

ANALISIS PENGGUNAAN ALGORITMA K-MEANS DAN SELF-ORGANIZING MAPS DALAM SISTEM DETEKSI KEMATANGAN TANDAN BUAH SEGAR KELAPA SAWIT BERBASIS CITRA DIGITAL

Yuza Reswan, Muhfi Syahril, Yulia Darmi, Dedy Abdullah

Teknik Informatika, Universitas Muhammadiyah Bengkulu

Jl. Bali, Kp. Bali, Kec. Tlk. Segara, Kota Bengkulu, Indonesia

yuzareswan@umb.ac.id

ABSTRAK

Skripsi ini bertujuan untuk mengembangkan sistem deteksi kematangan Tandan Buah Segar (TBS) kelapa sawit menggunakan algoritma K-Means untuk segmentasi citra dan SOM untuk klasifikasi tingkat kematangan TBS. K-Means berfungsi untuk mengelompokkan data citra berdasarkan karakteristik warna, sedangkan SOM akan membantu dalam memetakan data ke ruang berdimensi rendah untuk analisis lebih lanjut. Melalui pengolahan citra digital, penelitian ini akan menganalisis perubahan warna pada TBS selama proses pematangan, yang menjadi indikator utama dalam menentukan tingkat kematangan. Diharapkan bahwa sistem yang dikembangkan dapat meningkatkan akurasi deteksi kematangan hingga 92,5% dibandingkan dengan metode konvensional. Selain itu, penelitian ini juga bertujuan untuk memberikan kontribusi signifikan terhadap efisiensi proses produksi minyak sawit dan mengurangi kerugian akibat kesalahan penentuan kematangan yang dapat mempengaruhi rendemen minyak hingga 15-20%. Dengan demikian, penelitian ini tidak hanya berfokus pada aspek teknis, tetapi juga pada dampak praktisnya bagi industri kelapa sawit di Indonesia, mendukung transformasi menuju pertanian modern berbasis teknologi tinggi.

Kata kunci : Deteksi kematangan, Tandan Buah Segar (TBS), K-Means, Self Organizing Map (SOM), Pengolahan, citra digital

1. PENDAHULUAN

Indonesia merupakan negara dengan kontribusi signifikan dalam produksi minyak sawit global, dimana industri kelapa sawit telah menjadi tulang punggung perekonomian nasional sejak beberapa dekade terakhir, total luas perkebunan kelapa sawit mencapai 16,3 juta hektar dengan produksi minyak sawit sebesar 48,2 juta ton per tahun, mengukuhkan posisi Indonesia sebagai produsen terbesar di dunia. Dalam lanskap agroindustri kontemporer, kelapa sawit (*Elaeis guineensis*) telah mengukuhkan diri sebagai salah satu komoditas strategis yang mendefinisikan ekonomi global, terutama di wilayah tropis seperti Indonesia. Kompleksitas ekosistem perkebunan kelapa sawit melampaui sekadar aktivitas budidaya sederhana, melainkan mencerminkan interaksi dinamis antara teknologi pertanian, inovasi berkelanjutan, dan tantangan lingkungan yang semakin kompleks. Proses produksi minyak sawit sesungguhnya merupakan sebuah perjalanan panjang yang dimulai dari tahap kritis penentuan kematangan tandan buah segar (TBS), di mana setiap momen memiliki signifikansi yang mendalam terhadap kualitas dan kuantitas produk akhir. Kompleksitas ini tidak dapat dipahami secara parsial, melainkan memerlukan pendekatan holistik yang mempertimbangkan setiap variabel mikroskopis hingga makroskopis dalam sistem produksi. Sejarah perkembangan industri kelapa sawit di Indonesia mencatat transformasi signifikan dari praktik tradisional menuju sistem pertanian modern berbasis teknologi tinggi. Perkebunan yang semula mengandalkan metode konvensional dengan

ketergantungan penuh pada tenaga manusia kini bergeser menuju paradigma pertanian presisi yang memanfaatkan teknologi computational imaging dan kecerdasan buatan. Pergeseran ini bukan sekadar tren teknologis, melainkan respons strategis terhadap kebutuhan efisiensi, produktivitas, dan keberlanjutan [1].

Kompleksitas produksi minyak sawit sangat bergantung pada proses kritis penentuan kematangan tandan buah segar (TBS), dimana setiap tahapan kematangan memiliki karakteristik fisik dan kimia yang unik. Pusat Penelitian Kelapa Sawit menunjukkan bahwa variasi tingkat kematangan dapat mempengaruhi rendemen minyak hingga 15-20% dan kualitas minyak yang dihasilkan. Metode konvensional penentuan kematangan TBS yang masih mengandalkan penilaian visual manual memiliki tingkat kesalahan yang signifikan, berkisar antara 25-35% [2].

Perkembangan teknologi pengolahan citra digital dan kecerdasan buatan membuka peluang transformatif dalam mengatasi keterbatasan metode tradisional. Algoritma machine learning seperti K-Means dan Self-Organizing Maps (SOM) muncul sebagai solusi inovatif yang menawarkan pendekatan revolusioner dalam mengeksplorasi kompleksitas visual TBS. Penelitian mengungkapkan bahwa integrasi algoritma kecerdasan buatan dapat meningkatkan akurasi deteksi kematangan hingga 92,5% dibandingkan metode konvensional. Implementasi teknologi serupa di Malaysia dan Thailand telah menunjukkan peningkatan efisiensi panen sebesar 40% dan pengurangan kerugian pasca

panen hingga 35%. Kedua algoritma ini tidak sekadar tools matematis, melainkan representasi canggih dari kemampuan komputasi modern untuk mengurai dan memahami pola-pola tersembunyi yang tidak dapat ditangkap oleh pengamatan manusia.

K-Means, dengan mekanisme clustering-nya, mampu melakukan segmentasi citra dengan memecah ruang warna menjadi kelompok-kelompok yang memiliki karakteristik homogen. Algoritma ini beroperasi dengan cara membagi data ke dalam sejumlah kelompok berdasarkan kedekatan karakteristik, memungkinkan identifikasi zona-zona spesifik dalam citra TBS yang memiliki signifikansi terhadap tingkat kematangan. Sementara itu, Self-Organizing Maps (SOM) unggul dalam menangkap pola non-linear yang kompleks serta memetakan data ke ruang berdimensi rendah, sehingga memudahkan analisis kombinasi kedua algoritma ini dapat menghasilkan sistem deteksi kematangan TBS yang efisien, akurat, dan mudah diimplementasikan pada skala industri [3].

Dengan demikian, penelitian ini bertujuan untuk menganalisis penggunaan algoritma K-Means dan SOM dalam sistem deteksi kematangan TBS berbasis citra digital, yang diharapkan dapat memberikan kontribusi signifikan dalam mengoptimalkan proses produksi minyak sawit melalui pendekatan teknologi komputasional yang inovatif. Urgensi penelitian ini semakin diperkuat dengan proyeksi pertumbuhan industri kelapa sawit global yang diperkirakan mencapai USD 92,84 miliar pada tahun 2027, menciptakan kebutuhan mendesak akan solusi teknologi yang dapat meningkatkan efisiensi dan akurasi dalam setiap tahap produksi.

2. TINJAUAN PUSTAKA

2.1. 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. 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 2. Perubahan warna TBS kelapa sawit

2.2. 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.

2.3. 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.

2.4. 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 kluster 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 kluster dihitung ulang sebagai rata-rata posisi semua data dalam kluster tersebut. Proses ini diulang beberapa kali, dengan data terus dipetakan ulang ke kluster 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 kluster (K) yang optimal. Pemilihan nilai K yang salah dapat menyebabkan kluster 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 ector 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 keoranyean 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 kluster yang merepresentasikan tingkat kematangan buah tersebut, seperti kluster untuk buah yang masih muda, buah yang setengah matang, dan buah yang sudah matang. Proses ini dilakukan dengan memilih sejumlah kluster (K) yang mewakili tingkat kematangan yang berbeda, dan K-Means akan mencari centroid untuk setiap kluster berdasarkan nilai-nilai intensitas warna yang paling relevan untuk tiap kategori kematangan. Setelah proses klusterisasi, analisis lebih lanjut dapat dilakukan untuk mengidentifikasi kategori kematangan dengan mengamati kluster mana yang memiliki nilai warna atau intensitas yang paling sesuai dengan kriteria kematangan yang telah ditentukan. Misalnya, kluster dengan warna kuning atau oranye dapat diidentifikasi sebagai buah yang matang, sementara kluster 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 kluster 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.

2.5. Self Organizing Maps

Self Organizing Map (SOM) adalah algoritma pembelajaran tidak terawasi yang digunakan untuk 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 klasterisasi 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.

3. METODE PENELITIAN

3.1. Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimen untuk menganalisis penggunaan algoritma K-Means dan Self-Organizing Maps (SOM) dalam sistem deteksi kematangan Tandan Buah Segar (TBS) kelapa sawit berbasis citra digital. Metode ini dipilih untuk memungkinkan pengukuran yang objektif terhadap

akurasi dan efektivitas kedua algoritma dalam mengidentifikasi tingkat kematangan TBS. Proses penelitian dilakukan melalui beberapa tahapan yang meliputi pengumpulan data, pengolahan citra, penerapan algoritma, dan analisis hasil.

3.2. Populasi Sampel

Populasi dalam penelitian ini adalah seluruh TBS kelapa sawit yang dihasilkan dari perkebunan PT. ALNO AGRO UTAMA, SUMINDO ESTATE yang berlokasi di Bengkulu Utara, Provinsi Bengkulu. Sampel diambil secara acak dari beberapa lokasi perkebunan untuk memastikan representativitas data. Jumlah sampel yang digunakan dalam penelitian ini adalah 300 TBS, yang dibagi menjadi tiga kategori kematangan: mentah, mengkal, dan matang. Kategori ini ditentukan berdasarkan standar visual yang telah ditetapkan oleh ahli pertanian.

3.3. Penerapan Algoritma

a. Algoritma K-Means

Algoritma K-Means diterapkan untuk melakukan clustering pada data fitur yang telah diekstraksi. Proses clustering dimulai dengan menentukan jumlah cluster k yang sesuai, di mana setiap cluster merepresentasikan kategori kematangan TBS. Langkah-langkahnya meliputi:

- Inisialisasi:** Memilih k centroid awal secara acak dari dataset.
- Clustering:** Menghitung jarak setiap titik data ke centroid dan mengelompokkan titik-titik tersebut ke dalam cluster terdekat.
- Update Centroid:** Menghitung ulang posisi centroid berdasarkan rata-rata titik dalam setiap cluster.
- Iterasi:** Mengulangi langkah clustering dan update centroid hingga konvergensi tercapai (ketika tidak ada perubahan signifikan pada posisi centroid).
- Self-Organizing Maps (SOM)**
SOM digunakan untuk memetakan data ke ruang berdimensi rendah sambil mempertahankan hubungan topologis antar data.

Proses penerapan SOM meliputi:

- Inisialisasi Jaringan:** Menentukan ukuran peta dan inisialisasi bobot neuron secara acak.
- Proses Pembelajaran:** Menggunakan algoritma pembelajaran kompetitif, di mana setiap input dibandingkan dengan bobot neuron untuk menemukan neuron terdekat (Best Matching Unit).
- Update Bobot:** Bobot neuron diperbarui berdasarkan jarak ke input dan faktor pembelajaran.
- Iterasi:** Proses ini diulang selama sejumlah iterasi hingga bobot stabil.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Penelitian

Pada bab ini akan dibahas mengenai hasil penelitian setelah melakukan analisis terhadap penerapan algoritma K-Means dan Self-Organizing Maps (SOM) dalam sistem deteksi kematangan Tandan Buah Segar (TBS) kelapa sawit berbasis citra digital. Penelitian ini berakhir dengan melakukan proses pengolahan citra digital dan penerapan algoritma machine learning untuk mengelompokkan tingkat kematangan TBS. Hasil yang dicapai oleh penulis menunjukkan bahwa pendekatan berbasis K-Means dan SOM mampu meningkatkan akurasi deteksi kematangan dibandingkan dengan metode konvensional berbasis penilaian visual.

Implementasi metode ini dilakukan menggunakan bahasa pemrograman Python, dengan tahapan pengolahan citra, seperti preprocessing. Hasil yang diperoleh dari penelitian ini memberikan gambaran mengenai efektivitas kedua algoritma dalam mendeteksi tingkat kematangan TBS serta potensi penerapannya dalam industri kelapa sawit untuk mengoptimalkan proses produksi dan meningkatkan efisiensi panen.

4.2. Dataset Penelitian

Pada penelitian ini digunakan dataset citra Tandan Buah Segar (TBS) kelapa sawit yang diperoleh dari hasil pengambilan gambar di perkebunan kelapa sawit. Dataset ini terdiri dari citra TBS dengan berbagai tingkat kematangan, yang dikategorikan berdasarkan karakteristik warna dan tekstur. Dataset yang digunakan mencakup jumlah citra sebanyak 150 citra gambar, dengan variasi tingkat kematangan dari mentah, mengkal, hingga masak. Data ini digunakan sebagai input dalam proses segmentasi menggunakan algoritma K-Means dan klasifikasi menggunakan Self-Organizing Maps (SOM). Selain itu, untuk mengevaluasi akurasi sistem, dataset juga dibandingkan dengan penilaian manual oleh ahli perkebunan, sehingga memungkinkan perbandingan antara metode berbasis kecerdasan buatan dengan metode konvensional. Adapun isi dari dataset tersebut tampak seperti tabel 1 dan gambar 3

Tabel 1. Isi dataset

Nama Kelompok	Banyak Gambar
Sampel Buah Sawit Masak	50
Sampel Buah Sawit Mengkal	50
Sampel Buah Sawit Mentah	50

4.3. Tampilan Layar

Bagian "Tampilkan Layar" menyajikan tampilan antarmuka dari sistem yang telah dikembangkan untuk mendeteksi kematangan Tandan Buah Segar (TBS) kelapa sawit menggunakan algoritma K-Means dan Self-Organizing Maps (SOM). Setiap layar menunjukkan berbagai fitur utama sistem, mulai dari menu login, menu utama, preprocessing data, proses clustering, hingga hasil pengelompokan. Tampilan ini

memberikan gambaran visual tentang bagaimana pengguna berinteraksi dengan sistem serta kemudahan navigasi dalam mengoperasikan setiap fitur yang tersedia.

4.4. Tangkapan Layar K-Means Clustering

Tampilan layar K-Means Clustering menampilkan tombol "Process", yang berfungsi untuk memulai proses klusterisasi dataset menggunakan algoritma K-Means. Setelah tombol ditekan, sistem akan mengelompokkan gambar ke dalam beberapa cluster berdasarkan fitur yang telah diekstraksi. Proses ini akan menampilkan hasil pengelompokan serta memberikan notifikasi saat clustering selesai.



Gambar 3. Tampilan halaman K-Means clustering

4.5. Tangkapan Layar Result K-Means Clustering


Tampilan layar Result K-Means Clustering berfungsi untuk menampilkan hasil dari proses klusterisasi menggunakan algoritma K-Means. Halaman ini menyajikan informasi mengenai jumlah gambar yang tergabung dalam setiap cluster, serta dilengkapi dengan file manager yang memudahkan pengguna dalam menavigasi dan mengevaluasi hasil clustering secara lebih intuitif.



Gambar 4. Tampilan halaman result K-Means clustering

4.6. Tangkapan layar SOM Clustering

Tampilan layar SOM Clustering menyediakan tombol "Process" yang berfungsi untuk memulai proses klusterisasi dataset menggunakan algoritma Self-Organizing Maps (SOM). Halaman ini dirancang untuk memudahkan pengguna dalam menjalankan proses clustering secara efisien dengan sekali klik.



Gambar 5. Tampilan halaman SOM clustering

4.7. Tangkapan Layar Result SOM Clustering

Tampilan layar Result SOM Clustering berfungsi untuk menampilkan hasil proses klusterisasi menggunakan algoritma Self-Organizing Maps (SOM). Halaman ini menampilkan jumlah gambar yang termasuk dalam setiap cluster, sehingga pengguna dapat melihat distribusi hasil clustering secara jelas. Selain itu, tersedia file manager yang memudahkan pengguna dalam menavigasi dan mengelola hasil clustering SOM.



Gambar 6. Tampilan halaman result SOM clustering

4.8. Tangkapan layar Evaluasi K-Means


Tampilan layar Evaluasi K-Means menampilkan distribusi kategori Mengkal, Masak, dan Mentah dalam masing-masing cluster hasil proses K-Means, yaitu cluster_1, cluster_2, dan cluster_3. Karena K-Means merupakan metode unsupervised learning, algoritma ini tidak secara langsung mengetahui label setiap cluster. Oleh karena itu, evaluasi ini bertujuan untuk menganalisis hasil clustering dengan mencocokkan distribusi kategori berdasarkan karakteristik citra dalam tiap cluster.



Gambar 7. Tampilan Evaluasi K-Means clustering

4.9. Tangkapan layar evaluasi SOM

Tampilan layar Evaluasi SOM menampilkan distribusi kategori Mengkal, Masak, dan Mentah dalam masing-masing cluster hasil proses Self-Organizing Maps (SOM), yaitu cluster_1, cluster_2, dan cluster_3. Karena SOM juga merupakan metode unsupervised learning, sistem tidak secara langsung mengetahui label tiap cluster. Oleh karena itu, evaluasi ini bertujuan untuk menganalisis hasil clustering dengan mencocokkan distribusi kategori berdasarkan pola dan karakteristik citra dalam setiap cluster yang telah dibentuk.



Gambar 8. Tampilan Evaluasi SOM

5. KESIMPULAN DAN SARAN

Berdasarkan hasil analisis penggunaan algoritma K-Means dan Self-Organizing Maps (SOM) dalam sistem deteksi kematangan tandan buah segar (TBS) kelapa sawit berbasis citra digital, dapat disimpulkan bahwa kedua algoritma memiliki keunggulan masing-masing dalam proses pengelompokan dan klasifikasi tingkat kematangan. Algoritma K-Means lebih unggul dalam kecepatan komputasi dan kemudahan implementasi, sedangkan Self-Organizing Maps menunjukkan keunggulan dalam mengidentifikasi pola kompleks dengan tingkat akurasi yang lebih baik. Integrasi kedua metode ini dapat meningkatkan efektivitas sistem dalam mendeteksi kematangan TBS secara otomatis, yang berpotensi meningkatkan efisiensi dalam industri kelapa sawit.

DAFTAR PUSTAKA

- [1] N. Putu *et al.*, "KETEPATAN KLASIFIKASI PENERIMA BEASISWA STIMIK STIKOM BALI DENGAN HYBRID SELF ORGANIZING MAPS DAN ALGORITMA K-MEANS Abstrak Data mining adalah penemuan informasi baru dengan mencari pola atau aturan tertentu dari sejumlah data yang sangat besar . Salah sa," *J. Varian*, vol. 2, no. 1, pp. 10–15, 2017.
- [2] E. F. Himmah, M. Widyaningsih, and M. Maysaroh, "Identifikasi Kematangan Buah Kelapa Sawit Berdasarkan Warna RGB Dan HSV Menggunakan Metode K-Means Clustering," *J. Sains dan Inform.*, vol. 6, no. 2, pp. 193–202, 2020.
- [3] Ardi Wijaya, B. R. Daryono, Rozali Toyib, and Yovi Apridiansyah, "Analisis Pengenalan Pola Pada Citra Digital Untuk Prediksi Berat Buah Sawit," *Decod. J. Pendidik. Teknol. Inf.*, vol. 4, no. 3, pp. 713–724, 2024.
- [4] R. Triyogi, R. Magdalena, and B. Hidayat, "Mendeteksi Kematangan Buah Kelapa Sawit Menggunakan Convolution Neural Network Deep Learning," *J. Nas. SAINS dan Tek.*, vol. 1, no. 1, pp. 22–27, 2023.
- [5] W. E. Sari, M. Muslimin, A. Franz, and P. Sugiartawan, "Deteksi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit dengan Algoritme K-Means," *SINTECH (Science Inf. Technol. J.)*, vol. 5, no. 2, pp. 154–164, 2022.
- [6] S. P. Angin, A. Yahya, and A. A. Pasaribu, "Dampak Ancaman Resesi Ekonomi Dunia Terhadap Industri Kelapa Sawit," *Ekonomis J. Ekon. dan Bisnis*, vol. 25, no. 1, 2023.
- [7] P. Fajriyanti nur, Tessy Octavia Mukhti, Nonong Amalita, and Admi Salma, "Implementation of the Self Organizing Maps (SOMS) Method in Grouping Provinces in Indonesia Based on the Number of Crimes by Type of Crime," *UNP J. Stat. Data Sci.*, vol. 3, no. 1, pp. 39–46, 2025.
- [8] A. Ritonga, A. A. Munawar, and I. S. Nasution, "Klasifikasi Kematangan Tandan Buah Segar Kelapa Sawit (*Elaeis guineensis* Jacq) menggunakan Pengolahan Citra Digital," *J. Ilm. Mhs. Pertan.*, vol. 8, no. 3, pp. 437–445, 2023.
- [9] F. Priyulida, H. Situmorang, H. Muharry Yusdarsono, Universitas Sari Mutiara Indonesia, and Universitas Malikulsalleh, "Deteksi Otomatis Kelapa Sawit Menggunakan Jaringan Saraf Tiruan Backpropagation Dan Zoning," vol. 4307, no. 1, pp. 529–533, 2025.
- [10] D. F. Pasaribu, I. S. Damanik, E. Irawan, Suhada, and H. S. Tambunan, "Memanfaatkan Algoritma K-Means Dalam Memetakan Potensi Hasil Produksi Kelapa Sawit PTPN IV Marihat," *BIOS J. Teknol. Inf. dan Rekayasa Komput.*, vol. 2, no. 1, pp. 11–20, 2021.