

Penggunaan *Convolutional Neural Network* (CNN) untuk Menentukan Kesegaran Ikan Bawal Putih

Hanisa^{1,*}, Amelia Kartika², Delima Pakpahan³, Wulan Novitasari⁴, Qoriah Rahmadiyah Ismail⁵, Nurul Hayaty^{6*}
^{1,2,3,4,5,6}Program Studi Teknik Informatika, Fakultas Teknik Dan Teknologi Kemaritiman,
Universitas Maritim Raja Ali Haji
Jl. Politeknik Senggarang, Tanjungpinang 29100
*Corresponding Author: nurul.hayaty@umrah.ac.id

Abstract- *White pomfret (Pampus argenteus) is one of the high-value commodities and is widely exported frozen. However, its very freshness deteriorates easily, making it a key factor influencing quality and price. This study aims to develop a system to classify the freshness level of white pomfret using the Convolutional Neural Network (CNN) method. The images of the fish head are used, which has been processed to a size of 1700x1700 pixels and adjusted to a resolution of 224x224 pixels before being entered into the model. The CNN architecture applied consists of three convolution layers with a combination of Max-Pooling, Dropout, Flatten, and Dense Layer. This training process stops at the 30th epoch after the model reaches optimal performance and results in a training accuracy of 85%, a validation accuracy of 80%, and a test data accuracy of 81.2%. The evaluation results show that the model can classify fresh fish well (precision 0.865, recall 0.938), quite satisfactory for non-fresh fish (precision 0.788, recall 0.854), and less effective for less fresh fish (recall 0.646). Overall, this CNN model shows quite good performance and can be used as a tool to automatically detect the freshness level of white pomfret (Pampus argenteus).*

Keywords—White Pomfret Fish, Image Classification, Convolutional Neural Network (CNN), Machine Learning.

Intisari- Ikan bawal putih (*Pampus argenteus*) merupakan salah satu komoditas yang menjadi andalan yang memiliki nilai ekonomi tinggi dan banyak diekspor dalam keadaan beku. Namun, ikan sangat rentan terhadap kerusakan, sehingga kesegarannya merupakan faktor penting yang mempengaruhi kualitas dan harga jual. Penelitian ini bertujuan untuk mengembangkan sistem untuk mengklasifikasikan tingkat kesegaran ikan bawal putih dengan menggunakan metode *Convolutional Neural Network* (CNN). Citra kepala ikan dipilih sebagai data masukan, yang telah diproses menjadi ukuran 1700x1700 piksel dan disesuaikan dengan resolusi 224x224 piksel sebelum dimasukkan ke dalam model. Arsitektur CNN yang diterapkan terdiri atas tiga lapisan konvolusi dengan penggabungan *Max-Pooling*, *Dropout*, *Flatten*, dan *Dense Layer*. Proses pelatihan ini berhenti pada epoch ke-30 setelah model mencapai performa yang optimal dan menghasilkan akurasi pelatihan sebesar 85%, akurasi validasi sebesar 80%, dan akurasi data uji sebesar 81,2%. Hasil evaluasi menunjukkan bahwa model dapat mengklasifikasikan ikan segar dengan baik (*precision* 0.865, *recall* 0.938), cukup memuaskan untuk ikan tidak segar (*precision* 0.788, *recall* 0.854), dan kurang efektif untuk ikan yang kurang segar (*recall* 0.646). Secara keseluruhan, model CNN ini menunjukkan kinerja yang cukup baik dan dapat digunakan sebagai alat bantu untuk secara otomatis mendeteksi tingkat kesegaran ikan bawal putih (*Pampus argenteus*).

Kata kunci—Ikan Bawal Putih, Klasifikasi Citra, Convolution Neural Network(CNN), Deteksi Kesegaran Ikan, Pembelajaran Mesin.

I. PENDAHULUAN

Ikan adalah salah satu sumber protein hewani yang memiliki nilai gizi tinggi, setelah daging, susu, dan telur. Selain itu, ikan juga kaya

akan vitamin serta mineral penting yang berperan vital bagi kesehatan manusia [1]. Salah satu jenis komoditas yang memiliki nilai ekonomi yang tinggi adalah *Pampus argenteus*, atau ikan bawal putih.

Ikan bawal putih banyak diekspor dalam kondisi beku ke sejumlah negara akibat permintaan yang semakin meningkat. Kendati demikian, ikan adalah barang yang rentan terhadap kerusakan, sehingga penanganan pasca-tangkap perlu segera dilakukan pada suhu rendah dan dengan memperhatikan aspek sanitasi. Tingkat kesegaran ikan menjadi unsur penting yang mempengaruhi mutu serta harga jual produk hasil perikanan [2].

Berbagai penelitian telah dilakukan mengenai pemrosesan citra digital guna mendeteksi kesegaran ikan dengan citra kepala ikan sebagai data input dengan memanfaatkan berbagai metode yang berbeda. Penggunaan ciri warna HSV pada bola mata ikan untuk identifikasi tingkat kesegaran dengan algoritma KNN telah diteliti dalam [3], dengan akurasi pengujian mencapai 95% pada 40 citra ikan. Selanjutnya sistem identifikasi kesegaran ikan berbasis Android menggunakan *Convolutional Neural Network* (CNN) dan *TensorFlow Lite* telah dirancang pada penelitian [1]. Sistem ini menggunakan data preparation berupa *cropping* dan normalisasi RGB (0–1), serta menghasilkan akurasi pengujian sebesar 98% pada data uji dan 96,7% pada aplikasi Android dengan 60 sampel baru. Sistem identifikasi kesegaran ikan berbasis citra insang telah dikembangkan menggunakan metode *Convolutional Neural Network* (CNN), dengan arsitektur tiga layer konvolusi dan fungsi aktivasi ReLU serta *Softmax*, sebagaimana ditunjukkan dalam penelitian [baru]. Sistem ini diuji dengan 150 data citra insang yang terbagi dalam tiga kelas (segar, tidak segar, busuk), dan menghasilkan akurasi 100% pada data pelatihan serta 97.7% pada data pengujian.

Berdasarkan beberapa penelitian yang sudah ada, *Convolutional Neural Network* (CNN) dipilih sebagai metode dalam penelitian ini karena keunggulannya dalam melakukan ekstraksi fitur visual secara otomatis dan mendalam, jika dibandingkan dengan metode konvensional seperti *K-Nearest Neighbor* (KNN). Berbagai penelitian tentang klasifikasi ikan menunjukkan bahwa CNN dapat mencapai tingkat akurasi yang sangat tinggi, baik yang didasarkan pada citra mata, kepala, maupun insang. Selain itu, saat ini tidak ada penelitian

yang secara khusus menggunakan CNN untuk mendeteksi kesegaran ikan bawal putih (*Pampus argenteus*) dengan citra kepala ikan. Dengan adanya sistem ini, diharapkan sistem mampu mendeteksi kesegaran ikan dengan cepat, akurat, serta mendukung pengendalian mutu produk perikanan.

II. LANDASAN TEORI

A. Ikan Bawal Putih

Ikan bawal putih *Pampus argenteus* adalah jenis ikan laut yang memiliki nilai ekonomi signifikan dan termasuk dalam keluarga *Stromateidae* yang dapat ditemukan di dasar lautan berpasir atau berlumpur. Ikan ini tergolong dalam ordo Perciformes, kelas Actinopterygii, subfilum Vertebrata, filum Chordata, dan kerajaan Animalia. Spesies ini hidup di dasar laut dan termasuk dalam kategori demersal, biasanya ditemukan pada kedalaman antara 15 hingga 100 meter di area yang berpasir atau berlumpur. Bentuknya unik, dengan tubuh yang sangat pipih secara lateral, punggung yang melengkung, bagian atas tubuh berwarna abu-abu, dan bagian bawah berwarna putih keperakan, serta memiliki sirip ekor yang bercagak dengan bagian bawah yang lebih panjang. Ikan ini tidak memiliki sirip perut, dan tepi sirip dadanya tidak meruncing seperti pada bawal hitam. Ciri-ciri ini membuat bawal putih dikenali dengan mudah dan sangat berharga, baik untuk konsumsi dalam negeri maupun untuk diekspor [5].

B. Kesegaran

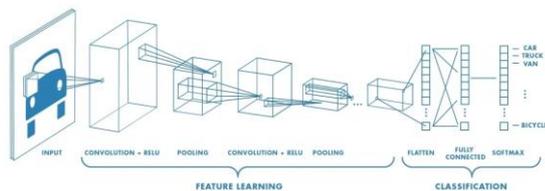
Kesegaran ikan merupakan keadaan terbaik ikan setelah penangkapan, yang ditunjukkan melalui ciri fisik, sensorik, dan kimia yang menunjukkan bahwa ikan tersebut masih aman untuk dikonsumsi [6]. Menurut SNI, kesegaran ikan dapat dinilai melalui kondisi mata, insang, bau, dan tekstur dagingnya. Mengonsumsi ikan yang segar sangat penting untuk mempertahankan nilai gizi dan mengurangi kemungkinan keracunan yang disebabkan oleh bakteri patogen [1]. Ikan yang sudah tidak segar memiliki ciri-ciri seperti mata yang tampak lesu, insang yang berwarna gelap, aroma amis yang sangat kuat, daging yang lembek, dan lendir yang berwarna kuning [7]. Oleh karena itu, diperlukan cara yang tepat untuk menilai tingkat kesegaran ikan.

C. Citra Digital

Citra digital adalah kumpulan *piksel* yang membentuk gambar dua dimensi yang mencerminkan cahaya. Dalam istilah matematis, citra dianggap sebagai fungsi kontinu dari intensitas cahaya dalam dua dimensi. Beberapa jenis citra yang sering dijumpai adalah gambar berwarna, citra skala abu-abu, dan gambar biner [7]. Untuk mendukung proses klasifikasi, ekstraksi fitur seperti warna, bentuk, dan tekstur seringkali diterapkan [8]. mengungkapkan bahwa penerapan citra digital dengan algoritma *Convolutional Neural Networks* (CNNs) dapat meningkatkan ketepatan identifikasi dalam sistem manajemen sampah pintar.

D. Convolutional Neural Network

CNN merupakan jaringan *syaraf multilayer feedforward* yang terinspirasi oleh mekanisme bidang reseptif dalam biologi [8]. CNN terkenal karena konektivitas lokal antar neuron, pembagian bobot, dan kemampuan down-sampling. Melalui beberapa lapisan transformasi fitur, representasi fitur dari data asli secara bertahap diubah menjadi representasi fitur tingkat tinggi, yang selanjutnya digunakan untuk tugas klasifikasi atau lainnya.

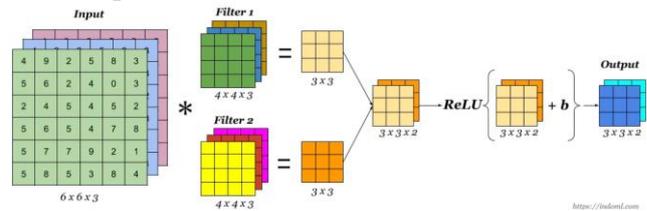


Gambar 1. Arsitektur umum CNN

E. Convolutional Layer

Convolutional Layer adalah komponen utama dalam arsitektur CNN yang terdiri dari sejumlah filter (*kernel*) yang digunakan untuk mengekstraksi fitur dari data input seperti gambar. Proses konvolusi dilakukan dengan menggeser filter di atas input dan melakukan operasi elemen-per-elemen antara filter dan bagian input yang sesuai, menghasilkan peta fitur (*feature map*) yang menyoroti karakteristik penting dari data [8]. Setiap filter dalam lapisan ini memiliki bobot yang dapat dilatih, yang awalnya diinisialisasi secara acak dan kemudian disesuaikan selama proses pelatihan untuk mengidentifikasi fitur-fitur spesifik dalam data. Dengan demikian, Lapisan Konvolusi

memungkinkan CNN untuk secara otomatis belajar dan mengenali pola-pola penting dalam data tanpa memerlukan ekstraksi fitur manual.

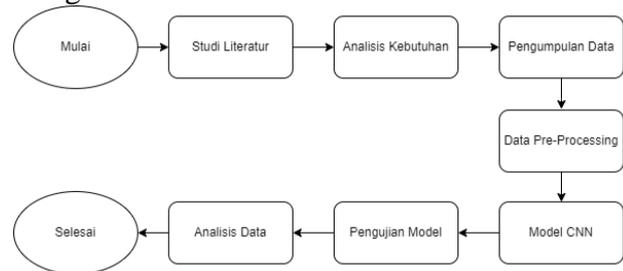


Gambar 2. Convolutional Layer

III. PEMBAHASAN

A. Metodologi Penelitian

Penelitian ini dilakukan melalui rangkaian langkah yang dimulai dengan studi literatur hingga analisis data. Setiap langkah diatur secara sistematis untuk memastikan bahwa kegiatan penelitian berjalan dengan terencana dan terorganisir.



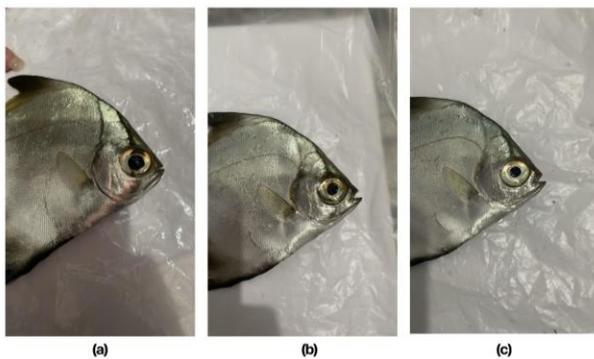
Gambar 3. Metode Penelitian

Berdasarkan diagram alur penelitian, tahapan pertama yang dilakukan peneliti yaitu studi literatur untuk memperoleh pemahaman yang berfokus pada klasifikasi gambar model *Convolutional Neural Networks* (CNN), teknik augmentasi data dan metode evaluasi performa model khususnya pada klasifikasi ikan segar yang mendukung analisis dan pengembangan dalam penelitian ini. Kemudian dilakukan analisis data agar sesuai untuk melatih tingkat kesegaran ikan secara akurat.

B. Pengumpulan Data

Data dalam penelitian ini diperoleh dengan membeli ikan bawal putih dari penangkaran ikan yang berlokasi di Kampung Madong, kota Tanjungpinang. Gambar diambil dari sisi kanan dan kiri dengan jarak satu jam selama waktu penyimpanan hingga 9 jam, dengan

ikan disimpan di dalam wadah tertutup pada suhu ruang. Berdasarkan lama penyimpanan, ikan diklasifikasikan ke dalam tiga kelas kesegaran, yaitu segar (jam ke-1 hingga jam ke-3), kurang segar (jam ke-4 hingga jam ke-6), dan tidak segar (jam ke-7 hingga jam ke-9) [10]. Dalam penelitian ini, parameter yang digunakan adalah yang umum dan utama, yang biasanya dilakukan oleh kebanyakan orang ketika memeriksa kesegaran ikan, yaitu pada bagian mata ikan seperti yang terlihat pada gambar.



Gambar 4. (a). Ikan segar, (b). Ikan kurang segar, (c). Ikan tidak segar

C. Data Pre-Processing

Penelitian ini melakukan klasifikasi tingkat kesegaran ikan bawal putih (*Pampus argenteus*) menggunakan dataset yang terdiri dari 288 citra, yang dikelompokkan ke dalam tiga kategori berdasarkan waktu pengambilan setiap tiga jam. Pada tahap awal pre-processing, dilakukan pemotongan (*cropping*) citra dengan ukuran 1700×1700 piksel untuk memperoleh area objek yang relevan dan mengurangi gangguan dari latar belakang. Selanjutnya, dilakukan proses *augmentasi* citra dengan menerapkan rotasi pada sudut 0° , 15° , -15° , 30° , dan -30° , menggunakan *library NumPy* dan *os*. Setiap citra asli menghasilkan lima citra baru hasil rotasi, sehingga meningkatkan variasi data berjumlah 1.440 dan memperkaya keragaman fitur yang dapat dipelajari model. Kemudian data ini dibagi 70% untuk pelatihan, 20% validasi, dan 10% pengujian agar model CNN dapat belajar, divalidasi, dan diuji secara optimal [9]. Rincian pembagian data ditampilkan pada tabel berikut.

Tabel 1. Pembagian data

Pembagian	3 Jam	6 Jam	12 Jam
Pelatihan	1.008	336	336
Validasi	288	96	96
Uji	144	48	48

D. Model CNN

Dalam penelitian ini, arsitektur *Convolutional Neural Network* (CNN) dirancang untuk memproses hasil *pre-processing* berukuran 1700×1700 piksel sebagai input. Arsitektur ini terdiri dari sejumlah lapisan utama yaitu:

1. Tahap awal diawali dengan *convolutional layer* pertama, yang memiliki 32 filter dengan kernel 3×3 piksel, mengandalkan fungsi aktivasi *Rectified Linear Unit* (ReLU) untuk mengekstraksi fitur lokal dasar seperti *edge*, *corner* dan *texture* dari citra *input* berukuran 224×224 piksel. Lapisan ini diikuti oleh *Max-Pooling2D* dengan *pool size* 2×2 yang berguna mengurangi dimensi spasial dari *feature map*, sehingga jumlah parameter dan kompleksitas komputasi dapat ditekan. *Dropout* dengan *rate* 0.2 diterapkan pada lapisan ini untuk menonaktifkan 20% *neuron* secara acak saat *training*, untuk mencegah *overfitting* pada tahap awal.
2. Kemudian *convolutional layer* kedua terdiri dari 64 filter dengan *kernel size* 3×3 dan *activation function* ReLU, yang mengekstraksi fitur tingkat menengah yang lebih kompleks dari *feature map*. Lapisan ini juga diikuti *MaxPooling2D* 2×2 untuk mereduksi dimensi spasial lebih lanjut.
3. Selanjutnya *convolutional layer* ketiga, menggunakan 128 filter dengan *kernel size* 3×3 dan *activation* ReLU untuk mengekstraksi fitur tingkat tinggi dan pola yang lebih abstrak yang relevan untuk membedakan tingkat kesegaran ikan. *Maxpooling2D* 2×2 digunakan kembali dan *Dropout* dengan *rate* 0.3 juga diterapkan untuk meningkatkan regulasi pada lapisan ini, karena model mulai memiliki jumlah parameter yang lebih besar.
4. Kemudian *flatten layer* digunakan untuk mengubah *output* dari *convolutional* dan *pooling layer* menjadi vektor satu dimensi untuk dapat diproses *fully connected layer*.
5. Lapisan *fully connected layer* (*dense*) memiliki 128 *neuron* dengan *activation function* ReLU, untuk menggabungkan fitur-fitur yang telah diekstraksi untuk mendukung klasifikasi.

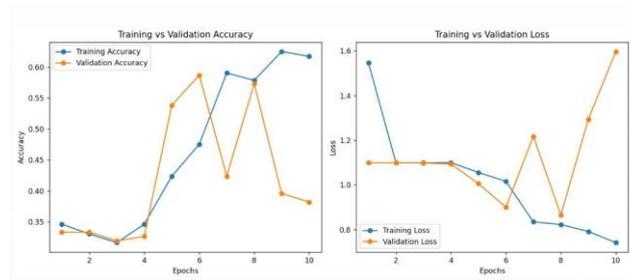
6. Terakhir *output layer* yang terdiri dari sejumlah *neuron* yang setara dengan jumlah kelas, masing-masing menggunakan *activation function softmax* untuk menghasilkan distribusi probabilitas prediksi terhadap tiga kelas tingkat kesegaran yaitu segar (3 jam), kurang segar (6 jam) dan tidak segar (9 jam).

Sistem arsitektur ini diterapkan untuk pelatihan model yang secara akurat mendeteksi kesegaran ikan bawal putih, dengan memanfaatkan data pelatihan dan validasi yang mampu mengenali setiap tingkat kesegaran ikan bawal putih.

E. Pengujian Model

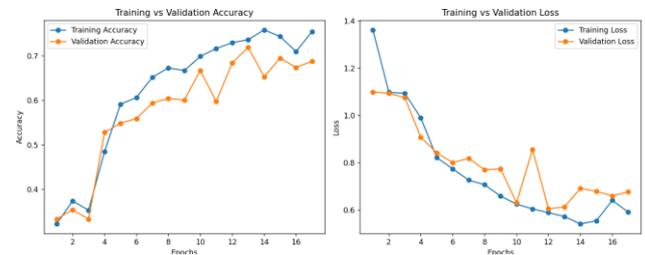
Setelah pelatihan model selesai, langkah berikutnya adalah melakukan uji coba untuk menilai kinerja model serta mengevaluasi efektivitasnya dalam mendeteksi dan mengklasifikasikan citra ikan bawal pada 10% data uji yang sebelumnya sudah dipisahkan. Data uji terdiri dari tiga kelas tingkat kesegaran yaitu segar, kurang segar dan tidak segar. Tujuan dari proses pengujian ini adalah untuk mengukur sejauh mana model dapat melakukan generalisasi, yaitu kemampuan dalam mengenali dan mengklasifikasikan citra ikan pada data baru yang sebelumnya tidak diperkenalkan selama pelatihan. Hal ini penting untuk memastikan bahwa model tidak hanya menghafal pola dari data pelatihan, tetapi juga dapat beroperasi dengan baik pada data yang belum pernah dilihat.

Uji coba model CNN dilakukan dengan variasi jumlah *epoch*, guna menilai seberapa baik model dapat mengenali tingkat kesegaran ikan pada data yang diuji. Evaluasi hasil pengujian dilakukan dengan mengamati grafik akurasi dan *loss* sepanjang proses pelatihan, serta melalui *confusion matrix*.



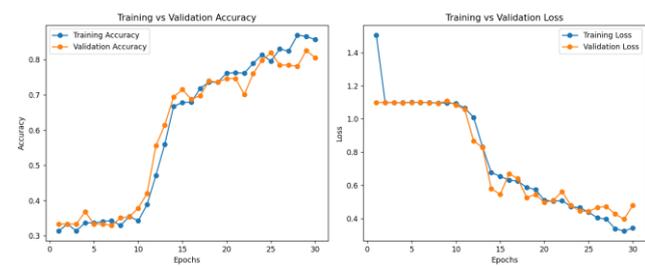
Gambar 5. Grafik epoch 10

Pada 10 *epoch*, tingkat akurasi untuk pelatihan mencapai 62%, dan untuk validasi akurasi hanya sekitar 59% dengan *validation loss* mulai meningkat yang menandakan adanya *overfitting*.



Gambar 6. Grafik epoch 20

Pada 20 *epoch* model mencegah *overfitting*. Dalam uji coba ini, model memiliki akurasi pelatihan 73% dan akurasi validasi mencapai 69%, dengan penurunan *loss* yang lebih konsisten sehingga *overfitting* pada mulai dikendalikan.



Gambar 7. Grafik 30 epoch

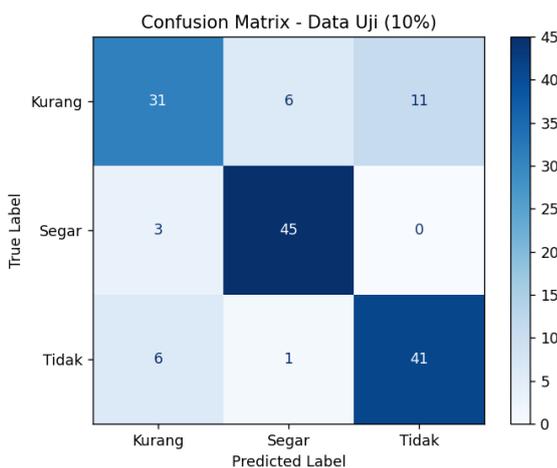
Selanjutnya, pada 30 *epoch*, model berhasil memperoleh akurasi pada pelatihan sebesar 85% dan akurasi pada validasi sebesar 80%. Dalam uji coba ini, penurunan *loss* berlangsung secara konsisten tanpa indikasi *overfitting*, sehingga model dapat belajar pola data dengan lebih efektif dan dapat melakukan generalisasi dengan baik pada data validasi.

Berikut adalah tabel hasil pengujian model dimulai dari epoch 10 hingga epoch 30.

Tabel 2. Hasil pengujian

Epoch	Training Accuracy	Validation Accuracy
1-10	62%	59%
11-20	73%	69%
21-30	85%	80%

Untuk mengevaluasi performa model secara detail, digunakan *confusion matrix* dengan tujuan untuk melihat seberapa efektif model dalam membedakan setiap kelas, serta mengidentifikasi kelas yang sering keliru memprediksi. Dengan *confusion matrix*, dapat terlihat pola kesalahan model dan distribusi prediksi terhadap masing-masing kelas.



Gambar 8. Grafik Confusion matrix

Prediction

Accuracy: 0.812

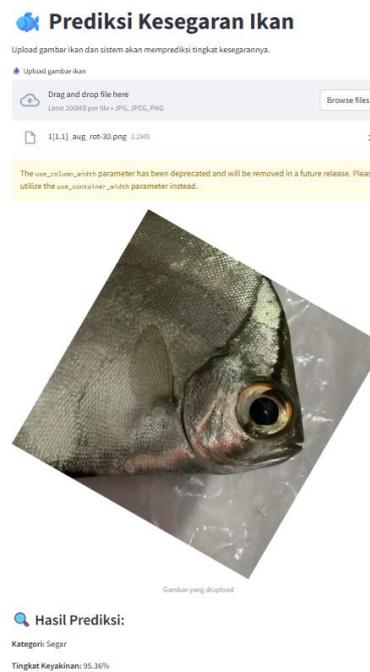
Classification Report:

	precision	recall	f1-score	support
Kurang	0.775	0.646	0.705	48
Segar	0.865	0.938	0.900	48
Tidak	0.788	0.854	0.820	48
accuracy			0.812	144
macro avg	0.810	0.812	0.808	144
weighted avg	0.810	0.812	0.808	144

Gambar 9. Hasil evaluasi model klasifikasi

Berdasarkan hasil pengujian pada Gambar 6. dan 7, data uji memiliki *accuracy* sebesar 81.2% yang menunjukkan model CNN memiliki performa yang cukup baik. Model sangat efektif dalam mendeteksi kelas Ikan Segar dengan *precision* 0.865 dan *recall* 0.938, cukup baik pada kelas Tidak Segar dengan *precision* 0.788 dan *recall* 0.854, dan kurang optimal pada kelas Kurang Segar dengan *recall* hanya 0.646.

F. Implementasi



Gambar 10. Implementasi Sistem

Setelah penyelesaian proses evaluasi model, tahap berikutnya adalah penerapan sistem. Pada fase ini, *Streamlit* digunakan sebagai alat untuk membuat aplikasi web sederhana yang mampu memprediksi kesegaran ikan. Aplikasi ini memungkinkan pengguna untuk meng-upload foto ikan, dan sistem akan memberikan hasil prediksi dalam bentuk kategori kesegaran yaitu segar, kurang segar, atau tidak segar dan lengkap dengan tingkat keyakinan dari sistem yang ditampilkan dalam persentase. Angka persentase ini mencerminkan seberapa yakin model terhadap prediksi yang dilakukan. Sebagai ilustrasi, seperti yang terlihat pada gambar, sistem berhasil mengidentifikasi seekor ikan dalam kategori

Segar dengan tingkat kepercayaan mencapai 95,36%.

IV. KESIMPULAN

Pada Penelitian ini Berdasarkan pengujian yang telah dikembangkan berhasil mencapai tingkat akurasi 81,2% ketika diuji, yang menunjukkan performa yang baik dalam mengklasifikasikan kesegaran ikan bawal putih. Secara keseluruhan, model CNN ini menunjukkan potensi yang baik dalam pengklasifikasian kesegaran ikan, tetapi masih memerlukan perbaikan lebih lanjut, terutama dalam membedakan kategori yang memiliki karakter visual yang lebih sulit, seperti kategori Kurang Segar.

UCAPAN TERIMA KASIH

Peneliti mengucapkan terima kasih kepada dosen pengampu mata kuliah Pengolahan Citra dan Universitas Maritim Raja Ali Haji atas dukungan dalam pelaksanaan penelitian ini.

REFERENSI

- [1] Justam, M. N. Takbir, S. M. Umar, Erlita, dan R. O. Lewa, "Sistem identifikasi kesegaran ikan berbasis Android menggunakan convolutional neural network (CNN)," *Jurnal Ilmiah Sistem Informasi dan Teknik Informatika (JISTI)*, vol. 7, no. 2, pp. 340–350, Oct. 2024, doi: 10.57093/jisti.v7i2.271.
- [2] C. R. Gunawan, Nurdin, and Fajriana, "Deteksi ikan segar secara realtime dengan YOLOv4 menggunakan metode convolutional neural network (CNN)," *Jurnal Komtika (Komputasi dan Informatika)*, vol. 7, no. 1, pp. 1–11, May 2023, doi: 10.31603/komtika.v7i1.8986.
- [3] J. S. N. Silalahi, Anisah, R. Fitra, dan C. Rozikin, "Penggunaan ciri warna HSV pada bola mata ikan untuk identifikasi tingkat kesegaran ikan menggunakan algoritma KNN," *J. Teknol. Inform.*, vol. 2, no. 2, pp. 1–6, Okt. 2023. [Online]. Tersedia: <https://jurnal.utu.ac.id/JTI/article/view/7711/4289>
- [4] M. Sholihin, M. R. Zamroni, dan Burhanuddin, "Identifikasi kesegaran ikan berdasarkan citra insang dengan metode Convolution Neural Network," *J. Tek. Inform. Sist. Inform.*, vol. 8, no. 3, pp. 1352–1360, Sep. 2021. [Online]. Tersedia: <http://jurnal.mdp.ac.id>
- [5] G. Zulfikar, *Studi Pemasaran Ikan Bawal Putih (Pampus argenteus) pada KUB (Kelompok Usaha Bersama) Nelayan di Kelurahan Kampung Nelayan Kabupaten Tanjung Jabung Barat*, Skripsi, Program Studi Pemanfaatan Sumberdaya Perikanan, Fakultas Peternakan, Universitas Jambi, 2023.
- [6] M. F. N. Al Fatic, A. I. Setyastuti, D. Kresnasari, dan Sarmin, "Identifikasi Tingkat Kesegaran Ikan Tongkol (*Euthynnus* sp.) di Pasar Bumiayu, Kabupaten Brebes," *Journal of Marine Research*, vol. 12, no. 3, pp. 511–518, Agustus 2023, doi: 10.14710/jmr.v12i3.40444. [Online]. Tersedia: <https://ejournal3.undip.ac.id/index.php/jmr>
- [7] S. Adiningsi, B. Pramono, A. M. Sajiah, dan R. A. Saputra, "Identifikasi kualitas ikan cakalang segar berbasis citra mata menggunakan metode support vector machine (SVM) dengan fungsi kernel radial basis function," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 1, pp. 1522–1530, Feb. 2025.
- [8] L. Alzubaidi, J. L. Zhang, A. J. Humaidi, A. Al-Dujaili, K. Duan, O. Al-Shamma, J. Santamaria, M. A. Fadhel, M. Al Amidie, dan F. Laith, "Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions," *Journal of Big Data*, vol. 8, art. no. 53, Mar. 2021, doi: 10.1186/s40537-021-00444-8.
- [9] W. Styorini, A. Pratiwi, dan C. Widiyari, "Identifikasi Tingkat Kesegaran Ikan Berbasis Android," *Jurnal Amplifier*, vol. 12, no. 1, pp. 12–20, Mei 2022, P-ISSN: 2089-2020, E-ISSN: 2622-2000.
- [10] A. Fendiawati dan M. E. A. Rivan, "Klasifikasi American Sign Language dengan Metode VGG-19," dalam *Prosiding MDP Student Conference (MSC)*, hlm. 193, 2023.