



Klasifikasi Ras Sapi Menggunakan *Hyperparameter* ResNet-50 Berbasis *Transfer Learning*

Adz Dziki Tamyizur Rijal^{1*}, Bain Khusnul Khotimah²

^{1,2} Program Studi Teknik Informatika, Fakultas Teknik, Universitas Trunojoyo Madura, Indonesia

Info Artikel

Riwayat Artikel:

Diterima : **08 Desember 2025**

Direvisi : **18 Desember 2025**

Diterbitkan : **01 Juni 2026**

Kata Kunci:

Klasifikasi,
Ras Sapi,
ResNet-50,
Transfer Learning,
Hyperparameter Tuning

Keywords:

Classification,
Cattle Breeds,
ResNet-50,
Transfer Learning,
Hyperparameter Tuning

ABSTRAK

Identifikasi ras sapi merupakan tantangan dalam pengelolaan peternakan modern, terutama pada ras yang memiliki kemiripan morfologi yang tinggi. Penelitian ini bertujuan mengoptimalkan kinerja klasifikasi citra ras sapi menggunakan arsitektur CNN ResNet-50. Tahapannya diawali dengan proses pra-pemrosesan yang meliputi penyeragaman ukuran citra menjadi 224×224 piksel, normalisasi serta penerapan augmentasi data untuk meningkatkan variasi data latih. Model dilatih menggunakan *optimizer* Adam dengan skenario pengaturan *hyperparameter*. Fokus utama penelitian adalah mengevaluasi efektivitas metode *Transfer Learning* dibandingkan dengan pelatihan dari awal. Dataset yang digunakan terdiri atas 1.251 citra morfologi yang terbagi dalam 5 kelas ras (*Ayrshire*, *Brown Swiss*, *Holstein Friesian*, *Jersey*, dan *Red Dane*). Hasil menunjukkan perbedaan performa yang signifikan. Model yang dilatih dari awal hanya mampu mencapai akurasi maksimal sebesar 81%, sedangkan model berbasis *Transfer Learning* mampu mencapai akurasi sebesar 95%. Peningkatan akurasi sebesar 14% ini membuktikan bahwa penggunaan bobot *pre-trained* yang dikombinasikan dengan augmentasi data efektif dalam mengenali karakteristik visual ras sapi dengan presisi tinggi.

ABSTRACT

Cattle breed identification presents a challenge in modern livestock management, particularly for breeds exhibiting high morphological similarities. This study aims to optimize cattle breed image classification performance using the ResNet-50 Convolutional Neural Network (CNN) architecture. The research methodology begins with preprocessing, which includes image resizing to 224×224 pixels, normalization, and the application of Data Augmentation to enhance training data diversity. The model was trained using the Adam optimizer with specific hyperparameter setting scenarios. The primary focus of this research is to evaluate the effectiveness of the Transfer Learning method compared to training from scratch. The dataset consists of 1,251 morphological images distributed across 5 breed classes (*Ayrshire*, *Brown Swiss*, *Holstein Friesian*, *Jersey*, and *Red Dane*). Experimental results demonstrate a significant performance disparity. The model trained from scratch achieved a maximum accuracy of only 81%, whereas the Transfer Learning-based model attained an accuracy of 95%. This 14% accuracy improvement demonstrates that utilizing pre-trained weights combined with Data Augmentation is highly effective in recognizing the visual characteristics of cattle breeds with high precision.

Penulis Korespondensi:

Adz Dziki Tamyizur Rijal,
Program Studi Teknik Informatika,
Universitas Trunojoyo Madura
Email: adriadtr@gmail.com

This is an open access article under the [CC BY-SA](#) license



1. PENDAHULUAN

Sektor peternakan memiliki peran strategis dalam ketahanan pangan nasional dan perekonomian masyarakat. Identifikasi ras sapi secara akurat menjadi fondasi penting dalam manajemen peternakan modern, meliputi program pemuliaan ternak, pencatatan silsilah, sertifikasi genetik, hingga optimalisasi produksi susu dan daging [1]. Di Indonesia, komposisi populasi sapi potong berdasarkan bangsa dan tingkat umur terus mengalami perubahan dinamis, sehingga membutuhkan sistem identifikasi yang akurat dan efisien [2]. Namun, metode identifikasi konvensional yang mengandalkan pengamatan visual oleh tenaga ahli menghadapi beberapa keterbatasan signifikan, seperti tingginya tingkat subjektivitas penilaian, keterbatasan ketersediaan tenaga ahli di daerah terpencil, serta inefisiensi waktu dan biaya operasional pada skala peternakan besar [3].


Perkembangan teknologi *Computer Vision* dan *Deep Learning* dalam beberapa tahun terakhir membuka peluang implementasi sistem identifikasi otomatis berbasis citra digital [4]. *Convolutional Neural Network* (CNN) telah terbukti unggul dalam berbagai tugas klasifikasi citra kompleks, termasuk di bidang pertanian dan peternakan [5][6]. Beberapa penelitian di Indonesia telah menunjukkan keberhasilan penerapan CNN untuk klasifikasi berbagai komoditas peternakan, seperti klasifikasi sapi perah dan non-perah yang mencapai akurasi 96% menggunakan arsitektur Xception [7], serta sistem identifikasi moncong sapi untuk pengenalan individu ternak [8]. Arsitektur ResNet-50, yang memperkenalkan mekanisme *Residual Learning* untuk mengatasi masalah *Vanishing Gradient* pada jaringan yang sangat dalam, menjadi salah satu pilihan populer untuk tugas klasifikasi dengan tingkat kompleksitas tinggi [9]. Beberapa studi terkini menunjukkan keunggulan ResNet-50 dalam berbagai aplikasi klasifikasi citra, termasuk klasifikasi daging ayam [10], klasifikasi ras sapi dengan akurasi mencapai 95,63% menggunakan ResNet50V2 [11], dan klasifikasi pneumonia dengan akurasi 93,26% [12].

Salah satu tantangan utama dalam penerapan *Deep Learning* pada domain spesifik seperti klasifikasi ras ternak adalah keterbatasan jumlah data latih [13]. Melatih model CNN dari awal (*training from scratch*) membutuhkan dataset dalam skala besar agar dapat menghasilkan representasi fitur yang optimal [14]. Dalam konteks ini, metode *Transfer Learning* menjadi solusi efektif dengan memanfaatkan pengetahuan visual umum yang telah dipelajari model pada dataset berskala besar seperti ImageNet, kemudian mengadaptasikannya pada tugas klasifikasi yang lebih spesifik [15][16]. Selain pemilihan arsitektur model, optimalisasi *hyperparameter* juga memiliki pengaruh krusial terhadap kinerja akhir sistem klasifikasi [17]. *Learning rate*, sebagai salah satu *hyperparameter* paling sensitif, menentukan seberapa besar langkah pembaruan bobot pada setiap iterasi pelatihan. Penelitian di Indonesia mengenai optimalisasi *hyperparameter* pada klasifikasi daging sapi dan babi menunjukkan bahwa kombinasi augmentasi data dengan pengaturan *hyperparameter* yang tepat dapat meningkatkan akurasi hingga 93% [18].

Penelitian ini bertujuan untuk mengoptimalkan kinerja klasifikasi citra ras sapi melalui pendekatan *Transfer Learning* menggunakan arsitektur ResNet-50, serta melakukan analisis komparatif dengan metode pelatihan dari awal. Selain itu, penelitian ini juga mengevaluasi dampak variasi *hyperparameter* terhadap akurasi dan stabilitas model. Dengan demikian, hasil penelitian diharapkan dapat memberikan kontribusi praktis berupa rekomendasi konfigurasi optimal untuk pengembangan sistem identifikasi ras sapi otomatis yang akurat, efisien, dan dapat diimplementasikan pada kondisi dataset terbatas.

2. METODE PENELITIAN

Penelitian ini dirancang dengan pendekatan eksperimental kuantitatif untuk mengoptimalkan kinerja klasifikasi ras sapi. Alur penelitian dilaksanakan melalui serangkaian tahapan sistematis yang saling terintegrasi, dimulai dari manajemen data hingga pengujian performa, sebagaimana diilustrasikan secara komprehensif pada Gambar 1.



Gambar 1. Arsitektur Penelitian

Tahapan penelitian diawali dengan penyiapan dataset Citra Sapi yang dipartisi menjadi tiga bagian terpisah, yaitu data *training*, *validation*, dan *testing*. Khusus pada data *training*, diterapkan teknik augmentasi data (meliputi *random rotation*, *flip*, dan *zoom*) untuk memperkaya variasi data sebelum masuk ke tahap selanjutnya. Seluruh data kemudian melalui proses *Preprocessing* yang meliputi penyeragaman dimensi citra (*resize*) menjadi 224×224 piksel dan Normalisasi berbasis statistik ImageNet. Tahap inti penelitian adalah pembangunan Base Model ResNet-50, di mana dilakukan komparasi antara strategi *Transfer Learning* dan pelatihan dari awal (*Scratch*). Proses Pelatihan Model dijalankan menggunakan *optimizer* Adam disertai *Hyperparameter Tuning* untuk menghasilkan *Trained Model* dengan bobot terbaik. Penelitian diakhiri dengan tahap hasil evaluasi menggunakan data *testing* untuk mengukur kinerja akurasi model secara objektif.

2.1. Data Collection

Tahapan ini merupakan langkah awal dalam pengumpulan data berupa gambar morfologi sapi. Dataset diambil pada laman penyedia dataset *public* yaitu kaggle. Dataset terdiri dari 1.251 gambar dan terdiri atas 5 (Lima) kelas antara lain: *Ayrshire*, *Brown Swiss*, *Holstein Friesian*, *Jersey*, dan *Red Dane*.

2.2. Preprocessing

Sebelum data citra diproses oleh model, dilakukan tahapan pra-pemrosesan untuk menyesuaikan format data dengan spesifikasi input arsitektur ResNet-50 [9]. Tahapan preprocessing yang sistematis sangat krusial dalam meningkatkan performa model *deep learning*, terutama pada dataset dengan ukuran terbatas [13]. *Resizing* atau mengubah resolusi spasial seluruh citra menjadi dimensi tetap 224×224 piksel sesuai dengan spesifikasi input standar ResNet-50. Langkah ini penting karena arsitektur CNN membutuhkan dimensi input yang seragam untuk operasi konvolusi [9]. Proses ini dilakukan dengan metode interpolasi bilinear untuk mempertahankan kualitas visual citra.

Setelah itu, maka dilakukan normalisasi piksel intensitas dengan menggunakan fungsi *preprocess_input* dari TensorFlow/Keras yang secara otomatis melakukan transformasi nilai piksel sesuai dengan standar *preprocessing* ImageNet. Proses ini mengonversi nilai piksel dari rentang $[0, 255]$ ke rentang yang sesuai untuk model *pre-trained*, yang umumnya melibatkan pengurangan nilai *mean* dan pembagian dengan standar deviasi dari dataset *ImageNet*. Teknik normalisasi ini bertujuan untuk memusatkan distribusi data di sekitar nol dan menstabilkan proses pembelajaran, sehingga mempercepat konvergensi gradien selama pelatihan [13].


Untuk mengatasi keterbatasan jumlah data dan meningkatkan kemampuan generalisasi model, diterapkan teknik augmentasi data secara *real-time* selama proses pelatihan menggunakan *layer* augmentasi TensorFlow [17]. Penelitian menunjukkan bahwa augmentasi data dapat meningkatkan performa model secara

signifikan, terutama pada dataset dengan ukuran terbatas [10]. Teknik augmentasi yang diimplementasikan meliputi:

1. *Random Horizontal Flip*: Membalik citra secara horizontal dengan probabilitas 50%, membantu model mengenali objek dari berbagai orientasi lateral.
2. *Random Rotation*: Merotasi citra secara acak hingga maksimal 10 derajat (0.10 radian), mensimulasikan variasi sudut pengambilan gambar di lapangan.
3. *Random Zoom*: Melakukan zoom in/out secara acak hingga 10%, membantu model mengenali objek pada berbagai skala dan jarak.
4. *Random Contrast*: Mengubah kontras citra secara acak hingga 10%, meningkatkan *robustness* model terhadap variasi kondisi pencahayaan.

2.3. ResNet-50

Arsitektur utama yang digunakan dalam penelitian ini adalah ResNet-50 (*Residual Network* dengan kedalaman 50 *layer*). Pemilihan ResNet-50 didasarkan pada kemampuannya mengatasi masalah *Vanishing Gradient* pada jaringan saraf yang sangat dalam melalui mekanisme *Skip Connection* atau *Residual Block*. Visualisasi lengkap mengenai susunan layer per *stage* dan transformasi dimensi data dari *input* hingga *output* dapat dilihat secara komprehensif pada ilustrasi berikut:



Gambar 2. Lapisan Model ResNet-50 Per Tahap

Secara struktural, arsitektur ResNet-50 tersusun atas lima tahapan (*stages*) utama yang memproses citra input secara hierarkis, sebagaimana diilustrasikan pada Gambar 2. Tahap pertama melakukan konvolusi awal dan *max pooling*, yang kemudian diikuti oleh empat tahapan blok residual (*Stage 2* hingga *Stage 5*). Setiap blok residual pada ResNet-50 menggunakan desain *bottleneck* yang terdiri dari tiga lapisan konvolusi (1×1 , 3×3 , dan 1×1) untuk efisiensi komputasi [9]. Dalam penelitian ini, arsitektur asli dimodifikasi dengan mengganti lapisan *Fully Connected* (FC) terakhir—yang awalnya ditujukan untuk 1000 kelas ImageNet—dengan lapisan *Global Average Pooling* diikuti oleh *Dense Layer* baru yang disesuaikan untuk klasifikasi 5 kelas ras sapi (Ayrshire, Brown Swiss, Holstein Friesian, Jersey, dan Red Dane). Pendekatan ini memanfaatkan bobot *pre-trained* dari ImageNet sebagai inisialisasi awal (*Transfer Learning*), sehingga model dapat langsung mengenali fitur visual dasar seperti tekstur dan bentuk tubuh sapi dengan presisi tinggi meskipun dilatih pada dataset yang terbatas [15][16].

2.4. Skenario Pengujian

Penelitian ini menggunakan dua skenario pengujian untuk mengevaluasi kinerja arsitektur ResNet-50 dalam klasifikasi ras sapi. Kedua skenario dirancang dengan arsitektur dan konfigurasi *hyperparameter* yang sama agar proses evaluasi bersifat objektif dan perbedaan performa sepenuhnya disebabkan oleh metode inisialisasi bobot. Skenario pertama menggunakan pendekatan *Transfer Learning*, yaitu memanfaatkan bobot awal *pre-trained* ImageNet pada *backbone* ResNet-50. Sementara itu, skenario kedua menerapkan pendekatan *training from scratch*, di mana seluruh bobot model diinisialisasi secara acak tanpa memanfaatkan *pre-trained*

weights. Keduanya menggunakan *hyperparameter* yang sama, yaitu *batch size* 32, *learning rate* 0,0001, *optimizer* Adam, dan jumlah *epoch* sebanyak 30. Pembagian dataset dilakukan secara otomatis melalui fungsi *image_dataset_from_directory*, menghasilkan proporsi 80% data untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian. Hasil yang diamati pada kedua skenario mencakup akurasi validasi, akurasi pengujian, serta *confusion matrix* sebagai ukuran kemampuan generalisasi model.

2.5. Evaluasi Performa

Evaluasi menggunakan *confusion matrix* merupakan langkah penting dalam menilai efektivitas dan kinerja suatu model klasifikasi. Matriks ini memberikan gambaran lengkap mengenai jumlah prediksi benar dan salah yang dilakukan oleh model, yaitu *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN). Melalui komponen-komponen tersebut, peneliti dapat menghitung metrik evaluasi utama seperti akurasi, presisi, *recall*, dan *F1-score* untuk setiap kelas yang diuji [19].

Dalam hal ini, *confusion matrix* dapat mengevaluasi sejauh mana model mampu membedakan setiap ras yang memiliki kemiripan morfologi yang tinggi. Bukan hanya itu tetapi juga mengungkap kelemahan spesifik yang dapat menjadi dasar perbaikan di tahap pengembangan berikutnya. Selain itu, penggunaan metrik turunan seperti akurasi, presisi, *recall*, dan *F1-score* memberikan penilaian yang lebih komprehensif mengenai keseimbangan performa model dalam menangani prediksi benar maupun salah. Adapun rumus yang digunakan adalah sebagai berikut:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4)$$


Akurasi mengukur proporsi prediksi yang benar secara keseluruhan. Presisi menilai sejauh mana prediksi positif benar-benar tepat. *Recall* mengukur kemampuan model dalam menemukan seluruh sampel positif yang benar, sedangkan *F1-score* memberikan nilai rata-rata harmonik antara presisi dan *recall*, sehingga menghasilkan evaluasi yang seimbang ketika terjadi ketidakseimbangan antara FP dan FN [19].

3. HASIL DAN ANALISIS

Pada bagian ini memaparkan analisis komparatif kinerja model ResNet-50 dalam mengklasifikasikan 5 ras sapi (*Ayrshire*, *Brown Swiss*, *Holstein Friesian*, *Jersey*, dan *Red Dane*) berdasarkan dua pendekatan eksperimen: pelatihan dari awal (*Scratch*) dan *Transfer Learning*. Evaluasi dilakukan menggunakan 250 data uji yang tidak dilibatkan selama proses pelatihan untuk menjamin objektivitas hasil.

3.1. Analisis Kinerja Model Non-Transfer Learning (Scratch)

Pada skenario pertama, model dilatih dari nol dengan inisialisasi bobot acak tanpa memanfaatkan pengetahuan sebelumnya. Proses pelatihan menunjukkan dinamika yang kurang stabil, di mana model kesulitan menemukan fitur global yang representatif dari citra sapi karena keterbatasan jumlah data latih. Hal ini terlihat jelas dari grafik pergerakan akurasi dan *loss* selama proses *training* berlangsung. Fenomena ini mengindikasikan bahwa jaringan saraf dalam (*deep neural network*) membutuhkan inisialisasi yang lebih baik daripada sekadar nilai acak. Detail pergerakan metrik evaluasi selama *epoch* berjalan dapat dilihat pada visualisasi grafik berikut:




Gambar 3. Grafik Akurasi dan Loss pada Pelatihan Scratch

Meskipun akurasi pelatihan (*training accuracy*) terus meningkat hingga mendekati 90%, akurasi validasi (*validation accuracy*) mengalami stagnasi dan fluktuasi yang cukup tinggi di kisaran 80%. Celah (*gap*) yang lebar antara garis pelatihan dan validasi mengindikasikan terjadinya *overfitting*, di mana model cenderung menghafal data latih namun gagal melakukan generalisasi pada data baru. Mekanisme *Early Stopping* menghentikan proses pelatihan secara otomatis pada epoch ke-28 karena tidak adanya perbaikan kinerja validasi dalam 7 iterasi berturut-turut.

Hasil evaluasi akhir menunjukkan model ini hanya mencapai akurasi 81%. Berdasarkan laporan klasifikasi, model memiliki performa terendah dalam mengenali ras *Brown Swiss* (Precision 0.69) dan *Ayrshire* (Precision 0.72), yang sering tertukar dengan ras lain yang memiliki kemiripan warna bulu.

3.2. Analisis Kinerja Model *Transfer Learning*

Berbeda dengan skenario sebelumnya, skenario kedua menerapkan *Transfer Learning* dengan memanfaatkan bobot *pre-trained* ImageNet sebagai titik awal. Strategi ini dikombinasikan dengan teknik *Fine-Tuning* pada layer-layer atas untuk menyesuaikan fitur visual umum menjadi fitur spesifik ras sapi. Pendekatan ini terbukti sangat efektif dalam mempercepat konvergensi model dan meningkatkan stabilitas pelatihan secara signifikan. Model tidak lagi memulai pembelajaran dari nol, melainkan melakukan adaptasi halus (*fine-tuning*) terhadap representasi fitur yang sudah kokoh. Stabilitas proses pelatihan model usulan ini divisualisasikan pada grafik berikut:



Gambar 4. Grafik Akurasi dan Loss pada Pelatihan Transfer Learning

Grafik pada Gambar 4 menunjukkan tren peningkatan akurasi yang sangat konsisten dan berimpitan antara data latih dan validasi. Hal ini menandakan bahwa model memiliki kemampuan generalisasi yang sangat baik (*robust*) dan tidak mengalami *overfitting* yang berarti. Pada pengujian akhir, model ini berhasil mencapai akurasi 95%. Detail performa per kelas disajikan dalam Tabel 1, yang memperlihatkan nilai presisi dan *recall* yang tinggi bahkan untuk ras yang memiliki kemiripan fisik.


Tabel 1. Laporan Klasifikasi Model *Transfer Learning*

Kelas Ras Sapi	Precision	Recall	F1-Score
<i>Ayrshire</i>	0.94	0.94	0.94
<i>Brown Swiss</i>	0.98	0.98	0.98
<i>Holstein Friesian</i>	0.96	1.00	0.98
<i>Jersey</i>	0.93	0.87	0.90
<i>Red Dane</i>	0.95	0.97	0.96
Akurasi Total	0.95		

Tabel 2 memperlihatkan bahwa model mampu mengenali ras *Holstein Friesian* dengan sempurna (*Recall* 1.00) dan *Brown Swiss* dengan presisi sangat tinggi (0.98). Kombinasi fitur visual dasar yang dibawa dari ImageNet terbukti sangat efektif dalam membedakan pola morfologi sapi.

3.3. Confusion Matrix

Untuk memahami di mana letak kesalahan model secara spesifik, dilakukan analisis menggunakan *confusion matrix*. Matriks ini memetakan prediksi model terhadap label sebenarnya, sehingga kita bisa melihat apakah ada ras tertentu yang sering tertukar. Analisis ini krusial mengingat beberapa ras sapi seperti *Jersey* dan *Brown Swiss* memiliki kemiripan warna bulu yang dominan coklat. Perbandingan visual *confusion matrix* antara kedua model ditampilkan di bawah ini untuk memperjelas perbedaan kualitas prediksi keduanya.

**Gambar 5. Perbandingan *Confusion Matrix Transfer Learning* dan *Scratch***

Berdasarkan Gambar 5, model *Transfer Learning* menunjukkan performa yang sangat solid dengan mayoritas prediksi berkumpul di garis diagonal utama (warna terang). Kesalahan prediksi sangat minim, misalnya hanya terdapat sedikit kebingungan antara ras *Jersey* dan *Red Dane*. Sebaliknya, pada model *Scratch* (tidak ditampilkan), kesalahan tersebar lebih luas antar kelas. Peningkatan performa ini menegaskan bahwa fitur visual yang dibawa dari ImageNet sangat membantu model dalam membedakan nuansa morfologi halus yang membedakan antar ras sapi.

3.4. Komparasi Akhir

Perbandingan kuantitatif antara kedua pendekatan dirangkum dalam Tabel 2.

Tabel 2. Perbandingan Performa Model

Metode	Epoch Stop	Akurasi Uji	Kesimpulan
<i>Non-Transfer Learning</i>	28	81%	Rentan <i>Overfitting</i>
<i>Transfer Learning</i>	50	95%	Optimal & Stabil

Peningkatan akurasi sebesar 14% menegaskan bahwa pada dataset dengan jumlah terbatas (1.251 citra), penggunaan *Transfer Learning* adalah mutlak diperlukan. Melatih arsitektur dalam seperti ResNet-50 dari awal tanpa data berskala masif akan menghasilkan filter fitur yang kurang optimal, sedangkan penggunaan bobot *pre-trained* memberikan inisialisasi fitur yang kuat yang kemudian disempurnakan melalui proses *Fine-Tuning* dan augmentasi data.

4. KESIMPULAN

Penelitian ini berhasil mengevaluasi efektivitas arsitektur ResNet-50 untuk klasifikasi ras sapi melalui pendekatan *Transfer Learning* dan optimalisasi *hyperparameter*. Berdasarkan hasil eksperimen, dapat disimpulkan bahwa metode *Transfer Learning* terbukti jauh lebih unggul dibandingkan pelatihan dari awal (*training from scratch*). Model ResNet-50 yang dilatih tanpa bobot awal hanya mampu mencapai akurasi pengujian sebesar 81%, sedangkan penerapan *Transfer Learning* dengan bobot *pre-trained* ImageNet berhasil meningkatkan akurasi secara signifikan hingga mencapai 95%.

Selain itu, pengaturan *hyperparameter Learning Rate* memiliki dampak krusial terhadap stabilitas dan performa akhir model. Penggunaan *Learning Rate* yang lebih kecil (0.0001) terbukti memberikan hasil yang lebih optimal dan stabil dibandingkan nilai standar (0.001), dengan capaian akurasi tertinggi sebesar 95%. Meskipun demikian, model masih menghadapi tantangan dalam membedakan ras dengan kemiripan visual tinggi seperti *Jersey* dan *Red Dane*, khususnya dalam mengidentifikasi fitur pembeda spesifik pada pigmentasi warna maupun corak. Untuk penelitian selanjutnya, disarankan untuk menerapkan teknik *Fine-Tuning* lanjutan dengan membuka blokir (*unfreeze*) pada beberapa *layer* terakhir ResNet-50 atau menerapkan teknik *Data Augmentation* yang lebih variatif untuk meningkatkan kemampuan model dalam menangkap fitur-fitur detail yang membedakan ras-ras yang mirip tersebut.

REFERENSI

- [1] J. Xu, B. Gu, dan G. Tian, "Review of agricultural IoT technology," 1 Januari 2022, *KeAi Communications Co.* doi: 10.1016/j.aiaa.2022.01.001.
- [2] S. Zamroni dkk., "Sistemasi: Jurnal Sistem Informasi Identifikasi Moncong Sapi menggunakan Metode Jaringan Saraf Tiruan Konvolusional (CNN)," *Sistemasi: Jurnal Sistem Informasi*, vol. 13, no. 6, hlm. 2479–2493, 2024, [Daring]. Tersedia pada: <http://sistemasi.ftik.unisi.ac.id>
- [3] K. Komposisi Populasi Sapi Potong Berdasarkan Bangsa, J. Kelamin, dan Tingkat Umur di Daerah Suliki Kabupaten Lima Puluh Kota, F. Lismanto Syaiful, A. Fernando dan Khasrad, dan K. Kunci, "A Study of Beef Cattle Population Composition Based on Breed, Gender, and Age Levels in the Suliki Area of the Lima Puluh Kota District," *Journal of Livestock and Animal Health JLAH*, vol. 7, no. 2, hlm. 32–41, 2024, doi: 10.32530/jlah.v7i2.47.
- [4] Y. Qiao, C. Clark, S. Lomax, H. Kong, D. Su, dan S. Sukkarieh, "Automated Individual Cattle Identification Using Video Data: A Unified Deep Learning Architecture Approach," *Frontiers in Animal Science*, vol. 2, 2021, doi: 10.3389/fanim.2021.759147.
- [5] L. Alzubaidi dkk., "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *J Big Data*, vol. 8, no. 1, Des 2021, doi: 10.1186/s40537-021-00444-8.
- [6] B. Xu dkk., "Evaluation of deep learning for automatic multi-view face detection in cattle," *Agriculture (Switzerland)*, vol. 11, no. 11, Nov 2021, doi: 10.3390/agriculture11111062.
- [7] L. Maramis, I. Nurtanio, dan H. Zainuddin, "Klasifikasi Sapi Perah dan Non-Perah Menggunakan Algoritma Convolutional Neural Network," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. 2, hlm. 664–674, Apr 2025, doi: 10.57152/malcom.v5i2.1824.
- [8] M. Akbar, A. S. Purnomo, dan S. Supatman, "Multi-Scale Convolutional Networks untuk Pengenalan Rambu Lalu Lintas di Indonesia," *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, vol. 11, no. 3, hlm. 310–315, Des 2022, doi: 10.32736/sisfokom.v11i3.1452.
- [9] M. Shafiq dan Z. Gu, "Deep Residual Learning for Image Recognition: A Survey," 1 September 2022, *MDPI*. doi: 10.3390/app12188972.
- [10] F. Yalda Sulistia dan A. Vatesia, "Penerapan Deep Learning Menggunakan Convolutional Neural Network (CNN) Untuk Klasifikasi Daging Ayam Menggunakan Arsitektur Resnet-50," *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 7, no. 3, 2024.
- [11] A. Salim dan M. Akbar, "Klasifikasi Ras Sapi Menggunakan Convolutional Neural Network," *Jurnal Sains Informatika Terapan (JSIT)*, vol. 4, no. 3, hlm. 664–673, 2025.
- [12] M. Agil Izzulhaq, "Indonesian Journal of Mathematics and Natural Sciences Penerapan Algoritma Convolutional Neural Network Arsitektur ResNet50V2 Untuk Mengidentifikasi Penyakit Pneumonia," 2024. [Daring]. Tersedia pada: <https://journal.unnes.ac.id/journals/JM/index>

- [13] D. Tribuana, Hazriani, dan A. L. Arda, "Image Preprocessing Approaches Toward Better Learning Performance with CNN," *Jurnal RESTI*, vol. 8, no. 1, hlm. 1–9, Feb 2024, doi: 10.29207/resti.v8i1.5417.
- [14] I. A. P. F. Imawati, M. Sudarma, I. K. G. Darma Putra, I. P. A. Bayupati, dan M. Jo, "Training VGG16, MobileNetV1 and Simple CNN Models from Scratch for Balinese Inscription Recognition," *Lontar Komputer: Jurnal Ilmiah Teknologi Informasi*, vol. 15, no. 03, hlm. 149, Jan 2025, doi: 10.24843/lkjiti.2024.v15.i03.p01.
- [15] L. Alzubaidi dkk., "Deepening into the suitability of using pre-trained models of ImageNet against a lightweight convolutional neural network in medical imaging: an experimental study," *PeerJ Comput Sci*, vol. 7, hlm. 1–27, 2021, doi: 10.7717/peerj-cs.715.
- [16] M. B. Hossain, S. M. H. S. Iqbal, M. M. Islam, M. N. Akhtar, dan I. H. Sarker, "Transfer learning with fine-tuned deep CNN ResNet50 model for classifying COVID-19 from chest X-ray images," *Inform Med Unlocked*, vol. 30, Jan 2022, doi: 10.1016/j.imu.2022.100916.
- [17] C. Shorten dan T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *J Big Data*, vol. 6, no. 1, Des 2019, doi: 10.1186/s40537-019-0197-0.
- [18] J. A1 dan S. Sanjaya, "Optimalisasi Convolutional Neural Network Menggunakan Augmentasi dan Hyperparameter untuk Klasifikasi Daging Sapi dan Daging Babi," *JUSTIN (Jurnal Sistem dan Teknologi Informasi)*, vol. 12, no. 4, hlm. 623–629, 2024, doi: 10.26418/justin.v12i4.80337.
- [19] A. Danang Krismawan, "Tomato Leaf Diseases Classification using Convolutional Neural Networks with Transfer Learning Resnet-50," *Computer Network, Computing, Electronics, and Control Journal*, vol. 9, no. 2, hlm. 149–158, 2024.