

Evaluasi Kinerja Model YOLOv8 dalam Deteksi Kesegaran Buah

Arie Ardiansyah^{*1}, Joko Triloka², Indera³

^{1,2}Magister Teknik Informatika, Institut Informatika dan Bisnis Darmajaya, Bandar Lampung

³Sistem Informasi, Institut Informatika dan Bisnis Darmajaya, Bandar Lampung

e-mail: ^{*}arie.ardiansyah.2321211044p@mail.darmajaya.ac.id, ²joko.triloka@darmajaya.ac.id, ³indera@darmajaya.ac.id

Abstrak

Klasifikasi kesegaran buah memiliki implikasi yang signifikan dalam industri pangan dan pertanian di Indonesia, karena mempengaruhi kualitas produk yang dijual, keamanan kesehatan konsumen dan mengurangi pemborosan pangan. Berdasarkan hal tersebut telah banyak teknologi pengolahan citra seperti ResNet, DenseNet, MobileNetV2, NASNet, dan EfficientNet, CNN, DCNN, dll untuk membantu industri melakukan klasifikasi deteksi kesegaran buah secara realtime dan efisien, oleh karena itu penelitian ini dimaksud untuk mengeksplorasi algoritma lain yaitu YOLOv8 untuk mengevaluasi kinerja akurasi dan presisi dalam deteksi kesegaran buah. Pada penelitian ini didapatkan hasil bahwa model YOLOv8 dengan 100 epoch dan batch size 8 memberikan hasil confusion matrix dengan akurasi 88%. Pada tingkat kepercayaan tinggi, model mampu mendeteksi kesegaran buah dengan presisi rata-rata 97%. Namun, pada tingkat kepercayaan rendah, recall rata-rata mencapai 87%. Pada tingkat kepercayaan seimbang (0.50), presisi dan recall F1-Score mencapai rata-rata 73%. Evaluasi di luar tingkat kepercayaan menunjukkan presisi 74% dan recall 75%. Hasil ini menunjukkan bahwa Model YOLOv8 dengan epoch dan batch rendah masih dapat bersaing dengan algoritma lainnya, pelatihan dengan epoch dan batch yang lebih tinggi memiliki kesempatan untuk mendapatkan model yang lebih optimal.

Kata kunci—Pengolahan Citra, Deteksi Kesegaran Buah, Kinerja Akurasi

Abstract

The classification of fruit freshness has significant implications in the food and agricultural industry in Indonesia, as it affects the quality of products sold, consumer health safety, and reduces food waste. Based on this, many image processing technologies such as ResNet, DenseNet, MobileNetV2, NASNet, and EfficientNet, CNN, DCNN, etc., have been used to help the industry perform real-time and efficient fruit freshness classification. Therefore, this research aims to explore another algorithm, YOLOv8, to evaluate its accuracy and precision in detecting fruit freshness. This study found that the YOLOv8 model with 100 epochs and a batch size of 8 produced a confusion matrix with an accuracy of 88%. At high confidence levels, the model was able to detect fruit freshness with an average precision of 97%. However, at low confidence levels, the average recall reached 87%. At a balanced confidence level (0.50), the precision and recall F1-Score averaged 73%. Evaluation outside the confidence level showed a precision of 74% and a recall of 75%. These results indicate that the YOLOv8 model with low epochs and batch size can still compete with other algorithms, and training with higher epochs and batch size has the potential to yield a more optimal model.

Keywords— Image Processing, Fruit Freshness Detection, Accuracy Performance

1. PENDAHULUAN

Kualitas buah-buahan sangat penting dalam industri pertanian dan makanan [1], karena menentukan nilai jual [2], ketersediaan nutrisi [3], dan kepuasan konsumen [4]. Salah satu aspek penting dari kualitas buah adalah tingkat kesegarannya [5]. Kesegaran buah-buahan tidak hanya memengaruhi rasa [6] dan tekstur [7], tetapi juga menunjukkan kondisi kesehatan buah tersebut [8]. Oleh karena itu, deteksi kesegaran buah secara cepat dan akurat menjadi sangat penting dalam rantai pasok makanan [9].

Indonesia sendiri merupakan salah satu negara pemasok buah-buahan terbesar di Dunia, berdasarkan data yang dirilis oleh Badan Pusat Statistik, Indonesia mencatat produksi buah hampir mencapai 26 juta ton sepanjang tahun 2021, dengan angka tepatnya berada di 25.975.608 ton. Buah-buahan yang dihasilkan oleh Indonesia tidak hanya untuk kebutuhan lokal, melainkan juga menjadi komoditas ekspor yang memberikan kontribusi besar terhadap perekonomian negara. Sebagai contoh, produksi buah pisang mendominasi total produksi sepanjang tahun 2021 dengan mencapai 8.741.147 ton. Selain pisang, nanas dan mangga juga menjadi komoditas buah yang mendominasi produksi buah Indonesia, masing-masing dengan total produksi mencapai 2.886.417 dan 2.835.442 ton. Provinsi Jawa Timur memuncaki daftar provinsi dengan produksi buah tertinggi sepanjang tahun 2021, mencapai total produksi sekitar 6.513.030 ton. Di posisi kedua terdapat Jawa Barat dengan total produksi sekitar 3.236.582 ton, dan di posisi ketiga adalah Provinsi Jawa Tengah dengan total produksi mencapai 3.101.741 ton buah pada tahun 2021 [10].

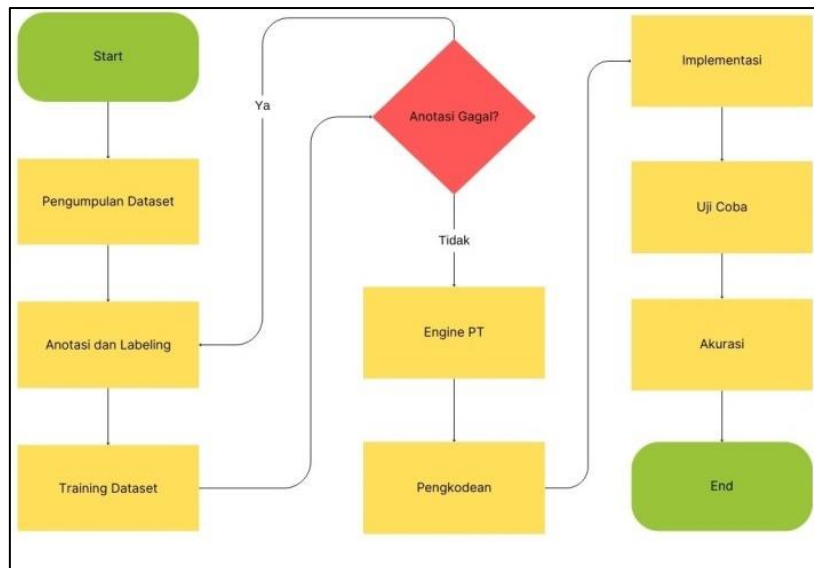
Berdasarkan statistik tersebut tentunya kesegaran dari buah yang dihasilkan adalah hal yang harus diperhatikan untuk menjaga kualitas sehingga aman dikonsumsi oleh masyarakat pada umumnya. Untuk membantu para pelaku industri buah dalam melakukan assessment terhadap kualitas yang buah yang diproduksi, banyak penelitian dibidang *deep learning* untuk membantu petani dan industri untuk mendeteksi kesegaran buah secara *realtime*, seperti pada tahun 2022 Nazrul Ismail *et al* membandingkan algoritma ResNet, DenseNet, MobileNetV2, NASNet, dan EfficientNet untuk menemukan model terbaik dalam menentukan tingkat kesegaran buah-buahan, dengan hasil penelitian menunjukkan bahwa model EfficientNet memberikan akurasi rata-rata sebesar 95,2 % [11]. Zarnaq *et al* dalam penelitiannya menggunakan klasifikasi *Multilayer Perceptron* (MLP) dengan metode seleksi fitur Linear Discriminant Analysis (LDA) dan mendapatkan akurasi rata-rata sebesar 97,2% [12]. Pada tahun 2023 Amin *et al* menggunakan arsitektur Alexnet pada algoritma Deep Convolutional Neural Network (DCNN) untuk mengidentifikasi kesegaran buah dengan akurasi sebesar 99.1% [13]. Ren S *et al* pada tahun 2023 menggunakan YOLOv5 untuk mendeteksi kesegaran buah nanas menghasilkan pengujian sebesar 94.5% [14].

Kemudian pada tahun 2024 Sharafudeen M *et al* menggunakan YOLOv7 untuk mendeteksi kesegaran buah dan mencapai akurasi 95.90% [15]. Dengan demikian penggunaan *deep learning* sangatlah potensial untuk dieksplorasi lebih lanjut untuk menguji algoritma lainnya untuk deteksi kesegaran buah. Dalam penelitian ini YOLOv8 akan digunakan untuk menguji seberapa baik algoritma ini digunakan untuk mendeteksi kesegaran buah, sehingga akan memberikan kontribusi dan gambaran baru, bagaimana akurasi, presisi dan *recall* ketika menggunakan model YOLOv8 dalam mendeteksi kesegaran buah, sehingga bisa menjadi pertimbangan bagi industry terkait dalam memilih teknologi kecerdasan buatan dalam mendeteksi kesegaran buah.

2. METODE PENELITIAN

2.1 Alur penelitian

Penelitian ini bertujuan untuk mengevaluasi presisi dan akurasi model YOLOv8 dengan 100 *epoch* dan 8 *batch*. Sehingga kita akan mendapatkan gambaran yang lebih jelas performa pada model YOLOv8 yang dilatih dengan parameter tersebut. Adapun alur penelitian diilustrasikan pada gambar 1.



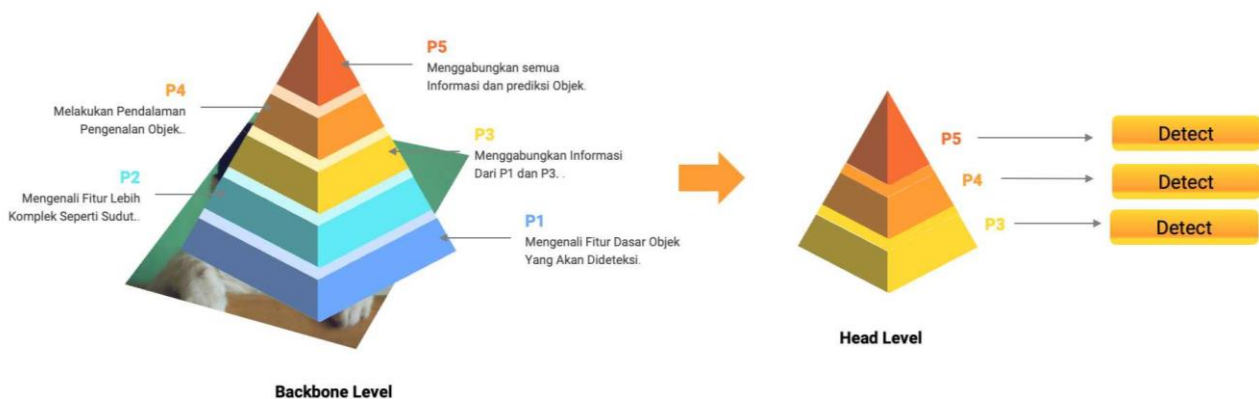
Gambar 1. Metode Pengembangan Penelitian

Pada gambar 1 dapat dijelaskan sebagai berikut:

1. Tahap pertama dalam penelitian ini adalah pengumpulan dataset jenis buah yang segar dan tidak segar. Dalam penelitian ini, kami hanya mengambil sampel Apel, Pisang, Mangga, Melon, Jeruk, Persik dan Pir.
2. Pada tahap kedua kami melakukan anotasi dan labelisasi gambar untuk memberikan objek koordinat terhadap jenis-jenis kesegaran buah dengan kelas segar, tidak segar dan semi segar.
3. Pada tahap ketiga kami melakukan pelatihan *dataset* dengan menggunakan *library ultralytics* untuk mendapatkan bobot *convolutional network* dalam format PT.
4. Selanjutnya di tahap kelima Bobot PT yang telah didapat akan dibaca dan kode python yang telah disusun, dan digunakan untuk melakukan deteksi kesegaran buah.
5. Pada tahap keenam, hasil dari deteksi akan kami evaluasi dengan *F1-Score* untuk melihat akurasi deteksi yang dihasilkan.

2.2 Algoritma YOLO

YOLOv8 adalah iterasi terbaru dalam seri keluarga detektor objek YOLO yang memiliki tingkat akurasi dan kecepatan diatas YOLO seri sebelumnya, sehingga menjadi pilihan yang paling baik untuk tugas deteksi kesegaran buah. Adapun ilustrasi arsitektur YOLOv8 dijabarkan pada gambar 1.




Gambar 2. Arsitektur YOLOv8

Pada gambar 2 dapat dijelaskan bahwa YOLOv8 memiliki 2 arsitektur jaringan yaitu *backbone* dan *head*. *Backbone* adalah bagian dari jaringan saraf konvolusi (CNN) yang bertanggung jawab untuk mengekstraksi fitur-fitur dari data masukan seperti gambar, video atau stream dari kamera. Pada Lapisan *backbone*, terdapat lima tingkatan yang merupakan tahapan metode pendeteksian.

1. Tingkatan P1 digunakan untuk mengenali fitur-fitur dasar dari objek, seperti garis, bentuk, warna dan elemen lainnya pada objek.
2. Tingkatan P2 digunakan untuk mengenali fitur yang lebih kompleks dari objek seperti sudut gambar.
3. Tingkatan P3 digunakan untuk menggabungkan informasi yang telah dikumpulkan oleh P1 dan P2 untuk diproses lebih lanjut.
4. Tingkatan P4 digunakan untuk melakukan pendalaman pengenalan objek yang sudah dikumpulkan level P1 dan P2.
5. Tingkatan P5 digunakan untuk menggabungkan semua informasi dan prediksi objek. Yang selanjutnya digunakan sebagai landasan untuk deteksi.

Selanjutnya pada tingkatan *head*, semua informasi yang telah diproses oleh *backbone* akan diproses untuk melakukan prediksi objek dengan membuat *bounding box*, *confidence score* dan mengeliminasi objek-objek lain dengan skor dibawah *threshold* yang telah diatur. Secara umum, YOLOv8 bekerja dengan metode yang ditunjukkan pada gambar 3, dimana ada 4 alir yang akan dilalui.



Gambar 3. Metode YOLOv8

1. Pada tahap awal, YOLO akan membagi gambar menjadi sel-sel (*grid cells*), dengan setiap sel bertugas untuk memprediksi objek yang terdapat di dalamnya. [16].
2. Selanjutnya, setiap sel akan membuat prediksi terhadap beberapa bounding box beserta skor kepercayaannya (*confidence score*) [17]. *Bounding box* ini menggambarkan koordinat objek

yang dideteksi dalam gambar, dengan menghubungkan koordinat objek yang sebenarnya dengan koordinat yang terdapat dalam dataset [18]. Untuk membuat bounding box, maka akan digunakan rumus (1)

$$(x, y) = \left(\frac{1}{1+e^{-tx}}, \frac{1}{1+e^{-ty}} \right) \quad (1)$$

(x, y) merupakan koordinat pusat dari bounding box objek. Sedangkan (tx, ty) merupakan koordinat pusat dari bounding box objek yang dihitung menggunakan fungsi sigmoid sebagaimana yang dijelaskan dalam rumus (1).

Kemudian, untuk menentukan ukuran bounding box, akan digunakan rumus (2).

$$(w, h) = (pw \cdot e^{tw}, ph \cdot e^{th}) \quad (2)$$

dimana pw dan ph merepresentasikan dimensi anchor box yang dipilih, sedangkan tw dan th adalah output dari jaringan saraf untuk dimensi kotak pembatas objek.

Lalu untuk menghitung *confidence score* maka akan menggunakan rumus (3).

$$P(\text{Objek}) = \sigma(t_{obj}) \quad (3)$$

Dimana t_{obj} adalah *output* dari jaringan saraf yang menunjukkan probabilitas keberadaan objek.

3. Selanjutnya, pada langkah terakhir, YOLO menggunakan teknik *Non-Maximum Suppression* (NMS) untuk menghilangkan *bounding box* yang memiliki skor kepercayaan rendah, sehingga hanya *bounding box* dengan skor kepercayaan tinggi yang dipertahankan. [19].
4. Terakhir, model menghasilkan output berupa *bounding box* yang mencakup prediksi objek beserta skornya. Setiap *bounding box* juga mencantumkan label kelas objek dan tingkat kepercayaan model terhadap prediksi tersebut. [20].

2.3 Parameter Dataset dan Pelatihan

Keterbatasan *hardware* menjadi perhatian dalam pemilihan parameter dalam melatih model YOLOv8 untuk mendeteksi kesegaran buah. Pada penelitian ini kami menggunakan *google colab pro* dengan GPU Nvidia L2 dengan 24Gb Vram untuk melatih 5215 gambar dataset yang bersumber dari Jawaharlal Nehru University [21]. *Dataset* tersebut dibagi kedalam 83% untuk training data, 11% untuk validasi data, dan 6% untuk testing data dengan rincian seperti yang dijabarkan pada tabel 1.

Tabel 1. Penjabaran Dataset

No	Jenis Buah	Class	Jumlah
1	Apel	<i>Apple</i>	221
		<i>Apple Rotten</i>	183
		<i>Apple Semifresh</i>	63
		<i>Apple Semirotten</i>	158
2	Pisang	<i>Banana</i>	57
		<i>Banana Rotten</i>	173
		<i>Banana Semifresh</i>	533

No	Jenis Buah	Class	Jumlah
		<i>Banana Semirotten</i>	83
3	Mangga	<i>Mango</i>	37
		<i>Mango Rotten</i>	127
		<i>Mango Semifresh</i>	64
		<i>Mango Semirotten</i>	112
4	Melon	<i>Melon</i>	47
		<i>Melon Rotten</i>	12
		<i>Melon Semifresh</i>	21
		<i>Melon Semirotten</i>	18
5	Orange	<i>Orange</i>	81
		<i>Orange Rotten</i>	103
		<i>Orange Semifresh</i>	62
		<i>Orange Semirotten</i>	47
6	Pir	<i>Pear</i>	31
		<i>Pear Rotten</i>	95
		<i>Pear Semifresh</i>	46
		<i>Pear Semirotten</i>	21
7	<i>Peach</i>	<i>Peach</i>	83
		<i>Peach Rotten</i>	72
		<i>Peach Semifresh</i>	152
		<i>Peach Semirotten</i>	47
<i>Preprocessing</i>		<i>Orient: Applied</i> <i>Resize: Stretch to 640x640</i>	
<i>Augmentations</i>		<i>Outputs per training example: 3</i> <i>Flip: Horizontal, Vertical</i>	

Pada tabel 1. *Orient* merujuk pada fitur untuk menyesuaikan orientasi gambar dalam dataset, sehingga semua gambar dalam dataset memiliki orientasi yang konsisten dan sesuai dengan kebutuhan model yang akan dilatih. Selain itu ukuran gambar dataset juga dibuat dengan ukuran 640x640 px. Selanjutnya pada augmentasi, kami menambahkan variasi gambar dengan merotasinya secara horizontal dan vertikal, masing-masing gambar akan di augmentasi 3x. Selanjutnya kami menggunakan 100 *epoch* pelatihan dengan 8 *batch*. *Epoch* mengacu pada jumlah siklus melalui seluruh dataset pelatihan yang akan dilakukan selama proses pelatihan [22]. Sedangkan *batch* mengacu pada jumlah sampel data yang dimasukkan ke dalam model pada satu waktu untuk setiap iterasi pelatihan [23].

2.4 Presisi, Recall dan F1-Score

Untuk menghitung presisi, *recall* dan *F1-score* pada model YOLOv8 yang dikembangkan untuk mendeteksi kesegaran buah. Maka kami menggunakan rumus (4) untuk menghitung presisi, rumus (5) untuk menghitung *recall*, dan rumus (6) hasil *F1-score*.

1. Rumus Presisi (*precision*) untuk mengukur seberapa banyak dari prediksi positif yang benar [24] adalah sebagai berikut:

$$\text{presisi} = \frac{\text{true positive}}{\text{true positive} + \text{false positive}} \quad (4)$$

2. Rumus *recall* untuk mengukur seberapa banyak dari keseluruhan data positif yang berhasil ditemukan oleh model [25] adalah sebagai berikut:

$$recall = \frac{true\ positive}{true\ positive + false\ positive} \quad (5)$$

3. Terakhir untuk mendapatkan *f1-score* kami menggunakan formula (6) sebagai berikut:

$$F1\ Score = 2 \frac{presisi * recall}{presisi + recall} \quad (6)$$

4. HASIL DAN PEMBAHASAN

4.1 Hasil Deteksi


Pada gambar 4 ditampilkan hasil deteksi dengan *confidence score* antara 0.4 – 1.0 dalam mendeteksi kesegaran buah. Hal ini menunjukkan bahwa model mampu untuk mendeteksi kesegaran buah secara baik.



Gambar 4. Hasil Deteksi

4.2 Confusion Matrix

Pada sesi ini kami mengevaluasi kinerja model YOLOv8 yang telah dihasilkan dengan beberapa pengujian. Pada tahap pertama, kami menggunakan *Confusion Matrix Normalized* untuk mengetahui seberapa baik model dalam membedakan antara buah-buah segar dan buah-buah busuk [26]. Hasil pengujian disajikan pada gambar 5 dibawah ini.



Gambar 5. Confusion Matrix Normalized


Berdasarkan hasil grafik pada gambar 4, dapat terlihat bahwa model YOLOv8 mampu mencapai tingkat akurasi yang tinggi dalam mendeteksi kesegaran buah, dengan nilai rata-rata akurasi sekitar 0.88 hingga 0.92 untuk setiap kelas buah yang diuji. Ini menunjukkan bahwa model dapat dengan efektif membedakan antara buah segar, semi busuk, dan busuk dalam berbagai kondisi dan variasi, seperti yang dijabarkan pada tabel 2.

Tabel 2. Hasil Evaluasi dengan Confusion Matrix Normalized

Buah	Fresh (Benar)	Semirotten (Benar)	Rotten (Benar)	Fresh (Salah)	Semirotten (Salah)	Rotten (Salah)	Akurasi Rata-rata
Apple	0.90	0.05	0.05	0.02	0.01	0.02	0.90
Banana	0.88	0.09	0.03	0.01	0.03	0.01	0.88
Mango	0.89	0.07	0.04	0.03	0.02	0.03	0.89
Melon	0.85	0.10	0.05	0.02	0.02	0.03	0.85
Orange	0.92	0.04	0.04	0.01	0.01	0.02	0.92
Pear	0.87	0.08	0.05	0.02	0.02	0.03	0.87
Peach	0.88	0.09	0.03	0.01	0.02	0.01	0.88


4.3 Presisi, Recall dan F1-Score Berdasarkan Tingkat Kepercayaan

Pada evaluasi pertama model YOLOv8 yang telah dilatih memiliki presisi sebesar 97% saat mencapai tingkat kepercayaan 100%. Hal ini menunjukkan pada tingkat kepercayaan yang tinggi, model memiliki tingkat akurasi yang optimal dalam mengidentifikasi dan mengklasifikasikan objek dalam semua kelas.




Gambar 6. Precision-Confidence Curve

Kemudian dalam tingkat kepercayaan yang paling rendah atau di 0%, model YOLOv8 memiliki *recall* atau sensitifitas deteksi sebesar 87%. Hal ini menunjukkan bahwa meskipun model memiliki tingkat keyakinan yang sangat rendah terhadap prediksinya, ia masih mampu mengidentifikasi dan mengenali kembali objek dalam semua kelas dengan akurat.



Gambar 7. Recall-Confidence Curve

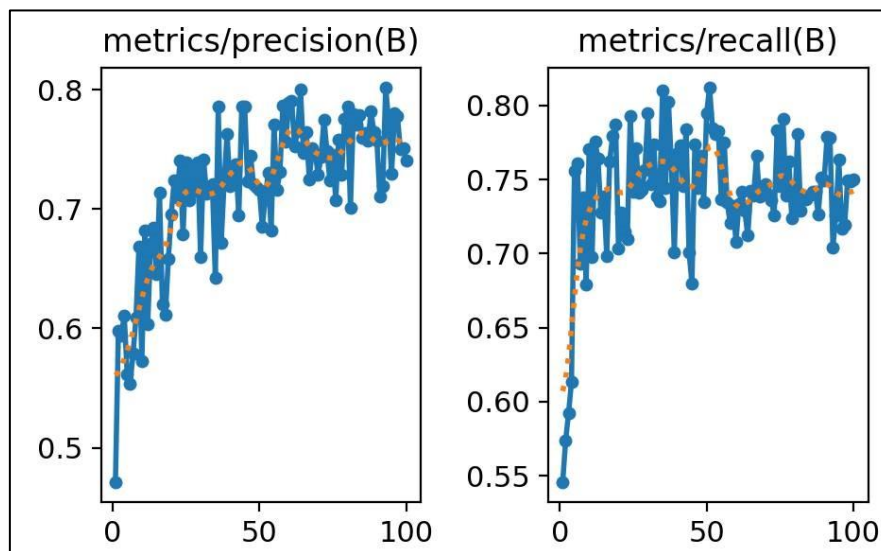
Grafik dari hasil evaluasi F1-Score pada grafik di gambar 5 menunjukkan bahwa presisi model adalah sebesar 0.73 atau 73% dengan ambang batas *threshold* diatas 50%. Hasil ini menunjukkan bahwa model memiliki keseimbangan yang cukup baik antara presisi dan *recall* pada tingkat kepercayaan diatas 50%.



Gambar 8. Hasil F1 Score

4.4 Metric Recall and Precision

Evaluasi terakhir adalah dengan menghitung *metrics precision* untuk mengukur tingkat keakuratan dari prediksi positif yang dibuat oleh model deteksi objek. Semakin tinggi nilai presisi, semakin sedikit objek negatif yang salah diprediksi sebagai positif [27]. Sedangkan *metrics recall* untuk mengukur proporsi dari semua objek positif yang benar-benar diprediksi sebagai positif oleh model. Semakin tinggi nilai *recall*, semakin sedikit objek positif yang terlewatkan atau tidak terdeteksi oleh model [28]. Hasil dari evaluasi terhadap *metric recall* dan *precision* disajikan pada grafik di gambar 8.

Gambar 9. Grafik metrik presisi dan *recall*

Dari grafik pada gambar 9 dapat disimpulkan bahwa model YOLOv8 untuk mendeteksi kesegeran buah memiliki presisi sebesar 74% dan memiliki *recall* sebesar 75% pada parameter *epoch* ke 100 dengan 8 *batch*.

4. KESIMPULAN

Berdasarkan hasil metrik evaluasi yang telah dilakukan maka dapat disimpulkan beberapa hal sebagai berikut:

1. Model YOLOv8 yang dilatih dengan 100 epoch dan batch ukuran 8 mampu mengklasifikasikan kesegaran buah (*fresh*, *semirotten*, *rotten*) dengan akurasi rata-rata 88%.
2. Evaluasi pada metrik umum menunjukkan presisi 74% dan recall 75% pada epoch ke-100. Sehingga Rata-rata presisi keseluruhan model dalam mendeteksi kesegaran buah adalah sekitar 73%.

5. SARAN

Model YOLOv8 yang dilatih dengan 100 *epoch*, 8 *batch* dan 5215 gambar memiliki tingkat akurasi sebesar 88%, ini menunjukkan dengan *epoch* yang terbatas model object YOLOv8 dapat masih bersaing dengan algoritma deteksi lainnya seperti gabungan ResNet, DenseNet, MobileNetV2, NASNet, dan EfficientNet yang memiliki akurasi sebesar 95,2 % [11]. Kemudian *Multilayer Perceptron* (MLP) dengan akurasi 97,2% [12], arsitektur Alexnet dengan akurasi 99.1% [13] dan YOLOv5 dengan akurasi sebesar 94.5% [14]. Oleh karena itu percobaan *epoch* dan *batch* yang lebih tinggi memiliki potensi menjadi penelitian selanjutnya, untuk dapat mengembangkan model YOLOv8 untuk deteksi buah dengan akurasi yang lebih tinggi.

DAFTAR PUSTAKA

- [1] J. Ni, J. Gao, L. Deng, and Z. Han, "Monitoring the Change Process of Banana Freshness by GoogLeNet," *IEEE Access*, vol. 8, pp. 228369–228376, Jan. 2020, doi: 10.1109/ACCESS.2020.3045394.
- [2] I. J. González-Hernández, R. Granillo-Macías, J. L. Martínez-Flores, D. Sánchez-Partida, and D. E. Gibaja-Romero, "Hybrid model to design an agro-food distribution network considering food quality," *International Journal of Industrial Engineering : Theory Applications and Practice*, vol. 26, no. 4, pp. 588–609, Jan. 2019.
- [3] V. L. Flax, C. Thakwalakwa, C. H. Schnefke, J. C. Phuka, and L. M. Jaacks, "Food purchasing decisions of Malawian mothers with young children in households experiencing the nutrition transition," *Appetite*, vol. 156, p. 104855, Jan. 2021, doi: 10.1016/j.appet.2020.104855.
- [4] V. Quick *et al.*, "Preserving farm freshness: Consumer preferences for local value-added products at urban farmers markets," *J Agric Food Syst Community Dev*, vol. 11, no. 2, pp. 113–134, doi: 10.5304/jafscd.2022.112.004.
- [5] H. N. J. Schifferstein, T. Wehrle, and C. C. Carbon, "Consumer expectations for vegetables with typical and atypical colors: The case of carrots," *Food Qual Prefer*, vol. 72, pp. 98–108, Mar. 2019, doi: 10.1016/j.foodqual.2018.10.002.
- [6] S. R. Jaeger, S. L. Chheang, C. M. Roigard, and M. B. Frøst, "Consumers' expectations and experiences of salad greens, herbs, and fruits from vertical farming: Comparison with organic produce," *Food Qual Prefer*, vol. 112, p. 105020, Dec. 2023, doi: 10.1016/j.foodqual.2023.105020.
- [7] X. Du, M. Davila, C. Williams, and Y. Weng, "Fresh Cucumber Fruit Physicochemical Properties, Consumer Acceptance, and Impact of Variety and Harvest Date," *ACS Food Science and Technology*, vol. 2, no. 4, pp. 616–629, Apr. 2022, doi: 10.1021/acscfoodscitech.1c00433.
- [8] H. Neetoo *et al.*, "A comparative assessment of the quality of minimally processed pineapples sold in wet markets and supermarkets of mauritius," *Current Research in Nutrition and Food Science*, vol. 7, no. 1, pp. 128–141, Apr. 2019, doi: 10.12944/CRNFSJ.7.1.13.
- [9] P. Choosung, T. Wasusri, W. Utto, P. Boonyariththongchai, and C. Wongs-Aree, "The supply chain and its development concept of fresh mulberry fruit in Thailand: Observations in Nan Province, the largest production area," *Open Agric*, vol. 7, no. 1, pp. 401–419, Jan. 2022, doi: 10.1515/opag-2022-0102.

-
- [10] “Produksi Tanaman Buah-buahan - Tabel Statistik - Badan Pusat Statistik Indonesia.” Accessed: Apr. 04, 2024. [Online]. Available: <https://www.bps.go.id/id/statistics-table/2/NjJjMg==/produksi-tanaman-buah-buahan.html>
- [11] N. Ismail and O. A. Malik, “Real-time visual inspection system for grading fruits using computer vision and deep learning techniques,” *Information Processing in Agriculture*, vol. 9, no. 1, pp. 24–37, Mar. 2022, doi: 10.1016/J.INPA.2021.01.005.
- [12] M. H. Zarnaq, M. Omid, M. S. Firouz, M. Jafarian, and P. Bazyar, “Freshness and quality assessment of parsley using image processing and artificial intelligence techniques,” *Agricultural Engineering International: CIGR Journal*, vol. 24, no. 2, pp. 282–290, Jun. 2022.
- [13] U. Amin, M. I. Shahzad, A. Shahzad, M. Shahzad, U. Khan, and Z. Mahmood, “Automatic Fruits Freshness Classification Using CNN and Transfer Learning,” *Applied Sciences 2023, Vol. 13, Page 8087*, vol. 13, no. 14, p. 8087, Jul. 2023, doi: 10.3390/APP13148087.
- [14] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” *IEEE Trans Pattern Anal Mach Intell*, vol. 39, no. 6, pp. 1137–1149, Jun. 2017, doi: 10.1109/TPAMI.2016.2577031.
- [15] M. Sharafudeen and V. Chandra S S, “Multimodal Siamese Framework for Accurate Grade and Measure Estimation of Tropical Fruits,” *IEEE Trans Industr Inform*, vol. 20, no. 3, pp. 4283–4291, Mar. 2024, doi: 10.1109/TII.2023.3316182.
- [16] D. Kholiya, A. K. Mishra, N. K. Pandey, and N. Tripathi, “Plant Detection and Counting using Yolo based Technique,” *2023 3rd Asian Conference on Innovation in Technology, ASIANCON 2023*, p. Ravet, doi: 10.1109/ASIANCON58793.2023.10270530.
- [17] Sandhya and A. Kashyap, “A novel method for real-time object-based copy-move tampering localization in videos using fine-tuned YOLO V8,” *Forensic Science International: Digital Investigation*, vol. 48, p. 301663, Mar. 2024, doi: 10.1016/j.fsidi.2023.301663.
- [18] Y. Tang, H. Zhou, H. Wang, and Y. Zhang, “Fruit detection and positioning technology for a Camellia oleifera C. Abel orchard based on improved YOLOv4-tiny model and binocular stereo vision,” *Expert Syst Appl*, vol. 211, p. 118573, Jan. 2023, doi: 10.1016/j.eswa.2022.118573.
- [19] Z. Sun, P. Li, Q. Meng, Y. Sun, and Y. Bi, “An Improved YOLOv5 Method to Detect Tailings Ponds from High-Resolution Remote Sensing Images,” *Remote Sens (Basel)*, vol. 15, no. 7, p. 1796, Apr. 2023, doi: 10.3390/rs15071796.
- [20] Z. Dahirou and M. Zheng, “Motion Detection and Object Detection: Yolo (You only Look Once),” *Proceedings - 2021 7th Annual International Conference on Network and Information Systems for Computers, ICNISC 2021*, pp. 250–257, 2021, doi: 10.1109/ICNISC54316.2021.00053.
- [21] J. N. University, “Fruits Detection and Quality Analysis Dataset,” *Roboflow Universe*. Roboflow, Aug. 2023. [Online]. Available: <https://universe.roboflow.com/jawaharlal-nehru-university-tour/fruits-detection-and-quality-analysis>
- [22] V. K. Kavyapriya *et al.*, “CNN Based Identification of weeds in Tomato Farm,” *2023 14th International Conference on Computing Communication and Networking Technologies, ICCCNT 2023*, p. Delhi, doi: 10.1109/ICCCNT56998.2023.10307829.
- [23] N. F. Alhussainan, B. Ben Youssef, and M. M. Ben Ismail, “A Deep Learning Approach for Brain Tumor Firmness Detection Based on Five Different YOLO Versions: YOLOv3–YOLOv7,” *Computation*, vol. 12, no. 3, p. 44, Mar. 2024, doi: 10.3390/computation12030044.
- [24] Md. Akkas Ali, R. Kumar Dhanaraj, and S. Kadry, “AI-enabled IoT-based pest prevention and controlling system using sound analytics in large agricultural field,” *Comput Electron Agric*, vol. 220, p. 108844, May 2024, doi: 10.1016/j.compag.2024.108844.
- [25] M. A. Ali, A. K. Sharma, and R. K. Dhanaraj, “Heterogeneous features and deep learning networks fusion-based pest detection, prevention and controlling system using IoT and pest sound analytics in a vast agriculture system,” *Computers and Electrical Engineering*, vol. 116, p. 109146, May 2024, doi: 10.1016/j.compeleceng.2024.109146.
- [26] B.-G. M., H. A., P.-M. S., A.-C. R., M.-R. F., and P. G., “Performance evaluation of three versions of a convolutional neural network for object detection and segmentation using a multiclass and reduced panoramic radiograph dataset,” *J Dent*, vol. 144, p. 104891, May 2024, doi: 10.1016/j.jdent.2024.104891.
- [27] D. Sukumarran *et al.*, “An optimised YOLOv4 deep learning model for efficient malarial cell detection in thin blood smear images,” *Parasit Vectors*, vol. 17, no. 1, p. 188, Dec. 2024, doi: 10.1186/s13071-024-06215-7.
- [28] A. Smith *et al.*, “Computer vision model for the detection of canine pododermatitis and neoplasia of the paw,” *Vet Dermatol*, vol. 35, no. 2, pp. 138–147, Apr. 2024, doi: 10.1111/vde.13221.