

Deteksi Kematangan Buah Cabai menggunakan YOLOv11

Detecting Chili Ripeness Using YOLOv11

¹Andika Ramadian Pratama*, ²Alfiah Fajriani, ³Sitti Najmia Rifai

^{1,2}Program Studi Sistem Teknologi dan Informasi, Fakultas Teknik, Universitas Muhammadiyah Kendari

³Program Studi Komunikasi dan Penyiaran Islam, Fakultas Ushuluddin Adab dan Dakwah, Institut Agama Islam Negeri Kendari

^{1,2}Jl. KH. Ahmad Dahlan No. 10, Kota Kendari Sulawesi Tenggara 93117

³Jl. Sultan Qaimuddin No. 17, Baruga, Kota Kendari, Sulawesi Tenggara

*e-mail: andika.22221005@umkendari.ac.id, alfiah.fajriani@umkendari.ac.id, sittinajmia17@iainkendari.ac.id

(received: 27 January 2026, revised: 10 February 2026, accepted: 11 February 2026)

Abstrak

Penelitian ini bertujuan untuk mengembangkan sistem deteksi kematangan cabai berbasis *deep learning* menggunakan model YOLOv11. Kematangan cabai diklasifikasikan menjadi tiga kelas: mentah, setengah matang, dan matang. Dataset yang digunakan terdiri dari 150 gambar asli yang kemudian ditambah menjadi 300 gambar untuk meningkatkan variasi data. Pelatihan model dilakukan menggunakan platform *Roboflow*, sedangkan pengujian *accuracy* dilakukan melalui *Google Colab* dengan metode pemrosesan *upload image*. Hasil pengujian menunjukkan bahwa model mencapai *accuracy* 93,94% dengan nilai *precision* 94,21%, *recall* 93,94% dan *F1-score* mencapai 93,94% pada data uji. Sistem ini diharapkan dapat membantu otomatisasi penyortiran cabai berdasarkan kematangannya.

Kata kunci: *chili fruit detection, computer vision, deep learning, ripeness classification, YOLOv11*

Abstract

This study aims to develop a deep learning-based chili ripeness detection system using the YOLOv11 model. Chili ripeness is classified into three categories: unripe, semi-ripe, and ripe. The dataset consists of 150 original images, which were expanded to 300 images to increase data variation. Model training was conducted using the Roboflow platform, while accuracy testing was performed in Google Colab through an image upload-based processing method. The experimental results show that the model achieved an accuracy of 93.94%, with a precision of 94.21%, recall of 93.94%, and an F1-score of 93.94% on the test dataset. This system is expected to support the automation of chili sorting based on ripeness levels.

Keywords: *chili fruit detection, computer vision, deep learning, ripeness classification, YOLOv11*

1 Pendahuluan

Dengan menjadi salah satu penghasil dan konsumen cabai terbesar di dunia, proses *sortasi* dan penilaian kematangan pascapanen cabai di Indonesia hingga saat ini masih sangat mengandalkan tenaga manusia [1]. Metode *sortasi* dan penilaian kematangan pascapanen cabai yang ada masih menggunakan metode manual berdasarkan pengalaman yang dikuasai oleh SDM. Selain lambat, mahal, dan rentan terhadap kelelahan, metode ini juga cenderung *subjektif* dan *inkonsisten*. Sebagai akibat dari kondisi ini, kualitas produk yang di pasaran menjadi tidak seragam, harga yang tidak stabil terjadi dan petani serta rantai pasok sering menghasilkan kerugian ekonomi. Dalam era Pertanian 4.0, di mana otomatisasi dan *precision* menjadi kunci utama, ketergantungan pada cara tradisional ini merupakan faktor penghambat utama yang menghambat efisiensi, produktivitas, dan daya saing peningkatan komoditas bernilai tinggi seperti cabai.

Tantangan teknis terbesar bersumber dari sifat *morfologi* (bentuk) buah yang khas. Cabai, tidak seperti tomat atau apel, bukan bulat dan mudah dipindai. Sebaliknya, cabai panjang pipih dan

seringkali melengkung dan tidak merata sepanjang buahnya. Mereka juga tidak matang menjadi warna merah “muda” yang tetap *konstan*; sebaliknya, cabai matang menjadi warna merah lebih tua dari warna hijau ke kuning, ke oranye dan kemudian menjadi merah. Secara *biologis*, cabai yang telah mencapai fase *generatif* (dewasa) ditandai dengan pertumbuhan dalam kelompok dan cenderung tumbuh diatas dedaunan serta sesama tanaman cabai, menciptakan bayangan dan kerumitan ketebalan. Kombinasi fitur *morfologi* dan lingkungan ini menghasilkan tugas klasifikasi secara manual yang rumit, dibuktikan oleh kebutuhan untuk memanfaatkan teknologi untuk memberikan tingkat *accuracy* dan konsistensi yang tinggi.

Untuk menjawab tantangan tersebut, teknologi kecerdasan buatan, terutama *deep learning* untuk deteksi objek, menawarkan solusi yang potensial. Diantara berbagai arsitektur, algoritma ‘*You Only Look Once*’ telah terbukti unggul dalam deteksi objek waktu nyata. Dalam penelitian ini, YOLOv11 dipilih sebagai fondasi pengembangan sistem berdasarkan karakteristik dan fitur teknis yang dinilai lebih sesuai dibandingkan beberapa generasi sebelumnya, seperti YOLOv5 dan YOLOv8 [2], karena kelebihan teknis yang signifikan. YOLOv11 dilaporkan memiliki peningkatan desain arsitektur, terutama dalam mendeteksi objek berukuran sangat kecil dan dengan rasio aspek yang *ekstrem* [3], yang sangat krusial untuk menangkap ujung cabai yang tipis. Selain itu, mekanisme *neck* dan *head* jaringan yang lebih efisien pada YOLOv11 meningkatkan kategorisasi dan keakuratan dalam membedakan objek yang saling berhimpitan [3], suatu kondisi yang sangat umum di kebun cabai.

Pendekatan berbasis *deep learning* ini terbukti mampu menggantikan proses penilaian manual ahli dengan sistem visi komputer yang andal [4]. Kinerja sistem semacam ini tidak hanya bergantung pada kuantitas data, tetapi juga pada variasi, resolusi, dan strategi augmentasi dataset. Studi menunjukkan bahwa bahkan dataset dengan ratusan gambar dapat mencapai kinerja yang layak dalam skenario pertanian terkontrol jika memiliki variasi yang memadai [5]. Lebih lanjut, identifikasi tingkat kematangan buah dapat dilakukan secara akurat berdasarkan analisis perbedaan warna dan fitur visual lainnya. Validasi pendekatan ini didukung oleh bukti bahwa penilaian berbasis gambar digital yang konsisten dapat mencapai tujuan yang sama dengan evaluasi sensorik tradisional, tanpa selalu memerlukan verifikasi langsung dari ahli pertanian [6]. Dengan demikian, integrasi YOLOv11 dengan dataset yang dirancang secara cermat menawarkan landasan yang kuat untuk mengembangkan sistem otomatis yang objektif dan konsisten.

Secara keseluruhan, penelitian ini memiliki makna ganda. Secara teknis, studi ini mengevaluasi dan mengatur ulang kemampuan model terkini dalam konteks pertanian yang lebih maju dan kurang dimanfaatkan. Praktis, hasil penelitian ini dijadwalkan menjadi landasan rancangan sistem *sortasi* otomatis yang lebih akurat. Dampak panjangnya diuraikan sebagai otomatisasi yang ditingkatkan dalam rantai pasok cabai Indonesia, yang pada gilirannya akan meningkatkan keseragaman kualitas, mengurangi ketergantungan pada tenaga kerja manusia, serta nilai tambah dan efisiensi sebagai hasil akhir.

2 Tinjauan Literatur

Studi Tandoballa dan Hartati [7] menunjukkan bahwa YOLOv11 cukup tangguh menghadapi variasi pencahayaan dan oklusi di lingkungan pertanian, dengan *precision* dan *recall* di atas 90% pada klasifikasi kematangan melon emas. Temuan ini relevan untuk cabai, namun keterbatasan jumlah kelas kematangan dan bentuk objek yang relatif bulat menandakan bahwa kemampuan YOLOv11 dalam menangani *morfologi* cabai yang lebih ekstrem serta klasifikasi kematangan yang lebih rinci masih perlu dikaji lebih lanjut.

Selanjutnya, Liu [8] memperkenalkan YOLOv11-HRS yang dikembangkan untuk deteksi stroberi dengan menambahkan mekanisme *attention* serta kepala deteksi khusus guna meningkatkan kinerja pada objek berukuran kecil di lingkungan dengan latar belakang kompleks. Pendekatan ini menghasilkan capaian mAP@0.5 sebesar 89,8% dan menjadi relevan bagi konteks cabai, yang kerap berukuran kecil dan tertutup daun sehingga menghadapi tantangan visual serupa. Namun demikian, penerapan model tersebut masih dibatasi pada tiga kelas kematangan dan diuji pada buah dengan karakteristik tekstur yang berbeda. Hal ini mengindikasikan bahwa meskipun solusi untuk permasalahan skala dan latar belakang telah tersedia, efektivitasnya pada buah berbentuk memanjang dengan transisi kematangan yang lebih kontinu, dari hijau hingga merah, masih memerlukan pembuktian lebih lanjut.

Zhang [9] menyoroti pentingnya ketahanan model melalui YOLOv11-BSD yang mampu mempertahankan *precision* tinggi pada kondisi visual ekstrem, seperti simulasi malam hari pada blueberry. Temuan ini relevan untuk konteks cabai yang juga berpotensi menghadapi gangguan visual di rumah kaca atau pascapanen, namun penelitian tersebut masih terbatas pada objek berbentuk bulat dengan klasifikasi kematangan sederhana, sehingga membuka peluang pengembangan model yang sama tangguh tetapi mampu menangani kompleksitas bentuk dan tahapan kematangan cabai.

Studi Alzharani dan Iqbal [10] menunjukkan bahwa YOLOv11 mampu menangani variasi visual tinggi dan klasifikasi kompleks, dibuktikan dengan *accuracy* 92% pada 15 varietas kurma. Temuan ini menegaskan potensi YOLOv11 untuk membedakan detail halus, yang relevan bagi klasifikasi varietas dan kematangan cabai, meskipun perbedaan *morfologi* yang signifikan antara kurma dan cabai mengindikasikan perlunya penyesuaian arsitektur agar fitur bentuk cabai dapat ditangkap secara optimal.


Penelitian Liu [11] menunjukkan bahwa model SSViT mampu menyeimbangkan *accuracy* dan efisiensi dengan menggabungkan *Transformer* dan *attention konvolusional* dalam kerangka YOLO ringan, menghasilkan kinerja yang cukup tinggi sekaligus cepat. Pendekatan *semi-hibrid* ini relevan untuk deteksi kematangan cabai karena mampu menangani klasifikasi yang rinci serta objek kecil dan terhalang, sekaligus menegaskan bahwa arah pengembangan ke depan perlu memadukan fitur lokal *konvolusional* dengan pemodelan konteks global.

3 Metode Penelitian

Bagian ini akan menjelaskan metode - metode yang dipakai di dalam penelitian untuk menggapai sasaran yang telah ditentukan. Penjelasan pada bagian ini meliputi beberapa hal pokok yaitu tahap penelitian, tahap pengujian, dan *flowchart*. Dengan gamblang setiap hal pokok dikupas secara rinci supaya proses penelitian yang dilakukan dapat dipahami secara menyeluruh.

3.1 Tahapan Penelitian

Tahapan-tahapan pada penelitian pengembangan sistem deteksi dan klasifikasi kematangan cabai ini meliputi berbagai proses disajikan dalam bentuk diagram alur yang ditampilkan pada (Gambar 1).



Gambar 1. Diagram alur penelitian

a. Pengumpulan Data

Sementara dalam penelitian ini, pengumpulan data dilakukan dengan cara merujuk kepada gambar langsung dari buah cabai dalam 3 kondisi kematangan. Baik yang masih mentah, setengah

matang, dan sudah matang. Gambar ini diambil secara manual meliputi keseluruhan variasi dari berbagai sudut, baik pencahayaan dan kondisi *visual*. Jumlah total gambar dari dataset awal mencapai 150 gambar. Dan kemudian, di tambah menjadi 300 gambar melalui teknik *augmenasi* untuk menambah variasi data secara keseluruhan.

b. Pengolahan Data

Pengolahan data dilakukan melalui platform *Roboflow* dengan penerapan *preprocessing* atau persiapan data mentah sebelum dilakukan analisis lebih lanjut, berupa *auto orient* dan *resize*. *Auto orient* yang bertujuan menyeragamkan orientasi gambar [12], sementara *resize* dilakukan untuk menyesuaikan ukuran gambar menjadi 640×640 *piksel* agar sesuai dengan arsitektur input model YOLOv11 [13].

c. Labelling

Labelling merupakan proses pemberian tanda, label, tag, atau anotasi pada data mentah pada platform *Roboflow* dengan membagi setiap gambar ke dalam tiga kelas kematangan cabai: mentah, setengah matang, dan matang. Proses ini bertujuan untuk menyiapkan data terstruktur yang dapat dikenali oleh model selama pelatihan [14].

d. Data Split

Setelah labelling, dataset dibagi menjadi tiga bagian: 75% untuk data latih, 12% untuk data validasi, dan 13% untuk data uji. Pembagian ini bertujuan untuk memudahkan proses pelatihan, evaluasi, dan pengujian model sekaligus mengurangi risiko *overfitting* atau kondisi dalam *machine learning* di mana model belajar terlalu spesifik pada data latih [15].


e. Hasil dan Pengujian Sistem

Diharuskan system dapat mendeteksi kematangan cabai dengan menampilkan data prediksi pada tiga kelas yaitu mentah, setengah matang dan matang. Pengujian sistem ini akan dilakukan secara manual langsung melalui proses *upload image*. Selain itu metode *Confusion Matrix* juga akan berperan aktif untuk mengukur sejauh mana kemampuan sistem dalam mengklasifikasikan data secara terstruktur.


4 Hasil dan Pembahasan

4.1 Hasil Dataset


Data untuk pengembangan sistem deteksi kematangan cabai ini berasal langsung dari penulis. Data dikumpulkan terkait dengan ketiga kelas utama dari cabai, yaitu mentah, setengah matang, dan matang. Telah dijelaskan sebelumnya bahwa lebih banyak informasi lengkap berkenaan dengan data ini muncul dalam (Gambar 2-4).



Gambar 2. Dataset cabai rawit kelas mentah



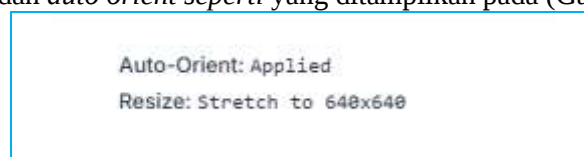
Gambar 3. Dataset cabai rawit kelas setengah matang



Gambar 4. Dataset cabai rawit kelas matang

4.2 Pengolahan Data


Tahap pembagian data awal dilakukan agar dapat memperoleh hasil *accuracy* yang maksimal. Proses ini akan mudah dilakukan jika proses ekstraksi ciri lolos. Di penelitian ini, dilakukan *preprocessing* oleh *rezise* dan *auto orient* seperti yang ditampilkan pada (Gambar 5).



Gambar 5. Preprocessing yang diterapkan pada roboflow

4.3 Labelling


Labelling merupakan langkah membagi foto ke setiap kelas di situs web *Roboflow*. Kedua, ketika sistem ini diterapkan dalam mendeteksi kematangan cabai, melalui tiga kelas dipilih untuk digunakan: mentah, setengah matang, dan matang. Seperti yang terlihat pada (Gambar 6-8) ini menunjukkan foto cabai di tiga kondisi.




Gambar 6. Label mentah Gambar 7. Label setengah matang Gambar 8. Label matang

4.4 Data Split

Pada website *Roboflow*, dilangkah data tersebut dibagi setelah dataset diberi *label* dan ukurannya diubah. Nama peminjam dapat digunakan karena fungsi membreak data dan memberikan nama harus tetap terpisah. Data dibagi menjadi tiga kategori, yaitu 75% data *train*, 12% data validasi, dan 13% data uji yang bertujuan biar proses pelatihan mudah dan pemasukan data harus sesuai. Hal ini berfungsi memperkecil tindakan *overfitting* dan *underfitting* pada dataset. Pada Gambar 9 dan Gambar 10 di bawah menunjukkan hasil dari pembagian data yang dilakukan di website tersebut.



Gambar 9. Data valid pada *dataset split*



Gambar 10. Presentase pada dataset split

4.5 Hasil dan Pengujian Sistem

Sistem dijalankan pada *Google Colab* setelah melakukan proses pelatihan atau *training dataset* dari roboflow dengan perintah (*python deteksi_kematangan_cabai.py*). Maka *upload* gambar akan terproses dan mendeteksi objek secara *real-time* seperti pada gambar berikut.


Pada pengujian dibawah ini menunjukkan bahwa sistem yang dikembangkan berhasil mendeteksi cabai berkualitas baik kedalam kelas *mentah* dengan nilai *accuracy* sebesar 94%.



Gambar 11. Hasil cabai terdeteksi kuning



Gambar 12. Hasil cabai terdeteksi merah



Gambar 13. Hasil cabai terdeteksi orange

Pada pengujian dengan *upload image*, sistem mampu mendeteksi cabai ke dalam tiga tingkat kematangan dengan akurasi yang ditunjukkan masing-masing sebesar 94% (Gambar 11), 93% (Gambar 13), dan 95% (Gambar 12).

4.6 Evaluasi

Dalam tahap ini, setelah tahap pemodelan dan pelatihan sistem adalah tahap terakhir yang perlu dilakukan jika ingin hasil penggunaannya maka dalam pengukuran kinerja modelnya dalam penelitian ini dihasilkannya dengan menggunakan *confusion matrix*, *accuracy*, *precision*, *recall* dan *F1-score* [16]. Dari tinjauan literatur, hasil penelitian ini menggunakan *transfer learning* menunjukkan bahwa pelatihan dengan *transfer learning* menghasilkan kinerja model yang lebih baik. Penelitian lain mencatat bahwa penerapan *transfer learning* dapat meningkatkan *accuracy* kategorisasi; hasil perbandingan ini menunjukkan kelebihan dari pola-pola [17].

Tabel 1. Confusion matrix

Aktual	Prediksi	
	+	-
+	True Positive (TP)	False Negative (FN)
-	False Positive (FP)	True Negative (TN)

Berikut rumus untuk *accuracy*, *precision*, *recall* dan *f1-score* ;


$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

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

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

$$F1-score = \frac{2TP}{2TP + FP + FN} \quad (4)$$

Seperti yang ada pada Tabel 1, di atas beserta formulasi metrik evaluasi meliputi *accuracy* (1), *precision* (2), *recall* (3), dan *F1-score* (4) menjadi landasan kuantitatif utama dalam proses analisis kinerja model pada penelitian ini. Melalui kerangka tersebut, Nilai-nilai ini diperoleh dari pemetaan setiap hasil prediksi ke dalam komponen *confusion matrix* (TP, TN, FP, FN), yang kemudian membuka ruang untuk interpretasi yang lebih mendalam [18]. Dengan demikian, skema evaluasi ini tidak hanya berfungsi sebagai alat hitung numerik, tetapi juga menghubungkan hasil visual seperti *confusion matrix* dan metrik evaluasi dengan simpulan bahwa model menunjukkan performa keseluruhan yang sangat kuat, meskipun masih menyisakan tantangan pada klasifikasi gradasi kematangan yang halus [19].




Gambar 14. Confusion matriks jumlah dan persentase


Berdasarkan *Confusion Matrix* pada Gambar 14, model klasifikasi tingkat kematangan menunjukkan kinerja yang sangat baik pada seluruh kelas, ditandai dengan dominasi nilai pada diagonal utama matriks. Kelas mentah berhasil dikenali secara sempurna tanpa kesalahan prediksi, sementara kelas setengah matang dan matang masing-masing mencapai tingkat ketepatan 90,9% dan 91,7%, meskipun masih terdapat satu kesalahan klasifikasi pada masing-masing kelas. Kesalahan

<http://sistemasi.ftik.unisi.ac.id>


yang relatif kecil ini mengindikasikan adanya kemiripan karakteristik visual antar tingkat kematangan pada kondisi tertentu, namun secara keseluruhan hasil tersebut menegaskan kemampuan model dalam membedakan tingkat kematangan buah secara akurat dan konsisten.



Gambar 15. Confidence score



Gambar 16. Metrik evaluasi



Gambar 17. Calibration plot

Hasil evaluasi terhadap model klasifikasi tingkat kematangan buah memperlihatkan bahwa tingkat kinerja dan reliabilitasnya tidak seragam pada setiap kelas. Dalam praktiknya, hal ini tampak jelas pada visualisasi *confidence score* yang ditunjukkan pada Gambar 15, model menunjukkan keyakinan yang paling stabil saat mengenali buah mentah, dengan skor kepercayaan yang terkonsentrasi pada rentang tinggi, khususnya antara 0,8 hingga 0,9. Pola tersebut konsisten dengan hasil yang ditampilkan pada Gambar 16, terkait metrik evaluasi klasifikasi (TP, TN, FP, FN). Kelas mentah kembali menunjukkan performa paling optimal, ditandai oleh jumlah *true positive* yang dominan dan tingkat kesalahan yang relatif rendah. Berbeda halnya dengan dua kelas lainnya, di mana peningkatan nilai *false positive* dan *false negative* cukup menonjol. Analisis lebih lanjut melalui *calibration plot* pada Gambar 17, memberikan perspektif tambahan mengenai reliabilitas prediksi. Secara umum, skor kepercayaan yang dihasilkan model selaras dengan tingkat akurasi aktual, terlihat dari kecenderungan prediksi benar yang terkonsentrasi pada *confidence* tinggi.

Tabel 2. Metrik per kelas

Kelas	Precision	Recall	F1-score	Support
Mentah	0.9091	1.0000	0.9524	10.0000
Setengah matang	1.0000	0.9091	0.9524	11.0000
Matang	0.9167	0.9167	0.9167	12.0000
Accuracy	0.9394	0.9394	0.9394	0.9394
Macro avg	0.9419	0.9419	0.9405	33.0000
Weighted avg	0.9421	0.9394	0.9394	33.0000
Accuracy Total			0.9394	

Berdasarkan Tabel 2, model kinerja per kelas yang relatif seimbang. Kelas mentah unggul pada kemampuan deteksi penuh (*recall* 100%), kelas setengah matang menunjukkan ketepatan prediksi sempurna (*precision* 100%), sementara kelas matang memiliki keseimbangan terbaik antara *precision* dan *recall*. Nilai *F1-score* tertinggi diperoleh pada kelas mentah dan setengah matang, dengan capaian sedikit lebih rendah pada kelas matang.


Tabel 3. Hasil confusion matriks

Metrik	Nilai
Accuracy	0.9394 (93.94%)
Precision	0.9421
Recall	0.9394
F1-Score	0.9394

Sebagaimana ditunjukkan dalam Tabel 3, *Confusion Matriks* Hasil, model klasifikasi tingkat kematangan cabai memiliki performa keseluruhan yang sangat *solid*, dengan *Accuracy* 93,94%, yang berarti model ini berhasil mendeteksi dengan betul 93,94% dari sejumlah total sampel yang sudah

diuji itu. Nilai *Precision* sebesar 0,9421 (94,21%) ini bermakna bahwa dari semua prediksi positif yang dibuat oleh model, persentase 94,21% adalah prediksi yang benar.

Adapun hasil mPA, *Precision*, dan *Recall* pada saat training dataset di Roboflow sebagai berikut.



Gambar 18. Presentase mPA, precision, dan recall

Hasil evaluasi pada (Gambar 18, di atas menunjukkan bahwa model memiliki kinerja deteksi yang sangat tinggi dan mendekati kondisi ideal. Nilai mAP@50 sebesar 99,5% menandakan kemampuan model yang sangat akurat dalam pengenalan objek dengan kesalahan tumpang-tindih yang minimal. Hal ini diperkuat oleh nilai *precision* sebesar 99,3%, yang menunjukkan bahwa hampir seluruh prediksi yang dihasilkan benar, dengan tingkat *false positive* yang sangat kecil. Selain itu, capaian *recall* 100,0% mengindikasikan bahwa seluruh objek target dalam data uji berhasil terdeteksi tanpa adanya kasus *false negative*, sehingga model mampu menangkap keseluruhan objek secara menyeluruh.

4.7 Analisis Kritis

Hasil evaluasi memperlihatkan bahwa walaupun kinerja keseluruhan model tergolong tinggi dengan *accuracy* mencapai 93,94%, masih terdapat kelemahan yang terkonsentrasi pada pembedaan kelas setengah matang dan matang. Seluruh kesalahan klasifikasi muncul pada peralihan antara kedua kelas tersebut, sementara cabai mentah dapat dikenali secara sempurna dengan nilai *recall* 100%. Kondisi ini dipengaruhi oleh karakter visual cabai yang mengalami perubahan warna secara bertahap dari oranye ke merah tua, serta sangat sensitif terhadap variasi pencahayaan. Kombinasi faktor tersebut membentuk wilayah ambang yang sulit ditangani secara konsisten oleh model.

Temuan ini sejalan dengan laporan dalam literatur yang menyebutkan bahwa objek dengan *spektrum* warna kontinu cenderung menimbulkan tantangan klasifikasi, terutama ketika data dikumpulkan pada kondisi yang tidak sepenuhnya terkontrol [6]. Indikasi ketidakpastian model pada kelas setengah matang dan matang juga terlihat dari sebaran *confidence score* yang lebih rendah dan tidak terpusat. Hal ini menegaskan bahwa capaian *accuracy* yang tinggi belum tentu mencerminkan keandalan pada setiap kelas, khususnya pada kategori dengan perbedaan visual yang halus. Dengan demikian, meskipun YOLOv11 menunjukkan efektivitas yang baik secara umum, penelitian ini menyoroti keterbatasan model *konvensional* dalam menangani gradasi warna yang bersifat gradual.

4.8 Kontribusi Ilmiah dan Praktis

Penelitian ini menghadirkan kebaruan metodologis dengan menguji YOLOv11 pada cabai buah non-bulat yang kecil, memanjang, dan memiliki gradasi warna kontinu mengisi gap literatur yang sebelumnya banyak fokus pada buah bulat seperti melon [7], stroberi [8], dan blueberry [9]. Analisis diagnostik mendalam melalui distribusi *confidence score* dan *calibration plot* mengungkap kelemahan model pada kelas transisi (setengah matang dan matang) yang tidak terlihat dari metrik, memberikan wawasan penting untuk pengembangan model deteksi objek dengan variasi warna halus. Selain itu, penelitian menunjukkan bahwa dengan strategi *preprocessing* dan *augmentasi* yang tepat di *platform* seperti Roboflow, model dapat mencapai kinerja tinggi (>93%) bahkan dengan dataset terbatas (150 gambar), memperkuat temuan sebelumnya [5].

Studi ini berhasil menghasilkan prototipe sistem terintegrasi berbasis web (Google Colab) yang mencakup pelabelan data, pelatihan model, dan pengujian, sehingga mudah direplikasi dan terjangkau bagi usaha tani skala kecil-menengah. *accuracy* dan konsistensi model, khususnya pada kelas mentah dan matang, menyediakan dasar teknis kuat untuk pengembangan sistem sortir

<http://sistemasi.ftik.unisi.ac.id>

otomatis berbasis *konveyor* dan visi komputer sesuai visi Pertanian 4.0. Temuan terkait kebingungan antara kelas setengah matang dan matang juga memberikan panduan spesifik untuk perbaikan di masa depan, melalui pengayaan data pada fase transisi dan *fine-tuning model*.

5 Kesimpulan

Berdasarkan hasil penelitian, dapat disimpulkan bahwa model YOLOv11 mampu mendeteksi tingkat kematangan cabai dengan kinerja yang sangat baik, ditandai oleh *accuracy* total 93,94%, *precision* 94,21%, *recall* 93,94%. Model memiliki kemampuan identifikasi optimal pada kelas cabai mentah (*recall* 100%) dan ketepatan prediksi yang sangat baik pada kelas setengah matang (*precision* 100%), meskipun masih terdapat tantangan pada pemisahan kelas setengah matang dan matang. Temuan ini menegaskan potensi YOLOv11 sebagai inti sistem sortir otomatis berbasis visi komputer yang dapat menangani variasi warna dan bentuk cabai, serta berpeluang diintegrasikan ke dalam sistem *konveyor* untuk meningkatkan efisiensi dan konsistensi kualitas rantai pasok. Penelitian ini memiliki beberapa keterbatasan penting. Pertama, meskipun dataset telah diperluas, ukuran dan variasinya masih terbatas, sehingga belum mencakup berbagai varietas cabai dan kondisi pencahayaan ekstrem. Kedua, seluruh kesalahan klasifikasi terjadi pada perbedaan antara kelas setengah matang dan matang, menunjukkan kerentanan model terhadap gradasi warna halus. Untuk penelitian selanjutnya, disarankan: (1) memperluas dataset dengan lebih banyak sampel pada fase transisi warna; (2) mengeksplorasi mekanisme *attention* atau arsitektur *neck* yang lebih kompleks untuk meningkatkan kemampuan membedakan kelas serupa; dan (3) menguji serta mengembangkan prototipe sistem real-time yang terintegrasi dengan perangkat keras sortir fisik.

Referensi

- [1] M. Anwar, M. A. Np, and M. Rohman, "Segmentasi Citra Daun dan Cabai menggunakan YOLOv7," Vol. 3, pp. 1–6, 2024.
- [2] Z. He, K. Wang, T. Fang, L. Su, R. Chen, and X. Fei, "Comprehensive Performance Evaluation of YOLOv11, YOLOv10, YOLOv9, YOLOv8 and YOLOv5 on Object Detection of Power Equipment," *Proc. 37th Chinese Control Decis. Conf. CCDC 2025*, pp. 1281–1286, 2025, DOI: 10.1109/CCDC65474.2025.11090973.
- [3] R. Khanam and M. Hussain, "YOLOv11: An Overview of the Key Architectural Enhancements," Vol. 2024, pp. 1–9, 2024, [Online]. Available: <http://arxiv.org/abs/2410.17725>
- [4] Y. Ma, Z. Peng, and Y. Ruan, "Deep Learning based Pepper Maturity Detection," *Proc. 2024 8th Int. Conf. Electron. Inf. Technol. Comput. Eng. EITCE 2024*, No. January, pp. 300–304, 2025, DOI: 10.1145/3711129.3711182.
- [5] J. Song, D. Kim, E. Jeong, and J. Park, "Determination of Optimal Dataset Characteristics for Improving YOLO Performance in Agricultural Object Detection," *Agric.*, Vol. 15, No. 7, 2025, DOI: 10.3390/agriculture15070731.
- [6] I. Esaki, S. Noma, T. Ban, R. Sultana, and I. Shimizu, "Maturity Classification of Blueberry Fruit using YOLO and Vision Transformer for Agricultural Assistance †," *Horticulturae*, Vol. 11, No. 10, pp. 1–14, 2025, DOI: 10.3390/horticulturae11101272.
- [7] L. Tandoballa and E. Hartati, "Implementation of the You Look Only Once (YOLOv11) Algorithm to Detect the Ripeness of Golden Melons," Vol. 5, No. 2, pp. 191–204, 2025.
- [8] J. Liu, J. Guo, and S. Zhang, "YOLOv11-HRS: An Improved Model for Strawberry Ripeness Detection," *Agronomy*, Vol. 15, No. 5, 2025, DOI: 10.3390/agronomy15051026.
- [9] R. Zhang, "YOLOv11-BSD: Blueberry Maturity Detection under Simulated Nighttime Conditions Evaluated with Causal Analysis," *Smart Agric. Technol.*, Vol. 12, No. July, 2025, DOI: 10.1016/j.atech.2025.101314.
- [10] A. S. Alzaharani and A. Iqbal, "A Multi-Stage Pipeline for Date Fruit Processing: Integrating YOLOv11 Detection, Classification, and Automated Counting," *Comput. Mater. Contin.*, Vol. 86, No. 1, pp. 1–27, 2026, DOI: 10.32604/cmc.2025.070410.
- [11] Y. Liu, Q. Yu, S. Geng, S. Guo, and L. Liu, "SSViT-YOLOv11: Fusing Lightweight YOLO & ViT for Coffee Fruit Maturity Detection," *Front. Plant SCI.*, Vol. 16, No. December, pp. 1–19, 2025, DOI: 10.3389/fpls.2025.1691643.

- [12] B. Sunarko, "Penerapan *Stacking Ensemble Learning* untuk Klasifikasi Efek Kesehatan Akibat Pencemaran Udara," *Edu Komputika J.*, Vol. 10, No. 1, pp. 55–63, 2023, DOI: 10.15294/edukomputika.v10i1.72080.
- [13] S. Cepeda, "Real-Time Brain Tumor Detection in Intraoperative Ultrasound: From Model Training to Deployment in the Operating Room," *Comput. Biol. Med.*, Vol. 193, pp. 1–27, 2025, DOI: 10.1016/j.compbiomed.2025.110481.
- [14] F. Schneider, J. Swiatek, and M. Jelali, "Detection of Growth Stages of Chilli Plants in a Hydroponic Grower using Machine Vision and YOLOv8 Deep Learning Algorithms," *Sustain.*, Vol. 16, No. 15, 2024, DOI: 10.3390/su16156420.
- [15] L. Nury, I. Afida, F. A. Bachtiar, and I. Cholissodin, "Klasifikasi Aktivitas Manusia menggunakan Metode *Long Short-Term Memory classification of Human Activity using Long Short-Term Memory*," *J. Teknol. Inf. dan Ilmu Komput.*, Vol. 11, No. 11, pp. 357–368, 2024, DOI: 10.25126/jtiik.2024117060.
- [16] D. R. B. Lubis and A. Armansyah, "Klasifikasi Mahasiswa Berpotensi Dropout menggunakan Metode Regresi Logistik," *Techno.Com*, Vol. 24, No. 3, pp. 768–778, DOI: 10.62411/tc.v24i3.13526.
- [17] K. A. Sahib, B. K. Oleiwi, and A. R. Nasser, "Medicinal Plants Recognition using Deep Transfer Learning Models," *Int. J. Des. Nat. Ecodynamics*, Vol. 19, No. 5, pp. 1501–1510, DOI: 10.18280/ij dne.190504.
- [18] T. Selvakumar, M. N. A. H. Sha'abani, M. S. . Aras, and M. B. Bahar, "Development of a YOLOv11-based Deep Learning System for Insect Pest Detection and Classification in Oil Palm Plantation," *Mod. Appl. SCI.*, Vol. 19, No. 2, p. 32, 2025, DOI: 10.5539/mas.v19n2p32.
- [19] Wulandari, Sasmita, M. R. Mulia, A. B. Kaswar, D. D. Andayani, and A. S. Agung, "Klasifikasi Kandungan Nutrisi Buah Pisang berdasarkan Fitur Tekstur dan Warna LAB menggunakan Jaringan Syaraf Tiruan berbasis Pengolahan Citra Digital," *J. Teknol. Inf. dan Ilmu Komput.*, Vol. 11, No. 3, pp. 507–518, 2024, DOI: 10.25126/jtiik.938332.