

FISH FRESHNESS PREDICTION WITH CONVOLUTIONAL NEURAL NETWORK METHOD BASED ON FISH EYE IMAGE ANALYSIS

Ruvita Faurina^{*1}, Robby Mahendra²

^{1,2}Informatics, Engineering Faculty, Universitas Bengkulu, Indonesia
Email: ruvita.faurina@unib.ac.id, robbymahendra2202@gmail.com

(Article received: August 27, 2023; Revision: September 14, 2023; published: June 05, 2024)

Abstract

The potential for fish resources in Bengkulu waters is abundant, but quality must be maintained for safety and selling value. Changes in the skin, eyes, gills and flesh of fish indicate a decrease in quality due to enzyme, chemical and bacterial activity. The process of sorting fish by fishermen or sellers is still often done manually, which is sometimes inaccurate due to limited vision. With advances in computing technology, classification algorithms are needed that can identify and differentiate between fresh fish and non-fresh fish. This research uses a Convolutional Neural Network with DenseNet201, VGG16, and InceptionV3 architecture. The dataset contains 880 Belato Alepes Djedaba fish eye images, with a ratio of 80:15:5 for train, validation, and test. DenseNet201 has the best performance compared to VGG16 and InceptionV3. Accuracy on DenseNet201 test data 98%, InceptionV3 95%, and VGG16 91%. The classification results of the best model using 8 images with various scenarios show that all images were successfully classified 100% correctly. This research makes a contribution to the field of fishery product processing technology which allows fish quality classification to be carried out quickly and accurately, as well as increasing efficiency in ensuring the quality of fish for consumption.

Keywords: *classification, confusion matrix, convolutional neural network, fish freshness, pretrained network.*

PREDIKSI KESEGERAN IKAN DENGAN METODE CONVOLUTIONAL NEURAL NETWORK BERDASARKAN ANALISIS CITRA MATA IKAN

Abstrak

Potensi sumber daya ikan di perairan Bengkulu melimpah, namun kualitas harus terjaga demi keamanan dan nilai jualnya. Perubahan pada kulit, mata, insang, dan daging ikan mengindikasikan penurunan kualitas akibat aktivitas enzim, kimiawi, dan bakteri. Proses penyortiran ikan oleh nelayan atau penjual masih sering dilakukan secara manual, yang terkadang tidak akurat karena adanya keterbatasan penglihatan. Dengan kemajuan teknologi komputasi, diperlukan algoritma klasifikasi yang dapat mengidentifikasi dan membedakan antara ikan segar dan ikan tidak segar. Penelitian ini menggunakan Convolutional Neural Network dengan arsitektur DenseNet201, VGG16, dan InceptionV3. Dataset berisi 880 citra mata ikan belato alepes djedaba, dengan perbandingan 80:15:5 untuk latih, validasi, dan uji. DenseNet201 memiliki performa terbaik dibandingkan VGG16 dan InceptionV3. Akurasi pada data uji DenseNet201 98%, InceptionV3 95%, dan VGG16 91%. Hasil klasifikasi pada model terbaik menggunakan 8 citra dengan berbagai skenario menunjukkan semua citra berhasil diklasifikasi 100% dengan benar. Penelitian ini memberikan kontribusi pada bidang teknologi pengolahan hasil perikanan yang memungkinkan klasifikasi kualitas ikan dilakukan dengan cepat dan akurat, serta meningkatkan efisiensi dalam memastikan kualitas ikan untuk konsumsi.

Kata kunci: *confusion matrix, convolutional neural network, kesegaran ikan, klasifikasi, pretrained network.*

1. PENDAHULUAN

Indonesia adalah negara maritim yang terdiri dari banyak pulau dan memiliki perairan luas. Potensi lautnya melimpah dengan berbagai spesies ikan yang dapat dikonsumsi. Ikan memiliki kandungan protein tinggi, asam lemak omega-3, serta vitamin dan mineral penting bagi tubuh. Selain itu, ikan juga memiliki harga yang lebih terjangkau dibandingkan

dengan sumber protein lainnya[1]. Ikan yang berkualitas adalah ikan yang masih segar, semakin lama ikan tertapar udara terbuka, kualitas kesegarannya akan semakin menurun. Perubahan pada mata ikan dapat menjadi indikator penurunan kualitas ikan tersebut[2]. Bengkulu merupakan salah satu provinsi di Indonesia yang memiliki perairan laut yang luas, sehingga daerah ini memiliki beragam

jenis ikan laut. Salah satu contoh ikan yang sering dikonsumsi masyarakat Bengkulu adalah ikan belato (nama lokal) atau *alepes djedaba*. Ikan belato memiliki warna putih dengan bercak hitam di bagian belakang *operculum*[3].

Dalam sektor perikanan, proses penyortiran ikan oleh nelayan atau penjual masih sering dilakukan secara manual, yang terkadang tidak akurat karena adanya keterbatasan penglihatan, terutama saat mereka sudah lelah. Selama ini pemeriksaan hanya dilihat secara fisik. Akibatnya, saat akan dikonsumsi ikan tersebut kerap kali sudah rusak. Dengan kemajuan teknologi komputasi, diperlukan algoritma klasifikasi yang dapat mengidentifikasi dan membedakan antara ikan segar dan ikan tidak segar. Ada banyak penelitian yang menangani masalah pemeriksaan kualitas kesegaran pada ikan. Salah satu pendekatan penelitian yang telah digunakan sebelumnya adalah penggunaan teknologi pengolahan citra digital[4].

Analisis citra dapat memeriksa kualitas ikan tanpa merusaknya dan aman bagi penguji. Metode ini memungkinkan pengolahan hasil perikanan dengan waktu yang relatif cepat sehingga memberikan informasi tentang kualitas ikan dengan akurat[5].

Beberapa penelitian sebelumnya menggunakan teknologi pengolahan citra digital mengenai prediksi kesegaran ikan, terbukti memberikan hasil yang cukup akurat. Pada tahun 2019, penelitian oleh Septioan Fauzi dan rekan-rekannya menggunakan *Convolutional Neural Network* untuk mengidentifikasi kesegaran citra ikan air tawar. Akurasi yang didapat sebesar 88,3% dengan total dataset sebanyak 300[6].

Convolutional Neural Network merupakan salah satu model yang paling populer dan akurat yang diimplementasikan dalam klasifikasi citra[7] Namun *Convolutional Neural Network* membutuhkan banyak data dan sumber daya komputasi. Dalam situasi dimana data terbatas, *transfer learning* dapat digunakan.

Transfer learning merupakan teknik *deep learning*, awalnya dilatih dengan dataset citra umum yang besar dan beragam, kemudian diterapkan pada tugas spesifik untuk memecahkan masalah yang lain. *Transfer learning* memungkinkan pelatihan mendalam dengan jumlah sampel kecil dengan akurasi tinggi[7]. Beberapa *transfer learning* yang populer adalah *VGGNet*, *DenseNet*, *MobileNet*, dan *Inception*[8]. Dalam penelitian ini, terdapat dua objek yang klasifikasikan, yaitu ikan segar dan ikan tidak segar.

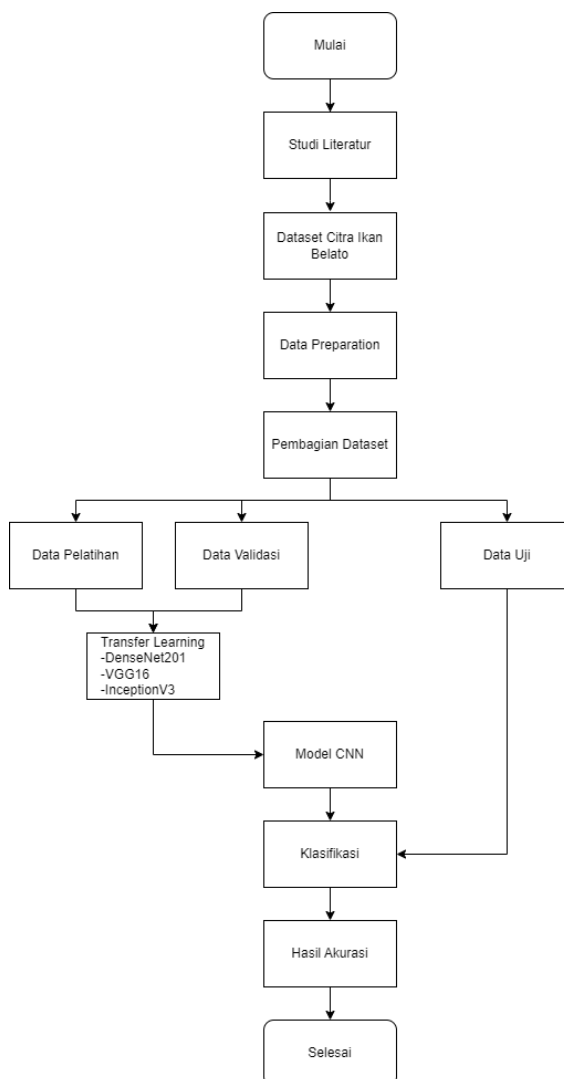
Mata ikan segar memiliki warna yang cerah, bola mata bening dan tidak keruh, serta bentuk yang tidak cekung. Disisi lain, mata ikan tidak segar terlihat keruh dengan warna kekuningan dan memiliki bentuk yang pecah atau melengkung ke dalam.

Transfer learning mempelajari pola dan fitur yang relevan dalam citra mata ikan, sehingga dapat

membedakan antara mata ikan segar dan mata ikan tidak segar berdasarkan data pelatihan. Dengan menggunakan *transfer learning*, klasifikasi mata ikan segar dan mata ikan tidak segar dapat dilakukan secara efektif [9]. Dari uraian latar belakang masalah dan kajian literatur singkat di atas maka penulis akan menggunakan *Convolutional Neural Network* yang bertujuan untuk membedakan ikan segar dan tidak segar.

2. METODE PENELITIAN

Tahapan Penelitian yang dilakukan dapat dilakukan pada Gambar 1.



Gambar 1. Tahapan Dalam Penelitian

2.1. Studi Literatur

Pada tahap studi literatur, peneliti melakukan pencarian sumber teori yang valid yang mendukung penelitian ini. Sumber data dan teori ini ditemukan melalui jurnal penelitian sebelumnya, jurnal yang relevan untuk mendukung teori yang dibuat, buku-buku, dan artikel di situs web yang mendukung pemahaman tentang penelitian ini. Tahap ini memiliki tujuan untuk digunakan sebagai referensi

dan memperkuat penelitian yang sedang dilakukan[10].

2.2. Dataset

Data yang digunakan yaitu data sekunder yang didapatkan dari peneliti sebelumnya yaitu Mario Haryzal. Data tersebut diambil menggunakan kamera *smartphone*, dengan tinggi pemotretan berkisar 10 cm - 60 cm, pada lokasi sekitar Pasar Pelabuhan Malabero Kec. Tlk. Segara, Kota Bengkulu[11].

Data tersebut terdiri dari citra ikan segar sebanyak 440 data dan ikan tidak segar sebanyak 440 data. Jadi, total data keseluruhan adalah 880 data dengan format *JPG*. Contoh data citra ikan segar yang digunakan dapat dilihat pada Gambar 1, dan ikan tidak segar pada gambar 2.



Gambar 1. Ikan Segar

Gambar 2. Ikan Tidak Segar

2.3. Data Preparation

Data preparation adalah tahap yang dilakukan untuk menyiapkan data pelatihan sebelum diolah. Preparation berfungsi untuk menghasilkan data citra yang lebih baik sebelum diproses ke tahap berikutnya. Tahap preparation yang dilakukan yaitu proses cropping bagian mata ikan[4], resize gambar menjadi 224 x 224 piksel. Split data membagi data menjadi 3 bagian yaitu data pelatihan sebesar 0.8, data validasi sebesar 0.15, dan data uji 0.05. Lalu augmentasi data dalam penelitian ini melibatkan berbagai transformasi pada data citra mata ikan. Ini termasuk flip horizontal dan vertical, rotasi acak, zoom acak, pergeseran acak dalam lebar dan tinggi, transformasi shear acak, dan pengisian piksel baru menggunakan nilai terdekat[12].

2.4. Modeling

Modeling dalam penelitian ini menggunakan tiga model Convolutional Neural Network yaitu DenseNet201, VGG16, dan InceptionV3. Melalui proses perbandingan model dan evaluasi, akhirnya dipilih satu model terbaik berdasarkan hasil evaluasi. Tahap yang dilalui untuk membuat model yaitu preparation data yaitu cropping, resizing, data split dan augmentasi. Kemudian melakukan transfer learning dengan import model yang telah dilatih sebelumnya dengan dataset imagenet. Selanjutnya buat model yang berisi pre-trained, fine tuning serta feature extractor, yang ditambah dengan layer full

connected. Kemudian lakukan pelatihan model terhadap data pelatihan. Melakukan perbandingan model untuk melihat model terbaik berdasarkan nilai accuracy dari proses evaluasi model[13]. Untuk mendapatkan model sistem terbaik diperlukan parameter uji sebagai nilai pembandingan untuk setiap model. Parameter performa yang digunakan dalam penelitian ini yaitu akurasi dan loss.[14].

2.5. Evaluasi

Pada tahap evaluasi, model yang telah dilatih akan diuji untuk mengukur seberapa baik kinerjanya. Beberapa evaluasi yang digunakan meliputi akurasi model terhadap data pelatihan, *loss* model terhadap data pelatihan, dan *confusion matrix*. Akurasi model mencerminkan seberapa tepat model dalam memprediksi data yang telah digunakan untuk pelatihan. *Loss* model menggambarkan sejauh mana perbedaan antara prediksi model dan label asli pada data pelatihan. Sementara itu, *confusion matrix* memberikan gambaran tentang jumlah prediksi yang benar (*true*) dan salah (*false*)[15].

Untuk mengukur performa, digunakan metrik-metrik performa yang direpresentasikan dalam persamaan (1) hingga (4). Salah satu metrik yang umum digunakan adalah akurasi (*Accuracy*), yang menghitung persentase sampel yang diklasifikasikan dengan benar, dan dihitung berdasarkan Persamaan (1).

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

Precision merupakan metrik yang mengukur seberapa tepat model dalam melakukan prediksi positif, yaitu seberapa banyak dari prediksi positif yang sebenarnya benar positif. *Precision* dihitung dengan menggunakan persamaan (2) dan memberikan informasi tentang seberapa akurat model dalam mengidentifikasi kasus positif.

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

Recall adalah metrik yang mengukur sejauh mana model dapat mengenali dengan akurat contoh-contoh positif, yaitu seberapa banyak dari keseluruhan contoh positif yang berhasil diidentifikasi dengan benar. Metrik ini dihitung menggunakan persamaan (3), di mana TP (*true positive*) adalah jumlah kasus positif yang berhasil diidentifikasi dengan benar, dan FN (*false negative*) adalah jumlah kasus positif yang salah diklasifikasikan sebagai negatif. *Sensitivity* memberikan informasi tentang kemampuan model dalam mendeteksi kasus positif secara komprehensif.

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

F1-Score adalah sebuah metrik yang menggabungkan presisi dan *recall* dengan memberikan bobot pada keduanya. Metrik ini

mengukur keseimbangan antara presisi dan *recall* dalam melakukan klasifikasi. *F1-Score* dihitung menggunakan persamaan (4). *F1-Score* memberikan gambaran tentang performa keseluruhan model dalam mengklasifikasikan contoh-contoh positif dan negatif dengan mempertimbangkan baik ketepatan dan kelengkapan prediksi [16].

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

3. HASIL DAN PEMBAHASAN

Dataset yang digunakan berjumlah 880 citra, dengan pembagian data 704 citra untuk data pelatihan, 132 citra untuk data validasi, dan 44 citra untuk data uji. Beberapa sampel data yang akan dijadikan bahan penelitian ditunjukkan pada Gambar 3 dan Gambar 4.



Gambar 3. Data Citra *Cropping* Ikan Segar



Gambar 4. Data Citra *Cropping* Ikan Tidak Segar.

3.1. Hyperparameter

Pada penelitian ini menggunakan *hyperparameter* seperti yang disajikan pada Tabel 1.


Tabel 1. *hyperparameter* yang digunakan

<i>Hyperparameter</i>	<i>DenseNet201</i>	<i>VGG16</i>	<i>InceptionV3</i>
<i>Optimizer</i>	Adam	Adam	Adam
<i>Batch size</i>	32	32	32
<i>Epoch</i>	30	30	30


<i>Loss function</i>	<i>categorical_crossentropy</i>	<i>categorical_crossentropy</i>	<i>categorical_crossentropy</i>
<i>Weight</i>	<i>Imagenet</i>	<i>Imagenet</i>	<i>Imagenet</i>
<i>Input image size</i>	50 x 50 pixel	50 x 50 pixel	75 x 75 pixel
<i>Fully Connected layer</i>	<i>Dense layer</i> pertama: 256 neuron. <i>Dense layer</i> kedua: 128 neuron.	<i>Dense layer</i> pertama: 128 neuron	<i>Dense layer</i> pertama: 128 neuron.

3.2. Hasil Pelatihan


Peneliti melakukan percobaan dengan tiga jenis *transfer learning Convolutional Neural Network* yaitu : *DenseNet201*, *VGG16*, dan *InceptionV3*. Pada gambar 5 grafik proses pelatihan *DenseNet201* memiliki pola pergerakan yang mirip dengan *inceptionV3*, keduanya cenderung naik turun dari *epoch* ke *epoch*, tetapi pada model *DenseNet201* dapat mencapai akurasi yang lebih tinggi. Pada gambar 6 akurasi model *VGG16* mengalami peningkatan yang sangat stabil tetapi tidak dapat mencapai akurasi yang terbaik. Dari gambar 7 dapat dilihat bahwa akurasi pada validasi *InceptionV3* mengalami naik turun yang cukup signifikan, dan hasil akhir *epoch* menunjukkan jarak yang paling jauh antara valid dan training dari ke tiga model. Hasil akhir semua *Convolutional Neural Network* yang peneliti uji menunjukkan bahwa *DenseNet201* mencapai kinerja terbaik. Akurasi pada data pelatihan dan validasi disajikan pada Tabel 2.




Gambar 5. Grafik Akurasi Pelatihan dan Validasi Menggunakan *DenseNet201*



Gambar 6. Grafik Akurasi Pelatihan dan Validasi Menggunakan *VGG16*



Gambar 7. Grafik Akurasi Pelatihan dan Validasi Menggunakan InceptionV3



Gambar 9. Grafik Loss Pelatihan dan Validasi Menggunakan VGG16


Tabel 2. Akurasi pada data pelatihan dan validasi

No	Arsitektur	Akurasi	
		Data Pelatihan	Data Validasi
1	DenseNet201	0.9867	0.9848
2	VGG16	0.9545	0.9772
3	InceptionV3	0.9526	0.9393


Nilai *Loss Function Convolutional Neural Network* pada akhir epoch pelatihan, seperti disajikan pada Tabel 3. Pada gambar 8, *DenseNet201* memiliki performa terbaik dengan nilai *loss* pelatihan dan validasi yang rendah, menunjukkan kemampuan baik dalam pembelajaran dan generalisasi. Pada gambar 9 menunjukkan performa *VGG16* yang sedikit lebih baik daripada *InceptionV3*, dengan penanganan *overfitting* yang lebih baik meskipun nilai *loss* validasi yang lebih tinggi. Pada gambar 10, *InceptionV3* memiliki *loss* pelatihan yang lebih tinggi, dan perbedaan *loss* pelatihan dan validasi yang lebih besar, menunjukkan adanya indikasi *overfitting*. Dalam pemilihan model, *DenseNet201* adalah pilihan yang tepat.

Tabel 3. Loss pada Data Pelatihan dan Validasi

No	Arsitektur	Loss	
		Data Pelatihan	Data Validasi
1	DenseNet201	0.0477	0.0425
2	VGG16	0.1060	0.0880
3	InceptionV3	0.1201	0.1371



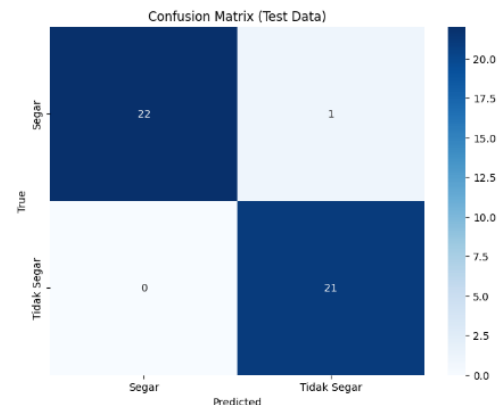
Gambar 8. Grafik Loss Pelatihan dan Validasi Menggunakan DenseNet201



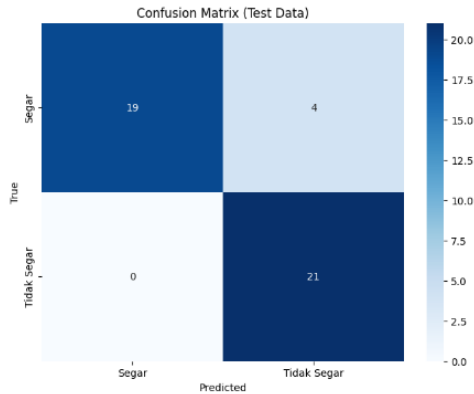
Gambar 10. Grafik Loss Pelatihan dan Validasi Menggunakan InceptionV3

3.3. Hasil Pengujian


Jika data validasi digunakan sebagai kontrol kinerja pada proses pelatihan dan selalu dilihat pada tiap *epoch*, maka data uji merupakan data yang belum pernah dilihat oleh *Convolutional Neural Network* selama pelatihan. Artinya, data ini dapat menjadi tolak ukur ketika sistem di implementasikan pada kasus nyata. Adakalanya, sebuah sistem mempunyai kinerja yang baik pada saat eksperimen, tetapi gagal ketika diimplementasikan pada kasus nyata. Data pada kasus nyata adalah data yang belum pernah dilihat oleh sistem, jadi di sinilah pentingnya kita juga menguji sistem menggunakan data uji.



Gambar 11. Confusion Matrix Model DenseNet201



Gambar 12. Confusion Matrix Model VGG16



Gambar 13. Confusion Matrix Model InceptionV3

Tabel 4. Kinerja Confusion Matrix pada Data Uji

Arsitektur	Precision	Recall	F1-Score	Akurasi
DenseNet201	1.00	0.96	0.98	0.98
	0.95	1.00	0.98	
VGG16	1.00	0.83	0.90	0.91
	0.84	1.00	0.91	
InceptionV3	0.92	1.00	0.96	0.95
	1.00	0.90	0.95	

Tabel 4 memuat hasil dari confusion matrix untuk tiga model yang telah dikembangkan. Gambar 11 menggambarkan confusion matrix untuk model DenseNet201, sementara Gambar 12 menampilkan confusion matrix untuk model VGG16, dan pada Gambar 13, terdapat confusion matrix untuk model InceptionV3.

Kinerja precision tertinggi ada pada model VGG16 dan InceptionV3 kelas segar sebesar 1.00 dan kinerja precision terendah pada model VGG16 pada kelas tidak segar sebesar 0.91. Kinerja Recall juga menunjukkan hasil yang mirip, kinerja tertinggi ada pada model VGG16 dan InceptionV3 kelas tidak segar sebesar 1.00 dan kinerja recall terendah pada model InceptionV3 pada kelas segar sebesar 0.87.





Kinerja F1-Score tertinggi dicapai oleh DenseNet201 sebesar 0.96 di kelas segar dan 0.96 di kelas tidak segar, dimana nilai ini jauh lebih unggul dibanding lainnya. Diposisi tertinggi kedua F1-score dicapai oleh VGG16 sebesar 0.95 dan 0.95, selanjutnya diikuti oleh InceptionV3. Dari sisi kinerja akurasi, DenseNet tetap lebih unggul dibanding lainnya sebesar 0.96. Secara urut dari kinerja terbaik dicapai oleh DenseNet201, VGG16, dan InceptionV3.



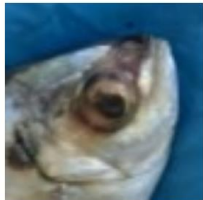

Dari hasil eksperimen perbandingan beberapa arsitektur Convolutional Neural Network untuk transfer learning dalam menyelesaikan masalah klasifikasi kesegaran ikan belato, DenseNet201 mencapai kinerja terbaik dibanding arsitektur lainnya seperti VGG16, dan InceptionV3. Dari hasil pengujian menunjukkan hasil bahwa DenseNet201 lebih tepat diimplementasikan karena memberikan kinerja lebih baik.

3.4. Akurasi Model

Setelah dilakukan pelatihan, validasi, dan pengujian pada ketiga transfer learning, didapatkan hasil bahwa model DenseNet201 merupakan model terbaik. Kemudian dilakukan pengujian dengan berbagai skenario menggunakan 8 citra yang terdiri dari 4 citra ikan segar dan 4 citra ikan tidak segar. Rincian hasil pengujian yang dilakukan dapat dilihat pada tabel 5.

Tabel 5. Pengujian Model Terbaik dengan Berbagai Skenario

No	Skenario	Prediksi	Presentase Kemiripan
HASIL PREDIKSI			
1.	Memprediksi citra ikan belato segar dengan gambar seluruh badan ikan		53%
IKAN SEGAR HASIL PREDIKSI			
2.	Memprediksi citra ikan belato segar dengan gambar setengah badan ikan		59%
IKAN SEGAR HASIL PREDIKSI			
3.	Memprediksi citra ikan belato segar dengan gambar hanya kepala ikan		98%
IKAN SEGAR HASIL PREDIKSI			
4.	Memprediksi citra ikan belato segar dengan gambar mata ikan		99%
IKAN SEGAR			

5.	Memprediksi citra ikan belato tidak segar dengan gambar seluruh badan ikan		91%
6.	Memprediksi citra ikan belato tidak segar dengan gambar setengah badan ikan		96%
7.	Memprediksi citra ikan belato tidak segar dengan gambar hanya kepala ikan		99%
8.	Memprediksi citra ikan belato tidak segar dengan gambar mata ikan		99%

4. DISKUSI

Dalam penelitian-penelitian sebelumnya mengenai prediksi kesegaran ikan, telah terbukti bahwa penggunaan model ini memberikan hasil yang lebih akurat. Pada tahun 2019, penelitian oleh Septioan Fauzi dan rekan-rekannya menggunakan *Convolutional Neural Network* untuk mengidentifikasi kesegaran citra ikan air tawar. Akurasi yang didapat sebesar 88,3% dengan total dataset sebanyak 300[6]. Lalu penelitian pada tahun 2021 yang dilakukan Miftahus Sholihin menggunakan *Convolutional Neural Network* pada citra insang ikan Tombro menghasilkan akurasi sebesar 97%[17]. Pada penelitian yang dilakukan Michael Christiawan dan rekan, menggunakan model *Convolutional Neural Network* dengan parameter mata dan warna insang menghasilkan akurasi sebesar 75% untuk analisis mata, dan 25% untuk analisis insang[18].

Dalam keseluruhan penelitian-penelitian tersebut, penggunaan *Convolutional Neural Network* telah terbukti efektif dalam meningkatkan akurasi

prediksi kesegaran ikan. Dengan demikian, dalam konteks penelitian ini, *Densenet201* dengan akurasi 98% dapat dipilih sebagai model terbaik untuk prediksi kesegaran ikan belato melalui citra mata ikan yang diteliti. Model ini memiliki tingkat akurasi yang tinggi dan dapat memberikan prediksi yang akurat.

Berdasarkan hasil penelitian ini, terdapat beberapa saran untuk pengembangan lebih lanjut dalam prediksi kesegaran ikan menggunakan *Convolutional Neural Network* dengan model *transfer learning*, antara lain penambahan jenis ikan yang dapat dideteksi, menambah parameter lain seperti insang dan juga dapat mendeteksi secara langsung.

5. KESIMPULAN

Dari hasil penelitian dan pembahasan pengolahan citra menggunakan *Convolutional Neural Network* dalam mengklasifikasikan kesegaran ikan menggunakan *transfer learning* dari arsitektur model *DenseNet201*, *VGG16*, dan *InceptionV3*, dapat ditarik kesimpulan bahwa model terbaik adalah *DenseNet201* dengan akurasi 98%. Sehingga dapat disimpulkan bahwa penerapan *Convolutional Neural Network* mampu mengklasifikasikan citra ikan segar dan tidak segar dengan sangat baik. Hasil klasifikasi pada model terbaik menggunakan 8 citra dengan berbagai skenario menunjukkan semua citra berhasil diklasifikasikan dengan benar.

Dengan kesimpulan di atas, ada beberapa hal yang dijadikan sebagai saran dalam penelitian selanjutnya antara lain memperbanyak *dataset*, menambah parameter lain seperti insang, penambahan jenis ikan yang bisa dideteksi, serta pengembangan pada aplikasi berbasis mobile agar dapat digunakan masyarakat luas sehingga lebih terasa manfaatnya.

DAFTAR PUSTAKA

- [1] Cakra, S. Syarif, H. Gani, A. Patombongi, and M. I. Andi, "Analisis Kesegaran Ikan Mujair Dan Ikan Nila Dengan Metode Convolutional Neural Network," *JURNAL SISTEM INFORMASI DAN TEKNIK KOMPUTER*, vol. 7, no. 2, pp. 74–79, 2022.
- [2] G. Ashari Rakhmat and M. Fikri Haekal, "Peningkatan Performa MobilenetV3 dengan Squeeze-and-Excitation (Studi Kasus Klasifikasi Kesegaran Ikan Berdasarkan Mata Ikan)," *Journal MIND Journal | ISSN*, vol. 8, no. 1, pp. 27–41, 2023, doi: 10.26760/mindjournal.v8i1.27-41.
- [3] A. R. Singkam, A. P. Yani, and A. Fajri, "Keragaman Ikan Laut Dangkal Provinsi Bengkulu," *Jurnal Enggano*, vol. 5, no. 3, pp. 424–438, 2020, doi: 10.31186/jenggano.5.3.424-438.
- [4] A. Agustyawan, "Pengolahan Citra untuk

- Membedakan Ikan Segar dan Tidak Segar Menggunakan Convolutional Neural Network,” *IJAI (Indonesian Journal of Applied Informatics)*, vol. 5, no. 1, pp. 11–19, 2020.
- [5] T. Dwi Novianto and I. Made Susi Erawan, “Perbandingan Metode Klasifikasi pada Pengolahan Citra Mata Ikan Tuna,” *Prosiding SNFA (Seminar Nasional Fisika dan Aplikasinya)*, pp. 216–223, 2020, doi: <https://doi.org/10.20961/prosidingsnfa.v5i0>.
- [6] S. Fauzi, P. Eosina, and G. F. Laxmi, “Implementasi Convolutional Neural Network Untuk Identifikasi Ikan Air Tawar,” *Seminar Nasional Teknologi Informasi (SEMNATI)*, vol. 2, pp. 163–167, 2019.
- [7] R. Fadiyah Alya and M. Wibowo, “CLASSIFICATION OF BATIK MOTIF USING TRANSFER LEARNING ON CONVOLUTIONAL NEURAL NETWORK (CNN),” vol. 4, no. 1, pp. 161–170, 2023, doi: [10.20884/1.jutif.2023.4.1.564](https://doi.org/10.20884/1.jutif.2023.4.1.564).
- [8] D. M. Wonohadidjojo, “Perbandingan Convolutional Neural Network pada Transfer Learning Method untuk Mengklasifikasikan Sel Darah Putih,” *Ultimatics : Jurnal Teknik Informatika*, vol. 13, no. 1, p. 51, 2021.
- [9] D. F. Anas, I. Jaya, and Nurjanah, “Design and implementation of fish freshness detection algorithm using deep learning,” in *IOP Conference Series: Earth and Environmental Science*, IOP Publishing Ltd, Dec. 2021. doi: [10.1088/1755-1315/944/1/012007](https://doi.org/10.1088/1755-1315/944/1/012007).
- [10] R. Prabowo, D. Lestari, and * Korespondensi, “Klasifikasi Image Tumbuhan Obat Sirih Hijau dan Sirih Merah Menggunakan Metode Decision Tree Medicinal Plants Image Classification of Green Betel and Red Betel Using Decision Tree Method,” *Online) Teknologi: Jurnal Ilmiah Sistem Informasi*, vol. 12, no. 1, pp. 16–22, 2023, doi: [10.26594/teknologi.v13i1.3352](https://doi.org/10.26594/teknologi.v13i1.3352).
- [11] M. Haryzal, “Identifikasi Kesegaran Ikan Hasil Tangkapan Menggunakan Mask R-Cnn,” University of Bengkulu, Bengkulu, 2022.
- [12] A. E. Wijaya, W. Swastika, and O. H. Kelana, “Implementasi Transfer Learning Pada Convolutional Neural Network Untuk Diagnosis Covid-19 Dan Pneumonia Pada Citra X-Ray,” *SAINSBERTEK Jurnal Ilmiah Sains & Teknologi*, vol. 2, no. 1, 2021.
- [13] E. Prasetyo, R. Purbaningtyas, R. Dimas Adityo, E. T. Prabowo, A. I. Ferdiansyah, and P. Korespondensi, “Perbandingan Convolution Neural Network Untuk Klasifikasi Kesegaran Ikan Bandeng Pada Citra Mata A Comparison Of Convolution Neural Network For Classifying Milkfish’s Freshness On Eye Images,” *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 8, no. 3, pp. 601–608, 2021, doi: [10.25126/jtiik.202184369](https://doi.org/10.25126/jtiik.202184369).
- [14] N. D. Miranda, L. Novamizanti, and S. Rizal, “CONVOLUTIONAL NEURAL NETWORK PADA KLASIFIKASI SIDIK JARI MENGGUNAKAN RESNET-50,” *Jurnal Teknik Informatika (Jutif)*, vol. 1, no. 2, pp. 61–68, Dec. 2020, doi: [10.20884/1.jutif.2020.1.2.18](https://doi.org/10.20884/1.jutif.2020.1.2.18).
- [15] F. Mashuri and U. Enri, “Implementasi Transfer Learning Dalam Mendeteksi Penyakit Pada Daun Gandum,” *JURNAL NUANSA INFORMATIKA*, vol. 16, no. 1, pp. 66–77, 2022, [Online]. Available: <https://journal.uniku.ac.id/index.php/ilkom>
- [16] D. M. Wonohadidjojo, “Perbandingan Convolutional Neural Network pada Transfer Learning Method untuk Mengklasifikasikan Sel Darah Putih,” *Ultimatics : Jurnal Teknik Informatika*, vol. 13, no. 1, p. 51, 2021.
- [17] M. Sholihin and M. Rosidi Zamroni, “Identifikasi Kesegaran Ikan Berdasarkan Citra Insang Dengan Metode Convolution Neural Network,” *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 8, no. 3, 2021, [Online]. Available: <http://jurnal.mdp.ac.id>
- [18] M. Christiawan, L. Willyanto Santoso, and D. Haryadi Setiabudi, “Deteksi Tingkat Kesegaran Ikan Menggunakan Metode Convolutional Neural Network Dengan Parameter Mata dan Warna Insang,” *Jurnal Infra*, vol. 9, no. 2, pp. 213–219, 2021.