

PENERAPAN MODEL *CONVOLUTIONAL NEURAL NETWORK* (CNN) BERBASIS MOBILENETV2 UNTUK KLASIFIKASI TINGKAT KESEGERAN IKAN NILA

Sarah Syakira Rambe^{1*}, Asriyanik², Prajoko³

^{1,2,3} Universitas Muhammadiyah Sukabumi; Jl. R. Syamsudin, S.H. No. 50, Cikole; Telpon/Fax (0266) 218345

Keywords:

Ikan nila; Deteksi kesegaran;
Pengolahan citra;
Convolutional Neural
Network; klasifikasi

Correspondent Email:

rambesarah03@gmail.com

Abstrak. Ikan nila (*Oreochromis niloticus*) merupakan salah satu komoditas perikanan bernilai ekonomi tinggi yang banyak dikonsumsi masyarakat Indonesia. Namun, ikan termasuk produk mudah rusak jika tidak ditangani dengan baik. Tingkat kesegaran ikan menjadi parameter penting dalam penentuan mutu dan harga jual, tetapi penilaian secara manual cenderung subjektif. Penelitian ini bertujuan mengembangkan sistem otomatis untuk mendeteksi tingkat kesegaran ikan nila menggunakan metode Convolutional Neural Network (CNN) dengan pendekatan CRISP-DM. Dataset terdiri dari 6.889 citra mata, kulit, dan insang ikan nila yang diperoleh dari Kaggle dan sumber data pribadi. Pengolahan data meliputi resize, normalisasi, dan augmentasi citra. Model dibangun dengan arsitektur MobileNetV2, diikuti GlobalAveragePooling2D, dense layer, dan aktivasi sigmoid sebagai output layer. Pelatihan dilakukan dalam dua tahap, pretraining dan fine-tuning. Hasil menunjukkan akurasi sebesar 99,39% pada data latih dan 100% pada validasi di tahap pretraining, serta akurasi sebesar 99,36% pada data latih dan 100% pada validasi di tahap fine-tuning. Evaluasi menggunakan Confusion Matrix menghasilkan akurasi, presisi, recall, F1-Score sebesar 95% pada threshold 0.4. Model CNN yang dikembangkan terbukti efektif dan dapat digunakan sebagai sistem pendukung keputusan dalam penilaian mutu produk perikanan.

Abstract. *Tilapia (Oreochromis niloticus) is a high-value fishery commodity widely consumed in Indonesia. However, fish is a perishable product if not properly handled. Freshness is a key parameter in determining quality and market value, but manual assessment is often subjective. This study aims to develop an automated system to detect tilapia freshness using a Convolutional Neural Network (CNN) with a CRISP-DM approach. The dataset includes 6.889 images of tilapia eyes, skin, and gills, sourced from Kaggle and private collections. Preprocessing involved resizing, normalization, and augmentation. The model used the MobileNetV2 architecture, followed by a GlobalAveragePooling2D layer, a dense layer, and a sigmoid activation output. Training was conducted in two stages: pretraining and fine-tuning. Results showed 99.39% training accuracy and 100% validation accuracy during pretraining, and 99.36% training accuracy and 100% validation accuracy during fine-tuning. Evaluation with a confusion matrix at a 0.4 threshold yielded 95% accuracy, precision, recall, and F1-score. The CNN model demonstrated strong performance and is suitable as a decision support system for assessing the quality of fishery products.*



JITET is licensed under
a Creative Commons
Attribution-NonCommercial
4.0 International License.

1. PENDAHULUAN

Sebagai negara kepulauan dengan wilayah laut yang sangat luas, Indonesia memiliki potensi sumber daya perikanan yang melimpah [1]. Ikan nila termasuk salah satu ikan air tawar yang populer di kalangan masyarakat Indonesia. Jenis ikan ini memiliki nilai ekonomi yang cukup tinggi, mudah dibudidayakan, serta memiliki jangkauan distribusi yang luas di berbagai daerah di Indonesia [2] [3]. Data dari Kementerian Kelautan dan Perikanan (KKP) menunjukkan adanya pertumbuhan produksi ikan nila, dari 1,35 juta ton pada 2021 menjadi 1,41 juta ton pada 2022, dengan kontribusi nilai ekonomi sebesar 36,47 triliun rupiah [4].

Sebelum mengonsumsi ikan, konsumen cenderung memilih ikan dalam kondisi segar. Menurut Standar Nasional Indonesia, penilaian kesegaran ikan dapat dilakukan melalui uji *organoleptic*, dengan mengamati kondisi mata, insang, aroma, lendir di permukaan tubuh, serta tekstur daging ikan tersebut [5]. Sayangnya, ikan merupakan komoditas yang mudah mengalami penurunan kualitas apabila tidak disimpan dalam suhu yang sesuai. Penurunan mutu ini biasanya disebabkan oleh kontaminasi bakteri yang tidak hanya menurunkan nilai gizi tetapi juga meningkatkan risiko toksisitas jika ikan mencapai tahap pembusukan. Oleh karena itu, penanganan mutu ikan secara cepat dan tepat menjadi sangat penting [6] [7].

Dalam praktiknya, proses pemilahan ikan umumnya masih dikerjakan secara manual oleh nelayan maupun pedagang, sehingga rentan terjadi kekeliruan akibat keterbatasan indra visual manusia. Di sisi lain, metode konvensional seperti analisis kimia, mikrobiologi, dan sensori memang dapat menghasilkan data yang akurat, namun cenderung memerlukan waktu yang cukup lama, biaya yang tinggi, dan tahap prosedural yang kompleks [8] [9].

Seiring dengan perkembangan teknologi, kecerdasan buatan (*Artificial Intelligence*) terus mengalami kemajuan untuk memungkinkan pemrosesan informasi secara cepat dan akurat. Salah satu bidang kecerdasan buatan yang berkembang pesat adalah *Deep Learning*, sebagai bagian dari *Machine Learning*, yang umum digunakan dalam tugas-tugas seperti deteksi objek serta segmentasi semantik melalui arsitektur jaringan berlapis [10] [11]. *Deep Learning* memungkinkan klasifikasi langsung

terhadap data berupa gambar maupun suara, serta memanfaatkan GPU untuk mempercepat komputasi dalam pengolahan data berukuran besar. Dalam pengolahan citra digital, metode ini digunakan untuk mengekstraksi, menganalisis, dan memahami informasi yang terkandung dalam citra [6] [12].

Dalam pengolahan citra, terdapat berbagai jenis model yang dapat dimanfaatkan, salah satunya yaitu *Convolutional Neural Network* (CNN). Berbagai studi terdahulu telah membuktikan bahwa CNN mampu memberikan hasil yang baik dalam mengidentifikasi tingkat kesegaran ikan melalui analisis visual citra. Seperti penelitian yang dilakukan oleh Erna Hudianti (2022) menggunakan CNN untuk mengidentifikasi tingkat kesegaran ikan nila berdasarkan perubahan warna pada mata ikan. Dengan memanfaatkan 50 citra sebagai data latih, proses pelatihan dilakukan selama 20 *epoch* dengan *learning rate* sebesar 0,001. Model yang dikembangkan berhasil mencapai akurasi sebesar 93% pada data pelatihan dan 90% pada data validasi, serta akurasi tertinggi mencapai 95% ketika menggunakan tiga lapisan konvolusi [13]. Penelitian lain oleh Zaky Luthfirana mengungkapkan bahwa CNN efektif dalam mengenali perubahan visual pada mata ikan, termasuk variasi warna dan tekstur, sehingga dapat membedakan antara ikan yang masih segar dan yang sudah tidak segar dengan tingkat akurasi yang memuaskan [14].

Namun demikian, sebagian besar penelitian terdahulu masih terbatas pada penggunaan satu atau dua parameter *visual*, seperti mata dan insang, serta melibatkan jumlah data yang relatif sedikit. Belum banyak pendekatan yang mengintegrasikan beberapa parameter visual secara bersamaan untuk meningkatkan akurasi klasifikasi.

Berdasarkan hal tersebut, penelitian ini bertujuan untuk mengembangkan model deteksi kesegaran ikan nila berbasis CNN dengan memanfaatkan tiga parameter *visual* utama, yaitu mata, kulit, dan insang. Selain itu, penelitian ini juga mengintegrasikan model CNN ke dalam sebuah *platform* berbasis *web*, sehingga sistem deteksi kesegaran ikan dapat diakses dan digunakan dengan mudah. Dengan demikian, sistem ini tidak hanya membantu proses penyortiran ikan secara lebih praktis dan handal, tetapi juga meningkatkan aksesibilitas dan efisiensi melalui aplikasi berbasis *website*.

2. TINJAUAN PUSTAKA

2.1 Ikan Nila

Oreochromis niloticus, atau ikan nila adalah ikan air tawar yang banyak dibudidayakan di Indonesia. Ikan ini dikenal sebagai sumber protein hewani dengan kandungan gizi tinggi, seperti omega-3, vitamin, dan mineral yang memberikan manfaat bagi kesehatan [1]. Secara morfologi, ikan nila memiliki tubuh pipih dengan garis vertikal pada ekor, sisik berbentuk sikloid, serta mulut *protusible* dengan moncong lebar [15].

2.2 Kesegaran Ikan

Kesegaran ikan mengacu pada keadaan fisiologis ikan yang belum mengalami perubahan fisik, kimia, atau mikrobiologis setelah proses penangkapan. Ikan segar biasanya melewati tiga tahap setelah ditangkap, yaitu *pre-rigor mortis*, *rigor mortis*, dan *post-rigor mortis* [16]. Berdasarkan tingkat kesegarannya, ikan dibagi menjadi empat kelas mutu, yakni mutu sangat baik, mutu baik, mutu sedang, dan mutu tidak segar atau sudah membusuk [17]. Menurut Standar Nasional Indonesia (SNI) 2729, penilaian kesegaran ikan secara organoleptik dapat dilakukan berdasarkan kondisi mata, insang, lendir tubuh, warna, dan tekstur daging, bau, serta elastisitas tubuh [8]. Penilaian kesegaran ikan dapat dilakukan secara *visual* dengan mengamati kondisi fisik ikan, antara lain mata menonjol dan jernih, insang merah cerah, kulit cerah, sisik melekat erat, dangin kenyal, lendir bening [5].

2.3 Deep Learning

Deep Learning adalah salah satu bidang dalam *machine learning* yang menggunakan Jaringan Saraf Tiruan (JST) dengan arsitektur berlapis-lapis yang meniru fungsi otak manusia [12]. Model *deep learning* tersusun dari beberapa lapisan, seperti *convolutional layer*, *pooling layer*, *ReLU layer*, dan *fully connected layer*, yang bekerja secara hierarkis untuk mengekstraksi fitur dan memahami data *input* secara mandalam.

Salah satu penerapan utama *deep learning* adalah dalam bidang *Computer Vision*, yaitu kemampuan sistem untuk mengenali dan menginterpretasikan objek dalam citra digital. Tujuan utamanya adalah mengekstraksi informasi lebih dalam terhadap model [18] [19].

2.4 Convolutional Neural Network

Convolutional Neural Network (CNN) adalah pengembangan dari *Multi-Layer*

Perceptron (MLP) yang dirancang khusus untuk mengenali pola visual dan mempelajari fitur spasial dari data citra. CNN banyak digunakan dalam bidang *computer vision*, seperti klasifikasi objek, deteksi citra, dan segmentasi gambar [20].

Arsitektur terdiri dari dua bagian utama yaitu lapisan ekstraksi fitur dan lapisan klasifikasi. Lapisan ekstraksi fitur menggunakan *convolutional layer* untuk mendeteksi pola lokal pada gambar, diikuti oleh *pooling layer* untuk mengurangi dimensi data. Aktivasi *non-linear* seperti ReLU digunakan untuk meningkatkan kemampuan jaringan dalam mempelajari fitur kompleks.

Hasil ekstraksi kemudian diteruskan ke lapisan klasifikasi yang mengubah fitur menjadi vektor dan menghasilkan probabilitas kelas target [20] [21].

2.5 MobileNetV2

MobileNetV2 adalah sebuah arsitektur *Convolutional Neural Network* (CNN) yang dibuat dengan fokus pada efisiensi, sehingga cocok digunakan pada perangkat dengan sumber daya terbatas, seperti perangkat *mobile* atau sistem tertanam (*embedded system*) [22]. Arsitektur ini menggabungkan dua fitur utama, yaitu *Linear Bottleneck* dan *Shortcut Connection* yang memungkinkan proses ekstraksi fitur tetap efisien tanpa kehilangan banyak informasi. *Linear Bottleneck* mempertahankan representasi fitur dalam dimensi rendah, sedangkan *Shortcut Connection* membantu mempercepat aliran gradien dan meningkatkan stabilitas pelatihan jaringan [23].

2.6 Confusion Matrix

Confusion matrix adalah metode evaluasi yang digunakan untuk mengukur kinerja model dengan membandingkan hasil prediksi dan nilai sebenarnya dari sebuah *dataset*. Klasifikasi hasil prediksi dapat dijelaskan dalam tabel berikut [24].

Tabel 1. Tabel *Confusion Matrix*

<i>Confusion Matrix</i>	Data Aktual	
	Positif	Negatif
Data	TP	FP
Prediksi	FN	TN

Keterangan:

a. TP (*True Positive*)

Prediksi yang benar dan sesuai dengan kelas positif sebenarnya.

b. TN (*True Negative*)

Prediksi yang benar dan sesuai dengan kelas negatif sesungguhnya.

- c. FP (*False Positive*)
Prediksi yang salah berupa positif, meskipun kelas sesungguhnya negatif.
- d. FN (*False Negative*)
Prediksi yang salah berupa negatif, meskipun kelas sesungguhnya positif.

Berdasarkan komponen tersebut, beberapa metrik evaluasi yang umum digunakan dalam penelitian klasifikasi adalah sebagai berikut.

- a. *Accuracy*, yang berfungsi untuk mengukur seberapa baik model dalam mengklasifikasikan data dengan benar secara keseluruhan.
- b. *Precision*, menunjukkan seberapa tepat model dalam mengklasifikasikan data ke kelas positif, dihitung sebagai rasio prediksi positif yang benar terhadap total prediksi positif.
- c. *Recall*, digunakan untuk mengukur kemampuan model dalam mendeteksi semua data yang memang termasuk kelas positif.
- d. *F1-score*, yaitu nilai yang menggabungkan *precision* dan *recall* untuk memberikan keseimbangan antara kedua metrik tersebut.

2.7 Python

Python merupakan bahasa pemrograman tingkat tinggi yang banyak digunakan dalam pengembangan model *deep learning* dan pengolahan citra karena mendukung berbagai pustaka, seperti NumPy, OpenCV, dan TensorFlow [25].

2.8 Google Colaboratory

Google Colaboratory merupakan *platform* berbasis *cloud* yang memungkinkan eksekusi kode Python secara langsung melalui peramban tanpa perlu konfigurasi lokal. Google Colab mendukung berbagai pustaka untuk pengembangan model kecerdasan buatan, seperti TensorFlow, Keras, NumPy, dan Pandas [26].

2.9 TensorFlow

TensorFlow merupakan pustaka *open-source* untuk mendukung komputasi numerik dan pengembangan model *machine learning* berskala besar. Pustaka ini menyediakan antarmuka pemrograman yang fleksibel, sehingga memudahkan dalam proses ekstraksi data, pelatihan model, prediksi, hingga penyempurnaan performa model [27].

2.10 Flask

Flask adalah sebuah *framework* yang ditulis menggunakan bahasa yang dirancang dengan mudah dan cepat dengan tujuan untuk meminimalisir waktu *load* dan meningkatkan kemampuan aplikasi yang lebih kompleks [21].

2.11 RoboFlow

RoboFlow adalah sebuah *platform* berbasis *cloud* yang dirancang untuk mendukung pengembangan sistem *computer vision* secara menyeluruh, mulai dari pengumpulan dan anotasi data, pra-pemrosesan, hingga pelatihan model [28].

3. METODE PENELITIAN

Metode penelitian yang digunakan adalah metode CRISP-DM (*Cross Industry Standard for Data Mining*) yang merupakan model proses yang independent dari industri dan umum digunakan untuk keperluan *data mining*. Metode ini terdiri dari enam tahapan terstruktur yang saling terkait untuk mendukung proses analisis data dan pengembangan model.

3.1 Business Understanding

Tahap *business understanding* bertujuan untuk memahami konteks bisnis atau permasalahan yang ingin diselesaikan. Dalam konteks penelitian ini, dilakukan identifikasi kebutuhan akan sistem deteksi tingkat kesegaran ikan nila berdasarkan citra digital. Tahapan ini melibatkan perumusan tujuan penelitian, identifikasi masalah, serta penentuan indikator, keberhasilan dari sistem yang akan dikembangkan.

3.2 Data Understanding

Tahap ini berfokus pada proses pengumpulan serta eksplorasi awal data yang akan digunakan untuk pelatihan dan pengujian model. Data dalam penelitian ini berasal dari dua sumber, yakni Kaggle dan dokumentasi pribadi peneliti. Dokumentasi pribadi dilakukan dengan cara mengambil gambar ikan nila segar dan tidak segar menggunakan kamera *smartphone* dalam kondisi yang terkontrol.

Setiap citra diamati dan dianalisis berdasarkan karakteristik visual yang relevan, seperti mata, kulit, dan insang ikan nila, karena fitur-fitur ini digunakan dalam penelitian untuk membedakan antara ikan segar dan tidak segar. Dengan memahami karakteristik visual tersebut, proses analisis dan pemodelan dapat dilakukan secara akurat dan terarah.

3.3 Data Preparation

Tahap *data preparation* meliputi serangkaian proses pra-pemrosesan yang bertujuan untuk memastikan data berada dalam kondisi yang baik sebelum model dilatih. Proses yang dilakukan antara lain *resizing* gambar, normalisasi nilai piksel, augmentasi data, dan pembagian data.

3.4 Modelling

Pada tahap *modelling*, dibangun model klasifikasi menggunakan algoritma *deep learning*. Model dibangun menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2. Model CNN dirancang untuk mendeteksi dan mengklasifikasikan tingkat kesegaran ikan nila berdasarkan fitur visual dari citra. Pelatihan model dilakukan menggunakan Google Colab untuk memanfaatkan GPU dan mempercepat proses komputasi.

3.5 Evaluation

Tahap evaluasi dilakukan untuk mengetahui sejauh mana performa model dalam mengklasifikasikan tingkat kesegaran ikan nila berdasarkan citra digital. Evaluasi dilakukan dengan membandingkan hasil prediksi model terhadap label asli pada data uji. Dalam penelitian ini, *Confusion Matrix* digunakan sebagai alat utama untuk menganalisis jumlah prediksi yang benar dan salah pada setiap kelas. Dari *confusion matrix* tersebut, berbagai metrik evaluasi umum yang sering digunakan dalam tugas klasifikasi dapat dihitung untuk menilai kinerja model secara menyeluruh, yaitu *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Berikut adalah rumus perhitungan untuk masing-masing metrik tersebut.

a. Accuracy

$$Accuracy = \frac{True\ Positive + True\ Negative}{Total\ Data} \quad (1)$$

b. Precision

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive} \quad (2)$$

c. Recall

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative} \quad (3)$$

d. F1-Score

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

3.6 Deployment

Tahap *deployment* merupakan tahap akhir di mana model yang telah melewati evaluasi dan menunjukkan kinerja yang baik dikembangkan

menjadi aplikasi berbasis *web* menggunakan *framework* Flask. Aplikasi ini memungkinkan pengguna untuk mengunggah citra ikan nila, yang kemudian akan diklasifikasikan sebagai “Segar” dan “Tidak Segar”.

4. HASIL DAN PEMBAHASAN

Dalam penelitian ini, deteksi tingkat kesegaran ikan nila dilakukan dengan memanfaatkan citra mata, kulit, dan insang menggunakan metode *Convolutional Neural Network* (CNN). *Dataset* yang digunakan melewati beberapa tahap, mulai dari pelabelan data, pembagian data, pra-pemrosesan, augmentasi, pemodelan hingga evaluasi.

4.1 Business Understanding

Proses penilaian kesegaran ikan nila yang dilakukan secara manual oleh penjual maupun konsumen masih bersifat subjektif dan rentan terhadap *bias*. Ketidaktepatan dalam penilaian tersebut dapat menurunkan kepuasan konsumen serta kepercayaan terhadap produk perikanan. Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan sistem klasifikasi kesegaran ikan nila menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2, yang diintegrasikan ke dalam sebuah sistem berbasis *web*. Sistem tersebut dirancang untuk menganalisis citra bagian tubuh ikan, seperti mata, kulit, dan insang, sehingga dapat mengidentifikasi tingkat kesegaran secara objektif. Pendekatan ini diharapkan dapat membantu dalam meningkatkan nilai jual produk sekaligus memudahkan dalam memilih ikan segar secara efisien.

4.2 Data Understanding

Data yang digunakan dalam penelitian ini berupa citra ikan nila dengan kondisi segar dan tidak segar, yang diambil dari dua sumber, yaitu *dataset* publik dari Kaggle dengan judul *Tilapia Fish Fresh and Non-Fresh Species* oleh Haripiya Sanga, dan pengambilan langsung menggunakan kamera *smartphone*. Citra yang dikumpulkan mencakup bagian mata, kulit, dan insang. Rincian jumlah *dataset* ditampilkan pada Tabel 2.

Tabel 2. Rincian Jumlah Gambar Dataset Ikan Nila

Parameter	Kaggle		Pengambilan Gambar Langsung	
	Kondisi Segar	Kondisi Tidak Segar	Kondisi Segar	Kondisi Tidak Segar
Mata	700	700	284	237
Kulit	217	76	382	390
Insang	700	700	218	271
Jumlah	3.093		1.782	
	6.889			

Dataset yang diperoleh masih dalam bentuk mentah dengan ukuran gambar yang bervariasi, kualitas pencahayaan yang tidak merata, nilai piksel yang berbeda serta sudut pengambilan gambar yang belum bervariasi.

4.3 Data Preparation

Tahapan *data preparation* dilakukan melalui serangkaian proses untuk memastikan data yang digunakan siap digunakan dalam pemodelan. Proses pertama adalah pelabelan data menggunakan RoboFlow, di mana seluruh citra ikan nila diklasifikasikan ke dalam dua kelas, yaitu “Segar” dan “Tidak Segar”. Setelah proses pelabelan selesai, *dataset* dibagi berdasarkan sumbernya. *Dataset* dari Kaggle digunakan untuk tahap *pretraining*, dan dibagi menjadi dua *subset*, yaitu 90% untuk data latih dan 10% untuk data validasi. Sementara itu, *dataset* dari pengambilan gambar langsung digunakan untuk tahap *fine-tuning* dan dibagi menjadi tiga *subset*, dengan proporsi 80% untuk data latih, 10% untuk data validasi, dan 10% untuk data uji.

Seluruh gambar kemudian diubah ukurannya menjadi 224x224 piksel untuk menyeragamkan *input* ke dalam model CNN. Setelah itu, dilakukan normalisasi nilai piksel dengan membagi setiap nilai piksel dengan angka 255, sehingga skala piksel berada dalam rentang 0-1.

Proses augmentasi dimulai dengan teknik *oversampling* terhadap kelas kulit segar pada *dataset pretraining* karena jumlah datanya lebih sedikit dibandingkan kategori lainnya. Parameter augmentasi pada proses *oversampling* kulit segar ditunjukkan pada Tabel 3.

Tabel 3. Parameter Teknik Augmentasi Kulit

Teknik Augmentasi	Parameter
Rotasi	10°
Zoom	0.05

Teknik Augmentasi	Parameter
Brightness Range	0.95 – 1.1
Fill Mode	Nearest
Horizontal Flip	True

Augmentasi kemudian diterapkan pada data latih *pretraining* dan *fine-tuning*. Rincian Teknik augmentasi ditampilkan pada Tabel 4.

Tabel 4. Parameter Teknik Augmentasi Gambar

Teknik Augmentasi	Parameter
Rotasi	30°
Zoom	0.3
Brightness Range	0.6 – 1.4
Height Shift	0.2
Width Shift	0.2
Shear	0.3
Fill Mode	Nearest
Horizontal Flip	True

Setelah melalui proses augmentasi, jumlah data yang digunakan untuk pelatihan dan validasi pada tahap *pretraining* adalah sebanyak 3.621 citra untuk data latih dan 402 citra untuk data validasi. Sementara itu, pada tahap *fine-tuning* digunakan 1.403 citra untuk pelatihan, 352 citra untuk validasi dan 300 citra untuk pengujian.

4.4 Modelling

Tahap *modelling* dilakukan dengan menerapkan model *Convolutional Neural Network* (CNN) menggunakan arsitektur MobileNetV2 sebagai *feature extractor*. Pelatihan model dibagi menjadi dua tahap, yaitu *pretraining* dan *fine-tuning*. Pada tahap *pretraining*, arsitektur MobileNetV2 dimanfaatkan sebagai model dasar yang telah dilatih sebelumnya pada *dataset ImageNet*. Lapisan awalnya dibekukan untuk mempertahankan fitur umum yang telah dipelajari. Struktur detail arsitektur model pada tahap *pretraining* disajikan pada Tabel 5.

Tabel 5. Arsitektur Layer Model CNN

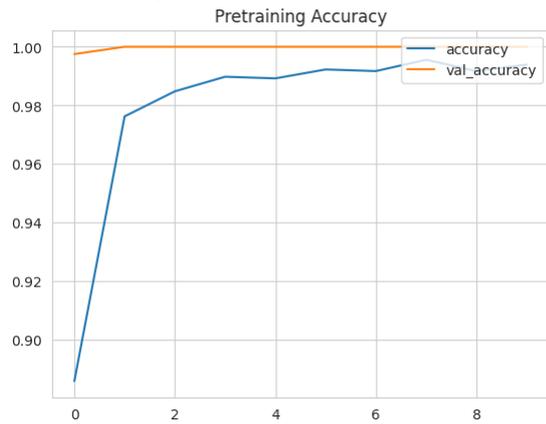
Layer	Output Shape	Aktivasi/ Keterangan
MobileNetV2 (<i>base model</i>)	7, 7, 1280	<i>Pretrained, frozen</i>
Global Average Pooling2D	1280	-
Dense	512	ReLU
BatchNormalization	512	-
Dropout	512	Rate = 0.5
Dense Layer (<i>Output Layer</i>)	1	Sigmoid

Proses pelatihan menggunakan konfigurasi optimasi seperti ditunjukkan pada Tabel 6.

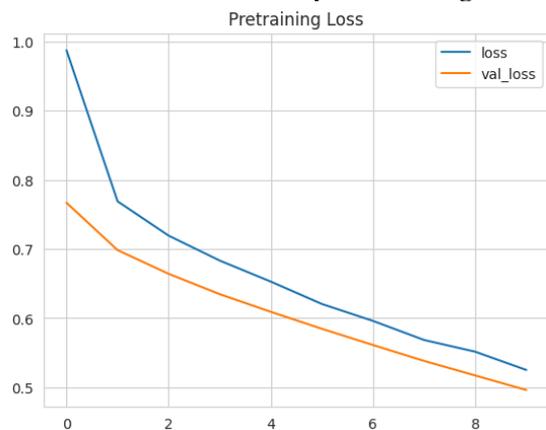
Tabel 6. Hyperparameter dan Konfigurasi Pelatihan

Parameter	Nilai
Loss Function	Binary Crossentropy
Optimizer	Adam
Learning Rate	0.0001 (1e-4)

Grafik hasil pelatihan tahap *pretraining* dapat dilihat pada Gambar 1 dan Gambar 2.



Gambar 1. Accuracy Pretraining



Gambar 2. Loss Pretraining

Gambar 1 memperlihatkan peningkatan nilai akurasi model pada data pelatihan dan validasi. Akurasi pada data validasi mencapai angka 100% sejak *epoch* pertama, menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data validasi. Di sisi lain, Gambar 2 menggambarkan penurunan nilai *loss* yang konsisten pada kedua data. Model berhasil mencapai akurasi sebesar 99,39% pada *training set* dan 100% pada *validation set*, dengan nilai *loss* sebesar 55,15% untuk *training set* dan 49,61% untuk *validation set*.

Hasil ini menunjukkan bahwa MobileNetV2 sebagai model dasar berhasil mengenali fitur visual utama dari *dataset* secara

efektif bahkan tanpa pelatihan tambahan yang kompleks. Kemampuan generalisasi yang tinggi sejak awal pelatihan kemungkinan besar disebabkan oleh kesamaan karakteristik visual dari gambar dalam *dataset*, serta sifat generalisasi fitur dasar dari *pretrained* model *ImageNet*. Namun, performa yang sangat tinggi sejak awal juga perlu diwaspadai sebagai potensi *overfitting*, meskipun grafik *loss* menunjukkan penurunan yang konsisten.

Setelah tahap *pretraining*, dilakukan tahap *fine-tuning* dengan membuka lapisan ke-80 hingga lapisan terakhir pada MobileNetV2 agar model dapat menyesuaikan terhadap fitur spesifik dari *dataset* lokal. Struktur detail model setelah pembukaan lapisan ditampilkan pada Tabel 7.

Tabel 7. Arsitektur Layer Model CNN *Fine-tuning*

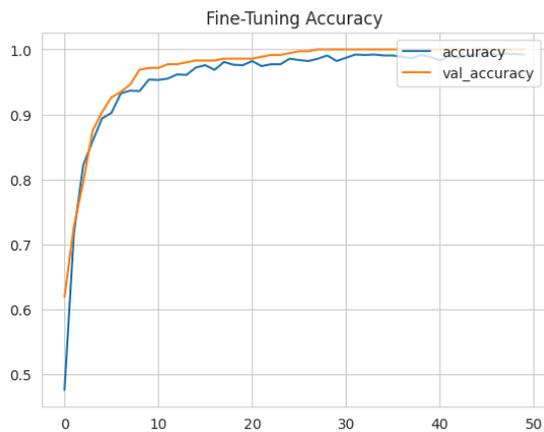
Layer	Output Shape	Aktivasi/ Keterangan
MobileNetV2 (layer ke-80 ke atas)	-	Dibuka untuk <i>fine tuning</i>
Global Average Pooling2D	1280	-
Dense	512	ReLU
BatchNormalizati on	512	-
Dropout	512	Rate = 0.5
Dense Layer (Output Layer)	1	Sigmoid

Konfigurasi pelatihan untuk tahap *fine-tuning* disajikan pada Tabel 8.

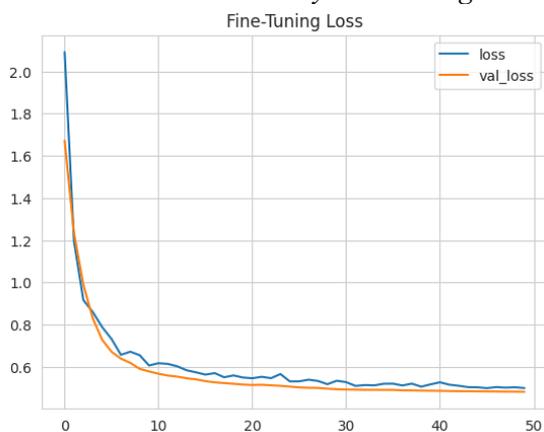
Tabel 8. Hyperparameter dan Konfigurasi *Fine-tuning*

Parameter	Nilai
Loss Function	Binary Crossentropy
Optimizer	Adam
Learning Rate	0.00001 (1e-5)

Grafik hasil pelatihan pada tahap *fine-tuning* ditunjukkan pada Gambar 3 dan Gambar 4.



Gambar 3. Accuracy Fine-tuning



Gambar 4. Loss Fine-tuning

Gambar 3 memperlihatkan peningkatan akurasi model secara konsisten seiring bertambahnya jumlah *epoch*, dengan akurasi validasi yang meningkat stabil hingga mendekati 100%. Hal ini menunjukkan bahwa model mampu menyesuaikan fitur-fitur lokal dari *dataset* dengan baik tanpa kehilangan kemampuan generalisasi. Gambar 4 memperlihatkan bahwa nilai *loss* pada data pelatihan dan validasi mengalami penurunan secara bertahap dan konsisten selama 50 *epoch* pelatihan. Akurasi terbaik dicapai pada *epoch* ke-48, di mana nilai *loss* validasi berada pada titik terendah, yang menandakan bahwa model tidak mengalami *overfitting*. Model mencapai akurasi sebesar 99,36% pada *training set* dan 100% pada *validation set*, dengan nilai *loss* sebesar 50,09% untuk *training set* dan 48,21% untuk *validation set*.

Temuan ini menunjukkan bahwa kombinasi arsitektur MobileNetV2 dan *fine-tuning* efektif untuk klasifikasi citra pada *dataset* lokal dengan kompleksitas sedang. Keberhasilan *fine-tuning* dari lapisan ke-80 ke atas mengindikasikan pentingnya

menyesuaikan *high-level feature representations* pada domain spesifik.

4.5 Evaluation

Setelah proses pelatihan model CNN dengan arsitektur MobileNetV2 selesai, langkah selanjutnya adalah melakukan evaluasi terhadap kinerja model menggunakan data uji. Evaluasi ini bertujuan untuk menilai kemampuan model dalam mengklasifikasikan citra ikan nila ke dalam dua kelas, yakni Segar dan Tidak Segar. Hasil klasifikasi awal divisualisasikan dalam *confusion matrix* berikut.



Gambar 5. Confusion Matrix

Berdasarkan *confusion matrix* tersebut diketahui bahwa 137 citra ikan nila Segar berhasil diklasifikasikan dengan benar sebagai Segar, 13 citra ikan nila Segar salah diklasifikasikan sebagai Tidak Segar, 4 citra ikan nila Tidak Segar salah diklasifikasikan sebagai Segar, dan 146 citra ikan nila Tidak Segar berhasil diklasifikasikan dengan benar sebagai Tidak Segar. Hasil tersebut kemudian digunakan untuk menghitung metrik evaluasi utama, yaitu *presisi*, *recall*, *F1-Score*, dan akurasi, yang ditampilkan dalam Tabel 9.

Tabel 9. Metrik Evaluasi

Kelas	Presisi	Recall	F1-Score	Akurasi
Segar	0.97	0.91	0.94	0.94
Tidak Segar	0.92	0.97	0.94	

Dari hasil evaluasi awal tersebut, dapat dilihat bahwa model memiliki presisi yang tinggi pada kelas Segar, menunjukkan bahwa prediksi ikan Segar cenderung akurat. Namun, nilai *recall* yang lebih tinggi pada kelas Tidak Segar menunjukkan bahwa model lebih andal dalam mendeteksi ikan yang Tidak Segar secara konsisten.

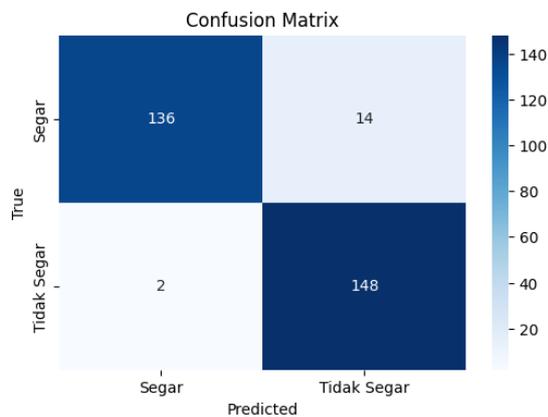
Dalam klasifikasi biner, penyesuaian nilai ambang batas (*threshold*) sangat penting. Dalam konteks klasifikasi tingkat kesegaran ikan, karena kesalahan dalam mengklasifikasikan ikan Tidak Segar sebagai Segar dapat menimbulkan permasalahan yang lebih serius, seperti risiko Kesehatan atau penurunan kualitas produk perikanan.

Threshold default pada umumnya adalah 0.5, namun dalam konteks ini, pengujian dilakukan dengan menurunkan *threshold* untuk mengoptimalkan performa model, khususnya dalam menekan kesalahan klasifikasi kritikal. Setelah dilakukan *tuning*, diperoleh *threshold* sebesar 0.4, yang menghasilkan perbaikan pada seluruh metrik evaluasi seperti ditunjukkan pada Tabel 10.

Tabel 10. Metrik Evaluasi Setelah *Threshold Tuning*

Kelas	Presisi	Recall	F1-Score	Akurasi	Best Threshold
Segar	0.99	0.91	0.94	0.95	0.4
Tidak Segar	0.91	0.99	0.95		

Tuning threshold berhasil meningkatkan akurasi keseluruhan dari 0.94 menjadi 0.95, dengan peningkatan pada *recall* kelas Tidak Segar menjadi 0.99, yang sangat penting dalam sistem ini.



Gambar 6. Confusion Matrix Setelah *Threshold Tuning*

Hasil *confusion matrix* setelah *tuning* menunjukkan penurunan jumlah kesalahan klasifikasi, khususnya dalam hal *false negative* pada kelas Tidak Segar.

Nilai *recall* yang tinggi pada kelas Tidak Segar menunjukkan bahwa model sangat andal dalam mengenali kondisi ikan yang Tidak Segar. Dalam industri perikanan, klasifikasi yang salah terhadap ikan Tidak Segar dapat

berdampak langsung terhadap kesehatan konsumen dan kepercayaan pasar.

Beberapa hasil deteksi terhadap citra ikan nila dalam kondisi segar maupun tidak segar dapat dilihat pada Tabel 11.

Tabel 11. Hasil Pengujian Model

Citra Uji	Kondisi	Hasil Uji
	Segar	Segar
	Tidak Segar	Tidak Segar
	Tidak Segar	Tidak Segar

Citra Uji	Kondisi	Hasil Uji
	Tidak Segar	Tidak Segar
	Tidak Segar	Tidak Segar
	Tidak Segar	Tidak Segar
	Tidak Segar	Tidak Segar

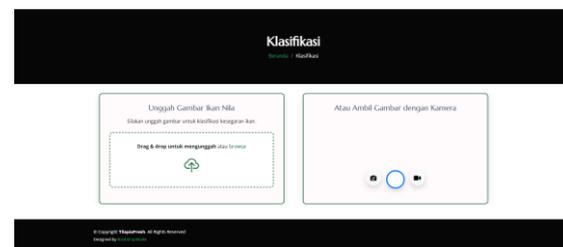
Hasil klasifikasi menunjukkan bahwa sebagian besar citra berhasil diprediksi dengan benar oleh model. Namun, masih terdapat beberapa kesalahan klasifikasi, salah satu faktor yang mempengaruhi hasil prediksi adalah perbedaan kualitas citra, seperti format gambar yang tidak segaram, variasi latar belakang, pencahayaan yang kurang optimal, serta jarak pengambilan gambar yang bervariasi. Faktor-faktor ini dapat mempengaruhi ekstraksi fitur oleh model CNN dan mengurangi akurasi prediksi.

4.6 Deployment

Setelah diperoleh model CNN terbaik berdasarkan hasil evaluasi, langkah selanjutnya adalah melakukan mengintegrasikan model ke dalam sistem nyata. Dalam penelitian ini, model diimplementasikan ke dalam sebuah sistem berbasis *website* menggunakan *framework* Flask.

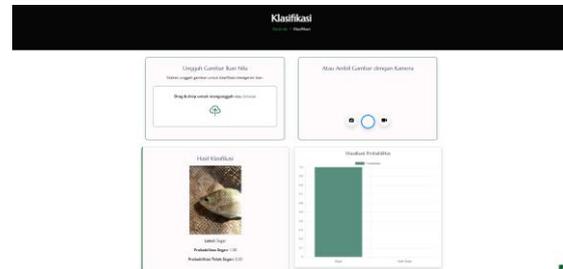


Gambar 7. Tampilan Beranda
Gambar menunjukkan halaman beranda yang menampilkan informasi umum mengenai sistem deteksi kesegaran ikan nila.



Gambar 8. Halaman Deteksi Kesegaran
Ketika pengguna mengklik tombol “Mulai”, sistem akan mengarahkan ke halaman utama deteksi kesegaran ikan nila seperti yang ditunjukkan pada Gambar. Pada halaman ini, pengguna diberikan dua opsi dalam memasukkan citra ikan, yaitu mengunggah gambar dari perangkat lokal dan mengambil gambar langsung melalui kamera.

Setelah gambar diunggah, sistem akan menampilkan hasil klasifikasi yang terdiri dari label prediksi kesegaran Segar atau Tidak Segar, nilai probabilitas masing-masing kelas dan grafik visual probabilitas yang memberikan Gambaran tingkat keyakinan model terhadap prediksi yang diberikan. Contoh hasil gambar yang berhasil diunggah ditunjukkan pada Gambar.



Gambar 9. Hasil Deteksi Kesegaran



Gambar 10. Halaman Informasi
Gambar merupakan informasi mengenai latar belakang serta tujuan dari pengembangan sistem,



Gambar 11. Halaman Detail

Gambar merupakan halaman detail yang menampilkan indikator *visual* yang digunakan dalam mendeteksi kesegaran ikan nila, serta karakteristik kesegaran dari masing-masing bagian tersebut.

5. KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa model *Convolutional Neural Network* (CNN) berbasis arsitektur *MobileNetV2* berhasil dikembangkan untuk mengklasifikasikan tingkat kesegaran ikan nila secara otomatis dengan performa yang baik. Model dilatih dalam dua tahap, yaitu *pretraining* dengan data Kaggle dan *fine-tuning* dengan *data private*, sehingga menghasilkan akurasi akhir sebesar 95% setelah dilakukan penyesuaian *threshold* sebesar 0.4. Evaluasi menggunakan *confusion matrix* serta metrik akurasi, presisi, *recall*, dan *F1-Score* menunjukkan peningkatan kinerja model setelah dilakukan *tuning threshold*, terutama dalam mengurangi kesalahan klasifikasi pada ikan yang tidak segar. Sistem ini juga telah berhasil diimplementasikan dalam bentuk aplikasi berbasis *web* yang dapat mengklasifikasikan kesegaran ikan nila dari citra yang diunggah pengguna. Meskipun demikian, masih terdapat beberapa kelemahan, seperti kesalahan klasifikasi dan deteksi yang disebabkan oleh variasi kualitas citra, latar

belakang, pencahayaan, serta sudut pengambilan gambar.

Untuk pengembangan lebih lanjut, disarankan agar *dataset* diperluas dengan lebih banyak variasi kondisi pencitraan, diterapkan teknik augmentasi dan *preprocessing* yang lebih beragam, serta dikombinasikan dengan teknik segmentasi citra seperti U-Net atau Mask R-CNN untuk meningkatkan akurasi dan fokus deteksi pada objek utama.

UCAPAN TERIMA KASIH

Penulis mengucapkan rasa syukur kepada Allah SWT. atas rahmat dan karunia-Nya, sehingga penelitian ini dapat diselesaikan dengan baik. Ucapan terima kasih juga disampaikan kepada orang tua serta semua pihak yang telah memberikan dukungan dan kontribusi selama proses pelaksanaan penelitian ini.

DAFTAR PUSTAKA

- [1] C. Cakra, S. Syarif, H. Gani, dan A. Patombongi, "Analisis Kesegaran Ikan Mujair Dan Ikan Nila Dengan Metode Convolutional Neural Network," *Simtek J. Sist. Inf. dan Tek. Komput.*, vol. 7, no. 2, hal. 74–79, 2022, doi: 10.51876/simtek.v7i2.138.
- [2] Pirmansyah Pirmansyah, Novita MZ, dan Arif Supendi, "Efektivitas Pencampuran Ekstrak Daun Kelor (*Moringa Oleifera*) yang Difermentasi Menggunakan *Aspergillus Niger* pada Pakan Buatan Terhadap Laju Pertumbuhan Ikan Nila (*Oreochromis Niloticus*)," *Manfish J. Ilm. Perikan. dan Peternak.*, vol. 2, no. 2, hal. 154–165, 2024, doi: 10.62951/manfish.v2i2.60.
- [3] F. R. Safsafubun, S. L. Undap, I. R. N. Salindeho, N. P. L. Pangemanan, W. J. Ch., dan H. Pangkey, "Fluktuasi Parameter Kualitas Air dan Perkembangan Flok Pada Budidaya Ikan Nila (*Oreochromis Niloticus*) Dengan Sistem Bioflok di BPBAT Telelu," *Budid. Perair.*, vol. 11, no. 2, hal. 213–226, 2023, doi: 10.14341/cong23-26.05.23-39.
- [4] Kementerian Kelautan dan Perikanan, "No Title," 2024, 2024. <https://kkp.go.id/news/news-detail/melihat-budidaya-ikan-nila-salin-yang-diresmikan-presiden-jokowi.html>.
- [5] Badan Standarisasi Nasional, "Ikan Segar," 2013. <https://jp2gi.org/public/docs/report/Standar Nasional Indonesia Ikan Segar-5ef96833e811d.pdf>.
- [6] S. Suprianto, D. S. Lestari, dan O. H. Simung, "Aplikasi Penentuan Kesegaran Ikan Bandeng Menggunakan Metode Convolution Neural

- Network,” *Insect (Informatics Secur. J. Tek. Inform.*, vol. 8, no. 2, hal. 77–86, 2023, doi: 10.33506/insect.v8i2.2196.
- [7] C. R. Gunawan, N. Nurdin, dan F. Fajriana, “Deteksi Ikan Segar Secara Realtime dengan YOLOv4 menggunakan Metode Convolutional Neural Network,” *J. Komtika (Komputasi dan Inform.*, vol. 7, no. 1, hal. 1–11, 2023, doi: 10.31603/komtika.v7i1.8986.
- [8] R. Faurina dan R. Mahendra, “Fish Freshness Prediction With Convolutional Neural Network Method Based on Fish Eye Image Analysis,” *J. Tek. Inform.*, vol. 5, no. 3, hal. 883–890, 2024.
- [9] S. Saputra dkk., “Identifikasi Kesegaran Ikan Menggunakan Algoritma KNN Berbasis Citra Digital,” vol. 10, no. 1, hal. 1–9, 2022, doi: 10.32832/kreatif.v10i1.6845.
- [10] V. T. Deco, A. Nilogiri, dan Q. A’yun, “Klasifikasi Kesegaran Ikan Lemuru Berdasarkan Citra Mata Menggunakan Metode Convolutional Neural Network,” *J. Apl. Sist.*, vol. 3, no. 1, hal. 14–25, 2021, [Daring]. Tersedia pada: <http://jurnal.unmuhjember.ac.id/index.php/JASIE/article/view/9159>.
- [11] R. Windiawan dan A. Suharso, “Identifikasi Penyakit pada Daun Kopi Menggunakan Metode Deep Learning VGG16,” *Exploreit*, vol. 13, no. 2, hal. 9–16, 2021, [Daring]. Tersedia pada: <https://doi.org/10.35891/explorit>.
- [12] H. A. Pratiwi, M. Cahyanti, dan M. Lamsani, “Implementasi Deep Learning Flower Scanner Menggunakan Metode Convolutional Neural Network,” *Sebatik*, vol. 25, no. 1, hal. 124–130, 2021, doi: 10.46984/sebatik.v25i1.1297.
- [13] E. H. Pujiarini dan F. N. Lenti, “Convolution Neural Network Untuk Identifikasi Tingkat Kesegaran Ikan Nila Berdasarkan Perubahan Warna Mata,” *J. Khatulistiwa Inform.*, vol. 11, no. 1, hal. 21–25, 2023, doi: 10.31294/jki.v11i1.14305.
- [14] Z. L. R. Nafi dan M. S. Hidayatullah, “Deteksi Kesegaran Ikan Nila Menggunakan Convolutional Neural Networks Berbasis Citra Digital,” *JIMU J. Ilm. Multi Disiplin*, vol. 02, no. 03, hal. 608–615, 2024.
- [15] V. A. Aldianto, “Tingkat Kesegaran Ikan,” *AGROTERAP J. Agroindustri dan Agribisnis*, vol. 1, no. 1, hal. 1–14, 2022, doi: <https://doi.org/10.30996/agro.v1i1.8590>.
- [16] M. Mardiani, “Identifikasi Kesegaran Ikan dengan Metode Convolutional Neural Network Berbasis Android,” Universitas Hasanuddin, 2023.
- [17] M. Sholihin, M. R. Zamroni, dan B. Burhanuddin, “Identifikasi Kesegaran Ikan Berdasarkan Citra Insang dengan Metode Convolution Neural Network,” *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 8, no. 3, hal. 1352–1360, 2021, doi: 10.35957/jatisi.v8i3.939.
- [18] M. A. Mulya dan Z. Arif, “Journal of Computer Science and Technology Tinjauan Pustaka Sistematis : Penerapan Metode Gabor Wavelet Pada Computer Vision,” vol. 1, hal. 83–88, 2023.
- [19] D. S. Ariansyah dan D. S. Ariansyah, “Pendeteksi Kata Dalam Bahasa Isyarat Menggunakan Algoritma Yolo Versi 8,” *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, 2024, doi: 10.23960/jitet.v12i3.4904.
- [20] J. Nurhakiki dan Y. Yahfizham, “Studi Kepustakaan: Pengenalan 4 Algoritma Pada Pembelajaran Deep Learning Beserta Implikasinya,” *J. Pendidik. Berkarakter*, vol. 2, no. 1, hal. 270–281, 2024, [Daring]. Tersedia pada: <https://doi.org/10.51903/pendekar.v2i1.598>.
- [21] M. Christiawan, L. W. Santoso, dan D. H. Setiabudi, “Deteksi Tingkat Kesegaran Ikan Menggunakan Metode Convolutional Neural Network Dengan Parameter Mata dan Warna Insang,” *J. Infra*, vol. 9, no. 2, hal. 213–219, 2021.
- [22] R. Bagaskara, A. Khairunnisa Rizkita, R. Fernandes, dan W. Yulita, “Pendetections Jumlah Bangunan Berbasis Citra Menggunakan Metode Deep Learning,” *J. Sains Komput. Inform. (J-SAKTI)*, vol. 6, no. 1, hal. 94–100, 2022.
- [23] I. F. Annur, J. Umami, M. N. Annafii, N. Trisnaningrum, dan O. V. Putra, “Klasifikasi Tingkat Keparahan Penyakit Leafblast Tanaman Padi Menggunakan MobileNetv2,” *Fountain Informatics J.*, vol. 8, no. 1, hal. 7–14, 2023, doi: 10.21111/fj.v8i1.9419.
- [24] I. Guntoro, D. M. Midyanti, dan R. Hidayati, “Penerapan Dropout Pada Jaringan Saraf Tiruan Backpropagation Dalam Mengklasifikasi Tingkat Fine Fuel Moisture Code (Ffmc) Untuk Kebakaran Hutan Dan Lahan,” *Coding J. Komput. dan Apl.*, vol. 10, no. 01, hal. 114, 2022, doi: 10.26418/coding.v10i01.52734.
- [25] D. F. Ningtyas dan N. Setiyawati, “Implementasi Flask Framework pada Pembangunan Aplikasi Purchasing Approval Request,” *J. Janitra Inform. dan Sist. Inf.*, vol. 1, no. 1, hal. 19–34, 2021, doi: 10.25008/janitra.v1i1.120.
- [26] D. A. Saputra, I. Istiadi, dan A. Y. Rahman, “Deteksi Kesegaran Ikan Layur Berdasarkan Citra Mata Menggunakan YOLOV8,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 8, no. 5, hal. 10263–10270, 2024.
- [27] P. A. Nugroho, I. Fenriana, dan R. Arijanto, “Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) Pada

Ekspresi Manusia,” *Algor*, vol. 2, no. 1, hal. 12–21, 2020.

- [28] N. J. Hayati, D. Singasatia, dan M. R. Muttaqin, “Object Tracking Menggunakan Algoritma You Only Look Once (YOLO)v8 untuk Menghitung Kendaraan,” *Komputa J. Ilm. Komput. dan Inform.*, vol. 12, no. 2, hal. 91–99, 2023, doi: 10.34010/komputa.v12i2.10654.