

Deteksi Tingkat Kematangan Buah Mangga Berdasarkan Fitur Warna Menggunakan Pengolahan Citra Digital

<http://dx.doi.org/10.28932/jutisi.v11i2.10578>

Riwayat Artikel

Received: 17 Desember 2024 | Final Revision: 27 Juli 2025 | Accepted: 02 Agustus 2025

Creative Commons License 4.0 (CC BY – NC)



Muhammad Aksa^{#1}, Andi Ranggareksa^{#2}, Muh. Riski Farukhi Aras^{#3}, Andi Baso Kaswar^{✉*4}, Dyah Darma Andayani^{#5}, Rezki Nurul Jariah S. Intam^{#6}

[#] Program studi Teknik Komputer, Universitas Negeri Makassar
Jl. AP. Pettarani, Makassar, 90222, Indonesia

¹muhammadaksa271@gmail.com

²ranggarekza@gmail.com

³muhriskif736@gmail.com

⁴a.baso.kaswar@unm.ac.id

⁵dyahdarma@unm.ac.id

⁶rezkinuruljariah@gmail.com

✉ Corresponding author: a.baso.kaswar@unm.ac.id

Abstrak — Klasifikasi tingkat kematangan buah mangga Golek penting untuk memastikan kualitas dan nilai ekonomisnya, terutama dalam industri. Penentuan kematangan secara manual dan subjektif sering tidak konsisten, mengakibatkan penurunan kualitas panen dan nilai jual. Penelitian ini bertujuan untuk mengklasifikasikan tingkat kematangan mangga Golek menjadi tiga kategori: muda, mengkal, dan matang, dengan menggunakan pengolahan citra digital berbasis fitur warna Hue, Saturation, Value (HSV) dan Lightness, A, B (LAB) yang dikombinasikan dengan algoritma K-Nearest Neighbor (KNN). Dataset yang digunakan terdiri dari 300 citra, yang dibagi menjadi 80% data pelatihan dan 20% data pengujian. Metode yang diusulkan meliputi akuisisi citra, preprocessing, segmentasi, operasi morfologi, ekstraksi fitur, dan klasifikasi. Hasil pengujian menunjukkan bahwa kombinasi fitur warna HSV dan LAB efektif dalam membedakan tingkat kematangan, dengan akurasi 81,67% pada data pengujian dan rata-rata precision, recall, dan F1-Score sebesar 82%. Pola warna yang konsisten pada kategori muda dan mengkal meningkatkan akurasi, sementara fluktuasi intensitas warna pada kategori matang menjadi tantangan. Pendekatan ini memiliki potensi untuk diterapkan dalam sistem penyortiran otomatis di industri.

Kata kunci— deteksi kematangan; fitur warna; K-Nearest Neighbor; mangga golek; pengolahan citra digital.

Mango Ripeness Detection Based on Color Features Using Digital Image Processing

Abstract — The classification of mango Golek ripeness is crucial for ensuring product quality and its economic value, especially in industrial applications. Manual and subjective ripeness determination often leads to inconsistency, resulting in decreased harvest quality and market value. This study aims to classify the ripeness of Golek mangoes into three categories: unripe, semi-ripe, and ripe,

using digital image processing based on Hue, Saturation, Value (HSV) dan Lightness, A, B (LAB) color features combined with the K-Nearest Neighbor (KNN) algorithm. The dataset consists of 300 images, split into 80% training data and 20% testing data. The proposed method includes image acquisition, preprocessing, segmentation, morphological operations, feature extraction, and classification. The results show that the combination of HSV and LAB color features is effective in distinguishing ripeness levels, with an accuracy of 81.67% on the testing data and an average precision, recall, and F1-Score of 82%. Consistent color patterns in the unripe and semi-ripe categories enhance accuracy, while fluctuations in color intensity in the ripe category pose challenges. This approach shows potential for implementation in automatic sorting systems in industry.

Keywords— color features; digital image processing; Golek mango; K-Nearest Neighbor; maturity detection.

I. PENDAHULUAN

Mangga adalah salah satu komoditas pertanian yang sangat penting di Indonesia, karena memiliki manfaat besar bagi kesehatan dan nilai ekonomi yang tinggi [1]. Buah ini kaya akan berbagai nutrisi penting, seperti vitamin C, A, serta serat, yang mendukung kesehatan tubuh. Vitamin C dalam mangga bertindak sebagai antioksidan yang dapat melindungi sel-sel tubuh dari kerusakan yang disebabkan oleh radikal bebas [2]. Selain itu, mangga juga merupakan sumber utama mikronutrien, vitamin, dan fitokimia lainnya. Buah ini menyediakan energi, serat, karbohidrat, protein, lemak, serta senyawa fenolik, yang menjadikannya pilihan yang bergizi [3]. Pada tahun 2023, produksi mangga di Indonesia mencapai 3.302.620 ton, dengan Sulawesi Selatan (Sulsel) berkontribusi sebesar 107.972 ton dari total produksi tersebut [4]. Salah satu varietas mangga yang banyak beredar di Indonesia adalah mangga golek. Mangga golek dikenal karena ciri-ciri bentuknya yang khas, yaitu buah bulat lonjong. Saat matang, kulit buah mangga golek berwarna kuning kehijauan hingga kuning kemerahan, sedangkan daging buahnya berwarna kuning tua sampai jingga dengan serat yang agak kasar [5]. Rasanya manis dan aromanya kuat, membuatnya sangat digemari baik untuk konsumsi segar maupun olahan seperti jus, selai, dan manisan [6].

Pada tahun 2023, nilai ekspor mangga Indonesia mencapai US\$ 1,4 juta, meningkat sebesar 151,11% dibandingkan tahun sebelumnya. Kenaikan ini mencerminkan tingginya permintaan mangga di pasar internasional [7]. Di sisi lain, nilai impor mangga juga meningkat menjadi US\$ 1,68 juta pada tahun yang sama. Konsumsi mangga di sektor rumah tangga dalam negeri turut mengalami peningkatan, mencapai 156,73 ribu ton pada tahun 2023, naik sebesar 3,34% dibandingkan tahun 2022 [7]. Meskipun tidak ada data spesifik terkait mangga golek dalam angka-angka ini, varietas golek dengan ciri khas rasa manis dan bentuknya yang bulat lonjong menjadi salah satu pilihan bagi konsumen lokal dan berpotensi berkontribusi pada peningkatan konsumsi dan ekspor mangga secara keseluruhan. Namun, salah satu tantangan utama dalam distribusi dan budidaya mangga golek adalah penentuan tingkat kematangan yang optimal.

Penentuan kematangan buah mangga golek yang masih dilakukan secara manual dan bergantung pada pengamatan visual sering kali bersifat subjektif, tidak konsisten, dan rentan terhadap perbedaan persepsi antar pekerja. Hal ini menyebabkan variasi hasil dalam penilaian kematangan, yang berimbas pada penurunan kualitas panen serta nilai jual buah mangga. Selain itu, metode manual yang diterapkan pada skala besar sangat tidak efisien, meningkatkan biaya operasional, serta membuka potensi kerugian akibat produk yang tidak terstandarisasi. Mangga golek yang dipanen pada tingkat kematangan yang tidak tepat baik terlalu matang maupun terlalu mentah dapat memengaruhi kualitas rasa, tekstur, serta masa simpan produk yang dihasilkan, seperti jus dan selai. Di samping itu, buah mangga golek segar cenderung cepat mengalami penurunan kualitas, sehingga memiliki umur simpan yang sangat terbatas [8]. Pada musim panen puncak, kondisi ini semakin parah, mengakibatkan banyak buah yang membusuk dan tidak dapat dimanfaatkan. Tantangan teknis dalam pengolahan citra juga turut memperburuk situasi ini, karena fitur morfologi buah yang sangat mirip antara mangga matang, mentah, dan busuk membuat deteksi otomatis melalui citra sulit dilakukan secara akurat. Pengolahan citra yang tidak mampu membedakan kondisi buah dengan tepat berpotensi mengurangi efektivitas dalam menjaga kualitas produk turunan. Oleh karena itu, pengendalian tingkat kematangan yang tepat menjadi kunci utama bagi industri pengolahan untuk memastikan produk akhir tetap terjaga kualitasnya dan memenuhi standar yang diinginkan [9].

Hingga saat ini, berbagai studi telah dilakukan untuk mengembangkan metode dalam mengklasifikasikan tingkat kematangan buah, terutama pada mangga dan buah-buahan lainnya, dengan memanfaatkan pendekatan pengolahan citra digital. Metode-metode ini menggunakan berbagai teknik klasifikasi, mulai dari K-Nearest Neighbor (KNN) hingga Jaringan Syaraf Tiruan (JST), untuk mendeteksi kematangan berdasarkan fitur visual seperti warna dan tekstur. Hasil penelitian menunjukkan akurasi yang bervariasi tergantung pada metode dan jenis buah yang digunakan.

Penelitian oleh Nafi'iyah menggunakan KNN dengan ekstraksi warna *Hue, Saturation, Value* (HSV) untuk mendeteksi kematangan buah mangga. Penelitian ini mencapai akurasi sekitar 55%, menunjukkan perlunya perbaikan dalam hal keandalan dan efisiensi [10]. Di tahun yang sama, Hendryanto Edha mengembangkan metode yang menggunakan transformasi ruang warna *Hue, Saturation, Intensity* (HSI) untuk mendeteksi kematangan mangga Harum Manis [11]. Dengan akurasi sebesar 87%, metode ini memperlihatkan peningkatan dibandingkan metode berbasis HSV, terutama dalam segmentasi objek dan penghitungan kemiripan warna.

Melanjutkan pendekatan transformasi warna, penelitian oleh Syafi'i menerapkan metode HSI pada mangga Garifta Merah. Penelitian ini mengklasifikasikan buah menjadi tiga kategori: matang, mengkal, dan mentah [12]. Hasil pengujian menunjukkan akurasi 80%, *precision* 80%, dan *recall* 87%. Temuan ini memperkuat efektivitas penggunaan ruang warna HSI dalam mendeteksi kematangan buah dan memberikan alternatif praktis untuk klasifikasi otomatis.

Kemudian, pada tahun 2022, penelitian oleh Syarifah berhasil mencapai akurasi 93% dalam klasifikasi kematangan jambu bol [13]. Peningkatan akurasi ini dicapai dengan menggabungkan fitur warna HSV dan tekstur menggunakan *Gray-Level Co-occurrence Matrix* (GLCM), yang menunjukkan bahwa penambahan fitur tekstur dapat memberikan hasil klasifikasi yang lebih akurat. Penelitian berikutnya oleh Siagian menggunakan ekstraksi ciri warna *Red, Green, Blue* (RGB) untuk mendeteksi kematangan buah jeruk [14]. Penelitian ini menghasilkan akurasi 80,8%, namun terdapat beberapa kendala terkait flek hitam pada kulit jeruk yang mengganggu deteksi.

Selanjutnya, Penelitian oleh Hermanto Laia menggunakan JST dengan metode *perceptron* untuk mendeteksi kematangan mangga, namun akurasi yang dicapai hanya sekitar 50% [15]. Ini menunjukkan keterbatasan metode tersebut dalam mengklasifikasikan kematangan buah mangga. Di sisi lain, penelitian oleh Arjun menggunakan *Self-Organizing Maps* (SOM) berbasis JST untuk mendeteksi kematangan pisang dan mencapai akurasi 82,5% [16]. Meskipun metode JST ini menunjukkan hasil yang lebih baik pada jenis buah tertentu, seperti pisang, tantangan dalam efisiensi komputasi tetap ada, terutama untuk implementasi pada skala industri.

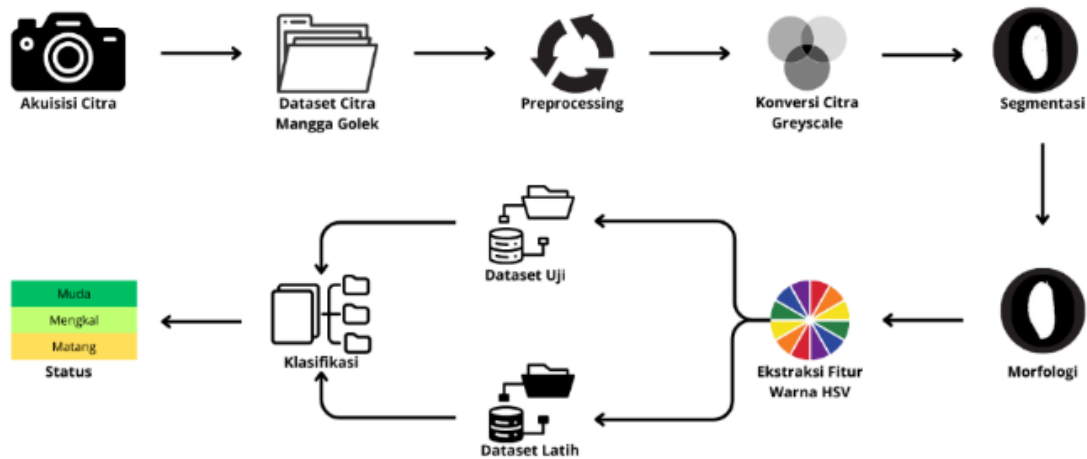
Namun, meskipun berbagai pendekatan telah menunjukkan hasil yang menjanjikan, tantangan signifikan masih ada, terutama terkait akurasi dan efisiensi. Misalnya, metode KNN sering kali menghasilkan akurasi yang bervariasi tergantung pada parameter yang dipilih, sementara metode berbasis JST memerlukan sumber daya komputasi yang besar, yang mungkin kurang efisien untuk skala industri. Oleh karena itu, diperlukan metode yang lebih efisien dan berbiaya rendah, yang tetap mampu menjaga akurasi tinggi dalam mendeteksi kematangan buah mangga untuk aplikasi komersial. Penelitian ini berusaha mengatasi keterbatasan tersebut dengan fokus pada ekstraksi fitur warna yang lebih optimal dan implementasi metode yang dapat diterapkan dalam skala industri secara efisien.

Penelitian ini mengusulkan sistem deteksi tingkat kematangan buah mangga golek berdasarkan fitur warna menggunakan pengolahan citra digital. Metode yang diajukan melibatkan enam tahap utama: akuisisi citra, pra-pemrosesan, segmentasi, operasi morfologi, ekstraksi fitur, dan klasifikasi. Gambar buah mangga diambil dalam kondisi yang terkendali, dengan tiga kategori kematangan: muda, mengkal, dan matang, yang masing-masing terdiri dari 100 sampel. Setiap citra berasal dari buah mangga yang berbeda, bukan dari dokumentasi perkembangan satu buah mangga yang sama. Dengan demikian, batasan dari metode ini adalah hanya berfokus pada klasifikasi tingkat kematangan dari buah-buah mangga yang berbeda, bukan pada pelacakan perubahan tingkat kematangan per individu buah. Setelah proses pra-pemrosesan untuk meningkatkan kualitas citra, tahap segmentasi dilakukan untuk memisahkan mangga dari latar belakang, diikuti dengan operasi morfologi untuk memperbaiki hasil segmentasi. Fitur warna diekstraksi menggunakan ruang warna HSV atau HSI untuk menilai tingkat kematangan. Proses klasifikasi dilakukan dengan metode K-Nearest Neighbor (KNN) untuk mengidentifikasi tingkat kematangan berdasarkan kemiripan fitur dengan data pelatihan.

Tujuan penelitian ini adalah untuk mengembangkan metode yang dapat meningkatkan tingkat akurasi dalam klasifikasi tingkat kematangan mangga serta efisiensi performa komputasi dibandingkan dengan metode yang ada. Diharapkan, solusi yang diusulkan dapat memberikan kontribusi signifikan dalam meningkatkan efektivitas proses penyortiran mangga pada skala industri, sehingga dapat meningkatkan nilai jual dan mengurangi kerugian akibat kesalahan dalam penentuan tingkat kematangan.

II. METODE

Dalam penelitian ini digunakan metode yang memiliki sejumlah tahapan yaitu akuisisi citra, *preprocessing*, melakukan segmentasi, operasi morfologi, ekstraksi fitur, dan klasifikasi. Beberapa Langkah ini harus diselesaikan secara berurutan. Adapun Gambaran proses yang dilakukan dapat dilihat pada Gambar 1.



Gambar 1. Bagan Sistem Klasifikasi yang Diusulkan

A. Akuisisi Citra

Langkah pertama dalam penelitian ini adalah pengambilan dataset citra mangga. Dataset yang digunakan terdiri dari 300 citra, yang terbagi menjadi 100 citra mangga muda, 100 citra mangga setengah matang, dan 100 citra mangga matang.

Pada tahap ini, dataset citra mangga Golek diambil menggunakan dua jenis *smartphone*, yaitu Samsung A54 dan iPhone 13, dengan pengaturan default. *Smartphone* Samsung A54 digunakan untuk memotret 53 citra mangga matang, sedangkan iPhone 13 digunakan untuk kategori lainnya. Pengambilan gambar dilakukan dengan pengaturan *zoom* 2x dan menggunakan flash untuk memastikan konsistensi kualitas citra yang dihasilkan, sehingga mendukung proses pengolahan citra pada tahap selanjutnya. Selama proses pengambilan gambar, digunakan kotak berukuran 50 x 50 cm dengan *background* kain hitam. Kotak ini dilengkapi dengan tiga lampu untuk pencahayaan, dan pada bagian atasnya terdapat lubang untuk menempatkan kamera, sehingga citra dapat diambil dari posisi tetap. Penggunaan kotak ini bertujuan untuk memastikan hasil pengambilan citra tetap konsisten dan tidak terpengaruh oleh gangguan atau fluktuasi intensitas cahaya eksternal. Dengan pengaturan ini, proses pengambilan citra dapat dilakukan dengan lebih terkontrol, menghasilkan dataset berkualitas tinggi untuk tahap pengolahan berikutnya. Kotak yang digunakan untuk pengambilan citra dapat dilihat pada Gambar 2.



Gambar 2. Box yang digunakan untuk pengambilan citra

B. Proses Preprocessing

Langkah ini dilakukan untuk memperbaiki kualitas citra, sehingga citra dapat diproses dengan lebih tepat pada tahap-tahap selanjutnya. Proses *preprocessing* dilakukan dengan prosedur mengatur kecerahan dan kontras dan konversi citra ke dalam

ruang warna yang lebih mudah diproses. Langkah ini bertujuan untuk memudahkan pemisahan antara objek dengan *background* [17].

Dalam metode yang diusulkan pada penelitian ini, citra mangga golek yang diambil digunakan sebagai input untuk sistem yang dirancang. Setelah citra mangga golek sukses diproses dalam sistem, citra tersebut kemudian diubah menjadi citra *grayscale*. Pemilihan ruang warna abu-abu (*grayscale*) bertujuan untuk mengurangi dimensi data yang awalnya terdiri dari tiga saluran warna (RGB) Menjadi satu saluran intensitas. Ini dapat menyederhanakan analisis dan pengolahan citra, membuat pemrosesan menjadi lebih cepat dan ringan dari segi komputasi.

C. Segmentasi

Tahap segmentasi bertujuan untuk memisahkan citra menjadi beberapa wilayah (*region*) atau objek tertentu, di mana setiap wilayah memiliki atribut yang serupa. Melalui proses segmentasi ini, setiap objek dalam citra dapat diekstraksi secara terpisah, sehingga dapat digunakan sebagai input untuk tahap pemrosesan selanjutnya [18]. Teknik segmentasi yang diterapkan pada penelitian ini adalah metode otsu yang bertujuan untuk menentukan batas antara *background* dan objek berdasarkan pemilihan ambang (*threshold*) optimal pada dua kelas piksel, yaitu objek dan *background* pada citra yang di ambil.

Pada penelitian ini, langkah awal segmentasi dilakukan dengan menganalisis histogram dari citra *grayscale* yang telah dipilih di proses pra-pemrosesan. Hasil dari proses ini merupakan citra biner, di mana area berwarna putih (nilai 1) merepresentasikan objek, sedangkan area hitam (nilai 0) mewakili *background*.

D. Operasi Morfologi

Setelah proses segmentasi, hasil yang diperoleh mungkin masih mengandung beberapa ketidaksempurnaan, seperti adanya *noise* yang mengganggu. Oleh karena itu, operasi morfologi diterapkan untuk membersihkan *noise* tersebut dan meningkatkan akurasi dalam mengenali objek sebelum melanjutkan ke proses ekstraksi fitur dari area objek citra. Operasi morfologi umumnya diterapkan pada citra biner (hitam-putih) untuk memodifikasi struktur objek dalam citra. Dalam operasi ini, citra dipandang sebagai kumpulan koordinat (x, y) yang memiliki nilai 1 untuk objek dan 0 untuk latar belakang [19]. Proses ini melibatkan dua set piksel: set pertama adalah citra yang akan diproses, dan set kedua adalah kernel atau elemen penstruktur (*structuring element*).

Dalam penelitian ini, dua operasi dasar dalam morfologi diterapkan, yaitu *erosi* dan *dilasi*, yang memiliki efek berlawanan satu sama lain. *Erosi* bertujuan untuk mengurangi ukuran objek dalam citra dengan mengubah piksel objek (1) yang berada di dekat piksel latar belakang (0) menjadi piksel latar belakang (0). Proses ini berfungsi untuk mengurangi *noise* dan menghilangkan bagian-bagian objek yang tidak diinginkan. Sebaliknya, *dilasi* adalah operasi yang memperbesar objek dalam citra dengan menambahkan lapisan piksel objek di sekitar objek yang ada. *Dilasi* berguna untuk memperluas area objek, sehingga bagian objek yang terpisah dapat tersambung dan membentuk kesatuan yang lebih solid. Proses *dilasi* ini juga memperkuat struktur objek dan mengisi celah yang ada dalam objek [20].

Proses *dilasi* dan *erosi* dilakukan satu kali masing-masing, menggunakan elemen penstruktur berbentuk disk dengan ukuran 30 piksel. *Dilasi* pertama-tama diterapkan pada objek hasil *closing* untuk memperbesar dan memperluas area objek, memungkinkan bagian objek yang terpisah untuk tersambung dan membentuk kesatuan yang lebih solid. Setelah itu, *erosi* diterapkan untuk mengembalikan ukuran objek ke bentuk yang lebih sesuai, menghilangkan perluasan berlebih akibat *dilasi*, dan mempertahankan bentuk utama objek. Proses ini memastikan objek tetap solid dengan ukuran dan bentuk yang sesuai, serta membantu memisahkan objek utama dari *noise* dan detail yang tidak diinginkan dalam citra. Transformasi citra yang terjadi dapat dilihat pada Gambar 6.

E. Ekstraksi Fitur

Proses ekstraksi fitur bertujuan untuk memperoleh atribut unik dari citra yang telah melalui tahap segmentasi dan morfologi. Atribut ini mencakup data informasi mengenai warna, bentuk, dan tekstur. Pemilihan fitur dilakukan dengan cermat agar dapat berfungsi sebagai parameter pembeda antara kelas-kelas citra dalam proses klasifikasi, sekaligus menjadi karakteristik utama dari setiap kelas yang teridentifikasi [17].

Dalam penelitian ini, fitur warna digunakan sebagai input pada tahap klasifikasi. Fitur warna diekstraksi menggunakan dua ruang warna, yaitu *Hue, Saturation, Value* (HSV) dan *Lightness, A, B* (LAB), untuk mengidentifikasi tingkat kematangan buah mangga golek. Ruang warna HSV terdiri dari tiga komponen, yaitu H (*Hue*) yang mewakili warna dasar, S (*Saturation*) yang menggambarkan intensitas warna, dan V (*Value*) yang menunjukkan kecerahan warna. Sedangkan ruang warna LAB terdiri dari tiga komponen, yaitu L (*Lightness*) yang mengukur kecerahan objek, A yang menggambarkan spektrum warna antara hijau dan merah, dan B yang menggambarkan spektrum warna antara biru dan kuning. Komponen H, S, dan V dalam ruang warna HSV digunakan untuk menggambarkan karakteristik warna secara keseluruhan, sementara komponen L, A, dan B dalam LAB digunakan untuk menggambarkan distribusi warna spesifik yang mencirikan tingkat kematangan mangga [17]. Setiap kelas kematangan memiliki karakteristik warna tertentu yang diukur berdasarkan intensitas atau rata-rata nilai dari

channel HSV dan LAB dalam citra objek, kemudian diolah untuk menghasilkan parameter warna yang lebih spesifik. Hasil ekstraksi fitur dari ruang warna HSV dan LAB dapat dilihat pada Gambar 7 dan Gambar 8, yang menunjukkan grafik nilai fitur warna dari masing-masing *channel*.

F. Klasifikasi


Tahap klasifikasi citra mangga golek dimulai dengan membagi dataset menjadi dua bagian yaitu 90% untuk data latih dan 10% untuk data uji dari total citra. *Dataset* ini terdiri dari tiga kelas, yaitu citra mangga muda, mengkal, dan matang. Data latih digunakan untuk membangun model klasifikasi yang kemudian akan diuji menggunakan data uji.

Penelitian ini menggunakan algoritma K-Nearest Neighbor (KNN), yang bekerja dengan mengklasifikasikan data berdasarkan jarak terdekat ke data latih yang telah diberi label [21]. Kedekatan diukur dalam ruang fitur menggunakan metrik jarak, dengan jarak *Euclidean* sebagai metode yang paling umum. Selain itu, algoritma ini juga dapat menggunakan metrik lain seperti *Manhattan distance* atau *Minkowski distance*, tergantung pada karakteristik data. Proses klasifikasi dilakukan dengan menghitung jarak dari data uji ke seluruh data latih, memilih K data latih terdekat, lalu menentukan kelas berdasarkan mayoritas dari K tetangga tersebut [22].


III. HASIL DAN PEMBAHASAN

Penelitian ini dimulai dengan membagi 300 citra buah mangga golek ke dalam dua kategori, yaitu data pelatihan dan data pengujian. *Dataset* ini terdiri dari tiga kelas tingkat kematangan buah mangga golek, yaitu muda, mengkal, dan matang. Data pelatihan mencakup 80% dari total citra, dengan masing-masing kelas terdiri atas 80 citra, sehingga totalnya mencapai 240 citra. Sementara itu, 20% dari dataset dialokasikan sebagai data pengujian, dengan masing-masing kelas memiliki 20 citra, menghasilkan total 60 citra uji. Dengan demikian, setiap kelas memiliki proporsi yang sama dalam dataset, baik pada data pelatihan maupun data pengujian, yaitu 80 citra untuk masing-masing kelas di data pelatihan dan 20 citra di data pengujian. Proporsi ini memastikan distribusi yang seimbang antara ketiga kelas tingkat kematangan dalam dataset.

Proses pemberian label atau anotasi dilakukan ketika membeli buah oleh penjual buah. Pada saat membeli mangga, penjual menilai tingkat kematangan buah berdasarkan ciri-ciri visual yang terlihat, seperti warna kulit dan tekstur buah. Penjual kemudian memberikan label sesuai dengan tingkat kematangan buah, yaitu muda, mengkal, atau matang. Pelabelan ini dilakukan secara manual, dengan penjual menggunakan pengalamannya dalam membedakan tingkat kematangan mangga untuk memastikan ketepatan label yang diberikan. Gambaran hasil pengelompokan citra berdasarkan kelas disajikan pada Gambar 3.




Gambar 3. Contoh citra kelas (a) muda, (b) mengkal, dan (c) matang



Gambar 4. Contoh citra *grayscale* kelas kelas (a) muda, (b) mengkal, dan (c) matang

Selanjutnya, Gambar 3 menunjukkan hasil pengelompokan citra berdasarkan kelas kematangan mangga. Pengelompokan ini bertujuan untuk memisahkan citra mangga sesuai dengan tahap kematangannya, yaitu muda, mengkal, dan matang. Namun, dataset yang digunakan hanya berisi gambar mangga pada berbagai tahap kematangan, tidak mencakup citra dari individu mangga yang sama pada setiap tahap perkembangan. Gambar-gambar tersebut diambil secara acak di setiap tahap kematangan, sehingga tidak ada dokumentasi yang menunjukkan perkembangan satu buah mangga dari fase muda, mengkal,

hingga matang. Selanjutnya, citra tersebut kemudian dikonversi ke dalam bentuk *grayscale*, yang hasilnya ditampilkan pada Gambar 4. Pemilihan citra *grayscale* dipertimbangkan karena dapat memberikan pemisahan yang lebih jelas antara objek penelitian dan latar belakang, meskipun warnanya cenderung seragam. Tahap segmentasi menggunakan metode *Otsu Thresholding*, dan hasil segmentasinya ditampilkan pada Gambar 5.



Gambar 5. Contoh hasil segmentasi (a) baik dan (b) kurang baik

Hasil segmentasi citra *grayscale* pada Gambar 5 menunjukkan perbedaan kualitas antara Gambar 5a dan Gambar 5b. Gambar 5a menampilkan segmentasi yang lebih bersih, sementara Gambar 5b gagal mengenali area gelap (noda hitam) yang sebenarnya masih merupakan bagian dari objek, sehingga mencerminkan kesalahan segmentasi. Meskipun terdapat kecenderungan bahwa mangga yang lebih matang memiliki lebih banyak noda hitam, noda tersebut juga dapat muncul pada mangga yang belum matang sepenuhnya [23]. Oleh karena itu, keberadaan noda hitam tidak digunakan sebagai prediktor utama tingkat kematangan dalam penelitian ini.


Segmentasi yang kurang optimal dapat mengurangi akurasi dalam proses ekstraksi fitur citra. Untuk mengatasi hal tersebut, prosedur morfologi perlu diterapkan guna meningkatkan kualitas segmentasi dan menghasilkan ekstraksi fitur yang lebih representatif. Dalam penelitian ini, beberapa operasi morfologi yang digunakan meliputi *dilasi* dan *erosi*. Operasi *dilasi* dan *erosi* dilakukan menggunakan elemen berbentuk disk dengan ukuran 30 piksel.



Gambar 6. Contoh (a) citra hasil segmentasi, dan (b) operasi morfologi

Gambar 6 menunjukkan perbedaan hasil segmentasi sebelum dan sesudah penerapan operasi morfologi. Pada Gambar 6a, proses segmentasi sebelum dilakukan operasi morfologi memperlihatkan adanya *noise* berupa objek kecil yang terdeteksi secara salah, serta beberapa piksel yang seharusnya menjadi bagian dari objek malah teridentifikasi sebagai *background*. Sebaliknya, Gambar 6b memperlihatkan hasil segmentasi setelah penerapan operasi morfologi, yang telah kembali menggunakan nilai pada kanal RGB. Dalam hasil ini, objek kecil yang sebelumnya terdeteksi telah sepenuhnya dihilangkan, dan bagian objek yang sebelumnya dianggap sebagai *background* kini lebih minim, menghasilkan segmentasi yang lebih akurat. Setelah segmentasi yang lebih tepat diperoleh, proses dilanjutkan dengan ekstraksi fitur. Penelitian ini hanya menggunakan fitur warna untuk ekstraksi, berdasarkan pengujian yang menunjukkan bahwa atribut warna dalam ruang HSV, dan LAB memberikan akurasi yang jauh lebih tinggi dibandingkan kombinasi fitur lainnya. Ekstraksi fitur warna dilakukan dengan memanfaatkan parameter dalam ruang warna HSV dan LAB.

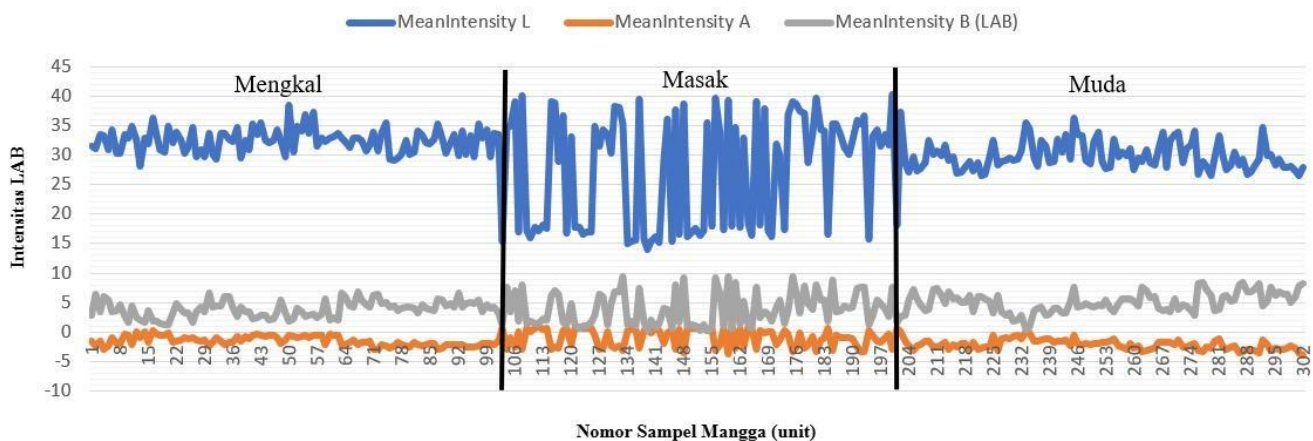
Grafik Nilai Fitur Warna Channel HSV



Gambar 7. Grafik Nilai Fitur Warna Channel HSV

Gambar 7 menunjukkan hasil ekstraksi fitur warna pada ruang warna HSV untuk mendeteksi tingkat kematangan mangga golek, dengan perbedaan pola intensitas antar kelas Mengkal, Masak, dan Muda. Komponen *Hue* (H) menunjukkan perbedaan paling signifikan, di mana intensitasnya cenderung stabil pada nilai 0,5–0,6 di kelas Mengkal, meningkat tajam dengan fluktuasi besar di kelas Masak, dan kembali menurun dengan pola yang lebih stabil di kelas Muda. Komponen *Saturation* (S) memiliki pola yang relatif stabil di semua kelas, dengan nilai rata-rata rendah (0,1–0,2), namun terdapat sedikit peningkatan di kelas Masak. Sementara itu, komponen *Value* (V) juga cenderung stabil di semua kelas dengan nilai rata-rata sekitar 0,3–0,4 dan fluktuasi kecil di kelas Masak. Hal ini menunjukkan bahwa intensitas *Hue* menjadi komponen paling berpengaruh dalam membedakan tingkat kematangan mangga.

Grafik Nilai Fitur Warna Channel LAB



Gambar 8. Grafik Nilai Fitur Warna Channel LAB

Selanjutnya, berdasarkan grafik pada Gambar 8, dapat diamati perbedaan pola intensitas warna antar kelas kematangan mangga pada ruang warna LAB. Pada channel A, nilai intensitas untuk kelas Mengkal cenderung lebih banyak mengarah ke nilai negatif, yang menunjukkan dominasi warna hijau. Sementara itu, pada kelas Masak, pola grafik menunjukkan fluktuasi naik-turun dengan variasi yang lebih signifikan dibandingkan kelas lainnya, mencerminkan peralihan warna hijau ke merah. Untuk kelas Muda, intensitas channel A kembali dominan di nilai negatif, serupa dengan pola yang terlihat pada kelas Mengkal. Pola ini menunjukkan bahwa *channel A* berperan penting dalam membedakan tingkat kematangan berdasarkan distribusi warna hijau-merah. Langkah selanjutnya setelah ekstraksi fitur adalah melaksanakan skenario pelatihan dan

pengujian dengan menguji berbagai kombinasi fitur yang tersedia. Fokus utama dari langkah ini adalah menentukan kombinasi fitur yang paling optimal, yaitu yang menghasilkan akurasi tinggi dengan waktu pemrosesan yang minimal.

TABEL 1
PERBANDINGAN AKURASI DAN WAKTU KOMPUTASI SKENARIO KOMBINASI FITUR

Kombinasi Fitur	Akurasi (%)		Misclassification Error (%)		Waktu Komputasi (s)	
	Pelatihan	Pengujian	Pelatihan	Pengujian	Pelatihan	Pengujian
RGB	85,42	68,33	14,58	31,67	149,631	34,555
HSV	83,33	68,33	16,67	31,67	177,014	41,942
LAB	89,58	81,67	10,42	18,33	421,971	102,189
Tekstur	85	45	15	55	263,584	63,597
RGB+HSV	84,58	65	15,42	35	215,453	57,434
RGB+LAB	87,08	83,33	12,92	16,67	466,467	121,104
RGB+Tekstur	89,17	33,33	10,83	66,67	293,048	43,955
LAB+Tekstur	88,75	58,33	11,25	41,67	628,145	141,441
HSV+LAB	90,83	81,67	9,17	18,33	502,612	121,465
HSV+Tekstur	85	63,33	15	36,67	360,818	84,353
RGB+HSV+LAB	87,08	83,33	12,92	16,67	539,201	129,854

Berdasarkan perbandingan hasil akurasi, kesalahan klasifikasi (*Misclassification Error* / ME), dan waktu komputasi yang ditunjukkan pada Tabel 1, skenario optimal dipilih dengan menggunakan kombinasi fitur warna HSV dan LAB. Fitur ini menghasilkan akurasi sebesar 90,83% pada tahap pelatihan, dengan ME sebesar 9,17%, serta membutuhkan waktu komputasi sekitar 502,612 detik.

Setelah fitur yang sesuai ditentukan, proses klasifikasi dilakukan dengan menggunakan 240 citra untuk pelatihan dan 60 citra untuk pengujian. Hasil pelatihan dapat dilihat pada Tabel 2 untuk data latih dan Tabel 3 untuk data uji. Pada tahap pengujian, skenario ini menghasilkan akurasi sebesar 81,67% dengan *Misclassification Error* (ME) sebesar 18,33%. Waktu komputasi yang dibutuhkan untuk pengujian ini adalah sekitar 121,47 detik, dengan proses klasifikasi dijalankan pada laptop yang menggunakan prosesor Intel Core i7-1255U dan RAM 16 GB, tanpa akselerasi GPU. Berdasarkan hasil tersebut, yang menunjukkan akurasi tinggi dan ME rendah, skenario 9 dianggap sebagai skenario yang paling optimal untuk klasifikasi tingkat kematangan mangga Golek.

TABEL 2
HASIL KLASIFIKASI DATA LATIH FITUR HSV+LAB

	Mengkal	Matang	Muda	Precision	Recall	F1 Score
Mengkal	72	3	5	0,91	0,91	0,91
Matang	7	73	0			
Muda	6	2	73			

Berdasarkan data yang ditampilkan pada Tabel 2, terdapat tiga kelas citra latih hasil klasifikasi yang tersaji dalam bentuk *confusion matrix*. Jumlah prediksi benar untuk setiap kelas adalah 72 citra untuk kelas Mengkal, serta masing-masing 73 citra untuk kelas Matang dan Muda. Kelas Matang dan Muda memiliki jumlah prediksi yang paling akurat dengan tingkat akurasi masing-masing sebesar 91,25%, sedangkan kelas Mengkal memiliki akurasi sebesar 90%. Secara keseluruhan, tingkat akurasi mencapai 90,83%, yang menunjukkan bahwa proses pelatihan model KNN telah berjalan dengan baik dan model siap digunakan pada tahap pengujian terhadap data uji.

Namun demikian, analisis lebih lanjut terhadap *confusion matrix* menunjukkan bahwa masih terdapat beberapa kesalahan klasifikasi berupa *False Positive* (FP) dan *False Negative* (FN), terutama pada kelas Mengkal. FP terjadi ketika sistem memprediksi suatu citra sebagai kelas tertentu padahal sebenarnya berasal dari kelas lain. Misalnya, terdapat 7 citra Matang yang salah diklasifikasikan sebagai Mengkal (FN untuk kelas Matang), serta 6 citra Muda yang juga diklasifikasikan sebagai

Mengkal (FP untuk kelas Mengkal). Selain itu, terdapat 5 citra Mengkal yang salah diprediksi sebagai Muda, dan 3 citra Mengkal sebagai Matang.

Kesalahan ini menunjukkan adanya tumpang tindih karakteristik warna antar fase kematangan, khususnya pada kelas Mengkal yang memiliki kemiripan fitur visual dengan kelas lain. Dalam jangka panjang, keberadaan FN dan FP semacam ini dapat berdampak pada performa model jika digunakan dalam skenario nyata, misalnya dalam proses seleksi atau sortasi buah berdasarkan kematangan. Contoh kesalahan klasifikasi ditunjukkan pada Gambar 9, di mana citra mangga mengkal salah diklasifikasikan sebagai muda karena kemiripan warna kulitnya.



Gambar 9. Contoh kesalahan klasifikasi pada data latih: mangga mengkal diprediksi sebagai muda.

Contoh kesalahan klasifikasi ditunjukkan pada Gambar 9, di mana citra buah mangga mengkal salah diklasifikasikan sebagai muda. Berdasarkan tampilan visual, kulit buah masih didominasi oleh warna hijau cerah, yang secara statistik memiliki nilai *Hue* dan *a** serupa dengan buah muda. Hal ini mengindikasikan keterbatasan fitur warna dalam membedakan fase kematangan yang berada dalam spektrum warna yang berdekatan.

TABEL 3
HASIL KLASIFIKASI DATA UJI FITUR HSV+LAB

	Mengkal	Matang	Muda	Precision	Recall	F1 Score
Mengkal	16	1	3	0,83	0,82	0,82
Matang	7	13	0			
Muda	0	0	20			

Berdasarkan Tabel 3 hasil klasifikasi data uji dan grafik distribusi fitur HSV dan LAB, kelas mengkal dan muda memiliki tingkat prediksi lebih tinggi dibandingkan kelas matang. Pada grafik HSV, kelas matang menunjukkan fluktuasi besar, terutama pada intensitas *H* (*Hue*), yang sering tumpang tindih dengan kelas mengkal, sehingga sulit dikenali. Sebaliknya, kelas mengkal memiliki nilai *V* (*Value*) yang stabil dan *H* serta *S* (*Saturation*) yang rendah, mencerminkan pola konsisten. Sementara itu, kelas muda menunjukkan pola *H*, *S*, dan *V* yang lebih rendah dan stabil, sehingga lebih mudah diidentifikasi.

Pada grafik LAB, kelas matang menunjukkan fluktuasi besar pada parameter *L* (*Lightness*), yang tumpang tindih dengan kelas mengkal. Sebaliknya, kelas mengkal memiliki nilai *L* yang stabil, dengan nilai *A* dan *B* yang lebih rendah dan konsisten, memudahkan klasifikasi. Kelas muda memiliki intensitas *L*, *A*, dan *B* yang rendah dan stabil, sehingga mendukung akurasi model. Hasil pengujian menunjukkan akurasi keseluruhan 81,67%, dengan rata-rata nilai *precision*, *recall*, dan *F1-Score* sebesar 82%. Hasil pengujian yang telah dilakukan menunjukkan bahwa, metode yang diusulkan berhasil dalam mengklasifikasikan kematangan buah mangga golek.

IV. SIMPULAN

Penelitian ini berhasil mengklasifikasikan tingkat kematangan buah mangga golek menggunakan gabungan fitur warna HSV dan Lab dengan algoritma K-Nearest Neighbor (KNN). Metode yang diusulkan mampu mencapai akurasi keseluruhan sebesar 81,67% pada data uji, dengan rata-rata *precision*, *recall*, dan *F1-score* sebesar 82,33%. Kelas muda dan mengkal menunjukkan tingkat prediksi yang lebih tinggi karena pola warna yang relatif stabil, sedangkan kelas matang mengalami kesulitan klasifikasi akibat fluktuasi intensitas warna yang lebih besar.

Dalam jangka panjang, keberadaan *False Negative* (FN) dan *False Positive* (FP) dapat berdampak pada performa model di skenario nyata. Untuk meningkatkan ketahanan model, beberapa perbaikan dapat diterapkan pada pendekatan saat ini.

Pertama, teknik seleksi fitur seperti PCA atau *Relief-F* dapat mengurangi redundansi. Kedua, penambahan fitur tekstur seperti GLCM atau LBP berpotensi memperkuat representasi pola permukaan. Selain itu, *augmentasi* data dan normalisasi intensitas dapat meningkatkan ketahanan terhadap variasi pencahayaan dan *noise*. Jika pengembangan lebih lanjut diperlukan, pendekatan *deep learning* menjadi opsi menjanjikan. Teknologi ini mampu mengekstraksi fitur kompleks secara otomatis dan mengatasi tantangan visual seperti ketidakaturan warna pada buah matang, yang sulit ditangani metode konvensional.

DAFTAR PUSTAKA

- [1] V. K. Sari, H. Sa'diyah, R. Y. Rusdiana, K. Hariyono, and S. Hartatik, "Keragaman Mangga (*Mangifera indica* L.) di Jawa Timur Berdasarkan Karakter Morfologi: Studi Kasus di Kabupaten Jember," *Vegetalika*, vol. 13, no. 1, pp. 90–103, 2024.
- [2] Kusumiyati, A. A. Munawar, and D. Suhandy, "Prediction of Vitamin C, Titratable Acidity, and Soluble Solids Content of Mango Fruits Using Near-Infrared Reflectance Spectroscopy," *Jurnal Teknologi Pertanian*, vol. 21, no. 3, pp. 145–154, 2020.
- [3] P. A. Ibrahim, I. Dhamayanthie, Y. Rubianti, and F. Yohana, "Studi Awal Pengaruh Pengeringan Serbuk Pelok (Biji) Mangga Cengkir Terhadap Tekstur Daging," *Blantika: Multidisciplinary journal*, vol. 2, no. 2, 2023.
- [4] Dinas Pertanian Kabupaten/Kota, "Produksi Tanaman Buah-buahan 2023," 2024. Accessed: Oct. 13, 2024. [Online]. Available: <https://www.bps.go.id/id/statistics-table/2/NjljMg==/produksi-tanaman-buah-buahan.html>
- [5] D. Fatmawati, S. Sutrisno, and P. Parlan, "Isolasi, karakterisasi, identifikasi, dan uji aktivitas antibakteri trigliserida biji mangga golek (*Mangifera indica* Linn)," *Jurnal MIPA dan Pembelajarannya*, vol. 2, no. 2, pp. 114–123, 2021.
- [6] S. Syamsuri, H. Alang, and H. Hafsah, "Pembuatan Asam Mangga Sebagai Upaya Meningkatkan Nilai Ekonomi Mangga di Desa Kanje Sulawesi Barat," *Jurnal ABDINUS: Jurnal Pengabdian Nusantara*, vol. 7, no. 3, pp. 758–767, 2023.
- [7] H. dan P. Direktorat Statistik Tanaman Pangan, "Statistik Hortikultura 2023," 2024. Accessed: Oct. 13, 2024. [Online]. Available: <https://www.bps.go.id/id/publication/2024/06/10/790c957ba8892f9771aeefb7/statistik-hortikultura-2023.html>
- [8] V. N. Lawalata and S. G. Sipahelut, "Pengolahan Fruit Leather Mangga Golek di Desa Mornaten, Kecamatan Taniwel Kabupaten Seram Bagian Barat," *HIRONO: Jurnal Pengabdian Masyarakat*, vol. 2, no. 1, 2022.
- [9] B. Zhang *et al.*, "Effects of Harvest Maturity on the Fruit Quality of Different Flesh-Type Peach Stored at Near-Freezing Point Temperature," *Foods*, vol. 11, no. 15, 2022.
- [10] H. Khotimah, N. Nafi'iyah, and Masruroh, "Klasifikasi Kematangan Buah Mangga Berdasarkan Citra HSV dengan KNN," *Jurnal Elektronika Listrik dan Teknologi Informasi Terapan*, vol. 1, no. 2, pp. 4–7, 2020.
- [11] H. Edha, S. H. Sitorus, and U. Ristian, "Penerapan Metode Transformasi Ruang Warna Hue Saturation Intensity (HSI) Untuk Mendeteksi Kematangan Buah Mangga Harum Manis," *CODING Jurnal Komputer dan Aplikasi*, vol. 8, no. 1, 2020.
- [12] A. M. Syafi'i, M. F. Ahadi, M. I. Rasyid, F. D. Adhinata, and A. Junaidi, "Mendeteksi Kematangan Pada Buah Mangga Garifta Merah Dengan Transformasi Ruang Warna HSI," *Journal of Applied Informatics and Computing*, vol. 5, no. 2, pp. 117–121, 2021.
- [13] A. Syarifah, A. A. Riadi, and A. Susanto, "Klasifikasi Tingkat Kematangan Jambu Bol Berbasis Pengolahan Citra Digital Menggunakan Metode K-Nearest Neighbor," *Jurnal Informatika Merdeka Pasuruan*, vol. 7, no. 1, pp. 27–35, 2022.
- [14] S. Siagian, K. Iknutama, and R. Mahyuni, "Implementasi Metode Ekstraksi Ciri Warna Untuk Mendeteksi Kematangan Buah Jeruk," *Jurnal Sistem Informasi Triguna Dharma (JURSI TGD)*, vol. 1, no. 6, pp. 898–905, 2022.
- [15] F. H. Laia, R. Rosnelly, K. Buulolo, M. C. Lase, and A. Naswar, "Klasifikasi Kematangan Buah Mangga Madani Berdasarkan Bentuk Dengan Jaringan Syaraf Tiruan Metode Perception," *Device*, vol. 13, no. 1, pp. 14–20, 2023.
- [16] A. Arjun, "Klasifikasi Citra Pada Tingkat Kematangan Buah Pisang Menggunakan Algoritma Deep Learning," *JEMSI: Jurnal Ekonomi Manajemen Sistem Informasi*, vol. 5, no. 3, pp. 203–208, 2024.
- [17] R. N. J. S. Intam, A. Raihan, M. Alfajri, A. B. Kaswar, D. D. Andayani, and Asnidar, "Sistem Klasifikasi Jenis Sampah Berdasarkan Kombinasi Fitur Warna Tekstur Menggunakan Artificial Neural Network Berbasis Pengolahan Citra Digital," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 2, pp. 411–420, Jul. 2024.
- [18] M. Mellyadi and P. Harlana, "Segmentasi Citra Satelit dalam Observasi dan Konservasi Hutan Lindung Taman Nasional Gunung Lauser Menggunakan Algoritma Fuzzy C-Means," *Hello World Jurnal Ilmu Komputer*, vol. 1, no. 2, pp. 90–96, 2022.
- [19] I. A. Sulisty, P. A. Sesotyo, and T. D. Cahyono, "Ekstraksi Ciri Citra Bentuk Sel Darah Merah Menggunakan Metode Morfologi," 2024. Accessed: Dec. 07, 2024. [Online]. Available: <https://repository.usm.ac.id/detail-penelitian-487.html>
- [20] N. I. Humaira B, M. Herman, Nurhikma, and A. B. Kaswar, "Klasifikasi Tingkat Kualitas dan Kematangan Buah Tomat Berdasarkan Fitur Warna Menggunakan Jaringan Syaraf Tiruan," *JESSI: Journal of Embedded Systems, Security and Intelligent Systems*, vol. 2, no. 1, pp. 18–23, 2021.
- [21] A. N. Dzulhijjah, S. Anraeni, and Sugiarti, "Klasifikasi Kematangan Citra Labu Siam Menggunakan Metode KNN (K-Nearest Neighbor) Dengan Ekstraksi Fitur HSV (Hue, Saturation, Value)," *Buletin Sistem Informasi dan Teknologi Islam (BUSITI)*, vol. 2, no. 2, pp. 103–110, 2021.
- [22] R. S. Ilhamy and U. P. Sanjaya, "Algoritma K-Nearest Neighbors (KNN) untuk Klasifikasi Citra Buah Pisang dengan Ekstraksi Ciri Gray Level Co-Occurrence," *Jurnal Telematika*, vol. 17, no. 2, 2022.
- [23] B. Liu *et al.*, "Research Progress on Mango Post-Harvest Ripening Physiology and the Regulatory Technologies," *Foods*, vol. 12, no. 173, 2023.