di dunia.

Khususnya Indonesia, sebagai Negara eksportir minyak sawit terbesar di dunia, sudah seharusnya terus melakukan peningkatan produksi dan melakukan ekspansi penanaman kelapa sawit. Manajemen yang baik pun perlu diupayakan untuk meningkatkan perekonomian Negara. Berbagai upaya penelitian perlu disalurkan dan dijembatani untuk meningkatkan kinerja industri dan mengurangi dampak negatif dari lingkungan yang disebabkan. Salah satunya adalah melalui estimasi model fenologis kelapa sawit.

Pengindraan jauh memainkan peranan penting dalam memantau dan estimasi fenologis kelapa sawit. Hal tersebut dapat dimanfaatkan untuk penilaian status lingkungan dan penilaian kondisi tanaman. Pastinya, hal tersebut bertujuan untuk mempersiapkan pertanian presisi, mengurangi biaya, dan meningkatkan produktivitas. Beberapa peneliti telah banyak

melakukan kajian mengenai aspek fenologi dan pertumbuhan pada pemodelan tanaman kelapa sawit.

Beberapa perusahaan perkebunan sawit juga bahkan sudah menggunakan teknologi tersebut. Hal tersebut dikarenakan penerapan penginderaan jauh untuk tanaman kelapa sawit sangat membantu perusahaan untuk memperoleh informasi yang berharga dan mahal namun dengan biaya yang relatif murah. Beberapa teknik telah diterapkan namun tidak dipublikasikan, sehingga desiminasi terkait teknik dan metode harus terus diberikan. Lebih baik lagi, integerasi antara pakar akademis dan industri sangat diperlukan untuk kemajuan dan keuntungan bersama.

DAFTAR PUSTAKA

- Al-doski, J., Mansor, S. B., Zulhaidi, H., dan Shafri, M. (2013): Image Classification in Remote Sensing, *3*(10), 141–148.
- Ali, I., Greifeneder, F., Stamenkovic, J., Neumann, M., dan Notarnicola, C. (2015): Review of machine learning approaches for biomass and soil moisture retrievals from remote sensing data, *Remote Sensing*, *7*(12), 16398–16421. <https://doi.org/10.3390/rs71215841>
- Amini, J., dan Sri Sumantyo, J. T. (2011): SAR and Optical Images for Forest Biomass Estimation, *Biomass - Detection, Production and Usage*, (January 2016). <https://doi.org/10.5772/18930>
- Arii, M., Van Zyl, J. J., dan Kim, Y. (2010): A general characterization for polarimetric scattering from vegetation canopies, *IEEE Transactions on Geoscience and Remote Sensing*, *48*(9), 3349–3357. <https://doi.org/10.1109/TGRS.2010.2046331>
- Avtar, R., Ishii, R., Kobayashi, H., Fadaei, H., Suzuki, R., dan Herath, S. (2013): Efficiency of multi-frequency, multi-polarized SAR data to monitor growth stages of oilpalm plants in Sarawak, Malaysia, *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2137–2140. <https://doi.org/10.1109/IGARSS.2013.6723236>
- Barber, C. B., Dobkin, D. P., dan Huhdanpaa, H. (1996): The

-
- Quickhull Algorithm for Convex Hulls, *ACM Transactions on Mathematical Software*, **22**(4), 469–483.
<https://doi.org/10.1145/235815.235821>
- Buana, L. (2003): Kultur Teknis Kelapa sawit, penilaian kesesuaian lahan, disain kebun dan pembukaan lahan., *Modul M-100-203*, 1–9.
- Carolita, I., Darmawan, S., Permana, R., Dirgahayu, D., Wiratmoko, D., Kartika, T., dan Arifin, S. (2019): Comparison of Optic Landsat-8 and SAR Sentinel-1 in Oil Palm Monitoring, Case Study : Asahan, North Sumatera, Indonesia, *IOP Conference Series: Earth and Environmental Science*, **280**(1).
<https://doi.org/10.1088/1755-1315/280/1/012015>
- Carolita, Ita., Yudhatama, D., Dirgahayu, D., Darmawan, S., Hernawati, R., Noviar, H., Kartika, T., Dewi, E. K., Arifin, S., dan Silvia (2019): *INFORMASI SPASIAL TEMATIK KLASIFIKASI TANAMAN SAWIT BERDASARKAN UMUR* (1 ed.), Pusat Pemanfaatan Penginderaan Jauh, LAPAN, Jakarta, 41.
- Carolita, Ita, Sitorus, J., Manalu, J., dan Wiratmoko, D. (2017): Growth Profile Analysis of Oil Palm By Using Spot 6 the Case of North Sumatra, *International Journal of Remote Sensing and Earth Sciences (IJReSES)*, **12**(1), 21.
<https://doi.org/10.30536/ijreses.2015.v12.a2669>
- Chan, T. F., Golub, G. H., dan Leveque, R. J. (1983): Statistical computing: Algorithms for computing the sample variance: Analysis and recommendations, *American Statistician*.
<https://doi.org/10.1080/00031305.1983.10483115>
-

-
- Chong, K. L., Kanniah, K. D., Pohl, C., dan Tan, K. P. (2017): A review of remote sensing applications for oil palm studies, *Geo-Spatial Information Science*, **20**(2), 184–200. <https://doi.org/10.1080/10095020.2017.1337317>
- Cohen, A. C. (1949): On Estimating the Mean and Standard Deviation of Truncated Normal Distributions, *Journal of the American Statistical Association*, **44**(248), 518–525. <https://doi.org/10.1080/01621459.1949.10483324>
- Congalton, R. G. (2001): Accuracy assessment and validation of remotely sensed and other spatial information, *International Journal of Wildland Fire*, **10**(3–4), 321–328. <https://doi.org/10.1071/wf01031>
- Crippen, R. E. (1990): Calculating the vegetation index faster, *Remote Sensing of Environment*, **34**(1), 71–73. [https://doi.org/10.1016/0034-4257\(90\)90085-Z](https://doi.org/10.1016/0034-4257(90)90085-Z)
- Czernecki, B., Nowosad, J., dan Jabłońska, K. (2018): Machine learning modeling of plant phenology based on coupling satellite and gridded meteorological dataset, *International Journal of Biometeorology*, **62**(7), 1297–1309. <https://doi.org/10.1007/s00484-018-1534-2>
- Darmawan, S., Carolita, I., Hernawati, R., Dirgahayu, D., Agustan., Permadi, D. A., Sari, D. K., Suryadini, W., Wiratmoko, D., dan Kunto, Y. (2021): The Potential Scattering Model for Oil Palm Phenology Based on Spaceborne X-, C-, and L-Band Polarimetric SAR Imaging, *Journal of Sensors*, **2021**(6625774), 14.
-

<https://doi.org/10.1155/2021/6625774>

Darmawan, S., Naser, M., Carolita, I., dan Sari, D. K. (2018): State of The Art Remote Sensing Technology For Oil Palm Management In Indonesia, *Proceedings Asian Conference on Remote Sensing (ACRS) 2018, Kuala Lumpur, Malaysia*, **1**, 830–834.

Darmawan, S., Takeuchi, W., Haryati, A., Najib, R. A. M., dan Na'Aim, M. (2016): An investigation of age and yield of fresh fruit bunches of oil palm based on ALOS PALSAR 2, *IOP Conference Series: Earth and Environmental Science*, **37**(1).
<https://doi.org/10.1088/1755-1315/37/1/012037>

Descals, A., Wich, S., Meijaard, E., Gaveau, D. L. A., Peedell, S., dan Szantoi, Z. (2021): High-resolution global map of smallholder and industrial closed-canopy oil palm plantations, *Earth System Science Data*, **13**(3), 1211–1231.
<https://doi.org/10.5194/essd-13-1211-2021>

Egwu Kalu, A. K. (2008): Introduction of Regression Analysis, diperoleh melalui situs internet:
<http://numericalmethods.eng.usf.edu>, (1), 1–6.

Faller, N., dan Weber, M. (2007): TerraSAR-X and TanDEM-X: Revolution in spaceborne radar, *International Geoscience and Remote Sensing Symposium (IGARSS)*, 4924–4928.
<https://doi.org/10.1109/IGARSS.2007.4423966>

Firmansyah, M. A. (2017): Karakterisasi, Kesesuaian Lahan dan Teknologi Kelapa Sawit Rakyat di Rawa Pasang Surut Kalimantan Tengah, *Jurnal Penelitian Pertanian Terapan*,

14(2), 97–105. <https://doi.org/10.25181/jppt.v14i2.147>

Flores-Anderson, A. I., Herndon, K. E., Thapa, R. B., dan Cherrington, E. (2019): THE SAR Comprehensive Methodologies for Forest. <https://doi.org/10.25966/nr2c-s697>

Foody, G. M. (2002): Status of land cover classification accuracy assessment, *Remote Sensing of Environment*, **80**(1), 185–201. [https://doi.org/10.1016/S0034-4257\(01\)00295-4](https://doi.org/10.1016/S0034-4257(01)00295-4)

Foody, G. M. (2004): Thematic map comparison: Evaluating the statistical significance of differences in classification accuracy, *Photogrammetric Engineering and Remote Sensing*, **70**(5), 627–633. <https://doi.org/10.14358/PERS.70.5.627>

Frost, J. (2020): *Regression Analysis: An Intuitive Guide for Using and Interpreting Linear Models*.

Gebhardt, S., Huth, J., Nguyen, L. D., Roth, A., dan Kuenzer, C. (2012): A comparison of TerraSAR-X Quadpol backscattering with RapidEye multispectral vegetation indices over rice fields in the Mekong Delta, Vietnam, *International Journal of Remote Sensing*, **33**(24), 7644–7661. <https://doi.org/10.1080/01431161.2012.702233>

Henderson, F. M., dan Lewis, A. J. (2008): Radar detection of wetland ecosystems: A review, *International Journal of Remote Sensing*, **29**(20), 5809–5835. <https://doi.org/10.1080/01431160801958405>

Hernawati, R., dan Darmawan, S. (2018): Change detection analysis using NDVI in Bandung, Indonesia, *Proceedings -*

-
- 39th Asian Conference on Remote Sensing: Remote Sensing Enabling Prosperity, ACRS 2018*, **2**(October 2018), 1203–1210.
- Hilal, Y. Y., Yahya, A., Ismail, W. i W., dan Asha'ari, Z. H. (2020): Neural Networks Method in Predicting Oil Palm FFB Yields for the Peninsular States of Malaysia, *Journal of Oil Palm Research*, (February).
<https://doi.org/10.21894/jopr.2020.0105>
- Holloway, J., dan Mengersen, K. (2018): Statistical machine learning methods and remote sensing for sustainable development goals: A review, *Remote Sensing*, **10**(9).
<https://doi.org/10.3390/rs10091365>
- Hu, J., Ghamisi, P., dan Zhu, X. (2018): Feature Extraction and Selection of Sentinel-1 Dual-Pol Data for Global-Scale Local Climate Zone Classification, *ISPRS International Journal of Geo-Information*, **7**(9), 379.
<https://doi.org/10.3390/ijgi7090379>
- Jensen, J. R. (2014): *Remote sensing of the environment: an earth resource perspective second edition*, Pearson Education Limited, Harlow, England, **1**, 333–378.
- Kee, Y. W., Shariff, A. R. M., Sood, A. M., dan Nordin, L. (2018): Application of SAR data for oil palm tree discrimination, *IOP Conference Series: Earth and Environmental Science*, **169**(1).
<https://doi.org/10.1088/1755-1315/169/1/012065>
- Lee, J. S., Jurkevich, I., Dewaele, P., Wambacq, P., dan Oosterlinck, A. (1994): Speckle filtering of synthetic aperture radar
-

-
- images: a review, *Remote Sensing Reviews*, **8**(4), 313–340.
<https://doi.org/10.1080/02757259409532206>
- Li, W., Fu, H., Yu, L., dan Cracknell, A. (2017): Deep learning based oil palm tree detection and counting for high-resolution remote sensing images, *Remote Sensing*, **9**(1).
<https://doi.org/10.3390/rs9010022>
- Lu, D., dan Weng, Q. (2007): A survey of image classification methods and techniques for improving classification performance, *International Journal of Remote Sensing*, **28**(5), 823–870. <https://doi.org/10.1080/01431160600746456>
- Maxwell, A. E., Warner, T. A., dan Fang, F. (2018): Implementation of machine-learning classification in remote sensing: An applied review, *International Journal of Remote Sensing*, **39**(9), 2784–2817.
<https://doi.org/10.1080/01431161.2018.1433343>
- McMorrow, J. (2001): Linear regression modelling for the estimation of oil palm age from Landsat TM, *International Journal of Remote Sensing*, **22**(12), 2243–2264.
<https://doi.org/10.1080/01431160117188>
- Miettinen, J., Liew, S. C., dan Kwoh, L. K. (2015): Usability of sentinel-1 dual polarization C-band data for plantation detection in Insular Southeast Asia, *ACRS 2015 - 36th Asian Conference on Remote Sensing: Fostering Resilient Growth in Asia, Proceedings*.
- Mohd Najib, N. E., Kanniah, K. D., Cracknell, A. P., dan Yu, L. (2020): Synergy of active and passive remote sensing data for
-

-
- effective mapping of oil palm plantation in Malaysia, *Forests*, **11**(8). <https://doi.org/10.3390/F11080858>
- Mubin, N. A., Nadarajoo, E., Shafri, H. Z. M., dan Hamedianfar, A. (2019): Young and mature oil palm tree detection and counting using convolutional neural network deep learning method, *International Journal of Remote Sensing*, **40**(19), 7500–7515.
<https://doi.org/10.1080/01431161.2019.1569282>
- Nordin, L., Lumpur, K., dan Palm, O. (1996): Application of Aisars Data To Oil Palm Tree, *Production*, (December), 3–9.
- Okarda, B., Carolita, I., Kartika, T., dan Komarudin, H. (2018): Mapping of smallholder oil palm plantation and development of a growth model, *IOP Conference Series: Earth and Environmental Science*, **169**(1), 0–7.
<https://doi.org/10.1088/1755-1315/169/1/012074>
- Omar, H., Misman, M. A., dan Kassim, A. R. (2017): Synergetic of PALSAR-2 and sentinel-1A SAR polarimetry for retrieving aboveground biomass in dipterocarp forest of Malaysia, *Applied Sciences (Switzerland)*, **7**(7).
<https://doi.org/10.3390/app7070675>
- Pohl, C., dan Loong, C. K. (2016): In-situ data collection for oil palm tree height determination using synthetic aperture radar, *IOP Conference Series: Earth and Environmental Science*, **34**(1).
<https://doi.org/10.1088/1755-1315/34/1/012027>
- Rawlings, J. O., Pantula, S. G., dan Dickey, D. A. (1990): *Applied Regression Analysis: A Research Tool*, Springer, **41**, 782.
-

<https://doi.org/10.2307/2583482>

Reiche, J., Verhoeven, R., Verbesselt, J., Hamunyela, E., Wielaard, N., dan Herold, M. (2018): Characterizing tropical forest cover loss using dense Sentinel-1 data and active fire alerts, *Remote Sensing*, **10**(5), 1–18. <https://doi.org/10.3390/rs10050777>

Sarzynski, T., Giam, X., Carrasco, L., dan Huay Lee, J. S. (2020): Combining radar and optical imagery to map oil palm plantations in Sumatra, Indonesia, using the Google Earth Engine, *Remote Sensing*, **12**(7). <https://doi.org/10.3390/rs12071220>

Schober, P., dan Schwarte, L. A. (2018): Correlation coefficients: Appropriate use and interpretation, *Anesthesia and Analgesia*, **126**(5), 1763–1768. <https://doi.org/10.1213/ANE.0000000000002864>

Shashikant, V., Shariff, A. R. M., Nordin, L., dan Pradhan, B. (2012): Estimation of above ground biomass of oil palm trees by PALSAR, *CHUSER 2012 - 2012 IEEE Colloquium on Humanities, Science and Engineering Research*, (May 2014), 838–841. <https://doi.org/10.1109/CHUSER.2012.6504430>

Shimada, M. (2011): Model-based polarimetric SAR calibration method using forest and surface-scattering targets, *IEEE Transactions on Geoscience and Remote Sensing*, **49**(5), 1712–1733. <https://doi.org/10.1109/TGRS.2010.2090046>

Stehman, S. V., dan Czaplewski, R. L. (1998): Design and Analysis for Thematic Map Accuracy Assessment - an application of satellite imagery, *Remote Sensing of Environment*, diperoleh

-
- melalui situs internet:
[http://www.ingentaconnect.com/content/els/00344257/1998/00000064/00000003/art00010%5Cnhttp://dx.doi.org/10.1016/S0034-4257\(98\)00010-8](http://www.ingentaconnect.com/content/els/00344257/1998/00000064/00000003/art00010%5Cnhttp://dx.doi.org/10.1016/S0034-4257(98)00010-8), **64**(January), 331–344.
- Talukdar, S., Singha, P., Mahato, S., Shahfahad, Pal, S., Liou, Y. A., dan Rahman, A. (2020): Land-use land-cover classification by machine learning classifiers for satellite observations-A review, *Remote Sensing*, **12**(7).
<https://doi.org/10.3390/rs12071135>
- Tan, K. P., Kanniah, K. D., dan Cracknell, A. P. (2013): Use of UK-DMC 2 and ALOS PALSAR for studying the age of oil palm trees in southern peninsular Malaysia, *International Journal of Remote Sensing*, **34**(20), 7424–7446.
<https://doi.org/10.1080/01431161.2013.822601>
- Teng, K. C., Koay, J. Y., Tey, S. H., Lim, K. S., Ewe, H. T., dan Chuah, H. T. (2015): A dense medium microwave backscattering model for the remote sensing of oil palm, *IEEE Transactions on Geoscience and Remote Sensing*, **53**(6), 3250–3259.
<https://doi.org/10.1109/TGRS.2014.2372796>
- van der Sanden, J. J. (1997): *Radar remote sensing to support tropical forest management* (Series 5) (P. & L. Bv, Ed.), Tropenbos-Guyana Series 5, Georgetown, Guyana, 356.
- Wang, H., Magagi, R., Goïta, K., Trudel, M., McNairn, H., dan Powers, J. (2019): Crop phenology retrieval via polarimetric SAR decomposition and Random Forest algorithm, *Remote Sensing of Environment*, **231**(May), 111234.
-

<https://doi.org/10.1016/j.rse.2019.111234>

Yalcin, H. (2018): Phenology recognition using deep learning: DeepPheno, *26th IEEE Signal Processing and Communications Applications Conference, SIU 2018*, 1–4.
<https://doi.org/10.1109/SIU.2018.8404165>

 **penerbit itenas**

Jl. PKH. Mustapha No.23, Bandung 40124
Telp. +62 22 7272215, Fax.: +62 22 7202892
e-mail: penerbit@itenas.ac.id

ISBN 978-623-7525-42-4

