



Penggunaan Convolutional Neural Network NASNetLarge Dalam Klasifikasi Citra Daging Babi dan Sapi

M Alfandri Aqilah, Jasril*, Suwanto Sanjaya, Fitri Insani

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

Email: ¹11950111710@students.uin-suska.ac.id, ^{2,*}jasril@uin-suska.ac.id, ³suwantosanjaya@uin-suska.ac.id,

⁴fitri.insani@uin-suska.ac.id

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

Abstrak—Pemalsuan daging sapi dengan campuran daging babi merupakan isu serius di Indonesia, terutama bagi konsumen Muslim yang mewajibkan konsumsi produk halal. Menurut laporan Kompas (2020), kasus pemalsuan daging sebanyak 100 kg daging oplosan dijual sebagai daging sapi ditemukan di Kota Tangerang. Praktik ini tidak hanya melanggar hukum agama, tetapi juga menimbulkan ancaman terhadap kesehatan dan kepercayaan masyarakat. Untuk mengatasi tantangan ini, penelitian ini menerapkan pendekatan deep learning menggunakan NASNetLarge dalam klasifikasi citra daging babi, daging sapi, dan daging oplosan. Berbeda dengan penelitian sebelumnya yang menggunakan EfficientNet-B2 menghasilkan akurasi sebesar 98.22%, pendekatan NASNetLarge dalam studi ini menghasilkan akurasi cukup kompetitif di angka 98.03%. Dataset yang digunakan terdiri dari 1.932 citra yang berasal dari platform Kaggle, kemudian diproses melalui tahapan preprocessing dan augmentasi. Setelah itu, data dibagi ke dalam dua skenario pembagian, yaitu keseluruhan data dan data yang telah diseimbangkan per kelas dengan rasio 90:10 dan 80:20. Hasil evaluasi menunjukkan bahwa kombinasi parameter terbaik diperoleh pada skenario pertama dengan rasio 90:10 menggunakan citra hasil augmentasi, learning rate 0.001, dense 128, dan optimizer Adam. Model berhasil mencapai akurasi tertinggi sebesar 98.03%, dengan nilai precision 98.63%, recall 98.40%, dan F1-score 98.50%. Hasil ini menunjukkan bahwa NASNetLarge efektif dalam mengklasifikasikan citra daging secara akurat dan konsisten. Augmentasi citra terbukti meningkatkan performa model dan rasio data 90:10 memberikan hasil yang lebih optimal dibandingkan 80:20. Temuan ini berpotensi mendukung upaya pengawasan pangan untuk mendeteksi pemalsuan daging secara cepat dan tepat.

Kata Kunci: Augmentasi; Convolutional Neural Network; Deep Learning; Klasifikasi Citra; NASNetLarge

Abstract—The adulteration of beef with pork is a serious issue in Indonesia, particularly for Muslim consumers who are required to consume halal products. According to a Kompas (2020) report, a case of meat adulteration involving 100 kilograms of mixed meat sold as beef was discovered in Tangerang City. This practice not only violates religious laws but also poses threats to public health and consumer trust. To address this challenge, this study adopts a deep learning approach using NASNetLarge for the classification of pork, beef, and mixed meat images. Unlike previous research that utilized EfficientNet-B2 and achieved an accuracy of 98.23%, this study's NASNetLarge approach produced a comparably competitive accuracy of 98.03%. The dataset used consists of 1,932 images sourced from the Kaggle platform, which were processed through preprocessing and augmentation stages. The data were then split into two distribution scenarios: the entire dataset and a balanced class dataset with 90:10 and 80:20 ratios. Evaluation results show that the best parameter combination was achieved in the first scenario with a 90:10 ratio using augmented images, a learning rate of 0.001, 128 dense units, and the Adam optimizer. The model achieved the highest accuracy of 98.03%, with a precision of 98.63%, recall of 98.40%, and an F1-score of 98.50%. These results indicate that NASNetLarge is effective in accurately and consistently classifying meat images. Image augmentation significantly improved model performance, and the 90:10 data ratio yielded more optimal results compared to 80:20. These findings have the potential to support food surveillance efforts by enabling rapid and accurate detection of meat adulteration.

Keywords: Augmentation; Convolutional Neural Network; Deep Learning; Image Classification; NASNetLarge

1. PENDAHULUAN

Di Indonesia, praktik pemalsuan daging sapi dengan mencampurkan daging babi kedalamnya menjadi isu yang sangat meresahkan, terutama bagi umat Muslim yang wajib mengonsumsi makanan halal. Kasus semacam ini sering terjadi menjelang bulan Ramadan atau hari besar keagamaan, saat permintaan daging sapi meningkat tajam. Salah satu kasus yang menonjol terjadi pada Mei 2020 di Kota Tangerang, Banten, ketika aparat kepolisian mengamankan 100 kilogram daging oplosan yang dijual sebagai daging sapi [1]. Kasus ini menimbulkan kekhawatiran serius, karena dalam ajaran Islam, daging babi termasuk makanan yang diharamkan secara tegas, sebagaimana tercantum dalam QS. Al-Baqarah ayat 168 dan 173. Selain melanggar hukum agama, pemalsuan ini juga menimbulkan dampak negatif secara sosial dan kesehatan masyarakat, termasuk potensi penyebaran penyakit.

Seiring pesatnya perkembangan teknologi, berbagai metode telah dikembangkan untuk mendeteksi dan mengklasifikasikan jenis daging secara lebih akurat. Salah satu pendekatan yang banyak digunakan adalah machine learning. Penelitian Saraswati dkk. menggunakan algoritma Backpropagation Neural Network (BPNN) dengan fitur GLCM dan menghasilkan akurasi 92%[2]. Sementara itu, Imam dkk. mengembangkan sistem klasifikasi menggunakan MATLAB dan Artificial Neural Network (ANN) dengan fitur yang sama dan memperoleh akurasi 80%[3]. Penelitian lain oleh Priyatno dkk. menggunakan metode Local Optimal Oriented Pattern (LOOP) serta fitur warna HSV, yang menghasilkan akurasi 91.16%[4].

Namun, pendekatan machine learning memiliki keterbatasan, terutama karena masih bergantung pada ekstraksi fitur manual. Untuk mengatasi hal ini, pendekatan deep learning mulai banyak digunakan karena kemampuannya dalam mengekstraksi fitur secara otomatis dan mengenali pola kompleks dalam data citra. Misalnya, penelitian oleh Naufal menunjukkan bahwa CNN memiliki akurasi tertinggi sebesar 94.2% dibandingkan SVM dan KNN[5]. Pada penelitian

lanjutan dengan 5-fold cross-validation, CNN kembali menunjukkan performa terbaik dengan rata-rata akurasi 95.91%[6].

Beberapa studi lainnya juga menunjukkan efektivitas arsitektur CNN dalam klasifikasi citra daging babi dan sapi. Alhafis menggunakan EfficientNet-B0 dan mencatat akurasi 95.17%[7]. Martias dengan EfficientNet-B6 menghasilkan akurasi 92% dengan augmentasi, dan 91.67% tanpa augmentasi[8]. Paisal menggunakan EfficientNet-B4 dan memperoleh akurasi tertinggi 96.28% pada rasio 80:20[9]. Ardianto dengan EfficientNet-B2 dan teknik augmentasi mendapatkan akurasi 98.22%[10]. Sementara itu, DLY dengan AlexNet mencatat akurasi 85% dengan augmentasi dan 80% tanpa augmentasi[11]. Penelitian oleh Laluma dkk. menunjukkan penggunaan citra berwarna tanpa grayscale menghasilkan akurasi 88.75%, lebih tinggi dibandingkan penggunaan grayscale yaitu 73.37% [12].

Dalam penelitian ini, penulis menggunakan NASNetLarge, yang merupakan hasil dari proses Neural Architecture Search [13]. NASNetLarge mampu menghasilkan struktur jaringan saraf yang lebih optimal dibandingkan arsitektur buatan manual [14]. Selain fleksibel dalam jumlah parameter, arsitektur ini unggul dalam menangkap fitur kompleks citra, serta lebih tahan terhadap variasi bentuk, tekstur, dan pencahayaan [15]. Keunggulan ini menjadikan NASNetLarge sebagai pilihan yang tepat untuk membedakan jenis daging berdasarkan karakteristik visualnya.


Beberapa penelitian dengan kasus lain mendukung keunggulan NASNetLarge dalam klasifikasi citra. Mehmood memperoleh akurasi 92% untuk klasifikasi tumor [16]. Ilhan dkk. mencatat akurasi 96.7% dalam klasifikasi gambar palsu [17]. Himel dkk. mencapai akurasi 99.65% pada klasifikasi citra kucing dan anjing [18]. Penelitian oleh Zulfa menunjukkan akurasi 94.31% dalam klasifikasi penyakit daun padi pada rasio 80:20 [19], sedangkan Solaiman dalam deteksi COVID-19 berbasis X-ray mencatat akurasi 94.2% pada pengujian dan 95.11% pada pelatihan [20].

Penelitian ini bertujuan untuk mengevaluasi performa NASNetLarge dalam mengklasifikasikan citra daging babi, sapi dan oplosan. Fokus utama penelitian ini adalah menguji akurasi, presisi dan konsistensi model dalam mendeteksi pemalsuan daging, serta membandingkan performanya dengan hasil studi sebelumnya. Dengan demikian, diharapkan NASNetLarge dapat menjadi solusi alternatif yang efektif dan andal untuk mendukung pengawasan pangan, khususnya dalam mendeteksi produk non-halal secara cepat dan akurat.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan untuk mencapai tujuan klasifikasi citra daging. Gambar 1 menyajikan alur proses mulai dari pengumpulan data hingga evaluasi model menggunakan CNN NASNetLarge.




Gambar 1. Tahapan penelitian

Gambar 1 memperlihatkan tahapan utama dalam penelitian ini. Proses dimulai dengan pengumpulan data, kemudian dilanjutkan dengan tahap preprocessing untuk menyiapkan data sesuai format input model. Setelah itu dilakukan augmentasi guna meningkatkan keragaman data. Data yang telah melalui tahap tersebut kemudian dibagi berdasarkan dua skenario pembagian. Selanjutnya, data dimasukkan ke dalam model CNN NASNetLarge untuk proses klasifikasi. Tahapan akhir adalah evaluasi kinerja model menggunakan metrik evaluasi untuk menilai performa klasifikasi.

2.2 Pengumpulan data


Dataset yang digunakan dalam penelitian ini terdiri dari tiga kelas citra, yaitu daging babi, daging oplosan dan daging sapi. Data diambil dari platform penyedia dataset terbuka Kaggle [21]. Total data berjumlah 1.932 citra dengan distribusi: 972 citra pada kelas babi, 206 pada kelas oplosan dan 754 pada kelas sapi, yang bentuk visualnya dapat dilihat pada Gambar 2.



Gambar 2. Citra daging

2.3 Preprocessing


Sebelum dilakukan augmentasi data, citra-citra dalam dataset terlebih dahulu melalui dua tahapan *pre-processing*. Pertama, dilakukan *cropping* untuk memotong bagian gambar yang tidak relevan dan memfokuskan area pada bagian daging saja. Kemudian, citra di-*resize* ke ukuran 331×331 piksel agar sesuai dengan input standar model NASNetLarge. Pada Gambar 3 dapat dilihat hasil dari tahapan preprocessing.



Gambar 3. Citra cropping dan resize

2.4 Augmentasi

Citra yang telah melalui tahapan preprocessing kemudian dilakukan teknik augmentasi untuk menambah variasi data, adapun teknik yang digunakan adalah rotasi secara acak hingga 180 derajat (rotation), penggeseran secara vertikal maupun horizontal (shifting), zoom in/out dan flip secara horizontal atau vertikal. Gambar 4 merupakan hasil citra sebelum dan setelah dilakukan proses augmentasi.



Gambar 4. Citra hasil augmentasi

2.5 Pembagian data

Setelah proses augmentasi dilakukan, dataset dibagi ke dalam tiga subset, yaitu data pelatihan, data validasi dan data pengujian. Penelitian ini menggunakan dua skenario pembagian data, yaitu:

- Skenario pertama menggunakan seluruh citra yang tersedia, baik citra asli maupun hasil augmentasi.
- Skenario kedua menggunakan dataset yang telah diseimbangkan berdasarkan jumlah citra pada kelas paling sedikit, yaitu sebanyak 200 citra tiap kelas dan hasil augmentasi.

Setiap skenario diuji menggunakan dua rasio data, yaitu 90:10 dan 80:20 yang dapat dilihat rincian pembagian data masing-masing skenario pada Tabel 1.


Tabel 1. Pembagian data

Skenario	Rasio	Kelas	Latih	Validasi	Uji
1	90:10 Asli	Babi	788	87	97
1	90:10 Asli	Oplosan	167	18	21
1	90:10 Asli	Sapi	611	68	75
1	90:10 Aug	Babi	3387	437	486
1	90:10 Aug	Oplosan	834	93	103
1	90:10 Aug	Sapi	3054	339	377
1	80:20 Asli	Babi	622	154	194
1	80:20 Asli	Oplosan	132	33	41
1	80:20 Asli	Sapi	482	121	151
1	80:20 Aug	Babi	3110	778	972
1	80:20 Aug	Oplosan	659	165	206
1	80:20 Aug	Sapi	2413	603	754
2	90:10 Asli	Babi	162	18	20

Skenario	Rasio	Kelas	Latih	Validasi	Uji
2	90:10 Asli	Oplosan	162	18	20
2	90:10 Asli	Sapi	162	18	20
2	90:10 Aug	Babi	810	90	100
2	90:10 Aug	Oplosan	810	90	100
2	90:10 Aug	Sapi	810	90	100
2	80:20 Asli	Babi	128	32	40
2	80:20 Asli	Oplosan	128	32	40
2	80:20 Asli	Sapi	128	32	40
2	80:20 Aug	Babi	640	160	200
2	80:20 Aug	Oplosan	640	160	200
2	80:20 Aug	Sapi	640	160	200

2.6 Deep learning

Gambar 5 memperlihatkan arsitektur model NASNetLarge yang digunakan dalam proses klasifikasi citra pada penelitian ini.



Gambar 5. Arsitektur NASNetLarge [22]

Setelah melalui tahap pembagian data, proses klasifikasi citra dilakukan dengan deep learning menggunakan arsitektur NASNetLarge. NASNet (Neural Architecture Search Network) merupakan arsitektur CNN hasil pencarian otomatis yang dirancang untuk menemukan struktur optimal dalam membangun jaringan konvolusional. NASNetLarge terdiri dari dua jenis blok utama, yaitu Normal Cell dan Reduction Cell, yang disusun secara berulang untuk membentuk jaringan yang dalam dan kompleks. Reduction cell berfungsi untuk mengurangi dimensi spasial data, sedangkan Normal cell mempertahankan dimensi dan mengekstraksi fitur yang lebih mendalam. Sebelum citra diproses oleh model, dilakukan normalisasi piksel dari rentang 0-255 menjadi 0-1. Struktur NASNetLarge ini diawali dengan konvolusi awal berukuran 3×3 dengan stride 2, diikuti oleh Reduction Cell, lalu diselingi beberapa Normal Cell hingga mencapai lapisan fully connected dan output softmax. Untuk mengoptimalkan performa model, digunakan beberapa kombinasi parameter berupa: epoch 20, 30, batch size 32, dropout 0.5, learning rate 0.1, 0.01, 0.001, dense 128, 256, optimizer Adam dan SGD.

2.7 Evaluasi

Evaluasi performa model dilakukan menggunakan metode confusion matrix untuk mengetahui accuracy, precision, recall dan f1-score pada tiap kelas. Terdapat empat komponen utama dalam confusion matrix, yaitu True Positive (TP), True Negative (TN), False Positive (FP), False Negative (FN) [23]. Berdasarkan nilai-nilai tersebut, empat metrik evaluasi dihitung sebagai berikut:

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

$$precision = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

$$recall = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

$$f1 - score = 2 \times \frac{presisi \times recall}{presisi + recall} \quad (4)$$

3. HASIL DAN PEMBAHASAN

Penelitian ini dilakukan melalui serangkaian eksperimen dengan memanfaatkan platform Google Colab. Eksperimen dilakukan dengan mencoba model CNN NASNetLarge terhadap citra asli dan hasil augmentasi, serta menggunakan dua rasio data, yaitu 90:10 dan 80:20. Terdapat dua skenario pembagian data yang diterapkan, pertama menggunakan keseluruhan citra dan kedua penggunaan data yang diseimbangkan citranya per kelas. Parameter yang digunakan dalam proses pelatihan meliputi dropout 0.5, dense 128 dan 256, learning rate sebesar 0.1, 0.01 dan 0.001, batch size 32, jumlah epoch 20 untuk skenario pertama, 30 pada skenario kedua, serta optimizer Adam dan SGD. Selain itu, diterapkan juga teknik EarlyStopping untuk mencegah overfitting selama pelatihan model.



3.1 Hasil pengujian

Tabel 2 menunjukkan hasil pengujian model terhadap citra asli dan augmentasi yang menggunakan pembagian data skenario pertama.

Tabel 2. Hasil pengujian skenario pertama

No	Rasio	Learning rate	Dense	Optimizer	Citra	
					Asli	Aug
1	90:10	0.1	128	Adam	90.67%	50.31%
2	90:10	0.01	128	Adam	92.75%	96.38%
3	90:10	0.001	128	Adam	94.30%	98.03%
4	90:10	0.1	256	Adam	87.56%	71.12%
5	90:10	0.01	256	Adam	95.34%	96.48%
6	90:10	0.001	256	Adam	95.85%	97.72%
7	90:10	0.1	128	SGD	95.85%	97.62%
8	90:10	0.01	128	SGD	93.26%	95.65%
9	90:10	0.001	128	SGD	89.12%	91.61%
10	90:10	0.1	256	SGD	96.37%	98.03%
11	90:10	0.01	256	SGD	92.75%	96.07%
12	90:10	0.001	256	SGD	89.64%	91.51%
13	80:20	0.1	128	Adam	89.64%	62.11%
14	80:20	0.01	128	Adam	93.01%	95.29%
15	80:20	0.001	128	Adam	95.34%	97.05%
16	80:20	0.1	256	Adam	89.90%	82.76%
17	80:20	0.01	256	Adam	94.04%	95.81%
18	80:20	0.001	256	Adam	95.85%	97.10%
19	80:20	0.1	128	SGD	95.08%	97.93%
20	80:20	0.01	128	SGD	92.75%	96.58%
21	80:20	0.001	128	SGD	87.56%	91.67%
22	80:20	0.1	256	SGD	95.60%	97.57%
23	80:20	0.01	256	SGD	92.75%	96.38%
24	80:20	0.001	256	SGD	88.34%	92.08%

Berdasarkan hasil pengujian pada skenario pertama yang ditampilkan pada Tabel 2, dapat dilihat bahwa model menunjukkan performa yang cukup baik pada rasio data 90:10, dengan akurasi tertinggi sebesar 98.03%. Hasil ini diperoleh dari citra hasil augmentasi menggunakan kombinasi parameter learning rate 0.001, dense 128, dan optimizer Adam. Sementara itu, pada rasio data 80:20, model juga menunjukkan performa kompetitif dengan akurasi tertinggi mencapai 97.93%, yang dicapai menggunakan kombinasi parameter learning rate 0.1, dense 128, dan optimizer SGD. Kedua hasil tertinggi pada tiap rasio diperoleh dari citra hasil augmentasi. Kombinasi parameter yang menghasilkan akurasi terbaik pada masing-masing rasio tidak hanya mencerminkan efektivitas konfigurasi tersebut, tetapi juga menggambarkan pengaruh proporsi data pelatihan terhadap performa model. Pada rasio 90:10, proporsi data latih yang lebih besar memberikan model kesempatan untuk belajar dari lebih banyak variasi fitur, sehingga meningkatkan kemampuan generalisasi terhadap data uji. Kombinasi learning rate 0.001 dan optimizer Adam sangat sesuai dalam konteks ini, karena Adam bersifat adaptif dan bekerja optimal pada learning rate kecil. Hal ini mendukung proses konvergensi yang stabil, terutama untuk model dengan arsitektur kompleks seperti NASNetLarge. Namun demikian, tidak semua kombinasi parameter memberikan dampak positif terhadap proses augmentasi. Pada Tabel 2 baris pertama, model justru mengalami penurunan akurasi secara signifikan, dengan nilai akurasi pengujian hanya mencapai 50.31%. Fenomena ini terjadi karena proses pelatihan terhenti terlalu dini akibat diterapkannya mekanisme earlystopping. Berdasarkan proses pelatihan, nilai validation loss stagnan dan tidak menunjukkan penurunan berarti sejak awal epoch, sehingga early stopping menghentikan pelatihan pada epoch ke-6 dengan akurasi validasi sekitar 50.40%. Hal ini mengindikasikan bahwa model tidak memperoleh cukup informasi dari citra hasil augmentasi pada konfigurasi tersebut, kemungkinan disebabkan oleh kombinasi parameter yang kurang optimal atau kompleksitas augmentasi yang justru mengaburkan fitur penting dalam citra.

Tabel 3 menunjukkan hasil pengujian model terhadap citra asli dan augmentasi yang menggunakan pembagian data skenario kedua.

Tabel 3. Hasil pengujian skenario dua

No	Rasio	Learning rate	Dense	Optimizer	Citra	
					Asli	Aug
1	90:10	0.1	128	Adam	86.67%	81.67%
2	90:10	0.01	128	Adam	88.33%	91.00%
3	90:10	0.001	128	Adam	90.00%	93.67%




No	Rasio	Learning rate	Dense	Optimizer	Citra	
					Asli	Aug
4	90:10	0.1	256	Adam	86.67%	84.00%
5	90:10	0.01	256	Adam	86.67%	91.67%
6	90:10	0.001	256	Adam	88.33%	91.67%
7	90:10	0.1	128	SGD	90.00%	93.00%
8	90:10	0.01	128	SGD	88.33%	93.67%
9	90:10	0.001	128	SGD	78.33%	89.00%
10	90:10	0.1	256	SGD	88.33%	94.00%
11	90:10	0.01	256	SGD	88.33%	93.33%
12	90:10	0.001	256	SGD	80.00%	89.00%
13	80:20	0.1	128	Adam	85.83%	48.83%
14	80:20	0.01	128	Adam	90.00%	88.17%
15	80:20	0.001	128	Adam	89.17%	88.00%
16	80:20	0.1	256	Adam	90.83%	83.17%
17	80:20	0.01	256	Adam	90.00%	87.17%
18	80:20	0.001	256	Adam	89.17%	87.33%
19	80:20	0.1	128	SGD	90.83%	87.67%
20	80:20	0.01	128	SGD	89.17%	87.33%
21	80:20	0.001	128	SGD	76.67%	83.33%
22	80:20	0.1	256	SGD	90.00%	88.33%
23	80:20	0.01	256	SGD	90.83%	87.33%
24	80:20	0.001	256	SGD	81.67%	85.17%

Hasil pengujian skenario dua yang ditampilkan pada Tabel 3 menunjukkan bahwa performa terbaik dalam skenario ini diperoleh pada rasio data 90:10 dengan akurasi 94.00%. Hasil ini diperoleh dari citra hasil augmentasi yang menggunakan kombinasi parameter berupa learning rate 0.1, dense 256 dan optimizer SGD. Sementara pada rasio data 80:20, performa terbaik diperoleh dari citra asli dengan tiga konfigurasi parameter yang sama-sama menghasilkan akurasi 90.83%. Ketiga konfigurasi tersebut terdiri dari learning rate 0.1, 0.01, dense 128, 256 serta penggunaan optimizer Adam dan SGD. Kombinasi parameter learning rate 0.1, dense 256, dan optimizer SGD yang menghasilkan akurasi tertinggi pada rasio 90:10 menunjukkan bahwa masing-masing komponen parameter memiliki kontribusi penting terhadap performa model. Learning rate 0.1 memberikan pembaruan bobot yang cepat, yang efektif dalam konteks penggunaan optimizer SGD, karena SGD cenderung membutuhkan learning rate yang lebih besar untuk mencapai konvergensi optimal. Selain itu, dense layer dengan 256 unit memberikan kapasitas representasi fitur yang lebih tinggi, memungkinkan model untuk menangkap pola yang lebih kompleks dari data. Kombinasi ini semakin diperkuat oleh penggunaan citra hasil augmentasi, yang menambah keragaman data pelatihan sehingga meningkatkan kemampuan generalisasi model. Sinergi antara konfigurasi parameter dan variasi data inilah yang secara empiris menghasilkan akurasi tertinggi pada skenario ini. Di sisi lain, terdapat pula konfigurasi yang menghasilkan performa sangat rendah. Pada Tabel 3 baris ke-13, model menunjukkan akurasi validasi hanya sebesar 43.75% dan akurasi pengujian sebesar 43.83%. Berdasarkan proses pelatihan, akurasi validasi sempat menyentuh angka 59.79% pada epoch pertama, namun kemudian mengalami penurunan konsisten hingga akhir pelatihan. Selain itu, validation loss cenderung meningkat, menandakan adanya kesulitan model dalam menyesuaikan diri terhadap distribusi data validasi. Hal ini mengindikasikan bahwa kombinasi parameter dan jenis augmentasi yang digunakan tidak cukup efektif dalam membantu proses pembelajaran. Ada kemungkinan bahwa augmentasi yang diterapkan menghasilkan citra dengan kompleksitas visual tinggi sehingga fitur penting menjadi tidak terbaca secara optimal oleh model.

3.2 Evaluasi model


Gambar 4 menunjukkan proses pelatihan model pada hasil terbaik skenario pertama dengan rasio data 90:10, learning rate 0.001, dense 128 serta optimizer Adam.



Gambar 4. Grafik pelatihan model

Berdasarkan grafik akurasi pelatihan dan validasi yang terlihat pada Gambar 4, terlihat bahwa model menunjukkan peningkatan performa yang konsisten sepanjang proses pelatihan. Akurasi pada proses pelatihan meningkat secara stabil dari angka 88.28% pada epoch pertama hingga mencapai 98.90% pada epoch ke-20. Tren yang sama juga terlihat pada proses validasi, di mana akurasi awal sebesar 92.52% terus meningkat dan mencapai nilai akhir 98.04%. Kenaikan yang sejalan antara akurasi pelatihan dan validasi ini mengindikasikan bahwa model mampu belajar secara efektif tanpa mengalami overfitting, karena tidak terdapat perbedaan signifikan antara keduanya. Selain itu, grafik loss pelatihan dan validasi juga menunjukkan hasil yang positif. Nilai loss pada pelatihan menurun cukup signifikan dari 0.2927 menjadi 0.0290 di akhir pelatihan. Sementara itu, loss pada validasi juga mengalami penurunan dari 0.1587 menjadi 0.0455.

Untuk mengevaluasi performa model dalam mengklasifikasikan citra daging, dilakukan analisis lebih lanjut menggunakan confusion matrix yang ditampilkan pada Gambar 5.



Gambar 5. Confusion matrix

Confusion matrix pada pengujian hasil terbaik skenario pertama dengan rasio data 90:10, *learning rate* 0.001, *dense* 128 serta *optimizer* yang ditampilkan Gambar 5 menunjukkan model mampu mengklasifikasikan citra dengan tingkat akurasi tinggi sebesar 98.03%, 98.63% presisi, 98.40% *recall* dan 98.50% *f1-score*. Dari total 486 citra kelas babi, sebanyak 482 diklasifikasikan dengan benar, sementara 4 citra salah prediksi sebagai kelas sapi. Untuk kelas oplosan, model berhasil mengklasifikasikan seluruh 103 citra secara sempurna tanpa kesalahan. Pada kelas sapi, dari 377 citra, 362 diklasifikasikan dengan benar dan 15 sisanya diklasifikasikan sebagai kelas babi.

4. KESIMPULAN

Berdasarkan hasil eksperimen dan evaluasi yang telah dilakukan, dapat disimpulkan bahwa model Convolutional Neural Network NASNetLarge mampu memberikan performa klasifikasi citra daging babi, oplosan, dan sapi secara efektif dan akurat, baik pada citra asli maupun citra hasil augmentasi. Penelitian ini mengevaluasi dua skenario pembagian data yaitu menggunakan data secara keseluruhan dan data yang diseimbangkan per kelas sesuai kelas minoritas, dengan dua rasio 90:10 dan 80:20 serta berbagai kombinasi parameter pelatihan. Dari seluruh percobaan yang dilakukan, model menunjukkan performa terbaik pada skenario pertama dengan rasio data 90:10 yang menggunakan citra hasil augmentasi dan kombinasi parameter *learning rate* 0.001, *dense* 128, dan *optimizer* Adam, menghasilkan akurasi 98.03%. Selain itu, model juga menunjukkan nilai evaluasi metrik yang tinggi, yaitu presisi 98.63%, *recall* 98.40%, dan F1-score 98.50%, yang menandakan ketepatan dan konsistensi klasifikasi model dalam mengenali tiap kelas citra. Grafik pelatihan dan validasi menunjukkan bahwa model berhasil belajar secara stabil dan konsisten, tanpa mengalami overfitting, dibuktikan dengan tren peningkatan akurasi dan penurunan nilai loss yang sejalan pada kedua proses tersebut. Sementara itu, pada skenario kedua dengan data yang diseimbangkan per kelas, performa model cenderung lebih rendah dibandingkan skenario pertama. Akurasi tertinggi tercatat sebesar 94.00% pada rasio data 90:10 dengan citra augmentasi. Hal ini menunjukkan bahwa keberagaman data serta jumlah data yang mencukupi per kelas memiliki pengaruh signifikan terhadap performa model CNN dalam melakukan klasifikasi citra. Model NASNetLarge terbukti efektif dalam klasifikasi citra daging, khususnya untuk mendeteksi daging babi, oplosan, dan sapi yang menjadi fokus utama dari penelitian ini. Dibandingkan dengan penelitian sebelumnya yang menggunakan arsitektur seperti EfficientNet-B0, B4, dan B6 dengan akurasi maksimal 96.26%, penelitian ini menunjukkan keunggulan NASNetLarge yang mampu mencapai akurasi hingga 98.03%. Keunikan penelitian ini terletak pada kombinasi evaluasi skenario pembagian data yang lebih menyeluruh, eksplorasi parameter pelatihan yang beragam, serta penerapan NASNetLarge dalam domain klasifikasi citra daging yang belum banyak dieksplorasi. Untuk penelitian selanjutnya, disarankan mengeksplorasi teknik augmentasi berbasis Generative Adversarial Networks (GAN) guna menghasilkan variasi tekstur citra daging yang lebih realistis, yang berpotensi meningkatkan kemampuan generalisasi model terhadap kondisi nyata. Selain itu, integrasi model klasifikasi citra dengan teknologi sensor hyperspectral dapat dipertimbangkan untuk memperkaya informasi spektral, terutama dalam mendeteksi daging oplosan secara lebih presisi.



REFERENCES

- [1] Singgih Wiryono dan Jessi Carina, "Fakta Kasus Daging Oplosan Sapi dan Babi di Tangerang, Kelabui Pembeli dengan Harga Murah," KOMPAS.com. Diakses: 15 Mei 2025. [Daring]. Tersedia pada: <https://megapolitan.kompas.com/read/2020/05/19/07120811/fakta-kasus-daging-oplosan-sapi-dan-babi-di-tangerang-kelabui-pembeli>
- [2] I. Saraswati, R. Fahrizal, A. N. Fauzan, dan M. A. S. Yudono, "Classification of Beef, Goat, and Pork using GLCM Texture-Based Backpropagation Neural Network," Sistemasi: Jurnal Sistem Informasi, vol. 13, no. 6, hlm. 2698–2708, Nov 2024, doi: <https://doi.org/10.32520/stmsi.v13i6.4715>.
- [3] C. Imam, E. W. Hidayat, dan N. I. Kurniati, "Classification of Meat Imagery Using Artificial Neural Network Method and Texture Feature Extraction By Gray Level Co-Occurrence Matrix Method," Jurnal Teknik Informatika (Jutif), vol. 2, no. 1, hlm. 1–8, Jun 2021, doi: <https://doi.org/10.20884/1.jutif.2021.2.1.37>.
- [4] A. M. Priyatno, F. M. Putra, P. Cholidhazia, dan 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, hlm. 12007, Jun 2020, doi: 10.1088/1742-6596/1563/1/012007.
- [5] M. F. Naufal, "Analisis Perbandingan Algoritma Svm, Knn, Dan Cnn untuk Klasifikasi Citra Cuaca.," Jurnal Teknologi Informasi dan Ilmu Komputer, vol. 8, no. 2, hlm. 311–317, 2021, doi: 10.25126/jtiik.202184553.
- [6] M. F. Naufal dkk., "Analisis perbandingan algoritma klasifikasi citra chest x-ray untuk deteksi COVID-19," Jurnal Teknologi Informasi dan Komunikasi Teknika IKADO, vol. 10, no. 2, hlm. 96–103, 2021, doi: 10.34148/teknika.v10i2.331.
- [7] G. Y. Alhafis, Jasril, S. Sanjaya, F. Syafria, dan E. Budianita, "Klasifikasi Citra Daging Sapi dan Daging Babi Menggunakan Ekstraksi Ciri dan Convolutional Neural Network," JURIKOM: Jurnal Riset Komputer, vol. 9, no. 3, hlm. 653–660, 2022, doi: <https://doi.org/10.30865/jurikom.v9i3.4175>.
- [8] M. F. Martias, Jasril, S. Sanjaya, L. Handayani, dan A. Nazir, "Implementasi Klasifikasi Citra Daging Sapi dan Daging Babi Menggunakan CNN Arsitektur Efficientnet-B6 Dan Augmentasi Data," JSON: Jurnal Sistem Komputer dan Informatika, vol. 4, no. 4, hlm. 642–653, 2023, doi: <https://doi.org/10.30865/json.v4i4.6195>.
- [9] A. Paisal, S. Sanjaya, L. Handayani, F. Syafria, dan others, "Klasifikasi Daging Sapi Dan Daging Babi Menggunakan Cnn Dengan Arsitektur Efficientnet-B4 Dan Augmentasi Data," Jurnal Informatika Universitas Pamulang, vol. 8, no. 2, hlm. 165–176, 2023, doi: <https://doi.org/10.32493/informatika.v8i2.30586>.
- [10] D. Ardianto, Jasril, S. Sanjaya, L. Handayani, dan F. Syafria, "Klasifikasi Citra Daging Sapi dan Babi Menggunakan Convolutional Neural Network (CNN) dengan Arsitektur EfficientNet-B2 dan Augmentasi Data," Jurnal Informatika Universitas Pamulang, vol. 8, no. 2, hlm. 153–164, 2023, doi: <https://doi.org/10.32493/informatika.v8i2.30587>.
- [11] I. A. DLY, Jasril, S. Sanjaya, M. Affandes, dan F. Yanto, "Klasifikasi Citra Daging Sapi dan Babi Menggunakan CNN Alexnet dan Augmentasi Data," JOSH: Jurnal of Information System Research, vol. 4, no. 4, hlm. 1176–1185, 2023, doi: <https://doi.org/10.47065/josh.v4i4.3702>.
- [12] R. H. Laluma dkk., "Klasifikasi Perbedaan Daging Sapi Dan Daging Babi Dengan Metode Convolutional Neural Network Berbasis Web," Infotronik: Jurnal Teknologi Informasi dan Elektronika, vol. 6, no. 1, hlm. 1–6, 2021, doi: <https://doi.org/10.32897/infotronik.2021.6.1.603>.
- [13] B. Zoph, V. Vasudevan, J. Shlens, dan Q. V Le, "Learning transferable architectures for scalable image recognition," dalam Proceedings of the IEEE conference on computer vision and pattern recognition, 2018, hlm. 8697–8710. doi: 10.1109/CVPR.2018.00907.
- [14] V.-K. Vo-Ho, K. Yamazaki, H. Hoang, M.-T. Tran, dan N. Le, "Neural architecture search for medical image applications," dalam Meta Learning With Medical Imaging and Health Informatics Applications, Elsevier, 2023, 19, hlm. 369–384. doi: <https://doi.org/10.1016/B978-0-32-399851-2.00029-6>.
- [15] R. P. Singh, N. H. Sree, K. L. S. P. Reddy, dan K. Jashwanth, "Convergence of Deep Learning and Forensic Methodologies Using Self-attention Integrated EfficientNet Model for Deep Fake Detection," SN Comput Sci, vol. 5, no. 8, hlm. 1–12, 2024, doi: <https://doi.org/10.1007/s42979-024-03455-3>.
- [16] M. Mehmood dkk., "Improved colorization and classification of intracranial tumor expanse in MRI images via hybrid scheme of Pix2Pix-cGANs and NASNet-large," Journal of King Saud University-Computer and Information Sciences, vol. 34, no. 7, hlm. 4358–4374, 2022, doi: <https://doi.org/10.1016/j.jksuci.2022.05.015>.
- [17] I. Ilhan, E. Bal, dan M. Karaköse, "An improved deepfake detection approach with NASNetLarge CNN," dalam 2022 International Conference on Data Analytics for Business and Industry (ICDABI), 2022, hlm. 598–602. doi: <https://doi.org/10.1109/icdabi56818.2022.10041558>.
- [18] G. M. S. Himel dan M. M. Islam, "Benchmark analysis of various pre-trained deep learning models on ASSIRA cats and dogs dataset," Journal of Umm Al-Qura University for Engineering and Architecture, vol. 16, hlm. 134–149, Jan 2025, doi: <https://doi.org/10.1007/s43995-024-00094-w>.
- [19] A. N. Zulfa, Jasril, M. Irsyad, F. Yanto, dan S. Sanjaya, "Optimasi Convolutional Neural Network NASNetLarge menggunakan augmentasi data untuk klasifikasi citra penyakit daun padi," MIB: Jurnal Media Informatika Budidarma, vol. 7, no. 2, hlm. 696–706, 2023, doi: <https://doi.org/10.30865/mib.v7i2.6056>.
- [20] I. A. Solaiman, T. I. Sanjana, S. Sobhan, T. S. Maria, dan M. K. Rahman, "X-Ray Classification to Detect COVID-19 using Ensemble Model.," dalam ICAART (2), 2022, hlm. 375–386. doi: <https://doi.org/10.5220/0010847200003116>.
- [21] A. A. Harahap dan B. Delvika, "datasetdagingsapioplosan," Kaggle. Diakses: 15 Mei 2025. [Daring]. Tersedia pada: <https://www.kaggle.com/datasets/akhirilanwar/datasetdagingsapioplosan>
- [22] S. Albahli dan W. Albattah, "Detection of coronavirus disease from X-ray images using deep learning and transfer learning algorithms," J Xray Sci Technol, vol. 28, no. 5, hlm. 841–850, 2020, doi: 10.3233/XST-200720.
- [23] A. Tharwat, "Classification assessment methods," Applied computing and informatics, vol. 17, no. 1, hlm. 168–192, 2021, doi: <https://doi.org/10.1016/j.aci.2018.08.003>.