



KLASIFIKASI KEMATANGAN PISANG BERDASARKAN CITRA WARNA KULIT MENGGUNAKAN DECISION TREE DAN SUPPORT VECTOR MACHINE DENGAN INTEGRASI YOLOV8

Deva Gitisari^{1*}, Restu Putri Nisrina², Nayla Natania Putri³, Sujiliani Heristian⁴, Veti Apriana⁵, Rame Santoso⁶
^{1,2,3,4,5,6} Program Studi Informatika, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika.

^{*}15230267@bsi.ac.id

Jl. RS. Fatmawati Raya No. 24, Pd. Labu, Jakarta Selatan, DKI Jakarta, Indonesia

Article history: Received: 6 November 2025; Revised: 20 December 2025; Accepted: 31 December 2025

Abstract

In Indonesia, banana harvesting is often done before the fruit reaches physiological maturity. As a result, unripe bananas are often sold in the market. This study attempts to examine how well two machine learning algorithms, Decision Tree and Support Vector Machine (SVM), can determine banana ripeness. The evaluation uses a dataset of 6000 banana photos, which are characterized as unripe, ripe, overripe, or rotten. The dataset was split into an 80:20 ratio for training and testing, then evaluated using accuracy, precision, recall, and F1-Score metrics. The test results showed that the SVM algorithm achieved the maximum accuracy of 92%, exceeding Decision Tree, which obtained an accuracy of 82%. The best SVM model was then combined with YOLOv8 for real-time banana ripeness identification using a camera. This research contributes by demonstrating the effectiveness of the HSV-SVM combination and the real-time implementation using YOLOv8, offering a practical solution for automatic banana quality monitoring.

Keywords: Banana Ripeness; Machine Learning; Support Vector Machine; Decision Tree; YOLOv8; Image Processing.

Abstrak

Di Indonesia, panen pisang sering dilakukan sebelum buah mencapai kematangan fisiologis. Akibatnya, seringkali pisang yang belum matang beredar di pasaran. Tujuan dari penelitian ini adalah untuk mengevaluasi akurasi dua algoritma *Machine Learning*, yaitu *Decision Tree* dan *Support Vector Machine* (SVM) untuk menentukan tingkat kematangan pisang dengan menggunakan dataset 6000 gambar pisang yang dikategorikan *unripe*, *ripe*, *overripe*, dan *rotten*. Dataset dipecah dalam rasio 80:20 untuk data latih dan data uji. Kemudian, metrik akurasi, presisi, recall, dan skor F1 digunakan untuk menguji. Hasil pengujian menunjukkan algoritma SVM memiliki akurasi tertinggi 92%, melampaui *Decision Tree* yang memiliki akurasi 82%. Model SVM Terbaik kemudian dikombinasikan dengan YOLOv8 untuk identifikasi kematangan pisang secara *real-time* menggunakan kamera. Penelitian ini memberikan kontribusi dengan menunjukkan efektivitas kombinasi HSV-SVM serta implementasi *real-time* menggunakan YOLOv8 menawarkan solusi praktis untuk pemantauan kualitas pisang secara otomatis.

Kata Kunci: Kematangan Pisang; Machine learning; Support Vector Machine; Decision Tree; YOLOv8; Pengolahan Citra.



Pendahuluan

Di Indonesia, penentuan waktu panen pisang tidak hanya ditentukan oleh tingkat kematangan fisiologis buah, tetapi juga dipengaruhi oleh pertimbangan ekonomi dan keamanan. Kondisi ini membuat pisang kerap dipanen sebelum matang sempurna, sehingga buah yang belum siap konsumsi pun sering beredar di pasaran [1]. Umumnya, sebagian petani masih menentukan tingkat kematangan buah secara manual melalui pengamatan visual terhadap warna kulit pisang. Metode manual ini sangat bergantung pada subjektivitas manusia yang rentan terhadap kesalahan, hingga pada akhirnya dapat mempengaruhi cita rasa, tekstur, serta nilai jual buah [2].

Teknologi pengolahan citra digital dan kecerdasan buatan (*Artificial Intelligence*) adalah solusi yang sangat mungkin untuk mengatasi masalah yang terjadi. Komputer dapat meniru kemampuan penglihatan manusia untuk mengenali objek visual, seperti warna dan tekstur kulit, untuk mengetahui tingkat kematangan buah pisang secara otomatis [3]. Oleh karena itu, untuk mencapai tujuan tersebut dilakukan berbagai penelitian dengan metode berbasis *machine learning* dan *deep learning*.

Seperti yang telah dilakukan oleh Y. A. Nisa et al. dalam penelitiannya yang menunjukkan bahwa *Convolutional Neural Network* (CNN) mampu menghasilkan akurasi tinggi dalam klasifikasi kematangan pisang Ambon. Namun, pendekatan *deep learning* tersebut memiliki keterbatasan, antara lain kebutuhan dataset berukuran besar, sumber daya komputasi yang tinggi, serta rendahnya interpretabilitas terhadap proses pengambilan keputusan. Selain itu, penelitian tersebut hanya berfokus pada tahap klasifikasi, tanpa melibatkan proses deteksi objek untuk menentukan posisi buah pada citra [4]. Kemudian, metode CNN tersebut juga digunakan oleh A. Hastungkoro et al. dalam penelitiannya untuk mengidentifikasi tingkat kematangan pisang berdasarkan citra digital dengan memperoleh hasil akurasi yang tinggi serta mampu membedakan kualitas buah secara otomatis [5].

Seiring perkembangan teknologi deteksi objek, beberapa penelitian mulai mengintegrasikan tahap deteksi dalam sistem penentuan kematangan buah, R. E. Saragih, A. R. Purnajaya, I. Syafrinal et al. dalam jurnalnya mengusulkan sistem pendekripsi otomatis tingkat kematangan buah pisang dan mangga menggunakan arsitektur YOLOv8 [6]. Selain itu, penelitian yang dilakukan oleh R. Musa dan M. Akbar menerapkan metode *Learning Vector Quantization* (LVQ) untuk membedakan efektivitas metode *supervised classification* berbasis citra digital [7]. Meskipun demikian, pendekatan berbasis *deep learning* dan metode tertentu tersebut umumnya memiliki kompleksitas komputasi yang relatif tinggi atau tidak secara eksplisit membandingkan performa beberapa algoritma klasifikasi yang berbeda.

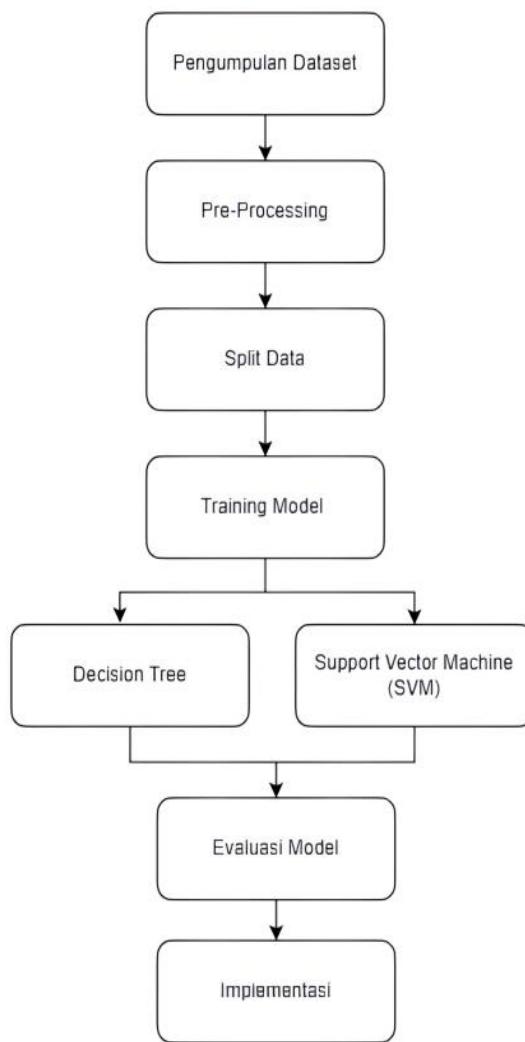
Sebaliknya, karena lebih ringan secara komputasi dan efektif untuk dataset berukuran sedang, algoritma *Machine Learning* klasik seperti *Decision Tree* dan *Support Vector Machine* (SVM) masih banyak digunakan. Pada jurnalnya, A. Sattar et al. menyatakan bahwa metode *Machine Learning* berbasis *Decision Tree* dapat menghasilkan hasil klasifikasi yang cepat dan mudah dipahami [8]. Sementara itu, menurut R. Kosasih, Sudaryanto dan A. Fahrurrozi menunjukkan bahwa dalam klasifikasi tingkat kematangan pisang, SVM masih memiliki kinerja yang baik dan stabil [9]. Namun, penelitian yang secara eksplisit membandingkan kinerja *Decision Tree* dan SVM dalam kerangka eksperimen yang sama masih sedikit. Ini terutama berlaku untuk klasifikasi kematangan pisang berdasarkan warna kulit.

Penelitian ini memilih algoritma *Decision Tree* dan *Support Vector Machine* (SVM) berdasarkan karakteristik data citra berbasis warna yang digunakan. SVM dikenal memiliki keunggulan dalam menangani pemisahan kelas *non-linear* pada data berdimensi tinggi seperti histogram warna, sehingga sering memberikan performa yang stabil pada klasifikasi berbasis fitur visual. Sementara itu, *Decision Tree* memiliki kelebihan dari sisi interpretabilitas model dan efisiensi komputasi, namun jika tidak dikendalikan dengan parameter yang tepat, *Decision Tree* seringkali rentan terhadap *overfitting*. Oleh karena itu, perbandingan kedua algoritma ini dilakukan untuk menemukan model yang sesuai untuk klasifikasi tingkat kematangan buah pisang secara akurasi dan efisiensi.

Berdasarkan permasalahan tersebut, penelitian ini akan membandingkan kinerja dua algoritma yaitu *Decision Tree* dan *Support Vector Machine* untuk membangun sistem klasifikasi otomatis tingkat kematangan buah pisang dengan menggunakan analisis citra warna kulit. Algoritma dengan nilai akurasi tertinggi akan digunakan sebagai model utama dalam sistem deteksi tingkat kematangan buah pisang dan diintegrasikan dengan YOLO (*You Only Look One*) sebagai tahap deteksi objek, sehingga posisi buah pada citra dapat diidentifikasi sebelum proses klasifikasi dilakukan. Integrasi ini memungkinkan sistem melakukan penilaian tingkat kematang buah pisang secara *real-time* melalui kamera. Pendekatan yang diusulkan diharapkan mampu menghasilkan penentuan tingkat kematangan yang lebih objektif, efisien dan mudah diimplementasikan serta memberikan kontribusi praktis bagi proses sortasi dan distribusi buah pisang di Indonesia.

Metode

Tujuan penelitian ini adalah untuk membuat sistem yang dapat melakukan klasifikasi otomatis untuk mengidentifikasi tingkat kematangan buah pisang dengan menggunakan analisis citra digital berbasis HSV dan algoritma pembelajaran mesin. Sistem ini kemudian diimplementasikan secara *real-time* dengan YOLOv8. Gambar 1 menunjukkan konsep metodologi penelitian.



Gambar 1. Konsep Penelitian

1. Pengumpulan Dataset

Para peneliti biasanya menggunakan metodologi pengumpulan data untuk memperoleh informasi yang diperlukan untuk penelitian mereka. Dataset adalah komponen penting dan harus ada dalam proses penelitian karena menjadi faktor utama dari penerapan algoritma agar dapat bekerja [10].

Dataset digunakan sebagai dasar penerapan algoritma *Machine Learning*. Dataset diambil dari website Kaggle dan terdiri dari 6000 citra yang terbagi rata dalam empat kategori tingkat kematangan buah pisang, yaitu *unripe* (mentah), *ripe* (matang), *overripe* (sangat matang) dan *rotten* (busuk). Seluruh dataset kemudian disimpan di Google Drive dan diatur ke dalam folder sesuai kategori tingkat kematangan.

2. Pre-Processing

Pre-processing atau *pra-pemrosesan* data adalah langkah yang dilakukan untuk meningkatkan kualitas dataset agar dapat digunakan secara efektif [10]. Setelah data dikumpulkan, ruang warna HSV (*Hue*, *Saturation*, *Value*) digunakan untuk mengubah citra pisang dari ruang warna BGR. Ini dilakukan dengan menggunakan OpenCV. Ruang warna HSV dipilih karena memiliki kemampuan untuk memisahkan informasi warna dari intensitas cahaya, sehingga lebih stabil terhadap variasi pencahayaan dan lebih representatif dalam membedakan perubahan warna kulit pisang pada berbagai tingkat kematangan dibandingkan ruang warna RGB yang lebih sensitif terhadap perubahan iluminasi [11].

Setiap kanal H, S, dan V memiliki histogram HSV dengan beberapa *bins* untuk ekstraksi fitur. Histogram yang dihasilkan kemudian dinormalisasi untuk memastikan konsistensi skala fitur antar citra. Histogram HSV mempresentasikan distribusi frekuensi piksel pada setiap kanal warna. Nilai histogram dinormalisasikan menggunakan persamaan:

$$h'_i = \frac{h_i}{\sum_{j=1}^n h_j}$$

dimana h_i adalah frekuensi piksel pada bin ke-1 dan n adalah jumlah bin histogram.

Penggunaan histogram HSV dipilih dibandingkan dengan fitur berbasis *Convolutional Neural Network* (CNN) karena penelitian ini berfokus pada algoritma *Machine Learning* klasik yang lebih ringan secara komputasi dan efektif untuk dataset berukuran sedang, serta lebih efisien untuk implementasi sistem real-time pada perangkat dengan keterbatasan sumber daya.

Fitur hasil ekstraksi disimpan dalam struktur data yang memuat *vektor* fitur, label dan lokasi citra. Proses dilakukan secara iteratif pada empat kategori tingkat kematangan pisang, yaitu *unripe*, *ripe*, *overripe* dan *rotten*, dengan jumlah data seimbang pada setiap kelas. Untuk mengurangi risiko *overfitting* dan mendorong kemampuan generalisasi model, fitur ditambahkan *noise* buatan berupa *Gaussian noise* beramplitudo rentang dengan nilai mean mendekati nol dan variansi kecil, sehingga hanya memberikan gangguan ringan pada distribusi histogram tanpa mengubah karakteristik utama data.

3. Split Data

Pada tahap ini, dataset dibagi menjadi dua bagian yaitu 20% data pengujian dan 80% data pelatihan. Data pengujian adalah data yang digunakan untuk mengevaluasi kinerja klasifikasi, sementara data pelatihan adalah data asli yang sesuai dengan fakta dan keadaan saat ini [12]. Pembagian ini sangat penting agar model dapat dilatih dan diuji dengan benar, dan agar kita dapat mengukur kinerja klasifikasinya terhadap data baru.

4. Pelatihan Model Decision Tree dan SVM

Pelatihan model saat ini terdiri dari dua algoritma klasifikasi yaitu *Decision Tree* dan *Support Vector Machine* (SVM). *Decision Tree* adalah algoritma klasifikasi yang sederhana namun efektif yang dapat memecahkan data kompleks menjadi banyak aturan yang dapat digunakan untuk analitik data [13]. Pada penelitian ini, dataset yang digunakan memiliki jumlah data yang seimbang untuk setiap kelas, sehingga tidak diperlukan prosedur data *balancing* tambahan seperti pengambilan sampel lebih banyak atau lebih sedikit.

Algoritma *Decision Tree* dilatih menggunakan dataset fitur hasil ekstraksi dan transformasi yang telah dilakukan sebelumnya. Model dibangun dengan parameter *maximum depth* sebesar 10 dan *minimum samples per leaf* sebesar 5. Pemilihan parameter tersebut dilakukan berdasarkan eksperimen awal

(preliminary experiments) untuk mengendalikan kompleksitas pohon dan mengurangi risiko *overfitting*. Selain itu, untuk memastikan stabilitas dan konsistensi kinerja model, evaluasi dilakukan menggunakan pendekatan *k-fold cross-validation* dengan nilai $k=5$.

Fungsi kernel digunakan oleh *Support Vector Machine* (SVM) untuk mengatasi keterbatasan pemisahan *linear* pada data. Kernel *Radial Basis Function* (RBF) digunakan karena dapat secara efektif menangkap hubungan *non-linear* antar komponen histogram HSV. Data *non-linear* diubah ke ruang dimensi yang lebih besar dengan kernel RBF, yang memungkinkan pemisahan kelas yang lebih baik [14]. Penelitian ini menggunakan kernel *Fungsi Basis Radial* (RBF) untuk membangun SVM dengan parameter $C=10$ dan $\gamma=0,01$. Proses pengaturan *hyperparameter* yang didasarkan pada eksperimen awal menghasilkan nilai parameter tersebut. Kemudian, untuk mengimbangi kompleksitas model dan kemampuan generalisasi, nilai parameter tersebut divalidasi menggunakan *cross-validation* berlipat ganda k ($k=5$). Selanjutnya, fitur dan label digunakan untuk melatih model, kemudian kinerjanya diuji menggunakan data uji yang telah ditentukan, Tabel 1 menunjukkan *Hyperparameter* Model Klasifikasi.

Tabel 1. *Hyperparameter* Model Klasifikasi

Model	Hyperparameter	Nilai
Decision Tree	Max Depth	10
Decision Tree	Min Samples Leaf	5
SVM (RBF)	C	10
SVM (RBF)	Gamma	0,01
Validasi	k-fold	5

5. Evaluasi Model

Untuk mengevaluasi model, capaian metrik klasifikasi yang dihasilkan oleh *Decision Tree* dan SVM dibandingkan, yang mencakup akurasi, presisi, *recall*, *support*, dan skor F1 [15].

Pada penelitian ini, evaluasi dilakukan menggunakan beberapa metrik utama yang diperoleh melalui hasil *classification report*, yaitu akurasi (*accuracy*), presisi (*precision*), *recall*, dan *F1-Score*. Selain itu, distribusi hasil prediksi antara kelas yang sebenarnya dan yang diprediksi oleh model digambarkan dengan menggunakan matriks *confusion*. Evaluasi dilakukan untuk menentukan metode yang memiliki performa paling efektif dalam identifikasi tingkat kematangan pisang, berdasarkan hasil perbandingan nilai performa tertinggi dari masing-masing metrik.

6. Implementasi

Pada tahap ini, implementasi dilakukan dengan mengintegrasikan model klasifikasi terbaik (*Decision Tree* atau SVM) dengan YOLOv8 untuk mendeteksi buah pisang secara *real-time*. YOLOv8 digunakan sebagai *object detector* untuk mendeteksi *Region of Interest* (ROI) buah pisang dari input video *webcam* atau kamera laptop [6]. YOLOv8 digunakan karena merupakan *single-stage object detector* yang memiliki kecepatan inferensi tinggi, sehingga sesuai untuk sistem deteksi dan klasifikasi tingkat kematangan buah pisang secara *real-time*.

Model YOLOv8 yang digunakan merupakan model pre-trained yang dilatih ulang (*fine tuning*) menggunakan dataset pisang untuk meningkatkan akurasi deteksi objek [6]. Arsitektur YOLOv8 yang digunakan adalah YOLOv8n karena lebih ringan dan sesuai implementasi *real-time*. Proses pelatihan YOLOv8 dievaluasi menggunakan metrik standar deteksi objek, yaitu mAP50.

Setelah ROI buah pisang terdeteksi, area tersebut dikonversi ke ruang warna HSV, diekstraksi histogram HSV-nya, kemudian dinormalisasi. Fitur ini selanjutnya dimasukkan ke dalam model klasifikasi SVM atau *Decision Tree* untuk menentukan tingkat kematangan pisang. *Pipeline* sistem secara keseluruhan terdiri dari tahapan YOLOv8 → ekstraksi ROI → HSV extraction → histogram HSV → klasifikasi tingkat kematangan.

Pembahasan

Set data yang digunakan dalam penelitian atau eksperimen disebut dataset [16]. Dalam kasus ini, dataset sebesar 6000 gambar dikumpulkan dari Kaggle dan dibagi menjadi empat kategori kematangan buah pisang meliputi unripe, ripe, overripe, dan rotten. Algoritma *Decision Tree* dan *SVM* merupakan algoritma klasifikasi dalam *Machine Learning*. *Decision Tree* merupakan algoritma yang membangun model yang membentuk pohon keputusan dengan memprediksi ketentuan dari berbagai fakta dari proses klasifikasi dan prediksi [17]. Namun, *Support Vector Machine* (*SVM*) adalah algoritma yang menggunakan *hyperlane* dan *margin* maksimum untuk mengklasifikasikan data secara *linear* dan *non-linear* [18].

Penerapan *Decision Tree* pada fitur warna HSV menunjukkan adanya pola kesalahan klasifikasi pada masing-masing kelas kematangan buah pisang. Hal ini disebabkan oleh mekanisme pemisahan berbasis *threshold* lokal pada fitur HSV yang membuat model sangat menyesuaikan diri terhadap pola spesifik pada data latih. Kondisi tersebut menunjukkan kemungkinan *overfitting* yang ditunjukkan pada penurunan performa data *testing*. Kesalahan klasifikasi sering terjadi pada kelas *overripe* dan *rotten* karena memiliki karakteristik warna kulit pisang yang saling tumpang tindih pada nilai *Hue* dan *Saturation*. Perubahan warnanya yang bersifat *gradual* membuat pemisahan antar kelas pada fitur HSV menjadi kurang jelas.

SVM memiliki kemampuan untuk memodelkan hubungan *non-linear* pada fitur warna HSV dengan margin maksimum sehingga dapat menunjukkan performa yang lebih stabil dan juga konsisten. Hal tersebut membuatnya lebih *robust* terhadap distribusi warna antar kelas yang tumpang tindih, sehingga secara teoritis *SVM* mampu untuk lebih unggul dalam klasifikasi tingkat kematangan berbasis fitur warna HSV. Penerapan kedua algoritma klasifikasi berbasis fitur warna HSV tersebut menampilkan perbedaan performa antara model jika dibandingkan dengan KKN sebagai model *baseline*.

Penelitian ini menggunakan algoritma *Decision Tree* dan *SVM* untuk melakukan perbandingan kinerja untuk menentukan proses klasifikasi yang paling akurat. Tujuan dari algoritma ini adalah untuk membantu mendeteksi tingkat kematangan buah pisang dengan akurat dan efisien. YOLO merupakan algoritma *deep learning* CNN yang menggunakan fitur deteksi kotak batas untuk mendeteksi objek dan mengklasifikasikan gambar atau video. YOLO memiliki banyak versi, dan YOLOv8 dirilis pada tahun 2023 dan lebih cepat, akurat, dan efektif [19]. YOLOv8 menjadi algoritma yang diimplementasikan pada perangkat lunak deteksi kematangan buah pisang untuk membantu dalam mendeteksi objek pisang pada citra. Selain itu, YOLOv8 dapat membedakan objek pisang dari objek lain yang bukan pisang. Dengan demikian, hanya objek pisang yang relevan yang akan digunakan pada tahap klasifikasi tingkat kematangan.

Hasil

Hasil penelitian dikumpulkan berdasarkan melalui dua tahapan utama yaitu pengolahan dan pengujian model klasifikasi, serta implementasi model terbaik dengan YOLOv8.

1. Hasil Pengujian Model Klasifikasi

Pada tahap ini, klasifikasi tingkat kematangan buah pisang dilakukan melalui penggunaan dua algoritma *Machine Learning* yaitu *Decision Tree* dan *Support Vector Machine*. Selain itu, perbandingan *baseline* menggunakan KNN juga dilakukan. Sebelum klasifikasi, gambar pisang secara keseluruhan diekstraksi menggunakan ruang warna HSV (*Hue*, *Saturation*, *Value*) untuk menghasilkan fitur warna yang menunjukkan karakteristik visual masing-masing kelas, seperti *unripe*, *ripe*, *overripe*, an *rotten*.

Tabel 2. Perbandingan Akurasi *Decision Tree*

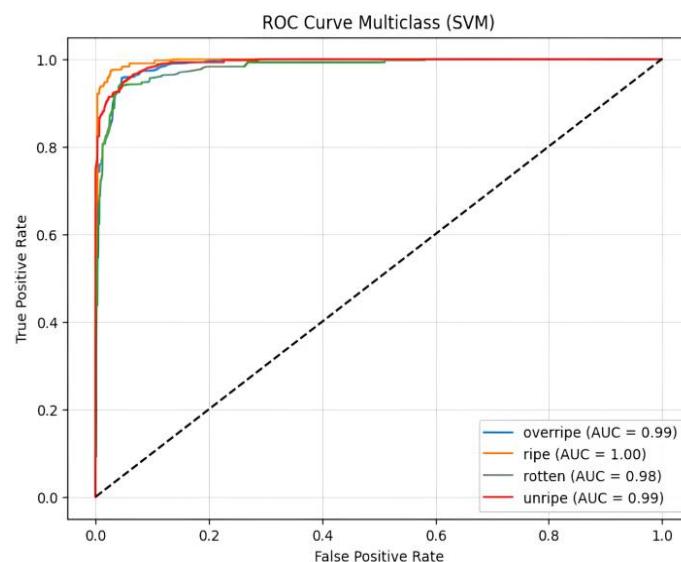
Model	Accuracy (Train)	Accuracy (Test)
<i>Decision Tree</i>	0.88	0.82

Menurut Tabel 2, pengujian model *Decision Tree* menunjukkan akurasi sebesar 0,88 untuk data pelatihan dan akurasi sebesar 0,82 untuk seluruh data pengujian. Hasil menunjukkan bahwa kinerja model menurun, yang membuktikan bahwa model masih memiliki kemampuan yang baik untuk mempelajari pola penyebaran data. Namun, kemungkinan generalisasi untuk data baru masih rendah. Sebagai perbandingan untuk menentukan model terbaik, pengujian juga dilakukan dengan menggunakan SVM.

Tabel 3. *Support Vector Machine (SVM)*

Kelas	Precision	Recall	F1-Score	Support
Overripe	0.89	0.93	0.91	300
Ripe	0.96	0.94	0.95	300
Rotten	0.89	0.91	0.90	300
Unripe	0.95	0.89	0.92	300
Accuracy			0.92	1200
Macro Avg	0.92	0.92	0.92	1200
Weighted Avg	0.92	0.92	0.92	1200

Hasil pengujian yang ditunjukkan pada Tabel 3, menunjukkan bahwa SVM memiliki akurasi sebesar 0,92. Selain itu, nilai presisi *recall*, dan *F1-Score* untuk kelas secara keseluruhan menunjukkan kinerja yang seimbang dan konsisten. Selain itu, dilakukan juga evaluasi performa SVM dengan menggunakan kurva ROC *Multiclass* yang dapat dilihat pada Gamabar 2 di bawah.

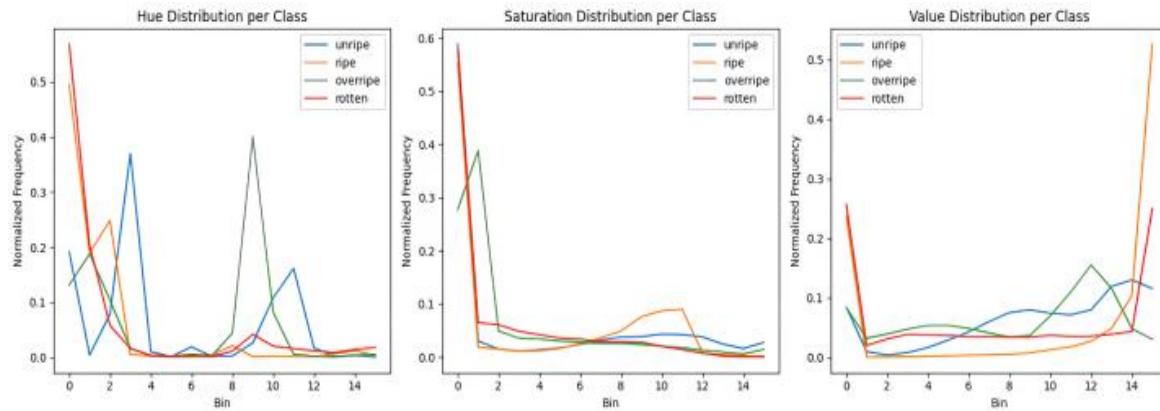
Gambar 2. Kurva ROC *Multiclass*

Kurva ROC menunjukkan kemampuan model untuk membedakan setiap kelas dengan tingkat diskriminasi yang kuat. Nilai Area Dibawah Curve (AUC) pada Gambar 2 menunjukkan bahwa nilai 1,00 untuk kelas *ripe*, 0,98 untuk kelas *rotten*, 0,99 untuk kelas *unripe*, dan nilai yang tinggi untuk kelas *overripe*. Selanjutnya sebagai model *baseline*, *K-Nearest Neighbor* (KNN) juga dilakukan pengujian untuk mendapatkan hasil performa klasifikasi.

Tabel 4. Pengujian Model *Baseline KNN*

Kelas	Precision	Recall	F1-Score	Support
Overripe	0.88	0.89	0.88	300
Ripe	0.97	0.87	0.92	300
Rotten	0.81	0.93	0.86	300
Unripe	0.93	0.86	0.89	300
Accuracy			0.89	1200
Macro Avg	0.89	0.89	0.89	1200
Weighted Avg	0.89	0.89	0.89	1200

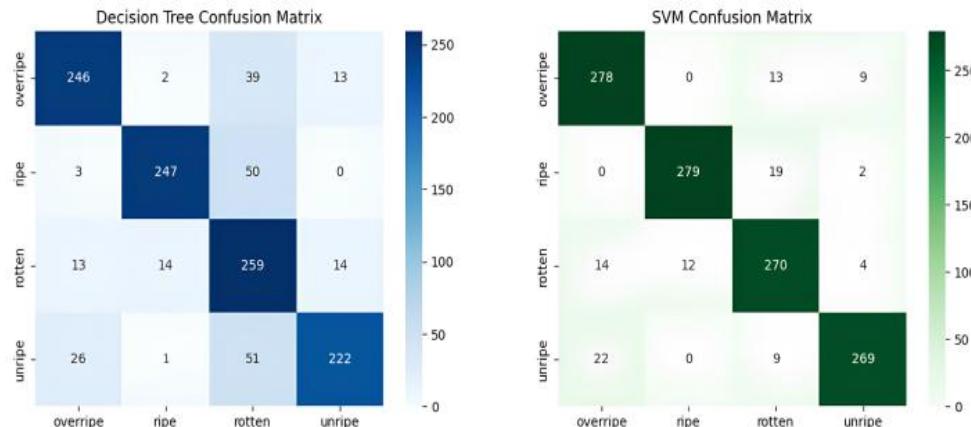
Berdasarkan hasil yang ditunjukkan pada Tabel 4, nilai akurasi KNN memperoleh sebesar 0,89. Namun, meskipun model ini mampu mengklasifikasikan kelas *ripe* dan *unripe* dengan baik, performa yang dihasilkan masih lebih rendah dan dibawah model SVM jika didasarkan pada nilai akurasi dan *F1-Score*. Setelah dilakukan pengujian model untuk mendapatkan hasil akurasi dari model, visualisasi histogram HSV juga dilakukan untuk melihat perbedaan dan tumpang tindih karakteristik warna antar kelas.



Gambar 3. Visualisasi Histogram HSV

Visualisasi histogram HSV pada Gambar 3 menunjukkan pola distribusi warna yang berbeda. Pada kanal *Hue*, kelas *unripe* dan *ripe* memiliki distribusi yang relatif terpisah, sedangkan pada kelas *overripe* dan *rotten* menunjukkan distribusi yang tumpang tindih. Pola serupa pada kelas *overripe* dan *rotten* juga terlihat pada kanal *Saturation* dan *Value*, di mana perbedaan antar kelas pada fase akhir kematangan tidak tegas. Hasil tersebut menunjukkan bahwa fitur warna HSV memiliki keterbatasan dalam membedakan kelas *overripe* dan *rotten*.

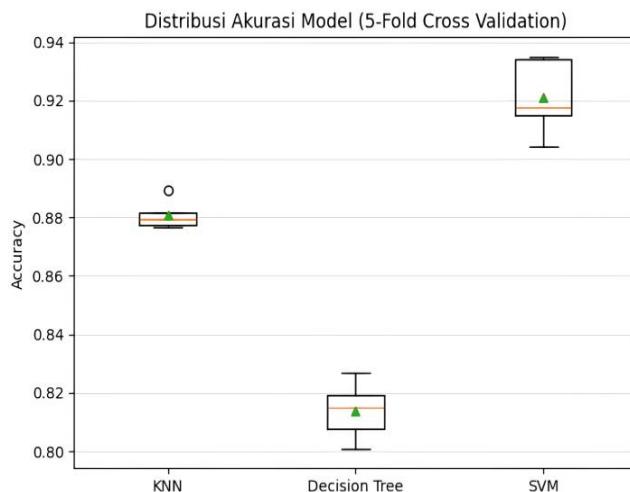
Hasil distribusi warna tersebut kemudian dievaluasi lebih lanjut dengan pembuatan *confusion matrix* untuk melihat pola kesalahan klasifikasi pada masing-masing model.



Gambar 4. Confusion Matrix

Gambar 4 menunjukkan hasil *confusion matrix* yang menunjukkan bahwa model Decision Tree dan *Support Vector Machine* (SVM) berbeda dalam mengklasifikasikan tingkat kematangan buah pisang. Hasil *confusion matrix* dari model *Decision Tree* menunjukkan kesalahan yang cukup signifikan pada 54 sampel *overripe* dan 48 sampel *unripe*. Hal tersebut menunjukkan bahwa *Decision Tree* mengalami kesulitan untuk memisahkan kelas yang memiliki warna yang berdekatan.

Sementara itu pada model *Support Vector Machine* (SVM), *confusion matrix* menunjukkan diagonal utama dengan jumlah kesalahan yang lebih sedikit di seluruh kelas dan memiliki jumlah prediksi benar yang tinggi di kelas *ripe* dengan total sebanyak 291 sampel dan *unripe* sebanyak 270 sampel. Hasil tersebut menunjukkan kemampuan klasifikasi SVM lebih stabil dibandingkan dengan *Decision Tree*. Uji statistik dengan *paired t-test* dilakukan untuk memastikan perbedaan dalam kinerja model.



Gambar 5. Boxplot Distribusi Akurasi

Berdasarkan hasil pengujian *5-fold cross validation* pada *boxplot* di Gambar 5, ditunjukkan bahwa model SVM memiliki nilai akurasi tertinggi sebesar 0,92 dan sebarannya yang sempit menunjukkan performa yang lebih stabil. Model KNN menunjukkan akurasi 0,88 untuk performa menengah, dan *Decision Tree* dengan sebaran yang lebar menunjukkan akurasi terendah 0,81. Nilai-nilai ini menunjukkan bahwa performa tidak stabil. Penelitian ini juga melakukan uji signifikansi dengan melakukan uji *paired t-test* untuk memastikan perbedaan performa yang bersifat signifikan.

Tabel 5. Tabel Uji Signifikansi

Perbandingan	p-value
Decision Tree vs SVM	0,00018
Decision Tree vs KNN	0,00014
SVM vs KNN	0,00115

Dari hasil uji signifikansi pada Tabel 5 tersebut menunjukkan bahwa perbedaan model bersifat signifikan yang dibuktikan dengan perbandingan antar model memiliki nilai *p-value* < 0,05.

Secara umum, dalam proses klasifikasi tingkat kematangan buah pisang, model *Support Vector Machine* (SVM) bekerja lebih baik daripada *Decision Tree*. Hasil pengujian ini menunjukkan bahwa SVM lebih cocok untuk tugas klasifikasi pada dataset ini karena mereka memberikan hasil yang lebih akurat, stabil, dan konsisten.

2. Hasil Implementasi dengan YOLOv8

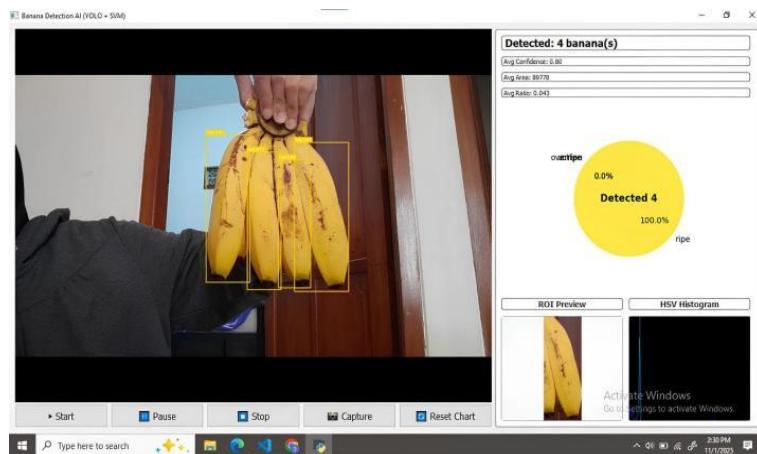
Untuk mencapai tahap implementasi ini, penggunaan YOLOv8 dan *Support Vector Machine* (SVM) yang dianggap sebagai model klasifikasi terbaik berdasarkan hasil pengujian sebelumnya diterapkan. Pada tahap ini memiliki tujuan agar sistem dapat mendeteksi objek pisang melalui kamera dan mengklasifikasikan tingkat kematangan buah pisang secara *real-time*.

Proses implementasi diawali dengan deteksi objek menggunakan YOLOv8 yang berfungsi untuk mengenali dan membedakan objek yang merupakan pisang dan yang bukan pisang. Setelah objek pisang terdeteksi, setiap area yang berisi objek pisang (*Region of Interest* atau ROI) akan diekstraksi oleh sistem melalui fitur warna HSV yang menjadi dasar dalam menentukan tingkat kematangan pisang. Nilai-nilai HSV ini kemudian dijadikan input bagi model SVM untuk melakukan klasifikasi ke dalam empat kategori, yaitu *unripe*, *ripe*, *overripe* dan *rotten*.

Hasil klasifikasi dari SVM kemudian ditampilkan langsung pada antarmuka aplikasi berbasis PyQt5 GUI. Setiap objek pisang yang terdeteksi akan diberi *bounding box* berwarna berbeda sesuai kelas kematangannya seperti hijau untuk *unripe*, kuning untuk *ripe*, orange untuk *overripe* dan coklat untuk *rotten*. Tidak lupa dengan label pada setiap *bounding box* juga akan menampilkan kelas prediksi dan nilai *confidence* dari hasil klasifikasi.

Selain itu sistem juga akan menampilkan nilai rata-rata *confidence*, luas area deteksi dan *ratio* ukuran objek pada panel informasi disebelah kanan *frame*. Dilengkapi juga dengan visualisasi histogram HSV untuk menunjukkan distribusi warna pada area pisang yang sedang dianalisis serta grafik *pie chart* yang memperlihatkan persentase jumlah pisang pada setiap kategori kematangan secara keseluruhan.

Berdasarkan hasil pengujian implementasi dilakukan secara langsung dengan menggunakan kamera laptop untuk mendeteksi dan mengklasifikasikan tingkat kematangan buah pisang secara *real-time*, sistem mampu menampilkan proses deteksi dan klasifikasi dengan baik namun tingkat akurasi hasil deteksi masih belum sepenuhnya stabil. Ketidakakuratan tersebut disebabkan oleh beberapa faktor terutama kualitas kamera laptop yang rendah dan pencahayaan ruangan yang tidak konstan sehingga mempengaruhi hasil ekstraksi fitur warna HSV pada citra pisang.



Gambar 6. Pengujian Sistem menggunakan Kamera HP

Untuk mengatasi hal tersebut, Gambar 6 menunjukkan dilakukan pengujian ulang dengan menggunakan kamera ponsel yang dihubungkan ke laptop melalui aplikasi Iriun Webcam. Pengujian ini masih dilakukan dengan cara kualitatif berdasarkan observasi visual dari hasil deteksi dan klasifikasi yang ditampilkan sistem.

Hasilnya menunjukkan bahwa deteksi citra dengan menggunakan kamera ponsel menampilkan citra yang lebih tajam sehingga hasil klasifikasi menjadi lebih baik. Hal ini disebabkan karena kamera ponsel memiliki resolusi dan penyesuaian cahaya otomatis yang lebih optimal sehingga sistem dapat mengenali warna dan pola permukaan pisang dengan lebih jelas. Namun, peningkatan kinerja ini belum diukur dengan metrik kuantitatif, yang merupakan salah satu keterbatasan penelitian ini.

Kesimpulan dan Saran

Penelitian ini menunjukkan bahwa ekstraksi kulit menggunakan ruang warna HSV berhasil menunjukkan berbagai tingkat kematangan buah pisang. Hasil perbandingan menunjukkan bahwa algoritma *Support Vector Machine* (SVM) lebih baik daripada *Decision Tree*. SVM memiliki akurasi 92%, sedangkan *Decision Tree* memiliki 82%. SVM juga memiliki nilai *precision*, *recall*, dan *F1-score* yang lebih konsisten, yang menunjukkan bahwa model ini mampu melakukan generalisasi yang lebih baik terhadap data yang diuji.

Implementasi model terbaik, yaitu SVM yang digabungkan dengan YOLOv8, mampu mendeteksi dan mengklasifikasikan tingkat kematangan buah pisang secara *real-time* melalui kamera. Sistem dapat mengenali objek pisang, menampilkan label prediksi, serta membedakan setiap tingkat kematangan dengan cukup akurat. Namun, kualitas kamera dan kondisi pencahayaan sangat mempengaruhi hasil klasifikasi yaitu penggunaan kamera dengan resolusi tinggi dan pencahayaan stabil dapat meningkatkan akurasi sistem secara signifikan. Secara keseluruhan, penelitian ini menunjukkan bahwa penggabungan algoritma YOLOv8 dan *Support Vector Machine* (SVM) adalah metode yang efektif untuk membangun sistem yang dapat mendeteksi dan mengklasifikasikan

tingkat kematangan pisang secara otomatis, akurat, dan efisien. Ini berarti bahwa algoritma tersebut dapat diterapkan dalam proses standarisasi dan objektif untuk sortasi dan distribusi buah.

Penulis menyadari bahwa penelitian ini tidak terlepas dari berbagai keterbatasan. Oleh sebab itu, penulis memberikan beberapa rekomendasi yang diharapkan dapat dimanfaatkan oleh peneliti berikutnya untuk melakukan penelitian yang serupa. Dengan menggunakan model deep learning lain seperti CNN, penelitian ini dapat dikembangkan untuk membandingkan kinerja SVM dalam mendekripsi tingkat kematangan buah pisang. Selain itu, penelitian ini berpotensi dikembangkan menjadi aplikasi berbasis Android sehingga proses deteksi pisang dapat dilakukan secara langsung menggunakan kamera ponsel tanpa terhubung menggunakan aplikasi tambahan.

Referensi

- [1] D. Andriansyah, E. Mufida, N. Iriadi, R. S. Anwar, and L. K. Rahayu, "Klasifikasi Kualitas Buah Pisang Berdasarkan Waktu Panen dan Tingkat Kematangan Menggunakan Metode SVM & KNN," *SATIN - Sains dan Teknol. Inf.*, vol. 10, no. 1, pp. 147-156, 2023, doi: 10.33372/stn.v9i2.1000.
- [2] Rendika Efando and Anisya Sonita, "Klasifikasi Tingkat Kematangan Buah Matoa Menggunakan Metode PCA dan KNN Berdasarkan Warna RGB," *JSAI (Journal Sci. Appl. Informatics)*, vol. 8, no. 2, pp. 337-346, Jun. 2025, doi: 10.36085/jsai.v8i2.7851.
- [3] Tjokorda Istri Agung Pandu Yuni Maharani, I Gusti Agung Indrawan, Gede Dana Pramitha, Christina Purnama Yanti, and I Made Marthana Yusa, "Classification of Cavendish Banana Ripeness With CNN Method," *Indones. J. Data Sci.*, vol. 6, no. 2, pp. 203-210, Jul. 2025, doi: 10.56705/ijodas.v6i2.259.
- [4] Y. A. Nisa, C. A. Sari, E. H. Rachmawanto, and N. Mohd Yaacob, "Ambon Banana Maturity Classification Based On Convolutional Neural Network (CNN)," *SinkrOn*, vol. 8, no. 4, pp. 2568-2578, Oct. 2023, doi: 10.33395/sinkron.v8i4.12961.
- [5] A. W. Hastungkoro, A. D. Putro Wicaksono, and Y. Diah Rosita, "Klasifikasi Kualitas dan Kematangan Pisang Cavendish Menggunakan Convolutional Neural Network," *J. SAINTEKOM*, vol. 14, no. 2, pp. 185-194, Sep. 2024, doi: 10.33020/saintekom.v14i2.686.
- [6] R. E. Saragih, Y. Pernando, A. J. Santoso, Y. Roza, M. KH, and I. Verdian, "Optimizing the Sorting of Barangan Bananas Through Hybrid and Transfer Learning Approaches," no. April, 2025, doi: 10.24507/icicel.19.04.459.
- [7] R. Musa and M. Akbar, "Identification of Formaldehyde Bananas using Learning Vector Quantization," *Indones. J. Inf. Syst.*, vol. 3, no. 2, pp. 160-170, Feb. 2021, doi: 10.24002/ijis.v3i2.4110.
- [8] A. Sattar, M. A. M. Ridoy, A. K. Saha, H. M. H. Babu, and M. N. Huda, "A comprehensive approach to detecting chemical adulteration in fruits using computer vision, deep learning, and chemical sensors," *Intell. Syst. with Appl.*, vol. 23, no. June, p. 200402, Sep. 2024, doi: 10.1016/j.iswa.2024.200402.
- [9] R. Kosasih, S. Sudaryanto, and A. Fahrurrozi, "Classification of six banana ripeness levels based on statistical features on machine learning approach," *Int. J. Adv. Appl. Sci.*, vol. 12, no. 4, pp. 317-326, Dec. 2023, doi: 10.11591/ijaas.v12.i4.pp317-326.
- [10] M. I. Khalif and L. Edi Prabowo, "Penerapan Model Algoritma Unsupervised Learning untuk Klasterisasi Tingkat Kenyamanan Ruang Tidur berdasarkan Faktor Lingkungan," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 12, no. 2, pp. 311-320, Apr. 2025, doi: 10.25126/jtiik.2025129456.
- [11] H. A. Ramadhan and S. Sriani, "Klasifikasi Tingkat Kematangan Buah Salak Sidempuan Menggunakan K-Nearest Neighbor pada Ruang Warna HSV," *INSOLOGI J. Sains dan Teknol.*, vol. 4, no. 4, pp. 997-1012, Aug. 2025, doi: 10.55123/insologi.v4i4.6298.
- [12] P. Astuti, "Klasifikasi Kualitas Buah Apel Dengan Algoritma K-Nearest Neighbor (K-NN)

Menggunakan Bahasa Pemrograman Python," *Comput. Sci.*, vol. 4, no. 2, pp. 127–132, Jul. 2024, doi: 10.31294/coscience.v4i2.3328.

- [13] Y. Jumaryadi, "Klasifikasi Penyakit Kardiovaskular Menggunakan Algoritma Decision Tree C4.5," *J. Ilm. FIFO*, vol. 17, no. 1, pp. 1–6, Jun. 2025, doi: 10.22441/fifo.2025.v17i1.001.
- [14] Y. Amrozi, D. Yuliati, A. Susilo, N. Novianto, and R. Ramadhan, "Klasifikasi Jenis Buah Pisang Berdasarkan Citra Warna dengan Metode SVM," *J. Sisfokom (Sistem Inf. dan Komputer)*, vol. 11, no. 3, pp. 394–399, Dec. 2022, doi: 10.32736/sisfokom.v11i3.1502.
- [15] M. Juventus Dappa Deke, T. Atha Anastasya, A. Diani Putri Saka, and E. Yulia Puspaningrum, "Analisis Pengaruh Metode Ekstraksi Fitur Citra Batik Terhadap Kinerja Klasifikasi SVM," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 5, pp. 7516–7523, Jul. 2025, doi: 10.36040/jati.v9i5.14752.
- [16] Y. Yuliska and K. U. Syaliman, "Literatur Review Terhadap Metode, Aplikasi dan Dataset Peringkasan Dokumen Teks Otomatis untuk Teks Berbahasa Indonesia," *IT J. Res. Dev.*, vol. 5, no. 1, pp. 19–31, Jul. 2020, doi: 10.25299/itjrd.2020.vol5(1).4688.
- [17] D. Septhya *et al.*, "Implementasi Algoritma Decision Tree dan Support Vector Machine untuk Klasifikasi Penyakit Kanker Paru," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 3, no. 1, pp. 15–19, May 2023, doi: 10.57152/malcom.v3i1.591.
- [18] M. K. Risqi, I. W. D. Prastyo, and M. J. Vikri, "Comparison of Decision Tree Algorithms and Support Vector Machine (SVM) In Depression Classification In Students," *Eduvest - J. Univers. Stud.*, vol. 5, no. 4, pp. 4557–4567, May 2025, doi: 10.59188/eduvest.v5i4.51108.
- [19] A. A. Rasjid, B. Rahmat, and A. N. Sihananto, "Implementasi YOLOv8 Pada Robot Deteksi Objek," *J. Technol. Syst. Inf.*, vol. 1, no. 3, pp. 1–9, Jul. 2024, doi: 10.47134/jtsi.v1i3.2969.