

Deteksi dan Klasifikasi Kematangan Pisang menggunakan YOLOv8 dan Model Hibrida MobileNetV2–KNN

M. Rinaldi Pratama^{1,*}, Joko Aryanto¹

¹ Program Studi Informatika, Universitas Teknologi Yogyakarta, Indonesia

* Correspondence: muhammadrinaldipratama123@gmail.com

Copyright: © 2025 by the authors

Received: 10 Oktober 2025 | Revised: 27 Oktober 2025 | Accepted: 20 November 2025 | Published: 7 Desember 2025

Abstrak

Kematangan pisang merupakan indikator penting yang menentukan kualitas, daya simpan, dan nilai jual, namun penilaian manual yang umum digunakan masih bersifat subjektif sehingga diperlukan sistem klasifikasi otomatis yang lebih objektif dan stabil. Penelitian ini bertujuan mengembangkan model hibrida dengan akurasi dan stabilitas tinggi untuk mengklasifikasikan tingkat kematangan pisang serta mengimplementasikannya dalam sistem inspeksi mutu berbasis citra secara *real-time*. Penelitian ini merupakan penelitian eksperimen sekaligus pengembangan perangkat lunak menggunakan model Waterfall, dengan mengintegrasikan YOLOv8 sebagai *pra-filtering* untuk mendeteksi dan mengekstraksi area pisang, MobileNetV2 sebagai *deep feature extractor* yang ringan namun representatif, serta K-Nearest Neighbor (KNN) sebagai klasifikator berbasis jarak *Euclidean*. Dataset terdiri dari 13.478 citra empat tingkat kematangan yang diproses melalui tahapan deteksi, ekstraksi fitur, normalisasi, dan klasifikasi. Evaluasi performa menggunakan akurasi, presisi, *recall*, *F1-score*, confusion matrix, dan *5-fold cross-validation* menunjukkan bahwa model mencapai akurasi 96,57% dengan presisi dan *recall* seimbang dan variansi *cross-validation* rendah, menandakan performa stabil serta minim overfitting. Kontribusi utama penelitian ini mencakup perancangan arsitektur hibrida YOLOv8–MobileNetV2–KNN yang mengatasi keterbatasan metode berbasis fitur manual maupun CNN murni, serta pengembangan sistem klasifikasi kematangan pisang berbasis GUI yang siap diterapkan dalam aplikasi *smart farming* secara *real-time*.

Kata kunci: k-nearest neighbor; klasifikasi citra; kematangan pisang; mobilenetv2; yolov8

Abstract

Banana ripeness is a key indicator of fruit quality, shelf life, and commercial value; however, manual assessment remains subjective and inconsistent, highlighting the need for an automated and objective classification system. This study aims to develop a high-accuracy and stable hybrid model for classifying banana ripeness levels and to implement it in a real-time image-based quality inspection system. This research is an experimental study combined with software development using the Waterfall model. The proposed method integrates YOLOv8 for object pre-filtering and banana detection, MobileNetV2 as a lightweight yet representative deep feature extractor, and K-Nearest Neighbor (KNN) as a Euclidean-distance-based classifier. A dataset of 13,478 images representing four ripeness categories was processed through detection, feature extraction, normalization, and classification stages. Performance evaluations using accuracy, precision, recall, F1-score, confusion matrix, and 5-fold cross-validation show that the model achieves an accuracy of 96.57% with balanced precision–recall values and low cross-validation variance, indicating strong stability and minimal overfitting. The main contributions of this study include the design of the YOLOv8–MobileNetV2–KNN hybrid architecture that overcomes the limitations of manually engineered features and pure CNN models, as well as the development of a GUI-based banana ripeness classification system suitable for real-time smart farming applications.



Keywords: *banana ripeness; image classification; k-nearest neighbor; mobilenetv2; yolov8*

PENDAHULUAN

Tanaman pisang (*Musa paradisiaca* L.) adalah tanaman tropis yang banyak ditemukan di wilayah Asia Tenggara, termasuk Indonesia (Widyawati et al., 2024). Badan Pusat Statistik (BPS) menyatakan bahwa produksi pisang di Indonesia mencapai 8,74 juta ton pada 2021. Jumlah tersebut mengalami kenaikan 6,85% dibandingkan tahun 2020 sekitar 8,18 juta ton, jumlah tersebut meningkat 12,39% dari 7,28 juta ton pada 2019. Produksi pisang di Indonesia mengalami peningkatan tinggi sejak lima tahun terakhir (Putri et al., 2022). Pisang merupakan salah satu jenis buah di bidang perkebunan yang banyak memberikan manfaat bagi kesehatan karena kaya nutrisi (Amrozi et al., 2022). Kualitas dan nilai gizi pisang sangat dipengaruhi oleh (Maula et al., 2025) tingkat kematangan dan kesegarannya. Kematangan menjadi faktor penting yang menentukan rasa, tekstur, dan masa simpan buah. Namun, penilaian kematangan secara manual bersifat subjektif dan tidak konsisten, sehingga diperlukan sistem otomatis untuk mengklasifikasikan tingkat kematangan guna menjamin mutu yang stabil dalam industri pertanian dan pangan. (Suhendri & Kusri, 2024)

Salah satu metode yang potensial untuk meningkatkan akurasi dan konsistensi dalam menentukan tingkat kematangan buah adalah dengan mengembangkan sistem klasifikasi otomatis berbasis analisis citra digital (Maula et al., 2025). Berbagai penelitian sebelumnya telah menggunakan metode *machine learning* klasik untuk melakukan klasifikasi kematangan buah pisang. Misalnya pada penelitian (Adenugraha et al., 2022) memperoleh akurasi sebesar 90,9% menggunakan kombinasi dari KNN dan PCA berbasis citra RGB dan HSV. Penelitian (Kosasih, 2021) juga menerapkan algoritma KNN dengan ekstraksi fitur tekstur dan mencapai akurasi 88,89%. Penelitian (Amrozi et al., 2022) menggunakan metode SVM dan memperoleh akurasi 89,86%. Meskipun memiliki hasil yang terbilang baik, pendekatan berbasis *machine learning* klasik ini sangat bergantung pada fitur-fitur yang didefinisikan secara manual (*manually defined features*) dan kurang adaptif terhadap variasi citra yang kompleks.

Seiring meningkatnya kompleksitas permasalahan dan kebutuhan terhadap generalisasi yang lebih baik, penelitian kemudian beralih ke pemanfaatan *deep learning*. Hanifah & Hermawan (2023) menggunakan *Convolutional Neural Network* (CNN) untuk klasifikasi kematangan buah pisang dan memperoleh akurasi 88%. Penelitian Huda & Putra (2023) yang juga menggunakan CNN mendapatkan akurasi 78%. Penelitian oleh Lee et al. (2025) menunjukkan bahwa penggunaan arsitektur CNN MobileNetV2 untuk klasifikasi kualitas pisang mampu mencapai akurasi sebesar 87%. Meski demikian, model CNN murni sering menghadapi keterbatasan, seperti risiko *overfitting* pada dataset berukuran kecil serta kebutuhan komputasi yang relatif tinggi, sehingga penerapannya pada perangkat dengan sumber daya terbatas menjadi kurang optimal. Temuan serupa juga dilaporkan oleh Shahi et al. (2022) yang mengembangkan *attention-based MobileNetV2* untuk klasifikasi buah, di mana model ringan diperlukan agar tetap efisien tanpa mengorbankan akurasi.

Berdasarkan dua pendekatan sebelumnya, terlihat perbedaan karakteristik antara metode klasik dan *deep learning*. Metode klasik lebih ringan secara komputasi, namun sangat bergantung pada fitur yang dirancang secara manual sehingga akurasinya terbatas. Sebaliknya, model *deep learning* murni mampu memberikan performa lebih tinggi tetapi memerlukan sumber daya komputasi besar, rentan *overfitting* ketika data terbatas, dan sering melakukan klasifikasi langsung pada citra utuh tanpa seleksi area objek sehingga bagian yang tidak relevan ikut diproses. Kondisi ini menunjukkan masih adanya ruang pengembangan, khususnya melalui integrasi metode yang mampu menggabungkan ketepatan deteksi, efisiensi ekstraksi fitur, dan kesederhanaan klasifikasi dalam satu alur kerja. Untuk itu, pendekatan ini memadukan YOLOv8 sebagai tahap pra-filtering objek, MobileNetV2 sebagai ekstraktor fitur, dan KNN sebagai klasifikator yang saling melengkapi. YOLOv8n dipilih karena jumlah

parameternya kecil dan kebutuhan komputasinya rendah (Wang et al., 2025). MobileNetV2 karena arsitekturnya yang ringan dibandingkan model besar seperti VGG-16 (Shahi et al., 2022), dan KNN karena sederhana, efektif, serta tidak memerlukan proses pelatihan (Sejuti & Islam, 2023). Kombinasi ini membantu menghasilkan prediksi yang lebih stabil dan adaptif terhadap variasi citra.

Pendekatan serupa juga telah diterapkan pada berbagai objek penelitian lain. Penelitian Wardhani et al. (2024) dengan mengombinasikan CNN dan KNN untuk klasifikasi penyakit mata dan memperoleh akurasi sebesar 94,03%. Penelitian Rukiastiandari et al. (2025) menggabungkan KNN dengan Genetic Algorithm (GA) untuk prediksi penyakit ginjal, meningkatkan akurasi dari 80% jadi 97,75%. Penelitian Sejuti & Islam (2023) dengan mengombinasikan CNN dan KNN untuk identifikasi COVID-19 dari CT scan memperoleh akurasi rata-rata sebesar 98,26%. Penelitian (Navarro Ortiz & Martinez Lopez, 2022) yang mengimplementasikan hibrida CNN-KNN dan EfficientNet-Lite untuk pengenalan ekspresi wajah pada Raspberry Pi memperoleh akurasi sebesar 75,26%. Sementara itu penelitian Sharifonnasabi et al. (2022) yang mengombinasikan HCNN dan KNN untuk estimasi usia pada gambar Orthopantomography (OPG) memperoleh akurasi sebesar 99,98%. Hasil-hasil tersebut menunjukkan bahwa penggabungan dua metode berbeda dapat meningkatkan akurasi model secara signifikan. Konsep serupa akan diadaptasi dalam penelitian dengan mengintegrasikan MobileNetV2 sebagai ekstraktor fitur dan KNN sebagai algoritma klasifikasi untuk meningkatkan performa dalam mendeteksi tingkat kematangan buah pisang.

Penelitian ini mengusulkan model hibrida yang mengintegrasikan YOLOv8, MobileNetV2, dan KNN sebagai upaya mengatasi keterbatasan pendekatan sebelumnya. Penelitian ini bertujuan menghasilkan sistem klasifikasi tingkat kematangan pisang yang akurat, cepat, dan mampu bekerja secara real-time. Pendekatan ini menekankan sinergi antara ketiga komponen guna mencapai keseimbangan antara akurasi dan kebutuhan komputasi serta meningkatkan robustness terhadap citra non-pisang. Ruang lingkup penelitian dibatasi pada dataset citra pisang dengan pencahayaan relatif seragam dan satu varietas. Sistem menerima input berupa citra tunggal melalui unggahan maupun kamera, dan evaluasi dilakukan dalam skenario terkontrol sesuai karakteristik data. Kontribusi utama penelitian ini mencakup penerapan pra-filtering objek menggunakan YOLOv8 untuk meningkatkan ketepatan deteksi, pemanfaatan MobileNetV2 sebagai ekstraktor fitur yang ringan namun representatif, serta penggunaan KNN sebagai klasifikator yang sederhana dan efisien.

METODE

Pengembangan sistem klasifikasi tingkat kematangan buah pisang menggunakan pendekatan *waterfall* yang memiliki beberapa tahapan berurutan. Pendekatan Waterfall dinilai paling sesuai karena penelitian ini berfokus pada pengembangan aplikasi fungsional berupa sistem klasifikasi kematangan pisang berbasis GUI, bukan pada eksplorasi data berulang seperti pada metode CRISP-DM.



Gambar 1. Contoh dataset

Tahap pertama adalah pengumpulan dataset yang digunakan dari Kaggle (<https://www.kaggle.com/datasets/atrithakar/banana-classification>) Dataset terdiri dari empat kelas kematangan pisang, yaitu mentah, setengah matang, matang, dan busuk dengan distribusi citra yang relatif seimbang untuk menghindari bias prediksi. Seluruh citra diperoleh pada pencahayaan yang seragam dengan latar belakang sederhana dan hanya mencakup satu varietas pisang agar karakteristik visual lebih konsisten. Semua gambar diubah ke ukuran 224×224 piksel sesuai kebutuhan input MobileNetV2. Tidak digunakan augmentasi tambahan karena kualitas dan jumlah citra sudah memadai. Dataset ini dipilih karena memberikan representasi visual yang jelas untuk setiap tingkat kematangan dan tidak menunjukkan class imbalance yang signifikan. Contoh dataset dapat dilihat pada gambar 1.

Tahap kedua adalah analisis kebutuhan untuk menentukan fitur dan spesifikasi yang diperlukan dalam pengembangan sistem klasifikasi kematangan pisang. Sistem dijalankan pada Windows 10 dengan prosesor Intel Core i7-1280P, RAM 16 GB, dan GPU NVIDIA RTX 4060Ti (16 GB VRAM). Kebutuhan utama sistem meliputi kemampuan menerima input citra, mendeteksi objek pisang, mengekstraksi fitur visual, melakukan klasifikasi tingkat kematangan, serta menampilkan hasil secara real-time melalui GUI interaktif.

Tahap perancangan model dilaksanakan setelah analisis kebutuhan, dengan membangun sistem hibrida yang terdiri atas tiga komponen utama: YOLOv8, MobileNetV2, dan KNN. Model YOLOv8n pra-latih dari Ultralytics digunakan tanpa pelatihan ulang untuk mendeteksi serta mengekstraksi area citra yang mengandung pisang sekaligus menyaring citra non-pisang. Hasil deteksi kemudian diproses melalui MobileNetV2, yang seluruh lapisannya dibekukan menggunakan bobot pra-latih ImageNet hingga bottleneck terakhir. Proses ini menghasilkan vektor fitur berdimensi 1×1280 dari citra berukuran 224×224 piksel, yang selanjutnya dinormalisasi dengan MinMaxScaler ke rentang 0–1. Vektor tersebut diklasifikasikan menggunakan algoritma KNN berbasis jarak Euclidean ke dalam empat kategori tingkat kematangan pisang. Pelatihan hanya dilakukan pada tahap KNN dengan seluruh vektor fitur dan berlangsung sekitar 40 menit, sedangkan inferensi yang mencakup deteksi, ekstraksi, dan klasifikasi berlangsung cepat, sekitar 1 detik per citra. Seluruh komponen diintegrasikan dalam antarmuka GUI berbasis Tkinter untuk mendukung deteksi dan klasifikasi secara real-time. Arsitektur hibrida ini diimplementasikan menggunakan Python dengan pustaka utama Ultralytics (YOLOv8), TensorFlow (MobileNetV2), dan Scikit-learn (KNN).

Tahap pengujian dan evaluasi dilakukan setelah sistem diimplementasikan. Dataset dibagi menjadi 80% data latih dan 20% data uji, dengan 20% dari data latih digunakan sebagai data validasi. Kinerja model dievaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score, sesuai definisi umum dalam literatur (Indahyanti et al., 2022; Merdiansah et al., 2024). Selain metode *hold-out*, digunakan pula 5-fold cross-validation untuk menilai konsistensi performa, dengan pertimbangan keseimbangan antara stabilitas evaluasi dan efisiensi komputasi. Hasil prediksi divisualisasikan melalui *confusion matrix* guna menganalisis distribusi klasifikasi benar dan salah pada setiap kategori tingkat kematangan pisang.

HASIL DAN PEMBAHASAN

Hasil


Dataset terdiri dari 13.478 citra, yang dibagi menjadi 80% data latih dan 20% data uji, dengan 20% dari data latih digunakan sebagai validasi. Eksperimen dilakukan untuk menentukan nilai k terbaik pada algoritma KNN, menggunakan MobileNetV2 sebagai feature extractor dan variasi $k = 1, 3, 5, 7$, dan 9 . Rentang ini dipilih karena mencakup tingkat sensitivitas dan kompleksitas lokal yang berbeda, sehingga memungkinkan identifikasi nilai k paling seimbang antara akurasi dan generalisasi.

Hasil pada tabel 1 menunjukkan bahwa nilai $k = 1$ memberikan performa terbaik dengan akurasi sebesar 96,57%, sedangkan $k = 9$ menghasilkan nilai terendah yaitu 94.10%. Pola ini


divisualisasikan pada gambar 2, yang memperlihatkan kecenderungan penurunan akurasi seiring meningkatnya nilai k . Fenomena tersebut menunjukkan bahwa semakin banyak tetangga yang dipertimbangkan, semakin besar kemungkinan model mengalami *over-smoothing* sehingga batas antar kelas menjadi kurang jelas. Berdasarkan tren tersebut, nilai $k = 1$ dipilih sebagai parameter optimal untuk tahap pengujian utama. Untuk memastikan kestabilan performa model, dilakukan pula pengujian *5-fold cross-validation* dengan konfigurasi $k = 1$.

Tabel 1. Hasil eksperimen nilai k

Nilai k	Akurasi	Presisi	<i>Recall</i>
1	96,57%	96,59%	96,57%
3	95,92%	95,98%	95,92%
5	95,08%	95,17%	95,08%
7	94,66%	94,78%	94,66%
9	94,10%	94,27%	94,10%



Gambar 2. Tren nilai k




Gambar 3. Performa *cross-validation*

Tabel 2. Hasil *5-fold cross validation* untuk $k = 1$

<i>Fold</i>	Akurasi	Presisi	<i>Recall</i>	<i>F1-Score</i>
1	96,21%	96,25%	96,21%	96,21%
2	95,55%	95,56%	95,55%	95,55%
3	96,33%	96,37%	96,33%	96,33%
4	96,15%	96,18%	96,15%	96,16%
5	96,57%	96,59%	96,57%	96,57%
Rata-rata	96,16%	96,19%	96,16%	96,17%
Standar Deviasi	0,34	0,35	0,34	0,35
Varians	0,0012	0,0012	0,0012	0,0012

Nilai variansi dan standar deviasi pada tabel 2 menunjukkan tingkat konsistensi model selama proses *5-Fold Cross-Validation*. Dengan standar deviasi hanya sebesar 0,34%, performa model pada setiap fold berada pada rentang yang sangat berdekatan. Variansi yang kecil ini mengindikasikan bahwa kualitas prediksi tidak bergantung pada subset data tertentu, sehingga model memiliki kemampuan generalisasi yang baik. Konsistensi ini juga tercermin pada gambar 3 yaitu boxplot distribusi akurasi, yang menampilkan rentang interkuartil sempit dan whisker pendek, menandakan bahwa fluktuasi performa antar-fold sangat minimal. Nilai

deviasi yang rendah menunjukkan bahwa arsitektur hibrida YOLOv8, MobileNetV2, KNN memiliki robustness tinggi: YOLOv8 memastikan input yang lebih bersih melalui seleksi objek yang presisi, MobileNetV2 menghasilkan representasi fitur yang stabil, dan KNN dengan $k = 1$ mampu memanfaatkan jarak antar-vektor secara efektif pada ruang fitur yang terstruktur dengan baik. Kombinasi ini membuat model tidak sensitif terhadap variasi antar fold dan mempertahankan performa yang relatif seragam.




Gambar 4. *Confusion matrix*

Berdasarkan gambar 4, model menunjukkan kinerja tinggi pada seluruh kelas kematangan, dengan jumlah prediksi benar terbesar pada kelas busuk dan matang. Kesalahan klasifikasi terutama terjadi pada kelas matang dan terlalu matang, yang memiliki kemiripan visual tinggi sehingga batas antar kelas mudah tumpang tindih. Beberapa citra busuk juga keliru dikenali sebagai terlalu matang karena pola warna coklat yang serupa, sementara kelas mentah mengalami kesalahan paling sedikit karena ciri visualnya paling berbeda. Pola ini menunjukkan bahwa sumber kesalahan lebih banyak dipengaruhi oleh kemiripan tekstur dan warna antar kelas daripada oleh ketidakseimbangan data, mengingat distribusi dataset relatif seimbang.

Tabel 3. Hasil laporan klasifikasi per kelas

Kelas	Presisi	Recall	F1-Score
Busuk	0,98	0,96	0,97
Matang	0,96	0,97	0,97
Mentah	0,97	0,98	0,97
Terlalu Matang	0,94	0,96	0,95

Berdasarkan tabel 3 analisis terlihat bahwa semua kelas memiliki nilai *f1-score* lebih besar dari 0,95, menunjukkan bahwa model memiliki keseimbangan yang baik antara presisi dan recall di seluruh kelas. Kesalahan klasifikasi terutama terjadi pada kelas yang memiliki kemiripan visual, seperti antara matang dan terlalu matang, namun perbedaannya relatif kecil dan tidak berdampak signifikan terhadap performa keseluruhan. Model yang telah dilatih diintegrasikan ke dalam sistem berbasis GUI menggunakan pustaka Tkinter, OpenCV, dan Pillow. Antarmuka ini memungkinkan pengguna untuk melakukan klasifikasi baik dari citra yang diunggah maupun dari kamera secara *real-time*. Pengujian fungsional dilakukan menggunakan *black box testing*, di mana setiap fitur diuji berdasarkan hasil yang diharapkan.



Gambar 5. Tampilan gui sistem

Pada gambar 5 ditampilkan bentuk dari GUI dai sistem yang telah kami buat. gambar sebelah kiri merupakan gambar saat melakukan deteksi menggunakan tombol pilih gambar menggunakan gambar pisang yang bukan dari dataset dan gambar batu bata. Kemudian untuk gambar sebelah kanan merupakan tampilan saat melakukan deteksi menggunakan kamera secara langsung, disana ditampilkan 3 buah pisang dan semua pisang tersebut berhasil ditampilkan kematangannya.

Tabel 4. Hasil pengujian *black box*

Skenario Pengujian	Hasil yang Diharapkan	Hasil Pengujian	Waktu Eksekusi / Inferensi	Kesimpulan
Membuka aplikasi	Menampilkan GUI normal	GUI tampil dengan normal	± 10 detik	Berhasil
Unggah citra pisang dan non pisang	Gambar diproses dan hasil klasifikasi ditampilkan jika citra pisang, sedangkan citra non-pisang ditolak	Gambar diproses dan hasil klasifikasi tampil jika citra pisang, sedangkan citra non-pisang ditolak	± 1 detik	Berhasil
Deteksi kamera	Kamera berhasil aktif dan menampilkan hasil klasifikasi	Kamera aktif dan tampil hasil klasifikasi	± 1 detik	Berhasil

Hasil pengujian sistem pada tabel 4 menunjukkan bahwa model hibrida MobileNetV2–KNN yang terintegrasi dengan YOLOv8 mampu berfungsi secara konsisten dan stabil pada seluruh skenario uji. Proses klasifikasi citra pisang maupun penolakan citra non-pisang berjalan akurat dengan waktu inferensi rata-rata sekitar 1 detik, sementara proses deteksi kamera juga menghasilkan prediksi dalam waktu ± 1 detik. Meskipun waktu awal pembukaan aplikasi membutuhkan sekitar 10 detik, keseluruhan sistem tetap responsif setelah berjalan. Nilai akurasi yang tinggi serta metrik evaluasi yang seimbang membuktikan bahwa arsitektur hibrida ini efektif dalam mengidentifikasi tingkat kematangan pisang. Integrasi model dengan antarmuka GUI memastikan bahwa proses deteksi dan klasifikasi dapat dilakukan secara praktis dan real-time, sehingga mendukung penerapan sistem ini dalam inspeksi mutu buah di lingkungan operasional.

Pembahasan

Hasil penelitian menunjukkan bahwa arsitektur hibrida YOLOv8, MobileNetV2, dan KNN berhasil mencapai kinerja klasifikasi yang sangat tinggi, dengan akurasi 96,57% pada nilai $k = 1$. Temuan ini menunjukkan bahwa kombinasi tahap deteksi objek, ekstraksi fitur, dan klasifikasi berbasis jarak bekerja secara sinergis untuk mengatasi tantangan visual pada citra kematangan pisang. Efektivitas nilai $k = 1$ memperlihatkan bahwa ruang fitur yang dihasilkan MobileNetV2 bersifat cukup terpisah secara linear sehingga keputusan berdasarkan tetangga terdekat tunggal lebih akurat dalam menangkap pola tekstural antar kelas. Penurunan performa pada nilai k yang lebih besar mengindikasikan bahwa agregasi multitetangga menurunkan sensitivitas model terhadap perbedaan halus, terutama pada kelas matang dan terlalu matang yang memiliki rentang variasi warna dan tekstur yang sempit. Stabilitas model diperkuat oleh hasil 5-fold cross-validation dengan variansi 0,0012, yang menunjukkan bahwa pipeline hibrida ini tidak bergantung pada subset data tertentu dan memiliki generalisasi internal yang kuat. Pola kesalahan dalam confusion matrix juga konsisten dengan karakteristik visual buah pisang, di mana kematangan yang berada pada fase transisi memang lebih sulit dibedakan. Tingkat kesalahan yang rendah pada kelas mentah dan busuk menunjukkan bahwa model mampu mengenali dua ekstrem kematangan dengan baik karena karakteristik visualnya sangat kontras dibandingkan kelas tengah.

Kinerja model yang dikembangkan dalam penelitian ini menunjukkan peningkatan yang sangat menonjol dibandingkan dari hasil temuan sebelumnya. Metode berbasis fitur buatan seperti KNN dan PCA (Adenugraha et al., 2022) hanya mampu mencapai akurasi 90,9%, yang menegaskan keterbatasan pendekatan *manual feature engineering* dalam merepresentasikan keragaman visual pada citra pisang. Sementara itu, model CNN murni yang digunakan oleh Hanifah & Hermawan (2023) serta Huda & Putra (2023) menghasilkan akurasi yang lebih rendah, masing-masing 88% dan 78%, terutama karena pemrosesan citra secara utuh tanpa segmentasi objek membuat model rentan terhadap *noise* latar belakang dan variasi pencahayaan. Bahkan penelitian Lee et al. (2025) yang menerapkan MobileNetV2 hanya memperoleh akurasi 85%, yang sebagian besar disebabkan oleh tidak adanya tahapan deteksi objek untuk menyaring area non-relevan. Dengan demikian, temuan penelitian ini secara jelas memperlihatkan bahwa arsitektur hibrida yang memisahkan proses deteksi, ekstraksi fitur, dan klasifikasi memberikan keunggulan performa yang signifikan baik secara empiris maupun metodologis dibandingkan pendekatan klasik maupun CNN konvensional.

Kebaruan dari penelitian ini terletak pada integrasi YOLOv8 sebagai pra-filtering objek dalam tugas klasifikasi kematangan pisang, yang sejauh penelusuran literatur belum banyak diterapkan pada domain ini. Penggunaan MobileNetV2 sebagai ekstraktor fitur ringan dan penggabungannya dengan KNN membentuk pipeline modular yang tidak ditemukan dalam penelitian sebelumnya, di mana CNN biasanya digunakan secara *end-to-end* tanpa pemisahan fungsi. Selain itu, penelitian ini memperkenalkan pendekatan sistemik yang mengombinasikan deteksi objek, ekstraksi fitur pra-latih, dan klasifikasi jarak, menghasilkan sistem yang lebih efisien, stabil, dan hemat komputasi dibanding arsitektur CNN tunggal.

Penelitian ini memberikan kontribusi yang signifikan dengan menghadirkan arsitektur hibrida yang mampu mengatasi berbagai keterbatasan pendekatan tradisional berbasis fitur manual maupun model CNN murni. Integrasi tahapan deteksi, ekstraksi fitur, dan klasifikasi dalam satu *pipeline* terbukti meningkatkan akurasi secara substansial tanpa menimbulkan penambahan beban komputasi yang berlebihan, sehingga memastikan efisiensi sistem tetap terjaga. Selain itu, penelitian ini menunjukkan relevansi praktis yang kuat melalui implementasi antarmuka real-time berbasis GUI yang memungkinkan penerapan langsung dalam ekosistem smart farming. Dengan kombinasi performa yang tinggi, stabilitas prediksi, serta kebutuhan komputasi yang relatif rendah, pendekatan hibrida yang diusulkan dapat

diposisikan sebagai landasan penting bagi pengembangan sistem inspeksi mutu berbasis visi komputer dalam konteks operasional berskala industri.

SIMPULAN

Penelitian ini membuktikan bahwa arsitektur hibrida yang menggabungkan YOLOv8, MobileNetV2, dan KNN mampu mengklasifikasikan tingkat kematangan pisang dengan akurasi tinggi, yakni 96,57%, serta menunjukkan konsistensi performa di seluruh rangkaian pengujian. Sinergi antara deteksi objek, ekstraksi fitur pra-latih, dan klasifikasi berbasis jarak efektif dalam menekan pengaruh noise visual, memperjelas batas pemisahan fitur, dan meningkatkan konsistensi prediksi pada setiap kategori kematangan. Jika dibandingkan dengan pendekatan sebelumnya yang menggunakan fitur manual maupun CNN tunggal, pendekatan ini memberikan peningkatan kinerja yang bermakna dan secara efektif mengatasi persoalan metodologis seperti gangguan latar belakang serta keterbatasan representasi fitur buatan manusia. Nilai kebaruannya terletak pada penerapan YOLOv8 sebagai tahap penyaringan objek, integrasi MobileNetV2 dan KNN dalam satu arsitektur modular, serta keberhasilan implementasi model dalam sistem GUI *real-time* yang efisien dan operasional. Dengan demikian, kontribusi utama penelitian ini bukan hanya pada peningkatan akurasi model, tetapi juga pada perumusan strategi pemrosesan citra yang lebih efisien, stabil, dan aplikatif untuk sistem inspeksi kualitas buah dalam konteks smart farming dan otomatisasi industri. Temuan ini memberikan landasan penting bagi penelitian lanjutan pada komoditas pertanian lainnya dan pengembangan teknik peningkatan generalisasi melalui domain adaptation.

REFERENSI

- Adenugraha, S. P., Arinal, V., & Mulyana, D. I. (2022). Klasifikasi Kematangan Buah Pisang Ambon Menggunakan Metode Knn Dan Pca Berdasarkan Citra Rgb Dan Hsv. *Jurnal Media Informatika Budidarma*, 6(1), 9-17. <https://doi.org/10.30865/mib.v6i1.3287>
- Amrozi, Y., Yulianti, D., Susilo, A., Novianto, N., & Ramadhan, R. (2022). Klasifikasi Jenis Buah Pisang Berdasarkan Citra Warna Dengan Metode Svm. *Jurnal Sisfokom (Sistem Informasi Dan Komputer)*, 11(3), 394–399. <https://doi.org/10.32736/sisfokom.v11i3.1502>
- 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>
- Hazizah, C. Y., & Widiyaningtyas, T. (2024). Analisis Metode Collaborative Filtering Menggunakan Knn Dan Svd++ Untuk Rekomendasi Produk E-Commerce Tokopedia. *Edumatic: Jurnal Pendidikan Informatika*, 8(2), 595–604. <https://doi.org/10.29408/edumatic.v8i2.27793>
- Huda, F., & Putra, M. P. K. (2023). Klasifikasi Jenis Buah Pisang Menggunakan Algoritma Convolutional Neural Network. *Journal of Artificial Intelligence and Technology Information (JAITI)*, 1(3), 100-105. <https://doi.org/10.58602/jaiti.v1i3.61>
- Indahyanti, U., Azizah, N. L., & Setiawan, H. (2022). Pendekatan Ensemble Learning Untuk Meningkatkan Akurasi Prediksi Kinerja Akademik Mahasiswa. *Jurnal Sains Dan Informatika*, 8(2). <https://doi.org/10.34128/jsi.v8i2.459>
- Lee, J., Park, J., & Lee, Y. (2025). Toward Efficient Cancer Detection on Mobile Devices. *IEEE Access*, 13, 34613-34626. <https://doi.org/10.1109/ACCESS.2025.3543838>
- Maula, A. I., Triyanto, W. A., & Setiaji, P. (2025). Sistem Klasifikasi Kematangan Apel Fuji Berdasarkan Warna Menggunakan Knn Untuk Sortasi Otomatis. *Edumatic: Jurnal Pendidikan Informatika*, 9(2), 589–598. <https://doi.org/10.29408/edumatic.v9i2.31243>

- Merdiansah, R., Siska, S., & Ali Ridha, A. (2024). Analisis Sentimen Pengguna X Indonesia Terkait Kendaraan Listrik Menggunakan Indobert. *Jurnal Ilmu Komputer Dan Sistem Informasi (Jikomsis)*, 7(1), 221–228. <https://doi.org/10.55338/jikomsis.v7i1.2895>
- Navarro Ortiz, D. J., & Martinez Lopez, S. A. (2022). Automatic Identification of Banana Quality With Deep Neural Network Classification (Dnn). *Ciencia Y Tecnología*, 10, 37–56. <https://doi.org/10.18682/cyt.vi22.4609>
- Putri, A., Purisky Redaputri, A., & Rinova, D. (2022). Pemanfaatan Limbah Kulit Pisang Sebagai Pupuk Menuju Ekonomi Sirkular (Ukm Olahan Pisang Di Indonesia). *Jurnal Pengabdian Ukm*, 1(2), 104–109. <https://doi.org/10.36448/jpu.v1i2.20>
- Rifki Kosasih. (2021). Klasifikasi Tingkat Kematangan Pisang Berdasarkan Ekstraksi Fitur Tekstur Dan Algoritme Knn. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 10(4), 383–388. <https://doi.org/10.22146/jnteti.v10i4.462>
- Rukiastindari, S., Rohimah, L., Aprillia, A., Chodidjah, C., & Mutia, F. (2025). Model Hibrida K-Nearest Neighbors Berbasis Genethic Algorithm Untuk Prediksi Penyakit Ginjal Kronis. *Infotek: Jurnal Informatika Dan Teknologi*, 8(1), 44–55. <https://doi.org/10.29408/jit.v8i1.27918>
- Sejuti, Z. A., & Islam, M. S. (2023). A Hybrid Cnn–Knn Approach for Identification of Covid-19 With 5-Fold Cross Validation. *Sensors International*, 4, 100229. <https://doi.org/10.1016/j.sintl.2023.100229>
- Shahi, T. B., Sitaula, C., Neupane, A., & Guo, W. (2022). Fruit classification using attention-based MobileNetV2 for industrial applications. *Plos one*, 17(2), e0264586. <https://doi.org/10.1371/journal.pone.0264586>
- Sharifonnasabi, F., Jhanjhi, N. Z., John, J., Obeidy, P., Band, S. S., Alinejad-Rokny, H., & Baz, M. (2022). Hybrid HCNN-KNN model enhances age estimation accuracy in orthopantomography. *Frontiers in Public Health*, 10, 879418. <https://doi.org/10.3389/fpubh.2022.879418>
- Suhendri, S., & Kusriani, K. (2024). Systematic Literature Review: Klasifikasi Tingkat Kematangan Buah Pisang. *G-Tech: Jurnal Teknologi Terapan*, 8(4), 2379–2389. <https://doi.org/10.70609/gtech.v8i4.5059>
- Wang, Q., Chen, D., Feng, W., Sun, L., & Yu, G. (2025). Enhancing Instance Segmentation In Agriculture: An Optimized YOLOv8 Solution. *Sensors*, 25(17), 5506. <https://doi.org/10.3390/s25175506>
- Wardhani, A. S., Anggraeny, F. T., & Rizki, A. M. (2024). Penerapan Model Hibrida Cnn-Knn Untuk Klasifikasi Penyakit Mata. *Jati (Jurnal Mahasiswa Teknik Informatika)*, 8(3), 3662–3667. <https://doi.org/10.36040/jati.v8i3.9774>
- Widyawati, I. E., Tuty, S., & Nuraini, A. (2024). Tinjauan Sistematis Pemanfaatan Tanaman Pisang (*Musa Paradisiaca* L.) Wilayah Indonesia Sebagai Bahan Sediaan Kosmetik. *Antigen: Jurnal Kesehatan Masyarakat Dan Ilmu Gizi*, 2(3), 192–199. <https://doi.org/10.57213/antigen.v2i3.334>
- Shahi, T. B., Sitaula, C., Neupane, A., & Guo, W. (2022). Fruit classification using attention-based MobileNetV2 for industrial applications. *Plos one*, 17(2), e0264586. <https://doi.org/10.1371/journal.pone.0264586>