

BAB II

TINJAUAN PUSTAKA

2.1 Grand Theory

Penelitian ini mengacu pada teori pengolahan citra digital dan kecerdasan buatan yang digunakan untuk menganalisis kematangan buah tandan segar kelapa sawit. Teori pengolahan citra digital melibatkan pengambilan, pemrosesan, dan analisis gambar menggunakan komputer untuk menghasilkan informasi yang relevan. Dalam konteks ini, pendekatan algoritma seperti K-Means Clustering dan Self-Organizing Maps (SOM) diterapkan untuk segmentasi dan klasifikasi data citra berdasarkan karakteristik tertentu.

2.2 Kelapa Sawit

Kelapa sawit (*Elaeis guineensis* Jacq) adalah salah satu tanaman perkebunan yang termasuk dalam famili Palmae dan berasal dari Afrika Barat seperti pada Gambar 1, kelapa sawit dikenal sebagai tanaman penghasil minyak nabati paling produktif dibandingkan dengan tanaman penghasil minyak nabati lainnya. Di Indonesia, tanaman ini telah berkembang menjadi komoditas perkebunan strategis yang memberikan kontribusi signifikan terhadap perekonomian nasional, dengan luas area perkebunan mencapai 14,99 juta hektar pada tahun 2020.



Gambar 1.1 Tandan buah segar kelapa sawit

Karakteristik warna pada Tandan Buah Segar (TBS) kelapa sawit mengalami perubahan yang signifikan seiring dengan proses pematangannya. Menurut penelitian yang dilakukan [4], perubahan warna ini menjadi indikator utama dalam menentukan tingkat kematangan buah. Pada fase awal atau buah mentah, TBS menunjukkan warna hitam kemerahan dengan permukaan yang relatif

halus. Seiring berjalannya proses pematangan, warna buah berangsur berubah menjadi kemerahan pada fase mengkal, yang menandakan mulai meningkatnya kandungan minyak dalam buah.

Ketika TBS mencapai fase kematangan optimal, warna buah berubah menjadi jingga kemerahan yang cerah dan merata. Menyatakan bahwa pada fase ini, intensitas warna jingga kemerahan berkorelasi kuat dengan kandungan minyak yang optimal, yaitu lebih dari 25%. Lebih lanjut, menambahkan bahwa buah yang telah memasuki fase lewat matang akan menunjukkan warna jingga kekuningan, yang sering kali disertai dengan peningkatan jumlah brondolan yang lepas dari tandannya seperti pada



Gambar 1.2 Perubahan warna TBS kelapa sawit

2.3 Pengolahan Citra Digital

Pengolahan citra digital merupakan sebuah disiplin ilmu yang berfokus pada manipulasi dan analisis gambar menggunakan teknologi komputer. Pengolahan citra digital melibatkan serangkaian proses transformasi citra input menjadi citra output atau informasi yang dapat diinterpretasikan, baik oleh manusia maupun mesin. Proses ini dimulai dengan akuisisi citra menggunakan perangkat digital seperti kamera atau scanner, yang mengubah informasi optik menjadi sinyal digital yang dapat diproses oleh komputer.

Dalam konteks pemrosesan menjelaskan bahwa citra digital direpresentasikan sebagai matriks dua dimensi yang terdiri dari pixel-pixel, dimana setiap pixel membawa informasi intensitas warna. Pada citra berwarna, setiap pixel umumnya direpresentasikan dalam ruang warna tertentu seperti RGB (Red, Green, Blue), HSV (Hue, Saturation, Value), atau model warna lainnya yang sesuai dengan kebutuhan analisis. Informasi warna ini menjadi dasar untuk berbagai operasi pengolahan citra seperti perbaikan kualitas gambar, segmentasi, deteksi tepi, dan pengenalan pola [5].

Pengolahan citra digital melibatkan berbagai teknik preprocessing untuk meningkatkan kualitas citra sebelum dilakukan analisis lebih lanjut. Teknik- teknik ini mencakup operasi perbaikan kontras, filtering untuk mengurangi noise, normalisasi intensitas, dan transformasi geometrik. Setelah preprocessing, citra dapat dianalisis menggunakan berbagai metode seperti segmentasi untuk memisahkan objek dari latar belakangnya, ekstraksi fitur untuk mengidentifikasi karakteristik penting dalam citra, dan klasifikasi untuk mengelompokkan objek berdasarkan fitur-fitur yang telah diekstrak.

Dalam konteks deteksi kematangan TBS kelapa sawit, bahwa pengolahan citra digital memainkan peran krusial dalam mengotomatisasi proses grading [6]. Proses ini dimulai dengan akuisisi citra TBS menggunakan kamera digital dalam kondisi pencahayaan yang terkontrol. Selanjutnya, citra tersebut melalui serangkaian tahap preprocessing untuk menstandarisasi kondisi pencahayaan dan menghilangkan noise. Fitur-fitur warna dan tekstur kemudian diekstrak dari citra yang telah dipreprocessing untuk digunakan dalam proses klasifikasi tingkat kematangan.

Sementara itu, menekankan pentingnya pemilihan ruang warna yang tepat dalam analisis kematangan TBS. Penelitian mereka menunjukkan bahwa transformasi dari ruang warna RGB ke HSV dapat memberikan representasi yang lebih robust terhadap variasi pencahayaan, memungkinkan sistem untuk lebih akurat dalam mengidentifikasi tingkat kematangan berdasarkan karakteristik warna buah. Kombinasi antara pengolahan citra digital dengan algoritma kecerdasan buatan seperti K-Means dan Self-Organizing Maps (SOM) telah terbukti efektif dalam menghasilkan sistem deteksi kematangan yang lebih akurat dan konsisten dibandingkan dengan metode manual..

2.4 Ekstraksi Ciri Citra

Ekstraksi ciri citra merupakan tahapan fundamental dalam pengolahan citra digital yang bertujuan untuk mengidentifikasi dan mengukur karakteristik atau fitur penting dari sebuah citra. Menurut Nixon & Aguado (2019), ekstraksi ciri adalah proses mengubah data citra mentah menjadi sekumpulan nilai numerik atau vektor fitur yang merepresentasikan karakteristik spesifik dari citra tersebut.

Proses ini menjadi jembatan penting antara tahap preprocessing dan klasifikasi dalam sistem pengenalan pola berbasis citra.

Dalam konteks analisis citra menjelaskan bahwa ciri atau fitur dapat dikategorikan menjadi beberapa kelompok utama berdasarkan karakteristik yang diukur. Fitur warna menjadi salah satu karakteristik yang paling mendasar dan sering digunakan, dimana distribusi dan statistik warna dalam berbagai ruang warna seperti RGB, HSV, atau Lab* dapat memberikan informasi diskriminatif tentang objek dalam citra. Histogram warna, momen warna, dan color coherence vector merupakan beberapa metode yang umum digunakan untuk mengekstrak informasi warna dari citra [7].

Sementara itu, analisis tekstur menawarkan cara untuk mengkarakterisasi pola intensitas lokal dan susunan piksel dalam citra, bahwa metode ekstraksi fitur tekstur dapat dibagi menjadi pendekatan statistik, struktural, dan spektral. Gray Level Co-occurrence Matrix (GLCM) merupakan salah satu metode statistik yang populer, yang menghasilkan berbagai statistik tekstur seperti kontras, korelasi, energi, dan homogenitas. Filter Gabor dan transformasi wavelet mewakili pendekatan spektral yang dapat menangkap informasi tekstur pada berbagai skala dan orientasi.

Dalam aplikasi deteksi kematangan TBS kelapa sawit, Kombinasi fitur warna dan tekstur memberikan hasil yang lebih robust dibandingkan penggunaan satu jenis fitur saja. Mereka menggunakan transformasi ruang warna HSV untuk mengekstrak fitur warna karena keunggulannya dalam memisahkan informasi intensitas (Value) dari informasi kromatik (Hue dan Saturation). Fitur tekstur dari GLCM kemudian digunakan untuk mengkarakterisasi perubahan tekstur permukaan buah yang terjadi selama proses pematangan, menambahkan bahwa selain warna dan tekstur, fitur bentuk dan morfologi juga dapat memberikan informasi penting dalam analisis citra TBS. Fitur bentuk dapat diukur melalui berbagai deskriptor seperti area, perimeter, kompaksi, dan momen invarian. Namun, ekstraksi fitur bentuk seringkali memerlukan segmentasi yang akurat, yang dapat menjadi tantangan tersendiri dalam kondisi pencahayaan yang bervariasi atau latar belakang yang kompleks. Proses seleksi dan evaluasi fitur menjadi aspek kritis dalam mengoptimalkan kinerja sistem klasifikasi. [8],

pentingnya memilih kombinasi fitur yang tidak hanya diskriminatif tetapi juga komputasional efisien. Teknik seleksi fitur seperti Principal Component Analysis (PCA), Linear Discriminant Analysis (LDA), atau metode wrapper dapat digunakan untuk mengurangi dimensionalitas vektor fitur sambil mempertahankan informasi yang paling relevan untuk tugas klasifikasi.

2.5 K-Means

K-Means adalah salah satu algoritma pembelajaran tidak terawasi (unsupervised learning) yang digunakan untuk melakukan klusterisasi, yaitu proses mengelompokkan data ke dalam beberapa kelompok atau klaster berdasarkan kemiripan antar data. Algoritma ini berusaha membagi dataset menjadi sejumlah klaster yang sudah ditentukan sebelumnya, dengan tujuan agar data dalam satu klaster memiliki kemiripan tinggi satu sama lain, dan kemiripan antar klaster serendah mungkin. K-Means bekerja dengan cara meminimalkan jarak antara data dalam klaster dengan pusat klaster (centroid), yang dihitung sebagai rata-rata posisi semua data dalam klaster tersebut. Proses K-Means dimulai dengan memilih jumlah klaster (K) yang diinginkan, yang merupakan input dari pengguna. Selanjutnya, K-Means secara acak memilih K titik sebagai centroid awal untuk setiap klaster. Setelah itu, setiap data dalam dataset akan dipetakan ke klaster yang centroid-nya paling dekat. Proses ini dilakukan dengan menghitung jarak, biasanya menggunakan rumus Euclidean, antara data dan masing-masing centroid. Setelah setiap data dikelompokkan, centroid untuk setiap klaster dihitung ulang sebagai rata-rata posisi semua data dalam klaster tersebut. Proses ini diulang beberapa kali, dengan data terus dipetakan ulang ke klaster terdekat dan centroid dihitung ulang, hingga konvergensi tercapai—yaitu, ketika posisi centroid tidak lagi berubah secara signifikan atau jumlah iterasi yang telah ditentukan tercapai [9].

Salah satu tantangan utama dalam K-Means adalah pemilihan jumlah klaster (K) yang optimal. Pemilihan nilai K yang salah dapat menyebabkan klaster yang tidak representatif atau kurang informatif. Untuk menentukan nilai K yang tepat, biasanya digunakan teknik seperti metode Elbow, yang menganalisis bagaimana jumlah total kesalahan kuadrat (sum of squared errors) berkurang saat K bertambah. Namun, tidak ada cara yang pasti untuk memilih K , dan sering kali

memerlukan eksperimen dan pemahaman domain untuk mendapatkan hasil yang terbaik.

K-Means memiliki kelebihan, seperti kesederhanaannya dan efisiensi dalam memproses dataset besar. Namun, algoritma ini juga memiliki keterbatasan, seperti ketergantungan pada pemilihan centroid awal yang acak, yang bisa mengarah pada hasil yang berbeda-beda untuk percakapan yang sama. K-Means juga kurang efektif untuk dataset dengan bentuk vektor yang tidak berbentuk bulat atau tidak terpisah dengan jelas. Selain itu, K-Means sensitif terhadap adanya outlier, karena outlier dapat mempengaruhi posisi centroid secara signifikan. Secara keseluruhan, K-Means merupakan algoritma yang sangat populer dalam klusterisasi, digunakan di berbagai bidang seperti segmentasi pasar, analisis citra, dan pengelompokan data dalam pembelajaran mesin. K-Means dapat digunakan dalam deteksi kematangan tandan buah segar kelapa sawit berbasis citra digital dengan cara mengelompokkan piksel-piksel citra ke dalam kluster-kluster yang merepresentasikan tingkatan kematangan tandan buah. Dalam konteks ini, citra digital dari tandan buah segar kelapa sawit diambil dengan menggunakan kamera atau perangkat pemindai, dan kemudian dianalisis menggunakan algoritma K-Means untuk membagi citra tersebut menjadi beberapa kluster berdasarkan karakteristik warna atau intensitas yang terkait dengan kematangan buah.

Proses pertama dalam penerapan K-Means untuk deteksi kematangan tandan buah segar kelapa sawit adalah pengumpulan citra digital dari tandan buah tersebut. Citra ini kemudian diproses untuk menghilangkan noise atau gangguan lain yang tidak relevan, menggunakan teknik pengolahan citra seperti pemfilteran. Selanjutnya, algoritma K-Means diterapkan untuk mengelompokkan piksel dalam citra berdasarkan intensitas warna atau komponen warna yang berbeda, seperti merah, hijau, dan biru (RGB) atau komponen warna lainnya seperti hue, saturation, dan value (HSV), yang dianggap dapat menggambarkan perubahan warna yang terjadi selama proses pematangan buah. Misalnya, dalam deteksi kematangan kelapa sawit, biasanya buah yang sudah matang akan menunjukkan perubahan warna, seperti warna kuning keoranye-an atau merah, sedangkan buah yang belum matang cenderung memiliki warna hijau atau lebih muda [10]. Dengan menggunakan K-Means, citra kelapa sawit dapat dikelompokkan ke dalam

beberapa klaster yang merepresentasikan tingkat kematangan buah tersebut, seperti klaster untuk buah yang masih muda, buah yang setengah matang, dan buah yang sudah matang. Proses ini dilakukan dengan memilih sejumlah klaster (K) yang mewakili tingkat kematangan yang berbeda, dan K-Means akan mencari centroid untuk setiap klaster berdasarkan nilai-nilai intensitas warna yang paling relevan untuk tiap kategori kematangan. Setelah proses klasterisasi, analisis lebih lanjut dapat dilakukan untuk mengidentifikasi kategori kematangan dengan mengamati klaster mana yang memiliki nilai warna atau intensitas yang paling sesuai dengan kriteria kematangan yang telah ditentukan. Misalnya, klaster dengan warna kuning atau oranye dapat diidentifikasi sebagai buah yang matang, sementara klaster dengan warna hijau atau lebih pucat mungkin menunjukkan buah yang belum matang.

Salah satu kelebihan penggunaan K-Means untuk deteksi kematangan tandan buah segar kelapa sawit adalah kemampuannya untuk secara otomatis mengelompokkan piksel berdasarkan karakteristik visual yang konsisten dalam citra, sehingga memungkinkan deteksi kematangan secara efisien tanpa memerlukan pengukuran manual atau subjektif. Namun, tantangan dalam penerapan K-Means untuk tugas ini meliputi pemilihan jumlah klaster yang tepat (K) dan kemungkinan terjadinya kesalahan dalam pengelompokan jika data citra memiliki variasi besar dalam pencahayaan atau kondisi gambar. Dalam praktiknya, deteksi kematangan tandan buah segar kelapa sawit berbasis citra digital dengan K-Means dapat membantu dalam proses pemanenan, memastikan bahwa hanya buah yang sudah mencapai tingkat kematangan optimal yang dipanen untuk menghasilkan minyak sawit dengan kualitas terbaik.

2.6 Self Organizing Maps

Pemetaan data ke dalam bentuk grid dua dimensi yang lebih mudah dipahami, sambil menjaga hubungan dan struktur asli dari data tersebut. SOM dikembangkan oleh Teuvo Kohonen pada 1980-an dan merupakan jenis jaringan syaraf tiruan yang memungkinkan analisis dan visualisasi data yang kompleks dengan cara yang lebih intuitif. Tujuan utama dari SOM adalah untuk mengelompokkan data input ke dalam klaster-klaster yang lebih terstruktur, di

mana data dengan kemiripan yang tinggi akan dipetakan ke area yang berdekatan di dalam peta dua dimensi.

Proses pelatihan SOM dimulai dengan memetakan data input, yang biasanya berupa vektor fitur dengan dimensi tinggi, ke dalam peta dua dimensi, yang terdiri dari neuron-neuron yang saling terhubung dalam grid. Setiap neuron pada peta memiliki bobot atau vektor fitur yang terkait dengannya. Pada awal pelatihan, bobot neuron diinisialisasi secara acak, dan data input akan dipresentasikan ke jaringan satu per satu. Setiap kali data input diberikan, neuron yang paling mirip dengan data tersebut, yang disebut sebagai neuron pemenang (winner neuron), akan ditentukan dengan menghitung jarak antara data input dan bobot neuron, biasanya menggunakan jarak Euclidean.

Setelah neuron pemenang ditentukan, bobot dari neuron pemenang dan neuron-neuron yang ada di sekitarnya akan diperbarui untuk lebih mendekati data input. Proses pembaruan bobot ini dilakukan dengan menggunakan aturan pembelajaran yang mengurangi jarak antara bobot neuron dan data input seiring dengan berjalannya waktu. Area sekitar neuron pemenang yang juga mengalami pembaruan bobot ini disebut sebagai jangkauan atau neighborhood, yang akan mengecil secara bertahap dalam iterasi selanjutnya. Tujuan dari pembaruan ini adalah agar neuron yang terletak dekat dengan neuron pemenang juga belajar untuk mewakili pola data yang serupa. Seiring berjalannya waktu dan iterasi, peta akan beradaptasi dan membentuk representasi yang lebih terstruktur dari data input, dengan data yang mirip dikelompokkan dalam area yang sama atau berdekatan di peta. Salah satu keunggulan SOM adalah kemampuannya untuk mengurangi dimensi data yang kompleks menjadi dimensi yang lebih sederhana dan mudah dianalisis, yang memungkinkan visualisasi yang lebih baik dari data dan pola yang mungkin sulit terlihat dalam ruang fitur berdimensi tinggi. SOM sering digunakan dalam berbagai aplikasi, termasuk pengenalan pola, pemrosesan citra, analisis data besar, dan visualisasi data. Misalnya, dalam analisis citra, SOM dapat digunakan untuk mengelompokkan gambar atau piksel berdasarkan karakteristik warna atau tekstur, sementara dalam analisis data, SOM bisa digunakan untuk segmentasi pasar atau klusterisasi data berdasarkan fitur-fitur yang relevan. Meskipun SOM efektif dalam banyak kasus, tantangan yang dihadapi oleh SOM meliputi pemilihan

ukuran peta yang tepat dan jumlah iterasi yang cukup untuk memastikan konvergensi yang baik.

Self Organizing Map (SOM) diterapkan dalam deteksi kematangan tandan buah segar kelapa sawit berbasis citra digital untuk mengelompokkan citra berdasarkan tingkat kematangan buah. SOM adalah algoritma pembelajaran tidak terawasi yang sangat efektif dalam mengidentifikasi pola dan struktur tersembunyi dalam data yang kompleks. Dalam konteks deteksi kematangan kelapa sawit, SOM digunakan untuk menganalisis citra buah kelapa sawit dan mengelompokkannya menjadi beberapa kategori yang mewakili tingkat kematangan, berdasarkan karakteristik visual yang terdapat dalam citra, seperti warna, tekstur, dan bentuk.

Proses pertama dalam menggunakan SOM untuk deteksi kematangan tandan buah kelapa sawit dimulai dengan pengambilan citra digital dari tandan buah kelapa sawit menggunakan kamera atau perangkat pemindai. Citra yang diambil kemudian diproses untuk mengekstraksi fitur-fitur penting yang dapat membedakan tingkat kematangan, seperti informasi warna (misalnya, perubahan warna dari hijau ke kuning atau oranye) dan tekstur permukaan buah. Fitur-fitur ini akan dikodekan dalam bentuk vektor data, yang kemudian dimasukkan ke dalam jaringan SOM.

SOM akan mengelompokkan vektor-vektor fitur ini ke dalam grid dua dimensi, di mana setiap neuron pada grid tersebut mewakili sekumpulan fitur yang memiliki kemiripan tinggi. Selama proses pelatihan, data citra akan dipresentasikan secara berulang, dan neuron-neuron dalam grid akan diperbarui untuk merepresentasikan pola atau karakteristik dari data input. Neuron yang paling mirip dengan data citra yang diberikan akan menjadi “neuron pemenang”, dan bobot neuron tersebut serta neuron-neuron sekitarnya akan diperbarui untuk lebih mendekati pola data yang baru. Dengan berjalannya waktu, peta SOM akan terbentuk, di mana klaster-klaster yang terbentuk mewakili berbagai tingkat kematangan buah kelapa sawit. Misalnya, area dalam peta yang memiliki warna lebih hijau dan tekstur lebih halus dapat menunjukkan buah yang belum matang, sedangkan area dengan warna kuning, oranye, atau merah dapat menunjukkan buah yang sudah matang. Proses ini memungkinkan pemisahan tingkat kematangan buah kelapa sawit berdasarkan citra visualnya secara otomatis.

Keuntungan utama dari menggunakan SOM untuk deteksi kematangan tandan buah kelapa sawit adalah kemampuannya dalam mengelompokkan data yang kompleks tanpa memerlukan label atau informasi sebelumnya tentang tingkat kematangan buah. Selain itu, SOM juga memungkinkan visualisasi hasil klasterisasi dalam bentuk peta dua dimensi, yang mempermudah pemahaman dan analisis data. Dengan menggunakan SOM, deteksi kematangan buah kelapa sawit dapat dilakukan dengan lebih efisien, akurat, dan dalam waktu yang lebih cepat, dibandingkan dengan metode manual atau berbasis pengukuran fisik lainnya.

2.7 Penelitian Relevan

Berikut penelitian relevan pada penelitian ini antara lain.

1. Wahyuni Eka Sari, Muslimin, Annafi Franz, dan Putu Sugiartawan (2022) dalam penelitian yang berjudul “Deteksi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit Dengan Algoritme K-Means”. Tujuan penelitian ini adalah untuk mengembangkan sistem yang dapat mendeteksi tingkat kematangan tandan buah segar (TBS) kelapa sawit dengan menggunakan algoritme K-Means berdasarkan analisis warna. Penelitian ini berfokus pada kebutuhan petani untuk menentukan kematangan TBS secara akurat, terutama ketika pohon kelapa sawit tinggi dan sulit dijangkau secara manual. Metode penelitian yang digunakan adalah klasterisasi K-Means, di mana data gambar TBS kelapa sawit diambil dari dua perkebunan di Kalimantan Timur dan Kalimantan Utara. Penelitian ini melibatkan pengambilan gambar TBS, ekstraksi ciri citra untuk mendapatkan nilai RGB (Red, Green, Blue), dan klasterisasi data ke dalam empat kategori kematangan yaitu mentah, kurang matang, matang, dan terlalu matang. Penentuan jumlah kluster optimal dilakukan menggunakan metode elbow, yang menunjukkan bahwa jumlah kluster terbaik adalah empat. Data yang digunakan terdiri dari 120 gambar, dengan 80 sebagai data latih dan 40 sebagai data uji. Hasil penelitian menunjukkan bahwa sistem klasterisasi ini memiliki akurasi mencapai 90% dalam mengelompokkan TBS kelapa sawit. Dari total 120 gambar yang diuji, 36 data berhasil diklasifikasikan dengan benar sesuai kategori kematangan yang ditentukan. Temuan ini menunjukkan potensi

besar penggunaan metode K-Means dalam membantu petani menentukan kematangan buah secara cepat dan akurat berdasarkan analisis warna.

2. Rahmat Pidi Putra, Jujum Jumadi, dan Deri Lianda (2024) dalam studi yang berjudul “Pengolahan Citra Digital Untuk Mengidentifikasi Tingkat Kematangan Buah Kelapa Sawit Berdasarkan Warna RGB Dan HSV Dengan Menggunakan Metode Self Organizing Map (SOM)”. Penelitian ini bertujuan untuk mengidentifikasi kematangan buah kelapa sawit menggunakan pengolahan citra digital dengan pendekatan analisis warna RGB (Red, Green, Blue) dan HSV (Hue, Saturation, Value), serta menerapkan metode Self Organizing Map (SOM) untuk klasifikasi. Metode penelitian yang digunakan meliputi pengambilan gambar buah kelapa sawit dengan kamera digital, diolah menggunakan perangkat lunak MATLAB. Data yang diambil kemudian dianalisis dengan metode SOM untuk mengevaluasi perbandingan hasil ekstraksi ciri dari model warna RGB dan HSV. Penelitian ini juga menggunakan beberapa metrik evaluasi kinerja seperti Quantization Error, Silhouette Score, dan Topographic Error untuk mengukur akurasi sistem. Hasil penelitian menunjukkan bahwa sistem berhasil membedakan tingkat kematangan buah kelapa sawit menjadi empat kategori: sangat matang, matang, hampir matang, dan mentah. Akurasi sistem dievaluasi dengan Quantization Error yang lebih rendah pada RGB dibandingkan dengan HSV, serta Silhouette Score yang menunjukkan kemampuan HSV sedikit lebih baik dalam pengelompokan objek. Secara keseluruhan, pendekatan menggunakan RGB lebih efektif dalam merepresentasikan data dalam konteks penelitian ini.
3. Syafriyudin & Novianty (2020) melakukan studi yang berjudul “Implementasi Metode K-Means Clustering untuk Menentukan Tingkat Kematangan Buah Kelapa Sawit”. Tujuan penelitian ini mengembangkan sistem otomatis untuk klasifikasi tingkat kematangan TBS kelapa sawit menggunakan metode K-Means berdasarkan citra digital. Penelitian ini (1) menggunakan kamera digital untuk pengambilan citra TBS, (2) preprocessing citra meliputi resize dan konversi RGB ke HSV, (3) segmentasi menggunakan K-Means dengan 3 cluster, (4) ekstraksi fitur warna dari hasil clustering, (5) dan pengujian dengan 100 sampel TBS. Hasil penelitian menunjukkan tingkat

akurasi mencapai 85% dalam mengelompokkan TBS menjadi 3 kategori (mentah, matang, lewat matang).

4. Hidayat et al. (2021) dalam studi yang berjudul “Perbandingan Algoritma K-Means dan Self-Organizing Maps dalam Klasifikasi Kematangan Kelapa Sawit”. Tujuan penelitian ini membandingkan performa algoritma K-Means dan SOM untuk deteksi kematangan TBS. Penelitian ini menggunakan (1) Dataset 200 citra TBS dari berbagai tingkat kematangan, (2) Preprocessing: normalisasi ukuran dan ekstraksi fitur warna, (3) Implementasi K-Means ($k=3$) dan SOM, (4) Validasi menggunakan confusion matrix. Hasil penelitian menunjukkan K-Means mencapai akurasi 88.5%, SOM mencapai akurasi 86%, K-Means lebih cepat dalam proses clustering.
5. Rahman & Kusuma (2022) dalam studi yang berjudul “Mengembangkan sistem hybrid yang menggabungkan kelebihan K-Means dan SOM”. Penelitian ini bertujuan mengembangkan sistem hybrid yang menggabungkan kelebihan K-Means dan SOM. Penelitian ini menggunakan (1) Preprocessing citra digital, (2) K-Means untuk segmentasi awal, (3) SOM untuk klasifikasi final, (4) Pengujian dengan 150 sampel. Hasil penelitian menunjukkan akurasi sistem hybrid mencapai 91%, waktu komputasi lebih lama dari metode tunggal, lebih robust terhadap variasi pencahayaan.
6. Pratama et al. (2023) dalam studi yang berjudul “Deep Learning vs Traditional Clustering untuk Deteksi Kematangan Kelapa Sawit”. Penelitian ini bertujuan untuk membandingkan metode clustering tradisional (K-Means, SOM) dengan deep learning. Penelitian ini menggunakan (1) Dataset 500 citra TBS, (2) Implementasi K-Means, SOM, dan CNN, (3) Evaluasi performa menggunakan multiple metrics. Hasil penelitian menunjukkan K-Means: akurasi 87%, SOM: akurasi 85%, CNN: akurasi 94%, Metode tradisional lebih efisien untuk dataset kecil.

2.8 Alur Penelitian

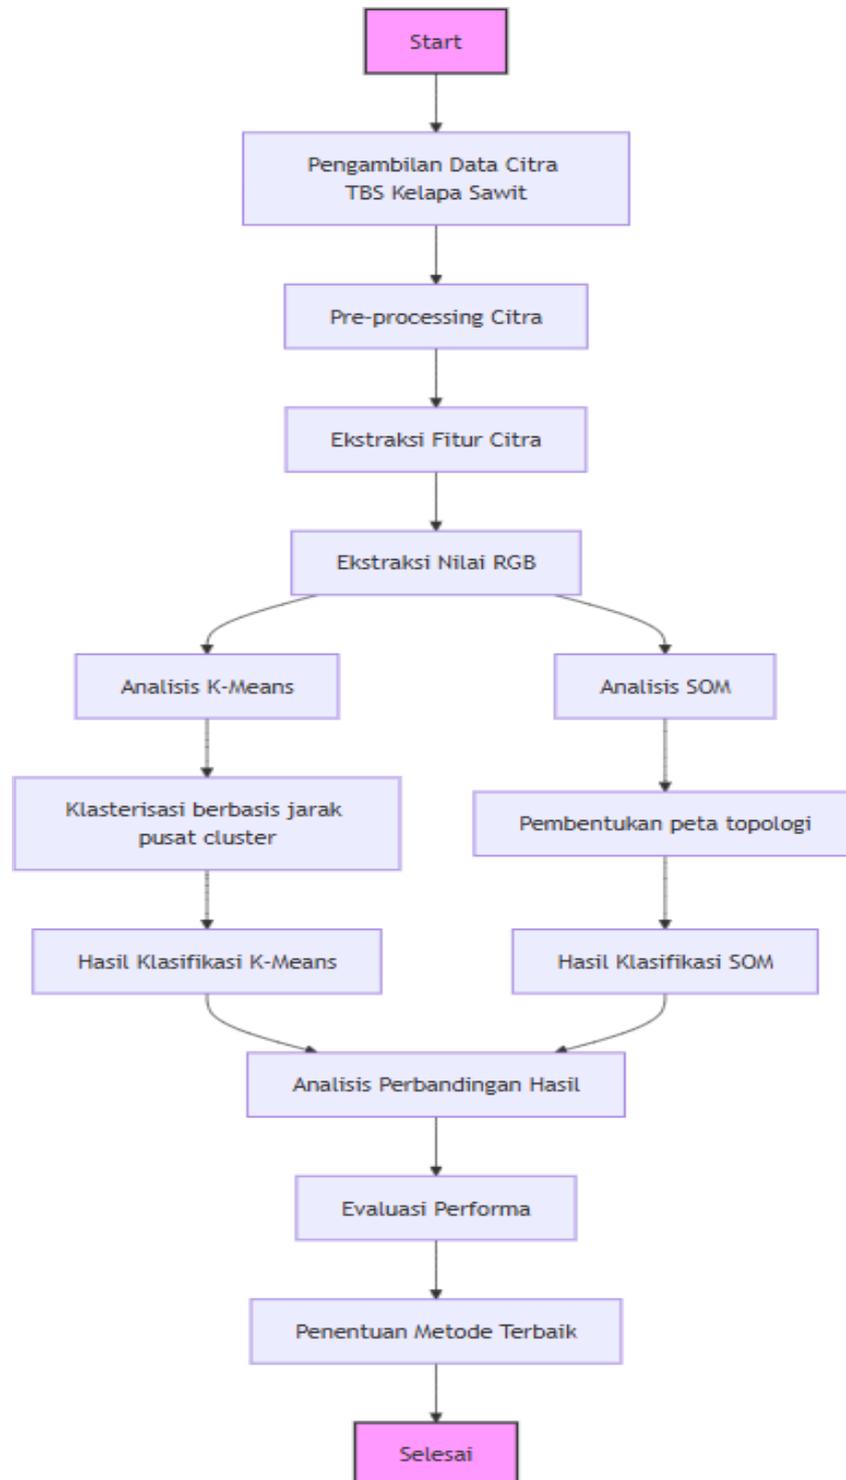
Gambar 3 dijelaskan diagram alir sistem pada proses klasterisasi tingkat kematangan TBS kelapa sawit. Berikut penjelasan detail setiap tahapnya:

1. Tahap Persiapan

- Pengumpulan dataset citra tandan buah segar kelapa sawit

- Pre-processing citra untuk standarisasi ukuran dan kualitas gambar
 - Ekstraksi fitur RGB dari citra untuk mendapatkan nilai-nilai yang akan diproses
2. Pemrosesan dengan K-Means
 - Implementasi algoritma K-Means
 - Melakukan clustering data berdasarkan fitur RGB
 - Menganalisis hasil pengelompokan K-Means
 3. Pemrosesan dengan SOM
 - Implementasi algoritma Self-Organizing Maps
 - Melakukan training jaringan SOM
 - Menganalisis hasil pengolahan SOM
 4. Tahap Evaluasi
 - Membandingkan performa kedua algoritma
 - Menganalisis tingkat akurasi masing-masing metode

- Melakukan validasi hasil deteksi kematangan



Gambar 2.1 Alur Penelitian