

OPTIMASI *HYBRID INTELLIGENT SYSTEM* UNTUK IDENTIFIKASI BUAH: STUDI KASUS PISANG DAN APEL

Rahma Yanti^{1*}; Agung Ramadhanu²

Magister Teknik Informatika^{1,2}

Universitas Putra Indonesia YPTK Padang, Padang, Indonesia^{1,2}

<https://upiypk.ac.id/>^{1,2}

rahmayanti210602@gmail.com^{1*}, agung_ramadhanu@upiypk.ac.id²

(*) Corresponding Author



Ciptaan disebarluaskan di bawah Lisensi Creative Commons Atribusi-NonKomersial 4.0 Internasional.

Abstract— *Image processing-based fruit classification is one of the rapidly growing applications of technology in the field of digital agriculture. This research aims to develop a fruit identification system, specifically yellow bananas, green bananas, and apples, by utilizing the K-Nearest Neighbors (KNN) and Principal Component Analysis (PCA) methods. The background of this research is the need for an accurate automated system to distinguish fruit types based on visual characteristics, such as color, texture, and shape, in order to support the distribution and management process of agricultural products. The method used in this research involves four main stages: image loading, segmentation, feature extraction, and classification. PCA was used to reduce the dimensionality of the data while retaining the main relevant features, while KNN served for classification based on the closest distance between the test and training data. The dataset used consists of 130 images, with 120 images as training data and 10 images as test data. The results show that the developed system is able to classify all test data with 90% accuracy. The model evaluation also showed 100% precision, 90% recall, and 94.7% F1-Score, indicating a good balance between classification accuracy and the system's ability to recognize data variations. This success proves that the combination of PCA and KNN methods is effective in identifying fruit types based on the extracted visual characteristics, and the system is expected to serve as a basis for further development in the field of automatic fruit classification.*

Keywords: *fruit classification, KNN, PCA.*

Abstrak— Klasifikasi buah berbasis pemrosesan citra merupakan salah satu aplikasi teknologi yang berkembang pesat di bidang pertanian digital. Penelitian ini bertujuan untuk mengembangkan sistem identifikasi buah, khususnya pisang kuning, pisang hijau, dan apel, dengan memanfaatkan metode *K-Nearest Neighbors* (KNN) dan *Principal Component Analysis* (PCA). Latar belakang penelitian ini adalah kebutuhan akan sistem otomatis yang akurat untuk membedakan jenis buah berdasarkan karakteristik visual, seperti warna, tekstur, dan bentuk, guna mendukung proses distribusi serta manajemen produk pertanian. Metode yang digunakan dalam penelitian ini mencakup empat tahap utama: pemuatan citra, segmentasi, ekstraksi fitur, dan klasifikasi. PCA digunakan untuk mereduksi dimensi data dengan tetap mempertahankan fitur utama yang relevan, sedangkan KNN digunakan untuk klasifikasi berdasarkan jarak terdekat antara data uji dan data latih. Dataset yang digunakan terdiri dari 130 citra, dengan 120 citra sebagai data latih dan 10 citra sebagai data uji. Hasil penelitian menunjukkan bahwa sistem yang dikembangkan mampu mengklasifikasikan seluruh data uji dengan akurasi 90%. Evaluasi model juga menghasilkan precision 100%, recall 90%, dan F1-Score 94,7%, yang menunjukkan keseimbangan yang baik antara akurasi klasifikasi dan kemampuan sistem dalam mengenali variasi data. Keberhasilan ini membuktikan bahwa kombinasi metode PCA dan KNN efektif dalam mengidentifikasi jenis buah berdasarkan karakteristik visual yang diekstraksi, serta diharapkan dapat menjadi dasar untuk pengembangan lebih lanjut dalam bidang klasifikasi buah otomatis.

Kata kunci: *klasifikasi buah, KNN, PCA.*

PENDAHULUAN

Identifikasi objek merupakan salah satu permasalahan mendasar dalam bidang pengolahan citra digital dan kecerdasan buatan (Jumadi et al., 2021). Dalam beberapa dekade terakhir, teknologi pengolahan citra telah mengalami perkembangan pesat, memungkinkan komputer untuk mengenali dan menganalisis objek dengan tingkat akurasi yang semakin tinggi (Sidiq, 2021). Identifikasi objek memiliki peran yang sangat penting dalam berbagai sektor, termasuk pertanian, kesehatan, keamanan, hingga perdagangan (Zahra et al., 2024). Dalam konteks sektor pertanian, teknologi ini berkontribusi secara signifikan dalam meningkatkan efisiensi operasional, seperti identifikasi jenis buah, pengklasifikasian tingkat kematangan, serta deteksi penyakit tanaman.

Buah merupakan salah satu komoditas penting dalam pertanian global, yang membutuhkan metode identifikasi yang efisien untuk mendukung berbagai aktivitas, mulai dari pengelolaan pasokan hingga proses distribusi (Putra et al., 2023). Dalam konteks ini, pisang dan apel menjadi dua jenis buah yang memiliki nilai ekonomi tinggi dan tersebar luas di seluruh dunia. Pisang dikenal sebagai salah satu buah tropis yang banyak dikonsumsi dan diproduksi di negara berkembang, sementara apel memiliki dominasi yang signifikan di pasar global, khususnya di negara-negara beriklim sedang (Khamidah et al., 2022). Dalam rantai pasokan yang kompleks, identifikasi jenis buah secara otomatis dapat memberikan keuntungan besar, seperti pengurangan waktu pemrosesan, penurunan biaya operasional, dan peningkatan akurasi klasifikasi (Manaek et al., 2023).

Di sisi lain, pengolahan citra digital menjadi salah satu pendekatan yang paling menjanjikan untuk mendukung identifikasi buah secara otomatis. Citra digital, yang merupakan representasi visual objek dalam bentuk data numerik, memungkinkan proses analisis yang lebih cepat dan presisi tinggi (Nuraini et al., 2023). Dengan memanfaatkan teknologi pengolahan citra, komputer dapat mengolah informasi visual dari buah, seperti bentuk, warna, tekstur, hingga ukuran, untuk membedakan jenis buah yang berbeda. Sebagai contoh, citra digital dapat digunakan untuk menganalisis pola tekstur permukaan pisang yang khas dibandingkan apel yang memiliki permukaan lebih halus. Selain itu, teknik pengolahan citra juga dapat mengatasi tantangan seperti variasi kondisi pencahayaan, sudut pengambilan gambar, serta kualitas citra (Nurdiansyah et al., 2024).

Namun, identifikasi buah berdasarkan citra digital bukanlah tugas yang sederhana. Berbagai tantangan teknis muncul, seperti kemiripan visual antara jenis buah tertentu, variasi warna yang dipengaruhi tingkat kematangan, serta noise pada citra yang dihasilkan dari kondisi lingkungan yang tidak ideal (Raysyah et al., 2022). Untuk mengatasi tantangan ini, diperlukan pendekatan yang lebih canggih, yang mampu menangkap dan menganalisis pola kompleks pada data citra. Salah satu pendekatan yang tengah berkembang adalah penerapan *Hybrid Intelligent System*.

Hybrid Intelligent System adalah kombinasi dari beberapa metode kecerdasan buatan, seperti algoritma berbasis logika *fuzzy*, jaringan saraf tiruan, dan teknik optimasi, yang dirancang untuk bekerja secara sinergis. Pendekatan ini menawarkan keunggulan dalam menangani kompleksitas data yang tinggi, meningkatkan akurasi, serta mengurangi kelemahan yang mungkin dimiliki oleh masing-masing metode jika digunakan secara terpisah. Dalam konteks identifikasi buah, *Hybrid Intelligent System* dapat mengintegrasikan kemampuan analisis data visual dari jaringan saraf tiruan dengan fleksibilitas logika *fuzzy* dalam menangani ketidakpastian, serta efisiensi algoritma optimasi dalam meningkatkan kinerja sistem secara keseluruhan (Dombale et al., 2023).

Sebagai contoh, jaringan saraf tiruan dapat digunakan untuk mempelajari pola visual pada citra buah berdasarkan dataset pelatihan, sementara logika *fuzzy* dapat membantu dalam menangani ambiguitas data, seperti membedakan warna pisang yang berubah dari hijau ke kuning seiring tingkat kematangan. Di sisi lain, algoritma optimasi, seperti algoritma genetika atau optimasi kawanan partikel (*Particle Swarm Optimization*), dapat digunakan untuk menyempurnakan parameter model, sehingga meningkatkan akurasi prediksi. Dengan memanfaatkan sinergi ini, *Hybrid Intelligent System* memiliki potensi besar untuk meningkatkan efektivitas dan efisiensi dalam identifikasi buah berdasarkan citra digital dengan menggunakan KNN dan juga PCA (Suahati et al., 2022).

Penggunaan kombinasi PCA dan KNN dalam penelitian ini didasarkan pada keunggulan masing-masing metode. PCA tidak hanya membantu dalam mengatasi masalah redundansi data, tetapi juga meningkatkan kecepatan proses klasifikasi, terutama pada dataset yang memiliki dimensi tinggi seperti citra digital. Sementara itu, KNN menawarkan keunggulan dalam proses pengklasifikasian karena algoritma ini tidak memerlukan asumsi distribusi data, sehingga cocok untuk berbagai jenis pola visual yang kompleks (Koten, 2024).

Penelitian terdahulu oleh Andi Danang dkk (2022) sejalan dengan penelitian ini menunjukkan hasil penelitian menggunakan PCA untuk ekstraksi fitur dan KNN untuk klasifikasi dalam deteksi masker pada wajah. Sistem mencapai akurasi 90% dengan 180 citra latih dan 20 citra uji. Hasil ini mendukung efektivitas kombinasi PCA dan KNN (Danang & Rachmawanto, 2022).

Studi kasus yang diangkat dalam penelitian ini adalah identifikasi pisang dan apel. Pemilihan studi kasus ini didasarkan pada relevansi kedua jenis buah dalam rantai pasokan global serta perbedaan karakteristik visual yang cukup signifikan, seperti bentuk, tekstur, dan warna. Pisang, dengan bentuk melengkung dan warna dominan kuning atau hijau, memiliki tekstur kulit yang khas, sementara apel cenderung berbentuk bulat dengan warna yang bervariasi, seperti merah, hijau, atau kuning, serta permukaan kulit yang lebih halus. Tantangan dalam identifikasi kedua jenis buah ini mencakup variasi tingkat kematangan yang memengaruhi warna dan tekstur, serta kondisi lingkungan yang dapat menghasilkan *noise* pada citra.

Penelitian ini bertujuan untuk menguji algoritma dengan sistem identifikasi buah berbasis *Hybrid Intelligent System*, yang dirancang untuk mengoptimalkan akurasi dan efisiensi dalam membedakan citra pisang dan apel. Sistem ini diharapkan tidak hanya mampu mengenali jenis buah dengan tingkat akurasi yang tinggi, tetapi juga dapat beradaptasi terhadap berbagai kondisi pencahayaan dan kualitas citra. Untuk mencapai tujuan tersebut, penelitian ini mencakup tahapan utama, seperti pengumpulan dan preprocessing data citra, pengembangan arsitektur *Hybrid Intelligent System*, pelatihan dan validasi model, serta evaluasi kinerja sistem berdasarkan parameter seperti akurasi, presisi, dan waktu komputasi.

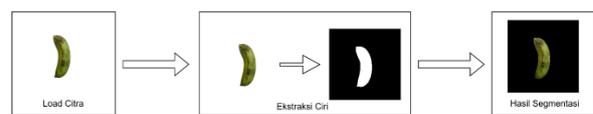
Penelitian ini memberikan kontribusi signifikan dalam bidang pengolahan citra digital dan kecerdasan buatan, khususnya dalam penerapan teknologi untuk sektor pertanian. Dengan mengintegrasikan metode *Hybrid Intelligent System* dalam identifikasi buah, penelitian ini diharapkan dapat membuka peluang baru untuk penerapan teknologi serupa dalam identifikasi objek lain, baik di sektor pertanian maupun sektor lainnya. Selain itu, hasil penelitian ini juga diharapkan dapat memberikan manfaat praktis bagi pelaku industri, seperti petani, pedagang, dan perusahaan logistik, dalam meningkatkan efisiensi operasional dan kualitas layanan.

Berdasarkan latar belakang maka peneliti tertatik mengangkat judul "*Optimasi Hybrid*

Intelligent System untuk Identifikasi Buah: Studi Kasus Pisang dan Apel" berfokus pada pengembangan sistem yang inovatif dan adaptif, yang mampu mengatasi tantangan identifikasi buah dalam kondisi nyata. Penelitian ini tidak hanya berkontribusi dalam pengembangan teknologi pengolahan citra digital, tetapi juga memberikan solusi praktis untuk mendukung pengelolaan rantai pasokan pertanian secara lebih efisien dan berkelanjutan.

BAHAN DAN METODE

Tahapan Penelitian



Sumber: (Hasil Penelitian, 2025)

Gambar 1. Tahapan Penelitian

Tahapan penelitian yang dijelaskan pada Gambar 1 mencakup langkah-langkah yang dilakukan untuk menyelesaikan masalah. Proses diawali dengan memuat citra buah yang akan diuji ke dalam sistem yang telah dikembangkan. Langkah pertama ini adalah proses *load citra*, di mana citra buah yang akan dikenali dimasukkan ke dalam program untuk diproses lebih lanjut. Setelah citra dimasukkan, langkah selanjutnya adalah pemrosesan citra, yang merupakan istilah umum untuk berbagai teknik manipulasi dan analisis citra. Pemrosesan ini bertujuan untuk mengekstraksi informasi penting dari citra, seperti pola, warna, atau fitur geometris, yang dapat digunakan dalam proses identifikasi. Pengolahan citra pada tahap ini bertujuan untuk meningkatkan akurasi klasifikasi dengan menghasilkan data yang relevan untuk dianalisis lebih lanjut.

Langkah berikutnya adalah tahap *segmentasi*, yang dilakukan untuk memisahkan objek utama (seperti pisang atau apel) dari latar belakang. Pada tahap segmentasi ini, citra akan diproses untuk mengidentifikasi area yang relevan dengan objek yang akan dikenali dan menghilangkan bagian-bagian yang tidak penting. Proses segmentasi ini menghasilkan citra biner yang hanya mempertahankan bagian objek yang relevan, memudahkan tahap selanjutnya.

Setelah objek berhasil disegmentasi, tahap berikutnya adalah ekstraksi ciri. Pada tahap ini, fitur-fitur penting dari citra seperti warna, tekstur, dan bentuk di ekstraksi. Untuk mereduksi dimensi data, metode *Principal Component Analysis* (PCA) digunakan. PCA membantu memilih fitur yang paling berkontribusi terhadap variabilitas data dan

mereduksi dimensi data, sehingga data yang dihasilkan lebih efisien dan relevan untuk analisis lebih lanjut. Fitur yang diekstraksi ini nantinya digunakan dalam proses klasifikasi.

Setelah fitur diekstraksi, tahap terakhir adalah *klasifikasi*, di mana data yang telah diproses diklasifikasikan menggunakan algoritma *K-Nearest Neighbors* (KNN). KNN mengklasifikasikan data berdasarkan kedekatan jarak dengan data latih yang sudah dikenal. Algoritma ini bekerja dengan menghitung jarak *Euclidean* antara data uji dan data latih, kemudian mengidentifikasi kategori data berdasarkan mayoritas tetangga terdekat.

Tahap terakhir adalah evaluasi sistem, di mana kinerja algoritma *hybrid* yang menggabungkan PCA dan KNN dianalisis. Evaluasi dilakukan dengan mengukur metrik dalam bentuk akurasi, *recall*, presisi dan *F1-score*. Langkah ini bertujuan untuk memastikan bahwa sistem dapat mengidentifikasi buah dengan tingkat akurasi yang tinggi dan efisiensi yang optimal.

K-Nearest Neighbors (KNN)

K-Nearest Neighbors adalah algoritma *supervised learning* yang bekerja berdasarkan prinsip "kesamaan" antar data (Danang & Rachmawanto, 2022). KNN digunakan baik untuk klasifikasi maupun regresi, di mana klasifikasi dilakukan dengan menentukan kategori suatu data berdasarkan mayoritas tetangga terdekatnya, sementara regresi memperkirakan nilai berdasarkan rata-rata tetangga terdekat (Nuraini et al., 2023).

Cara Kerja KNN

1. Pemilihan Parameter KK

Langkah awal dalam KNN adalah menentukan jumlah tetangga terdekat yang akan digunakan, yaitu KK. Pemilihan nilai KK sangat penting karena dapat memengaruhi performa algoritma. Jika KK terlalu kecil (misalnya $K=1$), algoritma menjadi sangat sensitif terhadap data *outlier* atau *noise*. Sebaliknya, jika KK terlalu besar, hasil klasifikasi dapat menjadi kurang spesifik karena terlalu banyak data tetangga yang dipertimbangkan, yang mungkin berasal dari kategori yang berbeda. Oleh karena itu, nilai KK optimal biasanya diperoleh melalui eksperimen atau validasi silang (Muhammad et al., 2021).

2. Penghitungan Jarak

Setelah KK ditentukan, langkah berikutnya adalah menghitung jarak antara data yang akan diklasifikasikan (data uji) dengan setiap data latih yang tersedia. Algoritma KNN menggunakan metrik jarak untuk mengukur kedekatan antara data uji

dan data latih. Metrik yang paling umum digunakan adalah jarak *Euclidean*.

Di mana $x_{i,j}$ adalah nilai fitur dari data uji dan $y_{i,j}$ adalah nilai fitur dari data latih pada dimensi ke- i . Alternatif lainnya termasuk jarak *Manhattan* atau jarak *Minkowski*, yang dapat digunakan tergantung pada karakteristik data (Rangkuti et al., 2021).

3. Identifikasi Tetangga Terdekat

Setelah semua jarak dihitung, data uji akan dibandingkan dengan seluruh data latih untuk menemukan KK data terdekat. Tetangga terdekat ini ditentukan berdasarkan jarak terkecil yang dihitung pada langkah sebelumnya. Data uji kemudian dianggap sebagai bagian dari tetangga-tetangga tersebut untuk klasifikasi lebih lanjut (Iqbal Mubarak et al., 2024).

4. Penentuan Kategori

Untuk menentukan kategori data uji, algoritma menghitung frekuensi kemunculan setiap kategori di antara KK tetangga terdekat. Kategori dengan frekuensi tertinggi dianggap sebagai kategori dari data uji tersebut. Jika terdapat nilai KK yang sama besar untuk beberapa kategori, beberapa strategi seperti pembobotan berdasarkan jarak dapat digunakan untuk memutuskan kategori akhir.

5. Evaluasi Model

Setelah proses klasifikasi selesai, kinerja KNN dievaluasi menggunakan data uji yang telah diberi label. Metrik seperti akurasi, presisi, *recall*, dan *F1-score* sering digunakan untuk menilai performa algoritma. Jika hasil klasifikasi tidak memuaskan, penyesuaian nilai KK, pemilihan metrik jarak yang berbeda, atau pengolahan data tambahan dapat dilakukan untuk meningkatkan hasil (Cholil et al., 2021).

Keunggulan KNN terletak pada kesederhanaan implementasinya, namun kekurangannya adalah algoritma ini membutuhkan waktu komputasi yang besar saat jumlah data latih dan dimensi data meningkat (Azizah et al., 2023).

Principal Component Analysis (PCA)

Principal Component Analysis adalah metode *unsupervised learning* yang digunakan untuk mereduksi dimensi data dengan tetap mempertahankan informasi sebanyak mungkin. PCA sangat berguna ketika data memiliki dimensi tinggi yang dapat menyebabkan kompleksitas komputasi dan kemungkinan redundansi (Koten, 2024).

Cara Kerja PCA

1. Normalisasi Data

Sebelum PCA diterapkan, langkah pertama adalah menormalisasi data agar setiap fitur memiliki skala yang sama. Normalisasi penting karena PCA sensitif terhadap perbedaan skala antar fitur. Normalisasi biasanya dilakukan dengan teknik seperti Z-score *normalization*, di mana nilai rata-rata setiap fitur diubah menjadi nol, dan simpangan baku menjadi satu (Rianti et al., 2024).

2. Pembentukan Matriks Kovarian

Setelah data dinormalisasi, matriks kovarian dihitung untuk menggambarkan hubungan antar fitur. Matriks kovarian menunjukkan seberapa besar perubahan dalam satu fitur berkorelasi dengan perubahan fitur lain (Wiyono & Imah, 2021).

3. Komputasi *Eigenvektor* dan *Eigenvalue*

Dari matriks kovarian, *eigenvektor* dan *eigenvalue* dihitung. *Eigenvektor* menunjukkan arah dari komponen utama, sedangkan *eigenvalue* menunjukkan seberapa besar variansi data yang dijelaskan oleh komponen utama tersebut. Komponen utama dipilih berdasarkan *eigenvalue* terbesar, yang berarti komponen tersebut memiliki kontribusi variansi paling besar terhadap data (Dewi & Pakereng, 2023).

4. Seleksi Komponen Utama

Jumlah komponen utama yang dipilih bergantung pada proporsi variansi yang ingin dipertahankan. Biasanya, jumlah komponen utama dipilih sedemikian rupa sehingga menjelaskan lebih dari 90% total variansi dalam data (Dewi & Pakereng, 2023).

5. Transformasi Data

Data asli kemudian diproyeksikan ke ruang baru yang dibentuk oleh komponen utama. Transformasi ini menghasilkan data dengan dimensi yang lebih rendah tetapi tetap mempertahankan informasi penting dari data asli (Sari et al., 2023).

6. Evaluasi Data Hasil PCA

Setelah transformasi selesai, data hasil PCA dievaluasi untuk memastikan bahwa informasi yang relevan tetap dipertahankan. Data ini kemudian dapat digunakan dalam algoritma klasifikasi seperti KNN untuk menghasilkan prediksi yang lebih akurat (Nugraha et al., 2021).

PCA memiliki keunggulan dalam mengurangi dimensi data tanpa kehilangan informasi penting, tetapi hasilnya tergantung pada korelasi antara fitur-fitur dalam data (Tanjung & Utomo, 2024).

HASIL DAN PEMBAHASAN

Citra Data

Dalam penelitian ini, sampel citra yang digunakan terdiri dari tiga jenis buah, yaitu pisang kuning, pisang hijau, dan buah apel. Terdapat total 130 citra yang diambil, yang kemudian dibagi menjadi dua kategori: citra latih dan citra uji. Sebanyak 120 citra digunakan untuk data latih, sementara 10 citra lainnya digunakan untuk pengujian. Pada tahap ini, peneliti melakukan proses prapemrosesan terhadap citra tersebut. Proses prapemrosesan ini bertujuan untuk memisahkan objek utama (pisang kuning, pisang hijau, dan apel) dari latar belakang citra, sehingga hanya objek yang relevan yang dapat dianalisis lebih lanjut dalam proses pengolahan citra. Gambar 2 merupakan contoh dari citra apel yang digunakan dalam penelitian ini.



Sumber: (Hasil Penelitian, 2025)
 Gambar 2. Citra Apel

Gambar 3 merupakan contoh dari citra pisang hijau yang digunakan dalam penelitian ini.



Sumber: (Hasil Penelitian, 2025)
 Gambar 3. Citra Pisang Hijau

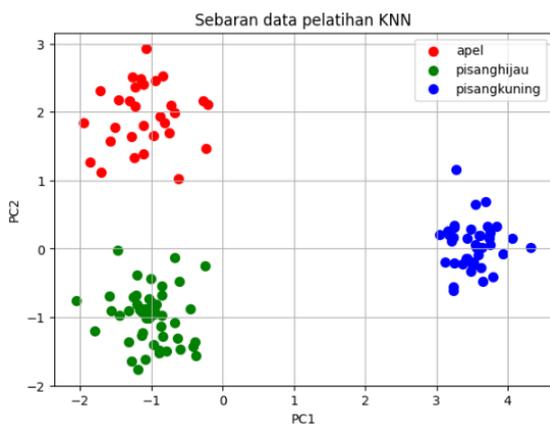
Gambar 4 merupakan contoh dari citra pisang kuning yang digunakan dalam penelitian ini.



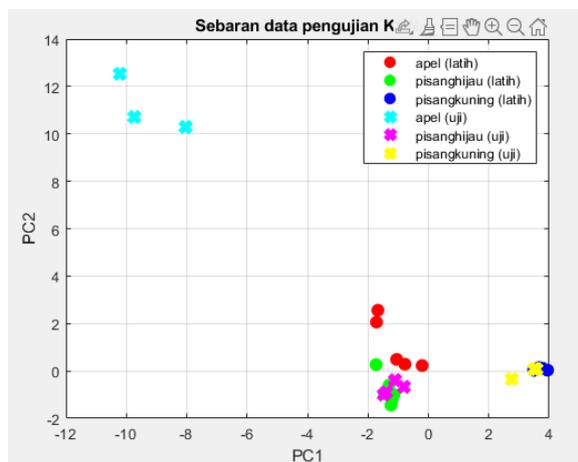
Sumber: (Hasil Penelitian, 2025)
 Gambar 4. Citra Pisang Kuning

Pengujian

Data citra latih merujuk pada kumpulan gambar yang digunakan untuk melatih model dalam menentukan kelas yang tepat untuk setiap gambar. Citra latih ini terdiri dari gambar pisang kuning, pisang hijau, dan buah apel, yang digunakan untuk mengajarkan model mengenali berbagai ciri khas dari masing-masing jenis buah. Sementara itu, citra data uji terdiri dari gambar baru yang akan diklasifikasikan menggunakan model yang telah dilatih, dan dari sini akan dinilai akurasi hasil klasifikasinya. Penelitian ini menyajikan hasil evaluasi berdasarkan data latih dan data uji, yang menunjukkan seberapa baik model dapat mengklasifikasikan jenis pisang kuning, pisang hijau, dan apel berdasarkan warna, bentuk, dan tekstur citra. Gambar 5 dibawah ini menunjukkan sebaran dari data pelatihan dan Gambar 6 menunjukkan sebaran dari data pengujian.



Sumber: (Hasil Penelitian, 2025)
 Gambar 5. Sebaran Data Latih

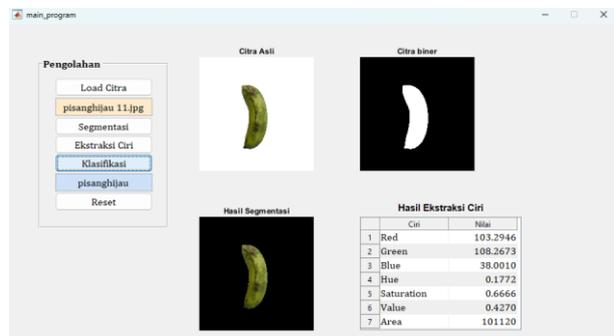


Sumber: (Hasil Penelitian, 2025)
 Gambar 6. Sebaran Data Uji

Gambar 6 menunjukkan sebaran data pengujian KNN dalam ruang dua dimensi yang

diperoleh dari analisis komponen utama (PCA). PC1 dan PC2 masing-masing mewakili komponen utama pertama dan kedua. Data latih terdiri atas tiga kelas: pisang kuning (ditandai dengan titik biru), pisang hijau (ditandai dengan titik hijau), dan buah apel (ditandai dengan titik merah). Data uji ditunjukkan oleh simbol silang, dengan pisang kuning (silang kuning), pisang hijau (silang ungu), dan apel (silang hijau). Distribusi data menunjukkan pola yang dapat dibedakan untuk masing-masing kelas, mendukung kemampuan metode KNN dalam mengklasifikasikan data berdasarkan warna, bentuk, dan tekstur.

Setelah mendapatkan sebaran data KNN dan PCA dari hasil pelatihan, langkah selanjutnya adalah menguji semua data pengujian yang telah dipersiapkan. Pengujian ini dilakukan dengan menggunakan 130 gambar dari pisang kuning, pisang hijau, dan apel. Sebanyak 10 gambar digunakan untuk menguji klasifikasi jenis pisang kuning, pisang hijau, dan apel berdasarkan karakteristik warna, bentuk, dan tekstur, dengan menggunakan metode *K-Nearest Neighbors* (KNN) untuk klasifikasinya. Hasil pengujian ini bertujuan untuk menilai seberapa baik model yang telah dilatih mampu mengklasifikasikan jenis buah dengan akurasi tinggi berdasarkan ciri yang telah diekstraksi. Gambar 7 merupakan contoh hasil ekstraksi yang telah diterapkan.



Sumber: (Hasil Penelitian, 2025)
 Gambar 7. Hasil Ekstraksi

Adapun hasil tabel hasil ekstraksi secara keseluruhan data uji yaitu yaitu :

Tabel 1. Hasil Pengujian Data Uji

Citra Uji	Citra Asli	Hasil Segmentasi	Hasil Ekstraksi Ciri	Klasifikasi	Keterangan																
1	Apel		<table border="1"> <thead> <tr> <th>Ciri</th> <th>Nilai</th> </tr> </thead> <tbody> <tr> <td>1 Red</td> <td>238.2291</td> </tr> <tr> <td>2 Green</td> <td>75.6910</td> </tr> <tr> <td>3 Blue</td> <td>68.8237</td> </tr> <tr> <td>4 Hue</td> <td>0.3306</td> </tr> <tr> <td>5 Saturation</td> <td>0.6537</td> </tr> <tr> <td>6 Value</td> <td>0.8204</td> </tr> <tr> <td>7 Area</td> <td>623796</td> </tr> </tbody> </table>	Ciri	Nilai	1 Red	238.2291	2 Green	75.6910	3 Blue	68.8237	4 Hue	0.3306	5 Saturation	0.6537	6 Value	0.8204	7 Area	623796	Apel	Akurat
Ciri	Nilai																				
1 Red	238.2291																				
2 Green	75.6910																				
3 Blue	68.8237																				
4 Hue	0.3306																				
5 Saturation	0.6537																				
6 Value	0.8204																				
7 Area	623796																				
2	Apel		<table border="1"> <thead> <tr> <th>Ciri</th> <th>Nilai</th> </tr> </thead> <tbody> <tr> <td>1 Red</td> <td>250.4385</td> </tr> <tr> <td>2 Green</td> <td>103.0636</td> </tr> <tr> <td>3 Blue</td> <td>63.5337</td> </tr> <tr> <td>4 Hue</td> <td>0.3038</td> </tr> <tr> <td>5 Saturation</td> <td>0.6923</td> </tr> <tr> <td>6 Value</td> <td>0.7469</td> </tr> <tr> <td>7 Area</td> <td>462512</td> </tr> </tbody> </table>	Ciri	Nilai	1 Red	250.4385	2 Green	103.0636	3 Blue	63.5337	4 Hue	0.3038	5 Saturation	0.6923	6 Value	0.7469	7 Area	462512	Apel	Akurat
Ciri	Nilai																				
1 Red	250.4385																				
2 Green	103.0636																				
3 Blue	63.5337																				
4 Hue	0.3038																				
5 Saturation	0.6923																				
6 Value	0.7469																				
7 Area	462512																				

Citra Uji	Citra Asli	Hasil Segmentasi	Hasil Ekstraksi Ciri	Klasifikasi	Keterangan																
3	Apel		<table border="1"> <tr><th>Ciri</th><th>Nilai</th></tr> <tr><td>1. Red</td><td>165,46711</td></tr> <tr><td>2. Green</td><td>82,8724</td></tr> <tr><td>3. Blue</td><td>40,7280</td></tr> <tr><td>4. Hue</td><td>0,4289</td></tr> <tr><td>5. Saturation</td><td>0,7423</td></tr> <tr><td>6. Value</td><td>0,6536</td></tr> <tr><td>7. Area</td><td>6262,25</td></tr> </table>	Ciri	Nilai	1. Red	165,46711	2. Green	82,8724	3. Blue	40,7280	4. Hue	0,4289	5. Saturation	0,7423	6. Value	0,6536	7. Area	6262,25	Apel	Akurat
Ciri	Nilai																				
1. Red	165,46711																				
2. Green	82,8724																				
3. Blue	40,7280																				
4. Hue	0,4289																				
5. Saturation	0,7423																				
6. Value	0,6536																				
7. Area	6262,25																				
4	Pisang Hijau		<table border="1"> <tr><th>Ciri</th><th>Nilai</th></tr> <tr><td>1. Red</td><td>70,8517</td></tr> <tr><td>2. Green</td><td>77,6799</td></tr> <tr><td>3. Blue</td><td>27,6974</td></tr> <tr><td>4. Hue</td><td>0,5744</td></tr> <tr><td>5. Saturation</td><td>0,6292</td></tr> <tr><td>6. Value</td><td>0,8249</td></tr> <tr><td>7. Area</td><td>9000,1</td></tr> </table>	Ciri	Nilai	1. Red	70,8517	2. Green	77,6799	3. Blue	27,6974	4. Hue	0,5744	5. Saturation	0,6292	6. Value	0,8249	7. Area	9000,1	Pisang Hijau	Akurat
Ciri	Nilai																				
1. Red	70,8517																				
2. Green	77,6799																				
3. Blue	27,6974																				
4. Hue	0,5744																				
5. Saturation	0,6292																				
6. Value	0,8249																				
7. Area	9000,1																				
5	Pisang Hijau		<table border="1"> <tr><th>Ciri</th><th>Nilai</th></tr> <tr><td>1. Red</td><td>77,4203</td></tr> <tr><td>2. Green</td><td>82,1899</td></tr> <tr><td>3. Blue</td><td>30,1754</td></tr> <tr><td>4. Hue</td><td>0,8379</td></tr> <tr><td>5. Saturation</td><td>0,6443</td></tr> <tr><td>6. Value</td><td>0,8749</td></tr> <tr><td>7. Area</td><td>9300,9</td></tr> </table>	Ciri	Nilai	1. Red	77,4203	2. Green	82,1899	3. Blue	30,1754	4. Hue	0,8379	5. Saturation	0,6443	6. Value	0,8749	7. Area	9300,9	Pisang Hijau	Akurat
Ciri	Nilai																				
1. Red	77,4203																				
2. Green	82,1899																				
3. Blue	30,1754																				
4. Hue	0,8379																				
5. Saturation	0,6443																				
6. Value	0,8749																				
7. Area	9300,9																				
6	Pisang Hijau		<table border="1"> <tr><th>Ciri</th><th>Nilai</th></tr> <tr><td>1. Red</td><td>183,2344</td></tr> <tr><td>2. Green</td><td>188,3636</td></tr> <tr><td>3. Blue</td><td>30,0010</td></tr> <tr><td>4. Hue</td><td>0,1272</td></tr> <tr><td>5. Saturation</td><td>0,4466</td></tr> <tr><td>6. Value</td><td>0,6339</td></tr> <tr><td>7. Area</td><td>10120</td></tr> </table>	Ciri	Nilai	1. Red	183,2344	2. Green	188,3636	3. Blue	30,0010	4. Hue	0,1272	5. Saturation	0,4466	6. Value	0,6339	7. Area	10120	Pisang Kuning	Belum Akurat
Ciri	Nilai																				
1. Red	183,2344																				
2. Green	188,3636																				
3. Blue	30,0010																				
4. Hue	0,1272																				
5. Saturation	0,4466																				
6. Value	0,6339																				
7. Area	10120																				
7	Pisang Hijau		<table border="1"> <tr><th>Ciri</th><th>Nilai</th></tr> <tr><td>1. Red</td><td>91,4891</td></tr> <tr><td>2. Green</td><td>96,1416</td></tr> <tr><td>3. Blue</td><td>71,0000</td></tr> <tr><td>4. Hue</td><td>0,1749</td></tr> <tr><td>5. Saturation</td><td>0,7004</td></tr> <tr><td>6. Value</td><td>0,9021</td></tr> <tr><td>7. Area</td><td>9122,1</td></tr> </table>	Ciri	Nilai	1. Red	91,4891	2. Green	96,1416	3. Blue	71,0000	4. Hue	0,1749	5. Saturation	0,7004	6. Value	0,9021	7. Area	9122,1	Pisang Hijau	Akurat
Ciri	Nilai																				
1. Red	91,4891																				
2. Green	96,1416																				
3. Blue	71,0000																				
4. Hue	0,1749																				
5. Saturation	0,7004																				
6. Value	0,9021																				
7. Area	9122,1																				
8	Pisang Kuning		<table border="1"> <tr><th>Ciri</th><th>Nilai</th></tr> <tr><td>1. Red</td><td>292,3281</td></tr> <tr><td>2. Green</td><td>176,6083</td></tr> <tr><td>3. Blue</td><td>8,0896</td></tr> <tr><td>4. Hue</td><td>0,1497</td></tr> <tr><td>5. Saturation</td><td>0,9017</td></tr> <tr><td>6. Value</td><td>0,7962</td></tr> <tr><td>7. Area</td><td>6219,9</td></tr> </table>	Ciri	Nilai	1. Red	292,3281	2. Green	176,6083	3. Blue	8,0896	4. Hue	0,1497	5. Saturation	0,9017	6. Value	0,7962	7. Area	6219,9	Pisang Kuning	Akurat
Ciri	Nilai																				
1. Red	292,3281																				
2. Green	176,6083																				
3. Blue	8,0896																				
4. Hue	0,1497																				
5. Saturation	0,9017																				
6. Value	0,7962																				
7. Area	6219,9																				
9	Pisang Kuning		<table border="1"> <tr><th>Ciri</th><th>Nilai</th></tr> <tr><td>1. Red</td><td>200,6139</td></tr> <tr><td>2. Green</td><td>177,8998</td></tr> <tr><td>3. Blue</td><td>14,9006</td></tr> <tr><td>4. Hue</td><td>0,1409</td></tr> <tr><td>5. Saturation</td><td>0,9049</td></tr> <tr><td>6. Value</td><td>0,7962</td></tr> <tr><td>7. Area</td><td>6219,1</td></tr> </table>	Ciri	Nilai	1. Red	200,6139	2. Green	177,8998	3. Blue	14,9006	4. Hue	0,1409	5. Saturation	0,9049	6. Value	0,7962	7. Area	6219,1	Pisang Kuning	Akurat
Ciri	Nilai																				
1. Red	200,6139																				
2. Green	177,8998																				
3. Blue	14,9006																				
4. Hue	0,1409																				
5. Saturation	0,9049																				
6. Value	0,7962																				
7. Area	6219,1																				
10	Pisang Kuning		<table border="1"> <tr><th>Ciri</th><th>Nilai</th></tr> <tr><td>1. Red</td><td>191,3001</td></tr> <tr><td>2. Green</td><td>159,5992</td></tr> <tr><td>3. Blue</td><td>18,0998</td></tr> <tr><td>4. Hue</td><td>0,1488</td></tr> <tr><td>5. Saturation</td><td>0,8801</td></tr> <tr><td>6. Value</td><td>0,7914</td></tr> <tr><td>7. Area</td><td>6300,9</td></tr> </table>	Ciri	Nilai	1. Red	191,3001	2. Green	159,5992	3. Blue	18,0998	4. Hue	0,1488	5. Saturation	0,8801	6. Value	0,7914	7. Area	6300,9	Pisang Kuning	Akurat
Ciri	Nilai																				
1. Red	191,3001																				
2. Green	159,5992																				
3. Blue	18,0998																				
4. Hue	0,1488																				
5. Saturation	0,8801																				
6. Value	0,7914																				
7. Area	6300,9																				

Sumber: (Hasil Penelitian, 2025)

Berdasarkan Tabel 1 proses pengujian menggunakan metode *K-Nearest Neighbor* (KNN) dilakukan pada 10 data uji. Dari hasil pengujian, sebanyak 9 citra berhasil diklasifikasikan dengan akurat, sementara 1 citra tidak berhasil diklasifikasikan dengan benar. Ketidakberhasilan ini diakibatkan oleh pengambilan foto objek yang kurang baik yang mengakibatkan sistem belum bisa mendeteksi dengan baik dan benar, dimana dari segi ekstraksi ciri pada warna lebih tinggi sehingga mendekati pada warna kuning. Tingkat akurasi klasifikasi ini dapat dirumuskan berdasarkan hasil pengujian sebagai berikut:

$$Akurasi = \frac{\text{jumlah data benar}}{\text{jumlah data uji keseluruhan}} \times 100\% \quad (1)$$

$$Akurasi = \frac{9}{10} \times 100\% = 90\%$$

Selain akurasi, evaluasi model juga dilakukan dengan mengukur presisi, *recall*, dan *F1-score* untuk mengetahui keseimbangan performa klasifikasi. Metrik ini dihitung berdasarkan perbandingan antara data yang diklasifikasikan dengan benar dan keseluruhan data yang diuji (Eko Prasetyo, 2022).

Presisi (*Precision*) mengukur seberapa banyak prediksi positif yang benar dibandingkan

total prediksi positif yang diberikan oleh model. Presisi dirumuskan sebagai berikut:

$$Presisi = \frac{TP}{TP+FP} \quad (2)$$

$$Presisi = \frac{9}{9+1} = 0.9 = 90\%$$

Recall mengukur seberapa banyak data yang seharusnya diklasifikasikan dengan benar oleh model. *Recall* dihitung dengan rumus sebagai berikut:

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

$$Recall = \frac{9}{9+1} = 0.9 = 90\%$$

F1-Score merupakan rata-rata harmonis antara presisi dan *recall* untuk mendapatkan keseimbangan antara keduanya. Rumus *F1-Score* adalah:

$$F1 - Score = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (4)$$

$$F1 - Score = 2 \times \frac{1 \times 0.9}{1 + 0.9}$$

$$= 2 \times \frac{0.9}{1.9}$$

$$= 2 \times 0.4737 = 0.947 = 94.7\%$$

Berdasarkan hasil perhitungan metrik evaluasi model di atas:

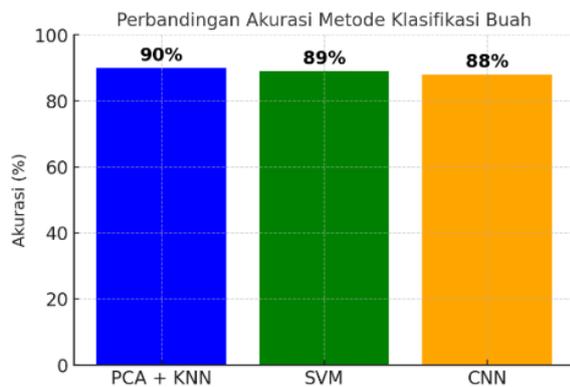
1. Presisi memiliki nilai 900%, mengindikasikan model dapat memprediksi positif secara benar sebesar 90% dari total data yang digunakan.
2. *Recall* memiliki nilai 90%, yang mengindikasikan bahwa model berhasil mengklasifikasikan 90% dari total data yang seharusnya dikenali dengan benar.
3. *F1-Score* sebesar 94.7%, yang menunjukkan keseimbangan optimal antara presisi dan *recall*, memastikan bahwa model tidak hanya akurat dalam klasifikasi tetapi juga dapat menangani variasi data dengan baik.

Program pengolahan citra yang ditampilkan dalam gambar bekerja melalui beberapa tahapan utama yang saling berkaitan. Pertama, pada tahap pengolahan citra, pengguna dapat membuka citra buah, baik pisang kuning, pisang hijau, maupun apel, yang akan dianalisis. Setelah citra dimasukkan, proses segmentasi dilakukan dengan mengonversi citra dari ruang warna RGB ke ruang warna Lab. Ruang warna Lab dipilih karena memisahkan

informasi luminansi dari warna, sehingga lebih memudahkan dalam proses segmentasi. Pada tahap ini, algoritma segmentasi digunakan untuk memisahkan objek utama (pisang kuning, pisang hijau, atau apel) dari latar belakang citra.

Setelah segmentasi selesai, program melanjutkan ke tahap ekstraksi ciri, di mana berbagai ciri penting dari citra diambil menggunakan metode *Principal Component Analysis* (PCA). Ciri-ciri yang diekstraksi meliputi aspek warna, tekstur, dan bentuk. Misalnya, fitur tekstur seperti *Energy* dan *Homogeneity* digunakan untuk mengukur keseragaman dan pola permukaan objek, sementara fitur geometris seperti *Eccentricity* menggambarkan seberapa memanjang bentuk objek. Ekstraksi ini bertujuan untuk menyederhanakan data dengan mempertahankan fitur-fitur yang paling relevan untuk proses klasifikasi.

Tahap terakhir adalah identifikasi, di mana algoritma *K-Nearest Neighbors* (KNN) digunakan untuk mengklasifikasikan objek berdasarkan ciri-ciri yang diekstraksi. Dalam proses ini, program menentukan apakah objek yang dianalisis adalah pisang kuning, pisang hijau, atau apel. Seluruh rangkaian proses, mulai dari membuka citra hingga identifikasi, dirancang untuk memungkinkan pengguna secara otomatis mengklasifikasikan buah dengan tingkat akurasi yang baik berdasarkan analisis citra.



Sumber: (Hasil Penelitian, 2025)

Gambar 8. Grafik Perbandingan Akurasi Metode

Grafik pada Gambar 8 menunjukkan perbandingan akurasi tiga metode klasifikasi dalam pengolahan citra untuk identifikasi buah, yaitu PCA + KNN, SVM, dan CNN. Hasil menunjukkan bahwa metode PCA + KNN memiliki akurasi tertinggi, yaitu 90%, dibandingkan dengan SVM sebesar 89% (Eko Prasetyo, 2022) dan CNN sebesar 88% (Hanifah & Hermawan, 2023), di mana kedua nilai akurasi tersebut diperoleh dari penelitian terdahulu. Pada

metode PCA + KNN, *Principal Component Analysis* (PCA) digunakan sebagai teknik reduksi dimensi sebelum proses klasifikasi dengan *K-Nearest Neighbor* (KNN). Sementara itu, metode SVM dan CNN dalam penelitian ini tidak menggunakan PCA, melainkan bekerja langsung dengan fitur citra yang diekstrak tanpa tahap reduksi dimensi. Hasil ini menunjukkan bahwa penggunaan PCA sebelum KNN dapat meningkatkan efisiensi dan akurasi klasifikasi dibandingkan dengan SVM dan CNN. Meskipun perbedaan akurasi tidak terlalu signifikan, kombinasi PCA dan KNN mampu mereduksi dimensi data tanpa kehilangan informasi penting, sehingga menjadikannya alternatif yang lebih efisien dalam tugas identifikasi buah.

KESIMPULAN

Berdasarkan hasil uji yang telah dilakukan untuk mengidentifikasi perbedaan antara pisang kuning, pisang hijau, dan buah apel menggunakan metode *K-Nearest Neighbors* (KNN) yang dikombinasikan dengan *Principal Component Analysis* (PCA), diperoleh hasil bahwa sistem berhasil mengklasifikasikan semua data uji dengan akurasi 90%. Metode ini memanfaatkan ekstraksi ciri warna, tekstur, dan bentuk untuk menghasilkan model klasifikasi yang andal. Selain itu, evaluasi model menunjukkan hasil yang sangat baik: presisi mencapai 90%, *Recall* sebesar 90%, dan *F1-Score* sebesar 94.7%.

Dari 130 citra yang digunakan, terdiri atas 120 citra latih dan 10 citra uji, ada sembilan citra uji berhasil dan satu data yang belum berhasil, diidentifikasi dengan benar sesuai kelasnya, yaitu pisang kuning, pisang hijau, atau buah apel. Jumlah data yang digunakan dalam penelitian ini hanya 130 citra karena penelitian difokuskan pada pengembangan dan pengujian awal sistem identifikasi buah berbasis metode PCA dan KNN. Pemilihan jumlah ini bertujuan untuk menguji keefektifan algoritma pada skala kecil, memastikan keandalan sistem, serta mengurangi waktu dan kompleksitas komputasi pada tahap awal sebelum dikembangkan lebih lanjut dengan dataset yang lebih besar. Hasil ini menunjukkan bahwa metode KNN yang diterapkan, dengan dukungan reduksi dimensi oleh PCA, sangat akurat dalam mengidentifikasi dan mengklasifikasikan objek berdasarkan karakteristik utama yang diekstraksi.

Keberhasilan ini membuktikan bahwa sistem yang dikembangkan menggunakan algoritma KNN dan PCA memiliki performa yang optimal untuk klasifikasi buah, khususnya untuk objek pisang kuning, pisang hijau, dan apel. Metode ini tidak hanya

memberikan hasil yang presisi tetapi juga dapat diandalkan untuk aplikasi serupa di masa depan.

Disarankan kepada penelitian selanjutnya untuk meningkatkan ukuran dataset dengan citra yang lebih beragam guna meningkatkan robustitas model.

REFERENSI

- Azizah, N., Riyad Firdaus, M., Suyaningsih, R., & Indrayatna, F. (2023). Penerapan Algoritma Klasifikasi K-Nearest Neighbor pada Penyakit Diabetes. *Prosiding Seminar Nasional Statistika Aktuaria*, 2(1), 119–126.
- Cholil, S. R., Handayani, T., Prathivi, R., & Ardianita, T. (2021). Implementasi Algoritma Klasifikasi K-Nearest Neighbor (KNN) Untuk Klasifikasi Seleksi Penerima Beasiswa. *IJCIT (Indonesian Journal on Computer and Information Technology)*, 6(2), 118–127.
- Danang, A., & Rachmawanto, E. H. (2022). Principal Component Analysis (PCA) dan K-Nearest Neighbor (KNN) dalam Deteksi Masker pada Wajah. *Prosiding Sains Nasional Dan Teknologi*, 12(1), 382. <https://doi.org/10.36499/psnst.v12i1.7066>
- Dewi, S., & Pakereng, M. A. I. (2023). Implementasi Principal Component Analysis Pada K-Means Untuk Klasterisasi Tingkat Pendidikan Penduduk Kabupaten Semarang. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 8(4), 1186–1195.
- Dombale, V., Gaikwad, B., & Gadakari, Y. (2023). Hybrid intelligent system. *International Research Journal of Modernization in Engineering*, 05(06), 497–498.
- Eko Prasetyo. (2022). Deteksi Kematangan Buah Melon dengan Algoritma Support Vector Machine Berbasis Ekstraksi Fitur GLCM. *Infortech*, 4(2), 200–206.
- Hanifah, A. I., & Hermawan, A. (2023). Klasifikasi Kematangan Pisang Menggunakan Metode Convolutional Neural Network. *Komputika : Jurnal Sistem Komputer*, 12(2), 49–56. <https://doi.org/10.34010/komputika.v12i2.9999>
- Iqbal Mubarok, M., Purwantoro, P., & Carudin, C. (2024). Penerapan Algoritma K-Nearest Neighbor (Knn) Dalam Klasifikasi Penilaian Jawaban Ujian Esai. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(5), 3446–3452.
- Jumadi, J., Yupianti, Y., & Sartika, D. (2021). Pengolahan Citra Digital Untuk Identifikasi Objek Menggunakan Metode Hierarchical Agglomerative Clustering. *JST (Jurnal Sains Dan Teknologi)*, 10(2), 148–156.
- Khamidah, N., Sofyan, A., & Elena, N. (2022). Teknologi Edible Coating dari Pati Kulit Pisang terhadap Mutu Buah Apel Malang (*Malis sylvestris*). *Jurnal Ilmiah Inovasi*, 22(2), 194–199.
- Koten, I. A. C. (2024). Penerapan Metode Principal Component Analysis (Pca) Mengidentifikasi Tekstur Buah Naga. *Bina Informatika Dan Komputer (BINER)*, 2(1).
- Manaek, R., Richardus Eko Indrajit, & Erick Dazki. (2023). Arsitektur Perusahaan Untuk Infrastruktur Telekomunikasi Di Daerah Pedalaman Indonesia. *SATIN - Sains Dan Teknologi Informasi*, 9(2), 01–11.
- Muhammad, D. I., Ermatita, E., & Falih, N. (2021). Penggunaan K-Nearest Neighbor (KNN) untuk Mengklasifikasi Citra Belimbing Berdasarkan Fitur Warna. *Informatik : Jurnal Ilmu Komputer*, 17(1), 9.
- Nugraha, D., Novantara, P., & Muhammad, A. (2021). Implementasi Algoritma PCA pada Pengenalan Pola Tanda Tangan dengan Menggunakan Bahasa Pemrograman Phytion. *JEJARING : Jurnal Teknologi Dan Manajemen Informatika*, 6(1), 7–12.
- Nuraini, R., Wibowo, A., Warsito, B., Syafei, W. A., & Jaya, I. (2023). Combination of K-NN and PCA Algorithms on Image Classification of Fish Species. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 7(5), 1026–1032.
- Nurdiansyah, N., Muliadi, M., Herteno, R., Kartini, D., & Budiman, I. (2024). Implementasi Metode Principal Component Analysis (Pca) Dan Modified K-Nearest Neighbor Pada Klasifikasi Citra Daun Tanaman Herbal. *Jurnal Mnemonic*, 7(1), 1–9.
- Putra, I. N. T. A., Prasetyo, J. E., Aminin, C., & Dana, I. K. A. (2023). Deteksi Kesegaran Buah Apel, Pisang, Dan Jeruk Menggunakan Metode Transformasi Ruang Warna HSI dan K-Nearest Neighbor. *INFORMATICS FOR EDUCATORS AND PROFESSIONAL : Journal of Informatics*, 7(2), 120.
- Rangkuti, M. Y. R., Alfansyuri, M. V., & Gunawan, W. (2021). Penerapan Algoritma K-Nearest Neighbor (Knn) Dalam Memprediksi Dan Menghitung Tingkat Akurasi Data Cuaca Di Indonesia. *Hexagon Jurnal Teknik Dan Sains*, 2(2), 11–16.
- Raysyah, S. R., Veri Arinal, & Dadang Iskandar Mulyana. (2022). Klasifikasi Tingkat Kematangan Buah Kopi Berdasarkan Deteksi Warna Menggunakan Metode Knn Dan Pca. *JSil (Jurnal Sistem Informasi)*, 8(2), 88–95.
- Rianti, R., Andarsyah, R., & Awangga, R. M. (2024). Penerapan PCA dan Algoritma Clustering untuk Analisis Mutu Perguruan Tinggi di LLDIKTI Wilayah IV. *Nuansa Informatika*, 18(2), 67–77.

- Sari, I. P., Ramadhani, F., Satria, A., & Apdilah, D. (2023). Implementasi Pengolahan Citra Digital dalam Pengenalan Wajah menggunakan Algoritma PCA dan Viola Jones. *Jurnal Ilmu Komputer*, 2(3), 146–157.
- Sidiq, S. A. (2021). Pengolahan Citra Untuk Identifikasi Telur Berdasarkan Ukuran. *Elinvo (Electronics, Informatics, and Vocational Education)*, 1(3), 151–156.
- Suahati, A. F., Nurrahman, A. A., & Rukmana, O. (2022). Penggunaan Jaringan Syaraf Tiruan – Backpropagation dalam Memprediksi Jumlah Mahasiswa Baru. *Jurnal Media Teknik Dan Sistem Industri*, 6(1), 21.
- Tanjung, R. P., & Utomo, D. W. (2024). Implementasi Principal Component Analysis (PCA) pada Pengenalan Wajah Resolusi Rendah. *Infotekmesin*, 15(01), 109–116. <https://doi.org/10.35970/infotekmesin.v15i1.2148>
- Wiyono, A. R., & Imah, E. M. (2021). Pengenalan Citra Ekspresi Wajah Menggunakan Algoritma Principal Component Analysis (Pca) Dan Extreme Learning Machine (Elm). *Jurnal Ilmiah Matematika*, 6(2), 2–6.
- Zahra, A., Azizah, S., Nazar, F., Yalis, T., & Narayana, I. S. (2024). Pengolahan Citra Digital Dengan Penerapan Teknik Ambang Batas : Studi Kasus Menggunakan Opencv. *Jurnal AI Dan SPK*, 1(4), 283–287.