

# Evaluasi Kinerja YOLOv8 dalam Identifikasi Kesegaran Ikan dengan Metode Deteksi Objek

1<sup>st</sup> Muhammad Dafa Maulana  
Fakultas Teknik Elektro  
Universitas Telkom

Bandung, Indonesia  
muhammaddafamaulana@student.telkomuniversity.ac.id

2<sup>nd</sup> Ledy Novamizanti  
Fakultas Teknik Elektro  
Universitas Telkom

Bandung, Indonesia  
ledyaldn@telkomuniversity.ac.id

3<sup>rd</sup> Suryo Adhi Wibowo  
Fakultas Teknik Elektro  
Universitas Telkom

Bandung, Indonesia  
suryoadhiwibowo@telkomuniversity.ac.id

**Abstrak** — Identifikasi kesegaran ikan merupakan aspek penting dalam industri perikanan karena mempengaruhi kualitas dan nilai jual produk akhir. Teknologi deteksi objek menawarkan solusi modern untuk mengotomatisasi proses ini, menggantikan metode manual yang seringkali memakan waktu dan kurang akurat. Dalam penelitian ini, dilakukan evaluasi kinerja YOLOv8, yaitu sebuah model deteksi objek untuk mengidentifikasi kesegaran ikan. *Dataset* yang digunakan dalam penelitian ini mencakup citra ikan cakalang yang diperoleh dari Perusahaan Aruna dan sumber-sumber tambahan. Data dianotasi dan diproses menggunakan platform Roboflow yang memfasilitasi pra-pemrosesan dan augmentasi data. Model YOLOv8 kemudian dilatih dan dievaluasi di lingkungan Google Colab dengan fokus pada akurasi, kecepatan, dan keandalannya dalam mendeteksi perbedaan antara ikan segar dan tidak segar. Hasilnya menunjukkan bahwa YOLOv8 mampu mencapai nilai mAP (*mean Average Precision*) lebih dari 87%, yang menunjukkan bahwa model memiliki efisiensi dan keakuratan dalam melakukan identifikasi kesegaran ikan. Kesimpulannya, YOLOv8 berpotensi untuk diadopsi secara luas dalam industri perikanan sebagai alat untuk meningkatkan efisiensi dan memastikan kualitas produk perikanan yang lebih baik.

**Kata kunci**— deteksi objek, YOLOv8, kesegaran ikan, industri perikanan, *mean Average Precision (mAP)*.

## I. PENDAHULUAN

Identifikasi kesegaran ikan merupakan aspek penting dalam industri perikanan dan rantai pasokannya. Kesegaran ikan sangat mempengaruhi kualitas produk akhir dan kepuasan konsumen. Proses penanganan ikan terdiri dari beberapa tahap yang mencakup penangkapan ikan, sortasi, pencucian, penirisan, dan penyimpanan ikan [1]. Sortasi merupakan tahapan yang perlu dilakukan untuk menjaga kualitas ikan segar dari kontaminasi ikan yang tidak segar [2]. Teknologi deteksi objek dapat menjadi alat penting untuk meningkatkan efisiensi dan akurasi dalam identifikasi kualitas suatu produk [3]. Teknologi deteksi objek seperti YOLO (*You Only Look Once*) telah digunakan secara luas dalam berbagai aplikasi untuk mendeteksi dan mengklasifikasikan objek dalam gambar dan video. Teknologi ini menawarkan solusi yang cepat dan akurat untuk mengidentifikasi kesegaran ikan.

YOLOv8 (*You Only Look Once version 8*) merupakan perkembangan dari rangkaian algoritma YOLO yang telah digunakan secara luas dalam berbagai aplikasi deteksi objek.

Algoritma ini dikenal karena memiliki kecepatan dan akurasi dalam mendeteksi berbagai objek dalam gambar. Penggunaan YOLOv8 dalam industri perikanan memerlukan evaluasi lebih lanjut untuk memastikan keefektifannya karena teknologi ini berpotensi menggantikan metode manual yang sering kali memakan waktu dan kurang akurat.

Penelitian ini bertujuan untuk mengevaluasi kinerja YOLOv8 dalam identifikasi kesegaran ikan dengan metode deteksi objek. Penelitian ini akan mengukur akurasi, kecepatan, dan keandalan YOLOv8 dalam mendeteksi perbedaan antara ikan segar dan tidak segar. Sistem ini dikatakan baik jika mendapatkan nilai mAP (*mean Average Precision*) yang lebih dari 87% [4]. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi dalam meningkatkan kualitas dan efisiensi proses identifikasi kesegaran ikan dalam industri perikanan. Dengan demikian, penelitian ini akan memberikan wawasan baru mengenai penerapan teknologi deteksi objek dalam industri perikanan dan potensi penggunaan YOLOv8 sebagai alat yang efektif untuk memastikan kualitas produk perikanan yang lebih baik.

## II. KAJIAN TEORI

Pada bagian ini dibahas teori yang berkaitan dengan variabel-variabel penelitian termasuk YOLOv8, deteksi objek, Roboflow, Google Colab, Python, dan kesegaran ikan.

### A. YOLOv8

YOLO adalah salah satu metode deteksi objek yang populer dalam bidang visi komputer. YOLOv8 adalah pengembangan metode YOLO dengan algoritma CNN (*Convolutional Neural Network*) [5]. YOLOv8 memiliki kinerja yang lebih baik dalam hal akurasi dan kecepatan dalam proses deteksi objek dibandingkan dengan versi YOLO yang sebelumnya [6]. YOLOv8 bekerja dengan membagi gambar input menjadi *grid* kemudian membuat prediksi *bounding box* dan kelas untuk setiap *grid cell*. Model ini memiliki deteksi multi skala yang memungkinkan sistem lebih baik mengenali gambar dengan *size* yang berbeda [7].

### B. Deteksi Objek

Deteksi objek merupakan salah satu bidang utama dalam visi komputer yang bertujuan untuk mengidentifikasi dan menentukan lokasi objek dalam gambar atau video [8]. Algoritma seperti YOLO, SSD (*Single Shot MultiBox Detector*), dan Faster R-CNN telah menjadi standar industri untuk tugas ini. YOLO dikenal dengan pendekatannya yang

langsung dan efisien, di mana seluruh gambar diproses dalam satu langkah, memungkinkan deteksi *real-time* dengan akurasi yang baik [9, 10] Versi terbaru dari YOLO, termasuk YOLOv8, terus meningkatkan kinerja deteksi objek melalui teknik pembelajaran mendalam dan optimalisasi jaringan yang lebih baik [11].

### C. Roboflow

Roboflow adalah sebuah platform *web* yang berfokus pada pengumpulan *dataset*. Platform ini menyediakan berbagai fitur terkait pengembangan *computer vision* dengan dapat melakukan pra-pemrosesan dan augmentasi data menggunakan fitur yang disediakan [12]. Roboflow menyediakan berbagai alat untuk mempermudah proses anotasi, pra-pemrosesan, augmentasi, dan pelatihan model deteksi objek. Platform ini mendukung berbagai *framework deep learning* dan mempermudah integrasi dengan berbagai model seperti YOLO, TensorFlow, dan PyTorch. Pada penelitian ini, Roboflow digunakan untuk mengelola *dataset*, melakukan anotasi objek, memberikan label pada objek, serta melakukan pra-pemrosesan dan augmentasi data secara otomatis.

### D. Google Colab

Pelatihan model YOLOv8 dilakukan dengan memanfaatkan Google Colab Pro. Google Colab merupakan IDE (*Integrated Development Environment*) yang memungkinkan pengguna untuk menulis dan menjalankan kode Python, di mana proses komputasinya dieksekusi oleh *server* milik Google yang dilengkapi dengan perangkat keras berkinerja tinggi. [13] Google Colab menyediakan akses ke GPU dan TPU yang berguna untuk melatih model. Dengan integrasi yang mudah dan berbagai pustaka *deep learning*, Google Colab menjadi alat yang populer untuk eksperimen dan pengembangan model *deep learning*.


### E. Python

Python dikenal sebagai bahasa pemrograman yang menawarkan kombinasi kemampuan dan sintaksis kode yang sederhana serta mudah dipahami. Kelebihannya juga terletak pada koleksi *library* yang lengkap sehingga memungkinkan pengembang untuk mengakses berbagai fungsi dan utilitas secara mudah. Dengan kelebihan tersebut, Python dinilai sebagai bahasa pemrograman yang andal dan fleksibel untuk berbagai keperluan pengembangan aplikasi [14]. Python sering dimanfaatkan sebagai bahasa *scripting*, namun dalam praktiknya, penggunaan Python jauh lebih luas dan menjangkau berbagai konteks yang biasanya tidak ditangani oleh bahasa *scripting* pada umumnya [15].

### F. Kesegaran Ikan

Kesegaran ikan adalah parameter penting yang menentukan kualitas dan nilai jual dari produk perikanan. Kesegaran dapat dinilai berdasarkan berbagai indikator seperti penampilan fisik, tekstur, dan parameter kimiawi. Deteksi kesegaran ikan menggunakan teknologi deteksi objek dengan *deep learning* dapat memberikan penilaian yang akurat dan konsisten dibandingkan metode manual.

Penelitian ini menggunakan metode eksperimental dengan tujuan mengevaluasi kinerja model YOLOv8 dalam mendeteksi kesegaran ikan. Rancangan penelitian melibatkan beberapa langkah utama yaitu akuisisi data, pra-pemrosesan dan augmentasi data, pelatihan model, dan evaluasi kinerja. Seluruh proses penelitian terlihat pada Gambar 1 berikut.



GAMBAR 1  
Alur Proses Penelitian

*Dataset* diperoleh melalui kerjasama dengan Perusahaan Aruna untuk mengambil citra ikan cakalang. Kemudian data citra tersebut dieksplorasi melalui platform Roboflow yang menyediakan alat anotasi untuk selanjutnya dilakukan pra-pemrosesan dan augmentasi data untuk meningkatkan variasi dan jumlah data yang akan digunakan dalam pelatihan model. Setelah itu dilakukan pelatihan dan pengujian untuk mengukur kinerja model yang sudah dilatih. Langkah terakhir yaitu evaluasi kinerja model dengan mengukur tingkat keberhasilan model dalam mengidentifikasi objek dengan memastikan nilai mAP model mencapai 87%.

### A. Akuisisi Data

Akuisisi data adalah langkah awal dalam memperoleh data citra yang diperlukan untuk melatih model. Selain mengumpulkan data dari perusahaan Aruna, dilakukan juga pengumpulan data yang bersumber dari internet dan pembuatan data sintesis untuk memperkaya variasi citra. *Dataset* sintesis adalah kumpulan data yang dibuat ketika data ril sulit diperoleh untuk menghasilkan citra dengan posisi dan latar belakang yang berbeda [16] Perolehan data untuk pelatihan model terlihat pada Tabel 1.

## III. METODE

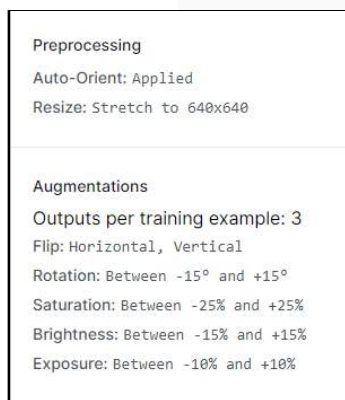
TABEL 1  
Rincian *Dataset*

Dataset	Kategori	Jumlah	Citra
Perusahaan Aruna	fresh	393	1.065
	no-fresh	469	
	multiple	203	
Internet	fresh	83	92
	no-fresh	9	
Sintetis	multiple	204	204
Jumlah			1.361

Dataset yang digunakan dalam penelitian ini terdiri dari citra ikan dengan dua kategori yaitu "fresh" dan "no-fresh", sedangkan kategori "multiple" adalah untuk citra yang di dalamnya terdapat beberapa ikan, baik dalam kondisi "fresh" maupun "no-fresh".

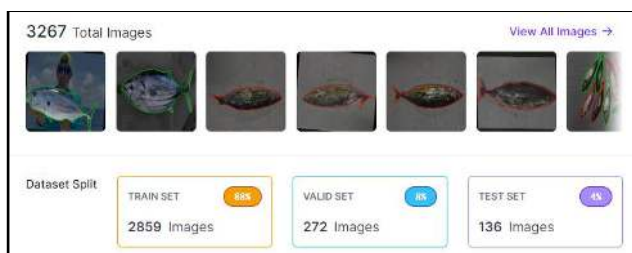
B. Pra-pemrosesan dan Augmentasi Data

Pra-pemrosesan dan augmentasi data menggunakan platform Roboflow dilakukan untuk meningkatkan keragaman data yang digunakan dalam proses pelatihan model [17] Pada tahap pra-pemrosesan, *auto-orient* dan *resize* diatur dengan ukuran yang sama yaitu 640x640 piksel. Augmentasi yang digunakan adalah *flip (horizontal dan vertical)*, *rotation* (antara -15° dan 15°), *saturation* (antara -25% dan +25%), *brightness* (antara -15% dan +15%), dan *exposure* (antara -10% dan +10%) seperti terlihat pada Gambar 2.



GAMBAR 2 Tahap Pra-pemrosesan dan Augmentasi Data

Setelah dilakukan tahap pra-pemrosesan dan augmentasi, data yang awalnya berjumlah 1.361 citra bertambah menjadi 3.267 citra dengan pembagian untuk masing-masing dataset adalah *train set* 88%, *valid set* 8%, dan *test set* 4% seperti terlihat pada Gambar 3.



GAMBAR 3 Pembagian Dataset

Sampel citra dari dataset terlihat pada Gambar 4, gambar (a) merupakan contoh citra ikan untuk kelas "fresh", sedangkan gambar (b) adalah untuk kelas "no-fresh".



GAMBAR 4 Sampel Dataset (a) Kelas "fresh" (b) Kelas "no-fresh"

Sampel citra hasil augmentasi terlihat pada Gambar 5, gambar (a) merupakan contoh citra ikan untuk kelas "fresh", sedangkan gambar (b) adalah untuk kelas "no-fresh".



GAMBAR 5 Sampel Dataset Hasil Augmentasi (a) Kelas "fresh" (b) Kelas "no-fresh"

C. Pelatihan Model YOLOv8

Tahap pelatihan model adalah ketika algoritma dilatih untuk mengenali pola data dan membuat prediksi serta mengambil keputusan [18]. Algoritma yang digunakan untuk melatih model menggunakan algoritma YOLOv8m (*You Only Look Once version 8m*).

Proses pelatihan model dilakukan dengan mengatur jumlah *epoch* sebanyak 200 *epoch* dan ukuran gambar input sebesar 640x640 piksel. Kombinasi "optimizer='AdamW'", "lr0=0,01", dan "momentum=0,9" digunakan untuk meningkatkan efisiensi dan stabilitas pelatihan model. Pengaturan beberapa parameter pelatihan model terlihat pada Gambar 6.



GAMBAR 6 Pengaturan Parameter Pelatihan Model

D. Evaluasi Kinerja

Dalam evaluasi kinerja, metrik evaluasi *accuracy*, *precision*, dan *recall* digunakan untuk mengukur performa model. Metrik tersebut akan menunjukkan seberapa baik model dapat mendeteksi ikan segar dan tidak segar dengan benar, serta seberapa konsisten model dalam melakukan prediksi [19].

TP (*True Positive*) menunjukkan prediksi yang benar untuk contoh positif, TN (*True Negative*) menunjukkan prediksi yang benar untuk contoh negatif, FP (*False Positive*) menunjukkan prediksi yang salah untuk contoh negatif, dan FN (*False Negative*) menunjukkan prediksi yang salah untuk contoh positif.

$$Precision = \frac{(TP+TN)}{(TP+FP+TN+FN)} \tag{1}$$



Akurasi mengukur keselarasan antara prediksi model dan nilai aktual. Akurasi dihitung dengan membagi jumlah prediksi yang benar dengan jumlah total prediksi. Rumus untuk akurasi terlihat pada (1).

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

Presisi mengukur rasio prediksi positif yang benar terhadap total prediksi yang diklasifikasikan sebagai positif. Rumus presisi terlihat pada (2).

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


Recall mengukur kemampuan model dalam mengidentifikasi kasus positif secara akurat di antara semua kasus positif yang sebenarnya. Rumus recall terlihat pada (3).

Selain itu, evaluasi kinerja model YOLOv8 dilakukan menggunakan metrik evaluasi mAP yang menunjukkan rata-rata dari precision di berbagai tingkat recall. Seluruh metrik yang diperhitungkan tersebut digunakan untuk menilai kinerja model dalam mendeteksi kesegaran ikan.

#### IV. HASIL DAN PEMBAHASAN

##### A. Pelatihan Model

Hasil dari pelatihan model terlihat pada Gambar 7. Seluruh grafik memiliki sumbu x yang sama yaitu jumlah epoch, sedangkan sumbu y adalah metrik proses latih model yang terdiri dari train box loss, train classification loss, train DFL loss, val box loss, val classification loss, val DFL loss, precision, recall, mAP@0,5, dan mAP@0,5 0,95.



GAMBAR 7 Hasil Pelatihan Model

Grafik “train/box\_loss” menunjukkan penurunan nilai box loss dari 0,8 hingga 0,4 dan semakin turun seiring berjalannya waktu dalam 173 epoch. Hal ini menunjukkan bahwa model semakin akurat dalam memprediksi lokasi objek. Grafik “train/cls\_loss” menggambarkan penurunan nilai classification loss dari 1,2 hingga 0,6 dan semakin turun sepanjang iterasi yang menandakan peningkatan kemampuan model dalam mengklasifikasikan objek. Sementara itu, grafik “train/df\_l\_loss” menampilkan penurunan nilai loss distribusi fitur lokasi dari 1,2 hingga 1,0 dan semakin turun sepanjang iterasi yang menunjukkan peningkatan dalam memprediksi fitur-fitur spesifik dari objek yang terdeteksi.

Grafik “metrics/precision(B)” dan “metrics/recall(B)” keduanya menunjukkan peningkatan performa model. Precision, yang mengukur proporsi prediksi positif yang benar meningkat mendekati nilai 1,0, menunjukkan tingkat

kesalahan yang rendah dalam prediksi positif. Recall, yang mengukur kemampuan model dalam menemukan semua kasus positif meningkat mendekati nilai 1,0, menandakan bahwa model dapat mendeteksi semua objek yang relevan dengan baik.

Grafik “val/box\_loss” menunjukkan penurunan nilai loss box dari sekitar 2,5 hingga kurang dari 0,5, menunjukkan bahwa model berperilaku baik pada data yang tidak dilihat selama pelatihan. Grafik “val/cls\_loss” dan “val/df\_l\_loss” juga menunjukkan penurunan nilai yang menandakan peningkatan kemampuan model dalam mengklasifikasikan objek dan memprediksi fitur spesifik pada data validasi.

Grafik “metrics/mAP@0,50” dan “metrics/mAP@0,50:0,95” menampilkan mAP model pada berbagai ambang batas IoU (Intersection over Union). Nilai mAP meningkat dari 0,2 hingga mendekati 1,0 untuk IoU 0,50, dan dari sekitar 0,2 hingga mendekati 1,0 untuk rentang IoU 0,50 hingga 0,95 dalam 173 epoch. Peningkatan ini menunjukkan peningkatan akurasi model dalam mendeteksi dan mengklasifikasikan objek dengan berbagai tingkat ketepatan.

Model deep learning yang sudah dilatih selanjutnya diujikan terhadap data valid. Hasil pengujian divisualisasikan dalam bentuk confusion matrix seperti pada Gambar 8.

PREDICTED	Fresh	612	61	69
	No-Fresh	57	566	44
	Background	76	86	0
		Fresh	No-Fresh	Background

GAMBAR 8 Hasil Confusion Matrix

Pada confusion matrix, didapatkan nilai TP sebesar 612 untuk ikan segar dan 566 untuk ikan tidak segar dengan FP yang didapatkan sebesar 130 untuk ikan segar dan 101 untuk ikan tidak segar. Sedangkan TN sebesar 696 untuk ikan segar dan 757 untuk ikan tidak segar dengan FN sebesar 133 untuk ikan segar dan 147 untuk ikan tidak segar. Kelas “background” mengacu pada deteksi TN dimana model mengidentifikasi dengan benar bahwa tidak ada objek yang terdeteksi. Sebaliknya, jika “fresh” atau “no-fresh” diprediksi untuk “background” yang sebenarnya, itu akan menjadi FP yang menunjukkan model melihat kesegaran ikan yang sebenarnya tidak ada. Dalam matriks untuk TP “background” harus bernilai nol [20].

Tabel 2 merupakan tabel yang meringkas hasil pelatihan model deep learning.

TABEL 2 Hasil Pelatihan Model

Parameter	Hasil
mAP	0,913
Accuracy	0,837
Precision	0,837
Recall	0,808
Waktu deteksi/citra	0,121

### B. Pengujian Model

Pada Gambar 9 ditunjukkan beberapa citra hasil pengujian model yang telah dilatih dan dievaluasi menggunakan *dataset testing*.



GAMBAR 9  
Citra Hasil Deteksi Model

## V. KESIMPULAN

Pengujian model YOLOv8 dilakukan dengan menghitung berbagai metrik performa model. Berdasarkan Tabel 2, model memiliki nilai mAP 91,3%. Hal ini menunjukkan bahwa model cukup akurat dalam mendeteksi kesegaran ikan cakalang. Pengujian lebih lanjut dilakukan dengan menggunakan *confusion matrix* untuk mengevaluasi kinerja model dalam mendeteksi kesegaran ikan. Berdasarkan *confusion matrix*, didapatkan nilai *accuracy* sebesar 83,7%; *precision* sebesar 83,7%; dan *recall* sebesar 80,8%.

Grafik performa pelatihan dan validasi model ditunjukkan pada Gambar 7 mencakup metrik seperti *train box loss*, *train classification loss*, *train DFL loss*, *val box loss*, *val classification loss*, *val DFL loss*, *precision*, *recall*, mAP@0.5, dan mAP@0.5-0.95. Dari grafik yang disajikan, gambar menunjukkan performa model yang baik dalam mendeteksi objek pada citra yang tidak dilihat selama pelatihan.

Analisis hasil pengujian menunjukkan bahwa model menunjukkan performa yang memadai untuk mendeteksi kesegaran ikan. Model YOLOv8 berhasil mencapai mAP lebih dari 87% yaitu 91,3% serta memenuhi berbagai metrik performa yang cukup tinggi dengan waktu deteksi yang efisien.

## REFERENSI

- [1] C. Litaay, S. Hari Wisudo, and H. Arfah, "Penanganan Ikan Cakalang oleh Nelayan Pole and Line," *Jurnal Pengolahan Hasil Perikanan Indonesia*, vol. 23, no. 1, pp. 112–121, Apr. 2020, doi: 10.17844/jphpi.v23i1.30924.
- [2] S. Soepardi, Sugiono, S. Nurhakim, and R. Sutanto, "Studi tentang Penanganan Hasil Tangkapan Ikan Cakalang (Katsuwonus pelamis) dengan Alat Tangkap Purse Seine KM. Anugerah Barokah di Perairan Nusa Tenggara Timur," *Jurnal Bahari Papadak*, vol. 3, no. 2, pp. 100-111, 2022.
- [3] S. Aras, P. Tanra, and M. Bazhar, "Deteksi Tingkat Kematangan Buah Tomat Menggunakan YOLOv5," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 2, pp. 623–628, Mar. 2024, doi: 10.57152/malcom.v4i2.1270.
- [4] K. M. Knausgård et al., "Temperate fish detection and classification: a deep learning based approach," *Applied Intelligence*, vol. 52, no. 6, pp. 6988–7001, Mar. 2021, doi: 10.1007/s10489-020-02154-9.
- [5] Y. Li, Q. Fan, H. Huang, Z. Han, and Q. Gu, "A Modified YOLOv8 Detection Network for UAV Aerial Image Recognition," *Drones*, vol. 7, no. 5, p. 304, May 2023, doi: 10.3390/drones7050304.
- [6] J. Terven, D.-M. Córdova-Esparza, and J.-A. Romero-González, "A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS," *Machine Learning and Knowledge Extraction*, vol. 5, no. 4, pp. 1680–1716, Nov. 2023, doi: 10.3390/make5040083.
- [7] M. Kukuh Isnaen and A. Stefanie, "Implementasi Raspberry PI dalam Alat Klasifikasi Penyakit Mata dengan Arsitektur YOLOv8 menggunakan Oftalmoskop," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 3, pp. 1885–1889, Nov. 2023, doi: 10.36040/jati.v7i3.6950.
- [8] M. R. Ardiansyah, Y. Supit, and M. S. Said, "Sistem Visi Komputer untuk Kalkulasi Kepadatan Kendaraan menggunakan Algoritma YOLO," *Simtek: Jurnal Sistem Informasi dan Teknik Komputer*, vol. 7, no. 1, pp. 52–59, Apr. 2022, doi: 10.51876/simtek.v7i1.123.
- [9] Paperspace, "YOLOv8: A Revolutionary Advancement in Object Detection," *Paperspace Blog*, [Online]. Available: <https://blog.paperspace.com/yolov8-a-revolutionary-advancement-in-object-detection-2/>. Accessed: Jul. 6, 2024.
- [10] M. Sohan, T. Sai Ram, and Ch. V. Rami Reddy, "A Review on YOLOv8 and Its Advancements," *Algorithms for Intelligent Systems*, pp. 529–545, 2024, doi: 10.1007/978-981-99-7962-2\_39.
- [11] Y. Swathi and M. Challa, "YOLOv8: Advancements and Innovations in Object Detection," *Smart Trends in*

- Computing and Communications*, pp. 1–13, 2024, doi: 10.1007/978-981-97-1323-3\_1.
- [12] N. J. Hayati, D. Singasatia, and M. R. Muttaqin, “Object Tracking Menggunakan Algoritma You Only Look Once (YOLO)v8 untuk Menghitung Kendaraan,” *Komputa : Jurnal Ilmiah Komputer dan Informatika*, vol. 12, no. 2, pp. 91–99, Nov. 2023, doi: 10.34010/komputa.v12i2.10654.
- [13] R. Gelar Guntara, “Pemanfaatan Google Colab Untuk Aplikasi Pendeteksian Masker Wajah Menggunakan Algoritma Deep Learning YOLOv7,” *Jurnal Teknologi Dan Sistem Informasi Bisnis*, vol. 5, no. 1, pp. 55–60, Feb. 2023, doi: 10.47233/jteksis.v5i1.750.
- [14] P. A. Nugroho, I. Fenriana, and R. Arijanto, “Implementasi deep learning menggunakan convolutional neural network (CNN) pada ekspresi manusia,” *Algor*, vol. 2, no. 1, pp. 12-20, 2020.
- [15] J. Tremblay, T. To, and S. Birchfield, “Falling Things: A Synthetic Dataset for 3D Object Detection and Pose Estimation,” *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Jun. 2018, doi: 10.1109/cvprw.2018.00275.
- [16] J. Sanjaya and M. Ayub, “Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan Random Crop, Rotate, dan Mixup,” *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 6, no. 2, Aug. 2020, doi: 10.28932/jutisi.v6i2.2688.
- [17] N. J. Hayati, D. Singasatia, and M. Muttaqin, “Object Tracking Menggunakan Algoritma You Only Look Once (Yolo)V8 Untuk Menghitung Kendaraan,” *Jurnal Ilmiah Komputer dan Informatika*, vol. 12, no. 2, pp. 91–99, Oct. 2023, doi: <https://doi.org/10.34010/komputa.v12i2.10654>.
- [18] Ultralytics, “Issue #6793: [Bug] The content should be downloaded via browser rather than wget,” GitHub, [Online]. Available: <https://github.com/ultralytics/ultralytics/issues/6793>. Accessed: Jul. 4, 2024.
- [19] H. M. Lathifah, L. Novamizanti, & S. Rizal, “Fast and accurate fish classification from underwater video using you only look once,” in *IOP Conference Series: Materials Science and Engineering*, vol. 982, no. 1, pp. 012003). IOP Publishing, December 2020.
- [20] F. Akhyar, L. Novamizanti, T. Putra, E. N. Furqon, M. C. Chang, & C. Y. Lin, “Lightning YOLOv4 for a surface defect detection system for sawn lumber,” in *2022 IEEE 5th International Conference on Multimedia Information Processing and Retrieval (MIPR)* (pp. 184–189). IEEE, August 2022.
- [21] F. Akhyar, L. Novamizanti, & T. Riantiarni, “Sistem inspeksi cacat pada permukaan kayu menggunakan model deteksi obyek YOLOv5,” *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 10, no.4, pp. 990, 2022.
- [22] A. K. Aziz, M. D. Maulana, R. F. Adawiyah, R. F. Firdaus, L. Novamizanti, & F. Ramdhon, “Comparative analysis of YOLOv8 models in skipjack fish quality assessment system,” in *2023 3rd International Conference on Intelligent Cybernetics Technology & Applications (ICICyTA)* (pp. 237-242). IEEE, December 2023.
- [23] S. Azizah, Wahidin, M. Padang, L. Novamizanti, S Saidah. Identifying the Ripeness and Quality Level of Strawberries Based on YOLOv7-EfficientNet. The 5th International Conference on Data Science and Its Applications (ICoDSA). IEEE, July 2024.
- [24] B. A. Wicaksono, L. Novamizanti, & N. Ibrahim, “Tea leaf maturity levels based on ycbcr color space and clustering centroid,” In *Journal of Physics: Conference Series* (Vol. 1367, No. 1, pp. 012028). IOP Publishing, November 2019.