

Fish Classification of Skipjack and Mackerel Tuna Using Convolutional Neural Network

Klasifikasi Ikan Cakalang dan Tongkol Menggunakan *Convolutional Neural Network*

Wellifan Arrank Tonapa, Pinrolinvic D. K. Manembu, Feisy D. Kambey

Jurusan Teknik Elektro, Universitas Sam Ratulangi Manado, Jl. Kampus Bahu, 95115, Indonesia

E-mails: 18021106028@student.unsrat.ac.id, Pmanembu@unsrat.ac.id, feisykambey@unsrat.ac.id

Received: 24 October 2023; revised: 26 October 2023; accepted: 31 October 2023

Abstract — *Indonesia has a rich diversity of fish species, especially marine fish species. However, the abundance of fish species also poses challenges for the community in classifying each species. This challenge becomes even more significant when dealing with species that share similar physical characteristics, such as the pelagic fish group, which includes skipjack tuna (*Katsuwonus pelamis*) and mackerel tuna (*Euthynnus affinis*). Therefore, it is essential to have a profound understanding of fisheries science to accurately classify each fish species. With advancements in current technology, species classification can be automated using image-based classification methods. This research employs the Convolutional Neural Network (CNN) method to classify skipjack tuna and mackerel tuna species. The research results in a CNN classification model constructed using a transfer learning approach by leveraging the pre-trained ResNet50 model available in Keras Applications. The CNN Classification Model generated achieves a performance with a 95% accuracy rate, an average macro precision of 95%, an average macro recall of 95%, and an average macro F1 score of 95%.*

Key words— *Classification; Convolutional Neural Network; Fish Species; Image; Transfer Learning.*

Abstrak — *Indonesia memiliki banyak keanekaragaman spesies ikan, terutama spesies ikan laut. Namun, keberagaman spesies ikan yang banyak juga menimbulkan kesulitan bagi masyarakat dalam melakukan klasifikasi pada setiap spesies ikan yang ada. Apalagi, pada beberapa spesies ikan yang memiliki fisik yang hampir sama, seperti kelompok ikan pelagis, yaitu cakalang (*Katsuwonus pelamis*) dan tongkol (*Euthynnus affinis*). Oleh karena itu, penting untuk memiliki pemahaman mendalam tentang ilmu perikanan agar dapat melakukan klasifikasi yang benar terhadap setiap spesies ikan. Dengan kemajuan teknologi saat ini, pengklasifikasian spesies ikan dapat dilakukan secara otomatis menggunakan metode klasifikasi berdasarkan citra. Penelitian ini menggunakan metode Convolutional Neural Network (CNN) untuk mengklasifikasikan spesies ikan cakalang dan tongkol. Penelitian ini menghasilkan model klasifikasi CNN yang dibangun menggunakan pendekatan transfer learning dengan memanfaatkan model *pre-trained* ResNet50 yang tersedia di *Keras Applications*. Model Klasifikasi CNN yang dihasilkan mendapatkan nilai performa akurasi 95%, rata-rata makro precision 95%, rata-rata makro recall 95%, rata-rata makro f1 score 95%.*

Kata kunci — *Citra; Convolutional Neural Network; Klasifikasi; Spesies Ikan; Transfer Learning.*

I. PENDAHULUAN

Indonesia memiliki banyak keanekaragaman spesies ikan, terutama spesies ikan laut. Diperkirakan jumlah ikan laut di Indonesia mencapai kurang lebih 3.200 spesies [1]. Namun, keberagaman spesies ikan yang banyak juga menimbulkan

kesulitan bagi masyarakat dalam melakukan klasifikasi pada setiap spesies ikan yang ada. Apalagi, pada beberapa spesies ikan yang memiliki fisik yang hampir sama, seperti kelompok ikan pelagis, yaitu cakalang (*Katsuwonus pelamis*) dan tongkol (*Euthynnus affinis*). Kedua ikan ini secara fisik memiliki kemiripan yang hampir sama, karena berasal dari keluarga *scombridae* atau ikan tanpa sisik dengan badan mengkilat. Sehingga, banyak yang mengira ikan tongkol dan ikan cakalang adalah spesies ikan yang sama dengan sebutan yang berbeda. Oleh karena itu, penting untuk memiliki pemahaman mendalam tentang ilmu perikanan agar dapat melakukan klasifikasi yang benar terhadap setiap spesies ikan. Biasanya, pengklasifikasian spesies ikan memerlukan identifikasi berdasarkan ciri-ciri khusus, seperti bentuk tubuh, pola warna, dan karakteristik fisik lainnya [2].

Dengan kemajuan teknologi saat ini, pengklasifikasian spesies ikan dapat dilakukan secara otomatis menggunakan metode klasifikasi berdasarkan citra. Salah satu metode klasifikasi yang dapat digunakan adalah *Convolutional Neural Network* (CNN). Metode ini melakukan pembelajaran fitur-fitur dari citra secara otomatis, yang dikenal sebagai *feature learning* [3], dan kemudian mampu mengidentifikasi fitur-fitur penting dalam citra tersebut melalui operasi konvolusi. Informasi fitur-fitur penting ini nantinya digunakan dalam proses klasifikasi, yang memungkinkan CNN untuk membedakan suatu objek dengan objek lain. Penelitian ini bertujuan untuk menerapkan CNN dalam melakukan klasifikasi spesies ikan cakalang dan tongkol. Dalam proses pelatihan model klasifikasi CNN, penelitian ini menggunakan pendekatan *transfer learning* dengan memanfaatkan model terlatih / model *pre-trained* dari pustaka *Keras Applications*, yaitu VGG16 dan ResNet50. Pada penggunaan kedua model tersebut, dilakukan perbandingan untuk mendapatkan model klasifikasi dengan performa yang terbaik.

A. Penelitian Terkait

Berikut beberapa penelitian sebelumnya terkait implementasi Convolutional Neural Network (CNN) pada tugas klasifikasi ikan dan beberapa di bidang lain:

- 1) Penelitian yang dilakukan oleh Fauzi, Eosina, dan Laxmi [4], mereka melakukan implementasi CNN untuk mengklasifikasikan 10 spesies ikan air tawar. Penelitian tersebut menghasilkan model klasifikasi CNN dengan tingkat akurasi mencapai 88,3%.
- 2) Penelitian yang dilakukan oleh Shammi, Das, Hasan, dan

Noori [5], mereka melakukan implementasi CNN untuk mengklasifikasikan 6 spesies ikan. Penelitian tersebut menghasilkan model klasifikasi CNN dengan tingkat akurasi mencapai 88,96%.

- 3) Penelitian yang dilakukan oleh Liawatimena, Heryadi, Trisetyarso, Wibowo, Abbas, dan Barlian [6], mereka melakukan implementasi CNN dengan teknik *transfer learning* menggunakan model terlatih AlexNet untuk mengklasifikasikan 3 spesies ikan. Penelitian tersebut menghasilkan model klasifikasi CNN dengan tingkat akurasi mencapai 99,63%.
- 4) Penelitian yang dilakukan oleh Bahar dan Kusuma [7], mereka melakukan implementasi CNN dengan teknik *transfer learning* menggunakan model terlatih ResNet50 untuk mengklasifikasikan 14 spesies ikan hiu. Penelitian tersebut menghasilkan model klasifikasi CNN dengan tingkat akurasi mencapai 86%.
- 5) Penelitian yang dilakukan oleh Ariawan, Arifin, Rosalia, Lukman, dan Tufailah [8], mereka melakukan implementasi CNN untuk mengklasifikasikan 3 genus ikan karang. Penelitian tersebut menghasilkan model klasifikasi CNN dengan tingkat akurasi mencapai 85,31%.
- 6) Penelitian yang dilakukan oleh Zuhri, Maulana, dan Maheswara [9], mereka melakukan implementasi CNN dengan teknik *transfer learning* menggunakan model terlatih VGG16 untuk mengklasifikasikan 10 spesies ikan hiu. Penelitian tersebut menghasilkan model klasifikasi CNN dengan tingkat akurasi 91,80%.
- 7) Penelitian yang dilakukan oleh Gultom, Arymurth, dan Masikome [10], mereka melakukan implementasi CNN dengan teknik *transfer learning* menggunakan model terlatih VGG16 untuk mengklasifikasikan 6 jenis kain batik. Penelitian tersebut menghasilkan model klasifikasi CNN dengan tingkat akurasi 89%.
- 8) Penelitian yang dilakukan oleh Tedjo, Sambul, dan Lumenta [11], mereka melakukan implementasi CNN dengan teknik *transfer learning* menggunakan model terlatih ResNet50 untuk mengklasifikasikan 6 jenis buah segar dan busuk. Penelitian tersebut menghasilkan model klasifikasi CNN dengan tingkat akurasi 98%.

B. Citra

Citra merupakan data dua dimensi yang merepresentasikan suatu objek atau benda. Citra terbagi dua yaitu citra yang bersifat analog dan citra digital. Citra analog tidak dapat direpresentasikan dalam komputer, sehingga tidak dapat diproses oleh komputer secara langsung. Citra analog membutuhkan proses konversi analog ke digital terlebih dahulu agar dapat diproses oleh komputer. Sedangkan pada citra digital, semua citra yang dihasilkan dapat direpresentasikan dalam komputer sehingga dapat diproses oleh komputer secara langsung [12].

C. Deep Learning

Deep learning adalah perkembangan dari *artificial neural network* (ANN) dalam domain *machine learning*. *Artificial neural network*, yang sering kali disebut sebagai *Multi-Layer*

Perceptron (MLP), memiliki struktur dasar dengan tiga hingga empat lapisan utama, yaitu *input layer*, *hidden layer*, dan *output layer*. *Deep learning* memperluas konsep ini dengan memanfaatkan banyak lapisan tersembunyi (*hidden layer*) dalam jaringan, sehingga jaringan mampu menggambarkan fitur-fitur yang semakin kompleks dalam data. Hal ini menghasilkan kemampuan *deep learning* yang telah terbukti sukses dalam berbagai tugas, seperti mengklasifikasikan citra atau memproses bahasa alami, yang menegaskan kemampuannya dalam menyelesaikan permasalahan yang semakin sulit dalam domain *machine learning*.

Referensi [13] mengatakan bahwa perbedaan utama antara *machine learning* dan *deep learning* terletak pada proses ekstraksi fitur. Pada *machine learning* konvensional, ekstraksi fitur melibatkan tindakan manual di mana jenis fitur yang akan digunakan harus ditentukan terlebih dahulu. Setelah fitur-fitur telah ditentukan, biasanya terdapat langkah klasifikasi yang dilakukan dengan menggunakan algoritma *machine learning*. Di sisi lain, dalam *deep learning*, ekstraksi fitur dan klasifikasi dilakukan secara otomatis. Dalam konteks *deep learning*, proses ekstraksi fitur sering disebut sebagai *feature learning*, di mana jaringan neural secara otomatis mempelajari dan memilih fitur-fitur yang memiliki relevansi penting dalam data sebelum melakukan klasifikasi.

D. Convolutional Neural Network

Convolutional Neural Network (CNN) adalah salah satu metode dari *Deep learning*. Metode ini merupakan pengembangan dari *Multi-Layer Perceptron* (MLP) yang memungkinkan untuk melakukan pengolahan data dua dimensi, seperti data citra atau suara [14]. CNN digunakan untuk tugas klasifikasi dengan pendekatan *supervised learning* [15]. Dalam pendekatan ini, CNN menggunakan dataset yang telah diberi label atau kelas sebagai panduan untuk melatih modelnya. Arsitektur pada CNN memiliki dua bagian utama yaitu *feature learning* dan *classification* [16]. Bagian *feature learning* terdiri dari lapisan konvolusi, fungsi aktivasi seperti ReLU (*Rectified Linear Unit*), dan lapisan *pooling*. Lapisan ini sering diulang atau disusun menjadi beberapa lapisan sesuai kebutuhan arsitektur yang dibuat. Bagian *classification* terdiri dari *flatten*, *fully connected*, dan *softmax*.

E. Transfer Learning

Transfer learning adalah metode yang menggunakan pengetahuan dan pengalaman yang sudah dimiliki oleh model yang telah dilatih sebelumnya, sehingga dapat diterapkan kembali dalam tugas yang berbeda atau baru [17]. Dalam klasifikasi citra, model-model yang umumnya digunakan adalah model yang telah dilatih menggunakan dataset yang mengandung ribuan atau bahkan jutaan citra, seperti *ImageNet*, *COCO*, *MNIST*, atau dataset lain yang cukup besar dan representatif untuk tugas tertentu. Model-model ini telah memperoleh pemahaman yang luas mengenai berbagai jenis objek dan fitur dalam citra. Pengetahuan tersebut yang dimanfaatkan pada tugas klasifikasi dengan dataset yang lebih sedikit. Hal ini membuat proses pelatihan pada model lebih efisien dan mendapat performa lebih baik.

II. METODE

A. Pengumpulan Data

Penelitian ini menggunakan dataset citra dari spesies ikan cakalang (*Katsuwonus pelamis*) dan tongkol (*Euthynnus affinis*). Pengumpulan citra pada penelitian ini dilakukan dengan melihat morfologi ikan berdasarkan sumber yang telah terverifikasi [18]. Citra ikan yang dikumpulkan adalah citra tampak samping dari ikan, yang diperoleh dari pencarian di internet serta beberapa diambil dari pasar lokal. Citra yang didapatkan langsung dimasukan ke dalam 2 folder kelas, yaitu folder cakalang dan folder tongkol.

B. Pra Pemrosesan Data

Citra-citra yang ada disetiap folder kelas dilakukan *cropping* dengan tujuan memperjelas area objek ikan, terutama pada beberapa citra yang memiliki 2 atau lebih objek ikan didalamnya. Setelah dilakukan *cropping*, dataset yang didapatkan ada sebanyak 426 citra terdiri dari 213 citra ikan cakalang dan 213 citra ikan tongkol. Kemudian, dilakukan *resize* pada seluruh citra menjadi ukuran 224 x 224 piksel. Setelah itu, dataset dibagi menjadi 80% data train dan 20% data validasi.

Dalam proses pelatihan model, diterapkan fungsi *'preprocess_input'* pada data train dan data validasi. Fungsi ini dapat ditemukan dalam pustaka *Keras Applications* untuk setiap model *pre-trained* yang ingin digunakan. Penerapan fungsi ini bertujuan untuk menyesuaikan data masukan agar sesuai dengan jenis pemrosesan yang diperlukan oleh masing-masing model *pre-trained* di dalam pustaka *Keras Applications*. Penelitian ini menggunakan model *pre-trained* VGG16 dan ResNet50, sehingga fungsi *'preprocess_input'* yang digunakan adalah *'vgg16.preprocess_input'* dan *'resnet.preprocess_input'*.

Dalam proses pelatihan model juga, diterapkan augmentasi data pada data train. Augmentasi diterapkan agar model dapat mempelajari variasi data yang ada. Teknik ini dapat membantu

meningkatkan performa model yang dilatih, seperti meningkatkan akurasi dan mengurangi overfitting [19]. Teknik augmentasi yang digunakan pada penelitian ini, yaitu *Rotation range* dan *Horizontal flip*. Kedua teknik ini diterapkan hanya pada data train saat proses pelatihan model.

C. Pembuatan Arsitektur Model

Penelitian ini membuat 2 arsitektur model untuk dibandingkan dalam pelatihan. Kedua arsitektur model ini dibuat menggunakan pendekatan transfer learning dengan memanfaatkan 2 model terlatih, yaitu model VGG16 dan model ResNet50. Kedua model tersebut telah dilatih sebelumnya menggunakan dataset *ImageNet* dan tersimpan di *Keras Applications*. Berikut adalah rancangan *feature learning* dan *classification* pada kedua arsitektur model yang dibuat:

1) Arsitektur Model Transfer Learning VGG16

Bagian *feature learning* dari arsitektur ini memakai arsitektur *feature learning* dari model *pre-trained* VGG16 yang ada di *Keras Applications*. Pada bagian *classification*, terdapat lapisan *global max pooling* dan 3 lapisan *fully connected*. Lapisan *global max pooling* akan mengambil nilai tertinggi dari setiap dimensi matriks atau *feature map* yang dihasilkan dari lapisan konvolusi terakhir. Lapisan ini menghasilkan vektor 1 dimensi yang digunakan sebagai input pada lapisan *fully connected*. Lapisan *fully connected* pertama mengambil 128 neuron dan menggunakan fungsi aktivasi ReLU. Lapisan *fully connected* kedua mengambil 128 neuron dan menggunakan fungsi aktivasi ReLU. Lapisan *fully connected* ketiga mengambil 2 neuron sebagai output klasifikasi dan menggunakan fungsi aktivasi *softmax*. Arsitektur ini dapat dilihat pada gambar 1.

Dalam pelatihan model dengan arsitektur ini, digunakan *weights* dari model *pre-trained* VGG16 yang telah dilatih dengan dataset *ImageNet*. *Weights* ini digunakan untuk melakukan ekstraksi fitur pada bagian *feature learning* dari arsitektur ini dengan mengatur parameter *'trainable'* menjadi *'false'* pada pustaka *Keras Applications*.

TABEL I
DATASET PELATIHAN

Kelas	Data Train	Data Validasi
Cakalang	170	43
Tongkol	170	43

TABEL II
DATASET PENGUJIAN

Kelas	Data Uji
Cakalang	20
Tongkol	20

Layer (type)	Output Shape	Param #
vgg16 (Functional)	(None, 7, 7, 512)	14714688
global_max_pooling2d (GlobalMaxPooling2D)	(None, 512)	0
dense (Dense)	(None, 128)	65664
dense_1 (Dense)	(None, 128)	16512
dense_2 (Dense)	(None, 2)	258
Total params: 14797122 (56.45 MB)		
Trainable params: 82434 (322.01 KB)		
Non-trainable params: 14714688 (56.13 MB)		

Gambar 1. Arsitektur Model Transfer Learning VGG16

Layer (type)	Output Shape	Param #
resnet50 (Functional)	(None, 7, 7, 2048)	23587712
global_max_pooling2d_1 (GlobalMaxPooling2D)	(None, 2048)	0
dense_3 (Dense)	(None, 128)	262272
dense_4 (Dense)	(None, 128)	16512
dense_5 (Dense)	(None, 2)	258
Total params: 23866754 (91.04 MB)		
Trainable params: 279042 (1.06 MB)		
Non-trainable params: 23587712 (89.98 MB)		

Gambar 2. Arsitektur Model Transfer Learning ResNet50

2) *Arsitektur Model Transfer Learning ResNet50*

Bagian *feature learning* dari arsitektur ini memakai arsitektur *feature learning* dari model *pre-trained* ResNet50 yang ada di *Keras Applications*. Pada bagian *classification*, terdapat lapisan *global max pooling* dan 3 lapisan *fully connected*. Lapisan *global max pooling* akan mengambil nilai tertinggi dari setiap dimensi matriks atau *feature map* yang dihasilkan dari lapisan konvolusi terakhir. Lapisan ini menghasilkan vektor 1 dimensi yang digunakan sebagai input pada lapisan *fully connected*. Lapisan *fully connected* pertama mengambil 128 neuron dan menggunakan fungsi aktivasi ReLU. Lapisan *fully connected* kedua mengambil 128 neuron dan menggunakan fungsi aktivasi ReLU. Lapisan *fully connected* ketiga mengambil 2 neuron sebagai output klasifikasi dan menggunakan fungsi aktivasi *softmax*. Arsitektur ini dapat dilihat pada gambar 2.

. Dalam pelatihan model dengan arsitektur ini, digunakan *weights* dari model *pre-trained* ResNet50 yang telah dilatih dengan dataset *ImageNet*. *Weights* ini digunakan untuk melakukan ekstraksi fitur pada bagian *feature learning* dari arsitektur ini dengan mengatur parameter '*trainable*' menjadi '*false*' pada pustaka *Keras Applications*.

D. *Evaluasi Model*

Setelah melatih kedua model menggunakan data train dan data validasi, kedua model tersebut diuji dengan menggunakan data uji. Data uji terdiri dari 20 citra per kelas, seperti yang tercantum dalam tabel II. Dalam proses pengujian, data uji tersebut diubah ke ukuran 224 x 224 piksel. Kemudian, dilakukan evaluasi model menggunakan *confusion matrix* dengan nilai performa yang dihitung adalah akurasi, rata-rata makro *precision*, rata-rata makro *recall*, dan rata-rata makro *f1*

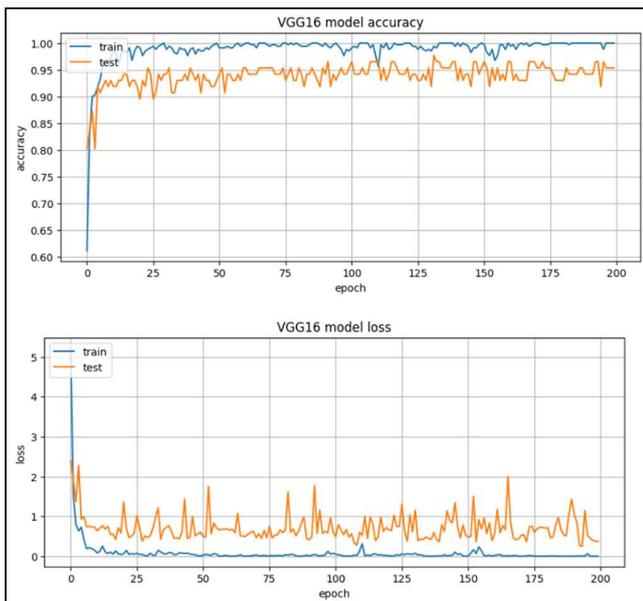
score [20]. Perhitungan nilai performa tersebut digunakan untuk memastikan keseimbangan hasil prediksi model pada setiap kelas. Hasil performa dari kedua model digunakan untuk menentukan model yang paling baik di antara keduanya.

III. HASIL DAN PEMBAHASAN

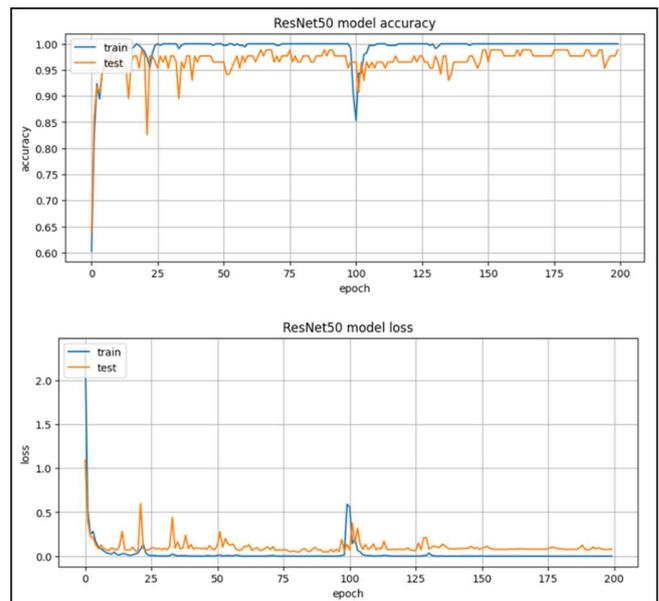
Pelatihan model dilakukan memakai pustaka *keras* yang ada pada *framework tensorflow*. Parameter-parameter yang dipakai, yaitu jumlah *epochs* 200, *batch size* 32, ukuran citra input 224 x 224 piksel, *optimizer Adam*, *learning rate* 0,001, fungsi *loss binary_crossentropy*, dan beberapa parameter lain yang telah diatur default dalam pustaka *keras*. Kedua arsitektur yang telah dirancag, dilatih menggunakan dataset pelatihan yang terdiri dari data train dan data validasi, dicantumkan pada tabel I.

Grafik pelatihan pada kedua model ditunjukkan pada gambar 3 dan 4. Pada gambar 3 merupakan grafik pelatihan model *transfer learning* VGG16, yang mana *epoch* terakhir dari pelatihan model ini mendapatkan nilai *loss* train 0.00000033882, akurasi train 100.00%, *loss* validasi 0.3685, dan akurasi validasi 95.35%. Pada gambar 4 merupakan grafik pelatihan model *transfer learning* ResNet50, yang mana *epoch* dari pelatihan model ini mendapatkan nilai *loss* train 0.000069, akurasi train 100.00%, *loss* validasi 0.0806, akurasi validasi 98.84%.

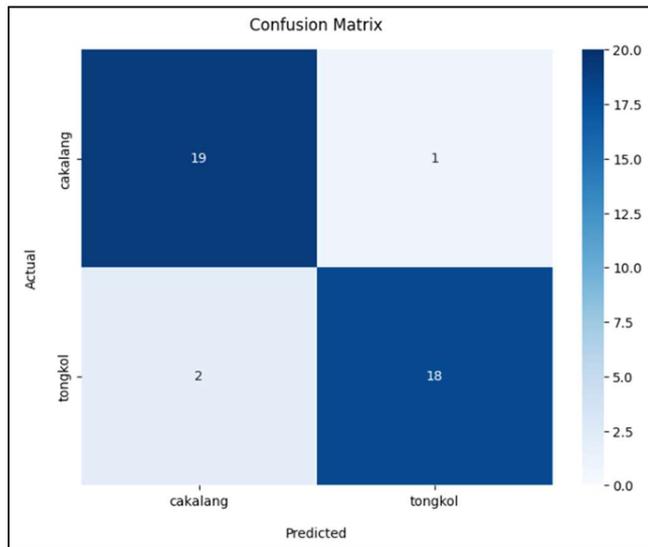
Selanjutnya, kedua model tersebut dilakukan uji pada data uji yang telah disediakan, dicantumkan pada tabel II. Pada gambar 5 dan 6, menunjukkan tabel *confusion matrix* dari hasil prediksi kedua model terhadap data uji. Pada model *transfer learning* VGG16 berhasil memprediksi 19 citra spesies ikan cakalang dan 18 citra spesies ikan tongkol. Sedangkan, pada model *transfer learning* ResNet50 berhasil memprediksi 19 citra spesies ikan cakalang dan 19 citra spesies ikan tongkol.



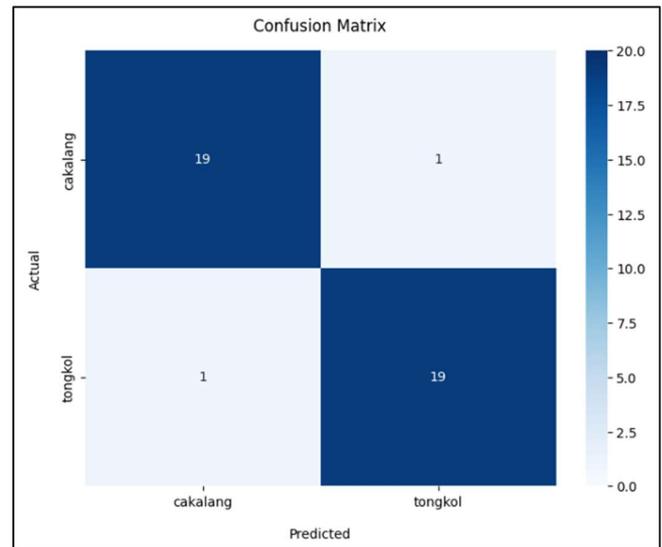
Gambar 3. Grafik Pelatihan Model Transfer Learning VGG16 Menggunakan Data Train dan Data Validasi



Gambar 4. Grafik Pelatihan Model Transfer Learning ResNet50 Menggunakan Data Train dan Data Validasi



Gambar 5. Confusion Matrix Hasil Prediksi Model Transfer Learning VGG16 Menggunakan Data Uji



Gambar 6. Confusion Matrix Hasil Prediksi Model Transfer Learning ResNet50 Menggunakan Data Uji

TABEL III
PERFORMA MODEL

Model	Akurasi	Rata-rata Makro Precision	Rata-rata Makro Recall	Rata-rata Makro F1 Score
Model Transfer Learning VGG16	93%	93%	93%	92%
Model Transfer Learning ResNet50	95%	95%	95%	95%

Berdasarkan perhitungan nilai performa model pada tabel III, menunjukkan bahwa performa model *transfer learning* ResNet50 lebih baik dibandingkan model *transfer learning* VGG16. Hasil prediksi model *transfer learning* ResNet50 terhadap data uji mendapat nilai performa akurasi 95%, rata-rata makro *precision* 95%, rata-rata makro *recall* 95%, rata-rata makro *f1 score* 95%. Sedangkan, pada hasil prediksi model *transfer learning* VGG16 terhadap data uji mendapat nilai performa akurasi 93%, rata-rata makro *precision* 93%, rata-rata makro *recall* 93%, rata-rata makro *f1 score* 92%.

IV. KESIMPULAN DAN SARAN

A. Kesimpulan

Penelitian ini telah melakukan implementasi metode *Convolutional Neural Network* untuk mengklasifikasikan spesies ikan cakalang dan tongkol. Model klasifikasi CNN yang didapatkan pada penelitian ini dibangun menggunakan pendekatan *transfer learning* dengan memanfaatkan model *pre-trained* ResNet50 yang ada pada pustaka *Keras Applications*. Proses pelatihan pada model ini mendapatkan nilai *loss* train 0.000069, akurasi train 100.00%, *loss* validasi 0.0806, akurasi validasi 98.84%. Setelah pelatihan, model ini diuji menggunakan data citra baru yang terdiri dari 20 citra perkelas, yang mana model ini mendapatkan nilai performa akurasi 95%, rata-rata makro *precision* 95%, rata-rata makro *recall* 95%, rata-rata makro *f1 score* 95%.

B. Saran

Saran untuk penelitian selanjutnya, kiranya dapat mencoba melakukan pelatihan model dengan memanfaatkan model *pre-*

trained lain yang tersedia di *Keras Applications*, seperti Xception, VGG19, varian ResNet yang lain, DenseNet, dll. Hal ini dilakukan untuk melihat perbandingan dari performa model yang dihasilkan. Selain itu, eksplorasi lebih lanjut dalam hal *fine-tuning*, augmentasi data, atau modifikasi arsitektur bisa dilakukan untuk mendapatkan pendekatan terbaik dalam meningkatkan performa dari model.

V. KUTIPAN

- [1] M. Samdani, I. W. Restu, and R. Ekawaty, "Inventarisasi Ikan Ekonomis Penting pada Musim Barat di PPI Kedonganan, Bali," *Journal of Marine and Aquatic Sciences*, vol. 7, no. 1, pp. 10–17, 2021.
- [2] L. D. Sukarman, G. F. Laxmi, and F. Fatimah, "Identifikasi ikan air tawar dengan metode color moment feature," in *Seminar Nasional Teknologi Informasi*, 2018, pp. 375–383.
- [3] S. F. Alamsyah, "Implementasi Deep Learning Untuk Klasifikasi Tanaman Toga Berdasarkan Ciri Daun Berbasis Android," *Ubiquitous: Computers and its Applications Journal*, vol. 2, no. 2, pp. 113–122, 2019.
- [4] S. Fauzi, P. Eosina, and G. F. Laxmi, "Implementasi Convolutional Neural Network Untuk Identifikasi Ikan Air Tawar," in *Seminar Nasional Teknologi Informasi*, 2019, pp. 163–167.
- [5] S. A. Shammii, S. Das, M. Hasan, and S. R. H. Noori, "FishNet: fish classification using convolutional neural network," in *2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, IEEE, 2021, pp. 1–5.
- [6] S. Liawatimena, Y. Heryadi, A. Trisetyarso, A. Wibowo, B. S. Abbas, and E. Barlian, "A fish classification on images using transfer learning and matlab," in *2018 Indonesian association for pattern recognition international conference (INAPR)*, IEEE, 2018, pp. 108–112.
- [7] A. Bahar and B. A. Kusuma, "Klasifikasi Spesies Hiu Dengan Arsitektur," *Journal Of Computer Science And Technology (JOCSTEC)*, vol. 1, no. 3, 2023.
- [8] I. Ariawan, W. A. Arifin, A. A. Rosalia, Lukman, and N. Tufailah, "Klasifikasi Tiga Genus Ikan Karang Menggunakan Convolution Neural Network," *Jurnal Ilmu dan Teknologi Kelautan Tropis*, vol. 14, no. 2, pp. 205–216, 2022.

- [9] A. B. Zuhri, D. I. Maulana, and E. S. Maheswara, "Optimization Image Classification Pada Ikan Hiu Dengan Metode Convolutional Neural Network Dan Data Augmentasi," *Jurnal Tika*, vol. 7, no. 1, pp. 1–11, 2022.
- [10] Y. Gultom, A. M. Arymurthy, and R. J. Masikome, "Batik classification using deep convolutional network transfer learning," *Jurnal Ilmu Komputer dan Informasi*, vol. 11, no. 2, pp. 59–66, 2018.
- [11] R. T. Tedjo, A. M. Sambul, and A. S. M. Lumenta, "Klasifikasi Gambar Bahan Makanan untuk Penderita Buta Warna," *Jurnal Teknik Elektro dan Komputer*, vol. 11, no. 2, pp. 67–76, 2022.
- [12] P. N. Andono and T. Sutojo, *Pengolahan Citra Digital*. Penerbit Andi, 2017. [Online]. Available: <https://books.google.co.id/books?id=zUJRDwAAQBAJ>
- [13] W. Setiawan, *Deep Learning menggunakan Convolutional Neural Network: Teori dan Aplikasi*. Media Nusa Creative (MNC Publishing), 2021. [Online]. Available: <https://books.google.co.id/books?id=sE9LEAAAQBAJ>
- [14] W. S. E. Putra, "Klasifikasi citra menggunakan convolutional neural network (CNN) pada caltech 101," *Jurnal Teknik ITS*, vol. 5, no. 1, 2016.
- [15] S. Ilahiyah and A. Nilogiri, "Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network," *JUSTINDO (Jurnal Sistem Dan Teknologi Informasi Indonesia)*, vol. 3, no. 2, pp. 49–56, 2018.
- [16] E. Christianto, A. M. Sambul, and F. D. Kambey, "Implementation of Convolutional Neural Network on Images for Starlings Classification," 2021.
- [17] A. E. Putra, M. F. Naufal, and V. R. Prasetyo, "Klasifikasi Jenis Rempah Menggunakan Convolutional Neural Network dan Transfer Learning," *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, vol. 9, no. 1, pp. 12–17, 2023.
- [18] W. T. White *et al.*, *Market fishes of Indonesia*. Australian Centre for International Agricultural Research, 2013.
- [19] R. Jain, P. Nagrath, G. Kataria, V. S. Kaushik, and D. J. Hemanth, "Pneumonia detection in chest X-ray images using convolutional neural networks and transfer learning," *Measurement*, vol. 165, p. 108046, 2020.
- [20] S. Suprihanto, I. Awaludin, M. Fadhill, and M. A. Z. Zulfikor, "Analisis Kinerja ResNet-50 dalam Klasifikasi Penyakit pada Daun Kopi Robusta," *J. Inform*, vol. 9, no. 2, pp. 116–122, 2022.



Wellifan Arrank Tonapa, lahir pada tanggal 14 Juli 2000 di Biak, Papua. Penulis menempuh Pendidikan Sekolah Dasar di SD Negeri Perumnas Sumberker Biak (2006-2012). Kemudian melanjutkan Sekolah Menengah Pertama di SMP Negeri 2 Biak Kota (2012-2015). Setelah itu penulis melanjutkan Sekolah Menengah

Atas di SMA Negeri 1 Biak (2015-2018). Penulis kemudian melanjutkan studi ke Perguruan Tinggi yang ada di Manado pada tahun 2018 yaitu Universitas Sam Ratulangi Manado dengan mengambil Program Studi S-1 Teknik Informatika, Jurusan Elektro, Fakultas Teknik.