



Klasifikasi Citra Daging Sapi dan Babi Menggunakan CNN Alexnet dan Augmentasi Data

Ikhwanul Akhmad DLY, Jasril*, Suwanto Sanjaya, Lestari Handayani, Febi Yanto

Fakultas Sains dan Teknologi, Program Studi Teknik Informatika, Universitas Islam Negeri Sultan Syarif Kasim Riau, Pekanbaru

Panam, Jl. HR. Soebrantas No.Km. 15, RW.15, Simpang Baru, Kota Pekanbaru, Riau, Indonesia

Email: ¹11950110043@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: 21/06/2023; Accepted: 22/07/2023; Published: 26/07/2023

Abstrak—Konsumsi daging di Indonesia didominasi oleh sapi, kerbau, dan ayam. Namun, beberapa pedagang nakal mencampur daging sapi dengan daging babi sehingga sulit dibedakan oleh masyarakat awam. Beberapa penelitian telah menggunakan metode Convolutional Neural Network (CNN) untuk mengklasifikasikan citra, namun kekurangan data menjadi tantangan. Oleh karena itu, penelitian ini menerapkan teknik augmentasi data pada model CNN Alexnet untuk mengklasifikasikan daging sapi, babi, dan daging oplosan. Penelitian ini menggunakan dua rasio pembagian data yang berbeda, yaitu 90:10 dan 80:20, dengan total 600 data non-augmentasi dan 3000 data augmentasi yang dibagi menjadi tiga kelas. Beberapa hyperparameter diuji untuk mengoptimalkan kinerja model seperti optimizer Adaptive Moment Estimation (Adam), Stochastic Gradient Descent (SGD) dan Propagasi Root Mean Square (RMSprop) serta learning rate 0.1, 0.01, 0.001 dan 0.0001. Hasil menunjukkan bahwa penggunaan data citra augmentasi dengan optimizer Adam dan learning rate 0,001 memberikan accuracy tertinggi sebesar 85,00%. Sementara itu, penggunaan data citra non-augmentasi dengan skenario optimizer RMSprop dan learning rate 0,0001 menghasilkan performa yang sedikit lebih rendah, yaitu mendapatkan accuracy 80,00%. Keduanya menggunakan perbandingan data 80:20. Teknik augmentasi data berhasil meningkatkan kinerja model deep learning dengan menciptakan data baru dari data yang ada.

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

Abstract—The consumption of meat in Indonesia is dominated by beef, buffalo, and chicken. However, some unscrupulous traders mix beef with pork, making it difficult to differentiate for the general public. Several studies have used Convolutional Neural Network (CNN) methods to classify images, but data scarcity remains a challenge. Therefore, this research applies data augmentation techniques to the CNN Alexnet model to classify beef, pork, and adulterated meat. The study employs two different data division ratios, namely 90:10 and 80:20, with a total of 600 non-augmented data and 3000 augmented data divided into three classes. Several hyperparameters were tested to optimize the model's performance, such as the Adaptive Moment Estimation (Adam) optimizer, Stochastic Gradient Descent (SGD), and Root Mean Square Propagation (RMSprop), as well as learning rates of 0.1, 0.01, 0.001, and 0.0001. The results showed that using augmented image data with the Adam optimizer and a learning rate of 0.001 yielded the highest accuracy of 85.00%. Meanwhile, using non-augmented image data with the RMSprop optimizer and a learning rate of 0.0001 resulted in slightly lower performance, with an accuracy of 80.00%. Both scenarios used an 80:20 data ratio. The data augmentation technique successfully improved the performance of the deep learning model by generating new data from the existing data

Keywords: Deep Learning; Classification; CNN; Alexnet; Augmentation

1. PENDAHULUAN

Pola konsumsi daging di masyarakat Indonesia didominasi oleh daging sapi, kerbau, dan ayam. Pada tahun 2021, konsumsi daging sapi dan kerbau di Indonesia, yang berpenduduk sekitar 272 juta orang, diperkirakan mencapai sekitar 696,96 ribu ton [1]. Peluang tersebut dimanfaatkan oleh beberapa pedagang nakal untuk memalsukan daging sapi dengan daging babi, seperti kasus penjualan daging babi yang disamarkan sebagai daging sapi yang terungkap di Lampung [2]. Contoh lainnya terjadi di Bandung, di mana 63 ton daging babi dicampur dengan boraks dan dijual dalam kemasan yang menyerupai daging sapi [3].

Kasus seperti ini tentu merugikan masyarakat Indonesia khususnya umat muslim. Allah Swt. berfirman, "Katakanlah: "Sesungguhnya aku tidak mendapati dalam wahyu yang diwahyukan kepadaku, sesuatu yang diharamkan bagi orang yang hendak memakannya, selain dari binatang yang sudah mati, atau darah yang mengalir, atau daging babi – karena sesungguhnya itu kotor – atau binatang yang disembelih atas nama selain Allah." Namun barangsiapa yang terpaksa karena kelaparan tanpa sengaja melakukan pelanggaran, tidak sedang mencari dosa, maka sesungguhnya Allah Maha Pengampun, Maha Penyayang." (QS. Al-An'am: 145).

Untuk melihat perbedaan antara daging sapi dan daging babi yang sudah dimanipulasi, sangat sulit dilakukan secara langsung oleh masyarakat awam. Oleh karena itu, teknologi dibutuhkan untuk mengenali perbedaan kedua jenis daging tersebut. Salah satu teknologi yang dapat digunakan adalah pengolahan citra. Beberapa penelitian terkait telah dilakukan yang memanfaatkan teknologi pengolahan citra untuk mengidentifikasi perbedaan daging sapi dan daging babi. Penelitian pertama menggunakan Implementasi Segmentasi Spatial Fuzzy C-Means dan machine learning berhasil mendapatkan akurasi tertinggi 62% untuk klasifikasi daging sapi dan daging babi serta 38% untuk klasifikasi tiga kelas, yaitu daging sapi, daging babi, serta daging oplosan [4].

Penelitian selanjutnya yaitu melakukan Optimasi pada Algoritma Learning Vector Quantization (LVQ) berbasis GLCM dan HSV dengan implementasi matlab, dan berhasil mencapai akurasi terbesar 76,25% [5]. Penelitian lain menggunakan Spatial Fuzzy C-Means (SFCM) dan Learning Vector Quantization 3 (LVQ3) berhasil mencapai akurasi tertinggi 95% [6]. Ada juga penelitian yang menggunakan kombinasi ekstraksi fitur berdasarkan tekstur dan warna menggunakan fitur HSV dan LOOP dan berhasil mencapai akurasi 100% untuk semua kategori pengukuran performa yaitu accuracy, recall, dan precision [7]. Serta penelitian menggunakan Neural Network dan fitur tekstur berhasil mencapai akurasi sebesar 90% dengan menggunakan 400 data gambar [8].

Pada era teknologi yang semakin canggih, pengolahan citra dapat dilakukan menggunakan metode deep learning. Beberapa studi sebelumnya telah melakukan perbandingan antara teknik machine learning dan deep learning, seperti pada penelitian Analisis Perbandingan Metode Deep Learning dan Non-Deep Learning menggunakan citra Chest X-ray untuk deteksi Covid-19. Penelitian ini menggunakan metode non-deep learning KNN dan SVM, serta metode deep learning CNN. Hasilnya menunjukkan bahwa CNN mendapatkan performa yang lebih baik dengan nilai akurasi sebesar 0,9591, sedangkan KNN dan SVM hanya mencapai 0,921 dan 0,93 [9]. Penelitian Analisis Perbandingan antara Algoritma Convolutional Neural Network dan Algoritma Multi-Layer Perception Neural, terdapat hasil yang menunjukkan bahwa CNN memiliki performa yang lebih baik dengan nilai precision, recall, f1-score, dan accuracy mencapai 0,98 dan lebih efektif dalam melakukan klasifikasi [10]. Selanjutnya, pada penelitian Analisis Perbandingan Algoritma SVM dan CNN dalam kasus Klasifikasi Buah, SVM mencapai akurasi sebesar 93,09% dan CNN mencapai akurasi sebesar 96,87% [11]. Dari hasil penelitian tersebut, terbukti bahwa menggunakan deep learning dapat menghasilkan kinerja yang lebih baik dibandingkan machine learning.


Beberapa penelitian klasifikasi daging sapi dan babi yang telah dilakukan menggunakan CNN diantaranya penelitian yang menggunakan CNN untuk klasifikasi tumor otak dengan resolusi super dan arsitektur ResNet50 yang mendapatkan akurasi sebesar 98.14% [12]. Kemudian, penelitian klasifikasi citra daging sapi dan daging babi menggunakan ekstraksi ciri dan CNN yang mendapatkan akurasi tertinggi sebesar 95.17% dengan precision 92.72%, recall 95.5%, dan f1 score 94.09% [13]. Selanjutnya, penelitian menggunakan algoritma CNN arsitektur ResNet-50 untuk mengklasifikasikan citra daging sapi dan babi. Dalam penelitian ini, didapatkan hasil akurasi tertinggi sebesar 97,83%, dengan precision, recall, dan f1 score masing-masing sebesar 97% [14]. Terakhir, penelitian klasifikasi daging menggunakan fitur ekstraksi tekstur dan menggunakan arsitektur Alexnet. Penelitian ini berhasil mendapatkan akurasi tertinggi sebesar 85,3%, precision 87%, recall 76%, dan f1-score 81% [15].

Penelitian ini melanjutkan [15] karena hasil penggunaan ekstraksi tekstur masih belum memberikan peningkatan akurasi. Pada penelitian ini digunakan teknik augmentasi data untuk memperbaiki performa dan meningkatkan akurasi penelitian [16]. Berdasarkan beberapa penelitian sebelumnya, teknik augmentasi data dapat meningkatkan performa klasifikasi pada arsitektur Alexnet, seperti pada klasifikasi gambar tumor otak MRI menggunakan model augmentasi data Lipschitz-based dan Alexnet yang memberikan hasil superior [17]. Penelitian lain yang menggunakan transfer learning dan augmentasi data dengan Alexnet pada klasifikasi lesi kulit juga mendapatkan peningkatan performa akurasi yang lebih tinggi [18]. Penelitian terakhir yang menggunakan teknik augmentasi data pada dataset land cover juga menunjukkan peningkatan performa klasifikasi menggunakan arsitektur Alexnet dan VGG-16 [19].

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Agar penelitian berjalan terstruktur, perlu diikuti alur dari setiap proses dan tahapannya. Metode penelitian berperan sebagai panduan dalam melakukan penelitian, sehingga setiap tahapan dapat dilakukan dengan terstruktur dari awal hingga akhir. Ilustrasi tahapan penelitian ini dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian


2.2 Pengumpulan Data

Langkah berikutnya setelah menetapkan permasalahan dalam penelitian adalah mengumpulkan data. Untuk tujuan itu, penelitian ini dilakukan melalui observasi langsung di sebuah pasar tradisional di Pekanbaru. Data dikumpulkan dengan mengambil gambar menggunakan kamera belakang ponsel Xiaomi Redmi Note 10s dan


POCO X3 GT dengan resolusi 64MP, dari jarak 10-15 cm dengan latar belakang putih. Sebanyak 600 data berhasil terkumpul dan dibagi menjadi tiga kelas, yakni daging sapi, daging babi, dan daging oplosan.

2.3 Preprocessing Data

Langkah berikutnya setelah selesai mengumpulkan data adalah melakukan preprocessing data. Preprocessing merupakan tahap awal pada pengolahan data citra yang bertujuan untuk mempersiapkan data agar dapat diolah oleh model. Pada penelitian ini, preprocessing yang dilakukan adalah crop dan resize. Crop dilakukan untuk memotong gambar agar hanya memuat bagian daging sapi, daging babi dan daging oplosan saja. Sedangkan resize dilakukan untuk mengubah ukuran gambar menjadi 224 x 224 piksel agar dapat diproses oleh model deep learning yang akan digunakan dalam penelitian. Gambar 2 menunjukkan citra daging yang belum dilakukan preprocessing, sedangkan Gambar 3 menunjukkan citra yang telah dilakukan preprocessing.




Gambar 2. Data Citra Sebelum di Preprocessing



Gambar 3. Data Citra Setelah di Processing

2.4 Augmentasi Data

Setelah tahap preprocessing selesai, tahap selanjutnya adalah augmentasi. Tujuan dari augmentasi adalah untuk memperbesar variasi data dan memperkuat generalisasi model deep learning [20]. Pada penelitian ini, augmentasi yang dilakukan meliputi rotasi acak hingga 180 derajat, penggeseran dengan batas 10%, memperbesar atau memperkecil gambar secara acak hingga 10%, membalik gambar secara horizontal dan vertikal serta menggunakan nilai piksel terdekat untuk mengisi piksel yang kosong [21]. Gambar 4 menunjukkan hasil dari proses augmentasi citra yang telah dilakukan. Setelah melalui proses augmentasi, total data untuk setiap kelas adalah 1000 data.



Gambar 4. Augmentasi Citra Daging Sapi

2.5 Pembagian Data

Proses selanjutnya adalah melakukan pembagian data untuk menyiapkan data yang akan digunakan dalam pelatihan model deep learning. Pembagian data dilakukan dengan menggunakan dua rasio berbeda, yaitu 90:10 dan 80:20, pada total 600 data non-augmentasi dan 3000 data augmentasi yang dibagi menjadi tiga kelas. Pada pembagian 90:10, masing-masing kelas terdiri dari 162 data latih, 18 data validasi, dan 20 data uji untuk data non-augmentasi, serta 810 data latih, 90 data validasi, dan 100 data uji untuk data augmentasi

Tabel 1. Pembagian Data dengan Rasio 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

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

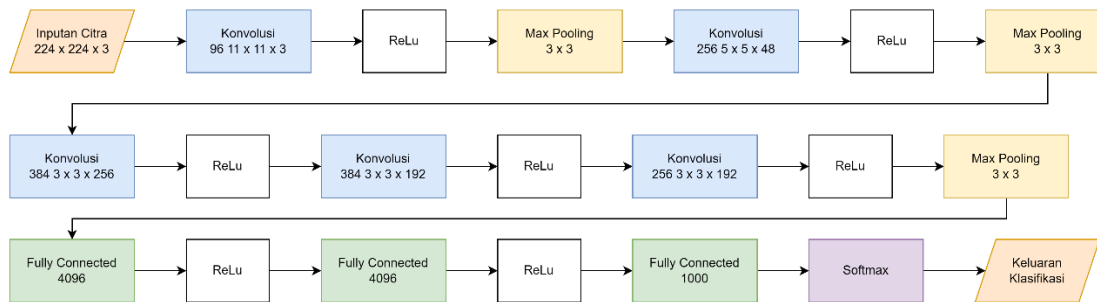
Sedangkan pada pembagian 80:20, masing-masing kelas terdiri dari 128 data latih, 32 data validasi, dan 40 data uji untuk data non-augmentasi, serta 640 data latih, 160 data validasi, dan 200 data uji untuk data augmentasi.

Tabel 2. Pembagian Data dengan Rasio 80:20

Kelas	Data Non-Augmentasi			Data Augmentasi		
	Latih (90%)		Uji (10%)	Latih 90%		Uji (10%)
	Latih (90%)	Validasi (10%)		Latih (90%)	Validasi (10%)	
Daging Sapi	128	32	40	640	160	200
Daging Babi	128	32	40	640	160	200
Daging Oplosan	128	32	40	640	160	200

2.6 Klasifikasi Menggunakan Deep Learning

Untuk melakukan pelatihan model deep learning pada data citra yang sudah dibagi, digunakanlah Convolutional Neural Network (CNN). Arsitektur yang digunakan pada penelitian ini adalah AlexNet, yang terdiri dari 5 layer konvolusi dan 3 layer fully connected [22].



Gambar 5. Arsitektur Alexnet

Selanjutnya, dilakukan percobaan dengan menggunakan beberapa hyperparameter seperti optimizer, dan learning rate untuk mengoptimalkan performa model deep learning. Optimizer yang digunakan untuk mengoptimalkan parameter model adalah Adaptive Moment Estimation (Adam), Stochastic Gradient Descent (SGD) dan Root Mean Square Propagation (RMSprop), sedangkan learning rate yang digunakan untuk menentukan seberapa besar model dapat menyesuaikan diri dengan data adalah 0.1, 0.01, 0.001 dan 0.0001.

2.7 Evaluasi

Setelah hasil dari beberapa pengujian didapatkan, tahap selanjutnya yang akan dilakukan adalah evaluasi. Evaluasi dilakukan guna untuk mengukur performa dari model yang dihasilkan. Penelitian ini menggunakan metode pengukuran performa yaitu matriks klasifikasi confusion matrix. Confusion matrix adalah tabel yang menjelaskan kinerja suatu model pembelajaran mesin dengan menampilkan jumlah prediksi yang benar dan salah pada set data yang telah diberikan.

Confusion matrix memiliki struktur yang terdiri dari empat bagian, yaitu True Positives (TP) yang merupakan jumlah instance yang benar-benar termasuk ke dalam kelas A dan diprediksi oleh model sebagai kelas A, False Positives (FP) yang merupakan jumlah instance yang benar-benar termasuk ke dalam kelas B, namun diprediksi oleh model sebagai kelas A, False Negatives (FN) yang merupakan jumlah instance yang benar-benar termasuk ke dalam kelas A, namun diprediksi oleh model sebagai kelas B, dan True Negatives (TN) yang merupakan jumlah instance yang benar-benar termasuk ke dalam kelas B dan diprediksi oleh model sebagai kelas B. Berikut beberapa rumus yang digunakan dalam perhitungan confusion matrix:

a. Accuracy

Accuracy adalah persentase prediksi yang benar yang dilakukan oleh model.

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

b. Recall

Recall adalah persentase instance kelas A yang benar-benar terdeteksi oleh model.

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

c. Precision

Precision adalah persentase instance yang diprediksi sebagai kelas A yang benar-benar merupakan kelas A.

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

d. F1-Score

F1-Score adalah rata-rata dari precision dan recall.

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

3. HASIL DAN PEMBAHASAN

3.1 Proses Pelatihan Model


Proses percobaan menggunakan Google Colab sebagai platform utama dengan menggunakan bahasa pemrograman python. Selain itu, juga menggunakan berbagai library seperti pyTorch, numPy, matplotlib, dan lain sebagainya untuk mendukung proses pelatihan dan pengolahan data. Pelatihan model dilakukan sebanyak 48 percobaan. Berikut tabel percobaan hasil pelatihan penelitian ini.

Tabel 3. Hasil Pelatihan Menggunakan Data Non-Augmentasi dan Augmentasi

No.	Pembagian Data	Jenis Data	Optimizer	Learning Rate	Training Accuracy (%)	Validation Accuracy (%)
1	90:10	Non-Augmentasi	Adam	0.1	74.90	75.93
2	90:10	Non-Augmentasi	Adam	0.01	71.19	79.63
3	90:10	Non-Augmentasi	Adam	0.001	76.13	87.04
4	90:10	Non-Augmentasi	Adam	0.0001	72.02	83.33
5	90:10	Non-Augmentasi	SGD	0.1	73.66	79.63
6	90:10	Non-Augmentasi	SGD	0.01	70.78	72.22
7	90:10	Non-Augmentasi	SGD	0.001	76.95	87.04
8	90:10	Non-Augmentasi	SGD	0.0001	60.70	68.52
9	90:10	Non-Augmentasi	RMSprop	0.1	73.05	61.11
10	90:10	Non-Augmentasi	RMSprop	0.01	65.64	57.41
11	90:10	Non-Augmentasi	RMSprop	0.001	80.25	85.19
12	90:10	Non-Augmentasi	RMSprop	0.0001	75.51	81.48
13	90:10	Augmentasi	Adam	0.1	70.12	72.59
14	90:10	Augmentasi	Adam	0.01	72.63	76.30
15	90:10	Augmentasi	Adam	0.001	77.86	84.81
16	90:10	Augmentasi	Adam	0.0001	78.52	85.19
17	90:10	Augmentasi	SGD	0.1	69.05	82.22
18	90:10	Augmentasi	SGD	0.01	72.43	65.19
19	90:10	Augmentasi	SGD	0.001	76.09	82.96
20	90:10	Augmentasi	SGD	0.0001	69.84	77.04
21	90:10	Augmentasi	RMSprop	0.1	72.88	76.30
22	90:10	Augmentasi	RMSprop	0.01	68.40	82.96
23	90:10	Augmentasi	RMSprop	0.001	76.46	84.44

No.	Pembagian Data	Jenis Data	Optimizer	Learning Rate	Training Accuracy (%)	Validation Accuracy (%)
24	90:10	Augmentasi	RMSprop	0.0001	76.09	84.07
25	80:20	Non-Augmentasi	Adam	0.1	71.35	75.00
26	80:20	Non-Augmentasi	Adam	0.01	80.73	75.00
27	80:20	Non-Augmentasi	Adam	0.001	81.51	75.00
28	80:20	Non-Augmentasi	Adam	0.0001	74.48	79.17
29	80:20	Non-Augmentasi	SGD	0.1	72.92	75.00
30	80:20	Non-Augmentasi	SGD	0.01	70.05	67.71
31	80:20	Non-Augmentasi	SGD	0.001	74.74	79.17
32	80:20	Non-Augmentasi	SGD	0.0001	69.53	81.25
33	80:20	Non-Augmentasi	RMSprop	0.1	73.96	73.96
34	80:20	Non-Augmentasi	RMSprop	0.01	75.52	67.71
35	80:20	Non-Augmentasi	RMSprop	0.001	78.65	72.92
36	80:20	Non-Augmentasi	RMSprop	0.0001	78.91	84.38
37	80:20	Augmentasi	Adam	0.1	68.91	75.21
38	80:20	Augmentasi	Adam	0.01	72.71	76.46
39	80:20	Augmentasi	Adam	0.001	80.52	80.83
40	80:20	Augmentasi	Adam	0.0001	76.30	80.63
41	80:20	Augmentasi	SGD	0.1	66.15	64.17
42	80:20	Augmentasi	SGD	0.01	70.21	78.54
43	80:20	Augmentasi	SGD	0.001	76.46	76.67
44	80:20	Augmentasi	SGD	0.0001	69.32	74.58
45	80:20	Augmentasi	RMSprop	0.1	72.71	72.92
46	80:20	Augmentasi	RMSprop	0.01	70.00	71.46
47	80:20	Augmentasi	RMSprop	0.001	76.72	82.29
48	80:20	Augmentasi	RMSprop	0.0001	79.64	80.21


Tabel 3 menunjukkan bahwa percobaan pelatihan dilakukan pada 2 jenis data yaitu citra non-augmentasi dan citra yang telah di augmentasi pada rasio pembagian data 90:10 dan 80:20. Percobaan dijalankan dengan berbagai variasi hyperparameter dan dilakukan hingga 50 epoch. Percobaan pada jenis data non-augmentasi mencapai validation accuracy tertinggi pada percobaan ke-7, sedangkan pada jenis data augmentasi mencapai validation accuracy tertinggi pada percobaan ke-16. Kedua percobaan dengan akurasi tertinggi tersebut terdapat pada percobaan menggunakan rasio pembagian data 90:10.



Gambar 6. Grafik Accuracy dan Loss Citra Non-Augmentasi

Grafik pada Gambar 6 menunjukkan accuracy dan loss dari percobaan ke-7 yang menggunakan kombinasi data citra non-augmentasi, optimizer SGD, dan learning rate sebesar 0.001. Percobaan ini mendapatkan hasil training accuracy 76.95% dan validation accuracy 87.04%. Berdasarkan nilai training accuracy dan validation

accuracy yang didapatkan, dapat disimpulkan bahwa model yang digunakan dalam skenario ini tidak mengalami overfitting atau underfitting.



Gambar 7. Grafik Accuracy dan Loss Citra Augmentasi

Grafik pada Gambar 7 menunjukkan accuracy dan loss dari percobaan ke-16 yang menggunakan kombinasi data citra augmentasi, optimizer Adam, dan learning rate sebesar 0.0001. Percobaan ini mendapatkan hasil training accuracy 78.52% dan validation accuracy 85.19%. Berdasarkan nilai training accuracy dan validation accuracy yang didapatkan, dapat disimpulkan bahwa model yang digunakan dalam skenario ini tidak mengalami overfitting atau underfitting.

3.2 Proses Pengujian


Setelah menyelesaikan tahap pelatihan menggunakan data latih dan data validasi, langkah selanjutnya adalah melakukan pengujian terhadap model menggunakan data uji. Model yang akan diuji adalah model yang memiliki tingkat validation accuracy 80% ke atas selama pelatihan. Untuk mengevaluasi kinerja model, dilakukan analisis menggunakan confusion matrix dengan memperhatikan nilai accuracy, precision, recall, dan f1-score, serta hasil prediksi pada setiap kelas.

Tabel 4. Hasil Pengujian Menggunakan Data Non-Augmentasi dan Augmentasi

No.	Pembagian Data	Jenis Data	Optimizer	Learning Rate	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
1	90:10	Non-Augmentasi	Adam	0.001	75.00	79.24	75.00	75.47
2	90:10	Non-Augmentasi	Adam	0.0001	73.33	77.57	73.33	73.48
3	90:10	Non-Augmentasi	SGD	0.001	65.00	72.99	65.00	63.90
4	90:10	Non-Augmentasi	RMSprop	0.001	66.67	78.43	66.67	64.75
5	90:10	Non-Augmentasi	RMSprop	0.0001	73.33	79.66	73.33	72.72
6	90:10	Augmentasi	Adam	0.001	80.67	83.82	80.67	80.85
7	90:10	Augmentasi	Adam	0.0001	82.67	83.20	82.67	82.77
8	90:10	Augmentasi	SGD	0.1	77.33	80.22	77.33	77.18
9	90:10	Augmentasi	SGD	0.001	80.67	82.15	80.67	80.71
10	90:10	Augmentasi	RMSprop	0.01	80.00	80.58	80.00	80.13
11	90:10	Augmentasi	RMSprop	0.001	78.33	81.01	78.33	78.12
12	90:10	Augmentasi	RMSprop	0.0001	81.67	82.78	81.67	81.64
13	80:20	Non-Augmentasi	SGD	0.0001	73.33	75.65	73.33	72.85
14	80:20	Non-Augmentasi	RMSprop	0.0001	80.00	80.28	80.00	79.99
15	80:20	Augmentasi	Adam	0.001	85.00	85.32	85.00	85.01
16	80:20	Augmentasi	Adam	0.0001	82.67	84.03	82.67	82.74
17	80:20	Augmentasi	RMSprop	0.001	81.33	83.50	81.33	81.41
18	80:20	Augmentasi	RMSprop	0.0001	84.17	84.51	84.17	84.22


Tabel 4 merupakan hasil pengujian yang dilakukan menggunakan data uji yang belum pernah digunakan sebelumnya. Hasil pengujian pada jenis data non-augmentasi mencapai akurasi tertinggi pada percobaan ke-14,

sedangkan pada jenis data augmentasi mencapai akurasi tertinggi pada percobaan ke-15. Kedua percobaan dengan akurasi tertinggi tersebut terdapat pada pengujian menggunakan rasio pembagian data 80:20.



Gambar 8. Confusion Matrix Citra Non-Augmentasi Pengujian ke-14

Hasil dari pengujian pada percobaan ke-14 dapat dilihat pada Gambar 8 yang menunjukkan confusion matrix dengan accuracy sebesar 80.00%, precision sebesar 80.28%, recall sebesar 80.00%, dan f1-score sebesar 79.99%.



Gambar 9. Confusion Matrix Citra Augmentasi Pengujian ke-15

Hasil dari pengujian pada percobaan ke-15 dapat dilihat pada Gambar 9 yang menunjukkan confusion matrix dengan accuracy sebesar 85.00%, precision sebesar 85.32%, recall sebesar 85.00%, dan f1-score sebesar 85.01%. Dari hasil pengujian diatas, pengujian pada percobaan ke-15 mendapatkan hasil yang terbaik karena selain akurasi yang tinggi, prediksi hasil dari daging babi dan daging oplosan yang diprediksi sebagai daging sapi juga sedikit, dan data uji yang terbaca di setiap kelas juga paling mendekati jumlah data aslinya.

4. KESIMPULAN

Penelitian ini menggunakan arsitektur CNN Alexnet untuk mengklasifikasikan citra daging sapi, babi, dan oplosan dengan memanfaatkan data citra non-augmentasi dan hasil augmentasi. Data citra dibagi menjadi data latih dan data uji dengan rasio 90:10 dan 80:20. Performa model diuji menggunakan matriks klasifikasi dan dibandingkan berdasarkan nilai accuracy, precision, recall, dan f1-score pada kedua jenis data citra. Hasil penelitian



menunjukkan bahwa penggunaan data citra hasil augmentasi dengan skenario optimizer Adam dan learning rate 0.001 memiliki performa tertinggi, yaitu 85.00% accuracy, 85.32% precision, 85.00% recall, dan 85.01% f1-score. Sementara itu, penggunaan data citra non-augmentasi dengan skenario optimizer RMSprop dan learning rate 0,0001 menghasilkan performa yang sedikit lebih rendah, yaitu 80.00% accuracy, 80.28% precision, 80.00% recall, dan 79.99% f1-score. Keduanya menggunakan perbandingan data 80:20. Penggunaan augmentasi pada data citra mampu meningkatkan performa karena dapat menambah jumlah data dengan membuat data baru dari data yang sudah ada. Selain itu, penggunaan augmentasi dianggap sebagai percobaan yang terbaik karena selain akurasi yang tinggi, prediksi hasil dari daging babi dan daging oplosan yang diprediksi sebagai daging sapi juga sedikit, dan data uji yang terbaca di setiap kelas juga paling mendekati jumlah data aslinya. Untuk penelitian selanjutnya, disarankan menggunakan lebih banyak data citra dengan kualitas yang lebih baik serta menerapkan metode k-fold cross validation.

REFERENCES

- [1] Badan Pusat Statistik, “Peternakan Dalam Angka Tahun 2021,” 2021.
- [2] Liputan6.com and A. Apriyono, “Terbongkarnya Modus Penjualan Daging Babi Berkedok Daging Sapi di Lampung - Regional Liputan6.com,” 2021. <https://www.liputan6.com/regional/read/4537734/terbongkarnya-modus-penjualan-daging-babi-berkedok-daging-sapi-di-lampung> (accessed Dec. 21, 2022).
- [3] Anggiono Risky, “Awais, Boraks Bisa Sulap Daging Babi Jadi Daging Sapi,” 2021. <https://jabarekspres.com/berita/2021/09/29/awais-boraks-bisa-sulap-daging-babi-jadi-daging-sapi/> (accessed Dec. 21, 2022).
- [4] F. U. Amri, “Implementasi Segmentasi Spatial Fuzzy C-Means Pada Identifikasi Citra Daging Sapi dan Babi,” in Seminar Nasional Teknologi Informasi Komunikasi dan Industri, 2018, pp. 206–214.
- [5] 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.
- [6] J. Jasril and S. Sanjaya, “Learning Vector Quantization 3 (LVQ3) and Spatial Fuzzy C-Means (SFCM) for Beef and Pork Image Classification,” *Indonesian Journal of Artificial Intelligence and Data Mining*, vol. 1, no. 2, pp. 60–65, 2018.
- [7] A. M. Priyatno, F. M. Putra, P. Cholidhazia, and L. Ningsih, “Combination of extraction features based on texture and colour feature for beef and pork classification,” *J Phys Conf Ser*, vol. 1563, no. 1, p. 012007, 2020, doi: 10.1088/1742-6596/1563/1/012007.
- [8] K. Anwar and S. Setyowibowo, “The Identification of Beef and Pork Using Neural Network Based on Texture Features,” *Journal of Engineering Research*, 2022.
- [9] M. F. Naufal, S. F. Kusuma, K. C. Tanus, R. V. Sukiwun, J. Kristiano, and J. O. Lieyanto, “Analisis Perbandingan Algoritma Klasifikasi Citra Chest X-ray Untuk Deteksi Covid-19,” *Teknika*, vol. 10, no. 2, pp. 96–103, 2021.
- [10] K. L. Kohsasih, M. D. A. Rizky, T. Fahriyani, V. Wijaya, and R. Rosnelly, “ANALISIS PERBANDINGAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK DAN ALGORITMA MULTI-LAYER PERCEPTRON NEURAL DALAM KLASIFIKASI CITRA SAMPAH,” *Jurnal TIMES*, vol. 10, no. 2, pp. 22–28, 2021.
- [11] G. A. Lustiansyah, H. Prasetyo, B. K. Widodo, B. A. Wibisono, and D. S. Prasvita, “Analisis Perbandingan Algoritma SVM dan CNN Untuk Klasifikasi Buah,” in *Prosiding Seminar Nasional Mahasiswa Bidang Ilmu Komputer dan Aplikasinya*, 2021, pp. 1–11.
- [12] A. Deshpande, V. v Estrela, and P. Patavardhan, “The DCT-CNN-ResNet50 architecture to classify brain tumors with super-resolution, convolutional neural network, and the ResNet50,” *Neuroscience Informatics*, vol. 1, no. 4, p. 100013, 2021, doi: <https://doi.org/10.1016/j.neuri.2021.100013>.
- [13] G. Y. Alhafis, “Klasifikasi Citra Daging Sapi dan Daging Babi Menggunakan Ekstraksi Ciri dan Convolutional Neural Network,” *Klasifikasi Citra Daging Sapi dan Daging Babi Menggunakan Ekstraksi Ciri dan Convolutional Neural Network*, vol. 9, no. 3, pp. 653–660, 2022.
- [14] D. Efendi, J. Jasril, S. Sanjaya, F. Syafria, and E. Budianita, “Penerapan Algoritma Convolutional Neural Network Arsitektur ResNet-50 untuk Klasifikasi Citra Daging Sapi dan Babi,” *JURIKOM (Jurnal Riset Komputer)*, vol. 9, no. 3, pp. 607–614, 2022.
- [15] 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.
- [16] 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.
- [17] S. Kollem et al., “AlexNet-NDTL: Classification of MRI brain tumor images using modified AlexNet with deep transfer learning and Lipschitz-based data augmentation,” *Int J Imaging Syst Technol*, 2023.
- [18] K. M. Hosny, M. A. Kassem, and M. M. Foad, “Classification of skin lesions using transfer learning and augmentation with Alex-net,” *PLoS One*, vol. 14, no. 5, p. e0217293, 2019.
- [19] R. Gharbia, N. E. M. Khalifa, and A. E. Hassanien, “Land cover classification using deep convolutional neural networks,” in *Intelligent Systems Design and Applications: 20th International Conference on Intelligent Systems Design and Applications (ISDA 2020) held December 12-15, 2020, 2021*, pp. 911–920.
- [20] C. U. Khasanah, A. K. Pertiwi, and F. Witamajaya, “Implementasi Data Augmentation Random Erasing dan GridMask pada CNN untuk Klasifikasi Batik,” *SISFOTENIKA*, vol. 13, no. 1, pp. 16–28, 2023.
- [21] E. Cano, J. Mendoza-Avilés, M. Areiza, N. Guerra, J. L. Mendoza-Valdés, and C. A. Rovetto, “Multi skin lesions classification using fine-tuning and data-augmentation applying NASNet,” *PeerJ Comput Sci*, vol. 7, p. e371, 2021.



- [22] K. Amalia, R. Magladena, and S. Saidah, “Klasifikasi Penyakit Tumor Otak Pada Citra Mri Menggunakan Metode CNN Dengan Arsitektur Alexnet,” eProceedings of Engineering, vol. 9, no. 6, 2023.