



KLASIFIKASI KESEGARAN IKAN TONGKOL BERDASARKAN CITRA MATA BERBASIS CONVOLUTIONAL NEURAL NETWORK (CNN)

Fitria Ningsih¹⁾, Agus Suhendar²

¹ Sarjana Informatika, Universitas Teknologi Yogyakarta

² Sarjana Informasi Diploma Tiga, Universitas Teknologi Yogyakarta

email: ¹ fitriansh081@gmail.com, ² agus.suhendar@staff.uty.ac.id

ARTICLE INFO

Article History:

Received : 4 Oktober 2025

Accepted : 28 Oktober 2025

Published : 21 Desember 2025

Keywords:

Fish Freshness,
Convolutional Neural
Network (CNN),
Image Classification,
Machine Learning,
Fish Eye Image

ABSTRACT

It Fish freshness is a crucial factor in ensuring food quality and safety. However, the conventional assessment process still relies on human observation, which is subjective supporting system, the risk of distributing non-fresh fish to consumers remains high, potentially affecting public health and consumer trust in fishery products. To address this issue, a fish freshness classification system based on eye image analysis using the Convolutional Neural Network (CNN) method was developed. The system development stages include collecting fish eye image data, labeling, image preprocessing, CNN model training, and implementing the system in an convolution and pooling layers to extract visual features from the images. The initial testing results show that the system can classify fish freshness into two categories, Fresh and Not Fresh, with a high level of accuracy. This system is expected to assist the public and fishery industry practitioners in evaluating fish quality more accurately and efficiently.

IEEE style in citing this article:

F. Ningsih, A. Suhendar. "Klasifikasi Kesegaran Ikan Tongkol Berdasarkan Citra Mata Berbasis Convolutional Neural Network (CNN)", *jurnalilmiahinformatika*, vol. 10, no. 2, pp. 88-94, Des. 2025.

1. PENDAHULUAN

Sektor perikanan memiliki peran penting dalam pangan dan perekonomian masyarakat, terutama di negara maritim seperti Indonesia. Salah satu komoditas perikanan yang memiliki nilai ekonomi tinggi adalah ikan tongkol (*Euthynnus affinis*). Tingginya tingkat konsumsi dan produksi menunjukkan bahwa ikan tongkol memiliki potensi besar dalam mendukung pemenuhan kebutuhan protein hewani masyarakat. Setelah proses penangkapan atau pemanenan, ikan akan melalui tahap pentimpanan atau penanganan tertentu yang dapat mempengaruhi dan menurunkan kualitasnya [1]. Penanganan ikan laut yang tidak ditangan ditangani secara higienis dan disimpan pada suhu tinggi dapat menghasilkan kadar *histamin* yang membahayakan. Kondisi ini menandakan bahwa penurunan kesegaran ikan berbanding lurus dengan peningkatan risiko paparan senyawa *toksik* [2]. Tingginya *histamin* pada ikan berdampak pada kualitas sensorik seperti bau dan tekstur. Konsumsi ikan dengan kadar *histamin* berlebih dapat memicu reaksi seperti pusing, mual, dan gangguan peredaran darah [3].

Suatu implementasi teknologi *digital* menggunakan *Convolutional Neural Network* (CNN) dimanfaatkan sebagai metode untuk menentukan kesegaran ikan tongkol objektif dalam sengan lebih cepat dan objektif, sehingga dapat mempercepat dan meringkas untuk ikut menentukan kesegarannya berdasar pada ciri-ciri visual ikan dengan fokus utama pada bentuk mata ikan. Metode *Deep Convolutional Neural Network* mampu memberikan performa yang lebih baik dibandingkan metode konvensional dalam menentukan tingkat kesegaran ikan berdasarkan citra insang dan mata ikan [4].

Penelitian terkait klasifikasi kesegaran ikan sebelumnya telah banyak diterapkan menggunakan metode *Machine Learning*. Salah satunya, analisis kesegaran ikan mujair dan ikan nila berbasis citra mata dengan metode (CNN) dan *transfer learning* pada enam arsitektur CNN, yaitu ResNet, AlexNet, VGG-16, SqueezeNet, DenseNet, dan Inception. Berdasarkan hasil penelitian, model VGG-16 menghasilkan performa paling optimal, dengan tingkat akurasi mencapai 73% pada ikan mujair dan 57,9% pada ikan nila. [5].

Pendekatan lain menggunakan *Backpropagation Neural Network* diterapkan untuk mendeteksi tingkat kesegaran ikan tongkol melalui citra mata. Model terdiri dari dua *hidden layer* dengan masing-masing 15 dan 5 neuron serta satu *output layer* yang diklasifikasikan ke dalam dua kelas, yakni segar dan tidak segar. Berdasarkan sepuluh kali percobaan, metode ini mampu mencapai akurasi hingga 90%, sehingga membuktikan efektivitas *Backpropagation* dalam pengenalan pola visual pada ikan [6].

Selain itu, pengembangan aplikasi berbasis Android dengan metode *K-Nearest Neighbor* (KNN) juga telah dilakukan untuk menentukan tingkat kesegaran ikan berdasarkan ruang warna RGB. Aplikasi tersebut mampu mengklasifikasikan ikan ke dalam empat kategori yaitu sangat segar, segar, kurang segar, dan tidak segar dengan akurasi mencapai 93,75% pada perangkat dengan spesifikasi kamera tinggi [7].

Implementasi CNN dalam sistem berbasis Android juga menunjukkan hasil yang menjanjikan. Model CNN menggunakan tiga lapisan konvolusi serta dua lapisan *fully connected*, dilatih menggunakan 540 citra mata ikan dengan tiga kategori kesegaran, yaitu segar, baik, dan tidak layak konsumsi. Pelatihan model dilakukan menggunakan *optimizer*

Adam serta fungsi aktivasi ReLU dan Softmax untuk meningkatkan kinerja klasifikasi. Setelah proses pelatihan selesai, model dikonversi ke format TensorFlow Lite untuk digunakan pada aplikasi Android. Hasil pengujian menunjukkan tingkat akurasi sebesar 98% pada data uji dan 96,67% pada pengujian menggunakan 60 sampel baru.[8].

Berdasarkan berbagai penelitian, penerapan algoritma CNN terbukti efektif dalam mendekripsi citra, khususnya pada klasifikasi kesegaran ikan. Penelitian ini berfokus pada klasifikasi ikan tongkol berdasarkan citra mata menggunakan metode *Convolutional Neural Network* (CNN) untuk menghasilkan sistem yang objektif dan akurat. Tujuan dari penelitian ini adalah menerapkan metode CNN dalam pengolahan citra digital untuk mengidentifikasi karakteristik visual pada mata ikan sebagai indikator utama, serta mengembangkan sistem klasifikasi otomatis yang mampu membedakan ikan tongkol segar dan tidak segar secara efisien.

2. METODE PENELITIAN

2.1 Dataset

Dataset pada penelitian ini diperoleh secara langsung sebagai data *primer* melalui pengambilan gambar mata ikan tongkol. Pengambilan citra dilakukan menggunakan kamera smartphone dengan kualitas resolusi 108MP. Gambar diambil dari ikan tongkol dengan tingkat kesegaran yang beragam, mulai dari ikan yang masih segar hingga ikan yang telah disimpan selama beberapa waktu. Dataset yang diperoleh terdiri atas total 1.239 citra, data dibedakan menjadi dua kategori, yaitu ikan segar dengan 592 citra dan ikan tidak segar dengan 647 citra.

2.2 Preprocessing Data

Tahap ini merupakan proses pra-pemrosesan citra sebelum digunakan untuk pelatihan dan validasi model CNN. Dataset dibagi menjadi dua bagian utama, dengan proporsi 70% sebagai data pelatihan dan 30% sebagai data validasi. Setiap citra diubah ukurannya menjadi 150×150 piksel agar sesuai dengan input CNN serta mempercepat proses pelatihan model.

Selanjutnya yaitu tahap normalisasi nilai piksel dengan membagi setiap piksel dengan 255 sehingga rentangnya berada antara 0 hingga 1. Langkah ini membantu menstabilkan distribusi data dan mempercepat proses konvergensi selama pelatihan.

Untuk memperkaya variasi data serta mengurangi risiko *overfitting*, diterapkan augmentasi data berupa rotasi hingga 20° , *zoom* acak sebesar 20%, *shear transform* 0.2, dan pembalikan horizontal. Teknik ini menghasilkan variasi citra baru tanpa perlu menambah jumlah data asli.

Seluruh proses pra-pemrosesan dilakukan menggunakan kelas *ImageDataGenerator* dari pustaka *TensorFlow Keras*, yang secara otomatis menangani proses augmentasi, pembagian data, serta pembacaan citra dalam bentuk batch saat pelatihan berlangsung.

2.3 Proses Latih Data

Pada tahap ini dilakukan proses pelatihan model menggunakan data citra yang telah melalui tahap pra-pemrosesan. Model CNN dilatih dengan menggunakan *optimizer* Adam, fungsi *loss* *categorical cross-entropy*, serta metrik evaluasi akurasi untuk menilai kinerja model.

Berdasarkan hasil beberapa percobaan awal, diperoleh konfigurasi pelatihan terbaik yang digunakan pada penelitian ini. Proses pelatihan dijalankan dengan parameter *learning rate* sebesar 0.0002, Model dilatih selama 15 *epoch* dengan *batch size* berjumlah 32.

Data dibagi menjadi 70% untuk pelatihan dan 30% untuk validasi. Selama pelatihan, digunakan *callback EarlyStopping* dan *ReduceLROnPlateau* untuk menghentikan pelatihan secara otomatis ketika akurasi validasi tidak mengalami peningkatan serta menyesuaikan laju pembelajaran apabila model mulai mengalami stagnasi.

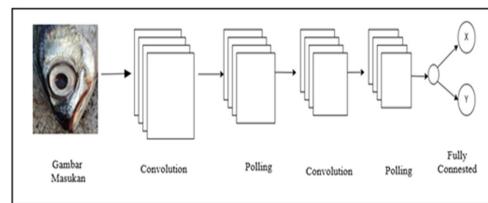
2.4 Convolutional Neural Network (CNN)

Pada penelitian ini, arsitektur *Convolutional Neural Network* (CNN) dibangun dari beberapa lapisan yang terhubung secara berurutan. Model diawali dengan dua lapisan *Convolutional Layer* yang masing-masing memiliki 32 dan 64 filter dengan ukuran kernel 3×3 serta menggunakan fungsi aktivasi ReLU berperan dalam mengekstraksi fitur penting dari gambar masukan. Setelah setiap lapisan konvolusi, terdapat lapisan *MaxPooling* berukuran 2×2 yang berfungsi untuk mereduksi dimensi fitur dan mempercepat proses komputasi. Hasil ekstraksi fitur kemudian diratakan melalui lapisan *Flatten* agar dapat diproses oleh lapisan-lapisan selanjutnya.

Selanjutnya, model memiliki dua lapisan *Fully Connected (Dense)* dengan 128 dan 64 neuron, yang masing-masing menggunakan fungsi aktivasi ReLU untuk memperkuat proses pembelajaran fitur. Untuk mencegah terjadinya *overfitting*, disisipkan dua

lapisan *Dropout* dengan tingkat penghapusan sebesar 0.5. Fungsi aktivasi *Softmax* diterapkan pada lapisan keluaran (*output layer*) sebagai penentu hasil klasifikasi, dengan dua neuron untuk menghasilkan prediksi terhadap dua kelas keluaran, yaitu Segar dan Tidak Segar.

Struktur umum arsitektur *Convolutional Neural Network* (CNN) yang digunakan pada penelitian ini ditunjukkan pada Gambar 1.



Gambar 1. Arsitektur Model CNN

Arsitektur pada Gambar 1 menunjukkan bahwa citra masukan melalui beberapa tahap konvolusi dan *pooling* untuk mengekstraksi fitur, kemudian hasilnya diteruskan ke lapisan *fully connected* yang menghasilkan dua keluaran kelas, yaitu Segar dan Tidak Segar.

3. HASIL DAN PEMBAHASAN

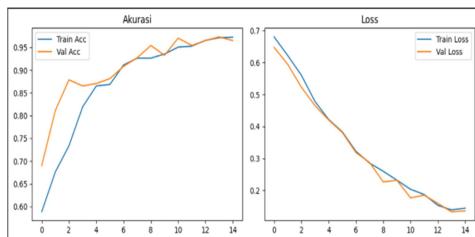
3.1 Hasil Pelatihan Model CNN

Model CNN dilatih menggunakan data citra mata ikan tongkol yang sudah melewati pra-pemrosesan data berupa resize, normalisasi, dan augmentasi data. Proses pelatihan model dilakukan dengan *optimizer* Adam, menggunakan fungsi *loss categorical cross-entropy* dan metrik akurasi sebagai indikator evaluasi performa model.

Parameter pelatihan yang digunakan terdiri dari learning rate sebesar 0.0002, model dilatih selama 15 *epoch* dengan *batch size* berjumlah 32, dengan pembagian data 70%

untuk pelatihan dan 30% untuk validasi.

Performa pelatihan ditunjukkan melalui grafik akurasi dan loss pada Gambar 2.

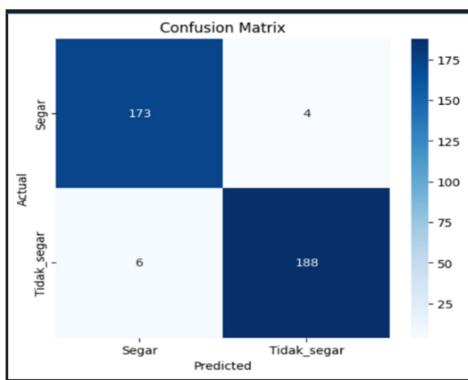


Gambar 2. Grafik Performa Pelatihan Model CNN

Dari grafik tersebut dapat dilihat bahwa akurasi model meningkat secara konsisten pada setiap epoch hingga mencapai stabilitas, sedangkan nilai loss mengalami penurunan bertahap. Hal ini menunjukkan bahwa model telah berhasil mempelajari fitur-fitur penting dari citra dengan baik dan tidak mengalami *overfitting* yang signifikan.

3.2 Evaluasi Model CNN

Proses evaluasi bertujuan untuk mengukur kemampuan model CNN dalam membedakan citra mata ikan tongkol menjadi dua kelas, yaitu segar dan tidak segar. Visualisasi hasil pengujian model ditunjukkan melalui *confusion matrix* pada Gambar 3.



Gambar 3. Confusion Matrix

Berdasarkan *confusion matrix*, model dapat mengklasifikasikan sebagian besar citra secara tepat. *Nilai True Positive (TP) dan True Negative (TN)* yang tinggi menunjukkan bahwa model memiliki akurasi dan kestabilan yang baik

Selain itu, performa model secara keseluruhan dapat dilihat pada Tabel 1, yang menampilkan hasil *classification report*.

Kelas	Precision	Recall	F1-Score
Segar	0.97	0.98	0.97
Tidak Segar	0.98	0.97	0.97
Rata-Rata	0.97	0.97	0.97
Akurasi			0.97
Keseluruhan			

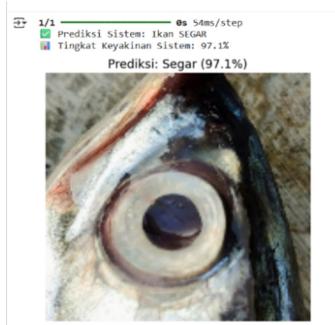
Tabel 1. Hasil *classification report*.

Berdasarkan hasil tersebut, model CNN mencapai akurasi sebesar 97%, dengan nilai precision dan recall yang tinggi serta seimbang pada kedua kelas. Hasil tersebut menunjukkan bahwa model memiliki kemampuan generalisasi yang baik, serta mampu membedakan fitur visual pada citra mata ikan antara kondisi segar dan tidak segar dengan tingkat akurasi yang tinggi.

Sebagai bentuk validasi tambahan, dilakukan pengujian langsung terhadap beberapa citra uji menggunakan model CNN yang telah dilatih.

Proses ini bertujuan untuk melihat kemampuan model dalam memberikan hasil klasifikasi secara visual terhadap citra mata ikan tongkol.

Hasil prediksi model ditampilkan dalam bentuk visual sebagaimana ditunjukkan pada gambar 4 dan gambar 5 sebagai berikut.



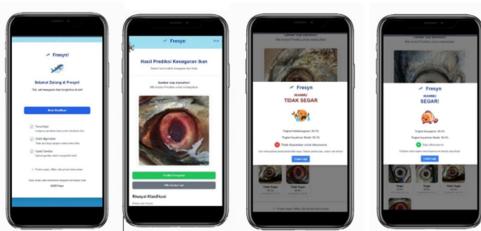
Gambar 4. Prediksi ikan segar



Gambar 5. Prediksi ikan tidak segar

Dengan hasil akurasi yang tinggi tersebut, model CNN dengan format .h5 kemudian diimplementasikan ke dalam aplikasi berbasis *website* agar dapat digunakan secara langsung oleh pengguna. Proses ini memungkinkan pengguna untuk mengunggah citra mata ikan tongkol dan memperoleh hasil klasifikasi secara otomatis.

Tampilan hasil prediksi sistem terhadap citra yang diunggah pengguna ditunjukkan pada Gambar 6



Gambar 6. Tampilan Klasifikasi Kesegaran ikan

Implementasi ini membuktikan bahwa model CNN dapat diintegrasikan dengan baik ke dalam sistem berbasis web, menghasilkan prediksi yang cepat dan akurat, serta mudah digunakan tanpa memerlukan perangkat khusus. Secara keseluruhan, kombinasi antara arsitektur CNN yang efektif dan antarmuka web yang interaktif menunjukkan bahwa pendekatan ini berpotensi diterapkan dalam dunia industri perikanan untuk membantu identifikasi kesegaran ikan secara otomatis dan efisien.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa penerapan metode *Convolutional Neural Network* (CNN) efektif dalam mengklasifikasikan tingkat kesegaran ikan tongkol berdasarkan citra mata. Melalui tahapan pra-pemrosesan berupa *resize*, normalisasi, dan augmentasi data, model CNN mampu mempelajari pola visual secara optimal dan menghasilkan tingkat akurasi sebesar 97% pada data uji. Nilai *precision* dan *recall* yang seimbang pada kedua kelas membuktikan kemampuan model dalam mengenali perbedaan karakteristik citra antara ikan segar dan tidak segar secara konsisten.

Hasil ini menegaskan bahwa fitur visual pada mata ikan dapat dijadikan indikator yang kuat untuk menilai kesegaran ikan secara otomatis. Selain itu, implementasi model ke dalam sistem berbasis web membuktikan bahwa teknologi *Convolutional Neural Network* dapat diintegrasikan dengan baik ke dalam aplikasi praktis yang mudah digunakan oleh masyarakat maupun pelaku industri perikanan.

Namun demikian, penelitian ini memiliki beberapa keterbatasan. Jumlah dataset yang terbatas dan kondisi pencahayaan yang belum seragam dapat mempengaruhi kemampuan generalisasi

model terhadap citra yang diambil di lingkungan berbeda. Selain itu, klasifikasi hanya dibatasi pada dua kategori kesegaran, sehingga belum mampu memberikan penilaian bertingkat yang lebih detail.

Sebagai tindak lanjut, penelitian selanjutnya disarankan untuk memperluas variasi dataset dengan menambahkan kondisi pengambilan gambar yang lebih beragam serta mempertimbangkan penggunaan model *transfer learning* agar performa sistem dapat ditingkatkan tanpa memerlukan data dalam jumlah besar. Sistem juga dapat dikembangkan ke arah klasifikasi multi-kelas atau penerapan *real-time detection* berbasis perangkat bergerak guna mendukung efisiensi dan kecepatan penilaian di lapangan.

Secara keseluruhan, hasil penelitian ini memberikan kontribusi terhadap pengembangan teknologi pengolahan citra digital dan *artificial intelligence* dalam mendukung sistem penilaian mutu hasil perikanan yang lebih objektif, efisien, dan terukur.

5. REFERENSI

- [1] A. Malirmasele, "Klasifikasi Kesegaran Ikan Pada Citra Mata Menggunakan VGG-16 Berbasis Web," *MARAS J. Penelit. Multidisplin*, vol. 2, no. 3, pp. 1337-1344, 2024, [Online]. Available: <https://ejournal.lumbungpare.org/index.php/maras>
- [2] A. M. Putri, "Semi Quantitative Risk Assessment Evaluation of Histamine on Pindang Cakalang Product in Jakarta," *Clarias J. Perikan. Air Tawar*, vol. 4, no. 1, pp. 25-32, 2023, doi: 10.56869/clarias.v4i1.478.
- [3] C. dotulong Masinambou *et al.*, "Pengujian Kandungan Histamin dan Mutu Organoleptik Bahan Baku Ikan Tuna Thunnus Albacares Kaleng," *Media Teknol. Has. Perikan.*, vol. 10, no. 3, pp. 143-149, 2022,
- [4] Zaenul Arif and Muhammad Lutfi, "Identifikasi Kesegaran Ikan Berdasarkan Citra Insang dengan Metode Convolution Neural Network," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 11, no. 3, pp. 1352-1360, 2022, doi: 10.35957/jatisi.v8i3.939.
- [5] C. Cakra, S. Syarif, H. Gani, and 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, pp. 74-79, 2022, doi: 10.51876/simtek.v7i2.138.
- [6] H. Honainah, F. F. Romadhoni, and A. Ato'illah, "Klasifikasi Kesegaran Ikan Tongkol Berdasarkan Warna Mata Menggunakan Metode Backpropagation," *J. Penelit. Inov.*, vol. 2, no. 2, pp. 405-414, 2022, doi: 10.54082/jupin.90.
- [7] W.- Styorini, A.- Pratiwi, and C.- Widiasari, "Identifikasi Tingkat Kesegaran Ikan Berbasis Android," *J. Amplif. J. Ilm. Bid. Tek. Elektro Dan Komput.*, vol. 12, no. 1, pp. 12-18, 2022, doi: 10.33369/jamplifier.v12i1.19174.
- [8] M. N. Takbir, S. M. Umar, and R. O. Lewa, "Sistem Identifikasi Kesegaran Ikan Berbasis Android Menggunakan Convolutional Neural Network (CNN)," vol. 7, 2024.