



## Sistem Identifikasi Kesegaran Ikan Berbasis Android Menggunakan Convolutional Neural Network (CNN)

Justam<sup>1</sup>, Muh. Nashir Takbir<sup>2</sup>, Sitti Mawaddah Umar<sup>3</sup>, Erlita<sup>4</sup>, Revah Oktria Lewa<sup>5</sup>

Program Studi Informatika, Universitas Mega Buana Palopo<sup>1,5</sup>,

Program Studi Sistem Informasi, Universitas Mega Buana Palopo<sup>2</sup>,

Program Studi Manajemen Infomasi Kesehatan, Politeknik Kesehatan megarezky<sup>3</sup>,

Program Studi Sistem Informasi, Institut Teknologi Pendidikan dan Bisnis (ITPB) Qana'ah Sidenreng Rappang<sup>4</sup>,

Jl. Andi Ahmad No. 25, Wara Utara, 91913, Kota Palopo, Sulawesi Selatan, Indonesia

justam@umegabuana.ac.id\*<sup>1</sup>, nashirtakbir@umegabuana.ac.id<sup>2</sup>, Sittimawaddahumar05@gmail.com<sup>3</sup>,

erlitazainddin3@gmail.com<sup>4</sup>, revahoktrial@gmail.com<sup>5</sup>

### Kata Kunci :

Kesegaran Ikan;  
Convolutional  
Neural Network  
(CNN);  
TensorFlow Lite;  
Pengolahan  
Citra;  
Android.

### ABSTRAK

Ikan merupakan sumber protein hewani penting dengan kandungan vitamin dan mineral esensial yang tinggi. Sebagai negara kepulauan, Indonesia memiliki potensi perikanan yang besar, namun masih banyak masyarakat yang kesulitan membedakan ikan segar dan tidak segar. Penelitian ini mengembangkan sistem berbasis Android untuk mengidentifikasi kesegaran ikan menggunakan Convolutional Neural Network (CNN). Model dilatih dengan 540 sampel gambar dalam tiga kategori (segar, baik, dan tidak layak) dengan resolusi  $256 \times 256$  piksel RGB. CNN yang digunakan terdiri dari tiga lapisan konvolusi dan dua fully connected layer, dengan optimizer Adam dan fungsi aktivasi ReLU serta Softmax. Model dilatih di Google Colaboratory, lalu dikonversi ke TensorFlow Lite untuk diterapkan pada Android. Hasil pengujian menunjukkan akurasi 98% pada data uji dan 96,67% pada aplikasi Android dengan 60 sampel baru, membuktikan sistem mampu berfungsi dengan baik dalam mengidentifikasi kesegaran ikan.

### Keywords

Fish Freshness;  
Convolutional  
Neural Network  
(CNN);  
TensorFlow Lite;  
Image  
Processing;  
Android.

### ABSTRACT

Fish is an essential source of animal protein with high levels of vitamins and essential minerals. As an archipelagic country, Indonesia has vast fisheries potential; however, many people still struggle to distinguish between fresh and non-fresh fish. This study develops an Android-based system to identify fish freshness using Convolutional Neural Network (CNN). The model was trained using 540 image samples classified into three categories (fresh, good, and unfit) with a resolution of  $256 \times 256$  RGB pixels. The CNN architecture consists of three convolutional layers and two fully connected layers, utilizing the Adam optimizer and ReLU and Softmax activation functions. The model was trained in Google Colaboratory and later converted into TensorFlow Lite for Android deployment. Experimental results showed 98% accuracy on test data and 96.67% accuracy on an Android application using 60 new samples, demonstrating the system's effectiveness in identifying fish freshness.

---Jurnal JISTI @2024---

## PENDAHULUAN

Ikan merupakan salah satu sumber protein hewani yang memiliki nilai gizi tinggi setelah daging, susu, dan telur. Berbagai penelitian telah mengidentifikasi ikan dan hasil laut lainnya sebagai sumber kaya vitamin dan mineral esensial yang berperan penting dalam kesehatan manusia. Selain itu, ikan mengandung asam lemak rantai panjang omega-3 (DHA) dan omega-6, yang memiliki peran krusial



dalam pertumbuhan serta kesehatan tubuh (Dewi et al., 2018). Sebagai negara kepulauan, Indonesia memiliki potensi sumber daya perikanan yang sangat besar (Prameswari, 2018). Salah satu daerah dengan produksi ikan terbesar di Indonesia adalah Sulawesi Selatan. Data dari Dinas Kelautan dan Perikanan Provinsi Sulawesi Selatan (2020) menunjukkan bahwa ikan layang menempati urutan pertama dengan jumlah produksi mencapai 38.307,1 ton, diikuti oleh ikan cakalang, ikan kembung/banjar, ikan selar, dan ikan tembang.

Berdasarkan laporan Kementerian Kelautan dan Perikanan (KKP, 2020), angka konsumsi ikan nasional mencapai 56,39 kg/kapita, meningkat sebesar 3,47% dibandingkan tahun sebelumnya (54,5 kg/kapita). Hal ini mencerminkan tingginya konsumsi ikan di Indonesia (Ailima, 2022). Namun, permasalahan yang masih dihadapi adalah kurangnya pemahaman masyarakat dalam membedakan ikan segar dan tidak segar, terutama di kalangan generasi muda yang memiliki pengalaman terbatas dalam memilih ikan berkualitas baik (Arrofiqoh, et al., 2018).

Menurut Standar Nasional Indonesia (SNI) tentang Ikan Segar, tingkat kesegaran ikan dapat diidentifikasi melalui berbagai parameter visual, termasuk kondisi mata dan insang, aroma, serta tekstur daging ikan. Konsumsi ikan segar sangat penting untuk menjaga kualitas gizi yang optimal. Sebaliknya, ikan yang sudah mengalami proses pembusukan tidak hanya mengalami penurunan nilai gizi, tetapi juga berpotensi menyebabkan gangguan kesehatan seperti keracunan makanan akibat kontaminasi bakteri patogen (Kompas, 2020). Oleh karena itu, dibutuhkan metode yang efektif untuk mengidentifikasi kesegaran ikan secara akurat dan efisien.

Dalam perkembangan teknologi saat ini, Artificial Intelligence (AI) telah banyak digunakan untuk membantu analisis data berbasis gambar, termasuk dalam bidang pengolahan citra digital. AI memungkinkan sistem untuk belajar dari data gambar dan menghasilkan keputusan secara otomatis (Dahira, 2008). Salah satu metode AI yang banyak digunakan dalam klasifikasi citra adalah Convolutional Neural Network (CNN). CNN telah terbukti memiliki kinerja yang baik dalam analisis gambar dan pengenalan pola, termasuk dalam deteksi kesegaran ikan.

Beberapa penelitian terdahulu telah membuktikan efektivitas CNN dalam mendeteksi kesegaran ikan. Penelitian yang dilakukan oleh Peryanto et al. (2020) mengembangkan sistem deteksi kesegaran ikan bandeng berdasarkan citra mata ikan menggunakan berbagai arsitektur CNN, di mana model VGG16 mencapai akurasi terbaik sebesar 97%. Sementara itu, penelitian oleh Sianturi (2021) yang menggunakan CNN untuk menganalisis insang ikan mujair menghasilkan akurasi 80%. Kedua penelitian tersebut menunjukkan bahwa CNN dapat digunakan sebagai metode yang andal dalam klasifikasi kesegaran ikan. Namun, penelitian sebelumnya masih berfokus pada satu parameter, baik mata maupun insang ikan, tanpa menggabungkan keduanya.

Berdasarkan penelitian terdahulu, penelitian ini akan berfokus pada pengembangan sistem identifikasi kesegaran ikan dengan menggunakan CNN berbasis Android. Studi ini akan menggunakan tiga jenis ikan dengan tingkat produksi tinggi di Sulawesi Selatan, yaitu ikan layang, ikan kembung/banjar, dan ikan tembang. Identifikasi kesegaran akan dilakukan dengan menganalisis bagian mata dan insang ikan (dengan kondisi penutup insang terbuka). Selain itu, sistem yang dikembangkan akan dikonversi ke dalam format *TensorFlow Lite* untuk diterapkan pada perangkat Android, sehingga lebih mudah digunakan oleh masyarakat luas.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan sistem berbasis CNN yang mampu mengidentifikasi kesegaran ikan secara otomatis dengan akurasi tinggi serta dapat diakses melalui perangkat Android.



## KAJIAN PUSTAKA

### 1. Ikan dan Kesegaran Ikan

Ikan merupakan salah satu sumber protein hewani yang memiliki kandungan vitamin dan mineral esensial tinggi serta mengandung asam lemak rantai panjang omega-3 (DHA) dan omega-6 yang bermanfaat bagi kesehatan manusia (Dewi et al., 2018). Namun, salah satu tantangan utama dalam konsumsi ikan adalah sifatnya yang mudah mengalami penurunan mutu dan pembusukan akibat faktor internal maupun eksternal, seperti aktivitas bakteri, enzim, dan oksidasi (Suprayitno, 2020).


### 2. Artificial Intelligence dalam Pengolahan Citra

Artificial Intelligence (AI) merupakan cabang ilmu komputer yang memungkinkan mesin meniru kemampuan berpikir manusia, termasuk dalam pengolahan citra digital (Dahira, 2008). AI dapat digunakan untuk membantu manusia dalam proses analisis citra, termasuk mendeteksi kesegaran ikan secara otomatis (Brownlee, 2018).

### 3. Deep Learning dan Convolutional Neural Network (CNN)

Deep Learning merupakan teknik dalam Artificial Neural Network (ANN) yang menggunakan lapisan jaringan saraf tiruan berlapis-lapis untuk meningkatkan akurasi prediksi (Nugroho, 2020). Salah satu algoritma deep learning yang efektif dalam analisis citra adalah *Convolutional Neural Network* (CNN). CNN bekerja dengan mengekstraksi fitur dari gambar melalui beberapa lapisan utama.

Beberapa penelitian telah menunjukkan efektivitas CNN dalam mendeteksi kesegaran ikan. Studi oleh Prasetyo et al. (2021) menunjukkan bahwa model VGG16 berhasil mencapai akurasi 97% dalam mendeteksi kesegaran ikan bandeng berdasarkan citra mata ikan. Sementara itu, penelitian oleh Sianturi (2021) menunjukkan bahwa CNN dapat mencapai akurasi 80% dalam menganalisis insang ikan mujair.



**Gambar 1.** Struktur CNN

### 4. K-Fold Cross Validation dan Confusion Matrix

Dalam evaluasi model machine learning, metode *K-Fold Cross Validation* sering digunakan untuk meningkatkan keandalan model. Teknik ini membagi dataset menjadi beberapa bagian (*fold*) dan melatih model sebanyak K kali untuk mendapatkan hasil evaluasi yang lebih stabil (Brownlee, 2018). Selain itu, Confusion Matrix digunakan untuk menilai performa model berdasarkan empat parameter utama:

- a. True Positive (TP): Model berhasil memprediksi kelas positif dengan benar.
- b. True Negative (TN): Model berhasil memprediksi kelas negatif dengan benar.
- c. False Positive (FP): Model salah mengklasifikasikan kelas negatif sebagai positif.
- d. False Negative (FN): Model salah mengklasifikasikan kelas positif sebagai negatif.

Akurasi model dihitung dengan rumus:

$$Accuracy = \frac{(TP+TN)}{(TP+TN+FP+FN)} \times 100\% \quad (1)$$

		Actual Values	
		1 (Positive)	0 (Negative)
Predicted Values	1 (Positive)	TP (True Positive)	FP (False Positive) <small>Type I Error</small>
	0 (Negative)	FN (False Negative)	TN (True Negative)



**Gambar 2.** model Confusion Matrix

## 5. TensorFlow dan TensorFlow Lite

*TensorFlow* merupakan framework *opensource* yang dikembangkan oleh Google untuk membangun dan melatih model *machine learning*, terutama dalam bidang *deep learning* (Abadi et al., 2016). *TensorFlow* mendukung eksekusi pada berbagai perangkat, termasuk CPU, GPU, dan *Tensor Processing Units* (TPUs).

Untuk implementasi pada perangkat mobile, *TensorFlow Lite* digunakan sebagai versi ringan dari *TensorFlow* (Carey, 2019). *TensorFlow Lite* memungkinkan model *deep learning* dijalankan secara efisien pada Android dan iOS, mendukung akselerasi menggunakan *Android Neural Networks API* (NNAPI), serta dapat berjalan tanpa memerlukan koneksi ke server eksternal.

## 6. Android Studio dalam Pengembangan Aplikasi

Android Studio merupakan *Integrated Development Environment* (IDE) resmi untuk pengembangan aplikasi Android (Duckworth, et al 2019). IDE ini menyediakan berbagai fitur seperti *Gradle based build system*, *emulator Android*, serta integrasi dengan *Google Cloud Platform* untuk mendukung pengembangan aplikasi berbasis AI dan *machine learning* (Gardy, et al, 2019).

## METODE PENELITIAN

### 1. Tahapan Penelitian

Penelitian ini terdiri dari beberapa tahapan utama yang diawali dengan studi literatur, di mana peneliti mengumpulkan referensi terkait *Convolutional Neural Network* (CNN) serta implementasinya dalam aplikasi Android (Jauhari, A. Fuad. 2022). Tahap selanjutnya adalah penentuan metode, di mana penelitian ini menggunakan pendekatan *CNN from scratch*, yang kemudian dikonversi ke *TensorFlow Lite* untuk mendukung implementasi pada perangkat Android. Pada tahap pengumpulan dataset, citra ikan diperoleh langsung dari nelayan di Sumpang Minangae, Kota Parepare, dengan teknik pemotretan standar menggunakan kamera Samsung Galaxy M31 dan tripod.

Setelah data dikumpulkan, tahap desain dan perancangan sistem dilakukan dengan membangun model berbasis CNN menggunakan *Python* (*TensorFlow*) serta mengembangkan aplikasi Android menggunakan Android Studio. Selanjutnya, sistem yang telah dikembangkan diuji melalui tahap analisis kinerja sistem, di mana performa model dievaluasi menggunakan *Confusion Matrix* untuk menilai akurasi dan efektivitas model (Kim, J., et al. 2016). Akhirnya, hasil penelitian didokumentasikan dalam tahap penyusunan laporan, yang akan digunakan sebagai bahan publikasi ilmiah serta referensi untuk penelitian lebih lanjut.



## 2. Teknik Pengumpulan Data

Dataset terdiri dari 600 citra ikan, dengan 540 citra digunakan untuk pelatihan model dan 60 citra untuk pengujian pada aplikasi Android. Data diperoleh melalui pengambilan gambar ikan yang berfokus pada mata dan insang, dilakukan setiap 2 jam sekali hingga 12 jam dalam ruang tertutup dengan pencahayaan terkontrol.

## 3. Metode Perancangan Sistem

Sistem ini dikembangkan untuk mengidentifikasi kesegaran ikan menggunakan *TensorFlow Lite* pada Android (Kholik, A. 2021). Prosesnya mencakup data *preparation*, *training*, dan *testing*, sebelum model dikonversi ke *TensorFlow Lite*. *Data preparation* melibatkan cropping dan normalisasi RGB (0–1), dengan dataset terbagi 60% *training*, 20% *validation*, dan 20% *testing*.

Model CNN terdiri dari tiga *convolutional layer* dan dua *fully connected layer*, dengan batch size 32, *optimizer Adam*, serta fungsi aktivasi ReLU dan *Softmax*. Pengujian menggunakan epoch 10, 20, dan 30, dievaluasi dengan *K-Fold Cross Validation* (K=4) dan *Confusion Matrix*. Model terbaik dikonversi ke *TensorFlow Lite* untuk implementasi efisien di *Android Studio*.

## 4. Pengujian Sistem

*Testing Model* dilakukan pada *Google Colaboratory* sebelum dikonversi ke *TensorFlow Lite*. *Testing* Aplikasi Android pengujian dilakukan menggunakan gambar baru yang tidak termasuk dalam dataset pelatihan untuk menguji keakuratan model dalam kondisi *real world*. Evaluasi Hasil Prediksi menggunakan *Confusion Matrix* untuk mengukur akurasi, recall, dan precision (Kushilevitz, E., et al., 2016).


## 5. Implementasi Aplikasi

Aplikasi berbasis Android dibangun untuk memungkinkan pengguna menginput gambar ikan melalui kamera atau galeri, lalu sistem akan melakukan identifikasi dan menampilkan prediksi tingkat kesegaran ikan beserta persentase akurasinya.


## HASIL DAN PEMBAHASAN

### 4.1 Hasil Training Model


Penelitian ini mengembangkan sistem identifikasi kesegaran ikan berbasis *Convolutional Neural Network (CNN)* dengan tiga kelas: segar, baik, dan tidak layak. Model CNN dilatih menggunakan 60% data training dan 20% data validation, kemudian diuji dengan 20% data testing.



Gambar 3. Pengujian epoch 10



Gambar 4. Pengujian epoch 20



Gambar 5. Pengujian epoch 30





Gambar 3, gambar 4, dan gambar 5, menunjukkan hasil pelatihan model menggunakan epoch 10, 20, dan 30, dengan evaluasi berdasarkan akurasi (acc) dan loss untuk data training (train) dan validasi (val). Nilai akurasi mengukur tingkat keberhasilan model, sementara loss menunjukkan tingkat error yang dihasilkan. Pada epoch 10, akurasi train mencapai 93,75% dan validation 92,71%, dengan nilai loss yang terus menurun hingga 0,1977 pada data test. Pada epoch 20, akurasi model meningkat signifikan, dengan 99,43% pada train dan 100% pada validation, serta loss 0,0403 pada data test. Epoch 30 menghasilkan akurasi 100% pada train, validation, dan test, dengan loss terkecil 0,0057. Meskipun akurasi tertinggi dicapai pada epoch 30, potensi overfitting lebih tinggi dibandingkan epoch 20, yang menunjukkan keseimbangan optimal antara akurasi dan generalisasi model.

## 4.2 Hasil Training K-Fold Cross Validation

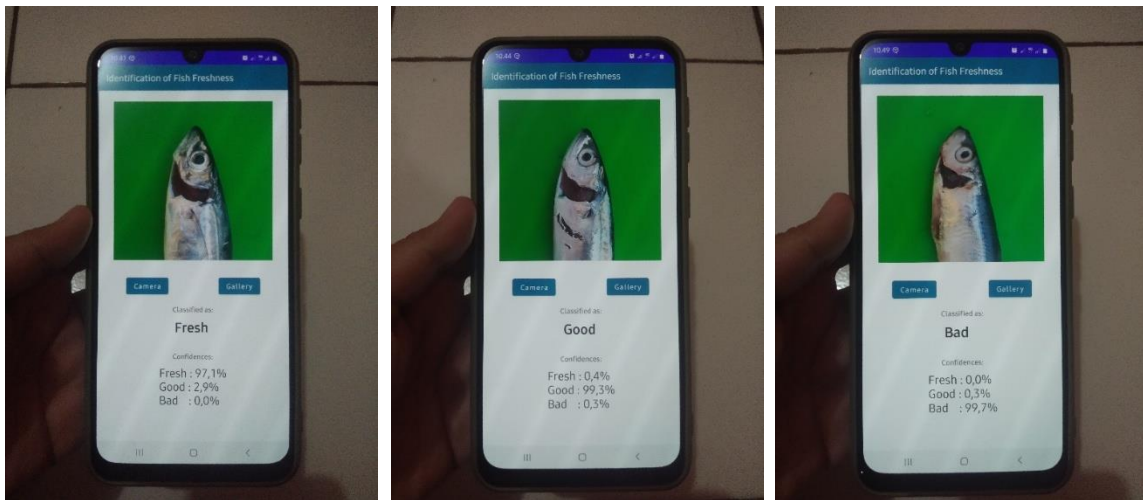
Tabel 1. Akurasi dan Loss dengan 4-Fold Cross Validation

Epoch	Iterasi Ke	Akurasi	Loss
10	1	91,85%	0.1982
	2	87,41%	0.2615
	3	90,37%	0.2442
	4	84,44%	0.3761
20	1	97,04%	0.0850
	2	91,85%	0.2049
	3	94,81%	0.1242
	4	93,33%	0.2065
30	1	94,81%	0.1752
	2	93,33%	0.1567
	3	94,81%	0.1887
	4	92,59%	0.2116

Berdasarkan tabel 1, hasil *K-Fold Cross Validation* (K=4), pada epoch 10, model terbaik diperoleh pada iterasi pertama dengan akurasi 91,85% dan loss 0,1982, sedangkan akurasi terendah terjadi pada iterasi keempat sebesar 84,44% (loss 0,3761). Pada epoch 20, iterasi pertama juga menghasilkan model terbaik dengan akurasi 97,04% dan loss 0,0850, sementara iterasi kedua memiliki akurasi terendah 91,85% (loss 0,2049). Untuk epoch 30, iterasi pertama dan ketiga mencapai akurasi 94,81%, namun model terbaik dipilih dari iterasi pertama karena memiliki loss terendah 0,1752, sedangkan akurasi terendah terjadi pada iterasi keempat sebesar 92,59% (loss 0,2116).

## 4.3 Hasil Testing Menggunakan Android

Pengujian dilakukan dengan 60 sampel citra baru (20 per kelas), menggunakan kamera (10 citra) dan galeri (10 citra). Ketiga jenis ikan diuji bersama untuk mengidentifikasi kesegaran melalui aplikasi.




**Gambar 6.** Hasil Klasifikasi Benar  
**Tabel 2.** Hasil Perhitungan Confusion Matrix

		Prediksi		
		Segar	Baik	Tidak Layak
Aktual	Segar	18	2	0
	Baik	0	20	0
	Tidak Layak	0	0	20


Tabel 2, merupakan hasil perhitungan dari pengujian keseluruhan data menggunakan aplikasi android yang telah dibangun. Untuk menghitung akurasi dari keseluruhan sistem digunakan rumus :

$$\begin{aligned}
 \text{Akurasi} &= \frac{TP}{\text{Jumlah Data}} \times 100\% \quad (1) \\
 &= \frac{58}{60} \times 100\% \\
 &= 96,67\%
 \end{aligned}$$

Selain pengujian sebelumnya, dilakukan percobaan dengan variasi latar dan jumlah ikan untuk menguji performa model. Pengambilan gambar dilakukan pada jarak ±10 cm, menggunakan 60 sampel citra (20 per kelas) dengan hasil sebagai berikut:



**Gambar 7.** Contoh Hasil Klasifikasi Benar



**Gambar 8.** Hasil Klasifikasi Salah


**Tabel 3.** Perhitungan Confusion Matrix untuk Latar yang Berbeda-beda  
**Prediksi**

		Prediksi		
		Segar	Baik	Tidak Layak
Aktual	Segar	20	0	0
	Baik	0	17	3
	Tidak Layak	0	0	20

Berdasarkan Tabel 3, model berhasil memprediksi 57 sampel dengan benar dan 3 sampel salah, dengan akurasi yang dihitung menggunakan rumus berikut.

$$Akurasi = \frac{TP}{Jumlah\ Data} \times 100\% = \frac{57}{60} \times 100\% = 95\% \quad (2)$$


Percobaan dengan jarak 20–30 cm dan banyak ikan dalam satu gambar menunjukkan bahwa model gagal memprediksi dengan benar, mengklasifikasikan semua ikan sebagai tidak layak.



**Gambar 9.** Hasil Klasifikasi dengan Banyak Ikan

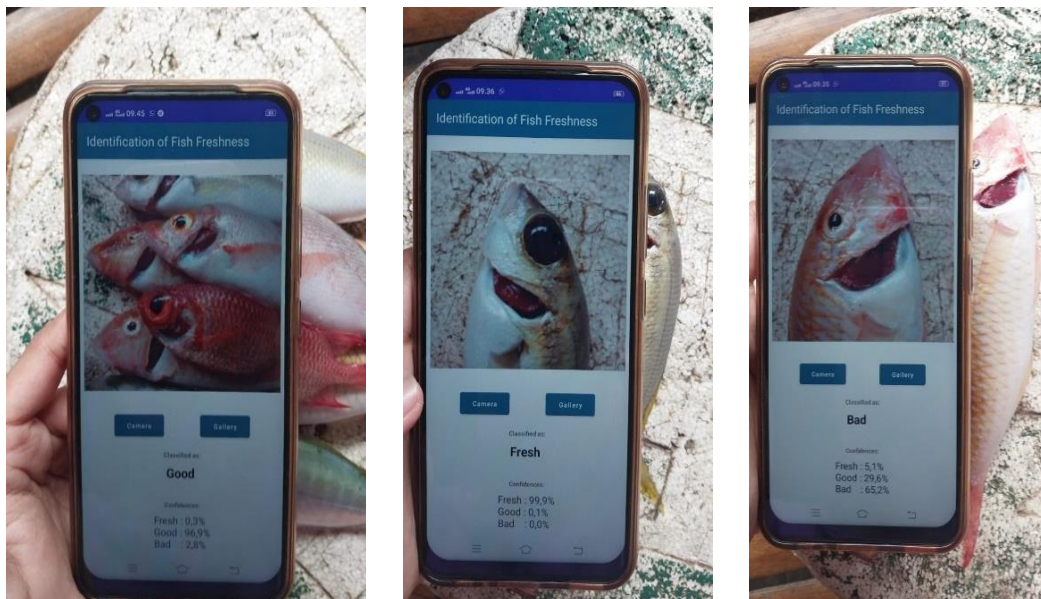
Percobaan berikutnya menguji skenario dengan ikan baik dan tidak layak dalam satu gambar, dengan hasil seperti pada Gambar ....





**Gambar 10.** Hasil Klasifikasi dengan Perpaduan Ikan Baik dan Tidak Layak

Selain ketiga jenis ikan utama (layang, banjar, dan tembang), percobaan dilakukan dengan variasi jenis ikan untuk mengevaluasi performa aplikasi, dengan hasil pada Gambar 11.



**Gambar 11.** Hasil Klasifikasi dengan Variasi Ikan yang Berbeda-Beda

## PEMBAHASAN

Model CNN dikembangkan dengan tiga *convolutional layer* dan dua *fully connected layer*, menggunakan citra 256×256 piksel (RGB). Model dilatih dengan batch size 32, *optimizer Adam*, serta fungsi aktivasi ReLU dan Softmax. Pengujian dilakukan pada epoch 10, 20, dan 30 untuk menemukan konfigurasi optimal.

Hasil evaluasi menunjukkan bahwa epoch 20 menghasilkan keseimbangan terbaik antara akurasi dan generalisasi model, dengan 98,91% akurasi pada split dataset dan 97,04% pada *K-Fold Cross Validation* (K=4). Sementara epoch 30 mencapai 100% akurasi, hasil ini berpotensi *overfitting*, sehingga epoch 20 dipilih sebagai model optimal.



Pengujian aplikasi Android menggunakan 60 sampel citra baru, dengan hasil akurasi 96,67% (58 prediksi benar, 2 salah). Model bekerja dengan baik untuk gambar yang diambil dari jarak  $\pm 10$  cm, tetapi mengalami penurunan akurasi pada jarak 20–30 cm atau saat terdapat beberapa ikan dalam satu gambar. Model juga mengalami keterbatasan dalam mengenali jenis ikan yang tidak termasuk dalam dataset pelatihan, menunjukkan perlunya pengembangan lebih lanjut dengan variasi dataset yang lebih luas.

### SIMPULAN

Penelitian ini menunjukkan bahwa penerapan *Convolutional Neural Network (CNN)* dengan 540 dataset mampu mendeteksi kesegaran ikan dengan akurasi 99% pada data training, 100% pada validation, dan 98% pada testing. Penggunaan *K-Fold Cross Validation (K=4)* menghasilkan akurasi tertinggi 91,85% (epoch 10), 97,04% (epoch 20), dan 94,81% (epoch 30). Implementasi pada aplikasi Android dengan 60 sampel baru menunjukkan akurasi 96,67%, membuktikan bahwa sistem dapat berjalan dengan baik.

### SARAN

Untuk pengembangan lebih lanjut, penelitian dapat membandingkan berbagai arsitektur CNN serta menambahkan variasi dataset seperti jenis ikan, warna latar, pencahayaan, dan sudut pengambilan gambar agar model lebih adaptif terhadap kondisi yang berbeda.

### DAFTAR PUSTAKA

- Ailima. (2022, April 13). Splitting Dataset in Machine Learning. <https://ailima.co.id/training-validation-testing-dataset/>
- Arrofiqoh, E.N. and Harintaka, H., 2018. Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi. *Geomatika*, 24(2), pp.61-68.
- Brownlee, Jason. (2018, Mei 23). A Gentle Introduction to k-fold Cross-Validation. <https://machinelearningmastery.com/k-fold-cross-validation/>
- Carey, B. (2019, March 22). Can we get better at forgetting? Retrieved from <https://abadi.m.umn.edu/>
- Abadi, M., et al. 2016. Tensorflow: A system for large-scale machine learning. *Symposium on Operating Systems Design and Implementation* (pp. 265–283).
- Dahria, Muhammad. 2008. Kecerdasan Buatan (Artificial Intelligence). *Jurnal Saintikom*, 5(2), pp.185-197.
- Dewi, Putu Febrina Ambara, dkk. 2018. “Pengetahuan Ibu tentang Ikan dan Pola Konsumsi Ikan pada Balita di Desa Kodongan Kabupaten Badung”. *Jurnal Ilmu Gizi*, vol. 7 No.1
- Duckworth, A. L., Quirk, A., Gallop, R., Hoyle, R. H., Kelly, D., & Matthews, M. D. (2019). Cognitive and noncognitive predictors of success. *Proceedings of the National Academy of Sciences*, 116(47), pp. 23499–23504. USA. doi:<https://doi.org/10.1073/pnas.1910510116>
- Gardy, J. S., Her, M., Moreno, G., Perez, C., & Yelinek, J. (2019). Emotions in storybooks: A comparison of storybooks that represent ethnic and racial groups in the United States. *Psychology of Popular Media Culture*, 8(3), 207-217. doi:<https://doi.org/10.1037/ppm0000185>
- Harris, L. (2014). *Instructional leadership perceptions and practices of elementary school leaders [Unpublished doctoral dissertation]*. University of Virginia



- 
- Jauhari, A. Fuad. 2022. “Klasifikasi Jenis Beras Menggunakan Metode Convolutional Neural Network Pada Arsitektur Mobilenet”. Skripsi. Jurusan Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim, Malang.
- Kim, J., dkk. 2016. Convolutional neural network with biologically inspired retinal structure. *Procedia Computer Science*, 88, pp.145-154.
- Kholik, A. 2021. Klasifikasi Menggunakan Convolutional Neural Network (CNN) Pada Tangkapan Layar Halaman Instagram. *Jurnal Data Mining dan Sistem Informasi*, 2(2), pp.10-20.
- Kushilevitz, E., & Malkin, T. (2016). Lecture notes in computer science: Vol. 9562. *Theory of cryptography*. Springer. doi:<https://doi.org/10.1007/978-3-662-49096-9>
- Nugroho, P.A., dkk. 2020. Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) Pada Ekspresi Manusia. *Algor*, 2(1), pp.12-20.
- Peryanto, A., Yudhana, A., & Umar, R. 2020. Klasifikasi Citra Menggunakan Convolutional Neural Network dan K Fold Cross Validation. *Journal of Applied Informatics and computing*, 4(1), 45-51.
- Prameswari, G.N., 2018. Promosi gizi terhadap sikap gemar makan ikan pada anak usia sekolah. *JHE (Journal of Health Education)*, 3(1), pp.1-6.
- Sianturi, Christian Immanuel. 2021. “Identifikasi Kesegaran Ikan Menggunakan Metode Convolutional Neural Network (CNN)”. Skripsi. Program Studi Teknologi Informasi Universitas Sumatera Utara, Medan.
- Suprayitno, Eddy. 2020. “Kajian Kesegaran Ikan di Pasar Tradisional dan Modern Kota Malang”. *Journal of Fisheries and Marine Research Vol. 4 No. 2 (2020) 289-295*
- Syarif, Ahmad Kurniawan. 2021. “Sistem Klasifikasi Penyakit Tanaman Cabai Menggunakan Metode Deep Learning Dengan Library Tensorflow Lite”. Skripsi. Departemen Teknik Informatika Universitas Hasanuddin, Makassar.