

Klasifikasi Citra Daging Sapi dan Daging Babi Menggunakan CNN Arsitektur EfficientNet-B6 dan Augmentasi Data

M Fadil Martias, Jasril*, Suwanto Sanjaya, Lestari Handayani, Febi Yanto

Fakultas Sains dan Teknologi, Prodi Teknik Informatika, Universitas Islam Negeri Sultan Syarif Kasim Riau, Pekanbaru, Indonesia

Email: ¹11950115110@students.uin-suska.ac.id, ^{2*}jasril@uin-suska.ac.id, ³suwantosanjaya@uin-suska.ac.id,

⁴lestari.handayani@uin-suska.ac.id, ⁵febiyanto@uin-suska.ac.id

Email Penulis Korespondensi: jasril@uin-suska.ac.id

Submitted: 26/05/2023; Accepted: 30/06/2023; Published: 30/06/2023

Abstrak—Dalam kehidupan sehari-hari, daging sapi seringkali menjadi kebutuhan utama manusia. Namun, harga daging sapi yang tinggi dan mahal menjadi masalah yang memicu pedagang untuk melakukan pengoplosan dengan daging babi demi meraih keuntungan. Pengoplosan semacam ini memiliki konsekuensi serius di dalam agama Islam, di mana tidak semua jenis daging halal dikonsumsi, seperti daging babi. Akibatnya, konsumen seringkali tidak menyadari bahwa daging sapi yang mereka beli telah dicampur dengan daging babi. Dalam pandangan kasat mata, kedua jenis daging ini memiliki bentuk dan tekstur yang serupa, sehingga sulit dibedakan. Penelitian ini bertujuan untuk mengklasifikasikan daging sapi dan babi menggunakan model deep learning dengan metode Convolutional Neural Network (CNN) yang dipadukan dengan augmentasi data. Model yang digunakan adalah EfficientNet-B6 dengan variasi skenario uji. Variasinya yaitu pada rasio pembagian data latih, data uji, learning rates, dan optimizer untuk EfficientNet-B6. Augmentasi data dilakukan dengan teknik rotasi acak, penggeseran, pembesaran atau pempersempitan citra, pembalikan citra secara vertikal dan horizontal, dan pengisian pixel terdekat. Hasil evaluasi menggunakan confusion matrix menunjukkan bahwa model dengan augmentasi data memiliki akurasi tertinggi untuk kelas sapi, babi dan oplosan sebesar 92,00%, sedangkan model tanpa augmentasi memiliki akurasi 91,67%. Namun, dari eksperimen ini, dapat diperoleh skenario terbaik untuk menghindari daging babi dan oplosan terklasifikasi sebagai sapi. Skenarionya yaitu model dengan augmentasi data, pembagian data 90:10, optimizer SGD, dan learning rate 0,01 ini memiliki nilai presisi kelas sapi tertinggi yaitu sebesar 96,05%. Hasil penelitian menunjukkan bahwa penggunaan augmentasi data pada citra dapat meningkatkan kinerja model, dan model dengan augmentasi data pada skenario rasio pembagian data 90:10, optimizer SGD, dan learning rate 0,01 memiliki kinerja terbaik dalam mengklasifikasikan citra sapi.

Kata Kunci: Augmentasi; CNN; Daging; Deep Learning; Klasifikasi

Abstract—In daily life, beef often serves as a staple food for humans. However, the high and expensive price of beef has prompted traders to adulterate it with pork for the sake of profit. Such adulteration has serious implications in the Islamic religion, where not all types of meat are considered halal (permissible for consumption), such as pork. As a result, consumers often remain unaware that the beef they purchase has been adulterated with pork. At a glance, both types of meat exhibit similar appearance and texture, making them difficult to differentiate. This research aims to classify beef and pork using a deep learning model with the Convolutional Neural Network (CNN) method, combined with data augmentation. The model used is EfficientNet-B6 with variations in the testing scenario. The variations include the ratio of training and testing data, learning rates, and optimizer for EfficientNet-B6. Data augmentation is performed using techniques such as random rotation, shifting, image scaling, vertical and horizontal flipping, and nearest pixel filling. Evaluation results using the confusion matrix show that the model with data augmentation achieves the highest accuracy for the classes of beef, pork, and adulterated samples at 92.00%, while the model without augmentation achieves an accuracy of 91.67%. However, from this experiment, the best scenario to avoid misclassifying pork and adulterated samples as beef can be obtained. This scenario involves a model with data augmentation, a 90:10 data split, SGD optimizer, and a learning rate of 0.01, which achieves the highest precision for the beef class at 96.05%. The research findings demonstrate that the use of data augmentation on images can improve the model's performance, and the model with data augmentation, a 90:10 data split, SGD optimizer, and a learning rate of 0.01 exhibits the best performance in classifying beef images.

Keywords: Augmentation; CNNs; Meat; Deep Learning; Classification

1. PENDAHULUAN

Daging merupakan sumber protein hewani. Ada banyak jenis daging yang dimakan oleh manusia. Daging sapi merupakan jenis daging yang paling banyak dikonsumsi. Salah satu manfaat memakan daging sapi adalah dapat mencegah anemia [1]. Namun, dalam Islam, tidak semua daging yang dikonsumsi itu halal. Makanan yang halal baik untuk kesehatan fisik dan mental [2], tetapi makanan yang tidak bersih dapat menyebabkan penyakit. Daging babi merupakan salah satu jenis daging yang tidak halal dan dilarang untuk dikonsumsi dalam agama Islam. Allah telah berfirman dalam Al-Qur'an Surat Al-Baqarah ayat 173 yang artinya "Sesungguhnya Dia hanya mengharamkan bagimu bangkai, darah, babi, dan (daging) binatang yang disembelih dengan (menyebut nama) selain Allah. dipaksa (memakannya), bukan karena ia menginginkannya dan tidak (juga) melampaui batas, maka tidak ada dosa baginya. Sesungguhnya Allah Maha Pengampun lagi Maha Penyayang." Memakan daging babi dapat menimbulkan berbagai penyakit seperti kanker usus besar, penyakit hati, hepatitis E, parasit, dan multiple sclerosis [3]. Selain itu, konsumsi daging babi yang berlebihan juga dapat berisiko terkena kolesterol tinggi, penyakit jantung, dan kanker [4].

Daging sapi memiliki harga yang relatif mahal dibandingkan daging babi, maka para pedagang mencampurkan daging sapi dan babi yang bertujuan untuk kepentingan pribadi seperti mendapatkan keuntungan

besar dengan modal sedikit. Hal ini tentu saja dapat merugikan konsumen, terutama umat muslim di Indonesia. Beberapa kasus pencampuran daging babi dan sapi di Indonesia, seperti yang terjadi di Gunung Kidul, selain mencampurkan daging, tersangka juga mencampurkan kikil yang ada pada daging sapi dan daging babi [5]. Di Lampung terdapat juga kasus dimana penjual menjual daging babi berkedok daging sapi [6]. Konsumen seringkali tidak menyadari bahwa daging sapi yang dibelinya telah tercampur dengan daging babi, karena sekilas kedua daging tersebut memiliki bentuk dan tekstur yang sama sehingga sulit dibedakan. Teknologi diperlukan untuk membantu konsumen dalam membedakan daging babi dan daging sapi. Teknologi yang banyak digunakan adalah pengolahan citra. Pengolahan citra dapat dilakukan dengan menggunakan Machine Learning dan Deep Learning.

Penelitian ini memiliki urgensi yang tinggi karena adanya penipuan dalam penjualan daging sapi yang dicampur dengan daging babi yang merugikan konsumen, terutama bagi umat Muslim yang menjalankan aturan makanan halal. Penelitian ini akan menggunakan pendekatan Deep Learning Convolution Neural Network (CNN) arsitektur EfficientNet-B6 untuk membedakan antara daging sapi, daging babi, dan daging oplosan. Data citra daging sapi dan daging babi akan dikumpulkan, difoto, dan dioplos. Kemudian, model EfficientNet-B6 akan dilatih menggunakan data tersebut. Model yang telah dilatih akan digunakan untuk mengklasifikasikan citra baru dan membedakan antara daging sapi, daging babi, dan daging oplosan. Akurasi dan performa model akan dievaluasi menggunakan confusion matrix.

Beberapa penelitian klasifikasi daging sapi dan babi dengan menggunakan Machine Learning yang telah dilakukan antara lain menggunakan metode Support Vector Machine yang diteliti oleh Sriwanti Ayu Aisah. Hasil penelitian ini didapatkan akurasi tertinggi ini sebesar 90%, dengan menggunakan total 30 data citra daging sapi, babi hutan babi dan sapi [7]. Usman Sudibyo, dkk juga melakukan penelitian tentang Optimasi Algoritma Learning Vector Quantization (LVQ) dalam Mengklasifikasikan Citra Daging Sapi dan Babi Berbasis GLCM dan HSV. Hasil akurasi tertinggi yang diperoleh adalah 76.25%. Untuk mengetahui kesalahan minimum maka digunakanlah MSE, sedangkan untuk mengukur kualitas pemrosesan citra digunakanlah PSNR [8]. Selanjutnya, Titis Yunita Purnomo dkk, mengklasifikasikan daging menggunakan algoritma Random Forest. Python dan library OpenCV digunakan untuk menunjang penelitian ini. Pemeriksaan dilakukan pada black box dan keakuratan sistem diperiksa dengan confusion matrix. Penelitian ini mengungkapkan bahwa akurasi metode Random Forest adalah 78,22% dengan jumlah pohon = 280 dan kedalaman maksimum = 10, dan 10-kfold digunakan untuk membagi data [9].

Seiring berkembangnya teknologi, para peneliti mulai beralih menggunakan Deep Learning untuk pengolahan citra. Hal ini dikarenakan Deep Learning terbukti mampu memberikan tingkat akurasi yang lebih tinggi dibandingkan dengan Machine Learning. Banyak penelitian telah dilakukan untuk membandingkan akurasi Machine Learning dan Deep Learning. Beberapa penelitian terkait perbandingan akurasi klasifikasi menggunakan Machine Learning dan Deep Learning yaitu Mohammad Farid telah melakukan penelitian dengan melakukan perbandingan Support Vector Machines (SVM), K-Nearest Neighbour (KNN), dan Convolutional Neural Networks (CNN) dalam klasifikasi citra cuaca tahun 2021. Berdasarkan uji coba yang dilakukan, CNN memiliki performa terbaik dengan akurasi 0.942, presisi 0.943, recall 0.942, dan f1 score 0.942 [10]. Penelitian selanjutnya dilakukan oleh Ari Peryanto yang membandingkan CNN dan SVM untuk klasifikasi citra bunga. Studi ini menyimpulkan bahwa CNN mengungguli SVM dalam klasifikasi citra bunga. CNN memberikan akurasi 91.6%, presisi 91.6%, recall 91.6% dan f1 score 91.6% [11].

Oleh sebab itu, metode Deep Learning Convolution Neural Network (CNN) akan digunakan pada penelitian ini. Arsitektur yang digunakan adalah EfficientNet-B6 dikarenakan banyaknya penelitian yang menggunakan arsitektur ini dalam hal klasifikasi citra dan mendapatkan hasil terbaik diantara arsitektur lainnya. Penelitian oleh Siwen Wu, dkk membandingkan model EfficientNet-B0, EfficientNet-B5 dan EfficientNet-B6. Hasil yang didapatkan yaitu nilai MAPE EfficientNet-B6 sebesar 0.768, lebih tinggi 1.59% dan 1.05% dibanding model EfficientNet-B0 dan EfficientNet-B5 [12]. Penelitian lain oleh Zahid Maqsood & Manoj Kumar Gupta membuktikan bahwa EfficientNet-B6 memiliki akurasi tertinggi dibandingkan ResNet50, Inceptionv3, EfficientNet-B5, dan VGG19 yaitu sebesar 86.03% [13].

Penelitian ini juga dipadukan dengan augmentasi data. Augmentasi data adalah proses memanipulasi gambar sehingga mengubah bentuk dan posisi gambar format standar asli. Tujuan augmentasi data adalah untuk memungkinkan mesin belajar dan mengenali dari banyak gambar yang berbeda dan mereproduksi data pada saat yang bersamaan [14]. Augmentasi data dapat digunakan untuk meningkatkan akurasi [15]. Model augmentasi data yang digunakan dalam penelitian ini adalah rotation, width_shift, height_shift, zoom, horizontal_flip, vertical_shift dan fill_mode. Model yang digunakan mengacu pada model yang dikembangkan oleh Elia Cano et al yang melakukan penelitian berjudul "Multi skin lesions classification using fine-tuning and data-augmentation applying NASNet" [16].

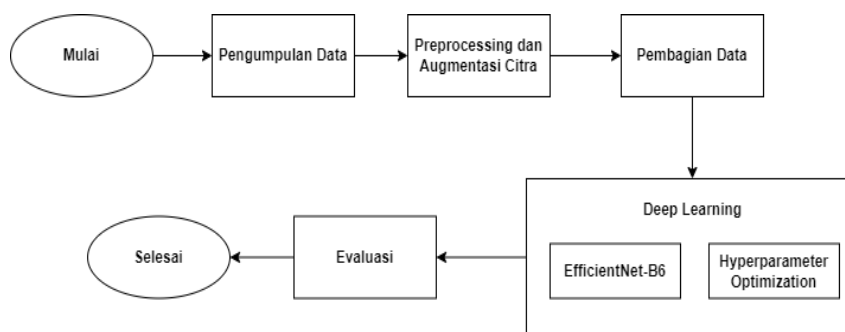
Beberapa penelitian EfficientNet yang telah menggunakan augmentasi data antara lain penelitian oleh Abdul Rafay dan Wawar Husain yang menggunakan EfficientNet untuk mengklasifikasikan 31 penyakit kulit. Didapatkan hasil akurasi model meningkat setelah menggunakan augmentasi, yaitu dari 74% menjadi 87.15% [17]. Penelitian lain oleh Fredy Barrientos-Espilloco, dkk juga membuktikan bahwa model UNet++ dengan EfficientNet-B6 dengan augmentasi data, mencapai generalisasi dan performa yang baik [18]. Lozhkin, dkk juga melakukan penelitian menggunakan model EfficientNet-B6 dan augmentasi data, dan didapatkan kesimpulan augmentasi data merupakan pendekatan yang efektif dalam memecahkan masalah segmentasi semantik [19].

Penelitian berikutnya yaitu oleh Hugo Vega-Huerta, dkk yang menyimpulkan augmentasi data dapat meningkatkan akurasi dan spesifisitas model EfficientNet sebesar 0,06% [20].

Penelitian sebelumnya oleh Gusrifaris Yuda Alhafis mengenai klasifikasi citra daging sapi dan daging babi menggunakan metode Contrast Limited Adaptive Histogram Equalization (CLAHE) dengan arsitektur EfficientNet-B0 menjadi dasar dari penelitian ini. Penggunaan metode CLAHE pada penelitian sebelumnya terbukti tidak memberikan peningkatan nilai akurasi yang diharapkan [21]. Oleh karena itu, dalam penelitian ini, penulis akan menggunakan augmentasi data dengan harapan dapat meningkatkan kinerja dan akurasi model [22].

2. METODOLOGI PENELITIAN

Gambaran dari tahapan penelitian ini dapat dilihat pada gambar 1. Tahapan yang akan dilakukan yaitu mulai dari pengumpulan data, preprocessing dan augmentasi citra, pembagian data, proses pengolahan data menggunakan Deep Learning Convolution Neural Network (CNN) arsitektur EfficientNet-B6, dan proses evaluasi. Berikut penjelasan dari masing-masing tahapan yang akan dilakukan:



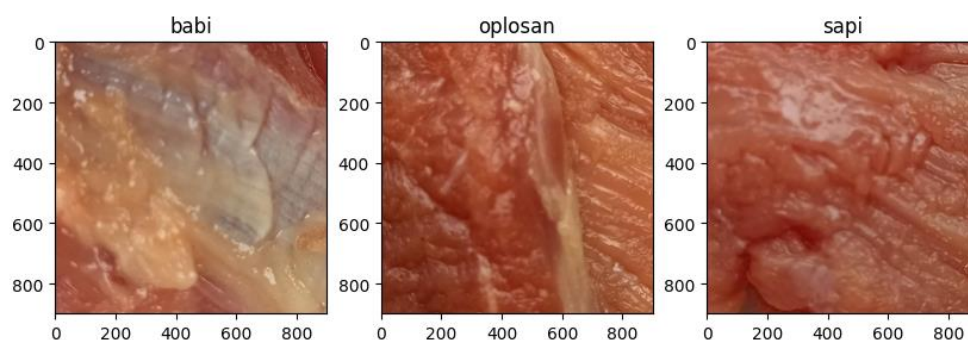
Gambar 1. Tahapan Penelitian

2.1 Pengumpulan Data

Data pada penelitian ini berupa gambar daging sapi, daging babi dan daging sapi yang dicampur babi (oplosan). Daging babi dan sapi dibeli di Pasar tradisional di kota Pekanbaru yaitu Pasar Sago dan Pasar Sentral Kota Pekanbaru Riau. Foto daging sapi dan babi diambil menggunakan kamera smartphone POCO X3 GT dan Redmi Note 10S dengan kamera utama 64 MP. Jarak pengambilan foto objek daging adalah 10 cm sampai 15 cm. Pencahayaan foto menyesuaikan dengan kondisi cahaya sekitar. Data yang telah terkumpul dibagi menjadi 3 bagian yaitu daging babi, daging sapi dan daging oplosan. Total data gambar yang diperoleh adalah 912 gambar.

2.2 Processing Data dan Augmentasi Citra


Preprocessing merupakan tahapan yang dilakukan sebelum melatih model Deep Learning untuk menyiapkan data agar lebih sesuai dengan kebutuhan model. Preprocessing dapat membantu meningkatkan performa model dengan membersihkan dan menyederhanakan data, sehingga model tidak terbebani oleh informasi atau noise yang tidak relevan. Gambar dicek terlebih dahulu apakah kualitasnya memadai untuk diolah, jika kualitas kurang bagus atau gambar blur, maka gambar akan dibuang dan tidak akan digunakan. Preprocessing yang digunakan pada penelitian ini adalah crop center dan resize image menjadi 224 x 224. Setelah dilakukan preprocessing, total data yang diperoleh yaitu sebanyak 723 gambar. Karena gambar pada setiap jenis daging yang didapatkan berbeda jumlahnya, maka banyak data yang akan digunakan pada penelitian ini yaitu sebanyak 200 dari setiap class nya, jadi total gambar yang digunakan pada penelitian ini yaitu sebanyak 600 data gambar.



Gambar 2. Data Citra Setelah Dilakukan Preprocessing

Data citra yang telah dilakukan preprocessing dapat dilihat pada gambar 2. Setelah melakukan preprocessing, langkah selanjutnya adalah melakukan augmentasi data. Augmentasi data adalah proses menambah

jumlah data pelatihan dengan memodifikasi data yang ada dengan cara yang sesuai. Augmentasi data bertujuan untuk meningkatkan performa model dengan memberikan lebih banyak contoh tentang bagaimana data dapat muncul di dunia nyata. Penambahan data juga dapat membantu mengurangi overfitting dengan membawa variasi data yang lebih besar ke model. Augmentasi data yang akan digunakan dalam penelitian ini adalah rotasi acak hingga 180 derajat, menggeser tinggi dan lebar citra dengan batas 10%, memperbesar atau memperkecil citra secara acak hingga 10%, membalik citra secara vertikal dan secara horizontal dan menggunakan nilai piksel terdekat untuk mengisi piksel yang hilang [16].



Gambar 3. Data Citra Setelah Dilakukan Augmentasi Data

Hasil citra setelah diaugmentasi dapat dilihat pada gambar 3. Data citra original menggambarkan citra daging dalam kondisi asli. Data citra augmentasi kemudian dibuat berdasarkan data original ini dengan menerapkan beberapa transformasi dan teknik augmentasi yang telah disebutkan di atas. Data citra augmentasi ini memberikan tambahan informasi yang bervariasi, sehingga memperkaya dataset dan membantu melatih model untuk menghadapi variasi kondisi dan situasi yang mungkin terjadi dalam dunia nyata.

2.3 Pembagian Data

Setelah dilakukan proses augmentasi, data akan dibagi menjadi dua bagian yaitu data latih dan data uji. Rasio pembagian data latih dan data uji yang akan dilakukan adalah 80:20 dan 90:10. Sebagian data training akan digunakan sebagai data validasi yaitu 20% data training untuk rasio split 80:20 dan 10% untuk rasio split 90:10.

Tabel 1. Dataset Tanpa Augmentasi dan Augmentasi dengan Rasio Pembagian 80:20

Kelas	Data Non-Augmentasi			Data Augmentasi		
	Latih (80%)		Uji (20%)	Latih (80%)		Uji (20%)
	Latih (80%)	Validasi (20%)		Latih (80%)	Validasi (20%)	
Daging Sapi	128	32	40	640	160	200
Daging Babi	128	32	40	640	160	200
Daging Oplosan	128	32	40	640	160	200

Tabel 1 menunjukkan dataset tanpa augmentasi dan dataset dengan augmentasi, dengan rasio pembagian 80:20 antara data latih dan data uji, serta pembagian 80:20 antara data latih dan data validasi. Tabel ini memberikan gambaran tentang jumlah data yang ada dalam masing-masing kategori untuk setiap kondisi dataset. Kelas-kelas dalam dataset terdiri dari "Daging Sapi", "Daging Babi", dan "Daging Oplosan". Tabel ini memberikan gambaran tentang pembagian dan jumlah sampel data dalam masing-masing kategori dataset, baik dengan atau tanpa augmentasi. Pembagian dataset ini penting dalam melakukan proses pelatihan, pengujian, dan validasi model pembelajaran mesin.

Tabel 2. Dataset Tanpa Augmentasi dan Augmentasi dengan Rasio Pembagian 90:10

Kelas	Data Non-Augmentasi			Data Augmentasi		
	Latih (90%)		Uji (10%)	Latih (90%)		Uji (10%)
	Latih (90%)	Validasi (10%)		Latih (90%)	Validasi (10%)	
Daging Sapi	162	18	20	810	90	100
Daging Babi	162	18	20	810	90	100
Daging Oplosan	162	18	20	810	90	100

Tabel 2 juga menggambarkan dataset tanpa augmentasi dan dataset dengan augmentasi, namun dengan rasio pembagian yang berbeda yaitu 90:10 antara data latih dan data uji, serta pembagian 90:10 antara data latih dan data validasi. Tabel ini memberikan informasi tentang jumlah data dalam setiap kategori dataset untuk setiap kondisi. Kelas-kelas dalam dataset adalah "Daging Sapi", "Daging Babi", dan "Daging Oplosan". Tabel ini memberikan gambaran tentang pembagian dan jumlah sampel data dalam setiap kategori dataset, baik dengan atau

tanpa augmentasi, dengan menggunakan rasio pembagian yang berbeda. Pembagian ini penting untuk memastikan bahwa model pembelajaran mesin dapat dilatih, diuji, dan divalidasi dengan benar menggunakan data yang representatif.

2.4 Deep Learning

Penelitian ini menggunakan algoritma Deep Learning Convolutional Neural Network (CNN) dengan arsitektur EfficientNet-B6.



Gambar 4. Arsitektur EfficientNet-B6

Gambar 4 merupakan arsitektur dari EfficientNet-B6. Berikut penjelasan layer-layer yang terdapat pada EfficientNet-B6:

- Convolutional Layer:** Layer pertama adalah lapisan konvolusi yang menerima input gambar dan melakukan konvolusi dengan sejumlah filter untuk mendeteksi fitur-fitur visual pada gambar.
- Intermediate Blocks:** Terdapat 8 blok utama dalam EfficientNet-B6. Setiap blok utama terdiri dari beberapa lapisan konvolusi yang dilanjutkan dengan normalisasi dan aktivasi. Setiap blok bertujuan untuk mengekstraksi fitur-fitur yang semakin kompleks dari data gambar.
- Global Average Pooling:** Setelah melalui blok-blok utama, hasilnya kemudian melewati lapisan Global Average Pooling. Ini adalah operasi yang mengurangi dimensi spasial fitur menjadi satu angka rata-rata untuk setiap saluran fitur. Hal ini mengurangi jumlah parameter dan menghasilkan representasi fitur yang lebih ringkas.
- Fully Connected Layers:** Setelah lapisan Global Average Pooling, hasilnya dihubungkan ke lapisan fully connected. Lapisan ini bertujuan untuk menghubungkan fitur-fitur yang terekstraksi sejauh ini dengan label kelas yang akan diprediksi.
- Output Layer:** Layer output terakhir berupa softmax layer yang menghasilkan probabilitas untuk setiap kelas yang mungkin. Ini memungkinkan model untuk melakukan klasifikasi multi-kelas dan memprediksi kelas gambar yang sesuai dengan probabilitas tertinggi.

Tabel 3. Hyperparameter

Optimizer	Learning Rate
Adam	0,1
RAdam	0,01
SGD	0,001
RMSprop	0,0001

Tabel 3 menggambarkan hyperparameter yang digunakan dalam pelatihan model. Hyperparameter adalah parameter yang ditentukan sebelum pelatihan dan mempengaruhi bagaimana model belajar dan memperbarui bobotnya selama proses optimisasi. Dalam tabel tersebut, terdapat beberapa optimizer yang digunakan untuk mengoptimalkan model, yaitu Adam, RAdam, SGD, dan RMSprop. Optimizer digunakan untuk mengoptimalkan parameter model, sedangkan untuk menentukan nilai koreksi bobot selama fase pelatihan digunakan learning rate [23].

2.5 Evaluasi

Selama fase ini, indikator kinerja utama dari pengujian model diperiksa. Matriks konfusi digunakan untuk mengukur kinerja dalam penelitian ini. Matriks konfusi adalah matriks yang berisi kelas prediksi yang dibandingkan dengan kelas asli dari data masukan. Istilah matriks kebingungan meliputi:

- True Positive (TP) merupakan banyaknya data positif yang diklasifikasikan benar oleh sistem.
- True Negative (TN) merupakan banyaknya data negatif yang diklasifikasikan benar oleh sistem.
- False Negative (FN) merupakan banyaknya data negatif yang dianggap salah oleh sistem.
- False Positive (FP) merupakan banyaknya data positif tetapi dianggap salah oleh sistem.

Berikut ini adalah rumus-rumus yang terdapat dalam confusion matrix:

- Akurasi**

Akurasi adalah persentase prediksi yang benar yang dibuat oleh model.

$$akurasi = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \tag{1}$$

b. Recall

Recall mewakili keberhasilan model dalam mengambil ulang informasi.

$$recall = \frac{TP}{TP+FN} \times 100\% \tag{2}$$

c. Presisi

Presisi mewakili ketepatan antara informasi yang diminta dan hasil prediksi dari model.

$$presisi = \frac{TP}{TP+FP} \times 100\% \tag{3}$$

d. F1 Score

F1 score menggambarkan akurasi yang didapatkan model pada seluruh dataset.

$$f1\ score = 2 \times \frac{presisi \times recall}{presisi+recall} \tag{4}$$

3. HASIL DAN PEMBAHASAN

3.1 Proses Training

Pelatihan model EfficientNet-B6 ini dilakukan dengan memanfaatkan library Tensorflow dan Keras. Proses pelatihan dilakukan dengan beberapa variasi hyperparameter seperti optimizer, dan learning rate. Setiap percobaan dilakukan sebanyak 32 kali untuk masing-masing rasio pembagian data. Proses pelatihan dilakukan selama 50 epoch dengan metode early stopping. Metode early stopping memantau nilai validation loss selama pelatihan. Jika nilai validation loss berhenti menurun dan mulai meningkat, ini menunjukkan tanda-tanda overfitting. Dalam hal ini, metode early stopping akan menghentikan proses pelatihan model agar tidak memperburuk kinerja model. Ukuran batch yang digunakan adalah 64, yang berarti model akan diperbarui setiap 64 sampel data. Penggunaan batch size dapat mempengaruhi kecepatan pelatihan dan penggunaan memori komputasi. Berikut tabel hasil training pada rasio pembagian data 80% : 20% dan 90% : 10%.

Tabel 4. Hasil Training dengan Rasio Pembagian Data 80:20

No	Jenis Data	Optimizer	Learning Rate	Training Loss	Training Accuracy	Validation Loss	Validation Accuracy
1	Tanpa Augmentasi	Adam	0,1	1,1148	0,3333	1,0992	0,3333
2	Tanpa Augmentasi	Adam	0,01	0,7829	0,5938	0,8561	0,5729
3	Tanpa Augmentasi	Adam	0,001	0,2427	0,9141	0,5736	0,7500
4	Tanpa Augmentasi	Adam	0,0001	0,3773	0,8750	0,5712	0,8021
5	Tanpa Augmentasi	RAdam	0,1	0,7164	0,6771	0,6726	0,7500
6	Tanpa Augmentasi	RAdam	0,01	0,2304	0,8776	0,6240	0,7917
7	Tanpa Augmentasi	RAdam	0,001	0,2301	0,9297	0,5664	0,8021
8	Tanpa Augmentasi	RAdam	0,0001	0,6220	0,7839	0,7027	0,6979
9	Tanpa Augmentasi	SGD	0,1	0,1887	0,9427	0,5613	0,7708
10	Tanpa Augmentasi	SGD	0,01	0,2381	0,9193	0,5881	0,7396
11	Tanpa Augmentasi	SGD	0,001	0,2526	0,9297	0,5751	0,7917
12	Tanpa Augmentasi	SGD	0,0001	0,3177	0,8698	0,6062	0,7812
13	Tanpa Augmentasi	RMSProp	0,1	0,4429	0,8255	0,6434	0,7500
14	Tanpa Augmentasi	RMSProp	0,01	0,3490	0,8385	0,7621	0,7396
15	Tanpa Augmentasi	RMSProp	0,001	0,2406	0,9245	0,8055	0,7292


No	Jenis Data	Optimizer	Learning Rate	Training Loss	Training Accuracy	Validation Loss	Validation Accuracy
16	Tanpa Augmentasi	RMSProp	0,0001	0,3394	0,8802	0,6628	0,7917
17	Augmentasi	Adam	0,1	1,1249	0,1667	1,0992	0,3333
18	Augmentasi	Adam	0,01	0,5269	0,7797	0,4999	0,8271
19	Augmentasi	Adam	0,001	0,0661	0,9807	0,2835	0,8979
20	Augmentasi	Adam	0,0001	0,2510	0,9182	0,3792	0,8625
21	Augmentasi	RAdam	0,1	1,1165	0,3750	1,0066	0,4729
22	Augmentasi	RAdam	0,01	0,4750	0,7984	0,5073	0,8146
23	Augmentasi	RAdam	0,001	0,1142	0,9677	0,3401	0,8917
24	Augmentasi	RAdam	0,0001	0,3856	0,8646	0,4591	0,8229
25	Augmentasi	SGD	0,1	0,1109	0,9651	0,4808	0,8271
26	Augmentasi	SGD	0,01	0,2363	0,9099	0,3455	0,8771
27	Augmentasi	SGD	0,001	0,1703	0,9380	0,4534	0,8375
28	Augmentasi	SGD	0,0001	0,1669	0,9391	0,3378	0,8771
29	Augmentasi	RMSProp	0,1	0,0829	0,9682	0,4788	0,8458
30	Augmentasi	RMSProp	0,01	0,1045	0,9641	0,4677	0,8500
31	Augmentasi	RMSProp	0,001	0,2242	0,9052	0,6335	0,7833
32	Augmentasi	RMSProp	0,0001	0,1489	0,9474	0,3888	0,8813

Tabel 5. Hasil Training dengan Rasio Pembagian Data 90:10

No	Jenis Data	Optimizer	Learning Rate	Training Loss	Training Accuracy	Validation Loss	Validation Accuracy
1	Tanpa Augmentasi	Adam	0,1	1,1189	0,3333	1,1043	0,3333
2	Tanpa Augmentasi	Adam	0,01	0,4474	0,8333	0,5213	0,8148
3	Tanpa Augmentasi	Adam	0,001	0,1030	0,9794	0,4758	0,8333
4	Tanpa Augmentasi	Adam	0,0001	0,3627	0,8745	0,5137	0,8519
5	Tanpa Augmentasi	RAdam	0,1	0,8481	0,6255	0,8304	0,6481
6	Tanpa Augmentasi	RAdam	0,01	0,1676	0,9362	0,4229	0,8704
7	Tanpa Augmentasi	RAdam	0,001	0,1684	0,9712	0,4378	0,8519
8	Tanpa Augmentasi	RAdam	0,0001	0,5797	0,7695	0,6423	0,7963
9	Tanpa Augmentasi	SGD	0,1	0,2263	0,9321	0,4162	0,8333
10	Tanpa Augmentasi	SGD	0,01	0,2347	0,9218	0,4538	0,8333
11	Tanpa Augmentasi	SGD	0,001	0,1833	0,9444	0,4388	0,7963
12	Tanpa Augmentasi	SGD	0,0001	0,1821	0,9486	0,4855	0,8704
13	Tanpa Augmentasi	RMSProp	0,1	0,2481	0,9074	0,4891	0,7778
14	Tanpa Augmentasi	RMSProp	0,01	0,1746	0,9383	0,4662	0,8148
15	Tanpa Augmentasi	RMSProp	0,001	0,2590	0,9300	0,4908	0,8519
16	Tanpa Augmentasi	RMSProp	0,0001	0,2731	0,9012	0,8048	0,6481
17	Augmentasi	Adam	0,1	1,1436	0,3333	1,0997	0,3333
18	Augmentasi	Adam	0,01	0,5686	0,7494	0,5785	0,8148
19	Augmentasi	Adam	0,001	0,1190	0,9543	0,2909	0,8704
20	Augmentasi	Adam	0,0001	0,2414	0,9177	0,3587	0,8407
21	Augmentasi	RAdam	0,1	1,1523	0,2823	1,0759	0,3593


No	Jenis Data	Optimizer	Learning Rate	Training Loss	Training Accuracy	Validation Loss	Validation Accuracy
22	Augmentasi	RAdam	0,01	0,4646	0,8053	0,4843	0,7963
23	Augmentasi	RAdam	0,001	0,0701	0,9802	0,3248	0,8667
24	Augmentasi	RAdam	0,0001	0,3319	0,8844	0,4340	0,8148
25	Augmentasi	SGD	0,1	0,1072	0,9650	0,3623	0,8741
26	Augmentasi	SGD	0,01	0,1479	0,9469	0,3886	0,8630
27	Augmentasi	SGD	0,001	0,1219	0,9593	0,2914	0,8926
28	Augmentasi	SGD	0,0001	0,1028	0,9683	0,2750	0,8926
29	Augmentasi	RMSProp	0,1	0,0815	0,9704	0,3319	0,9037
30	Augmentasi	RMSProp	0,01	0,0674	0,9745	0,3885	0,8444
31	Augmentasi	RMSProp	0,001	0,0666	0,9778	0,3352	0,8963
32	Augmentasi	RMSProp	0,0001	0,0937	0,9642	0,2816	0,9148

Tabel 4 dan 5 di atas merupakan hasil evaluasi dari berbagai skenario pada penelitian yang dilakukan. Setiap baris dalam tabel mewakili satu skenario yang berbeda, dengan informasi tentang jenis data, optimizer yang digunakan, dan learning rate. Hasil evaluasi termasuk training loss, training accuracy, validation loss, dan validation accuracy dicatat untuk setiap skenario. Training loss dan validation loss mengukur sejauh mana prediksi model dari data pelatihan dan validasi mendekati label yang sebenarnya. Training accuracy dan validation accuracy mengukur sejauh mana model mampu mengklasifikasikan data pelatihan dan validasi dengan benar. Model yang akan diproses pada proses testing nantinya ialah model dengan validation accuracy di atas 85%. Berikut adalah beberapa grafik model loss dan model accuracy dari model dengan validation accuracy di atas 85%.




Gambar 4. Grafik Model Loss dan Akurasi Percobaan ke-12 Rasio Pembagian Data 90:10

Grafik pada gambar 4 menunjukkan model akurasi dan loss dari percobaan ke-12 dengan pembagian data 90:10 menggunakan kombinasi data citra tanpa augmentasi dan pengoptimal SGD dengan learning rate 0,0001. Dapat dilihat nilai akurasi validasi sebesar 0,8704 tidak berbeda jauh dengan nilai akurasi training sebesar 0,9486, hal ini membuktikan tidak terjadi overfitting pada model dengan skenario tersebut.



Gambar 5. Grafik Model Loss dan Akurasi Percobaan ke-26 Rasio Pembagian Data 90:10

Grafik pada gambar 5 menunjukkan model akurasi dan loss dari percobaan ke-26 dengan pembagian data 90:10 menggunakan kombinasi data citra augmentasi dan optimizer SGD dengan learning rate 0,01. Dapat dilihat nilai akurasi validasi sebesar 0,863 tidak berbeda jauh dengan nilai akurasi training sebesar 0,9469, hal ini membuktikan tidak terjadi overfitting pada model dengan skenario tersebut.



Gambar 6. Grafik Model Loss dan Akurasi Percobaan ke-29 Rasio Pembagian Data 90:10

Grafik pada gambar 6 menunjukkan model akurasi dan loss dari percobaan ke-29 dengan pembagian data 90:10 menggunakan kombinasi data citra augmentasi dan optimizer RMSprop dengan learning rate 0,1. Dapat dilihat nilai akurasi validasi sebesar 0,9037 tidak berbeda jauh dengan nilai akurasi training sebesar 0,9704, hal ini membuktikan tidak terjadi overfitting pada model dengan skenario tersebut.

3.2 Proses Testing


Setelah dilakukan proses training dengan data validasi, model akan diuji menggunakan data uji yang telah dibagi sebelumnya. Model yang akan digunakan pada tahap pengujian ini adalah model yang memiliki validation accuracy di atas 85% berdasarkan tabel 4 dan tabel 5. Ukuran batch yang digunakan pada proses ini adalah 64. Performa model diukur menggunakan confusion matrix dengan melihat nilai akurasi, presisi, recall, f1 score, dan presisi dari kelas sapi. Tabel 6 memperlihatkan hasil pengujian.

Tabel 6. Hasil Testing

No	Pembagian Data	Jenis Data	Optimizer	Learning Rate	Akurasi (%)	Presisi (%)	Recall (%)	F1 score (%)	Presisi Kelas Sapi (%)
1	80:20	Augmentasi	Adam	0,001	90,17	90,25	90,17	90,16	88,61
2	80:20	Augmentasi	Adam	0,0001	87,33	87,34	87,33	87,31	87,96
3	80:20	Augmentasi	RAdam	0,001	88,50	88,65	88,50	88,53	85,31
4	80:20	Augmentasi	SGD	0,01	87,67	88,03	87,67	87,60	84,73
5	80:20	Augmentasi	SGD	0,0001	89,33	89,62	89,33	89,29	87,62
6	80:20	Augmentasi	RMSProp	0,0001	88,33	88,70	88,33	88,32	86,70
7	90:10	Tanpa Augmentasi	Adam	0,0001	86,67	88,10	86,67	86,25	93,33
8	90:10	Tanpa Augmentasi	RAdam	0,01	86,67	86,70	86,67	86,67	88,24
9	90:10	Tanpa Augmentasi	RAdam	0,001	88,33	88,27	88,33	88,15	88,89
10	90:10	Tanpa Augmentasi	SGD	0,0001	91,67	91,79	91,67	91,57	94,44
11	90:10	Tanpa Augmentasi	RMSProp	0,001	88,33	88,83	88,33	88,10	93,75
12	90:10	Augmentasi	Adam	0,001	89,67	90,09	89,67	89,67	86,92
13	90:10	Augmentasi	RAdam	0,001	90,00	90,83	90,00	90,11	81,20
14	90:10	Augmentasi	SGD	0,1	88,00	88,85	88,00	87,95	94,05
15	90:10	Augmentasi	SGD	0,01	86,00	88,18	86,00	85,96	96,05
16	90:10	Augmentasi	SGD	0,001	89,00	89,65	89,00	88,98	83,19
17	90:10	Augmentasi	SGD	0,0001	90,67	90,87	90,67	90,67	91,00
18	90:10	Augmentasi	RMSProp	0,1	92,00	92,37	92,00	92,01	87,27


No	Pembagian Data	Jenis Data	Optimizer	Learning Rate	Akurasi (%)	Presisi (%)	Recall (%)	F1 score (%)	Presisi Kelas Sapi (%)
19	90:10	Augmentasi	RMSProp	0,001	90,33	90,56	90,33	90,32	87,04
20	90:10	Augmentasi	RMSProp	0,0001	91,00	91,09	91,00	90,98	90,20

Tabel 6 di atas merupakan hasil evaluasi dari berbagai skenario pada penelitian yang dilakukan. Setiap baris dalam tabel mewakili satu skenario yang berbeda, dengan variasi pembagian data latih dan uji, jenis augmentasi data, optimizer yang digunakan, dan learning rate. Hasil evaluasi termasuk akurasi, presisi, recall, dan f1 score dicatat untuk setiap skenario. Nilai presisi kelas sapi juga dicatat untuk menunjukkan kemampuan model dalam mengklasifikasikan data sapi dengan tepat. Berdasarkan tabel 6, percobaan dengan rasio pembagian data 90:10 memiliki performa model yang lebih baik dibandingkan dengan percobaan yang menggunakan rasio pembagian data 80:20. Akurasi dan performa terbaik menggunakan tipe data tanpa augmentasi ditemukan pada percobaan ke-10, sedangkan akurasi tertinggi menggunakan tipe data augmentasi ditemukan pada percobaan ke-18. Akan tetapi apabila dilihat dari kemampuan model untuk mengklasifikasikan citra, percobaan ke-15 mencapai performa terbaik karena memiliki nilai presisi kelas sapi tertinggi.




Gambar 7. Confusion Matrix Percobaan ke-10

Hasil percobaan ke-10 dapat dilihat pada gambar 7 yang menunjukkan confusion matrix dengan akurasi 91,67%, presisi 91,79%, recall 91,67%, dan f1 score 91,57%. Untuk performa model dalam mengklasifikasikan citra, skenario ini adalah yang terbaik di antara skenario tanpa augmentasi data karena hanya 1 citra babi dan tidak ada citra oplosan yang terklasifikasi sapi dari 20 data uji, dan memiliki nilai presisi kelas sapi sebesar 94,44%.



Gambar 8. Confusion Matrix Percobaan ke-15

Hasil percobaan ke-15 dapat dilihat pada gambar 8 yang menunjukkan confusion matrix dengan akurasi 86,00%, presisi 88,18%, recall 86,00%, dan f1 score 85,96%. Akan tetapi model ini merupakan model yang terbaik karena hanya terdapat 1 citra oplosan dan 2 citra babi yang terklasifikasi sebagai sapi dari total 100 data uji, dan berhasil mendapatkan nilai presisi kelas sapi tertinggi yaitu sebesar 96,05%.



Gambar 9. Confusion Matrix Percobaan ke-18

Hasil percobaan ke-18 dapat dilihat pada gambar 9 yang menunjukkan confusion matrix dengan akurasi 92,00%, presisi 92,37%, recall 92,00%, dan f1 score 92,01%. Apabila dilihat dari performa model dalam mengklasifikasikan citra, skenario ini kurang baik karena terdapat 8 citra babi dan 6 citra oplosan yang terklasifikasi sapi dari 100 data uji, sehingga meraih nilai presisi kelas sapi hanya sebesar 87,27%.

4. KESIMPULAN

Pada penelitian ini dilakukan pengklasifikasian citra daging babi, sapi, dan campuran menggunakan arsitektur CNN EfficientNet-B6 dengan memanfaatkan data citra tanpa hasil augmentasi dan augmentasi. Data citra telah dibagi antara data latih dan data uji dengan rasio perbandingan 80:20 dan 90:10. Performa model diuji menggunakan confusion matrix dan dibandingkan berdasarkan akurasi, presisi, recall, f1 score, dan juga kemampuan model dalam mengklasifikasikan citra daging babi dan daging oplosan agar tidak terklasifikasikan sebagai daging sapi pada kedua jenis data citra. Hasil penelitian menunjukkan bahwa penggunaan augmentasi data dengan skenario rasio pembagian data 90:10, optimizer RMSprop, dan learning rate 0,1 memiliki akurasi tertinggi yaitu dengan akurasi 92,00%, presisi 92,37%, recall 92,00%, f1 score 92,01%, 8 citra babi dan 6 citra oplosan yang terklasifikasi sapi dari 100 data uji, dan menghasilkan nilai presisi kelas sapi sebesar 87,27%. Sedangkan penggunaan data citra tanpa augmentasi dengan skenario rasio pembagian data 90:10, optimizer SGD, dan learning rate 0,0001 menghasilkan akurasi yang sedikit lebih rendah yaitu dengan akurasi 91,67%, presisi 91,79%, recall 91,67%, f1 score 91,57%, 1 citra babi dan tidak ada citra oplosan yang terklasifikasi sapi dari 20 data uji, dan mendapatkan nilai presisi kelas sapi sebesar 94,44%. Namun, apabila melihat dari kemampuan model dalam mengklasifikasikan citra, terlihat bahwa skenario dengan penggunaan augmentasi data, rasio pembagian data 90:10, optimizer SGD, dan learning rate 0,01 menunjukkan kinerja terbaik. Pada skenario ini, hanya terdapat 1 citra oplosan dan 2 citra babi yang terklasifikasi sebagai sapi dari total 100 data uji, dan mencapai nilai presisi tertinggi untuk kelas sapi sebesar 96,05%, sedangkan untuk akurasinya hanya sebesar 86,00%, presisi 88,18%, recall 86,00% dan f1 score 85,96%. Nilai akurasi yang didapatkan model ini memang lebih rendah daripada model dengan akurasi tertinggi, tetapi karena tujuan utama tema penelitian ini adalah untuk menghindari daging sapi dan oplosan terklasifikasi sebagai sapi, maka model ini merupakan model yang terbaik. Penggunaan augmentasi pada data citra juga dapat meningkatkan kinerja karena dapat menambah jumlah data dengan membuat data baru dari data yang sudah ada. Disarankan untuk menggunakan lebih banyak data gambar berkualitas tinggi untuk penelitian berikutnya dan menggunakan teknik k-fold cross validation.

REFERENCES

- [1] L. Milana and W. Whydiantoro, "Analisis Kelayakan Investasi Dendeng Daging Sapi (Studi Kasus di PD 'Carole Jaya')," *Jurnal Riset Bisnis dan Investasi*, vol. 4, no. 2, p. 10, 2018, doi: 10.35697/jrbi.v4i2.1182.
- [2] T. Septiani, "Detection of Porcine DNA in Processed Beef Products Using Real Time – Polymerase Chain Reaction," *Indonesian Journal of Halal Research*, vol. 1, no. 2, pp. 31-34, 2019, doi: 10.15575/ijhar.v1i2.5601.

- [3] S. Maiyena and E. R. Mawarnis, “Kajian Analisis Konsumsi Daging Sapi dan Daging Babi Ditinjau dari Kesehatan,” *Jurnal Pendidikan Tambusai*, vol. 6, no. 1, pp. 3131–3136, 2022, Accessed: Dec. 06, 2022. [Online]. Available: <https://jptam.org/index.php/jptam/article/view/3359>
- [4] S. Agustin, “Bahaya Mengonsumsi Daging Babi bagi Kesehatan,” Dec. 16, 2021.
- [5] Agregasi Harian Jogja, “Nekat Oplos Daging Sapi dan Babi, 2 Pedagang di Gunungkidul Ditangkap,” Jan. 23, 2019. <https://news.okezone.com/read/2019/01/23/510/2008401/nekato-ops-daging-sapi-dan-babi-2-pedagang-di-gunungkidul-ditangkap>
- [6] Liputan6.com, “Terbongkarnya Modus Penjualan Daging Babi Berkedok Daging Sapi di Lampung,” Apr. 21, 2021.
- [7] S. A. Aisah, “IDENTIFIKASI PERBEDAAN DAGING SAPI DENGAN DAGING BABI BERDASARKAN CIRI WARNA DAN TEKSTUR MENGGUNAKAN METODE SUPPORT VECTOR MACHINE (SVM),” 2018.
- [8] U. Sudibyo, D. P. Kusumaningrum, E. H. Rachmawanto, and C. A. Sari, “Optimasi Algoritma Learning Vector Quantization (Lvq) Dalam Pengklasifikasian Citra Daging Sapi Dan Daging Babi Berbasis Gcm Dan Hsv,” *Simetris: Jurnal Teknik Mesin, Elektro dan Ilmu Komputer*, vol. 9, no. 1, pp. 1–10, 2018, doi: 10.24176/simet.v9i1.1943.
- [9] T. Y. Purnomo, F. Yanto, F. Insani, S. Ramadhani, and Jasril, “Penerapan Algoritma Random Forest Pada Klasifikasi Daging,” *Jurnal Intra Tech*, vol. 6, no. 1, 2022.
- [10] M. F. Naufal, “ANALISIS PERBANDINGAN ALGORITMA SVM, KNN, DAN CNN UNTUK KLASIFIKASI CITRA CUACA,” *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, vol. 8, 2021, doi: 10.25126/jtiik.202184553.
- [11] A. Peryanto, A. Yudhana, and R. Umar, “Convolutional Neural Network and Support Vector Machine in Classification of Flower Images,” *Khazanah Informatika : Jurnal Ilmu Komputer dan Informatika*, vol. 8, no. 1, pp. 1–7, 2022, doi: 10.23917/khif.v8i1.15531.
- [12] S. Wu, J. Wang, Y. Ping, and X. Zhang, “Research on Individual Recognition and Matching of Whale and Dolphin Based on EfficientNet Model,” 2022 3rd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE), pp. 635–638, 2022, doi: 10.1109/ICBAIE56435.2022.9985881.
- [13] Z. Maqsood and M. K. Gupta, “Automatic Detection of Diabetic Retinopathy on the Edge,” in *Cyber Security, Privacy and Networking*, D. P. Agrawal, N. Nedjah, B. B. Gupta, and G. Martinez Perez, Eds., Singapore: Springer Nature Singapore, 2022, pp. 129–139.
- [14] Adhi Setiawan, “Augmentasi Data Pada Computer Vision,” Aug. 27, 2021. <https://medium.com/data-folks-indonesia/augmentasi-data-pada-computer-vision-45c5ebe10e8f> (accessed Apr. 17, 2023).
- [15] Y. Jeong, J. Kim, D. Kim, J. Kim, and K. Lee, “Methods for Improving Deep Learning-Based Cardiac Auscultation Accuracy: Data Augmentation and Data Generalization,” *Applied Sciences*, vol. 11, no. 10, 2021, doi: 10.3390/app11104544.
- [16] E. Cano, J. Mendoza-Avilés, M. Areiza, N. Guerra, J. Mendoza-Valdés, and C. Rovetto, “Multi skin lesions classification using fine-tuning and data-augmentation applying NASNet,” *PeerJ Comput Sci*, vol. 7, p. e371, Apr. 2021, doi: 10.7717/peerj-cs.371.
- [17] A. Rafay and W. Hussain, “EfficientSkinDis: An EfficientNet-based classification model for a large manually curated dataset of 31 skin diseases,” *Biomed Signal Process Control*, vol. 85, p. 104869, Aug. 2023, doi: 10.1016/J.BSPC.2023.104869.
- [18] F. Barrientos-Espillo, E. Gascó, C. I. López-González, M. J. Gómez-Silva, and G. Pajares, “Semantic segmentation based on Deep learning for the detection of Cyanobacterial Harmful Algal Blooms (CyanoHABs) using synthetic images,” *Appl Soft Comput*, vol. 141, p. 110315, Jul. 2023, doi: 10.1016/J.ASOC.2023.110315.
- [19] I. A. Lozhskin, M. E. Dunaev, K. S. Zaytsev, and A. A. Garmash, “Augmentation of Image Sets for Training Neural Networks in Solving Semantic Segmentation Problems,” *International Journal of Open Information Technologies*, vol. 11, no. 1, Jan. 2023.
- [20] H. Vega-Huerta et al., “Convolutional Neural Networks on Assembling Classification Models to Detect Melanoma Skin Cancer,” *International Journal of Online and Biomedical Engineering (iJOE)*, vol. 18, no. 14, pp. 59–76, Nov. 2022, doi: 10.3991/ijoe.v18i14.34435.
- [21] A. H. Artya, “Implementasi Convolutional Neural Network Untuk Klasifikasi Daging Menggunakan Fitur Ekstraksi Tekstur dan Arsitektur AlexNet,” *IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI DAGING MENGGUNAKAN FITUR EKSTRAKSI TEKSTUR DAN ARSITEKTUR ALEXNET*, vol. 9, no. 3, pp. 635–643, 2022.
- [22] Y. P. Irawan and I. Susilawati, “Klasifikasi Jenis Aglaonema Berdasarkan Citra Daun Menggunakan Convolutional Neural Network (CNN),” *Journal Of Information System And Artificial Intelligence*, vol. 2, no. 2, pp. 64–70, 2022.
- [23] N. Rochmawati, H. B. Hidayati, Y. Yamasari, H. P. A. Tjahyaningtjas, W. Yustanti, and A. Prihanto, “Analisa Learning Rate dan Batch Size pada Klasifikasi Covid Menggunakan Deep Learning dengan Optimizer Adam,” *JIEET (Journal of Information Engineering and Educational Technology)*, vol. 5, no. 2, pp. 44–48, Dec. 2021.