REKAYASA
Journal of Science and Technology
https://journal.trunojoyo.ac.id/rekayasa

REKAYASA ,19(1): 2026 p. 38-48
ISSN: 0216-9495 (Print)
ISSN: 2502-5325 (Online)

Klasifikasi Kematangan Buah Kelapa Sawit Berdasarkan Fitur Citra Warna Kulit Menggunakan Metode Transformasi Ruang Warna HSV dan K-Nearest Neighbor

Ewa Aji Azhar Nasution[1], Yusuf Ramadhan Nasution[2*]
[1,2] Program Studi Ilmu Komputer, Universitas Islam Negeri Sumatera Utara
*e-mail : ramadhannst@uinsu.ac.id

DOI: https://doi.org/10.21107/rekayasa.v19i1.33679

Submitted March, 3rd 2026, Accepted April, 2nd 2026, Published April, 28th 2026

Abstrak

Penentuan tingkat kematangan Tandan Buah Segar (TBS) kelapa sawit merupakan faktor kritis dalam menjamin kualitas *Crude Palm Oil* (CPO). Metode konvensional yang mengandalkan pengamatan visual manusia seringkali subjektif dan tidak konsisten akibat variasi kondisi lapangan. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi kematangan buah kelapa sawit yang objektif menggunakan ekstraksi fitur warna pada ruang warna HSV (Hue, Saturation, Value) dan algoritma *K-Nearest Neighbor* (KNN). *Dataset* penelitian terdiri dari 180 citra digital yang dibagi menjadi 150 data pelatihan dan 30 data pengujian dengan tiga kelas kematangan yaitu Matang, Setengah Matang, dan Mentah. Proses *preprocessing* meliputi *resizing* citra menjadi 256 × 256 piksel, diikuti ekstraksi fitur RGB dan transformasi ke HSV. Algoritma KNN dikonfigurasi dengan nilai K=3 menggunakan metrik *Euclidean Distance*. Hasil pengujian sistem menunjukkan tingkat akurasi sebesar 90%, dimana 27 dari 30 citra uji berhasil diklasifikasikan dengan benar. Penelitian ini menyimpulkan bahwa kombinasi fitur ruang warna HSV dan algoritma KNN efektif dalam mengklasifikasikan kematangan buah kelapa sawit dan tahan terhadap variasi pencahayaan dibandingkan ruang warna RGB. Sistem ini berpotensi diterapkan sebagai teknologi pendukung keputusan panen presisi di industri perkebunan kelapa sawit.
Kata kunci: Kelapa Sawit, Kematangan Buah, Ruang Warna HSV, K-Nearest Neighbor, Pengolahan Citra Digital

Abstract

Determining the maturity level of Fresh Fruit Bunches (FFB) of oil palm is a critical factor in ensuring Crude Palm Oil (CPO) quality. Conventional methods relying on human visual observation are often subjective and inconsistent due to variations in field conditions. This study aims to develop an objective oil palm fruit maturity classification system using color feature extraction in the HSV (Hue, Saturation, Value) color space and the K-Nearest Neighbor (KNN) algorithm. The research dataset consisted of 180 digital images divided into 150 training data and 30 test data, with three maturity classes: Ripe, Half-Ripe, and Unripe. The preprocessing process included resizing images to 256 × 256 pixels, followed by RGB feature extraction and transformation to HSV. The KNN algorithm was configured with a K value of 3 using the Euclidean Distance metric. System testing results showed an accuracy level of 90%, where 27 out of 30 test images were successfully classified correctly. This study concludes that the combination of HSV color space features and the KNN algorithm is effective in classifying oil palm fruit maturity and is more robust to lighting variations compared to the RGB color space. This system has the potential to be implemented as a precision harvest decision support technology in the oil palm plantation industry.
Keywords: *Oil Palm, Fruit Maturity, HSV Color Space, K-Nearest Neighbor, Digital Image Processing*

© 2026 Authors

PENDAHULUAN

Kelapa sawit (Elaeis guineensis Jacq) merupakan salah satu komoditas perkebunan yang memiliki peran strategis dalam perekonomian Indonesia, terutama sebagai penghasil minyak sawit mentah atau Crude Palm Oil (CPO). Kualitas CPO sangat bergantung pada tingkat kematangan Tandan Buah Segar (TBS) kelapa sawit saat dipanen. Buah yang dipanen terlalu muda (mentah) akan menghasilkan kadar minyak yang rendah, sedangkan

buah yang terlalu matang akan memiliki kadar Asam Lemak Bebas (Free Fatty Acid) yang tinggi, yang menurunkan kualitas minyak (Anjani et al., 2022). Oleh karena itu, ketepatan dalam menentukan tingkat kematangan buah menjadi faktor krusial dalam proses produksi.

Saat ini, proses penyortiran dan penentuan tingkat kematangan buah kelapa sawit di banyak perkebunan masih dilakukan secara manual berdasarkan pengamatan visual manusia (mandor atau pemanen). Metode ini memiliki kelemahan utama, yaitu bersifat subjektif, memakan waktu, dan sangat dipengaruhi oleh kondisi fisik serta pengalaman pekerja. Kesalahan persepsi visual akibat kelelahan atau kondisi pencahayaan yang berubah-ubah di lapangan seringkali menyebabkan kesalahan klasifikasi (Sari et al., 2022).

Untuk mengatasi permasalahan tersebut, pendekatan teknologi berbasis visi komputer (computer vision) dan pengolahan citra digital menjadi solusi yang menjanjikan. Salah satu indikator visual utama kematangan kelapa sawit adalah perubahan warna kulit buah, dari hitam/ungu (mentah) menjadi jingga kemerahan (matang). Namun, penggunaan ruang warna RGB (Red, Green, Blue) dalam analisis warna seringkali tidak konsisten karena sangat sensitif terhadap perubahan intensitas cahaya atau iluminasi (Napitu et al., 2023). Sebagai alternatif, ruang warna HSV (Hue, Saturation, Value) menawarkan representasi yang lebih mirip dengan cara pandang mata manusia dan lebih tahan terhadap variasi pencahayaan karena memisahkan informasi warna (chrominance) dari intensitas cahaya atau luminance (Candra, 2023).

Beberapa penelitian terdahulu telah menerapkan metode kecerdasan buatan untuk klasifikasi buah. Masruroh et al. (2023) menerapkan HSV dan KNN pada buah pepaya dengan akurasi 86,67%. Sementara itu, penelitian lain menggunakan algoritma K-Means pada kelapa sawit, namun masih berbasis fitur RGB yang memiliki bias terhadap cahaya (Sari et al., 2022). Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi kematangan buah kelapa sawit yang lebih handal dengan mengkombinasikan ekstraksi fitur warna HSV dan algoritma klasifikasi K-Nearest Neighbor (KNN). KNN dipilih karena merupakan algoritma non-parametrik yang sederhana namun efektif untuk klasifikasi data berdasarkan kemiripan fitur dengan data latih (Saputra & Oktaviyani, 2023).

Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan teknologi pertanian presisi (smart farming) di Indonesia, khususnya dalam membantu petani dan industri kelapa sawit meningkatkan efisiensi panen dan menjaga kualitas produksi CPO melalui sistem deteksi kematangan yang objektif dan akurat.

METODE PENELITIAN

Pengolahan Citra Digital

Dalam konteks komputasi, citra digital berfungsi sebagai wujud visual dari objek nyata yang telah dikonversi ke format data agar dapat diproses oleh mesin. Struktur dasar citra ini dibangun dari kumpulan titik kecil bernama piksel yang diorganisir secara sistematis dalam bentuk matriks baris dan kolom. Informasi visual pada setiap lokasi spesifik direpresentasikan melalui nilai angka pada piksel tersebut yang menentukan tingkat intensitas cahaya maupun warnanya. (Rohman, 2023). Sementara itu, pengolahan citra digital adalah proses transformasi dan analisis terhadap citra digital menggunakan algoritma tertentu untuk meningkatkan kualitas visual atau mengekstraks informasi penting. Proses ini mencakup berbagai teknik untuk meningkatkan kualitas citra, memperbaiki citra yang rusak, memisahkan objek, hingga menafsirkan isi visual dari citra tersebut (Siregar et al., 2025).

Visi Komputer (*Computer Vision*)

Computer Vision atau visi komputer merupakan bagian dari kecerdasan buatan yang berfungsi untuk mengajarkan komputer memahami, menggali, menangkap, menginterpretasikan, dan memproses informasi penting dari data berupa citra, video dan sumber visual lainnya (Narlan, 2023). Visi komputer dapat dipandang sebagai hasil integrasi antara pengenalan pola dan pengolahan citra (Munawar et al., 2023). Sebagai sebuah disiplin dalam ilmu komputer, bidang ini bertujuan merancang sistem otomatis yang mampu menginterpretasi serta mengambil informasi dari data visual, mencakup gambar maupun video (Supiyandi Supiyandi & Rafif Rasendriya, 2024). Tujuan utama dari visi komputer adalah untuk memungkinkan komputer atau mesin menafsirkan dan memahami dunia nyata visual seperti manusia (Sutisna et al., 2024).

Ruang Warna HSV

Ruang warna HSV terdiri dari tiga layer, yaitu: derajat warna (hue), kandungan cahaya putih (saturation), dan tingkat muda (value). Hue menunjukkan derajat warna dengan interval [0°,360°]. Adapun daftar derajat warna ditunjukkan pada Tabel 1 Kandungan cahaya putih direpresentasikan pada sumbu y seperti yang ditunjukkan pada Gambar 1 Sementara itu, value menunjukkan tingkat kemudaan/kegelapan suatu warna. Semakin tinggi value, maka semakin muda suatu warna. Sebaliknya, semakin rendah warna value, maka semakin gelap suatu warna (Candra, 2023).

Tabel 1. Representasi Hue

Derajat Warna	Representasi Warna
0°/ 360°	Merah
30°	Orange
60°	Kuning
120°	Hijau
180°	Cyan
240°	Biru
300°	Ungu



Gambar 1. Representasi Ruang Warna HSV

Transformasi RGB ke HSV

Ruang warna HSV merupakan turunan dari ruang warna RGB. Oleh karena itu, untuk mendapatkan nilai ruang warna HSV diperlukan proses konversi dari ruang warna RGB menjadi ruang warna HSV (Saputro & Purnamasari, 2022). Untuk melakukan transformasi dari RGB ke HSV, korrdinat-koordinat R, G, dan B yang berurutan seperti merah, hijau, dan biru harus ditentukan terlebih dahulu dalam ruang warna RGB, dengan *max* adalah nilai maksimum dari nilai *red*, *green*, dan *blue*, serta *min* adalah nilai minimum dari nilai *red*, *green*, dan *blue* (Ellif et al., 2021). Sebelum dilakukan konversi, nilai komponen RGB perlu dinormalisasi terlebih dahulu untuk memastikan rentang nilai berada dalam skala [0, 1], sesuai dengan persyaratan algoritma konversi standar. Normalisasi dilakukan dengan membagi setiap nilai komponen RGB (yang umumnya berada dalam rentang [0, 255]) dengan jumlah nilai R, G, dan B, sebagaimana dirumuskan dalam Persamaan 1:

$$r = \frac{R}{255}$$
$$g = \frac{G}{255}$$
$$b = \frac{B}{255} \quad \text{.....(1)}$$

Keterangan:
r, g, b = Nilai RGB yang telah dinormalisasi
R, G, B = Nilai RGB yang belum dinormalisasi

Selanjutnya, nilai RGB yang telah dinormalisasi dikonversi ke dalam ruang warna HSV menggunakan tiga persamaan berikut.

$$V = max \quad \text{.....(2)}$$

$$H = \begin{cases} 0 & ,jika\ max = min \\ 60° \times \left(\frac{g-b}{max-min}\right) mod 6 & ,jika\ max = r \\ 60° \times \left(\frac{b-r}{max-min} + 2\right) & ,jika\ max = g \\ 60° \times \left(\frac{r-g}{max-min} + 4\right) & ,jika\ max = b \end{cases} \quad \text{.....(3)}$$

$$S = \begin{cases} 0 & ,jika\ V = 0 \\ 1 - \frac{min}{V} & ,jika\ V > 0 \end{cases} \quad \text{.....(4)}$$

Keterangan:
H, S, V = Nilai HSV
r, g, b = Nilai RGB yang telah dinormalisasi
max = Nilai terbesar di antara nilai r, g, dan b
min = Nilai terkecil di antara nilai r, g, dan b

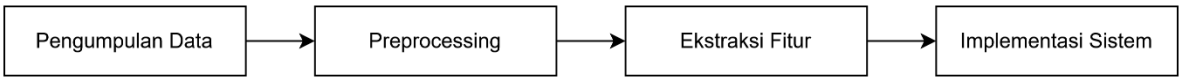
K-Nearest Neighbor (K-NN)

Dalam dunia pembelajaran mesin, K-NN dikenal sebagai teknik klasifikasi sederhana dengan prinsip utama bahwa data yang memiliki karakteristik serupa biasanya berada dalam kelas yang sama. Tahapan eksekusinya dimulai ketika ada titik data yang akan diproses dari kumpulan data latih berlabel. Algoritma ini kemudian menemukan K jumlah tetangga terdekat, di mana nilai K sudah dikonfigurasi oleh pengguna. Untuk menentukan kedekatan tersebut, digunakan perhitungan metrik jarak antara titik target dan calon tetangganya. Penentuan kelas akhir dilakukan melalui voting, yaitu mengambil label yang paling dominan muncul di antara K tetangga terdekat itu (Kusuma & Cahyono, 2023). Penelitian ini menggunakan nilai $k = 3$, dimana pengukuran jarak antara data baru dengan data pelatihan dihitung menggunakan persamaan *Euclidean Distance*.

$$d(x, y) = \sqrt{\sum_{i=1}^{n}(x_i - y_i)^2} \quad \text{.....(5)}$$

Keterangan:
$d(x, y)$ = Nilai *euclidean distance* antara citra uji dengan citra latih
x_i = Citra uji ke-i
y_i = Citra latih ke-i

Tahapan Penelitian

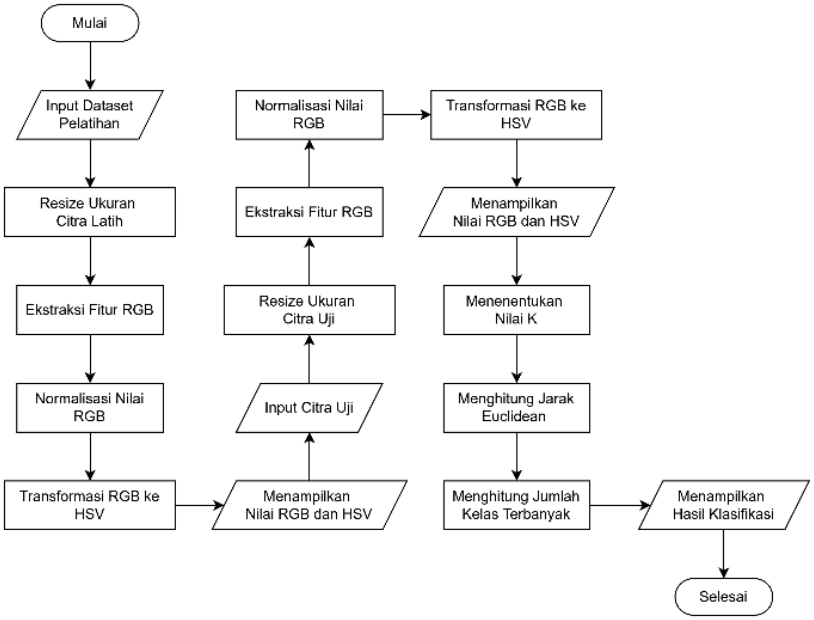


Gambar 2. Tahapan Penelitian

Penelitian ini dilaksanakan melalui empat tahapan utama yang dimulai dari pengumpulan data citra buah kelapa sawit secara langsung di perkebunan PT. Asam Jawa, Kecamatan Torgamba, Kabupaten Labuhan Batu Selatan, Sumatera Utara. Dataset yang digunakan terdiri dari 180 citra yang diklasifikasikan ke dalam 41ig akelas tingkat kematangan, yaitu Matang, Setengah Matang, dan Mentah, dengan pembagian 150 citra untuk data pelatihan dan 30 citra untuk data pengujian. Selanjutnya, citra yang telah dikumpulkan diproses melalui tahap *preprocessing* dengan melakukan *resizing* menjadi ukuran seragam 256 × 256 piksel guna menghindari perbedaan nilai ekstraksi fitur akibat variasi dimensi citra. Pada tahap ekstraksi fitur, sistem mengekstrak dua jenis fitur warna, yaitu fitur RGB yang diperoleh secara langsung dari citra dan fitur HSV yang didapatkan melalui transformasi nilai RGB menggunakan persamaan konversi standar. Terakhir, pada tahap implementasi sistem, proses *preprocessing* dan ekstraksi fitur diotomatisasi sehingga ketika pengguna menginput citra, baik untuk pelatihan maupun pengujian, sistem secara otomatis melakukan *resizing*, ekstraksi fitur RGB, dan transformasi ke nilai HSV tanpa memerlukan intervensi manual. Keempat tahapan ini dirancang secara terintegrasi untuk memastikan konsistensi data, efisiensi pemrosesan, dan kesiapan fitur sebagai input bagi algoritma *K-Nearest Neighbor* (K-NN) dalam klasifikasi tingkat kematangan buah kelapa sawit.

Implementasi Sistem

Implementasi sistem pada penelitian ini merupakan proses integrasi menyeluruh terhadap tahapan-tahapan sebelumnya, yaitu *preprocessing* dan ekstraksi fitur dengan tujuan mengotomatisasi seluruh alur pemrosesan data serta menghubungkannya secara langsung dengan algoritma klasifikasi *K-Nearest Neighbor* (K-NN). Dalam sistem yang dirancang, pengguna cukup menginput citra buah kelapa sawit, baik untuk keperluan pelatihan maupun pengujian, kemudian sistem secara otomatis melakukan *resizing* citra menjadi ukuran 256 × 256 piksel, mengekstrak fitur warna RGB, mengonversinya ke ruang warna HSV, dan menggabungkan kedua jenis fitur tersebut sebagai representasi numerik citra. Fitur-fitur yang telah diekstrak kemudian diumpankan ke algoritma K-NN untuk diklasifikasikan ke dalam salah satu dari 42ig akelas tingkat kematangan (Matang, Setengah Matang, atau Mentah) berdasarkan kedekatan jarak fitur terhadap tetangga terdekat dalam ruang fitur. Diagram alir sistem yang menggambarkan keseluruhan mekanisme kerja, mulai dari input citra, *preprocessing*, ekstraksi fitur, hingga klasifikasi dan output hasil, disajikan secara lengkap pada Gambar 3 yang menunjukkan arsitektur sistem yang terstruktur, efisien, dan siap dioperasikan secara *end-to-end* untuk mendukung keputusan panen yang objektif dan akurat.



Gambar 3. Diagram Alir Sistem

HASIL DAN PEMBAHASAN

Ekstraksi Fitur

Ekstraksi fitur pada penelitian ini dilakukan dengan mengekstrak dua jenis representasi warna dari citra buah kelapa sawit, yaitu nilai RGB dan nilai HSV. Nilai RGB diekstraksi secara langsung oleh sistem dari setiap citra yang diinput pengguna tanpa memerlukan transformasi tambahan. Sedangkan nilai HSV diperoleh melalui proses konversi matematis dari nilai RGB yang telah diekstrak sebelumnya menggunakan Persamaan 2, 3, dan 4 yang menghitung komponen Hue (H), Saturation (S), dan Value (V) secara berurutan. Tahap ekstraksi fitur ini diterapkan secara konsisten pada kedua fase utama penelitian, yaitu proses pelatihan menggunakan 150 citra dan proses pengujian menggunakan 30 citra. Sampel hasil ekstraksi fitur untuk citra pelatihan disajikan secara rinci pada Tabel 2, sedangkan sampel hasil ekstraksi fitur untuk citra pengujian ditampilkan pada Tabel 3. Kombinasi kedua jenis fitur ini, RGB yang merepresentasikan intensitas warna dasar dan HSV yang lebih tangguh terhadap variasi pencahayaan, digunakan sebagai input numerik bagi algoritma *K-Nearest Neighbor* untuk mengklasifikasikan tingkat kematangan buah kelapa sawit ke dalam tiga kelas: Matang, Setengah Matang, dan Mentah.

Tabel 2. Sampel Hasil Ekstraksi Fitur Citra Pelatihan

Nama File	R	G	B	H	S	V
Matang027.jpg	148,13	97,19	75,47	0,05	0,49	0,58
Matang002.jpg	141,79	101,94	75,1	0,07	0,47	0,56
Matang049.jpg	152,87	103,86	83,6	0,05	0,44	0,6
Matang039.jpg	133,78	113,76	116,94	0,98	0,15	0,53
Setengah Matang008.jpg	124,57	110,03	111,02	0,99	0,12	0,49
Setengah Matang018.jpg	130,37	115,84	116,61	0,99	0,11	0,51
Mentah033.jpg	112,84	111,12	110	0,06	0,03	0,44
Mentah014.jpg	115,17	114,04	112,43	0,11	0,03	0,45
Mentah030.jpg	108,26	106,4	101,56	0,11	0,06	0,42

Tabel 3. Sampel Hasil Ekstraksi Fitur Citra Pengujian

Nama File	R	G	B	H	S	V
UjiMatang01.jpg	153,05	107,12	75,66	0,0671	0,5033	0,6
UjiSetengah Matang1.jpg	125,29	112,59	113,65	0,9861	0,0960	0,4902
UjiMentah001.jpg	110,34	109,08	107,78	0,0833	0,0182	0,4314

Algoritma *K-Nearest Neighbor*

Setelah citra pelatihan dan citra pengujian melewati tahap ekstraksi fitur, nilai fitur RGB yang diperoleh secara langsung dari sistem terlebih dahulu dinormalisasi untuk menyeragamkan skala nilai dan mencegah dominasi fitur tertentu dalam perhitungan jarak. Hasil normalisasi nilai fitur RGB untuk citra pelatihan disajikan pada Tabel 4, sedangkan nilai fitur RGB yang telah dinormalisasi untuk citra pengujian ditampilkan pada Tabel 5. Selanjutnya, nilai fitur RGB yang telah dinormalisasi dan nilai fitur HSV yang diperoleh melalui transformasi dari nilai RGB digabungkan menjadi sebuah vektor fitur. Kemudian vektor fitur tersebut digunakan untuk menghitung nilai *Euclidean Distance* antara setiap citra pengujian dengan seluruh citra pelatihan menggunakan Persamaan (5).

Tabel 4. Nilai Fitur RGB Citra Pelatihan Yang Telah Dinormalisasi

Nama File	R	G	B
Matang027.jpg	0,5809	0,3811	0,2960
Matang002.jpg	0,5560	0,3998	0,2945
Matang049.jpg	0,5995	0,4073	0,3278
Matang039.jpg	0,5246	0,4461	0,4586
Setengah Matang008.jpg	0,4885	0,4315	0,4354
Setengah Matang018.jpg	0,5113	0,4543	0,4573
Mentah033.jpg	0,4425	0,4358	0,4314
Mentah014.jpg	0,4516	0,4472	0,4409
Mentah030.jpg	0,4245	0,4173	0,3983

Tabel 5. Nilai Fitur RGB Citra Pengujian Yang Telah Dinormalisasi

Nama File	R	G	B
UjiMatang01.jpg	0,6002	0,4201	0,2967
UjiSetengah Matang1.jpg	0,4913	0,4415	0,4457
UjiMentah001.jpg	0,4327	0,4278	0,4227

$$d(x,y) = \sqrt{\sum_{i=1}^{n}(x_i - y_i)^2}$$

$$d(x,y) = \sqrt{\begin{matrix}(0{,}6002 - 0{,}5809)^2 + (0{,}4201 - 0{,}3811)^2 + (0{,}2967 - 0{,}2960)^2 + \\ (0{,}0671 - 0{,}05)^2 + (0{,}5033 - 0{,}49)^2 + (0{,}6 - 0{,}58)^2\end{matrix}}$$

$$d(x,y) = \sqrt{\begin{matrix}0{,}00037249 + 0{,}001521 + 0{,}00000049 + 0{,}00029241 + \\ 0{,}00017689 + 0{,}0004\end{matrix}}$$

$$d(x,y) = 0{,}0526$$

Perhitungan nilai *Euclidean Distance* tersebut dilakukan secara berulang untuk membandingkan nilai fitur citra pengujian UjiMatang01.jpg dengan seluruh nilai fitur citra pelatihan, mulai dari citra pelatihan pertama hingga citra pelatihan terakhir sehingga diperoleh 9 nilai jarak yang merepresentasikan kedekatan kemiripan antara citra uji dengan setiap citra dalam *dataset* pelatihan. Keseluruhan hasil perhitungan nilai *Euclidean Distance* antara citra UjiMatang01.jpg dengan sampel citra pelatihan disajikan secara lengkap pada Tabel 4. Tabel ini menjadi dasar untuk menentukan K tetangga terdekat dalam algoritma K-NN, di mana K citra pelatihan dengan nilai *Euclidean Distance* terkecil akan dipilih untuk menentukan kelas prediksi berdasarkan mayoritas label kelas dari tetangga-tetangga terdekat tersebut.

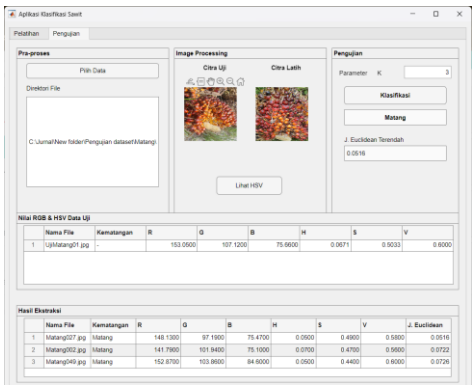
Tabel 6. Hasil Perhitungan Nilai *Euclidean Distance* UjiMatang01.jpg

Nama File	R	G	B	H	S	V	Euclidean Distance
Matang027.jpg	148,13	97,19	75,47	0,05	0,49	0,58	0,0523
Matang002.jpg	141,79	101,94	75,1	0,07	0,47	0,56	0,0713
Matang049.jpg	152,87	103,86	83,6	0,05	0,44	0,6	0,0737
Matang039.jpg	133,78	113,76	116,94	0,98	0,15	0,53	0,9978
Setengah Matang008.jpg	124,57	110,03	111,02	0,99	0,12	0,49	1,0211
Setengah Matang018.jpg	130,37	115,84	116,61	0,99	0,11	0,51	1,0244
Mentah033.jpg	112,84	111,12	110	0,06	0,03	0,44	0,5412
Mentah014.jpg	115,17	114,04	112,43	0,11	0,03	0,45	0,5403
Mentah030.jpg	108,26	106,4	101,56	0,11	0,06	0,42	0,5215

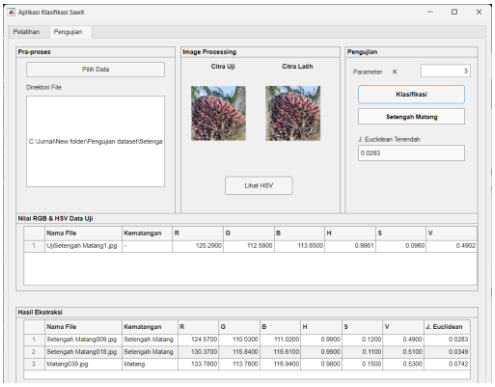
Penelitian ini menggunakan nilai k = 3 pada algoritma *K-Nearest Neighbor* sehingga klasifikasi tingkat kematangan untuk setiap citra pengujian ditentukan berdasarkan mayoritas label dari tiga tetangga terdekatnya. Berdasarkan Tabel 4 yang berisi daftar nilai *Euclidean Distance* antara citra UjiMatang01.jpg dengan seluruh citra pelatihan, tiga citra dengan jarak terkecil, yaitu Matang027.jpg, Matang002.jpg, dan Matang049.jpg teridentifikasi sebagai tetangga terdekat. Ketiga citra tersebut memiliki label kelas Matang sehingga berdasarkan prinsip mayoritas voting pada K-NN, citra UjiMatang01.jpg diklasifikasikan sebagai kelas Matang. Dengan pendekatan yang sama, citra UjiSetengahMatang1.jpg diklasifikasikan sebagai Setengah Matang dan citra UjiMentah001.jpg diklasifikasikan sebagai Mentah.

Implementasi Sistem

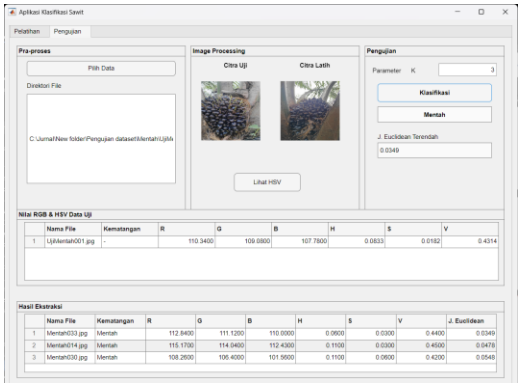
Tahapan *preprocessing* dan ekstraksi fitur pada penelitian ini telah diintegrasikan ke dalam sebuah sistem terapan yang dikembangkan menggunakan MATLAB 2023a. Sistem ini dirancang untuk mengotomatisasi seluruh alur pemrosesan citra, mulai dari input citra pengguna, *resizing* menjadi ukuran 256 × 256 piksel, ekstraksi fitur RGB yang kemudian dinormalisasi, transformasi ke ruang warna HSV, hingga klasifikasi akhir menggunakan algoritma *K-Nearest Neighbor* dengan nilai k= 3. Hasil klasifikasi citra UjiMatang01.jpg, citra UjiSetengah Matang1.jpg, dan citra UjiMentah001.jpg oleh sistem disajikan secara visual pada Gambar 4, Gambar 5, dan Gambar 6.



Gambar 4. Hasil Klasifikasi Citra UjiMatang01.jpg Oleh Sistem



Gambar 5. Hasil Klasifikasi Citra UjiSetengah Matang1.jpg Oleh Sistem



Gambar 6. Hasil Klasifikasi Citra UjiMentah001.jpg Oleh Sistem

Setelah melakukan klasifikasi secara berulang terhadap 30 citra pengujian menggunakan sistem yang telah dirancang, dilakukan perhitungan akurasi untuk menilai keandalan sistem dalam mengklasifikasikan tingkat kematangan buah kelapa sawit. Hasil klasifikasi terhadap 30 citra pengujian tersebut disajikan secara lengkap pada Tabel 7 yang memuat prediksi sistem untuk setiap citra uji beserta label aktualnya.

Berdasarkan perbandingan antara hasil prediksi dan label aktual, akurasi sistem dihitung dengan menggunakan pendekatan berikut.

$$Akurasi = \frac{Jumlah\ Prediksi\ Benar}{Total\ Citra\ Uji} \times 100\%$$
$$Akurasi = \frac{27}{30} \times 100\%$$
$$Akurasi = 90\%$$

Tabel 7. Hasil Klasifikasi Citra Pengujian

Nama Citra	Label Aktual	Hasil Klasifikasi
UjiMatang01.jpg	Matang	Matang
UjiMatang02.jpg	Matang	Matang
UjiMatang03.jpg	Matang	Matang
UjiMatang04.jpg	Matang	Matang
UjiMatang05.jpg	Matang	Matang
UjiMatang06.jpg	Matang	Matang
UjiMatang07.jpg	Matang	Matang
UjiMatang08.jpg	Matang	Matang
UjiMatang09.jpg	Matang	Matang
UjiMatang10.jpg	Matang	Matang
UjiSetengahMatang1.jpg	Setengah Matang	Setengah Matang
UjiSetengahMatang2.jpg	Setengah Matang	Setengah Matang
UjiSetengahMatang3.jpg	Setengah Matang	Setengah Matang
UjiSetengahMatang4.jpg	Setengah Matang	Matang
UjiSetengahMatang5.jpg	Setengah Matang	Setengah Matang
UjiSetengahMatang6.jpg	Setengah Matang	Setengah Matang
UjiSetengahMatang7.jpg	Setengah Matang	Setengah Matang
UjiSetengahMatang8.jpg	Setengah Matang	Setengah Matang
UjiSetengahMatang9.jpg	Setengah Matang	Matang
UjiSetengahMatang10.jpg	Setengah Matang	Setengah Matang
UjiMentah001.jpg	Mentah	Mentah
UjiMentah002.jpg	Mentah	Mentah
UjiMentah003.jpg	Mentah	Mentah
UjiMentah004.jpg	Mentah	Mentah
UjiMentah005.jpg	Mentah	Mentah
UjiMentah006.jpg	Mentah	Mentah
UjiMentah007.jpg	Mentah	Mentah
UjiMentah008.jpg	Mentah	Setengah Matang
UjiMentah009.jpg	Mentah	Mentah
UjiMentah010.jpg	Mentah	Mentah

Hasil perhitungan akurasi sistem menunjukkan nilai sebesar 90%, yang mengindikasikan bahwa sistem mampu mengklasifikasikan tingkat kematangan buah kelapa sawit dengan tingkat keandalan yang tinggi. Dari 30 citra pengujian, sistem berhasil memprediksi dengan benar sebanyak 27 citra, sementara 3 citra lainnya mengalami kesalahan klasifikasi. Akurasi 90% ini menunjukkan bahwa integrasi *preprocessing* (*resizing*), ekstraksi fitur ganda (RGB yang dinormalisasi dan HSV), serta algoritma *K-Nearest Neighbor* dengan nilai k = 3 telah membentuk sistem yang efektif dalam membedakan tiga kelas kematangan, yaitu Matang, Setengah Matang, dan Mentah berdasarkan karakteristik warna kulit buah. Hasil ini memberikan dasar yang kuat untuk penerapan sistem sebagai pendukung keputusan panen yang objektif di perkebunan kelapa sawit.

KESIMPULAN DAN SARAN

Arsitektur sistem yang dibangun dalam studi ini memanfaatkan pengolahan citra digital untuk menentukan tingkat kematangan kelapa sawit. Kesimpulan akhir menegaskan bahwa penggabungan fitur warna HSV dengan *classifier K-Nearest Neighbor* (KNN) berhasil diaplikasikan dengan baik. Penggunaan ruang warna HSV terbukti lebih unggul dalam merepresentasikan karakteristik warna kulit buah dibandingkan RGB karena mampu memisahkan informasi warna dari intensitas cahaya sehingga lebih tahan terhadap variasi iluminasi. Implementasi algoritma KNN dengan nilai k = 3 menghasilkan tingkat akurasi klasifikasi sebesar 90% pada 30

data pengujian yang mengindikasikan bahwa sistem mampu membedakan tiga kelas kematangan yaitu Matang, Setengah Matang, dan Mentah dengan tingkat keandalan yang tinggi. Sistem ini berpotensi menjadi teknologi pendukung keputusan panen yang objektif untuk meningkatkan efisiensi produksi CPO.

Untuk pengembangan penelitian selanjutnya, penulis menyarankan agar jumlah *dataset* diperbanyak dengan variasi kondisi perkebunan dan jenis bibit kelapa sawit yang berbeda guna meningkatkan generalisasi sistem. Pengujian juga perlu dilakukan pada kondisi pencahayaan yang lebih ekstrem seperti malam hari atau cuaca mendung untuk menguji ketahanan sistem secara lebih rigor. Selain itu, sistem yang masih berbasis simulasi MATLAB disarankan untuk diimplementasikan pada perangkat keras *embedded* seperti Raspberry Pi atau mikrokontroler dengan kamera agar dapat digunakan secara *real-time* di lapangan oleh petani. Terakhir, penambahan ekstraksi fitur tekstur seperti GLCM selain fitur warna dapat dipertimbangkan untuk meningkatkan akurasi klasifikasi, terutama untuk membedakan buah yang memiliki kemiripan warna namun berbeda tekstur permukaan.

DAFTAR PUSTAKA

Anjani, I. G., Saputri, A. B., Armeira, A. N. P., & Januarita, D. (2022). Analisis Konsumsi Dan Produksi Minyak Kelapa Sawit Di Indonesia Dengan Menerapkan Metode Moving Average. *JURIKOM (Jurnal Riset Komputer)*, *9*(4), 1014. https://doi.org/10.30865/jurikom.v9i4.4506

Candra, K. K. (2023). *Pengolahan Citra Digital* (N. A. Hawa, Ed.). Ahliamedia Press.

Ellif, E., Sitorus, S. H., & Hidayati, R. (2021). Klasifikasi Kematangan Pepaya Menggunakan Ruang Warna Hsv Dan Metode Naive Bayes Classifier. *Coding Jurnal Komputer Dan Aplikasi*, *9*(01), 66. https://doi.org/10.26418/coding.v9i01.45906

Kusuma, I. H., & Cahyono, N. (2023). Analisis Sentimen Masyarakat Terhadap Penggunaan E-Commerce Menggunakan Algoritma K-Nearest Neighbor. *Jurnal Informatika: Jurnal Pengembangan IT*, *8*(3), 302–307. https://doi.org/10.30591/jpit.v8i3.5734

Masruroh, A. I., . S., & Syauqi, A. (2023). Klasifikasi Tingkat Kematangan Buah Pepaya California Dalam Ruang Warna Hsv (Hue Saturation Value) Dengan Algoritma K-Nearest Neighbors. *Jurnal Informatika Dan Riset*, *1*(1), 9–14. https://doi.org/10.36308/iris.v1i1.470

Munawar, Z., Hasnawi, M., Beno, I. S., Darma, I. W. A. S., Sastradipraja, C. K., Sutramiani, N. P., Amir, A., Manurung, H. E., Kharisma, I. L., Mandowen, S. A., Pomalingo, S., Indra, D., Irmawati, Setyawan, A. A., Mansyur, St. H., & Koibur, M. E. (2023). *Visi Komputer Konsep, Metode, dan Aplikasi* (R. Komalasari, Ed.). Kaizen Media Publishing.

Napitu, S., Panjaitan, R. P., Nulhakim, P. A., & Lubis, M. K. (2023). Klasifikasi Buah Jeruk Segar dan Busuk Berdasarkan RGB dan HSV Menggunakan Metode KNN. *Jurnal SAINTEKOM*, *13*(2), 214–221. https://doi.org/10.33020/saintekom.v13i2.420

Narlan, R. (2023, February). Penerapan Visi Komputer Dalam Bidang Konstruksi. *Proceeding Civil Engineering Research Forum*.

Rohman, D. (2023). *Buku Ajar Pengolahan Citra Digital* (.M.Kn M.TanzilM S.H & M. P. MahardikaD.KW, Eds.). UMSIDAPress.

Saputra, A. chandra, & Oktaviyani, E. D. (2023). Rancang Bangun Sistem Deteksi Kematangan Buah Kelapa Sawit Berdasarkan Deteksi Warna Menggunakan Algoritma K-NN. *Jurnal Teknologi Informasi: Jurnal Keilmuan Dan Aplikasi Bidang Teknik Informatika*, *7*(2), 222–229. https://doi.org/10.47111/jti.v7i2.9232

Saputro, A. K., & Purnamasari, D. N. (2022). *Identifikasi Jenis Plastik Berdasarkan Reflektansi Cahaya Menggunakan Transformasi Ruang Warna Hsv Identification Of Plastic Type Based On Light Reflection In Hsv Colorspace Conversion*. *11*(1).

Sari, W. E., Franz, A., Sugiartawan, P., Komputer, P. T. R., Informasi, J. T., Ciptomangunkusumo, P. N. S. J., Lunak, P. T. R. P., dan Informasi, J. T., Samratulangi, P. N. S. J., & Kunci, K. (2022). Deteksi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit Dengan Algoritme K-Means. *SINTECH Journal*, *5 No 2*. https://doi.org/10.31598

Siregar, A. C., Poetro, B. S. W., Octariadi, B. C., Robet, & Sucipto. (2025). *Buku Ajar Pengolahan Citra Digital* (Efitra, Ed.). PT. Green Pustaka Indonesia.

Supiyandi Supiyandi, & Rafif Rasendriya. (2024). Penggunaan Visi Komputer untuk Mengidentifiksi Jenis Buah dari Gambar. *Router : Jurnal Teknik Informatika Dan Terapan*, *2*(4), 94–103. https://doi.org/10.62951/router.v2i4.287

Sutisna, T., Agung Rachmat, R., Hariyadi, E., & Putra, V. H. C. (2024). Penggunaan Computer Vision untuk Menghitung Jumlah Kendaraan dengan Menggunakan Metode SSD (Single Shoot Detector). *INNOVATIVE: Journal Of Social Science Research*, *4*, 6060–6067.