

PAPAYA TYPE CLASSIFICATION USING YOLOv8

Egi Verdiansyah*¹, Firman Nurdiyansyah², Istiadi*³

^{1,2,3}Department of Informatics, Faculty of Engineering, Widya Gama Malang University, Indonesia

²Master of Management, Human Resource Management, Islamic University of Malang, Indonesia

³Electrical Engineering, Faculty of Engineering, Gadjah Mada University, Indonesia

Email: ¹egiverdiansyah@gmail.com, ²firmannurdiyansyah7@gmail.com, ³istiadi@widyagama.ac.id

(Article received: June 20, 2024; Revision: July 20, 2024; published: October 20, 2024)

Abstract

Papaya (Carica papaya L) is a fruit that is easily found in subtropical and tropical regions, including Indonesia. With many varieties of papaya, the manual method used in distinguishing papaya types by humans depends on individual knowledge which can cause inaccuracies in the classification process. The manual classification process also takes a very long time if production is done on a large scale. Therefore, a technology for sorting automation is needed, especially in the industrial world. This research aims to classify papaya classes based on their type. The classification is divided into four classes, namely bangkok papaya, california papaya, hawaii papaya, and red lady papaya. The classification process in this study uses the YOLOv8 model, where the total dataset is 1200 papaya images with a training data division of 88% (1050 images), 8% validation data (100 images), and 4% test data (50 images). The dataset is separated according to papaya fruit class. Data training was conducted with 300 epochs. The results show that bangkok papaya has a mAP value of 96%, california papaya 97%, hawaii papaya 95%, and red lady papaya has 95% mAP. The average class has a precision value of 99.6%, and recall 100.0%. It can be concluded that the YOLOv8 classification model is able to achieve a high level of accuracy.

Keywords: *classification, papaya, You Only Look Once.*

KLASIFIKASI JENIS BUAH PEPAYA MENGGUNAKAN YOLOv8

Abstrak

Buah pepaya (*Carica papaya L*) merupakan buah yang mudah ditemukan di daerah subtropis maupun tropis, termasuk Indonesia. Dengan banyaknya varietas pepaya, cara manual yang digunakan dalam membedakan jenis pepaya oleh manusia bergantung pada pengetahuan individu yang dapat menyebabkan ketidakakuratan dalam proses klasifikasi. Proses klasifikasi manual juga memakan waktu yang sangat lama jika produksi dilakukan dalam skala yang besar. Maka dari itu, dibutuhkan sebuah teknologi untuk otomatisasi sortasi, terutama di dunia industri. Penelitian ini bertujuan untuk mengklasifikasi kelas pepaya berdasarkan jenisnya. Klasifikasi terbagi dalam empat kelas, yaitu kelas pepaya bangkok, pepaya *california*, pepaya hawaii, dan pepaya *red lady*. Proses klasifikasi dalam penelitian ini menggunakan model YOLOv8, dimana total dataset sebesar 1200 citra pepaya dengan pembagian data latih sebesar 88% (1050 citra), data validasi 8% (100 citra), dan data uji 4% (50 citra). Dataset dipisah sesuai kelas buah pepaya. Pelatihan data dilakukan dengan 300 *epochs*. Hasil penelitian menunjukkan bahwa pepaya bangkok memiliki nilai *mAP* sebesar 96%, pepaya *california* 97%, pepaya hawaii 95%, dan pepaya *red lady* memiliki *mAP* 95%. Rata-rata kelas memiliki nilai *precision* sebesar 99,6%, dan *recall* 100,0%. Dapat disimpulkan bahwa model klasifikasi YOLOv8 mampu mencapai tingkat akurasi yang tinggi.

Kata kunci: *klasifikasi, pepaya, You Only Look Once.*

1. PENDAHULUAN

Buah pepaya (*Carica papaya L*) merupakan buah yang mudah ditemukan di daerah subtropis maupun tropis, termasuk Indonesia [1]. Tanaman ini dapat tumbuh dengan baik pada ketinggian 0 hingga 1000 meter di atas permukaan laut [2]. Tanaman ini

dapat tumbuh dengan subur di lingkungan tropis maupun subtropis, serta terkenal tahan terhadap berbagai jenis penyakit [3], [4]. Buah pepaya memiliki ciri, yaitu berat antara 0,7kg – 2,5kg, berbentuk lonjong, berkulit tebal, halus dan mengkilat, pepaya matang berwarna kuning, dan daging buah berwarna oranye dan bertekstur kenyal

[1]. Selain rasanya yang nikmat, pepaya mengandung banyak nutrisi seperti kalsium, asam askorbat, dan vitamin A yang tinggi sehingga bermanfaat bagi kesehatan mata [5], [6]. Selain itu, pepaya juga bermanfaat untuk kecantikan sehingga banyak diminati oleh masyarakat [7]. Buah pepaya merupakan salah satu buah unggulan Indonesia untuk ekspor dan konsumsi dalam negeri. Menurut Ezar Dkk [8], buah yang tersedia secara komersial ini merupakan buah yang penting.

Indonesia adalah penghasil buah pepaya terbesar di ASEAN (*Association of Southeast Asian Nations*) [9]. Bahkan penghasil buah pepaya terbesar kelima di dunia setelah Brazil, Nigeria, India, dan Mexico dimana hal tersebut dinyatakan oleh badan Perserikatan Bangsa-Bangsa yaitu *Food & Agriculture Organization* (FAO). Dengan nilai ekspor yang tinggi maka dibutuhkan sebuah teknologi untuk menentukan jenis buah pepaya yang akurat. Saat ini proses penentuan jenis pepaya masih dilakukan secara konvensional yang memakan waktu dan tenaga yang cukup besar. Proses penentuan jenis buah pepaya dengan cara tersebut memiliki beberapa kekurangan. Pertama, membutuhkan tenaga yang lebih untuk memilah buah pepaya. Kedua, tingkat persepsi manusia berbeda-beda sehingga menghasilkan keputusan yang berbeda pula. Ketiga, manusia dapat mengalami kelelahan sehingga tidak dapat menjamin konsistensi dalam proses penentuan jenis buah pepaya [8].

Pemilihan jenis buah pepaya dapat berpengaruh pada selera konsumen, yaitu konsumen tidak mendapatkan jenis pepaya yang sesuai dengan kebutuhannya. Oleh karena itu dibutuhkan cara untuk mengidentifikasi jenis buah pepaya dengan menggunakan teknologi yang akurat. Selain itu teknologi ini dapat membantu sektor pertanian dalam memilah jenis buah pepaya.

Penelitian sebelumnya yang dilakukan oleh Ezar, Dkk [8], adalah melakukan identifikasi mutu buah pepaya menggunakan metode Jaringan Saraf Tiruan. Sebanyak 150 data citra pepaya *california* yang digunakan sebagai dataset dalam penelitian ini. Kumpulan data terdiri dari 3 kategori kualitas pepaya yaitu bagus, sedang, dan jelek. Pengujian dilakukan dengan metode jaringan syaraf tiruan *backpropagation*. Terdapat 17 *training function* yang digunakan pada setiap data latih dengan 3 neuron berbeda untuk setiap *hidden layer*-nya. Hasil terbaik yang diperoleh dengan menggunakan *training function* pada neuron 10 menghasilkan *accuracy* sebesar 81,33%, *precision* sebesar 73,37%, dan *recall* sebesar 72%. Sedangkan pada neuron 20 menghasilkan *accuracy* sebesar 82,67%, *precision* sebesar 75,24%, dan *recall* sebesar 74%. Lalu pada neuron 25 menghasilkan *accuracy* sebesar 80,89%, *precision* sebesar 74,42%, dan *recall* sebesar 71,33% [8].

Dalam penelitian yang dilakukan Bimantoro, Dkk [10] melakukan klasifikasi jenis dan tingkat kematangan buah pepaya berdasarkan fitur warna, tekstur dan bentuk menggunakan *Support Vector Machine* (SVM). Dalam penelitian ini sebuah sistem telah dikembangkan dengan kemampuan mengklasifikasikan jenis dan tingkat kematangan berdasarkan fitur warna, tekstur, dan bentuk menggunakan metode *Support Vector Machine*. Proses ekstraksi fitur melibatkan metode pendekatan statistik dan GLCM (*Gray Level Co-occurrence Matrix*). Fitur warna diekstraksi dalam ruang warna HSI dan YCbCr, fitur tekstur dengan GLCM, serta fitur bentuk menggunakan *Horizontal Vertical Projection Integral*. Jumlah keseluruhan data yang digunakan mencapai 600 data citra buah pepaya yang dibagi menjadi data pelatihan dan data uji. Hasil akurasi tertinggi untuk dataset pepaya bangkok diperoleh pada fitur HSI dengan nilai 63%, sementara pada dataset *california*, akurasi tertinggi juga diperoleh pada fitur HSI dengan nilai 61% [10].

Pada penelitian lain juga telah dilakukan oleh Ezar, Dkk. Penelitian ini bertujuan untuk mengevaluasi kualitas buah pepaya berdasarkan atribut fisiknya dengan menerapkan metode *K-Nearest Neighbors* (K-NN). Pendekatan K-NN digunakan untuk mengklasifikasikan buah berdasarkan kemiripan data uji dengan dataset yang telah diberi label. Atribut fisik pepaya yang diobservasi melibatkan warna, ukuran, dan kecacatan, dengan fokus pada fitur warna dari model RGB, serta dimensi minor dan mayor. Eksperimen ini menggunakan matrik jarak Euclidean dan Manhattan dengan variasi nilai k, yaitu 3, 5, 7, dan 9. Dataset terdiri dari 150 citra buah pepaya yang dikategorikan sebagai baik, sedang, dan jelek, dengan pembagian 120 data untuk pelatihan dan 30 data untuk pengujian. Hasil optimal dicapai menggunakan jarak Euclidean dengan $k=7$, mencapai akurasi sebesar 86,67%, presisi sebesar 87,50%, dan recall sebesar 80,00%. Evaluasi nilai akurasi, presisi, dan recall menunjukkan kinerja yang memuaskan dalam penilaian kualitas buah pepaya [7].

Penelitian lain yang serupa juga telah dilakukan pendeteksian tingkat kematangan pada buah pepaya menggunakan algoritma *You Only Look Once* (YOLO). Penelitian ini mengadopsi metode tinjauan literatur untuk mengidentifikasi tingkat kematangan buah melalui observasi, pengumpulan, dan analisis data. Penggunaan algoritma YOLO dalam deteksi kematangan buah, menunjukkan tingkat akurasi yang tinggi. Studi ini juga menegaskan bahwa algoritma YOLO mampu digunakan secara *real-time* untuk mengenali tingkat kematangan buah. Selain itu, penelitian ini melakukan perbandingan hasilnya dengan metode lain seperti *K-Nearest Neighbor*, ekstraksi fitur warna, dan Analisis Diskriminan Linear, yang menunjukkan bahwa algoritma YOLO memberikan

hasil yang lebih baik. Implementasi algoritma YOLO dalam mendeteksi tingkat kematangan buah menunjukkan potensi pengembangan lebih lanjut dalam teknologi deteksi buah yang lebih efisien dan akurat [11].


Pada penelitian serupa yang dilakukan oleh Helsaputra, Dkk yaitu melakukan prediksi tingkat kematangan dan bobot buah pepaya menggunakan metode *Deep Learning*. Penelitian ini melibatkan penggunaan 60 data citra buah pepaya yang diambil dari pedagang buah menggunakan kamera *smartphone* untuk melakukan klasifikasi tingkat kematangan dan bobot buah pepaya. Dalam penelitian ini, peneliti menerapkan metode *Convolutional Neural Network (CNN)* untuk melakukan klasifikasi tersebut. Hasil dari penelitian menunjukkan bahwa sistem yang dikembangkan berhasil mengklasifikasi tingkat kematangan dan bobot buah pepaya. Klasifikasi tingkat kematangan buah pepaya mencapai tingkat akurasi training sebesar 94,08% dan 68% untuk pengujian. Sementara itu, prediksi bobot buah pepaya mencapai tingkat akurasi *training* sebesar 100% dan 80% untuk pengujian [12].

Dalam penelitian ini penulis menggunakan metode *You Only Look Once (YOLO)*. Algoritma YOLO merupakan sebuah metode yang digunakan untuk melakukan klasifikasi objek pada suatu citra secara *real-time* dengan kecepatan tinggi [13]. Meskipun lebih cepat, YOLO tetap mampu mencapai tingkat akurasi yang tinggi dalam klasifikasi objek [14]. YOLOv5, versi terbaru YOLO [15], mampu mencapai *mAP (mean Average Precision)* 50,7% pada dataset COCO (*Common Objects in Context*) yang merupakan benchmark standar untuk deteksi objek. *Ultralytics* baru saja merilis versi terbaru algoritma YOLO, yaitu YOLOv8 pada Januari 2023 [16]. YOLOv8 inilah yang akan digunakan dalam penelitian ini. Versi ini merupakan versi tercanggih dengan berbagai peningkatan dibandingkan versi sebelumnya [17].

2. METODE PENELITIAN

2.1. Tahapan Umum Penelitian

Tahapan umum pada setiap penelitian bergantung pada jenis penelitian yang dilakukan. Pada penelitian ini ada beberapa tahapan umum, diantaranya adalah persiapan, studi pustaka, perencanaan, pengumpulan data, implementasi, pengujian, dan hasil. Dapat dilihat pada Gambar 1 adalah tahapan umum penelitian klasifikasi jenis buah pepaya menggunakan YOLOv8:

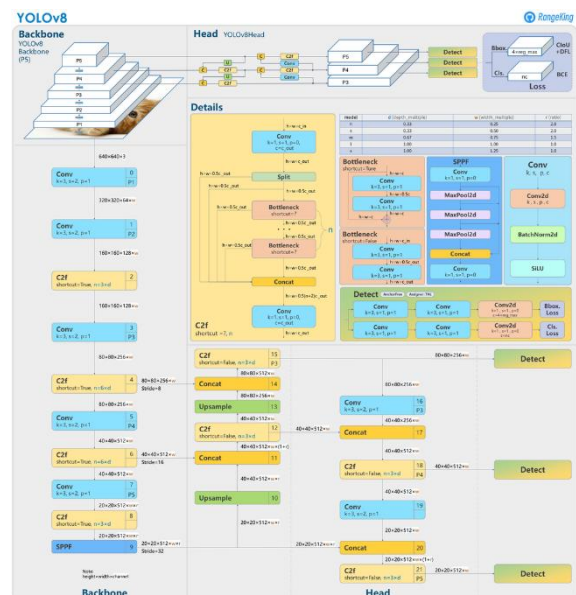


Gambar 1. Tahapan umum penelitian.

2.2. Arsitektur YOLOv8

Arsitektur YOLOv8 adalah evolusi dari YOLOv7, dan membawa banyak perbaikan dan keunggulan baru. Peningkatan kinerja dan ketepatan dalam mendeteksi objek YOLOv8 adalah salah satu keunggulan utamanya. Untuk mencapai hal ini, lapisan pemrosesan gambar tambahan dan penggunaan metode pembelajaran mesin yang lebih canggih digunakan. Berbeda dengan YOLOv7, YOLOv8 menggunakan teknik *anchor-free* yang lebih sederhana dan efisien, yang berarti implementasi dan deteksi objek yang lebih cepat. Selain itu, karena menambahkan lapisan pemrosesan gambar dan menerapkan teknik pembelajaran mesin yang lebih canggih, YOLOv8 juga memiliki kemampuan deteksi objek yang lebih baik dan akurat dibandingkan dengan YOLOv7. Secara keseluruhan, desain YOLOv8 adalah peningkatan dari YOLOv7 dan memiliki keunggulan dalam hal kinerja, ketepatan, dan kemampuan untuk mendeteksi objek [13].

Struktur YOLOv8 melibatkan jaringan tulang punggung (*backbone network*), leher (*neck*), dan kepala (*head*). *Backbone network* menggunakan *Feature Pyramid Network (FPN)* untuk mengekstraksi ciri-ciri dari gambar masukan, sementara *neck* menggunakan serangkaian *Cross-Layer Connection (CLC)* untuk memperbaiki fitur ini. Jaringan *head* menggunakan ciri-ciri yang telah diperbaiki untuk memprediksi kotak pembatas, skor kelas objek, dan tingkat ketepatan untuk setiap objek dalam gambar [13].



Gambar 2. Arsitektur YOLOv8 (visualisasi yang dibuat oleh pengguna GitHub RangeKing).

2.3. Proses Penelitian

a. Pengumpulan Data

Data yang diperlukan merupakan data dari hasil pengambilan gambar buah pepaya yang

diambil dari kamera *smartphone*. Sementara data foto yang telah dikumpulkan terdapat empat jenis buah pepaya yaitu pepaya *california*, pepaya bangkok, pepaya hawaii, dan pepaya *red lady*. Seluruh data pengujian sebanyak 1200 dengan pembagian 1050 data pelatihan, 100 data validasi, dan 50 data uji. 4 kelas yang digunakan untuk klasifikasi.

b. Implementasi

Selanjutnya setelah pengumpulan data yaitu melakukan implementasi, dimulai dari anotasi citra buah pepaya untuk dilakukan labeling dengan cara memberikan kelas pada setiap objek yang di-bounding menggunakan fitur *bounding box tool* yang tersedia pada aplikasi web *Roboflow*. Terdapat empat kelas yang telah ditentukan sesuai jenis pepaya, yaitu: pepaya bangkok, pepaya *california*, pepaya hawaii, dan pepaya *red lady*. Selanjutnya, pelatihan data dilakukan dengan mengolah data yang telah dianotasi sebelumnya. Ini membentuk model karakteristik yang akan dipertimbangkan selama pengujian.

c. Pengujian

Setelah tahap implementasi selesai, maka tahap selanjutnya yaitu melakukan pengujian. Pengujian dilakukan dengan cara menguji hasil terbaik dari data *training* yang telah dilatih sebelumnya. Pada tahap ini juga dilakukan evaluasi model dan menunjukkan kemampuan algoritma YOLOv8 untuk mendeteksi jenis pada gambar buah pepaya.

d. Hasil

Hasil merupakan akhir dari semua tahapan yang telah dilakukan dalam penelitian. Hasil adalah capaian akhir dari tujuan dilakukannya penelitian. Tahapan ini merupakan tahapan penting dalam penelitian untuk menyajikan temuan penelitian. Disini terdapat nilai perolehan yang dapat dievaluasi untuk dilakukan penelitian selanjutnya.

2.3. Alat dan Bahan

a. Peralatan

Peralatan yang digunakan dalam melakukan penelitian meliputi perangkat lunak dan perangkat

keras. Dapat dilihat detail perangkat keras yang digunakan pada Tabel 1. Untuk detail perangkat lunak yang digunakan dapat dilihat pada Tabel 2.

Tabel 1. Perangkat keras yang digunakan.

Sistem Operasi	Windows 8.1
Processor	Intel(R) Core(TM) i5-6200U CPU @ 2.30GHz
RAM	8.00 GB
SSD	239 GB
GPU	Intel(R) HD Graphics 520

Tabel 2. Perangkat lunak yang digunakan.


IDE	<i>Google Collaboratory</i>
Bahasa pemrograman	<i>Python</i>
Platform pengolahan citra	<i>Roboflow</i>

b. Bahan

Bahan yang digunakan dalam penelitian ini adalah hasil pengambilan gambar buah pepaya. Data citra buah pepaya merupakan dataset utama yang diterapkan pada penelitian ini. Data tersebut didapatkan dari perkebunan milik petani di Kabupaten Malang.

3. HASIL DAN PEMBAHASAN

Berdasarkan uji coba yang telah dilakukan, klasifikasi buah pepaya ditunjukkan pada Gambar 3 dapat dijelaskan bahwa pepaya *california* memiliki hasil nilai sebesar 97%. Kemudian pepaya bangkok memiliki hasil klasifikasi sebesar 96%. Buah pepaya hawaii memiliki nilai 95%, dan buah pepaya *red lady* memiliki nilai 95%. Hasil keakuratan pada klasifikasi jenis buah pepaya menggunakan YOLOv8 cukup baik. Dalam melakukan klasifikasi dibutuhkan waktu yang relatif cepat, kecepatan: 0.0ms *preprocess*, 0.7ms *inference*, 0.0ms *postprocess per image at shape*. Untuk menerapkan ke dalam aplikasi nyata, inferensi kecepatan merupakan faktor penting dalam melakukan klasifikasi objek.



Gambar 3. Hasil prediksi jenis buah pepaya menggunakan YOLOv8.

Proses pelatihan dan pengujian dari klasifikasi jenis buah pepaya menggunakan YOLOv8, menggunakan kumpulan data berukuran 128 x 128 piksel yang diunggah ke *Google Colab* dan jenis *runtime Python 3* dan GPU. Untuk pembagian data latih sebesar 88% (1050 *image*), data validasi 8% (100 *image*), dan data uji 4% (50 *image*). Dataset dipisah pada setiap kelas buah pepaya. Pelatihan data dilakukan dengan menggunakan 300 *epochs*. Pada Tabel 3 adalah hasil percobaan terbaik dari model YOLOv8 untuk mengklasifikasi buah pepaya menggunakan 300 *epochs*.


Tabel 3. Hasil *custom learning rate* menggunakan 300 *epochs*.

<i>Learning rate</i>	<i>Class</i>	<i>mAP</i>	<i>Confidence</i>	<i>All class</i>
<i>Epochs:</i> 300 <i>Batch size:</i> 128 <i>lr0:</i> 0.01 <i>lrf:</i> 0.01	Pepaya Bangkok	96%	0.967	99.5%
	Pepaya California	97%	0.969	
	Pepaya hawai	95%	0.955	
	Pepaya red lady	95%	0.971	

Dari Tabel 3 menunjukkan hasil penerapan nilai *custom learning rate* menggunakan 300 *epochs* didapatkan hasil *mAP* 96%, *confidence* 0,967 untuk pepaya bangkok. Pepaya *california* mendapat hasil *mAP* 97% dan *confidence* 0,969. Pepaya hawai memiliki *mAP* 95% dan *confidence* 0,955. Kemudian pepaya *red lady* memiliki *mAP* 95% dan *confidence* 0,971. Proses *training* berhenti pada *epochs* ke 272 karena tidak ditemukan data terbaik di 28 *epochs* terakhir, data terbaik mulai didapat pada *epochs* ke 144. Berikut matrik yang dihasilkan.

3.1. Train/box_loss

Train/box_loss memberikan informasi seberapa baik model dalam memprediksi kotak pembatas (*bounding box*) pada data pelatihan. Tujuan dari pelatihan ini adalah untuk mendapatkan nilai *box_loss* serendah mungkin, yang menandakan tingginya tingkat akurasi dalam memprediksi kotak pembatas. Grafik *Train/box_loss* dapat ditunjukkan pada Gambar 4.



Gambar 4. Grafik kegagalan (*loss*) pada proses pelatihan.


Pada Gambar 4 jelas terlihat bahwa pada *epoch* 0-300 grafik kegagalan (*loss*) dari *epochs* 0 hingga 20 turun secara drastis dan turun secara signifikan hingga iterasi terakhir.

Kurva: Sumbu X (*horizontal*): *Epochs*.

Sumbu Y (*vertical*): *train/box_loss*.

3.2. Validation/box_loss

Validation/box_loss memberikan informasi seberapa baik model dalam memprediksi kotak pembatas (*bounding box*) pada data validasi. Tujuan dari validasi adalah untuk mendapatkan nilai *box_loss* serendah mungkin pada data yang tidak digunakan dalam pelatihan, untuk menunjukkan kemampuan generalisasi model yang baik. Grafik *validation/box_loss* dapat ditunjukkan pada Gambar 5.



Gambar 5. Grafik kegagalan (*loss*) pada data validasi.

Pada Gambar 5 menunjukkan grafik kerugian/kegagalan (*loss*) yang dihitung berdasarkan data validasi. Bahwa terjadi fluktuasi yang besar pada awal iterasi, menandakan model sedang menyesuaikan dan mengalami variabilitas yang tinggi dalam akurasi prediksi. Kemudian mengalami penurunan yang stabil, menandakan model


mengalami perbaikan prediksi yang stabil dan generalisasi model dengan baik.

Kurva: Sumbu X (*horizontal*): *Epochs*.

Sumbu Y (*vertical*): *val/box_loss*.

3.3. *Train/cls_loss*

Train/cls_loss memberikan informasi seberapa baik model dalam mengklasifikasi objek pada data pelatihan. Tujuan dari pelatihan adalah untuk mendapatkan nilai *classification loss* serendah mungkin, untuk menunjukkan bahwa model mengklasifikasi objek dengan baik. Grafik *train/cls_loss* dapat ditunjukkan pada Gambar 6.



Gambar 6. Grafik kegagalan (*loss*) pada data latih.


Pada Gambar 6 menunjukkan grafik kerugian/kegagalan (*loss*) dalam klasifikasi yang dihitung berdasarkan data latih selama proses pelatihan model. Bahwa terjadi penurunan yang signifikan pada awal pelatihan. Kemudian turun dengan stabil hingga iterasi terakhir. Menunjukkan bahwa kegagalan klasifikasi menurun.

Kurva: Sumbu X (*horizontal*): *Epochs*.

Sumbu Y (*vertical*): *train/cls_loss*.

3.4. *Val/cls_loss*

Val/cls_loss memberikan informasi seberapa baik model dalam mengklasifikasi objek pada data validasi. Tujuan validasi adalah untuk mendapatkan nilai *classification loss* serendah mungkin pada data yang tidak digunakan dalam pelatihan, untuk menunjukkan generalisasi model dengan baik. Grafik *val/cls_loss* dapat ditunjukkan pada Gambar 7.



Gambar 7. Grafik kegagalan (*loss*) klasifikasi pada data validasi.


Pada Gambar 7 jelas terlihat bahwa terjadi fluktuasi yang tidak terlalu besar di bawah 200 *epochs*, kemudian turun secara signifikan hingga iterasi terakhir. Ini menunjukkan bahwa model memprediksi dengan baik data yang tidak ada dalam dataset pelatihan.

Kurva: Sumbu X (*horizontal*): *Epochs*.

Sumbu Y (*vertical*): *val/cls_loss*.

3.5. *Train/dfl_loss*

Train/dfl_loss adalah nilai *Distribution Focal Loss* yang memberikan informasi seberapa baik model dalam mengarahkan perhatian pada bagian-bagian yang lebih penting dari data pelatihan. *Focal loss* dirancang untuk menangani masalah ketidakseimbangan kelas. Grafik *train/dfl_loss* dapat ditunjukkan pada Gambar 8.



Gambar 8. Grafik kegagalan (*loss*) DFL pada data latih.

Pada Gambar 8 jelas terlihat bahwa nilai *dfl_loss* pada awal pelatihan mencapai hampir 1,6. Ini menunjukkan pada awal pelatihan, model memiliki kesulitan dalam memfokuskan pada bagian-bagian penting dari data pelatihan. Kemudian terjadi penurunan yang signifikan, menunjukkan model dengan cepat memperbaiki distribusi perhatiannya secara drastis. Setelah penurunan


drastis, penurunan menjadi stabil seiring bertambahnya jumlah iterasi, ini menunjukkan kemampuan model dapat memprediksi bagian penting dari data pelatihan dengan baik.

Kurva: Sumbu X (*horizontal*): *Epochs*.

Sumbu Y (*vertical*): *train/df_loss*.

3.6. *Val/df_loss*

Val/df_loss adalah nilai *Distribution Focal Loss* yang memberikan informasi seberapa baik model dapat memprediksi bagian penting dari data validasi. Tujuan dari validasi adalah untuk mendapatkan nilai *Distribution Focal Loss* serendah mungkin pada data validasi. Grafik *val/df_loss* dapat ditunjukkan pada Gambar 9.



Gambar 9. Grafik kegagalan (*loss*) DFL pada data validasi.


Pada Gambar 9 jelas terlihat bahwa terjadi fluktuasi yang besar pada awal iterasi hingga pertengahan iterasi, menandakan model melakukan penyesuaian dan mengalami variabilitas yang tinggi dalam mengarahkan fokus perhatiannya. Kemudian mengalami penurunan yang stabil hingga iterasi akhir, menunjukkan bahwa model mencapai tingkat akurasi yang cukup baik dalam memprediksi bagian penting dari data validasi.

Kurva: Sumbu X (*horizontal*): *Epochs*.

Sumbu Y (*vertical*): *val/df_loss*.

3.7. *Metrics/precision(B)*

Metrics/precision(B) adalah matrik evaluasi yang menunjukkan proporsi prediksi positif yang benar. Mengukur seberapa banyak dari prediksi positif yang benar-benar positif. Grafik *Metrics/precision(B)* dapat ditunjukkan pada Gambar 10.



Gambar 10. Grafik prediksi positif (*precision*) untuk mengukur kinerja model klasifikasi.


Pada Gambar 10 jelas terlihat bahwa pada awal iterasi, nilai *precision* meningkat secara drastis dan terjadi fluktuasi, menunjukkan bahwa model dengan cepat membedakan antara prediksi positif yang benar dan salah. Kemudian *precision* cenderung stabil mendekati nilai 1, menunjukkan bahwa model semakin akurat dalam prediksi positif.

Kurva: Sumbu X (*horizontal*): *Epochs*.

Sumbu Y (*vertical*): *metrics/precision(B)*.

3.8. *Metrics/recall(B)*

Metrics/recall(B) adalah matrik evaluasi yang digunakan untuk menilai kinerja model klasifikasi. Dapat didefinisikan, dari semua contoh yang sebenarnya merupakan kelas positif, berapa banyak yang berhasil diprediksi dengan benar oleh model. Grafik *Metrics/recall(B)* dapat ditunjukkan pada Gambar 11.



Gambar 11. Grafik prediksi positif (*recall*) untuk mengukur kinerja model klasifikasi.

Pada Gambar 11 jelas terlihat bahwa nilai *recall* meningkat secara drastis dan terjadi fluktuasi pada awal iterasi, menunjukkan bahwa model dengan cepat mengidentifikasi *instance* positif.


dengan benar. Kemudian *recall* cenderung stabil mencapai nilai 1, menunjukkan model semakin baik dalam mengidentifikasi semua *instance* positif.

Kurva: Sumbu X (*horizontal*): *Epochs*.

Sumbu Y (*vertical*): *metrics/recall(B)*.

3.9. Metrics/mAP50(B)

Metrics/mAP50(B) adalah matrik yang digunakan untuk mengevaluasi kinerja deteksi objek. *mAP50* merupakan *mean Average Precision* yang dihitung menggunakan ambang batas *Intersection over Union (IoU)* sebesar 0,50. Grafik *Metrics/mAP50(B)* dapat ditunjukkan pada Gambar 12.



Gambar 12. Matrik pada ambang batas *IoU* 0.50.


Pada Gambar 12 jelas terlihat bahwa nilai *mAP50* meningkat secara drastis dan terjadi fluktuasi pada awal iterasi, menunjukkan bahwa model dengan cepat mendeteksi dengan baik. Kemudian *mAP50* cenderung stabil mendekati nilai 1, menunjukkan bahwa model semakin akurat dalam mendeteksi objek dengan ambang batas *IoU* 0.50.

Kurva: Sumbu X (*horizontal*): *Epochs*.

Sumbu Y (*vertical*): *metrics/mAP50(B)*.

3.10. Metrics/mAP50-95(B)

Metrics/mAP50-95(B) memberikan gambaran kinerja model dalam melakukan deteksi objek pada berbagai tingkat ketelitian. *mAP50-95* adalah *mean Average Precision* yang dihitung dengan meratakan *AP* pada berbagai ambang batas *IoU* 0,50 hingga 0,95. Grafik *mAP50-95(B)* dapat ditunjukkan pada Gambar 13.



Gambar 13. Matrik pada ambang batas *IoU* 0.50-0.95.


Pada Gambar 13 jelas terlihat bahwa nilai *mAP50-95* mengalami peningkatan secara drastis dan terjadi fluktuasi yang cukup besar pada awal pelatihan. Menunjukkan bahwa model dengan cepat untuk mendeteksi objek dengan baik pada ambang batas *IoU* 0,50 hingga 0,95. Pada akhir iterasi nilai *mAP50-95* mendekati angka 1, menunjukkan bahwa model mampu mendeteksi objek dengan presisi tinggi.

Kurva: Sumbu X (*horizontal*): *Epochs*.

Sumbu Y (*vertical*): *metrics/mAP50-95(B)*.

3.11. Confusion Matrix

Confusion matrix adalah parameter yang digunakan untuk mengevaluasi kinerja model klasifikasi, memperlihatkan kinerja model klasifikasi dengan menunjukkan jumlah prediksi benar dan salah yang dibuat oleh model dibandingkan dengan nilai sebenarnya dalam dataset uji. Grafik *confusion matrix* dapat ditunjukkan pada Gambar 14.



Gambar 14. *Confusion matrix*.

Pada Gambar 14 jelas terlihat bahwa model memprediksi dengan benar 16 *instance* dari pepaya bangkok. Kemudian model memprediksi dengan benar 13 *instance* dari pepaya *california* dan pepaya *red lady*. Pada pepaya hawaii, model memprediksi dengan benar 8 *instance*.

Kurva: Sumbu X (*horizontal*): meawakili label sebenarnya dari data (*true labels*).
Sumbu Y (*vertical*): mewakili prediksi yang dibuat oleh model (*predicted labels*).

4. DISKUSI

Tabel 4. Hasil pelatihan dan pengujian jenis pepaya model deteksi dan klasifikasi.

<i>Class</i>	<i>mAP</i>	<i>Confidence</i>	<i>Precision</i>	<i>Recall</i>	<i>mAP50-95</i>
Pepaya bangkok	96%	0.967	99.6%	100.0%	0.981
Pepaya <i>california</i>	97%	0.969			
Pepaya hawai	95%	0.955			
Pepaya <i>red lady</i>	95%	0.971			

Tabel 4 adalah hasil komputasi *precision recall* dari rata-rata semua kelas. Akurasi model terbaik pada ambang batas *IoU (Intersection over Union)* 0,50 hingga 0,95 sebesar 0,981 dari 300 *epochs* yang dilakukan selama pelatihan. *Precision* menunjukkan seberapa prediksi positif yang benar-benar positif. *Recall* menunjukkan seberapa banyak data positif yang sebenarnya dapat diprediksi oleh model. *Confidence* adalah tingkat kepercayaan model terhadap prediksi yang dilakukan.

Hasil yang telah didapat untuk berbagai pepaya yaitu pepaya bangkok, pepaya *california*, pepaya hawai, dan pepaya *red lady*, menunjukkan kinerja yang sangat baik dari model yang digunakan.

- a. Pepaya bangkok
Pepaya bangkok memiliki nilai *mAP* sebesar 96%, dan nilai *confidence* sebesar 0,967, menunjukkan bahwa model memiliki kemampuan yang baik dalam mengklasifikasi jenis pepaya bangkok.
- b. Pepaya *california*
Pepaya *california* memiliki nilai *mAP* sebesar 97%, dan nilai *confidence* sebesar 0,969, menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam mengklasifikasi jenis pepaya *california*.
- c. Pepaya hawai
Pepaya hawai dengan nilai *mAP* sebesar 95%, dan nilai *confidence* sebesar 0,955, menunjukkan bahwa model memiliki performa yang baik meskipun hasil yang didapat sedikit lebih rendah dibandingkan dengan pepaya bangkok dan pepaya *california*.
- d. Pepaya *red lady*
Pepaya *red lady* memiliki nilai *mAP* sebesar 95%, dan nilai *confidence* sebesar 0,971, menunjukkan bahwa model memiliki kemampuan yang baik dalam mengklasifikasi jenis pepaya *red lady*.

Tabel 5. Hasil perbandingan klasifikasi jenis pepaya menggunakan metode yang berbeda.

Peneliti	Metode	Fitur	Kelas	Akurasi
Bimantoro, Dkk. [10]	<i>Support Vector Machine</i>	HSI (<i>Hue Saturation and Intensity</i>)	Pepaya bangkok	63%
			Pepaya <i>california</i>	61%
Rata-rata				62%

Tabel 5 adalah hasil penelitian yang telah dilakukan sebelumnya untuk mengklasifikasi jenis pepaya dan tingkat kematangan berdasarkan fitur warna menggunakan *Support Vector Machine*. Dari sekian banyak fitur yang diterapkan pada penelitian sebelumnya, sebagai perbandingannya memakai hasil akurasi tertinggi, yaitu pada fitur HSI. Untuk pepaya bangkok memiliki hasil akurasi sebesar 63%, dan pepaya *california* memiliki hasil akurasi sebesar 61% [10].

Dalam penelitian yang dilakukan Bimantoro, Dkk [10] melakukan klasifikasi jenis dan tingkat kematangan buah pepaya berdasarkan fitur warna, tekstur dan bentuk menggunakan *Support Vector Machine (SVM)*. Dalam penelitian ini sebuah sistem telah dikembangkan dengan kemampuan mengklasifikasikan jenis dan tingkat kematangan berdasarkan fitur warna, tekstur, dan bentuk menggunakan metode *Support Vector Machine*. Proses ekstraksi fitur melibatkan metode pendekatan statistik dan GLCM (*Gray Level Co-occurrence Matrix*). Fitur warna diekstraksi dalam ruang warna HSI dan YCbCr, fitur tekstur dengan GLCM, serta fitur bentuk menggunakan *Horizontal Vertical Projection Integral*. Jumlah keseluruhan data yang digunakan mencapai 600 data citra buah pepaya yang dibagi menjadi data pelatihan dan data uji. Hasil akurasi tertinggi untuk dataset pepaya bangkok diperoleh pada fitur HSI dengan nilai 63%, sementara pada dataset *california*, akurasi tertinggi juga diperoleh pada fitur HSI dengan nilai 61% [10].

Berdasarkan hasil klasifikasi yang telah dilakukan pada citra buah pepaya, peneliti dapat menyimpulkan bahwa model klasifikasi yang digunakan mampu mencapai tingkat akurasi yang tinggi. Dapat dibandingkan pada penelitian sebelumnya, hasil akurasi yang didapat masih kurang akurat, oleh sebab itu peneliti akan meningkatkan nilai akurasi klasifikasi jenis pepaya menggunakan model yang berbeda. Karena hal tersebut peneliti mengusulkan untuk melakukan klasifikasi jenis pada citra pepaya menggunakan YOLOv8.

5. KESIMPULAN

Berdasarkan hasil klasifikasi yang telah dilakukan pada citra buah pepaya, peneliti dapat menyimpulkan bahwa model klasifikasi yang digunakan mampu mencapai tingkat akurasi yang tinggi. Hasil tersebut menunjukkan potensi yang besar dalam melakukan otomatisasi sortasi pepaya di dunia industri. Adapun beberapa kesimpulan yang didapat oleh peneliti, sebagai berikut:

1. Dalam melakukan deteksi klasifikasi jenis pepaya, YOLOv8 mampu mencapai tingkat akurasi yang tinggi.
2. Model memiliki *mAP* terbaik dan konsisten pada *epochs* ke 144 dari 300 *epochs*, dengan nilai 0,995.
3. Mendapat hasil maksimal dalam melakukan klasifikasi sesuai masing-masing kelas pepaya. Buah pepaya Bangkok memiliki nilai *mAP* sebesar 96%. Kemudian pepaya *california* memiliki nilai *mAP* tertinggi yaitu sebesar 97%. Untuk pepaya hawai dan pepaya *red lady* masing-masing memiliki nilai *mAP* sebesar 95%. Hasil akurasi klasifikasi jenis pepaya menggunakan YOLOv8 cukup baik, model mampu mengklasifikasi dengan baik sesuai masing-masing kelas pepaya.
4. Dibutuhkan waktu yang relatif cepat dalam melakukan klasifikasi, yaitu *speed: 0.0 ms preprocess, 0.7ms inference, 0.0ms postprocess per image*.

Model terbukti efisien dengan waktu pemrosesan yang singkat. Bukti tersebut menunjukkan bahwa dengan penelitian ini memiliki potensi besar ketika diimplementasikan ke dunia industri guna otomatisasi sortasi jenis pepaya. Dengan waktu pemrosesan yang singkat, dapat mengurangi waktu dan tenaga yang cukup besar jika dilakukan secara manual.

DAFTAR PUSTAKA

- [1] P. Barat *et al.*, “Jurnal Inovasi Penelitian,” vol. 1, no. 4, 2020.
- [2] W. E. Sari, “JOINTECS,” vol. 3, no. 28, pp. 4–8, 2022.
- [3] A. D. Setiawan, “PENGEMBANGAN BUDIDAYA PEPAYA JENIS CALIFORNIA,” vol. 1, no. 1, pp. 51–59, 2023.
- [4] K. Magetan, D. Membuat, A. E. Cahyani, N. Fadillah, P. Oktaviana, and L. Yuhanna, “OLAHAN PEPAYA CALIFORNIA EMPOWERMENT OF THE KERIK VILLAGE COMMUNITY , MAGETAN REGENCY IN MAKING CALIFORNIA PAPAIA PRODUCTS,” pp. 12–19, 2022, doi: 10.25105/jamin.v4i1.10344.
- [5] A. Firlansyah, “Klasifikasi Tingkat Kematangan Buah Pepaya Berdasarkan Fitur Warna Menggunakan Jaringan Syaraf Tiruan,” vol. 6, no. 2, pp. 55–60, 2021.
- [6] S. V. Widyasari, M. I. Muttaqin, T. P. Ananda, and A. Stefanie, “IMPLEMENTASI INTERNET OF THINGS PADA SISTEM MONITORING KEMATANGAN BUAH PEPAYA CALIFORNIA DENGAN METODE DEEP LEARNING,” vol. 7, no. 3, pp. 1946–1952, 2023.
- [7] M. Ezar *et al.*, “PENENTUAN KUALITAS BUAH PEPAYA CALIFORNIA MENGGUNAKAN METODE K-NN,” vol. 6, no. 1, pp. 1–8, 2021.
- [8] M. Ezar, A. Rivan, and G. R. Sung, “Identifikasi Mutu Buah Pepaya California (Carica Papaya L .) Menggunakan Metode Jaringan Syaraf Tiruan,” vol. 10, pp. 113–119, 2021.
- [9] A. Jayadi and D. Meilinda, “KLASIFIKASI TINGKAT KEMATANGAN BUAH PEPAYA BERDASARKAN WARNA KULIT MENGGUNAKAN SENSOR WARNA TCS3200,” vol. 3, no. 2, pp. 1–13.
- [10] F. Bimantoro, P. Studi, T. Informatika, F. Teknik, and U. Mataram, “KLASIFIKASI JENIS DAN TINGKAT KEMATANGAN BUAH PEPAYA BERDASARKAN FITUR WARNA , TEKSTUR DAN BENTUK,” vol. 4, no. 1, pp. 75–87, 2022.
- [11] A. Kusuma, A. Rangga, S. Nurrohman, K. T. Anggoro, and R. Susun, “Implementasi Algoritma Yolo Dalam Pendeteksian Tingkat Kematangan Pada Buah Pepaya,” vol. 1, no. 1, pp. 74–77, 2023.
- [12] A. Helsaputra, A. L. Prasasti, R. R. Septiawan, and U. Telkom, “IMPLEMENTASI DEEP LEARNING UNTUK PREDIKSI TINGKAT KEMATANGAN DAN BOBOT BUAH PEPAYA DEEP LEARNING IMPLEMENTATION FOR WEIGHT AND RIPENESS PREDICTION OF,” vol. 8, no. 6, pp. 11993–11998, 2021.

- [13] F. Aziz, U. Bina, S. Informatika, U. N. Mandiri, and M. Wajah, "YOLO-V8 PENINGKATAN ALGORITMA UNTUK DETEKSI," vol. 7, no. 3, pp. 1437–1444, 2023.
- [14] A. Setiyadi, E. Utami, and D. Ariatmanto, "Analisa Kemampuan Algoritma YOLOv8 Dalam Deteksi Objek Manusia Dengan Metode Modifikasi Arsitektur," vol. 7, no. September, pp. 891–901, 2023.
- [15] L. Suroiyah, Y. Rahmawati, and R. Dijaya, "FACEMASK DETECTION USING YOLO V5 DETEKSI MASKER WAJAH MENGGUNAKAN METODE YOLO V5," vol. 4, no. 6, pp. 1277–1286, 2023.
- [16] I. Maulana, N. Rahaningsih, T. Suprpti, T. Informatika, K. Cirebon, and O. Detection, "ANALISIS PENGGUNAAN MODEL YOLOV8 (YOU ONLY LOOK ONCE)," vol. 7, no. 6, pp. 3621–3627, 2023.
- [17] M. Algoritma, A. Beregerak, G. I. Andaru, and D. H. Fudholi, "Pengembangan Sistem Deteksi On-Shelf Availability Produk Abstrak," vol. 5, no. 2, pp. 1980–1988, 2024.