

BAB I. PENDAHULUAN

1.1 Latar Belakang

Kemajuan teknologi di era digital memberikan banyak manfaat dalam berbagai aspek kehidupan, termasuk pengelolaan sumber daya alam. Salah satu teknologi yang semakin berkembang adalah penginderaan jauh dan Sistem Informasi Geografis (SIG) yang memungkinkan pemetaan wilayah secara akurat dan efisien. Teknologi ini sangat bermanfaat dalam sektor pertanian, khususnya untuk mendukung pengelolaan tanaman kakao. Hal ini memanfaatkan teknologi dengan menggunakan SIG dan penginderaan jauh, pemetaan lahan kakao dapat dilakukan dengan lebih mudah, mulai dari pemetaan lahan hingga pemantauan kondisi tanaman, sehingga mendukung keberlanjutan pengelolaan dan peningkatan produktivitas tanaman kakao (Amiruddin *et al.*, 2015).

Kakao (*Theobroma cacao* L.) merupakan salah satu komoditas perkebunan yang memiliki peran penting di pasar pangan global. Industri ini melibatkan jutaan petani di berbagai negara, membantu mengurangi kemiskinan dan menciptakan banyak lapangan kerja. Dalam perekonomian Indonesia, kakao menjadi salah satu produk unggulan di sektor perkebunan. Selain berkontribusi pada pertumbuhan ekonomi nasional, kakao juga menjadi komoditas ekspor yang mendatangkan devisa bagi negara, sejalan dengan sektor minyak dan gas. Data Internasional *Cocoa Organization* tahun 2022/2023, Indonesia menjadi produsen kakao di dunia dengan produksi 160 ribu ton kakao. menurut data statistik kakao Indonesia pada tahun 2022, perkebunan kakao didominasi perkebunan rakyat dengan petani kecil sebagai pengelola mencakup 1,42 juta hektar atau 99,63% dari total perkebunan kakao di Indonesia (Rohmando & Hartini, 2024).

Kabupaten Pinrang di Sulawesi Selatan merupakan salah satu daerah penghasil kakao di Indonesia, yang pernah mencapai masa kejayaan pada era 1990-an dengan luas lahan mencapai 18.900 hektar dan produksi sekitar 9.000 ton per tahun. Namun serangan hama, penyakit dan penurunan harga pasar menyebabkan penyusutan produktivitas. Dalam upaya mengembalikan kejayaan kakao, pemerintah Kabupaten Pinrang meluncurkan berbagai inisiatif, termasuk pelatihan petani mengelola lahan. Pemetaan lahan kakao menjadi bagian penting dari strategi ini, karena dapat membantu dalam identifikasi kondisi lahan, sebaran tanaman, serta evaluasi produktivitas melalui teknologi penginderaan jauh dan sistem informasi geografis (Dimas, 2022). Dengan pemetaan yang akurat, program penelitian ini akan efisien dan berkelanjutan dalam mendukung keberlanjutan petani lokal.

Pemetaan tanaman kakao sangat penting untuk membantu petani mengelola perkebunan dengan lebih baik. Salah satu cara yang digunakan adalah dengan indeks vegetasi, seperti NDVI (*Normalized Difference Vegetation Index*) yang mengukur kesehatan tanaman berdasarkan pantulan cahaya. Dengan indeks ini, kita bisa mengetahui apakah tanaman kakao tumbuh dengan baik atau mengalami masalah, seperti kekurangan nutrisi atau serangan hama. Informasi ini membantu petani mengambil tindakan yang tepat untuk menjaga kualitas tanaman. Selain itu, pemetaan kakao juga bisa dilakukan dengan citra multispektral, yang menangkap gambar dalam berbagai warna, termasuk cahaya yang tidak terlihat oleh mata manusia (Marlina, 2022). Dengan teknik ini, kita bisa membedakan tanaman kakao dari tanaman lain dan juga melihat kondisi lahan secara lebih jelas

Untuk analisis yang lebih detail, bisa digunakan metode *random forest* dan penggabungan citra multiband dalam pemetaan kakao karena dapat membantu menghasilkan peta yang akurat. Metode *random forest* merupakan teknik komputer yang cerdas untuk mengenali pola dari data, termasuk membedakan tanaman kakao dari tanaman lainnya. Citra multiband berasal dari satelit dan terdiri dari beberapa saluran warna (band) yang bisa mencakup ciri khas tanaman berdasarkan pantulan cahaya, seperti warna daun dan kelembaban. Citra multiband berguna untuk mengetahui sebaran tanaman kakao dan mendeteksi masalah yang mungkin tidak terlihat secara langsung (Tridawati *et al.*, 2023).

Random forest diartikan sebagai metode *machine learning* dimana menggunakan kumpulan pohon keputusan (*decision trees*) untuk melakukan prediksi yang lebih akurat. Setiap pohon dalam *random forest* dilatih menggunakan subset data yang berbeda-beda dan memberikan hasil prediksi masing-masing. Hasil akhir ditentukan berdasarkan mayoritas suara (*voting*) untuk klasifikasi atau rata-rata untuk regresi, sehingga mengurangi risiko *overfitting* dan meningkatkan akurasi model. Algoritma ini banyak digunakan dalam berbagai bidang seperti lingkungan, kesehatan dan lainnya untuk mendeteksi pola dan membuat prediksi yang kompleks (Wibowo, 2020).

Teknik penginderaan jauh atau *remote sensing* termasuk referensi yang baik untuk memberikan pembaca dalam memahami dan menafsirkan data yang diilustrasikan dalam bentuk gambar sehingga memperoleh sebuah informasi. Data citra penginderaan jauh, seperti sentinel sangat populer untuk pemantauan lahan (Hastina *et al.*, 2023), sehingga dapat digunakan untuk menganalisis karakteristik air, vegetasi dan tanah dengan memanfaatkan band sinar tampak (*visible*) dan inframerah (*infrared*). Air menyerap gelombang inframerah, sementara vegetasi dan tanah memantulkan panjang gelombang tertentu dengan kuat. Kombinasi teknik ini sangat efektif dalam memetakan perubahan tutupan lahan daerah daratan dan perairan, termasuk dalam identifikasi perubahan garis pantai serta pemetaan tanaman (Kasim, 2012).

Dengan semakin berkembangnya teknologi pemetaan berbasis penginderaan jauh, diharapkan petani dan pemangku kepentingan di sektor perkebunan kakao dapat mengadopsi pendekatan ini untuk meningkatkan efisiensi produksi, mengurangi dampak lingkungan dan memastikan keberlanjutan industri kakao di masa depan. Berdasarkan uraian diatas maka perlu untuk melakukan penelitian ini untuk mengetahui analisis persebaran tanaman pada suatu wilayah dengan memanfaatkan teknologi menggunakan bantuan citra satelit berdasarkan sistem informasi geografis.

1.2. Tujuan dan Manfaat


Tujuan dari penelitian ini yaitu memetakan tanaman kakao dan *non-kakao* di wilayah Kecamatan Batulappa Kabupaten Pinrang, menggunakan indeks vegetasi NDVI, GLCM atau fitur tekstur dan komposit band RGB citra satelit sentinel-2A.

Kegunaan dari penelitian ini dapat membantu dalam memantau kondisi tanaman secara lebih mudah dan akurat. Selain itu, bagi pemerintah dan lembaga terkait, penelitian ini dapat menjadi dasar dalam perencanaan dan pengelolaan perkebunan kakao secara lebih efektif dan berkelanjutan.

BAB II. METODE PENELITIAN

2.1 Waktu dan Tempat

Penelitian ini dilaksanakan pada bulan Juni hingga Agustus 2025 dan bertempat pada wilayah penghasil kakao di Desa Tapporang, Desa Watang Kassa dan Desa Kassa, Kecamatan Batulappa, Kabupaten Pinrang, Sulawesi Selatan, Indonesia.



Gambar 1. Lokasi Penelitian Kecamatan Batulappa, Kabupaten Pinrang

2.2 Alat dan Bahan

Alat yang digunakan pada penelitian yaitu laptop, *Software* Quantum GIS (QGIS) 3.32, aplikasi *Avenza Maps*, *handphone* dan alat tulis. Bahan yang digunakan yaitu, citra *google earth*, data lokasi kebun kakao Kecamatan Batulappa yang diperoleh dari Dinas Peternakan dan Perkebunan Kabupaten Pinrang, data *ground truth* dalam bentuk survei lapangan, Peta Rupa Bumi Indonesia (RBI) Kabupaten Pinrang, dokumentasi dan citra sentinel-2A akuisisi 28/05/2025 pada level 2A (telah terkoreksi atmosferik dan geometrik). Citra Sentinel-2A dilengkapi dengan instrumen utama *Multispectral Instrument* (MSI), memiliki kemampuan menangkap 13 band spektral. Citra Sentinel-2A juga memiliki resolusi spasial bervariasi antara 10 meter, 20 meter hingga 60 meter, tergantung pada panjang gelombang yang diukur, karakteristik seluruh band citra sentinel-2A dilihat pada Tabel 1.

Tabel 1. Karakteristik Citra Sentinel-2A

Band	Panjang Gelombang (mikrometer)	Resolusi Spasial (meter)
Band 1- Coastel Aerosol	0,443	60
Band 2 - Blue	0,490	10
Band 3 - Green	0,560	10
Band 4 - Red	0,665	10
Band 5 - Vegetation Red Edge	0,705	20
Band 6 - Vegetation Red Edge	0,740	20
Band 7 - Vegetation Red Edge	0,783	20
Band 8 - NIR	0,842	10
Band 8A - Vegetation Red Edge	0,865	20
Band 9 - Water Vapour	0,945	60
Band 10 SWIR - Cirrus	1,375	60
Band 11 - SWIR	1,610	20
Band 12 - SWIR	2,190	20

Sumber : Sentinel-2 *User Handbook* (ESA, 2015).

2.3 Metode Penelitian

2.3.1 Tahap Persiapan

Tahapan awal yang dilakukan dalam penelitian ini berupa mencari literatur atau studi pustaka mengenai pemetaan kakao, Sentinel-2A, indeks vegetasi dan algoritma *random forest*.

2.3.2 Tahap Pengumpulan Data

Tahapan pengumpulan data dimulai dengan mengunduh peta Rupa Bumi Indonesia (RBI) wilayah Kabupaten Pinrang pada laman tanahair.indonesia.go.id data citra sentinel-2A pada laman sentinel-hub.com dan data lokasi kebun kakao yang diperoleh dari kantor Dinas Peternakan dan Perkebunan Kabupaten Pinrang. Tahap pengumpulan data lapangan dilakukan dengan mensurvei kelas tutupan lahan, pengambilan *ground truth* data pada setiap jenis tutupan lahan menggunakan aplikasi *Avenza Maps* dan pengambilan dokumentasi. Selain itu, citra *google earth* digunakan sebagai referensi visual dalam identifikasi jenis tutupan lahan dan juga untuk menentukan titik koordinat tambahan yang mendukung data *ground truth*. Kemudian data *ground truth* ini akan dibagi menjadi dua, 60% untuk *training* area dan 40% untuk pengujian atau *testing*. Pembagian data ini membantu dalam memastikan model yang dihasilkan memiliki kinerja yang baik (Masdian *et al.*, 2023).

2.3.3 Tahap Pengolahan Data

1. Interpretasi Visual

Interpretasi visual pada citra Sentinel-2A merupakan tahap awal dalam pengolahan citra satelit yang bertujuan untuk memberikan gambaran awal tentang data citra yang tersedia. Pada tahap ini, mengevaluasi kualitas citra, mengenali objek-objek yang ada, serta mendeteksi potensi masalah seperti awan atau bayangan (Kosasih *et al.*, 2019).

2. Pemotongan Citra Sentinel-2A di Kecamatan Batulappa

Pemotongan citra sesuai dengan batas wilayah Kecamatan Batulappa. Proses ini dapat dilakukan menggunakan alat *clip raster by mask layer* di perangkat lunak QGIS. Pada tahap ini, penting untuk memastikan bahwa resolusi spasial dan data atribut citra tetap terjaga agar hasil pemotongan tidak kehilangan kualitas.

3. Pengolahan Data Citra NDVI

Normalized Difference Vegetation Index (NDVI) diartikan sebagai indeks yang digunakan untuk mengukur tingkat kehijauan atau aktivitas fotosintesis vegetasi. Perhitungan NDVI menghasilkan nilai kisaran vegetasi antara -1 sampai +1 (Tabel 2), di mana nilai -1–0,2 menunjukkan lahan tanpa ada vegetasi, sedangkan nilai 0,72–1 menunjukkan kepadatan vegetasi rapat atau kepadatan vegetasi tertinggi (NASA Earth Observatory, 2000).

Menurut Xavier *et al.*, (2006), NDVI dihitung berdasarkan kombinasi reflektansi band merah (*Red*) dan inframerah dekat (NIR), yang dapat dilihat pada persamaan (1) sebagai berikut:

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

Tabel 2. Kisaran Rentan Kerapatan Vegetasi

Kelas	Kisaran Nilai NDVI	Tingkat Kerapatan
1	-1 – 0,12	Lahan Tanpa Vegetasi
2	0,12 – 0,22	Vegetasi Sangat Jarang
3	0,22 – 0,42	Vegetasi Jarang
4	0,42 – 0,72	Vegetasi Sedang
5	0,72 – 1	Vegetasi Rapat

Sumber : (NASA Earth Observatory, 2000).

Adapun alasan memilih NDVI sebagai tahap pemilihan indeks vegetasi sebab, studi sebelumnya telah menunjukkan bahwa NDVI sangat efektif untuk mengidentifikasi tutupan vegetasi sehingga lebih akurat dalam membedakan tanaman yang memiliki warna daun serupa (Haeruddin *et al.*, 2023). Oleh karena itu pemilihan NDVI tepat sebagai indeks vegetasi dalam penelitian. NDVI juga salah satu indeks vegetasi yang paling populer dan banyak digunakan dalam berbagai penelitian pertanian berbasis penginderaan jauh, karena kemampuannya memberikan informasi vegetasi secara sederhana namun efektif (Haerani, 2019).

4. Komposit Band Citra Sentinel-2A

Komposit band merupakan proses dalam melakukan kombinasi 3 band multispektral sehingga membentuk sebuah citra berwarna yang menghasilkan tampilan warna target sama dengan objek aslinya. Komposit band dilakukan dengan menggabungkan 3 band yaitu *red* (band 4), *green* (band 3) dan *blue* (band 2). Penentuan band disesuaikan dengan warna spektralnya, yakni band 4 (*red*) untuk *red*, band 3 (*green*) untuk *green* dan band 2 (*blue*) untuk *blue*. Adapun tahapan melakukan komposit band dengan membuka menu *raster > semi-automatic classification plugin*, pilih tab *preprocessing* kemudian menambahkan semua band dari citra sentinel-2A. Setelah memilih band pilih *create RGB*

composite untuk menggabungkan band menjadi satu citra komposit. Hasil dari komposit band akan menampilkan warna objek aslinya.

5. Pengolahan GLCM

Gray Level Co-occurrence Matrix (GLCM), adalah cara untuk mengukur pola dan tekstur dalam suatu gambar dengan melihat bagaimana piksel-piksel yang ada dengan tingkat keabuan tertentu berkelompok atau terdistribusi. Menurut Moraiti *et al.* (2024), bahwa GLCM bekerja dengan menghitung seberapa sering pasangan nilai piksel tertentu muncul berdampingan, dengan hal itu maka bisa mengenali pola permukaan objek seperti kasar, halus atau berpola dalam gambar. Tahapan yang dilakukan dengan menggunakan *plugin haralick texture extraction > parameter texture advanced and all direction* (0°, 45°, 90°, 135°).

Analisis fitur tekstur citra dilakukan dengan GLCM menggunakan matriks 3×3 di *software* QGIS. Ukuran 3×3 dipilih agar bisa menangkap informasi tekstur dalam skala yang kecil, misalnya pada tanaman kakao, sehingga pola pikselnya lebih jelas terlihat oleh tingkat teksturnya. Band yang digunakan adalah band NIR citra Sentinel-2A. Hasil pengolahan GLCM akan dibandingkan dengan hasil klasifikasi berbasis indeks vegetasi dan RGB dari kedua citra tersebut.

6. Klasifikasi

Klasifikasi *random forest* merupakan algoritma berbasis *machine learning* bersifat *supervised* yang dapat digunakan untuk membuat prediksi atau klasifikasi. *Random forest* bekerja dengan cara membuat banyak pohon keputusan (*decision trees*) dari data yang diberikan, kemudian menggabungkan hasil dari semua pohon tersebut untuk memberikan prediksi yang lebih akurat (Mutoffar *et al.*, 2022). Keunggulan *random forest* adalah kemampuannya menangani data yang kompleks dan mencegah *overfitting* (Mutoffar *et al.* 2022). Proses klasifikasi algoritma *random forest* dilakukan menggunakan *plugin EnMap-Box 13.3* di QGIS. Adapun tahapannya yaitu *plugin EnMap-Box > classification workflow > training dataset > split testing (40%) > run*.

Tabel 3. Kelas Tutupan Lahan

No	Kelas Tutupan Lahan	Deskripsi
1	Perkebunan Kakao	Lahan yang ditanami dengan tanaman kakao dalam bentuk hamparan yang luas, homogen dan pola tanam yang teratur, baik yang dikelola perorangan maupun perusahaan
2	Sawah	Lahan basah berupa sawah yang ditanami padi secara terus menerus, bias dua atau tiga kali dalam setahun tergantung varietas padinya, tanpa ada pergiliran tanam dengan tanaman lain
3	Ladang/Tegalan dengan Palawija (Jagung)	Lahan kering (bukan sawah) yang ditanami dengan tanaman semusim bukan padi melainkan tanaman palawija seperti misalnya jagung, kedelai, kacang tanah dan sebagainya
4	Hutan	Areal yang tertutup oleh liputan vegetasi yang berkembang secara alami/semi-alami, baik berupa perpohonan rapat maupun vegetasi lain termasuk semak dan rumput dengan tingkat ketinggian dan kerapatan yang lebih rendah
5	Lahan Terbuka	Lahan tanpa tutupan atau lahan yang tidak terbangun baik bersifat alami maupun semi-alami, kelas-kelas ini meliputi lahan terbuka di wilayah daratan maupun daerah pesisir
6	Lahan Terbangun	Bangunan yang dibuat untuk permukiman (tempat tinggal) dan bangunan yang dibuat untuk kegiatan selain tempat tinggal permanen, terutama meliputi perdagangan, perkantoran dan industri
7	Tubuh air	Semua kenampakan perairan, baik yang alami maupun semi-alami, termasuk laut, waduk, kenampakan bawah permukaan berupa terumbu karang dan padang lamun

Sumber : (SNI, 7645-1:2014).

Pada tahap klasifikasi, data *training* berperan sebagai acuan bagi algoritma dalam membedakan kelas tutupan lahan. Data *training* merupakan sekumpulan piksel pada citra satelit yang telah diketahui kelasnya berdasarkan data referensi, seperti hasil survei atau intrerpretasi visual. Data ini digunakan untuk melatih model agar mampu mengenali pola spektral dari masing-masing kelas pada Tabel 3, (Subarnas *et al.*, 2025). Seperti yang telah disebutkan tahap pengumpulan data, data *training* nantinya akan dibagi menjadi 60% untuk *training* area dan 40% untuk pengujian atau testing. Hal ini akan membantu memastikan bahwa model klasifikasi yang dilakukan tidak hanya menghasilkan data yang dilatih, tetapi juga akurat dilapangan.

7. Nilai Akurasi

Akurasi hasil klasifikasi dihitung berdasarkan nilai *Overall Accuracy* (OA) secara keseluruhan, sedangkan *Producer Accuracy* (PA) dan *User Accuracy* (UA) untuk menilai ketepatan pada setiap kelas tutupan lahan. Jika hasil PA dan UA mendekati 100% maka tingkat kesalahan dalam identifikasi kelas dapat diminimalkan (Apriyanti *et al.*, 2025). Tingkat akurasi dianggap layak jika OA berada pada kisaran 80-89% kemudian klasifikasi dinilai sangat baik jika OA mencapai 90-94% dan klasifikasi dianggap memiliki ketelitian yang tinggi jika akurasinya lebih dari 95% (Zulfajri *et al.*, 2021). Adapun metode yang dilakukan pada *confussion matrix* dapat dilihat dari Tabel 4.

Tabel 4. *Confussion Matrix (error matrix)*

	TL I	TLII	TLIII	TLIV	Total Baris
TLI	A	a	b	c	Σ Baris 1
TLII	d	B	e	f	Σ Baris 2
TLIII	g	h	C	i	Σ Baris 3
TLIV	j	k	l	D	Σ Baris 4
Total Kolom	Σ Kolom 1	Σ Kolom 2	Σ Kolom 3	Σ Kolom 4	Σ Total Kolom dan Baris

Sumber : (Stehman, 1997).

Keterangan:

TLI,II...IV = Tutupan lahan

A,B,C,D = Jumlah piksel benar

a,b,c,...l = Jumlah piksel dalam satu kelas

Perlu diketahui bahwa *confussion matrix* merupakan tabel yang digunakan untuk mengevaluasi kinerja model klasifikasi. Tabel ini membandingkan hasil prediksi model dengan data aktual, sehingga kita bisa melihat seberapa akurat model dalam mengklasifikasikan data. Menurut Congalton, (1991) terdapat rumus perhitungan akurasi sebagai berikut:

a. *Overall Accuracy* (OA)

$$\text{Overall Accuracy} = \frac{\text{Jumlah data sesuai}}{\text{Jumlah total sampel}} \times 100\% \quad (2)$$

Akurasi keseluruhan mengukur persentase prediksi yang benar dari total prediksi yang dilakukan oleh model. Ini memberikan gambaran umum tentang seberapa baik model dalam melakukan klasifikasi secara keseluruhan, dapat dilihat pada persamaan (2).

b. *User Accuracy* (UA)

$$\text{User Accuracy} = \frac{\text{Jumlah kelas yang diklasifikasikan benar}}{\text{Jumlah total kelas yang diterima sebagai kelas tersebut}} \times 100\% \quad (3)$$

Akurasi pengguna (*user accuracy*) adalah ukuran yang menunjukkan seberapa benar hasil klasifikasi dalam peta dibandingkan dengan kondisi sebenarnya di lapangan. Rumus perhitungan ini dapat dilihat pada persamaan (3). Nilai ini dihitung dengan membandingkan jumlah piksel atau area yang benar dalam suatu kelas dengan total

piksel atau area yang diklasifikasikan dalam kelas tersebut. Semakin tinggi nilai akurasi pengguna, semakin besar kemungkinan bahwa data yang terlihat dalam peta sesuai dengan kondisi nyata di lapangan.

c. *Producer Accuracy* (PA)

$$\text{Producer Accuracy} = \frac{\text{Jumlah kelas yang diklasifikasikan benar}}{\text{Jumlah total kelas yang ada di lapangan}} \times 100\% \quad (4)$$

Akurasi produser (*producer accuracy*) menunjukkan sejauh mana suatu kelas di lapangan dapat terwakili dengan benar dalam peta hasil klasifikasi, dapat dilihat pada persamaan (4). Nilai ini dihitung dengan membandingkan jumlah piksel atau area yang benar dalam suatu kelas dengan total piksel atau area dari kelas tersebut di lapangan. Akurasi produser yang tinggi menunjukkan bahwa sebagian besar objek atau area dari suatu kelas berhasil terdeteksi dan diklasifikasikan dengan baik dalam peta.