

Perbandingan Arsitektur ResNet18 dan ConvNeXt-Tiny untuk Klasifikasi Jenis Ikan Berbasis Transfer Learning

Comparison of ResNet18 and ConvNeXt-Tiny Architectures for Transfer Learning-Based Fish Species Classification

Septia Nawang Wulan^{*1}, Retno Wahyusari²

Program Studi Informatika, Universitas Teknologi Ronggolawe, Cepu, Indonesia

E-mail : nawangwulannn30@gmail.com^{*1}, retnowahyusari@gmail.com²

^{*}Corresponding author

Received 14 June 2026; Revised 3 August 2026; Accepted 12 August 2026

Abstrak - Identifikasi jenis ikan merupakan proses penting dalam sektor perikanan, namun metode konvensional yang mengandalkan pengamatan visual masih memiliki keterbatasan dalam hal efisiensi dan akurasi. Penelitian ini bertujuan untuk mengklasifikasikan jenis ikan menggunakan metode Convolutional Neural Network (CNN) berbasis transfer learning dengan membandingkan arsitektur ResNet18 dan ConvNeXt-Tiny. Dataset yang digunakan adalah Fish Dataset dari Kaggle yang terdiri dari 13.304 citra ikan. Tahap preprocessing meliputi resize citra menjadi 224×224 piksel, normalisasi, transformasi tensor, dan augmentasi data. Proses pelatihan dilakukan menggunakan optimizer Adam dan fungsi loss *CrossEntropyLoss* dengan variasi epoch 10 hingga 100. Hasil menunjukkan bahwa kedua model mengalami peningkatan akurasi seiring bertambahnya jumlah epoch. ResNet18 menunjukkan kemampuan adaptasi yang lebih cepat pada tahap awal pelatihan, sedangkan ConvNeXt-Tiny memberikan performa yang lebih baik pada tahap akhir. *Accuracy* tertinggi diperoleh ConvNeXt-Tiny sebesar 96,93%, lebih tinggi dibandingkan ResNet18 sebesar 94,26%. Selain itu, ConvNeXt-Tiny menunjukkan peningkatan performa yang lebih konsisten seiring bertambahnya epoch pelatihan. Hasil menunjukkan bahwa transfer learning efektif diterapkan pada klasifikasi jenis ikan dan ConvNeXt-Tiny memiliki kemampuan yang lebih baik dalam merepresentasikan fitur visual citra ikan.

Kata Kunci - Klasifikasi Jenis Ikan, CNN, Transfer Learning, ResNet18, ConvNeXt-Tiny.

Abstract - Fish species identification is a crucial process in the fisheries sector, but conventional methods that rely on visual observation still have limitations in terms of efficiency and accuracy. This study aims to classify fish species using a transfer learning-based Convolutional Neural Network (CNN) method by comparing the ResNet18 and ConvNeXt-Tiny architectures. The dataset used is the Fish Dataset from Kaggle consisting of 13,304 fish images. The preprocessing stage includes image resizing to 224×224 pixels, normalization, tensor transformation, and data augmentation. The training process was carried out using the Adam optimizer and the *CrossEntropyLoss* loss function with epoch variations of 10 to 100. The results show that both models experience increased accuracy as the number of epochs increases. ResNet18 shows faster adaptation capabilities in the early stages of training, while ConvNeXt-Tiny provides better performance in the final stages. The highest accuracy obtained by ConvNeXt-Tiny is 96.93%, higher than ResNet18 at 94.26%. Furthermore, ConvNeXt-Tiny shows more consistent performance improvement as the number of training epochs increases. The results indicate that transfer learning is effective for fish species classification and that ConvNeXt-Tiny has a better ability to represent visual features of fish images.

Keywords - Fish Species Classification, CNN, Transfer Learning, ResNet18, ConvNeXt-Tiny.

1. PENDAHULUAN

Indonesia sebagai negara maritim memiliki potensi sumber daya perikanan yang sangat besar dan berperan penting dalam menunjang ketahanan pangan, pertumbuhan ekonomi, serta pelestarian keanekaragaman hayati akuatik [1]. Dalam sektor ini, proses identifikasi jenis ikan menjadi aspek krusial karena berkaitan langsung dengan kegiatan budidaya, distribusi hasil tangkapan, pengendalian kualitas produk, hingga pemantauan spesies yang dilindungi [2], [3]. Namun demikian, metode identifikasi secara konvensional yang mengandalkan pengamatan visual oleh tenaga ahli masih memiliki berbagai keterbatasan, di antaranya bersifat subjektif, membutuhkan waktu relatif lama, serta berpotensi menimbulkan kesalahan klasifikasi akibat kemiripan karakteristik morfologi antarspesies. Selain itu, faktor eksternal seperti variasi pencahayaan, sudut pengambilan gambar, latar belakang yang kompleks, serta perbedaan ukuran objek turut menjadi tantangan dalam proses klasifikasi citra ikan [2].

Perkembangan teknologi computer vision dan deep learning membuka peluang untuk mengatasi keterbatasan metode identifikasi konvensional melalui pendekatan otomatis berbasis citra digital. Salah satu metode yang banyak digunakan adalah Convolutional Neural Network (CNN), yaitu model jaringan saraf tiruan yang dirancang untuk memproses data visual melalui serangkaian operasi konvolusi, fungsi aktivasi nonlinier, dan pooling. CNN memiliki kemampuan melakukan ekstraksi fitur secara otomatis sehingga mampu mengenali pola visual kompleks tanpa memerlukan rekayasa fitur secara manual [4]. Dalam klasifikasi jenis ikan, CNN dapat mempelajari berbagai karakteristik visual seperti pola tekstur sisik, bentuk tubuh, struktur sirip, kontur kepala, dan distribusi warna yang menjadi pembeda antarspesies [5].

Meskipun demikian, pelatihan CNN dari awal (*training from scratch*) membutuhkan dataset dalam jumlah besar, sumber daya komputasi tinggi, serta waktu pelatihan yang relatif lama. Pada kasus klasifikasi jenis ikan, keterbatasan jumlah data, distribusi dataset yang tidak seimbang, dan variasi kondisi visual objek menyebabkan model rentan mengalami *overfitting* sehingga kemampuan generalisasi terhadap data baru menjadi kurang optimal [6]. Untuk mengatasi permasalahan tersebut, pendekatan Transfer Learning menjadi salah satu metode yang banyak diterapkan. Transfer learning memungkinkan model memanfaatkan bobot awal (*pre-trained weights*) dari model yang telah dilatih pada dataset skala besar, kemudian dilakukan penyesuaian (*fine-tuning*) pada dataset target yang lebih spesifik. Pendekatan ini mampu mempercepat proses pelatihan, meningkatkan efisiensi komputasi, dan mempertahankan performa klasifikasi yang tinggi meskipun menggunakan dataset yang relatif terbatas [7].

Berbagai penelitian sebelumnya menunjukkan bahwa CNN dan transfer learning memberikan hasil yang menjanjikan pada tugas klasifikasi citra. Penelitian F. Ningsih, A. Suhendar [4], A. Rahman, dkk [7], W. D. Setiawan, dkk [8] menegaskan bahwa kombinasi CNN dengan augmentasi data dapat meningkatkan robustness model terhadap variasi visual seperti rotasi, perubahan pencahayaan, dan skala objek.

Penerapan transfer learning berbasis CNN juga menunjukkan performa tinggi pada berbagai domain klasifikasi citra lainnya. Penelitian Holid saparudin, dkk [9] menggunakan arsitektur ResNet-18 pada klasifikasi kerusakan jalan berbasis citra dan memperoleh akurasi sebesar 92%, sehingga menunjukkan kemampuan yang baik dalam mengenali pola visual kompleks. Penelitian G. Mediose, dan J. Supardi [10] menerapkan ResNet18 pada klasifikasi kondisi gigi berbasis citra RGB dan memperoleh *accuracy* hingga 97% pada kelas tertentu, memperlihatkan kemampuan ekstraksi fitur visual yang kuat. Sementara itu, penelitian A. Faouzi, dkk [11] menggunakan ConvNeXt berbasis *transfer learning* pada klasifikasi varietas beras dan memperoleh akurasi sebesar 98% setelah pelatihan selama 10 epoch.


Meskipun berbagai penelitian terdahulu menunjukkan capaian *accuracy* yang tinggi, sebagian besar penelitian masih berfokus pada perbandingan arsitektur model serta pencapaian nilai akurasi akhir [12], [13]. Kajian mengenai efektivitas transfer learning sebagai strategi untuk meningkatkan efisiensi proses pelatihan dan kemampuan generalisasi model pada klasifikasi jenis

ikan masih relatif terbatas. Selain itu, sebagian penelitian lebih menitikberatkan pada optimasi melalui augmentasi data atau modifikasi arsitektur tanpa mengkaji secara mendalam bagaimana transfer learning memengaruhi kemampuan model dalam membedakan kelas ikan yang memiliki kemiripan morfologi tinggi [5], [3]. Kondisi tersebut menunjukkan adanya research gap yang masih terbuka pada penerapan transfer learning untuk klasifikasi jenis ikan.

Berdasarkan telaah terhadap penelitian terdahulu, kebaruan (*novelty*) penelitian ini terletak pada analisis penerapan CNN berbasis Transfer Learning untuk klasifikasi jenis ikan melalui perbandingan dua arsitektur yang memiliki karakteristik berbeda, yaitu ResNet18 dan ConvNeXt-Tiny. Berbeda dengan penelitian sebelumnya yang umumnya berfokus pada peningkatan *accuracy* melalui pemilihan arsitektur tanpa perbandingan dengan arsitektur lainnya [12], [13], Penelitian ini tidak hanya membandingkan nilai *accuracy* antara ResNet18 dan ConvNeXt-Tiny, tetapi juga menganalisis pola perkembangan konvergensi model pada rentang 10 hingga 100 epoch. Evaluasi berbasis confusion matrix dan metrik klasifikasi lengkap (*Precision*, *Recall*, *F1-Score*) juga diterapkan untuk menguji ketepatan model dalam membedakan 31 kelas ikan yang kemiripan morfologi tinggi.

2. METODE PENELITIAN

Proses ini disusun secara sistematis untuk melakukan klasifikasi jenis ikan menggunakan metode CNN dengan tujuan memperoleh model terbaik. Hasil penelitian diharapkan mampu memberikan performa klasifikasi yang optimal serta menjadi dasar dalam analisis perbandingan antararsitektur model yang digunakan. Alur tahapan penelitian ditunjukkan pada Gambar 1.



Gambar 1. Tahapan penelitian

2.1. Pengumpulan Data

Data dalam penelitian ini diperoleh dari Kaggle, yaitu *Fish Dataset* Kaggle oleh Mark Daniel Lampa, jumlah data yang digunakan sebanyak 13.304 citra yang telah terorganisasi dalam 31 jenis kelas ikan. Citra memiliki variasi ukuran, pencahayaan, dan latar belakang, sehingga dilakukan preprocessing agar data lebih seragam dan siap digunakan. Dataset kemudian dibagi menjadi tiga bagian utama, yaitu data pelatihan (training), data validasi (validation), dan data pengujian (testing). Pembagian data dilakukan dengan proporsi 70% untuk data pelatihan, 15% untuk data validasi, dan 15% untuk data pengujian. Berikut contoh beberapa gambar dataset

ditunjukkan pada Gambar 2.



Gambar 2. Dataset

2.2. Preprocessing Data

Pada tahap ini, seluruh citra dilakukan preprocessing dengan mengubah ukuran citra (resize) menjadi 224×224 piksel agar sesuai dengan kebutuhan input model CNN. Sebelum dilakukan resize, setiap citra memiliki resolusi yang berbeda sehingga tidak dapat langsung diproses oleh model. Setelah resize, seluruh citra memiliki ukuran yang sama sehingga memudahkan proses pelatihan. Selanjutnya, dilakukan normalisasi nilai piksel dari rentang 0–255 menjadi 0–1 untuk menjaga kestabilan distribusi data selama proses pelatihan. Normalisasi membantu model melakukan pembelajaran secara lebih efisien serta menghindari fluktuasi yang berlebihan pada proses optimasi. Tahap berikutnya adalah transformasi citra ke dalam bentuk tensor agar dapat diproses secara numerik oleh model CNN. Dengan transformasi ini, data dapat diolah dalam bentuk batch sehingga meningkatkan efisiensi komputasi selama proses pelatihan. Selain itu, dilakukan penerapan data augmentation untuk meningkatkan variasi data latih, meliputi rotasi, flipping horizontal, zoom, dan pergeseran posisi objek. Augmentasi memungkinkan model mempelajari berbagai variasi kondisi citra sehingga meningkatkan kemampuan generalisasi, dengan tetap menjaga karakteristik utama objek. Secara keseluruhan, tahapan preprocessing ini berperan penting dalam meningkatkan kualitas representasi citra sehingga model dapat mempelajari pola secara lebih optimal.

Tabel 1. Perubahan Data pada Tahap Preprocessing

Tahap	Sebelum	Sesudah	Dampak
Resize	Ukuran bervariasi	224×224	Input seragam
Normalisasi	0–255	0–1	Training stabil
Tensor	Citra biasa	Data numerik	Bisa diproses model
Augmentasi	Data terbatas	Data bervariasi	Generalisasi meningkat

Setiap tahapan preprocessing memberikan kontribusi yang berbeda dalam menyiapkan data sebelum proses pelatihan, seperti yang ditunjukkan dalam Tabel 1. Resize digunakan untuk menyeragamkan ukuran gambar, normalisasi membantu menstabilkan proses pembelajaran, transformasi tensor memungkinkan data diproses oleh model CNN, augmentasi data meningkatkan variasi data latih sehingga dapat mengurangi risiko overfitting dan meningkatkan kemampuan generalisasi model.


2.3. Transfer Learning

Metode yang digunakan adalah transfer learning, yaitu pendekatan pembelajaran mesin yang memanfaatkan model yang telah dilatih sebelumnya pada dataset berskala besar seperti ImageNet dataset. Pendekatan ini terbukti mampu meningkatkan performa klasifikasi serta mempercepat proses pelatihan, terutama pada dataset dengan jumlah data terbatas [14]. Arsitektur yang digunakan adalah ResNet18 dan ConvNeXt-Tiny, yang merupakan bagian dari CNN dengan

performa tinggi dalam klasifikasi citra. Kedua model ini telah memiliki *pre-trained weights* sehingga mampu mengekstraksi fitur visual seperti tekstur, bentuk, dan pola objek secara efektif [9], [15]. Proses transfer learning dilakukan dengan pendekatan feature extraction, yaitu dengan membekukan (freeze) seluruh layer pada model dasar sehingga bobot tidak berubah selama pelatihan. Selanjutnya, hanya layer akhir yang dimodifikasi dan dilatih ulang sesuai jumlah kelas pada dataset penelitian [16]. Pendekatan ini memungkinkan model memanfaatkan fitur umum yang telah dipelajari sebelumnya dan menyesuaikannya dengan tugas baru. Hal ini membuat proses pelatihan lebih efisien, mempercepat konvergensi, serta mengurangi risiko overfitting [17].

2.4. Training ResNet18


ResNet-18 adalah arsitektur CNN yang terdiri dari 18 lapisan dan menggunakan konsep residual learning melalui *shortcut connection* (skip connection). Mekanisme ini memungkinkan informasi dan gradien mengalir lebih efektif selama proses pelatihan sehingga dapat mengurangi masalah *vanishing gradient* pada jaringan yang dalam. Karena memiliki performa yang baik dengan kompleksitas yang relatif ringan, ResNet-18 banyak digunakan untuk tugas klasifikasi citra dan berbagai aplikasi *computer vision* lainnya [18]. Skema arsitektur lengkap dari varian ResNet18 disajikan pada Gambar 3.



Gambar 3. Arsitektur ResNet18

2.5. Training ConvNeXt-Tiny

ConvNeXt-Tiny adalah arsitektur CNN modern yang dikembangkan dengan mengadaptasi beberapa prinsip desain dari Vision Transformer (ViT) ke dalam jaringan konvolusi. Model ini menggunakan struktur hierarkis, *depthwise convolution*, dan *layer normalization* untuk meningkatkan efisiensi serta akurasi dalam tugas klasifikasi citra. Meskipun berbasis CNN murni, ConvNeXt-Tiny mampu mencapai performa yang kompetitif dibandingkan arsitektur Transformer pada berbagai tugas *computer vision* [19]. Skema arsitektur lengkap dari varian ConvNeXt-Tiny disajikan pada Gambar 4.



Gambar 4. Arsitektur ConvNeXt-Tiny

2.6. Training Model

Proses pelatihan (*training*) dilakukan menggunakan data latih (*training set*) dengan memanfaatkan algoritma optimasi Adam (*Adaptive Moment Estimation*) dengan fungsi loss *CrossEntropyLoss*. Optimizer Adam dipilih karena mampu mempercepat proses konvergensi dan memberikan performa yang stabil pada pelatihan model *deep learning* [20]. Nilai *learning rate* yang digunakan sebesar 0,0001 untuk menjaga kestabilan pembaruan bobot selama proses pelatihan model. Pemilihan *learning rate* yang tepat sangat penting karena berpengaruh terhadap proses konvergensi dan performa model, di mana nilai 0,0001 terbukti memberikan hasil yang optimal pada berbagai kasus klasifikasi citra berbasis *deep learning* [21]. Selama proses *training*, model mempelajari pola visual dari data latih untuk membedakan setiap kelas ikan berdasarkan karakteristik citra seperti bentuk, warna, dan tekstur. CNN mampu mengekstraksi fitur-fitur visual tersebut secara otomatis melalui proses pembelajaran berlapis sehingga efektif digunakan untuk tugas klasifikasi citra [22]. Pelatihan dilakukan dengan variasi jumlah *epoch*, yaitu 10 hingga 100 *epoch*, guna mengetahui pengaruh jumlah iterasi terhadap performa model. Semakin besar jumlah *epoch*, model memiliki kesempatan lebih banyak untuk mempelajari pola data, namun juga berpotensi mengalami *overfitting* apabila pelatihan berlangsung terlalu lama [23]. Setelah setiap proses pelatihan selesai, model dievaluasi menggunakan data validasi (*validation set*) untuk mengukur tingkat akurasi performa model. Nilai akurasi yang diperoleh dari setiap variasi *epoch* kemudian dicatat dan digunakan untuk membandingkan performa model ResNet18 dan ConvNeXt-Tiny dalam proses klasifikasi jenis ikan [24].

2.7. Evaluasi Model

Tahap evaluasi dilakukan untuk mengukur kemampuan model dalam melakukan klasifikasi jenis ikan secara akurat. Pada penelitian ini, parameter evaluasi yang digunakan adalah *accuracy*. Parameter ini digunakan untuk mengetahui tingkat ketepatan model dalam memprediksi kelas ikan berdasarkan data uji (*testing set*). *Accuracy* dihitung dengan membandingkan jumlah prediksi yang benar terhadap seluruh jumlah data yang diuji. Semakin tinggi nilai *accuracy*, maka semakin baik performa model dalam melakukan klasifikasi. Evaluasi dilakukan menggunakan data uji yang tidak digunakan selama proses pelatihan, sehingga hasil evaluasi dapat menggambarkan kemampuan generalisasi model terhadap data baru [24].

Secara matematis, nilai *accuracy* dapat dihitung menggunakan rumus berikut:

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

Keterangan:

TP = *True Positive*

TN = *True Negative*

FP = *False Positive*


FN = *False Negative*

Nilai *accuracy* dari setiap model kemudian dibandingkan untuk mengetahui model dengan performa terbaik dalam klasifikasi jenis ikan menggunakan metode *transfer learning* berbasis CNN.

3. HASIL DAN PEMBAHASAN

3.1. Preprocessing Data

Pada penelitian ini, data citra ikan yang diperoleh dari dataset memiliki ukuran dan karakteristik yang beragam. Oleh karena itu, dilakukan tahap preprocessing untuk menyiapkan data sebelum digunakan pada proses pelatihan model. Tahapan preprocessing yang diterapkan meliputi resize, normalisasi, transformasi tensor, dan augmentasi data. Hasil dari proses tersebut ditunjukkan pada Gambar 5.



Gambar 5. Hasil preprocessing data berupa resize, normalisasi, transformasi tensor, dan augmentasi citra

Tahap preprocessing, seluruh citra diubah ukurannya menjadi 224x224 piksel agar memiliki dimensi yang seragam dan sesuai dengan input model. Selanjutnya, dilakukan normalisasi nilai piksel dari rentang 0–255 menjadi 0–1 untuk menstandarisasi data. Citra kemudian ditransformasikan ke dalam bentuk tensor berukuran (3, 224, 224) sehingga dapat diproses oleh model CNN. Selain itu, diterapkan augmentasi data berupa *horizontal flip* untuk menambah variasi data latih. Berdasarkan hasil preprocessing, seluruh citra berhasil diubah menjadi format yang lebih seragam dan siap digunakan pada proses pelatihan model klasifikasi jenis ikan.

3.2. Hasil Evaluasi Model

Hasil pengujian model ResNet18 dan ConvNeXt-Tiny pada proses klasifikasi jenis ikan ditunjukkan pada Tabel 2. Evaluasi dilakukan menggunakan parameter *accuracy* untuk mengetahui perkembangan performa model selama proses pelatihan dari epoch ke-10 hingga epoch ke-100.


Tabel 2. Perbandingan *Accuracy* ResNet18 dan ConvNeXt-Tiny pada Setiap Epoch

Epoch	ResNet18 (%)	ConvNeXt-Tiny (%)
10	60,3	39,35
20	74,44	62,07
30	79,27	75,64
40	83,87	82,51
50	86,82	87,73
60	88,75	90,23

70	90,4	92,62
80	92,05	95,06
90	93,18	96,37
100	94,26	96,93

Berdasarkan Tabel 2, kedua model menunjukkan peningkatan performa yang konsisten selama proses pelatihan. Pada epoch awal, ResNet18 memiliki nilai *accuracy* yang lebih tinggi dibandingkan ConvNeXt-Tiny. Pada epoch ke-10, ResNet18 memperoleh akurasi sebesar 60,30%, sedangkan ConvNeXt-Tiny mencapai 39,35%. Hasil tersebut menunjukkan bahwa ResNet18 mampu beradaptasi lebih cepat terhadap dataset pada tahap awal pelatihan.

Seiring bertambahnya epoch, kedua model mengalami peningkatan akurasi secara bertahap. Pada epoch ke-40, perbedaan performa mulai mengecil dengan nilai *accuracy* sebesar 83,87% pada ResNet18 dan 82,51% pada ConvNeXt-Tiny. Setelah memasuki epoch ke-50, ConvNeXt-Tiny mulai menunjukkan performa yang lebih baik dengan nilai akurasi sebesar 87,73%, sedikit lebih tinggi dibandingkan ResNet18 yang memperoleh 86,82%. Kondisi ini menunjukkan bahwa ConvNeXt-Tiny memerlukan waktu adaptasi pada tahap awal, namun memiliki kemampuan pembelajaran yang lebih baik setelah model mempelajari pola visual pada dataset.



Gambar 6. Grafik Perbandingan *Accuracy* ResNet18 dan ConvNeXt-Tiny

Berdasarkan Gambar 6, terlihat bahwa kedua model mengalami peningkatan *accuracy* yang cukup signifikan selama proses pelatihan. Kurva ResNet18 berada di atas ConvNeXt-Tiny pada epoch awal, menunjukkan bahwa model tersebut memiliki kemampuan adaptasi yang lebih cepat terhadap dataset. Namun demikian, peningkatan *accuracy* ConvNeXt-Tiny berlangsung lebih tajam pada epoch menengah hingga akhir.

Titik perubahan performa mulai terlihat pada sekitar epoch ke-50 ketika ConvNeXt-Tiny mulai melampaui ResNet18. Setelah titik tersebut, kurva ConvNeXt-Tiny terus menunjukkan tren peningkatan yang lebih tinggi dibandingkan ResNet18 hingga akhir pelatihan. Pada epoch ke-100, ConvNeXt-Tiny mencapai *accuracy* sebesar 96,93%, sedangkan ResNet18 memperoleh 94,26%.

Selisih *accuracy* sebesar 2,67% menunjukkan bahwa ConvNeXt-Tiny memiliki kemampuan yang lebih baik dalam mengenali serta membedakan karakteristik visual pada citra ikan. Hasil penelitian menunjukkan kinerja ConvNeXt-Tiny lebih baik dalam mengenali jenis ikan dibandingkan dengan ResNet18, seiring pertambahan epoch. Hal ini sesuai dengan hasil penelitian yang dilakukan oleh M. A. Baqir *et al.*, [25] yang menyatakan bahwa hasil *accuracy* meningkat secara bertahap seiring bertambahnya epoch sebelum mencapai titik konvergensi, sehingga dapat digunakan sebagai bukti empiris bahwa performa ConvNeXt-Tiny sensitif terhadap jumlah epoch training. Selain itu, ResNet18 tidak terpengaruh, sesuai dengan penelitian oleh L. Avanzini, A., dkk [26] menyatakan bahwa ResNet18 tidak terpengaruh dengan


bertambahnya jumlah epoch. Hal ini menunjukkan bahwa ConvNeXt-Tiny memiliki kemampuan pembelajaran yang lebih baik.

Tabel 3. Hasil evaluasi model ResNet18 dan ConvNeXt-Tiny

Matrik	ResNet18	ConvNeXt-tiny
Accuracy	94.09%	96.93%
Precision	94.43%	97.03%
Recall	93.71%	96.63%
F1-Score	93.92%	96.72%

Berdasarkan Tabel 3, performa ConvNeXt-Tiny mendominasi ResNet18 pada semua parameter pengujian. Model ConvNeXt-Tiny mencatatkan akurasi sebesar 96,93% dan ResNet18 94,09%, yang menegaskan keandalan klasifikasinya. Tingginya nilai presisi (97,03% dibandingkan dengan 94,43%) mengindikasikan ketepatan prediksi positif yang lebih baik, sekaligus mengurangi potensi tertukarnya kelas ikan.

Pada metrik recall, ConvNeXt-Tiny unggul dengan nilai 96,63% dibandingkan dengan ResNet18 yang mencatatkan 93,71%, menunjukkan sensitivitas deteksi sampel yang lebih optimal. Konsistensi model juga dibuktikan oleh F1-Score sebesar 96,72%, unggul atas ResNet18 (93,92%) berkat keseimbangan presisi dan recall yang terjaga. Secara umum, arsitektur ConvNeXt-Tiny terbukti memiliki representasi fitur visual yang lebih kuat dibandingkan dengan ResNet18 dalam mengklasifikasikan 31 spesies ikan melalui pendekatan transfer learning.



Gambar 6. Confusion Matrix Model ConvNeXt-Tiny

Berdasarkan Gambar 6, secara keseluruhan, model berhasil mengenali sebagian besar jenis ikan dengan baik. Hampir semua data uji mampu ditebak dengan tepat, bahkan sepertiga dari total jenis ikan yang diuji seperti Goby, Gurame, Lele (*Catfish*), dan Ikan Sapu-sapu (*Janitor Fish*) berhasil ditebak sempurna tanpa ada kesalahan. Sedikit salah tebak hanya terjadi pada beberapa ikan yang bentuk fisiknya memang mirip, seperti Mudfish yang sempat dikira Lele. Hal ini membuktikan bahwa kombinasi fitur yang digunakan sudah sangat kuat untuk membedakan tiap spesies ikan.

4. KESIMPULAN

Metode CNN berhasil dalam mengklasifikasi 31 jenis ikan dengan hasil yang sangat baik. Kedua model yang diuji, yaitu ResNet18 dan ConvNeXt-Tiny, menunjukkan peningkatan akurasi dengan bertambahnya jumlah pada epoch. ResNet18 mampu beradaptasi lebih cepat di fase awal pelatihan, sementara ConvNeXt-Tiny menunjukkan hasil yang lebih baik di fase akhir dengan *accuracy* sebesar 96,93%, *precision* 97,03%, *recall* 96,63%, dan *F1-Score* 96,72%, melampaui ResNet18 yang memperoleh *accuracy* 94,26%. Hasil tersebut menunjukkan bahwa ConvNeXt-Tiny memiliki kemampuan yang lebih baik dalam mempelajari representasi fitur visual citra ikan sehingga mampu menghasilkan performa klasifikasi yang lebih tinggi. Untuk penelitian selanjutnya disarankan untuk menguji keandalan model pada kondisi lingkungan nyata (*real-world*) dengan pencahayaan dan latar belakang bervariasi. Penggunaan model modern seperti *Vision Transformer* (ViT) atau *EfficientNet* serta pengoptimasian hyperparameter juga direkomendasikan untuk meningkatkan efisiensi konvergensi model.

DAFTAR PUSTAKA

- [1] F. A. Zahra and N. Firmansyah, "Klasifikasi Citra Jenis Ikan Air Tawar Dan Air Laut Menggunakan Algoritma CNN (Convolutional Neural Network)," no. Hidayat, pp. 495–502, 2023.
- [2] N. Abdurrahman, B. Rahmat, and A. N. Sihananto, "Perbandingan Performa Klasifikasi Citra Ikan Menggunakan Metode K-Nearest Neighbor (K-NN) Dan Convolutional Neural Network (CNN)," *J. Sist. Inf. dan Inform.*, vol. 2, no. 2, pp. 84–93, 2023, doi: 10.33379/jusifor.v2i2.3728.
- [3] J. Nasional, S. Informasi, S. Azka, and T. Arifin, "Perbandingan Arsitektur CNN Berbasis Transfer Learning untuk Klasifikasi pada BreastMNIST," vol. 02, pp. 192–200, 2025.
- [4] F. Ningsih and A. Suhendar, "Klasifikasi Kesegaran Ikan Tongkol Berdasarkan Citra Mata Berbasis Convolutional Neural Network (CNN)," vol. 8, no. 2, pp. 88–94, 2025.
- [5] S. S. Rambe and U. M. Sukabumi, "Penerapan Model Convolutional Neural Network (CNN) Berbasis Mobilenetv2 Untuk," vol. 13, no. 3.
- [6] C. Lubis, "Klasifikasi Citra Ikan Menggunakan Convolutional Neural Network".
- [7] A. Rahman, M. Salim, and I. Riadi, "Klasifikasi Citra Spesies Bunga Di Indonesia Berbasis Convolutional Neural Network Menggunakan Teknik Transfer Learning," *J. Softw. Eng. Comput. Intell.*, vol. 2, no. 02, pp. 92–100, 2025, doi: 10.36982/jseci.v2i02.4942.
- [8] D. Setyawan, A. Nilogiri, U. M. Jember, G. Kerang, and K. Jember, "Implementasi Convolution Neural Network (CNN) Untuk," vol. 7, no. 1, 2023.
- [9] H. Saparudin, M. A. Ramdi, and F. S. Alfarizi, "Implementasi Convolutional Neural Network dan ResNet-18 untuk Klasifikasi Kerusakan Jalan Berbasis Citra," vol. 1, no. 1, pp. 27–31, 2025.
- [10] G. Mediose, A. Sihotang, and J. Supardi, "Pengembangan Model CNN ResNet-18 untuk Klasifikasi Kondisi Gigi Berbasis Citra RGB sebagai Solusi Diagnostik Digital Development of CNN ResNet-18 Model for RGB Image-Based Dental Condition Classification as a Digital Diagnostic Solution," vol. 4, no. 12, pp. 747–758, 2024.
- [11] A. Faouzi, A. Bahtiar, P. Studi, T. Informatika, P. Studi, and S. Informasi, "Analisis Performa Metode Convolutional Neural Network," vol. 06, no. 02, pp. 1–9, 2025, doi: 10.32485/jesai.JOURNAL.
- [12] "Klasifikasi Citra Ikan Menggunakan Algoritma (CNN) dengan arsitektur VGG-16," 2023.
- [13] D. Simanjuntak and A. Matondang, "Penerapan Transfer Learning untuk Klasifikasi Citra

- Bunga Berbasis Convolutional Neural Network,” vol. 14, pp. 1062–1067, 2025.
- [14] G. Ayana, K. Dese, and A. Mohammed, *Multistage transfer learning for medical images*, vol. 57, no. 9. Springer Netherlands, 2024. doi: 10.1007/s10462-024-10855-7.
 - [15] A. Mechanism and L. Smoothing, “JURNAL RESTI Remote Sensing Scene Classification using ConvNeXt-Tiny Model with,” vol. 5, no. 158, pp. 389–400, 2026.
 - [16] D. chahyati Fauzan muhammad, Aniati murni arimurthy, “Transfer learning pada Network VGG16 dan ResNet50,” *JournalIndonesian J. Comput. Sci.*, vol. 12, no. 1, 2023, doi: <https://doi.org/10.33022/ijcs.v12i1.3130>.
 - [17] G. Thiodorus, A. Prasetia, L. Afrizal, and N. Yudistira, “Klasifikasi citra makanan / nonmakanan menggunakan metode Transfer Learning dengan model Residual Network Classification of food / non-food images using Transfer Learning method with Residual Network model,” vol. 11, no. 2, pp. 74–83, 2021.
 - [18] K. He and J. Sun, “Deep Residual Learning for Image Recognition,” pp. 1–9.
 - [19] Z. Liu, H. Mao, C. W. Christoph, F. Trevor, D. Saining, and U. C. Berkeley, “A ConvNet for the 2020s,” pp. 11976–11986.
 - [20] B. Irawan *et al.*, “Optimasi Algoritma Adam untuk Peningkatan Akurasi Klasifikasi Penyakit Daun Padi Berbasis CNN Optimization Adam Algorithm for Improving the Accuracy of Rice Leaf Disease Classification Based on CNN,” vol. 13, no. 105, pp. 738–743, 2024.
 - [21] N. Rochmawati, H. B. Hidayati, and Y. Yamasari, “Analisa Learning rate dan Batch size Pada Klasifikasi Covid Menggunakan Deep learning dengan Optimizer Adam,” vol. 05, pp. 44–48, 2021.
 - [22] N. S. Atmaja, S. Harahap, and M. K. Harahap, “Analisis Pengaruh Jumlah Data Latih terhadap Kinerja Convolutional Neural Network pada Klasifikasi Citra,” no. 2022, 2026.
 - [23] F. Masykur, M. B. Setyawan, and K. Winangun, “Optimalisasi Epoch Pada Klasifikasi Citra Daun Tanaman Padi Menggunakan Convolutional Neural Network (CNN) MobileNe t Epoch Optimization on Rice Leaf Image Classification Using Convolutional Neural Network (CNN) MobileNet,” no. July, pp. 581–590, 2022.
 - [24] A. Informatics, V. Ayumi, M. Buana, and A. Info, “Perbandingan Model Transfer Learning Untuk Klasifikasi Data Agricultural Crop Images,” vol. 5, no. 3, pp. 214–222, 2022.
 - [25] M. A. Baqir *et al.*, “OPEN A lightweight CNN for enhanced non-small cell lung cancer classification using CT scan image,” pp. 1–19, 2026.
 - [26] L. Avanzini, A. La Rocca, S. A. Pfau, and A. Cairns, “Automated particle recognition for engine soot nanoparticles,” no. July, pp. 28–39, 2022, doi: 10.1111/jmi.13140.