

Perbandingan Model Arsitektur CNN Dengan Metode Transfer Learning Untuk Klasifikasi Spesies Ikan Laut

Ilham Anugrah^{1*}, Alda Cendekia Siregar², Barry Ceasar Octariadi³

Teknik Informatika, Universitas Muhammadiyah Pontianak, Pontianak, Indonesia

*e-mail Corresponding Author: ilhamanugrah633@gmail.com

Abstract

Fish are cold-blooded animals that are widely utilized by humans. Fish are a diverse group of poikilothermic vertebrates with over 27,000 species worldwide. The large number of fish species poses a challenge in distinguishing between them. This study aims to implement and compare three popular Convolutional Neural Network (CNN) architectures, namely Xception, Nasnet, and MobileNet V3L, in the task of classifying marine fish species. The research results show that all three CNN architectures perform exceptionally well in classifying marine fish species. The MobileNet V3L architecture achieves the highest level of accuracy with a value of 99% for all evaluation metrics. The Xception architecture achieves an overall accuracy of 97%, while the NasNet architecture achieves an overall accuracy of 92%. Overall, the comparison indicates that the MobileNet V3L architecture is the best architecture in this study.

Keyword: Convolutional Neural Network; Transfer Learning; Sea Fish Classification

Abstrak

Ikan merupakan hewan berdarah dingin yang banyak di manfaatkan oleh manusia. Ikan adalah kelompok *vertebrata poikilothermik* yang beraneka ragam dengan jumlah spesies lebih dari 27.000 di seluruh dunia. Banyaknya jumlah spesies ikan menjadi satu masalah dalam membedakan jenis ikan. Penelitian ini bertujuan untuk menerapkan dan membandingkan tiga arsitektur *Convolutional Neural Network* (CNN) yang populer, yaitu *Xception*, *Nasnet*, dan *MobileNet V3L*, dalam tugas klasifikasi spesies ikan laut. Hasil penelitian menunjukkan bahwa semua tiga arsitektur CNN memiliki performa yang sangat baik dalam klasifikasi spesies ikan laut. Arsitektur *MobileNet V3L* mencapai tingkat akurasi tertinggi dengan nilai sebesar 99% untuk semua metrik evaluasi. Untuk arsitektur *Xception* menghasilkan akurasi keseluruhan 97% dan arsitektur *NasNet* menghasilkan akurasi keseluruhan 92%. Secara keseluruhan perbandingan dapat dikatakan bahwa arsitektur *MobileNet V3L* adalah arsitektur terbaik dalam penelitian ini.

Kata kunci: Convolutional Neural Network; Transfer Learning; Klasifikasi Ikan Laut

1. Pendahuluan

Ikan adalah anggota *vertebrata poikilothermic* (berdarah dingin) yang hidup di air dan bernafas dengan insang. Ikan adalah kelompok *vertebrata* yang paling beragam dengan jumlah lebih dari 27.000 spesies di seluruh dunia [1]. Istilah *vertebrata* digunakan untuk membedakan ikan dengan kelompok binatang *invertebrata* lainnya, seperti udang atau siput yang sama-sama hidup di air[2]. Ikan sangatlah kaya akan manfaat bagi kesehatan tubuh dikarenakan kandungan yang ada di dalamnya, seperti Omega 3. Masalah yang terjadi adalah secara fisik spesies ikan laut ini memiliki kemiripan yang hampir sama antara satu jenis dengan jenis lainnya. Banyaknya spesies ikan dan spesies ikan laut maka akan sulit untuk otak manusia mengingat atau mengetahui spesies ikan yang sudah teridentifikasi.

Beberapa metode identifikasi ikan yang dilakukan selama ini masih konvensional, yaitu menggunakan buku identitas, literatur tentang situs web data besar seperti www.fishbase.com dan literatur lainnya dalam bentuk tulisan yang diterbitkan. Sekarang metode identifikasi ikan dapat dipercepat dengan cara komputerisasi. Salah satu teknik komputerisasi yang dapat dilakukan adalah pemrosesan gambar digital. Pengolahan citra digital adalah studi tentang hal-hal yang berkaitan dengan perbaikan kualitas gambar (peningkatan kontras, perubahan warna, restorasi gambar), transformasi gambar (terjemahan, rotasi transformasi, skala, geometris),

melakukan seleksi Gambar fitur optimal untuk tujuan analisis, menyimpan data sebelumnya dilakukan pengurangan dan kompresi, transmisi data, dan waktu pemrosesan data[3].

Spesies ikan laut dapat diidentifikasi melalui sebuah pengolahan citra digital. Hal ini dapat dilakukan karena perkembangan teknologi yang memudahkan manusia dalam pengambilan gambar melalui kamera digital. Selain itu, perkembangan ilmu komputer di bidang *computer vision* kini memungkinkan manusia untuk mengenali berbagai jenis ikan laut melalui citra digital dengan lebih akurat. *Convolutional Neural Network* (CNN) adalah salah satu metode *deep learning* yang sering digunakan dalam pengenalan citra digital[4]. Hal ini dikarenakan CNN berusaha meniru cara pengenalan citra pada *visual cortex* manusia. CNN memiliki kemampuan untuk dapat mengenali ciri pada citra digital (*feature learning*) melalui sebuah konvolusi filter dalam proses pelatihannya[5]. *Convolutional Neural Network* (CNN) adalah bagian dari ilmu kecerdasan buatan yang digunakan untuk mengklasifikasikan gambar. Kecerdasan Buatan (*Artificial Intelligence*) merupakan suatu bidang dalam ilmu komputer yang memfokuskan pada pengembangan mesin pintar (*smart machine*) yang memiliki kemampuan untuk menyelesaikan permasalahan yang kompleks dengan tingkat ketepatan yang lebih tinggi. Mesin ini mampu melakukan tugas-tugas seperti manusia, dan dapat diarahkan sesuai dengan kebutuhan manusia[6].

Penelitian ini bertujuan untuk melakukan perbandingan antara model arsitektur CNN dan metode *transfer learning* dalam klasifikasi spesies ikan laut. CNN, sebagai salah satu algoritma *deep learning*, telah terbukti efektif dalam menangani tugas klasifikasi citra. Sementara itu, metode *transfer learning* memanfaatkan pengetahuan yang telah diperoleh dari satu tugas untuk meningkatkan kinerja pada tugas terkait, sehingga dapat menjadi alternatif yang menjanjikan untuk klasifikasi spesies ikan laut[7]. Dalam penelitian ini menggunakan 3 arsitektur CNN yaitu *MobileNetV3*, *Xception* dan *Nasnet* dalam mengklasifikasi spesies ikan laut.

2. Tinjauan Pustaka

Pada studi sebelumnya diteliti oleh Nur Rachmat yang berkaitan dengan klasifikasi spesies ikan laut dengan judul *Klasifikasi Jenis Ikan Laut Menggunakan Metode SVM Dengan Fitur HOG Dan HSV* [8]. Penelitian ini menggunakan citra ikan laut dari dataset publik yang berisi tujuh spesies ikan laut. Terdapat 7.000 gambar untuk setiap spesies ikan laut, yang dijalankan melalui fase segmentasi warna HSV dengan mengubah nilainya menjadi skala abu-abu. HOG memproses SVM dan mengklasifikasikan spesies ikan di laut. Teknik tes dan pertukaran data menggunakan teknik *Fold Cross Validation tipe Leave One Out* (LOO). Hasil pengujian klasifikasi SVM untuk kernel linier dan polinomial 3x, 4x, dan 5x menunjukkan akurasi lebih dari 90%, dan akurasi tertinggi untuk jenis ikan *Black Sea Sprat* sebesar 94,06%. Nilai tertinggi pada ikan *Gilt Head Bream* sebesar 94,31% untuk jenis ikan. Selain itu, jenis ikan *Horse Mackerel* memperoleh nilai akurasi tertinggi yaitu 94,74%. Berikutnya jenis ikan *Red Mullet* mempunyai nilai akurasi paling tinggi yaitu 94,76%. Selain itu, jenis ikan *Red Sea Bream* memperoleh nilai akurasi tertinggi sebesar 94,86%, jenis ikan *Sea Bass* memperoleh nilai akurasi tertinggi sebesar 77,86%, dan ikan *Striped Red Mullet* memperoleh nilai akurasi tertinggi sebesar 94,41%.

Studi lainnya yang diteliti oleh Ishak Ariawan dengan judul *Klasifikasi Tiga Genus Ikan Karang Menggunakan Convolution Neural Network*[9]. Metode klasifikasi citra yang digunakan adalah *convolutional neural network* (CNN) yang terdiri dari dua tahap, pertama menggunakan metode *backpropagation* untuk melakukan pelatihan, dan tahap kedua menggunakan metode *feedforward* untuk mengklasifikasikan citra. Kombinasi kedua metode tersebut menghasilkan akurasi sebesar 85,31%. Selain itu, model yang dibangun cukup bagus karena selisih nilai rata-rata antara *precision* dan *sensitivity* tidak terlalu besar, *precision* sebesar 89,92% dan *sensitivity* sebesar 86,49%. Dari hasil analisis dan evaluasi yang dilakukan, dapat disimpulkan bahwa metode klasifikasi CNN berhasil digunakan untuk mengelompokkan citra ikan berdasarkan genus. selain itu model yang dibangun sudah sangat baik karena selisih rata-rata nilai akurasi dan sensitivitasnya tidak terlalu besar, yaitu akurasi sebesar 89,92% dan sensitivitas sebesar 86,49%. Dari hasil analisis dan evaluasi yang dilakukan, dapat disimpulkan bahwa metode klasifikasi CNN dapat digunakan dengan baik untuk mengelompokkan citra ikan berdasarkan genus.

Penelitian lainnya yang diteliti oleh Ahmad Bustomi Zuhari yang berjudul *Optimization Image Classification Pada Ikan Hiu Dengan Metode Convolutional Neural Network Dan Data Augmentasi*[10]. Peneliti menghasilkan program pengenalan citra pada hiu menggunakan algoritma *Convolutional Neural Network*, yaitu kegiatan konvolusi dengan menggabungkan

beberapa lapisan persiapan, memanfaatkan beberapa komponen yang bergerak bersama dan dimotivasi oleh sistem sensorik biologis. Gambar hiu yang digunakan adalah *basking*, *blacktip*, *blue*, *bull*, *hammerhead*, *lemon*, *mako*, *nurse*, *sand tiger*, dan *thresher*. Implementasi pengenalan gambar hiu dilakukan dengan menggunakan 2 model uji, yaitu model Sequential dan VGG16 on top model yang berjalan di aplikasi Google Collaboratory, dan Keras. Data uji dalam penelitian ini adalah 1089 citra data pelatihan dan 1073 citra data uji yang menghasilkan nilai evaluasi dengan nilai akurasi 86,58% dan nilai kerugian 0,701 pada model Sequential dan nilai akurasi 91,80% dan nilai kerugian 0,0355 pada VGG16 pada model atas.

Penelitian lainnya yang diteliti oleh Ahmad Bahar yang berjudul Klasifikasi Spesies Hiu Dengan Arsitektur *ResNet50*[11]. Penelitian ini menggunakan teknik *Convolutional neural Network* dengan arsitektur *ResNet50*. Penelitian ini Menggunakan 4720 data gambar hiu dari 14 kelas model *ResNet50* mencapai akurasi 86% dalam klasifikasi spesies ikan hiu. Model ini dapat digunakan untuk mengidentifikasi spesies hiu dengan baik.

Dalam penelitian ini secara khusus mengimplementasikan metode CNN seperti penelitian-penelitian sebelumnya. perbedaannya adalah penulis bertujuan untuk melakukan perbandingan arsitektur CNN pada tugas klasifikasi citra ikan laut. Kehadiran berbagai arsitektur CNN yang berkembang pesat memberikan peluang untuk meningkatkan akurasi dan efisiensi dalam klasifikasi jenis ikan laut.

3. Metodologi

Metode Transfer learning digunakan untuk mengklasifikasi kan data citra spesies ikan laut. Gambar 1 merupakan diagram alur penelitian klasifikasi spesies ikan laut.



Gambar 1. Alur penelitian klasifikasi spesies ikan laut

3.1 Data Citra

Dalam penelitian ini menggunakan dataset public dari *Large-Scale Dataset for Fish Segmentation and Classification*. Citra ikan laut yang dikumpulkan sebanyak 9.000 gambar. Gambar-gambar ini dibagi menjadi 9 jenis ikan laut, yaitu ikan *Black Sea Sprat*, *GiltHead Bream*, *Horse Mackerel*, *Red Mullet*, *Red Sea Bream*, *Sea Bass*, *Shrimp*, *Trout* dan *Striped Red Mullet*. Setiap jenis spesies ikan laut ada 1.000 gambar dengan ukuran 590 x 445 pixel.

Table 1. Jenis dan Jumlah Dataset spesies Ikan Laut yang Digunakan.

No	Jenis Ikan Laut	Jumlah Citra
1	<i>Black Sea Sprat</i>	1.000
2	<i>Gilt-Head Bream</i>	1.000
3	<i>Hourse Mackerel</i>	1.000
4	<i>Red Mullet</i>	1.000
5	<i>Red Sea Bream</i>	1.000
6	<i>Sea Bass</i>	1.000
7	<i>Striped Red Mullet</i>	1.000
8	<i>shrimp</i>	1.000
9	<i>trout</i>	1.000

3.2 Preprocessing

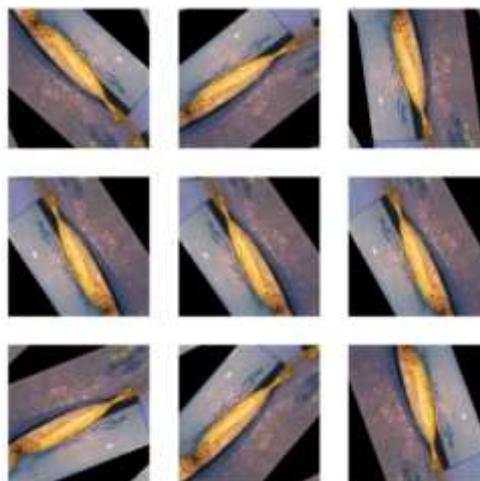
Preprocessing dilakukan pada data citra spesies ikan laut. *Dataset* dibagi menjadi tiga bagian yaitu 70% data *training*, 10% data validasi, dan 20% data *testing*. Gambar memiliki tiga *channels* warna, yaitu merah, hijau, dan biru (RGB). Untuk ukuran gambar diubah menjadi 224 x 224 untuk setiap data training dan testing karena model dari *Xception*, *Nasnet* dan *MobileNetV3L* sendiri menggunakan ukuran 224 x 224. Selain itu, citra juga di normalisasi dengan cara membagi nilai intensitas tiap piksel dengan 255 sehingga rentang nilai tiap piksel adalah -1 sampai 1. Normalisasi secara matematis dihitung dengan persamaan (1)

$$Normalization = \frac{x - \mu}{\sigma} \tag{1}$$

Dimana x adalah vektor fitur asli, μ adalah mean, dan σ adalah standar deviasi [12].

3.3 Data Augmentation

Deep Convolutional Neural Network Mengandalkan *Big Data* untuk menghindari *overfitting*, tetapi data besar belum tentu mudah didapatkan. Jadi *augmentasi* data adalah Solusi untuk meningkatkan ukuran dan kualitas pelatihan kumpulan data terbatas [13]. *Augmentasi* data dilakukan dengan menerapkan pembalikan acak *horizontal* dan *vertical*, serta *random rotation* dengan nilai 0,2. Hal ini dilakukan agar model dapat mempelajari citra dengan transformasi yang berbeda. Dengan begitu, model akan lebih mampu mengenali citra spesies ikan laut dengan berbagai variasinya. Berikut contoh implementasi data augmentation pada citra ditunjukkan pada gambar 2.

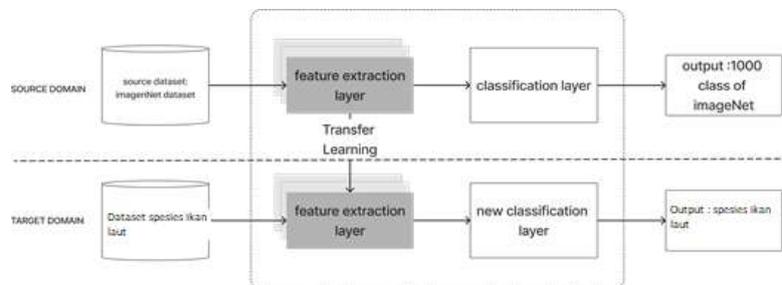


Gambar 2. Data Augmentation

3.4 Import jaringan Pre-trained

Dalam penelitian ini, digunakan model-model *pre-trained* seperti *Xception*, *MobileNetV3*, dan *NasNet*. Model-model *pre-trained* tersebut telah melalui pelatihan menggunakan dataset *ImageNet* yang mencakup berbagai fitur mulai dari yang sederhana seperti kecerahan dan batas,

hingga fitur yang lebih kompleks dan unik seperti warna dan bentuk. *Transfer learning* dapat diterapkan untuk melakukan klasifikasi spesies ikan laut dalam domain target dengan menggunakan hasil ekstraksi fitur dari lapisan ekstraksi fitur dalam domain sumber dan mengaplikasikannya pada lapisan ekstraksi fitur dalam domain target. Proses ini diilustrasikan dalam kerangka kerja transfer learning yang tergambar pada gambar tersebut.



Gambar 3. Kerangka kerja Transfer Learning

3.4.1 MobilenetV3L

Model ini merupakan versi terbaru dari MobileNet yang menggunakan arsitektur *MobileNetV3*. *MobileNetV3* dikembangkan khusus untuk perangkat seluler dengan daya komputasi yang terbatas. *MobileNetV3-Large* menggunakan teknik "*squeeze-and-excitation*" yang memungkinkan model untuk menggabungkan informasi dari lapisan terhubung dan meningkatkan akurasi model. Selain itu, model ini juga menggunakan teknik "koneksi residual" untuk menangkap informasi yang hilang selama proses konvolusi dan meningkatkan efisiensi komputasi. *MobileNetV3-Large* telah terbukti efektif dalam berbagai tugas pembelajaran mesin, termasuk klasifikasi gambar dan pengenalan objek [14].

3.4.2 Nasnet

NASNet (Neural Architecture Search Network) adalah sebuah arsitektur jaringan saraf tiruan yang dikembangkan menggunakan metode pencarian otomatis arsitektur. Ada beberapa varian *NASNet*, dan "*NASNet Large*" adalah salah satu varian dari arsitektur ini. *NASNet Large* adalah salah satu hasil dari penelitian dalam pencarian otomatis arsitektur jaringan saraf tiruan (*Neural Architecture Search, NAS*) [15]. Arsitektur ini dibangun dengan menggunakan metode pencarian otomatis untuk menemukan arsitektur yang optimal untuk tugas pengenalan objek dalam gambar. *NASNet Large* terkenal karena memiliki tingkat akurasi yang tinggi dalam berbagai tugas pengenalan objek pada dataset gambar populer seperti *ImageNet*. Arsitektur *NASNet Large* biasanya memiliki banyak lapisan konvolusi dan beberapa blok yang dirancang secara khusus untuk meningkatkan performa pengenalan objek. Arsitektur ini juga telah diuji dan digunakan dalam berbagai aplikasi dalam bidang pengenalan gambar dan pemrosesan gambar lainnya.

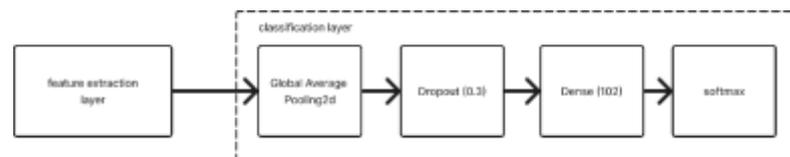
3.4.2 Xception

Arsitektur *Xception* dikembangkan oleh *Francois Chollet*, seorang peneliti di Google, dan diperkenalkan pada tahun 2016. *Xception* adalah singkatan dari "*Extreme Inception*", dan merupakan evolusi dari arsitektur *Inception* yang sebelumnya telah dikembangkan oleh tim Google [16]. Arsitektur *Xception* didasarkan pada konsep dasar dari *Inception*, yaitu penggunaan blok-blok konvolusi paralel dengan berbagai ukuran filter, namun dengan beberapa perubahan kunci. *Xception* menggabungkan pendekatan "*depthwise separable convolution*" yang diperkenalkan sebelumnya dalam arsitektur *MobileNet* dengan konsep *Inception*. Pendekatan "*depthwise separable convolution*" memisahkan operasi konvolusi menjadi dua tahap: konvolusi spasial dan konvolusi silang *channel-wise*. Dalam tahap konvolusi spasial, setiap saluran input dihubungkan ke kernel konvolusi 3x3 yang berbeda secara individu. Kemudian, dalam tahap konvolusi silang *channel-wise*, konvolusi linier dilakukan di antara saluran-saluran yang diperoleh sebelumnya. Pendekatan ini membantu mengurangi jumlah parameter dan komputasi yang dibutuhkan, sambil tetap mempertahankan kualitas fitur yang baik. Dengan menggabungkan *depthwise separable convolution* dengan struktur *Inception*, *Xception* berhasil mencapai tingkat akurasi yang baik dengan jumlah parameter yang lebih sedikit daripada model sebelumnya.

Arsitektur *Xception* telah berhasil diterapkan dalam berbagai tugas pengolahan gambar, termasuk klasifikasi gambar, deteksi objek, dan segmentasi semantik.

3.5 Penambahan Layer Baru

Dalam penelitian ini, hanya lapisan awal atau fitur ekstraksi dari model *pre-trained* yang digunakan. Model tersebut awalnya dilatih pada dataset Imagenet yang terdiri dari 1000 kelas. Namun, untuk tugas klasifikasi yang sedang diteliti, input model harus diubah agar sesuai dengan konteks tugas tersebut. Selain itu, *output layer* juga diubah sehingga mencakup jumlah kelas yang relevan dalam tugas klasifikasi, yaitu sebanyak 9 kelas. Dengan menggunakan lapisan awal dan melakukan penyesuaian *input* dan *output* sesuai dengan kebutuhan, model dapat digunakan untuk melakukan klasifikasi dengan akurasi yang diharapkan dalam penelitian ini. Berikut penambahan layer baru ditunjukkan pada Gambar 4.



Gambar 4. Ilustrasi Penambahan Layer baru

3.6 Pelatihan Model

Pelatihan model Arsitektur CNN, *Xception*, *MobileNetV3L*, dan *Nasnet Large*, ini akan menggunakan masukan (224,224,3) sesuai dengan masukan yang digunakan ketiga model tersebut pada *ImageNet*. *epoch* yang digunakan pada pelatihan adalah 50 agar tidak memakan waktu terlalu lama saat menggunakan *kaggle Notebook*.

3.7 Evaluasi Model

Setelah proses pelatihan model selesai, langkah selanjutnya adalah mengevaluasi model yang telah dilatih. Evaluasi model dilakukan dengan menggunakan dataset yang terpisah dari dataset yang digunakan untuk pelatihan model. Untuk mengukur kinerja model yang digunakan untuk klasifikasi, digunakan *confusion matrix* (cm). Evaluasi model dilakukan dengan memantau jumlah *true positive*, *true negative*, *false positive*, dan *false negative*. Dari data tersebut dapat dihitung akurasi, presisi, recall, dan skor f1. Masing-masing disajikan dari persamaan (2) ke persamaan (5).

$$Accuracy = \frac{(TN+TP)}{(TN+TP+FN+FP)} \tag{2}$$

$$Precision = \frac{TP}{(TP+FP)} \tag{3}$$

$$Recall = \frac{TP}{(TP+FN)} \tag{4}$$

$$F1 - score = 2 \times \frac{Precision \times Recall}{(Precision + Recall)} \tag{5}$$

Istilah-istilah berikut digunakan untuk menjelaskan kinerja model:

- True positive* (TP): data citra spesies ikan laut positif yang diprediksi dengan benar
- True negative* (TN): data citra spesies ikan laut negatif yang diprediksi dengan benar
- False positive* (FP): data citra spesies ikan laut negatif yang salah diprediksi positif
- False negative* (FN): data citra spesies ikan laut positif yang salah diprediksi sebagai negatif.

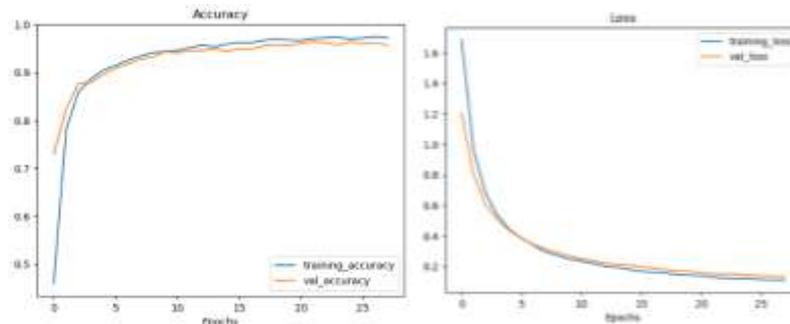
4. Hasil dan Pembahasan

4.1 Hasil Training

Tahap pengujian dilakukan dengan melatih data ikan laut ke dalam *fit model* dengan menggunakan *epoch* sebanyak 50 kali, *batch size* = 32, dan *dataset* dibagi menjadi tiga bagian yaitu 70% data *training*, 10% data validasi, dan 20% data *testing*. *Adam Optimizer* digunakan sebagai pengoptimal dan fungsi *loss* adalah *cross Entropy*. Untuk pencegahan *Overfitting* penulis menggunakan *early Stopping*. *Early Stopping* adalah teknik pembelajaran mesin yang bertujuan untuk menghentikan proses pelatihan model sebelum mencapai titik *overfitting*. *Epoch* dapat

diartikan sebagai jumlah *neuron* yang dapat melihat seluruh data yang dikumpulkan, dan *batch size* adalah jumlah sampel pelatihan dalam *forward/backward* pass. Berikut hasil *training* dengan 3 model yang sudah dibangun ditunjukkan pada Gambar 5 sampai Gambar 7.

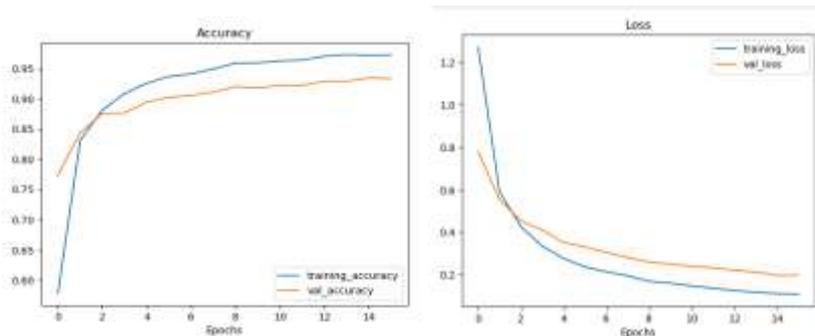
4.1.1 Xception



Gambar 5. plot akurasi dan *loss* Xception

Pada Gambar 5. Grafik Akurasi dan *loss* pada arsitektur Xception menghasilkan model yang baik (tidak mengalami *overfitting* ataupun *underfitting*). Hal ini ditandai dengan parameter *training loss* dan *test loss* tidak memiliki nilai yang berbeda secara signifikan. Kemudian, parameter *train accuracy* dan *test accuracy* pengujian memiliki nilai yang tidak jauh berbeda.

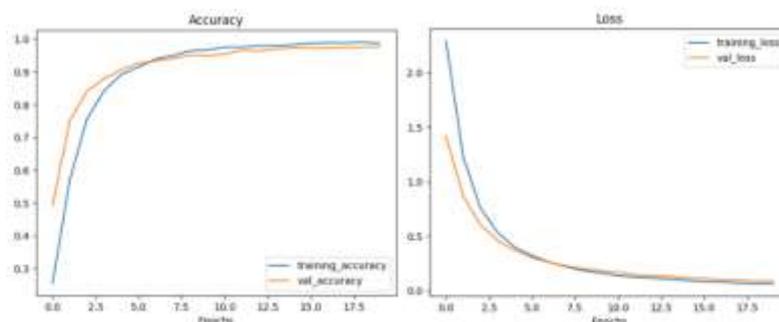
4.1.2 NasNet



Gambar 6. plot akurasi dan *loss* Nasnet

Pada Gambar 6. Grafik Akurasi dan *loss* pada arsitektur Nasnet menghasilkan model yang baik (tidak mengalami *overfitting* ataupun *underfitting*). Hal ini ditandai dengan parameter *training loss* dan *test loss* tidak memiliki nilai yang berbeda secara signifikan. Kemudian, parameter *train accuracy* dan *test accuracy* pengujian memiliki nilai yang tidak jauh berbeda.

4.1.3 Mobilenet V3L



Gambar 7. Plot akurasi dan *loss* Mobilenet V3L

Pada gambar 7 yaitu grafik akurasi dan *loss* dari model terbaik, bisa kita simpulkan bahwa model tidak mengalami *overfitting* karena garis grafik antara *train_accuracy* dan *validation_accuracy* tidak memiliki selisih yang terlalu jauh dan model juga tidak mengalami *underfitting* yang dimana untuk kasus *underfitting* ditandai dengan garis *validation_accuracy* lebih besar daripada garis *train_accuracy*.

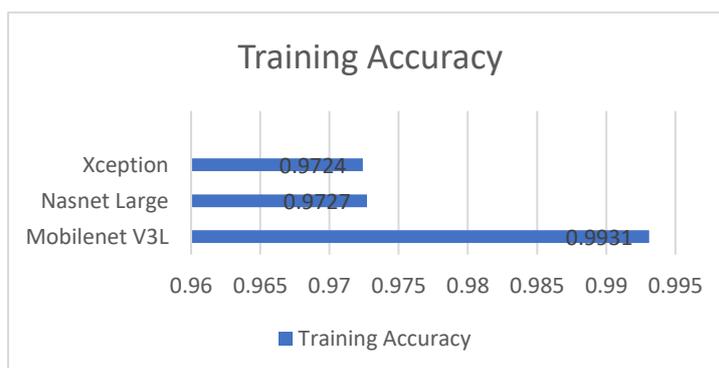
Pelatihan akurasi. Setiap model memiliki jumlah parameter yang berbeda. Varians dalam parameter total dari setiap model terlatih arsitektur ditunjukkan pada Tabel 2.

Table 2.Total Training Paramerters.

Model	Total Params	Trainable Params
<i>Xception</i>	20,879,921	18,441
<i>Nasnet</i>	84,953,115	36,297
<i>Mobilenet V3L</i>	3,005,001	8,649

Model *Mobilenet V3L* memiliki ukuran model yang paling kecil di antara ketiga model tersebut. *Xception* memiliki ukuran model yang lebih kecil dibandingkan dengan *Nasnet* dan *Nasnet* memiliki jumlah parameter yang lebih besar.

Hasil Perbedaan akurasi antara model yang dilatih dengan arsitektur cnn di tunjukkan pada gambar 8.



Gambar 8. Hasil Perbedaan akurasi antara model yang di latih

Grafik tersebut menunjukkan perbandingan hasil akurasi pada skenario pelatihan pada model CNN.

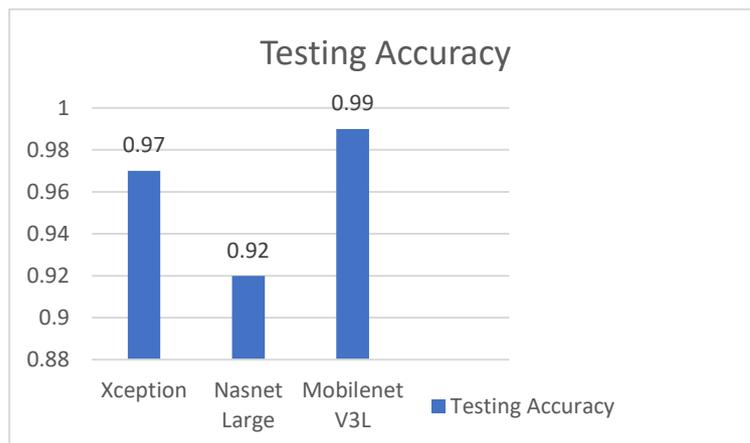
4.2 Hasil Testing

Hasil pengujian diperoleh dengan menggunakan confusion matrix pada data pengujian. berikut hasil rata rata *Accuracy*, *Precision*, *Recall*, *F1-Score* performa *matrix* dari pengujian dengan 3 model pada Table 3.

Table 3.Performance metrics

Model	Accuracy	Precision	Recall	F1-Score
<i>Xception</i>	0.97	0.97	0.97	0.97
<i>Nasnet Large</i>	0.92	0.93	0.92	0.92
<i>Mobilenet V3L</i>	0.99	0.99	0.99	0.99

Berdasarkan tabel 2 semua model CNN yang dievaluasi memiliki kinerja yang sangat baik dalam hal akurasi. Semua model mencapai tingkat akurasi yang tinggi, dengan nilai mencapai 92% hingga 99%. Ini menunjukkan bahwa semua model efektif dalam melakukan klasifikasi tugas yang diberikan. Perbedaan hasil akurasi antara model yang diuji ditunjukkan pada Gambar 9.



Gambar 9. Hasil perbedaan arsitektur yang di testing

Setelah mengevaluasi beberapa model, *Mobilenet-V3L* dianggap sebagai model yang paling cocok dan memberikan hasil yang paling baik dalam klasifikasi spesies ikan laut. Oleh karena itu, model tersebut digunakan untuk melakukan klasifikasi spesies ikan laut dalam penelitian ini. selanjutnya dilakukan prediksi dengan 9 data citra ikan laut untuk melihat hasil prediksi dengan label aslinya. Gambar 10. menunjukkan hasil prediksi dengan data uji menggunakan model *Mobilenet-V3L*.



Gambar 5. contoh hasil prediksi dengan data uji menggunakan model Mobilenet-V3L.

Model CNN yang digunakan menghasilkan performa klasifikasi yang tergolong sangat baik karena nilai akurasinya diantara 92%-99%. Namun, jika dibandingkan ketiga model tersebut maka yang memiliki performa lebih baik yaitu *MobilenetV3L* seperti pada tabel 3. Hal ini dibuktikan dengan nilai akurasi *mobileNetV3L* yang tinggi dibandingkan *Xception* dan *NasNet*. Temuan ini sejalan dengan penelitian[17]. yang telah menguji model arsitektur *MobileNet* dan *NasNet* dalam kasus Klasifikasi Penyakit Daun Teh pada penelitian tersebut akurasi *MobileNet* sebesar 95% sedangkan *Nasnet* mendapatkan akurasi sebesar 88%. Selain itu arsitektur *MobileNet* cukup efisien dalam melakukan komputasi karena memiliki ukuran yang kecil, baik dari segi jumlah parameter maupun ukuran model yang dihasilkan[18]. Oleh karena itu, pada kasus ini *MobileNet* lebih unggul daripada *Xception* dan *Nasnet*.

5. Simpulan

Berdasarkan perbandingan arsitektur CNN, dapat disimpulkan bahwa semua model memiliki performa yang sangat baik dalam melakukan klasifikasi spesies ikan laut. Semua model memiliki akurasi yang tinggi, dengan nilai mencapai 92% hingga 99%. Selain itu, semua model juga menunjukkan konsistensi dalam hal *precision*, *recall*, dan *F1-Score*, dengan nilai yang sebanding dan berkisar antara 92% hingga 99%. Dalam hal ini, model *Mobilenet V3L* memiliki

performa yang sedikit lebih tinggi dibandingkan dengan model *Xception*, dan *Nasnet Large*. Model-model tersebut mencapai akurasi, *precision*, *recall*, dan *F1-Score* sekitar 92% hingga 99%, menunjukkan kemampuan yang sangat baik dalam mengenali dan mengklasifikasikan spesies ikan laut.

Daftar Referensi

- [1] A. I. Burhanuddin, *Vertebrata Laut*. Deepublish, 2018.
- [2] T. N. Utami and E. Indrayani, *Komoditas Perikanan*. Universitas Brawijaya Press, 2018.
- [3] N. Z. Munantri, H. Sofyan, and M. Y. Florestiyanto, "Aplikasi Pengolahan Citra Digital Untuk Identifikasi Umur Pohon," *Telemat. J. Inform. dan Teknol. Inf.*, vol. 16, no. 2, pp. 97–104, 2020.
- [4] M. L. Suyanto, "Tingkat Dasar dan Lanjut," *Inform. Bandung*, 2018.
- [5] S. Pattanayak, J. S. Pattanayak, and S. John, *Pro deep learning with tensorflow*. Springer, 2017.
- [6] M. Pasaribu and A. Widjaja, *Artificial Intelligence: Perspektif Manajemen Strategis*. Kepustakaan Populer Gramedia, 2022.
- [7] S. Amat, I. M. Dadang, and B. Y. Mesra, "Klasifikasi jenis alat musik tradisional Papua menggunakan metode transfer learning dan data augmentasi," *J. Sist. Komput. dan Kecerdasan Buatan*, vol. 5, no. 2, pp. 36–44, 2022.
- [8] N. Rachmat, Y. Yohannes, and A. Mahendra, "Klasifikasi Jenis Ikan Laut Menggunakan Metode SVM dengan Fitur HOG dan HSV," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 8, no. 4, pp. 2235–2247, 2021.
- [9] I. Ariawan, W. A. Arifin, A. A. Rosalia, and N. Tufailah, "Klasifikasi Tiga Genus Ikan Karang Menggunakan Convolution Neural Network," *J. Ilmu dan Teknol. Kelaut. Trop.*, vol. 14, no. 2, pp. 205–216, 2022.
- [10] A. B. Zuhri, D. I. Maulana, and E. S. Maheswara, "Optimization Image Classification Pada Ikan Hiu Dengan Metode Convolutional Neural Network Dan Data Augmentasi," *J. Tika*, vol. 7, no. 1, pp. 1–11, 2022.
- [11] A. Bahar and B. A. Kusuma, "Klasifikasi Spesies Hiu Dengan Arsitektur," *J. Comput. Sci. Technol.*, vol. 1, no. 3, pp. 118–123, 2023.
- [12] R. Kalaiarasan, K. Madhan Kumar, S. Sridhar, and M. Yuvarai, "Deep Learning-based Transfer Learning for Classification of Skin Cancer," *Proc. - Int. Conf. Appl. Artif. Intell. Comput. ICAAIC 2022*, pp. 450–454, 2022, doi: 10.1109/ICAAIC53929.2022.9792651.
- [13] C. Shorten and T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning," *J. big data*, vol. 6, no. 1, pp. 1–48, 2019.
- [14] A. Howard *et al.*, "Searching for mobilenetv3," in *Proceedings of the IEEE/CVF international conference on computer vision*, 2019, pp. 1314–1324.
- [15] B. Zoph, V. Vasudevan, J. Shlens, and Q. V Le, "Learning transferable architectures for scalable image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 8697–8710.
- [16] N. Jaymon, S. Nagdeote, A. Yadav, and R. Rodrigues, "Real time emotion detection using deep learning," in *2021 International conference on advances in electrical, computing, communication and sustainable technologies (ICAECT)*, 2021, pp. 1–7.
- [17] N. Hardi, "Komparasi Algoritma MobileNet Dan Nasnet Mobile Pada Klasifikasi Penyakit Daun Teh," *Reputasi J. Rekayasa Perangkat Lunak*, vol. 3, no. 1, pp. 50–55, 2022.
- [18] W. Bismi and H. Harafani, "Perbandingan Metode Deep Learning dalam Mengklasifikasi Citra Scan MRI Penyakit Otak Parkinson," *InComTech J. Telekomun. dan Komput.*, vol. 12, no. 3, pp. 177-185, 2022, doi: 10.22441/incomtech.v12i3.15068.