

MODEL MACHINE LEARNING UNTUK DETEKSI TINGKAT KEMATANGAN TANDAN BUAH SEGAR KELAPA SAWIT MENGGUNAKAN METODE YOLOV8

Machine Learning Model for Detecting the Ripeness Level of Fresh Palm Fruit Bunches using The YOLOV8 Method

Zahwa Genoveva¹, Rama Dian Syah^{2*}

¹ Program Studi Informatika, Fakultas Teknologi Industri, Universitas Gunadarma.
zahwagenoveva09@gmail.com

² Program Studi Sistem Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi
Universitas Gunadarma. rama_ds@staff.gunadarma.ac.id.

*) Penulis korespondensi

Diterima 05 Juli 2024; Disetujui 28 Agustus 2024

ABSTRAK

Kemajuan teknologi informasi membawa banyak perubahan dibidang pertanian. Pemanfaatan teknologi dapat dilakukan pada kelapa sawit untuk mendukung pertanian di Indonesia. Penelitian ini bertujuan untuk membuat model machine learning untuk deteksi tingkat kematangan Tandan Buah Segar (TBS) kelapa sawit menggunakan model YOLOv8. Model machine learning ini dirancang untuk meningkatkan akurasi dan efisiensi penentuan kematangan buah kelapa sawit, yang sangat penting bagi industri kelapa sawit. *Dataset* yang digunakan dalam penelitian ini terdiri dari 6592 citra yang dikumpulkan dari platform *Roboflow*, yang mencakup berbagai tingkat kematangan buah kelapa sawit. Metodologi penelitian yang diterapkan adalah *Cross Industry Standard Process for Data Mining* (CRISP-DM), yang meliputi tahap pemahaman bisnis, pemahaman data, persiapan data, pemodelan, dan evaluasi. Proses pelatihan model machine learning berlangsung selama 3107 jam dengan nilai *precision* mencapai 0.945, nilai *recall* mencapai 0.947, dan nilai *mean Average Precision* (mAP) mencapai 0.98. Model deteksi ini mampu mendeteksi tingkat kematangan kelapa sawit dengan baik yang dibuktikan oleh evaluasi model dengan nilai kurva *f1-confidence* mencapai 95% serta nilai kurva *precision-recall* mencapai 98%.

Kata kunci: Machine Learning, Sistem Deteksi, TBS Kelapa Sawit, YOLOv8.

ABSTRACT

Advances in information technology have brought many changes in the agricultural sector. The use of technology can be done in oil palm to support agriculture in Indonesia. This study aims to create a machine learning model for the detection of the maturity level of Fresh Fruit Bunches (FFB) of oil palm using the YOLOv8 model. This machine learning model is designed to improve the accuracy and efficiency of determining the ripeness of oil palm fruits, which is very important for the palm oil industry. The dataset used in this study comprises 6592 images collected from the Roboflow platform, covering various ripeness levels of oil palm fruits. The research methodology applied is the Cross Industry Standard Process for Data Mining (CRISP-DM), encompassing stages of business understanding, data understanding, data

*preparation, modeling, and evaluation. The machine learning model training process took 3107 hours with a precision value reaching 0.945, a recall value reaching 0.947 and a mean Average Precision (mAP) value reaching 0.98. This detection model can detect the ripeness level of palm oil well as proven by model evaluation with an f1-confidence curve value reaching 95% and a precision-recall curve value reaching 98%.
Keyword: Machine Learning, Detection System, Oil Palm FFB, YOLOv8.*

PENDAHULUAN

Di era komputer dan internet saat ini, kemajuan teknologi telah membawa banyak perubahan besar dalam berbagai bidang, salah satunya adalah sektor pertanian (Maulida et al., 2023). Indonesia adalah negara kepulauan terbesar di dunia dengan banyak perkebunan, salah satunya adalah perkebunan kelapa sawit. Dengan luas sekitar 15,4 juta hektar dan produksi 47 juta ton pada tahun 2023, perkebunan kelapa sawit Indonesia adalah produsen utama kelapa sawit di dunia (Badan Pusat Statistik, 2024). Menurut penelitian yang dilakukan oleh Himmah, kelapa sawit atau *elaeis guineensis* adalah tanaman perkebunan atau industri yang menghasilkan minyak nabati yang memiliki banyak keuntungan (Himmah et al., 2020). Minyak kelapa sawit digunakan secara luas dalam berbagai produk makanan, kosmetik, dan bahan bakar bio (Rosmegawati, 2021). Kelapa sawit memiliki peranan yang cukup penting bagi perekonomian Indonesia, khususnya sebagai penyedia lapangan kerja dan sumber pendapatan

masyarakat. Selain itu Indonesia juga menjadi produsen CPO (*Crude Palm Oil*) nomor satu di dunia (Saragih & Rahayu, 2022). Hal ini membuka peluang untuk kembali meningkatkan harga beli TBS (Tandan Buah Segar) kelapa sawit oleh pihak pabrik yang pada akhirnya meningkatkan harga jual CPO di pasar dunia.

Menurut Sari, tahap kematangan kelapa sawit sangat mempengaruhi tingkat ekstraksi minyak dari (Tandan Buah Segar) kelapa sawit (Sari et al., 2022). Kematangan kelapa sawit memiliki perbedaan kematangan yang terlihat dari perubahan warna. Kelapa sawit dengan warna merah menunjukkan matang, warna oranye kemerahan menunjukkan terlewat matang, warna hitam kemerahan menunjukkan kurang matang, dan warna hitam keunguan menunjukkan mentah. Deteksi kelapa sawit dengan cara manual dapat mengalami kesulitan. Kemampuan deteksi kelapa sawit dengan akurat dan tepat sangat diperlukan. Perbedaan persepsi sangat mempengaruhi keoptimalan dalam menyeleksi buah kelapa sawit dengan tingkat kematangan

yang tepat. Deteksi tingkat kematangan TBS kelapa sawit dengan cara yang efektif dan akurat sangat diperlukan.

Perkembangan teknologi *Artificial Intelligence* (AI) menawarkan solusi yang mampu mengatasi tantangan dalam mendeteksi kematangan TBS kelapa sawit. Salah satu cabang AI yang sangat berpengaruh adalah pembelajaran mesin (*Machine Learning*), dimana komputer dilatih untuk mengenali pola dan membuat prediksi berdasarkan data yang diberikan. Penelitian terdahulu sudah banyak dilakukan untuk mendeteksi tingkat kematangan kelapa sawit menggunakan metode *Computer Vision*. Pendekatan terbaik untuk deteksi tingkat kematangan TBS kelapa sawit menggunakan model deep learning yang merupakan cabang machine learning (Rifqi & Suharjito, 2021). Deteksi objek atau biasa disebut pengenalan objek merupakan suatu aplikasi komputer yang bertujuan untuk mendeteksi dan mengidentifikasi objek tertentu (Dompeipen & Sompie, 2020). Kemampuan mendeteksi objek ini merupakan bagian dari ilmu *Computer Vision*, yang mempelajari cara komputer dapat bekerja seperti mata manusia untuk mengenali objek. Dalam *Computer Vision*, deteksi objek dapat menganalisis

video maupun citra untuk menyelesaikan berbagai masalah (Agustina, 2022).

Penelitian sebelumnya telah menunjukkan berbagai pendekatan dalam mendeteksi kematangan buah kelapa sawit oleh Muhammad Rifqi dan Suharjito menggunakan model *EfficientNet* untuk deteksi kematangan TBS dengan model *EfficientNetB0* mencapai akurasi 0.9893 dan *EfficientNetB1* mencapai 0.9949 (Rifqi & Suharjito, 2021). Penelitian oleh Sari menggunakan algoritma *K-Means* untuk melakukan klusterisasi terhadap tingkat kematangan TBS yang terlihat berdasarkan warna, dengan akurasi mencapai 90% (Sari et al., 2022). Penelitian oleh Feri Agustina dan Muhammad Sukron menggunakan algoritma *YOLO* untuk deteksi kematangan buah pepaya berbasis Android, dengan nilai *accuracy* 93% (Agustina, 2022). Penelitian oleh Suhardi Aras, Putriana Tanra, dan Muhammad Bazhar menggunakan *YOLOv5* untuk mendeteksi tingkat kematangan buah tomat dengan akurasi 73% yang dipengaruhi oleh kualitas *dataset* dan sudut pengambilan citra (Aras et al., 2024).

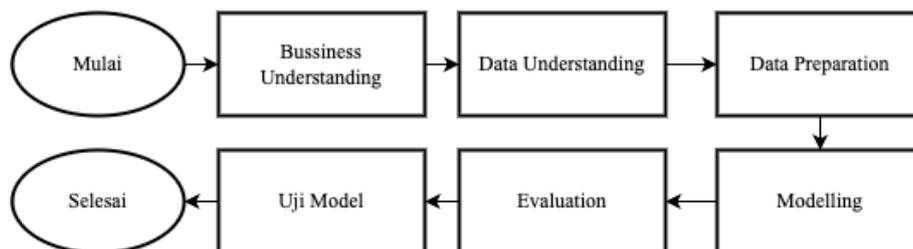
Berdasarkan uraian tersebut, penelitian ini bertujuan untuk membuat

model machine learning untuk deteksi kematangan kelapa sawit menggunakan data dari platform *Roboflow*, yang mencakup berbagai citra buah kelapa sawit dengan tingkat kematangan yang berbeda-beda, untuk melatih model *YOLOv8* dengan evaluasi kinerja algoritma menggunakan metrik standar seperti akurasi, f1-score, dan mAP. Setelah model terlatih, sistem ini akan diintegrasikan dengan *video input* sehingga mampu menampilkan *frame video* dan mendeteksi tingkat kematangan buah kelapa sawit dalam setiap *frame*. Dengan mengimplementasikan *YOLOv8*, sistem ini diharapkan dapat memberikan solusi yang lebih efisien dan akurat dalam mendeteksi kematangan TBS kelapa sawit, sehingga meningkatkan produktivitas dan mengurangi kesalahan manusia dalam proses penilaian kematangan.

BAHAN DAN METODE

Dalam penelitian ini, bahan sebagai perangkat lunak yang digunakan yaitu

platform *Google Colab*, *Roboflow*, dan data citra TBS kelapa sawit dengan menerapkan metode *YOLOv8*. Metode penelitian yang digunakan dalam penelitian ini adalah CRISP-DM. Metode penelitian CRISP-DM adalah kerangka kerja yang menerjemahkan masalah bisnis menjadi proyek *data mining* dan mengimplimentasikannya pada teknologi apapun. Tahapan CRISP-DM dapat dilihat pada Gambar 1. Penelitian ini bertujuan untuk dekteksi tingkat kematangan buah kelapa sawit dengan melakukan identifikasi tingkat kematangan Tandan Buah Segar (TBS) kelapa sawit. Proses pembuatan program sendiri terdiri dari beberapa tahapan yaitu *business understanding*, *data understanding*, *data preparation*, *modelling*, *evaluation* dan uji model menggunakan metode *YOLOv8*. Penelitian ini menggunakan *dataset* yang berasal dari platform *Roboflow*, dengan setiap citra akan diberi label “masak”, “kurang masak”, “terlalu masak” dan “mentah”.



Gambar 1. Metode CRISP-DM

A. Business Understanding

Seperti manusia, komputer harus diperkenalkan kepada objek yang akan dipelajari. Salah satu cara untuk mengenalkan objek-objek yang ada yaitu dengan cara memberikan sekumpulan data citra objek. Pada kasus ini objek yang dimaksud adalah citra TBS kelapa sawit dengan tingkat kematangan yang berbeda. Data yang digunakan untuk pembelajaran biasanya disebut dengan data *understanding*. Pada tahap ini, data yang akan digunakan dikumpulkan dan dianalisis kualitasnya secara menyeluruh. *Dataset* yang diperlukan untuk pembuatan program terdiri dari 6592 citra yang diperoleh dari platform *Roboflow* yang mencakup berbagai tingkat kematangan buah kelapa sawit.

B. Data Preparation

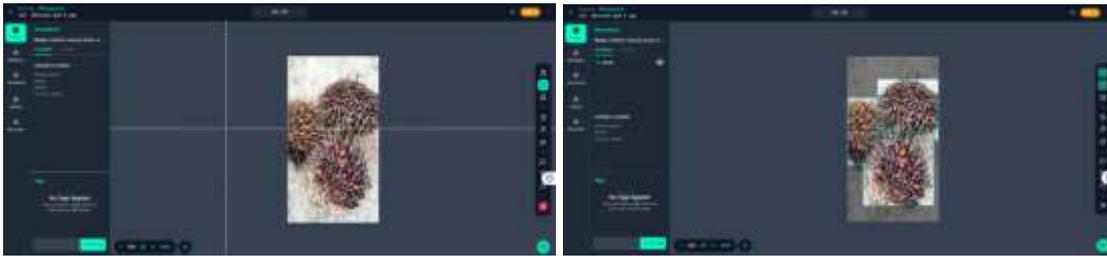
Preprocessing pada penelitian ini dilakukan menggunakan *Roboflow*. Tahapan *preprocessing* yang dilakukan diantaranya adalah anotasi, split data, auto orient, resize dan auto-adjust-contrast.

Tahapan Anotasi melibatkan penerapan label pada citra yang menunjukkan posisi dan jenis citra (Pawidya & Salam, 2024). Penggunaan *labeling* pada *Roboflow* dilakukan untuk menggambar *bounding box* anotasi di

sekitar objek dan memberikan informasi kepada model mengenai posisi dan jenis objek yang terdapat pada citra. Proses anotasi memiliki peran krusial dalam menghasilkan *dataset training* berkualitas tinggi, serta mendukung kelancaran proses pengenalan objek pada tahap selanjutnya. Gambar 2 menunjukkan tahapan anotasi.

Tahapan split dataset dikelompokkan menjadi tiga *subset* yang berbeda, yaitu *train*, *valid*, dan *test* yang diimplementasikan melalui platform *Roboflow* dengan perbandingan 7 : 2 : 1 untuk masing-masing bagian. Pengelompokan ini dilakukan dengan tujuan untuk mengatur *dataset* yang digunakan dalam penelitian dan memfasilitasi proses pelatihan, validasi dan pengujian model dengan prosedur yang sesuai. Tahapan split dataset terlihat pada Gambar 3.

Tahapan auto-orient digunakan untuk mengatasi variasi orientasi objek pada citra dalam *dataset* yang diterapkan dalam penelitian (Nugraha & Wibowo, 2024). Fitur *Auto Orient* bertujuan untuk secara otomatis mengatur orientasi objek dalam *dataset*, sehingga menciptakan konsistensi dan akurasi penempatan. Gambar 4. Tahapan Auto-Orient pada *Roboflow*.



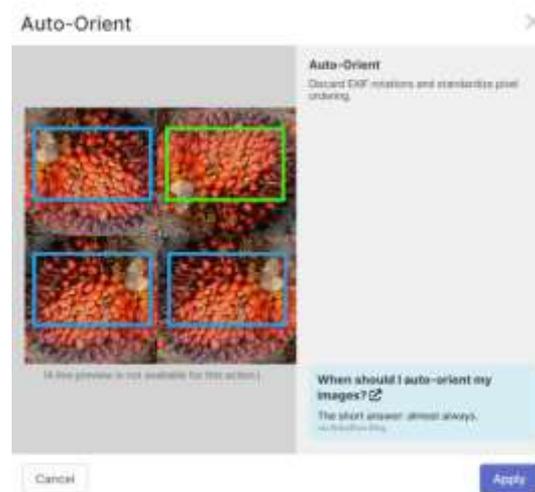
(a) Sebelum Anotasi

(b) Sesudah Anotasi

Gambar 2. Tahapan Anotasi pada Roboflow



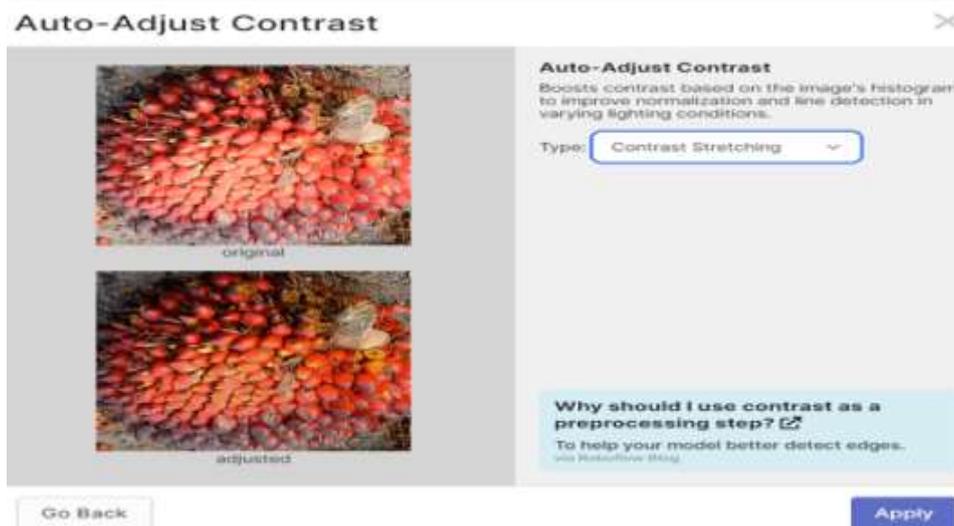
Gambar 3. Tahapan Split Dataset pada Roboflow



Gambar 4. Tahapan Auto Orient pada Roboflow

Tahapan resize digunakan untuk mengubah ukuran citra menjadi 540×540 piksel menggunakan platform *Roboflow*. Ukuran ini dipilih karena cukup besar untuk mempertahankan detail penting, namun cukup kecil untuk mengurangi beban komputasi, sehingga

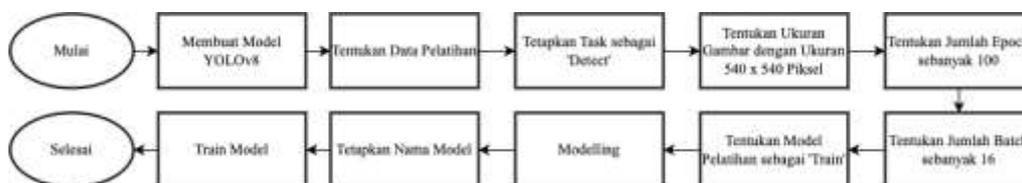
efisien untuk melatih model. Selain itu, dimensi yang seragam memungkinkan model memproses citra dengan lebih konsisten dan cepat, karena tidak perlu menyesuaikan setiap ukuran citra yang berbeda. Tahapan resize pada Roboflow terdapat pada Gambar 5.



Gambar 5. Tahapan Resize pada Roboflow



Gambar 6. Tahapan Auto-Adjust Contrast Roboflow



Gambar 7. Flowchart Train Model

Tahapan *Auto-Adjust Contrast* diatur menggunakan teknik *Contrast Stretching*. Pendekatan ini berguna untuk meningkatkan kontras citra berdasarkan histogram citra, yang membantu dalam

normalisasi dan deteksi garis dalam berbagai kondisi pencahayaan. Dengan menggunakan *Contrast Stretching*, perbedaan antar piksel dalam citra menjadi lebih mencolok, sehingga detail

yang ada lebih mudah terlihat. Tahapan *Auto-Adjust Contrast* terlihat pada Gambar 6.

C. Modelling

Tahapan modelling memiliki fokus utama yaitu mengembangkan dan melatih model menggunakan kumpulan data yang telah disiapkan sebelumnya. Model yang digunakan pada penelitian ini adalah model *YOLOv8s.pt* dan *YOLOv8n.pt* dengan menggunakan arsitektur *YOLOv8* untuk melakukan *object detection*. Model ini dibangun dengan tujuan untuk mengenali dan membedakan objek pada

Berdasarkan flowchart pada Gambar 7. pelatihan model bertujuan untuk mengajarkan model bagaimana mengenali dan membedakan tingkat kematangan buah kelapa sawit dari berbagai citra yang telah disiapkan, sehingga model dapat bekerja secara akurat dan efisien. Setelah model selesai dilatih, hasil akhir dari pelatihan akan ditampilkan. Hasil terbaik dari pelatihan disimpan dalam *file* bernama *best.pt*.

HASIL DAN PEMBAHASAN

Evaluasi dilakukan untuk mengukur kinerja model dalam mendeteksi tingkat kematangan buah kelapa sawit pada citra. Tujuan evaluasi ini adalah untuk mengetahui seberapa efektif model dalam

citra. Proses ini melibatkan tahap pelatihan model dengan memanfaatkan *dataset* yang telah mengalami sejumlah langkah pra-pemrosesan, termasuk *split*, anotasi dan penyesuaian ukuran. Proses *model training* dilakukan di *Google Colaboratory*. Pelatihan model dilakukan sebanyak 100 *epoch*.

Setiap iterasi (*epoch*) membantu model mempelajari lebih dalam tentang variasi dalam data, sehingga model dapat mendeteksi tingkat kematangan buah dengan lebih akurat dan konsisten. Berikut Flowchart untuk Train Model terdapat pada Gambar 7. mengenali objek pada citra baru yang belum pernah dilihat sebelumnya. Beberapa metode evaluasi yang digunakan meliputi mAP (*mean Average Precision*) matrix, Kurva Hubungan antara *Precision* dengan *Recall*, Kurva Hubungan antara *F1* dengan *Confidence*, dan Confusion Matrix

A. mAP Matrix

Mean Average Precision (mAP) memberikan pandangan keseluruhan tentang kemampuan model untuk mengenali berbagai kelas objek secara akurat (Yuliyanto et al., 2022). *Mean Average Precision* (mAP) mengukur akurasi deteksi model dengan

membandingkan *bounding box* prediksi dengan yang sebenarnya. Dalam konteks ini, mAP dihitung pada dua nilai ambang yang berbeda, yaitu ‘*mAP50*’ dan ‘*mAP50-95*’. Setiap nilai ambang ini mencerminkan Tingkat kesulitan deteksi yang berbeda dan mengukur Tingkat persisi model dalam mengenali objek dalam berbagai situasi. Matriks mAP terdapat pada Gambar 8. Proses pelatihan ini berlangsung selama 3.107 jam dan menghasilkan nilai *mean Average Precision* (mAP) mencapai 0.98 atau 98%. mAP mengukur seberapa baik model mengenali objek dengan membandingkan *bounding box* pada data latih dengan yang terdeteksi. Semakin tinggi nilai mAP, semakin akurat model dalam mendeteksi objek. Nilai recall mencapai 0.947 atau 95%. Nilai Precision mencapai 0.945 atau 95%.

B. Kurva Precision-Recall

Precision merupakan proporsi hasil yang relevan dari hasil yang diprediksi. *Recall* merupakan proporsi hasil yang relevan yang berhasil diidentifikasi oleh model) Semakin tinggi nilai recall yang diperoleh dari pelatihan dan validasi data, maka nilai precision juga semakin tinggi. Gambar 9 menunjukkan kurva hubungan antara nilai precision dan recall.

Kurva pada Gambar 9 menunjukkan hubungan antara Deteksi yang dibangun memiliki nilai *precision* dan *recall* yang baik untuk semua kelas, dengan nilai mencapai 0.98 atau 98%. Ini menunjukkan bahwa model memiliki kemampuan yang baik dalam menghindari kesalahan dan berhasil mengidentifikasi sebagian besar objek yang relevan.

```

100 epochs completed in 3.107 hours.
Optimizer stripped from runs/detect/train/weights/last.pt, 22.5MB
Optimizer stripped from runs/detect/train/weights/best.pt, 22.5MB

Validating runs/detect/train/weights/best.pt...
Ultralytics YOLOv8.0.196 Python-3.10.12 torch-2.3.0+cu121 CUDA:0 (Tesla T4, 15102MiB)
Model summary (fused): 168 layers, 11127132 parameters, 0 gradients, 28.4 GFLOPs

```

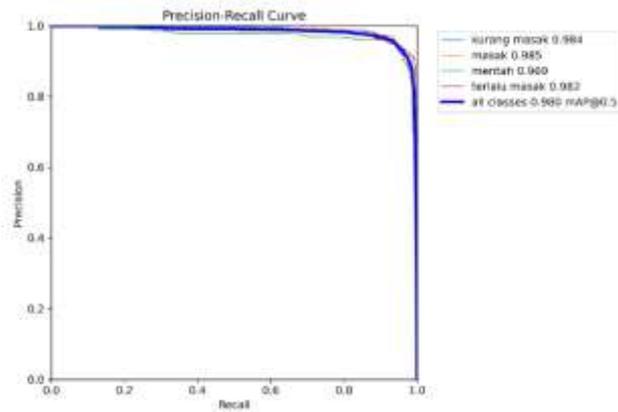
Class	Images	Instances	Box(P)	R	mAP50	mAP50-95
all	1311	2654	0.945	0.947	0.98	0.791
kurang masak	1311	757	0.958	0.934	0.984	0.78
masak	1311	556	0.939	0.96	0.985	0.843
mentah	1311	786	0.936	0.952	0.969	0.749
terlalu masak	1311	635	0.945	0.944	0.982	0.791

```

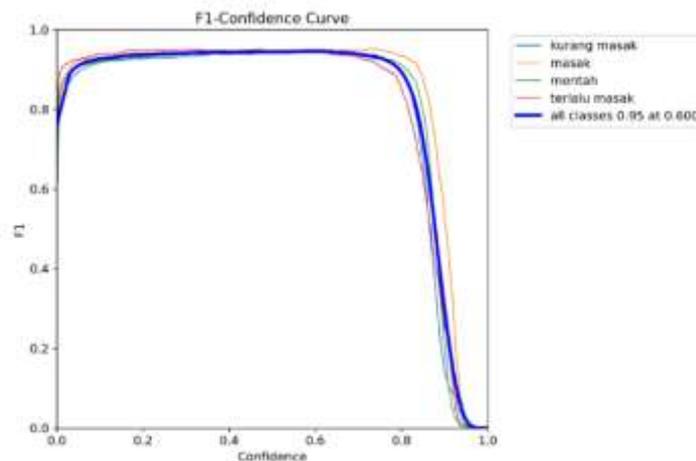
Speed: 0.2ms preprocess, 3.2ms inference, 0.0ms loss, 2.0ms postprocess per image
Results saved to runs/detect/train
Learn more at https://docs.ultralytics.com/modes/train

```

Gambar 8. mAP Matrix



Gambar 9. Kurva hubungan antara Precision dan Recall



Gambar 10. Kurva hubungan antara F1 dan Confidence

C. Kuva F1-Confidence

Nilai F1-score merupakan rata-rata perbandingan antara nilai precision dan recall (Kohsasih & Situmorang, 2022) dan nilai confidence adalah seberapa yakin model dalam mengenali objek. Kurva F1-Confidence pada Gambar 10.

Kurva pada Gambar 10 menunjukkan hubungan antara *F1* dan *confidence* tertinggi yang adalah 95%. Ini menunjukkan bahwa model memiliki

keseimbangan yang baik antara *f1* dan *confidence* dalam mendeteksi objek, dengan kemampuan yang tinggi dalam mengenali sebagian besar objek yang ada dengan tingkat kepercayaan yang cukup tinggi.

D. Confusion Matrix

Confusion Matrix adalah metrik penting dalam evaluasi kinerja model yang digunakan untuk mengukur akurasi

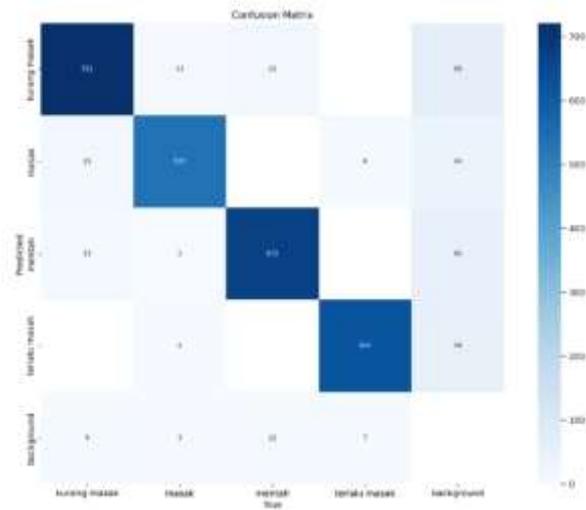
dan kemampuan model untuk mengklasifikasikan data ke dalam kategori yang benar (Romadloni et al., 2022). Matrix Confusion dapat memperlihatkan jumlah data yang diklasifikasikan dengan benar ke dalam kategori positif dan negatif, serta berapa banyak data yang salah diklasifikasikan. Ini memberi gambaran tentang seberapa baik model dapat mengenali objek atau fenomena yang dimaksud. Terdapat 4 nilai yang merupakan representasi hasil proses klasifikasi pada confusion matrix yaitu *True Positive* (TP), *False Positive* (FP), *False Negative* (FN), dan *True Negative* (TN).

Jika dilihat dari *Matriks Confusion* pada Gambar 11, dapat dijelaskan bahwa persentase prediksi yang benar untuk setiap kelas (*True Positive*) cukup tinggi, sekitar 97%. Namun, dapat dilihat juga bahwa ada objek yang seharusnya terdeteksi tetapi tidak terdeteksi (*False Negative*), dengan persentase tertinggi terjadi pada kelas "mentah", mencapai 3%. Hal ini membuktikan bahwa model memiliki kinerja yang baik dengan sedikit kelemahan.

E. Batch

Pendekatan *batch* digunakan karena dataset yang besar sehingga *dataset* dapat dibagi menjadi bagian-bagian kecil yang disebut *batch* (Ayyiyah et al., 2023). Setiap *batch* berisi sejumlah sampel data yang akan digunakan dalam satu iterasi pelatihan. Implementasi penggunaan *batch* juga dilakukan dalam validasi untuk memeriksa kinerja model pada setiap langkah. Dengan menggunakan pendekatan ini, pelatihan model dapat dilakukan secara bertahap dan efisien, memungkinkan penggunaan sumber daya komputasi yang optimal. *Batch* sampel data terdapat pada Gambar 12.

Gambar 12 menunjukkan kemampuan model untuk mendeteksi dan mengklasifikasikan tingkat kematangan buah kelapa sawit dengan cukup akurat yang ditunjukkan dengan nilai *confidence score*. Model memberikan prediksi dengan tingkat keyakinan tertentu yang ditunjukkan oleh skor prediksi di setiap label. Setiap kotak berwarna memiliki label teks yang menunjukkan klasifikasi tingkat kematangan buah dan angka skor prediksi. Skor ini menunjukkan tingkat kepercayaan model terhadap prediksinya.



Gambar 11. Confusion Matrix



Gambar 12. Batch



Gambar 13. Pengujian Terhadap Citra Baru

F. Uji Model

Sistem yang dikembangkan untuk mendeteksi tingkat kematangan buah kelapa sawit dapat dilakukan dari sumber data seperti *file video* dan citra. Pengujian dilakukan pada citra baru dan video. Pengujian dilakukan dengan *best weights* yang berarti iterasi *dataset* terbaik yang telah diproses. Berikut hasil pengujian terhadap citra baru terdapat pada Gambar 13.

Dari hasil pengujian pada Gambar 13 terlihat bahwa model algoritma *YOLOv8* berhasil mendeteksi beberapa buah kelapa sawit dengan baik yang ditunjukkan dengan nilai *confidence score* yang tampak seperti terlalu masak mencapai 98%, kurang masak mencapai 91%, terlalu masak mencapai 93%. Namun, terlihat bahwa ada beberapa buah kelapa sawit yang tidak terdeteksi oleh model. Misalnya, beberapa buah kelapa sawit yang terletak di belakang objek utama atau sebagian tertutup oleh objek

lain tidak terdeteksi. Kemampuan model *YOLO* untuk mendeteksi objek dipengaruhi oleh berbagai faktor, termasuk sudut pandang, pencahayaan, dan tingkat kematangan buah yang mungkin sulit dikenali dari beberapa sudut tertentu. Setelah melakukan uji deteksi pada citra, langkah selanjutnya adalah melakukan uji deteksi pada *video*. Pengujian dengan *video* akan memberikan informasi lebih mendetail mengenai kemampuan model untuk mendeteksi tingkat kematangan buah kelapa sawit dalam kondisi yang lebih dinamis dan realistis, seperti yang terjadi di lingkungan lapangan. Dengan melanjutkan pengujian pada *video*, diharapkan dapat lebih memahami kekuatan dan kelemahan model dalam situasi nyata, dan melakukan penyesuaian yang diperlukan untuk meningkatkan performa deteksi objek buah kelapa sawit. Pengujian pada video terdapat pada Gambar 14.



Gambar 14. Pengujian Terhadap Video

Pada Gambar 14 terdapat banyak buah sawit yang tidak terdeteksi atau hanya terdeteksi sekilas (tidak tampak confidence score) dikarenakan faktor posisi dan banyaknya buah yang mempengaruhi kemampuan model algoritma *YOLOv8* untuk mendeteksi objek. Banyak hal yang dapat mempengaruhi tidak akuratnya *YOLOv8* dalam mendeteksi objek seperti kurangnya *dataset* pada *training*, kualitas citra yang kurang bagus, serta kualitas *dataset* itu sendiri.

KESIMPULAN DAN SARAN

Penelitian ini berhasil menunjukkan model machine learning dengan metode *YOLOv8* mampu mendeteksi tingkat kematangan Tandan Buah Segar (TBS) kelapa sawit dengan baik sesuai dengan kelas “masak”, “kurang masak”, “terlalu masak” dan “mentah” yang terlihat pada pengujian model terhadap citra dan video baru. Performa model dilihat dari nilai *mean Average Precision* (mAP) mencapai 98%, nilai precision mencapai 97% dan nilai recall mencapai 95%. Evaluasi model menunjukkan kurva f1-confidence mencapai 95% dan kurva precision-recall mencapai 98%. Performa model dipengaruhi oleh berbagai faktor seperti

kualitas *dataset*, variasi sudut pengambilan citra, kualitas citra, dan *video* yang digunakan. Pemanfaatan *dataset* dengan sudut pengambilan citra yang berbeda membuktikan bahwa nilai akurasi dapat meningkat dengan signifikan. Area pada citra juga memiliki peran yang sangat penting untuk menentukan akurasi ketika objek bertumpuk atau berpotong.

Untuk memperoleh performa model yang lebih baik, disarankan untuk menggunakan *video* dengan kualitas gambar yang lebih jelas, kualitas *dataset* yang baik dengan mencakup berbagai macam sudut pandang agar hasil deteksi tingkat kematangan TBS kelapa sawit mendapatkan performa yang lebih baik dan optimal. Penelitian lebih lanjut dapat mempertimbangkan pengumpulan data tambahan yang mencakup variasi kondisi lingkungan dan varietas kelapa sawit yang lebih luas. Optimalisasi proses *preprocessing* seperti anotasi dan augmentasi data juga dapat membantu dalam meningkatkan kualitas dan konsistensi *Dataset*.

DAFTAR PUSTAKA

Agustina, F. (2022). Deteksi Kematangan Buah Pepaya Menggunakan Algoritma YOLO Berbasis

- Android. *Jurnal Ilmiah Infokam*, 18(2), 70–78. <https://doi.org/10.53845/infokam.v18i2.320>
- Aras, S., Tanra, P., & Bazhar, M. (2024). Deteksi Tingkat Kematangan Buah Tomat Menggunakan YOLOv5. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(2), 623–628. <https://doi.org/10.57152/malcom.v4i2.1270>
- Ayyiyah, N. K., Kusumaningrum, R., & Rismiyati, R. (2023). Film Recommender System Menggunakan Metode Neural Collaborative Filtering. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 10(3), 699–708. <https://doi.org/10.25126/jtiik.20231036616>
- Badan Pusat Statistik. (2024). *Produksi Tanaman Perkebunan (Ribu Ton), 2023*. Produksi Tanaman Perkebunan.
- Dompeipen, T. A., & Sompie, S. R. U. (2020). Penerapan computer vision untuk pendeteksian dan penghitung jumlah manusia. *Jurnal Teknik Informatika*, 15(4), 1–12.
- Himmah, E. F., Widyaningsih, M., & Maysaroh, M. (2020). Identifikasi Kematangan Buah Kelapa Sawit Berdasarkan Warna RGB Dan HSV Menggunakan Metode K-Means Clustering. *Jurnal Sains Dan Informatika*, 6(2), 193–202. <https://doi.org/10.34128/jsi.v6i2.242>
- Kohsasih, K. L., & Situmorang, Z. (2022). Comparative Analysis of C4.5 and Naïve Bayes Algorithms in Predicting Cerebrovascular Disease. *Jurnal Informatika*, 9(1), 13–17.
- Maulida, P., Muryani, M., & Faristiana, A. R. (2023). Dampak Perkembangan Teknologi Pertanian Terhadap Perubahan. *Student Scientific Creativity Journal (SSCJ)*, 1(4), 349–365. <https://doi.org/10.55606/sscj-amik.v1i4.1650>
- Nugraha, Y. P. P., & Wibowo, E. P. (2024). Deteksi Cacat pada Sekrup Berbasis Citra Menggunakan YOLOv5. *Jurnal Ilmiah Komputasi*, 23(1), 59–66. <https://doi.org/10.32409/jikstik.23.1.3516>
- Pawidya, N. P., & Salam, A. (2024). Pengembangan Sistem Deployment Deteksi untuk Kista Ginjal pada Citra CT Scan dengan Metode Yolo. 9(1), 396–407.
- Rifqi, M., & Suharjito. (2021). Deteksi Kematangan Tandan Buah Segar (Tbs) Kelapa Sawit Berdasarkan Komposisi Warna Menggunakan Deep Learning. *Jurnal Teknik Informatika*, 6(1), 125–134.
- Romadloni, P., Adhi Kusuma, B., & Maulana Baihaqi, W. (2022). Komparasi Metode Pembelajaran Mesin Untuk Implementasi Pengambilan Keputusan Dalam Menentukan Promosi Jabatan Karyawan. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 6(2), 622–628. <https://doi.org/10.36040/jati.v6i2.5238>
- Rosmegawati, R. (2021). Peran Aspek Tehnologi Pertanian Kelapa Sawit Untuk Meningkatkan Produktivitas Produksi Kelapa Sawit. *Jurnal Agrisia*, 13(2), 74–80.
- Saragih, H., & Rahayu, H. (2022). Pengaruh kebijakan Uni Eropa terhadap ekspor kelapa sawit Indonesia. *JPPi (Jurnal Penelitian Pendidikan Indonesia)*, 8(2), 296–303. <https://doi.org/10.29210/020221377>
- Sari, W. E., Muslimin, M., Franz, A., & Sugiartawan, P. (2022). Deteksi

Tingkat Kematangan Tandan Buah Segar Kelapa Sawit dengan Algoritme K-Means. *SINTECH (Science and Information Technology) Journal*, 5(2), 154–164. <https://doi.org/10.31598/sintechjournal.v5i2.1146>

Yuliyanto, S., Nurinda Fadhilah Amani, Fityanul Akhyar, & Koredianto

Usman. (2022). Sistem Inspeksi Permukaan Baja Berbasis Deep Learning Menggunakan Metode Anchor-Free. *Jurnal Ilmiah Teknik Mesin, Elektro Dan Komputer*, 2(3), 184–190. <https://doi.org/10.51903/juritek.v2i3.364>