

Analisis Performa K-Nearest Neighbor Berdasarkan Ekstraksi Fitur Warna untuk Identifikasi Kematangan Mangga Podang

^{1*}Muhammad Wahyu Rifa'i, ²Danang Wahyu Widodo, ³Patmi Kasih

^{1,2,3} Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ¹[*¹wahyurifa49@gmail.com](mailto:wahyurifa49@gmail.com), ²danangwahyuwidodo@unpkediri.ac.id, ³patmikasih@unpkdr.ac.id

Penulis Korespondens : Muhammad Wahyu Rifa'i

Abstrak— Mangga Podang merupakan salah satu varietas mangga lokal khas Kediri yang memiliki rasa asam manis, Tetapi dalam Pemasaran Mangga Podang kerap melibatkan praktik pematangan buatan menggunakan kalsium karbida yang dapat meninggalkan residu logam berbahaya. Penelitian ini bertujuan untuk menganalisis kematangan mangga secara otomatis menggunakan algoritma K-Nearest Neighbor (KNN) berdasarkan ekstraksi fitur warna. Dataset yang digunakan berjumlah 400 citra Mangga Podang yang didistribusikan secara seimbang menjadi 200 citra matang alami dan 200 citra matang buatan. Proporsi data dibagi menjadi 70%/(280) gambar untuk data latih dan 30%/(120) gambar untuk data validasi kemudian di uji menggunakan 80 citra mangga podang. Nilai fitur warna primer yang diekstraksi dari citra ditetapkan ke dalam kategori data statis untuk kebutuhan pemodelan algoritma. Evaluasi model dilakukan melalui dua skenario ekstraksi fitur ruang warna, yaitu kombinasi Histogram HSV dan HSI serta kombinasi Histogram HSV dan RGB. Hasil penelitian menunjukkan bahwa skenario kedua (HSV dan RGB) menghasilkan performa klasifikasi yang lebih unggul dengan akurasi keseluruhan sebesar 78% pada parameter K=7, yang terbukti paling stabil untuk menghindari overfitting. Sementara itu, pengujian pada skenario pertama (HSV dan HSI) mencapai akurasi optimal sebesar 70% menggunakan parameter K=13. Pemodelan sistem deteksi ini juga telah diintegrasikan dengan sukses ke dalam antarmuka aplikasi berbasis web menggunakan kerangka kerja Flask.

Kata Kunci— ekstraksi fitur warna, HSV, HSI, k-nearest neighbor, kematangan mangga.

Abstract— Podang Urang Mango is a typical local mango variety from Kediri that has a sweet and sour taste. However, the marketing of Podang Urang Mango often involves artificial ripening practices using calcium carbide, which can leave harmful metal residues. This study aims to automatically analyze mango ripeness using the K-Nearest Neighbor (KNN) algorithm based on color feature extraction. The dataset used consists of 400 Podang Urang Mango images, evenly distributed into 200 naturally ripened images and 200 artificially ripened images. The data proportion was divided into 70%/(280) images for training data and 30%/(120) images for validation data, and then tested using 80 Podang Urang Mango images. The primary color feature values extracted from the images were assigned to the static data category for algorithmic modeling needs. Model evaluation was conducted through two color space feature extraction scenarios: a combination of HSV and HSI Histograms, and a combination of HSV and RGB Histograms. The results showed that the second scenario (HSV and RGB) produced superior classification performance with an overall accuracy of 78% at the K=7 parameter, which proved to be the most stable for avoiding overfitting. Meanwhile, testing on the first scenario (HSV and HSI) achieved an optimal accuracy of 70% using the K=13 parameter. This detection system modeling has also been successfully integrated into a web-based application interface using the Flask framework.

Keywords— color feature extraction, HSV, HSI, k-nearest neighbor, mango ripeness,

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Mangga Podang merupakan salah satu komoditas buah unggulan khas dari Kabupaten Kediri yang sangat diminati oleh masyarakat karena cita rasanya yang manis dan aromanya yang kuat. Berbagai varietas mangga Podang, seperti varietas Urang, Lumut, dan Gunung, memiliki karakteristik morfologi yang unik baik dari segi warna kulit dan tekstur daging buahnya [1]. Tingginya permintaan pasar sering kali mendorong sebagian petani atau pedagang untuk melakukan praktik pematangan buatan guna mempercepat proses distribusi panen. Praktik pematangan paksa ini tidak hanya memengaruhi profil nutrisi pada bagian daging buah maupun kulitnya, tetapi juga dapat menurunkan potensi pemanfaatan berkelanjutan dari komoditas tersebut [2].

Salah satu bahan kimia yang sering disalahgunakan dalam proses pematangan buatan adalah kalsium karbida (karbit) yang memicu pematangan secara instan. Penggunaan bahan kimia ini terbukti dapat meninggalkan residu logam berbahaya pada buah, yang apabila dikonsumsi secara terus-menerus akan berisiko buruk bagi kesehatan [3]. Oleh karena itu, diperlukan sebuah terobosan teknologi berbasis pengolahan citra digital yang mampu mengidentifikasi mangga Podang matang alami dan buatan secara otomatis. Teknologi pengolahan citra digital telah terbukti efektif dalam mendeteksi dan mengklasifikasikan jenis buah-buahan berdasarkan ekstraksi fitur visualnya secara non-destruktif [4].

Berdasarkan permasalahan diatas penelitian ini bertujuan untuk mengembangkan sistem deteksi Mangga Podang Alami & Buatan, pemanfaatan fitur warna seperti HSI, RGB dan HSV sangat berpengaruh juga dari cahaya menjadi salah satu parameter paling krusial karena perubahan warna kulit buah merupakan indikator utama dari proses fisiologis pematangan. Analisis ruang warna pada citra digital mampu menangkap pola spesifik dari degradasi warna yang tidak selalu dapat dibedakan dengan mata telanjang [5]. Dalam penerapan sistem cerdas, algoritma K-Nearest Neighbor (KNN) menjadi salah satu metode klasifikasi yang paling direkomendasikan karena model algoritmanya yang sederhana namun memiliki performa tinggi. Algoritma KNN bekerja dengan sangat baik untuk mengkategorikan objek ke dalam kelas kematangan yang berbeda dengan menghitung jarak kedekatan fitur data [6]. Keunggulan algoritma KNN juga terlihat dari kemampuannya menghasilkan tingkat akurasi yang stabil saat diterapkan pada dataset visual buah-buahan tropis. Selain itu, algoritma ini sangat tangguh ketika digunakan untuk membedakan kelas kematangan buah jika dibandingkan dengan beberapa metode pembelajaran mesin klasifikasi lainnya [7].

II. METODE PENELITIAN

Penelitian ini menggunakan desain penelitian dan pengembangan (Research and Development / R&D) untuk mentransformasikan model komputasi yang terbagi ke dalam beberapa tahapan prosedur sistematis, dimulai dari akuisisi data, ekstraksi fitur, hingga proses klasifikasi. Dataset yang digunakan terdiri dari 400 citra potret mangga Podang yang kemudian dibagi secara proporsional menjadi proporsi data valid dan data latih Tahapan berikutnya adalah prapemrosesan dan ekstraksi ciri, di mana setiap gambar yang telah diakuisisi akan diekstrak nilai

fitur warna dasarnya menggunakan ruang warna citra digital [8]. Proses ekstraksi fitur ini berperan sangat penting untuk menerjemahkan persepsi visual kematangan buah ke dalam nilai matematis agar dapat diproses oleh mesin [9].

Setelah nilai fitur warna berhasil diekstrak, data statistik tersebut diklasifikasikan secara komputasi menggunakan algoritma *K-Nearest Neighbor* dengan perhitungan metrik jarak *Euclidean*. Penentuan nilai parameter *K* (tetangga terdekat) dilakukan melalui pengujian beberapa skenario nilai *K* yang berbeda untuk menemukan hasil klasifikasi yang paling optimal serta mencegah terjadinya fenomena *overfitting* [10]. Pengujian performa model dievaluasi secara menyeluruh menggunakan *confusion matrix* pada berbagai skenario dataset, meliputi citra alami, hasil *cropping*, dan data gabungan. Hasil pengklasifikasian dengan akurasi terbaik ini pada tahap selanjutnya berpotensi untuk diimplementasikan ke dalam sebuah antarmuka sistem agar dapat digunakan secara praktis oleh pengguna [11].

A. Subjek, Bahan, dan Alat Penelitian

Bahan utama penelitian ini adalah gambar buah/citra Mangga Podang (kategori Matang Alami dan Matang Buatan) yang menggunakan kamera dengan kondisi pencahayaan dan latar belakang yang relatif sama untuk menjaga konsistensi kualitas citra. Sistem ini dibangun menggunakan fondasi bahasa pemrograman Python 3.10. Proses pengolahan citra mengandalkan pustaka OpenCV, sementara perancangan model machine learning untuk algoritma *K-Nearest Neighbor* (KNN) bertumpu pada pustaka Scikit-learn. Untuk kebutuhan aksesibilitas dan pengembangan antarmuka sistem, aplikasi ini diintegrasikan melalui framework Flask.

B. Variabel Penelitian

Variabel independen dalam pemodelan ini adalah parameter *K* (jumlah tetangga terdekat) pada algoritma KNN, sedangkan variabel dependennya meliputi tingkat akurasi dan kinerja klasifikasi. Adapun data *input* berupa nilai fitur warna primer yang diekstraksi dari citra ditetapkan ke dalam kategori data statis.

$$d(p, q) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (1)$$

C. Rancangan Percobaan dan Evaluasi Model


Eksperimen komputasi mengevaluasi performa KNN melalui 2 skenario ekstraksi fitur warna yaitu: HSV, HSI dan HSV, RGB. Kinerja setiap skenario dievaluasi secara statistik menggunakan *Confusion Matrix* untuk mengukur metrik Akurasi, Presisi, *Recall*, dan *F1-Score*.

D. Pengumpulan dan Pembagian Dataset

Penelitian menggunakan 400 citra primer yang terbagi seimbang (200 matang alami dan 200 matang buatan/karbitan) pada gambar 2.1. Kemudian gambar dimasukkan ke dalam aplikasi roboflow untuk proses *cropping* pada gambar 2.2. Guna mencegah *overfitting*, proporsi data didistribusikan menjadi: 70% Data Latih (untuk pembentukan ruang fitur) dan 30% Data Validasi (untuk penyesuaian nilai *K*). Gambar di bawah merupakan gambar/citra yang belum di roboflow dan sesdual di roboflow.



Gambar 1. Citra Mangga Podang sebelum di roboflow




Gambar 2. Citra Mangga Podang Setelah di roboflow

E. Prosedur Penelitian

Seluruh tahapan dieksekusi secara sistematis (divisualisasikan pada diagram alir Gambar 2.2) dengan urutan sebagai berikut:

1. Pengumpulan Data: Akuisisi 400 citra Mangga Podang dari kedua kelas uji.
2. Prapemrosesan: Penyesuaian ukuran citra menjadi 224×224 piksel dan normalisasi nilai matriks menggunakan OpenCV.
3. Pembagian Data: Distribusi dataset ke dalam data latih (70%) dan validasi (30%).
4. Ekstraksi & Pemodelan: Ekstraksi fitur visual ruang warna histogram HSV, HSI dan HSV, RGB, dilanjutkan dengan pelatihan klasifikasi KNN melalui pengujian variasi parameter K .
5. Evaluasi Model: Pengujian ketahanan dan keakuratan model pada ketiga skenario dataset menggunakan *Confusion Matrix*.
6. Implementasi Sistem: Integrasi model KNN terpilih ke dalam antarmuka *web* responsif menggunakan kerangka kerja Flask.
7. Pengujian Fungsional: Validasi kinerja aplikasi (unggah citra, kecepatan ekstraksi, dan akurasi prediksi visual) menggunakan metode *Black Box Testing*.



Gambar 3. Diagram Alir Proses Penelitian.

III. HASIL DAN PEMBAHASAN

A. Evaluasi performa algoritma K-Nearest Neighbor (KNN)

Evaluasi performa algoritma K-Nearest Neighbor (KNN) berbasis ekstraksi warna HSV, HSI dan HSV, RGB, dilakukan melalui tiga skenario dataset. Hasil pengujian divisualisasikan melalui tabel parameter K dan *Confusion Matrix* yang divalidasi menggunakan 80 citra uji statis.

1. Analisis Skenario 1 (Histogram HSV & HSI)

Tabel 1. Tabel Pencarian K Terbaik

Nilai K	Akurasi	Presisi Matang alami	Presisi Matang Buatan
1	43.75%	0.00	0.47
3	50.00%	0.00	0.50
5	38.75%	0.09	0.43
7	46.25%	0.20	0.48
9	42.50%	0.33	0.45
11	67.50%	0.61	0.94
13	70.00%	0.62	1.00
15	68.75%	0.62	1.00
17	70.00%	0.62	1.00
19	70.00%	0.62	1.00
21	70.00%	0.62	1.00
23	67.50%	0.61	1.00
25	63.75%	0.59	0.79
27	70.00%	0.62	1.00
29	71.25%	0.63	1.00


Berdasarkan analisis performa, model *K-Nearest Neighbor* diatas menunjukkan akurasi yang buruk dan fluktuatif pada parameter K rendah (K=1 hingga K=9). Kinerja model baru mengalami lonjakan dan mencapai tingkat stabilitas (*plateau*) di angka akurasi 70.00% pada rentang interval K=13 hingga K=27. Meskipun akurasi puncak secara matematis berada pada K=29 (71.25%), parameter K=13 ditetapkan sebagai konfigurasi yang paling optimal karena menjadi titik awal memasuki fase stabil yang panjang dan telah mampu menghasilkan tingkat presisi absolut (1.00) dalam memprediksi kelas Mangga Matang Buatan.

Tabel 2. Tabel Akurasi

Kelas	Presisi	Recall	F1-score	Akurasi
Matang alami	0.62	1	0.77	70%
Matang Buatan	1	0.40	0.57	70%

Berdasarkan tabel pada 2, model klasifikasi memiliki akurasi keseluruhan sebesar 70%. Model ini sangat baik dalam mengenali seluruh sampel kelas "Matang alami" (Recall: 1) dan memiliki ketepatan prediksi sempurna pada kelas "Matang Buatan" (Presisi: 1). Namun, performanya kurang seimbang karena kelas "Matang alami" sering salah mendeteksi kelas lain (Presisi: 0.62), sementara kelas "Matang Buatan" banyak melewatkan data yang seharusnya terdeteksi (Recall: 0.40).

Setelah menetapkan nilai parameter K terbaik dan metrik evaluasi model selanjutnya diukur secara komprehensif menggunakan *Confusion Matrix*. Metode ini bertujuan untuk memetakan secara jelas rincian jumlah data uji yang berhasil ditebak dengan benar maupun yang mengalami kesalahan prediksi pada tiap-tiap kelas.



Gambar 4. *Confusion Matrix*

Hasil pengujian model divisualisasikan melalui Confusion Matrix guna melihat perbandingan antara label prediksi sistem dengan label data yang sebenarnya. Uraian lengkap mengenai performa model berdasarkan matriks tersebut, termasuk jumlah prediksi yang tepat sasaran maupun yang meleset, dapat ditinjau lebih lanjut pada Tabel 3.

Tabel 3. Tabel Hasil Dari Data Uji

Kategori	Akurasi	Presisi Matang alami
Terdeteksi Benar	56	40 (Matang Alami) + 16 (Matang Buatan)
Terdeteksi Salah	24	0 (Alami diprediksi Buatan) + 24 (Buatan diprediksi Alami)
Total keseluruhan	80	Total seluruh sampel data pengujian

Berdasarkan pengujian terhadap 80 sampel data, pemodelan sistem berhasil memprediksi 56 citra secara akurat, yang terdiri dari 40 kelas matang alami dan 16 kelas matang buatan. Sementara itu, 24 galat prediksi yang terjadi seluruhnya disebabkan oleh kelemahan model yang keliru mengklasifikasikan potret mangga matang buatan sebagai matang alami.

Kesimpulannya, ekstraksi fitur warna Histogram HSV dan HSI pada skenario pertama cukup baik untuk diimplementasikan sebagai penetapan kategori data statis masukan. Parameter $K=13$ direkomendasikan sebagai konfigurasi optimal untuk sistem deteksi akhir karena pada titik inilah model mulai memasuki fase kestabilan performa (*plateau*) dengan tingkat akurasi yang cukup baik, yaitu sebesar 70,00%.

2. Analisis Skenario 2 (Histogram HSV dan RGB)

Tabel 4. Tabel Pencarian K Terbaik

Nilai K	Akurasi	Presisi Matang Alami	Presisi Matang Buatan
1	81.25%	0.80	0.82
3	55.00%	0.70	0.53
5	72.50%	0.88	0.66
7	77.50%	0.87	0.72
9	65.00%	0.83	0.60
11	56.25%	0.86	0.53
13	58.75%	0.89	0.55
15	56.25%	1.00	0.53
17	53.75%	1.00	0.52
19	53.75%	1.00	0.52
21	52.50%	1.00	0.51
23	52.50%	1.00	0.51
25	53.75%	1.00	0.52
27	53.75%	1.00	0.52
29	53.75%	1.00	0.52

Meskipun akurasi puncak tercapai pada $K=1$ (81,25%), rentannya penurunan dan risiko overfitting menjadikan $K=7$ sebagai pilihan konfigurasi yang lebih stabil dan optimal untuk mempertahankan akurasi lokal tertinggi (77,50%). Namun, jika fokus utama pemodelan adalah memastikan tingkat presisi yang sempurna (1,00) untuk mendeteksi mangga matang alami tanpa adanya kesalahan prediksi, jangkauan parameter dapat diperlebar hingga $K=15$ yang menandai


awal dari fase stabilitas (plateau) presisi pada model. Setelah Pencarian K terbaik berikut hasil dari evaluasi matrik pada tabel 5.

Tabel 5. Akurasi

Kelas	Presisi	Recall	F1-score	Akurasi
Matang alami	0.87	0.65	0.74	78%
Matang Buatan	0.72	0.90	0.80	78%

Berdasarkan Tabel 3.5, model mencapai akurasi keseluruhan sebesar 78%. Meskipun sistem lebih presisi saat menebak kelas matang alami (0,87), sensitivitas (*recall*) untuk kelas matang buatan jauh lebih unggul (0,90). Perbandingan nilai *F1-score* (0,80 berbanding 0,74) menyimpulkan bahwa secara keseluruhan, model lebih optimal dan seimbang dalam mengenali mangga matang buatan (karbitan).

Setelah menetapkan nilai parameter K terbaik dan Metrik evaluasi performa model selanjutnya diukur secara komprehensif menggunakan *Confusion Matrix*. Metode ini bertujuan untuk memetakan secara jelas rincian jumlah data uji yang berhasil ditebak dengan benar maupun yang mengalami kesalahan prediksi pada tiap-tiap kelas.



Gambar 5. Confusion Matrix

Berdasarkan *Confusion Matrix* yang dihasilkan, performa model dalam mengklasifikasikan kelas matang alami dan buatan dapat dievaluasi secara mendalam. Penjelasan detail mengenai rincian angka prediksi benar dan salah pada masing-masing kategori telah diuraikan pada Tabel 6.

Tabel 6. Tabel Hasil Dari Data Uji

Kategori	Jumlah Data	Hasil
Terdeteksi Benar	62	26 (Matang Alami) + 36 (Matang Buatan)
Terdeteksi Salah	18	14 (Alami diprediksi Buatan) + 4 (Buatan diprediksi Alami)
Total keseluruhan	80	Total seluruh sampel data pengujian

Pada skenario kedua (gabungan fitur RGB dan HSV), sistem berhasil memprediksi 62 citra dengan tepat dan menyisakan 18 galat. Karena akurasi puncak di K=1 (81,25%) sangat rentan *overfitting*, parameter K=7 (77,50%) ditetapkan sebagai konfigurasi optimal yang lebih stabil. Kesimpulannya, ekstraksi fitur gabungan ini terbukti efektif sebagai masukan data statis. Apabila pemodelan memprioritaskan presisi sempurna (1,00) khusus pada deteksi mangga matang alami, parameter dapat diperlebar hingga rentang K=15.


Berdasarkan kedua skenario diatas jadi dapat disimpulkan skenario ke dua lebih baik daripada skenario pertama dengan akurasi mencapai 78%, Angka ini cukup mumpuni sebagai modeling dalam program. Pada gambar 6 contoh pengujian Data yang benar dan salah prediksi.



Gambar 6. Prediksi hasil dari data uji sejumlah 10 citra

B. Hasil Implementasi Sistem

Untuk memfasilitasi kebutuhan klasifikasi di masyarakat, algoritma yang telah dilatih kemudian diintegrasikan ke dalam tampilan antarmuka. Berdasarkan hasil evaluasi pengujian performa sebelumnya, sistem deteksi ini diimplementasikan secara final gambaran saat pengguna mengakses sistem disajikan pada Gambar 7.



Gambar 7. Tampilan Sistem Deteksi Mangga Podang Alami atau buatan

IV. KESIMPULAN

Kesimpulan Berdasarkan Penelitian ini berhasil membangun sistem klasifikasi untuk mengidentifikasi Mangga Podang matang alami dan buatan menggunakan algoritma K-Nearest Neighbor (KNN) berbasis ekstraksi warna, yang kemudian diimplementasikan secara fungsional ke dalam antarmuka web interaktif menggunakan kerangka kerja Flask.

Berdasarkan hasil pengujian komputasi, skenario kedua yang menggunakan kombinasi ekstraksi fitur ruang warna HSV dan RGB terbukti memberikan hasil prediksi yang lebih baik dibandingkan skenario pertama (HSV dan HSI).

Pemodelan pada skenario gabungan HSV dan RGB tersebut mampu mencapai tingkat akurasi keseluruhan sebesar 78%, sebuah angka yang disimpulkan sudah cukup mumpuni untuk dijadikan standar perancangan model di dalam program aplikasi.

Penetapan parameter ketetanggaan $K=7$ diputuskan sebagai konfigurasi yang paling stabil dan optimal pada skenario terbaik guna mempertahankan akurasi lokal tertinggi dan menghindari risiko overfitting yang sangat rentan terjadi pada titik puncak $K=1$.

Jika sistem kelak diatur untuk memprioritaskan tingkat presisi sempurna (1,00) agar sama sekali tidak ada kesalahan prediksi pada mangga matang alami, jangkauan evaluasi parameter tetangga dapat diperlebar hingga $K=15$.

UCAPAN TERIMAKASIH

Terima kasih yang sebesar-besarnya kepada semuanya atas dedikasi waktu, bimbingan, serta saran-saran yang sangat membangun selama proses penelitian dan rekan-rekan yang sangat membantu motivasi hingga penyelesaian artikel ini. Ucapan terima kasih juga ditujukan kepada program studi Teknik Informatika Universitas Nusantara PGRI Kediri atas fasilitas dan dukungan akademik yang telah diberikan. Tidak lupa, penulis juga mengapresiasi dukungan moral dan doa dari keluarga, serta rekan-rekan yang selalu memberikan semangat di setiap tahapan penyelesaian penelitian ini.

DAFTAR PUSTAKA

- [1] dan Pembelajaran, J. Dina Wahyu Niken, E. Herawati, and A. Muji Santoso, "Karakteristik Varian Mangga Podang Asal Kediri dan Potensi Olahannya," *Pros. Semin. Nas. Kesehatan, Sains dan Pembelajaran*, vol. 3, no. 1, pp. 191–195, Feb. 2024, doi: 10.29407/0BQ5Q840.
- [2] S. Samudi, E. Rohana, and T. Irawati, "Karakteristik Nilai Nutrisi Limbah Kulit Buah Mangga Podang (*Mangifera indica* L.) di Kabupaten Kediri," *JAMI J. Ahli Muda Indones.*, vol. 5, no. 1, pp. 24–27, Jun. 2024, doi: 10.46510/JAMI.V5I1.283.
- [3] P. P. Wahyudi and B. Harsono, "Identifikasi Mangga Arumanis yang Dimatangkan dengan Kalsium Karbida (CaC_2) Menggunakan Metode Spektroskopi," *Techné J. Ilm. Elektrotek.*, vol. 22, no. 1, pp. 143–156, Apr. 2023, doi: 10.31358/TECHNE.V22I1.368.
- [4] A. R. Juwita, C. E. Sukmawati, A. R. Pratama, R. S. Bijokangko, and A. Susilo, "BULLETIN OF COMPUTER SCIENCE RESEARCH Identifikasi Jenis Buah Apel berdasarkan Ekstraksi Ciri Warna Fitur HSV dengan Model Jaringan Syaraf Tiruan Backpropagation," vol. 6, no. 2, pp. 784–792, 2026, doi: 10.47065/bulletincsr.v6i2.1010.
- [5] K. Kematangan Daun Kayu Putih Berdasarkan Citra Warna Hsi Dan Xyz Dengan Menggunakan Metode Knn *et al.*, "KLASIFIKASI KEMATANGAN DAUN KAYU PUTIH BERDASARKAN CITRA WARNA HSI DAN XYZ DENGAN MENGGUNAKAN METODE KNN," *IJIS - Indones. J. Inf. Syst.*, vol. 10, no. 2, pp. 224–235, Sep. 2025, doi: 10.36549/IJIS.V10I2.433.
- [6] K. Tingkat *et al.*, "KLASIFIKASI TINGKAT KEMATANGAN PARIJOTO BERDASARKAN KARAKTERISTIK WARNA MENGGUNAKAN ALGORITMA K-NEAREST NEIGHBOR," *J. Digit Digit. Inf. Technol.*, vol. 15, no. 1, pp. 30–40, Jun. 2025, doi: 10.51920/JD.V15I1.419.
- [7] M. Muchtar and R. A. Muchtar, "PERBANDINGAN METODE KNN DAN SVM DALAM KLASIFIKASI KEMATANGAN BUAH MANGGA BERDASARKAN CITRA HSV DAN FITUR STATISTIK," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 2, pp. 2830–7062, Apr. 2024, doi: 10.23960/JITET.V12I2.4010.
- [8] R. Artikel *et al.*, "Deteksi Tingkat Kematangan Buah Mangga Berdasarkan Fitur Warna Menggunakan Pengolahan Citra Digital Mango Ripeness Detection Based on Color Features

- Using Digital Image Processing,” vol. 11, pp. 240–250, 2025.
- [9] H. A. Ramadhan, I. Komputer, U. Islam, and N. Sumatera, “Klasifikasi Tingkat Kematangan Buah Salak Sidempuan Menggunakan K-Nearest Neighbor pada Ruang Warna HSV,” vol. 4, no. 4, pp. 997–1012, 2025, doi: 10.55123/insologi.v4i4.6298.
- [10] Y. Nahdiyah, D. Swanjaya, M. Kom, R. A. Ramadhani, and S. Geges, “Sistem Diagnosa Dini Menstrual Disorders Dengan K-NN,” *Agustus*, vol. 8, pp. 2549–7952, 2024.
- [11] T. Informatika and U. H. Medan, “Analisis Tingkat Kematangan Buah Jeruk Menggunakan Chain Code Dan KNN (K-Nearest Neighbors) Berbasis Website,” no. November, pp. 84–99, 2025, doi: 10.30829/algorithm.v9i2.258998.