



## KLASIFIKASI RAS SAPI MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK

Agus Salim<sup>1)</sup>, Mutaqin Akbar<sup>2)</sup>

<sup>1,2</sup>Informatika, Universitas Mercu Buana Yogyakarta

Corresponding Author: <sup>1</sup> [211110088@student.mercubuana-yogya.ac.id](mailto:211110088@student.mercubuana-yogya.ac.id)

### Article Info

#### Article history:

Received: July 14, 2025  
Revised: Sept 10, 2025  
Accepted: Okt 20, 2025  
Published: Nov 11, 2025

#### Keywords:

CNN  
ResNet50V2  
*Cattle classification*  
*image classification*  
*transfer learning*

### ABSTRACT

Penelitian ini bertujuan mengembangkan model klasifikasi otomatis berbasis *Convolutional Neural Network* (CNN) untuk mengidentifikasi lima jenis ras sapi, yaitu Bali, Brahma, Angus, Holstein, dan Beefmaster. Data citra sapi diperoleh melalui dokumentasi lapangan serta sumber dataset publik, dengan total 1.500 gambar yang dibagi ke dalam tiga subset: pelatihan, validasi, dan pengujian. Model yang digunakan adalah *ResNet50V2* dengan pendekatan *transfer learning*, yang dilatih menggunakan teknik data *augmentation* dan normalisasi citra untuk meningkatkan generalisasi model. Evaluasi performa dilakukan dengan menggunakan sejumlah metrik, meliputi akurasi, presisi, recall, F1-score, serta analisis *confusion matrix* dan visualisasi hasil prediksi. Hasil eksperimen menunjukkan bahwa model *ResNet50V2* mampu mengklasifikasikan ras sapi dengan akurasi mencapai 95,63% pada data uji. Rata-rata nilai *F1-score* untuk seluruh kelas adalah 0,95, yang mencerminkan kinerja model yang tinggi dan seimbang. Berdasarkan *confusion matrix*, sebagian besar kelas dapat dikenali secara akurat, meskipun masih terdapat kesalahan klasifikasi pada kelas dengan kemiripan visual yang tinggi. Temuan ini menunjukkan bahwa pendekatan CNN, khususnya dengan arsitektur *ResNet50V2*, memiliki potensi yang kuat sebagai solusi sistem identifikasi otomatis dalam sektor peternakan, terutama dalam mendorong digitalisasi dan efisiensi manajemen ternak.



This is an open-access article distributed under the terms of the Creative Commons Attribution-NonCommercial 4.0 International (CC BY SA 4.0)

## 1. INTRODUCTION

Sapi merupakan spesies mamalia ruminansia dari famili *Bovidae* yang secara luas dibudidayakan oleh manusia sebagai komoditas ternak. Menurut Badan Pusat Statistik pada tahun 2020 terdapat 17.466.792 ekor populasi sapi potong yang ada di Indonesia dan 568.265 ekor populasi sapi perah yang ada di Indonesia [1]. Industri peternakan sapi di Indonesia terus mengalami perkembangan yang signifikan, baik pada skala kecil maupun besar. Pertumbuhan ini didorong oleh meningkatnya permintaan pasar serta kemajuan teknologi yang mendukung efisiensi produksi dan kemudahan dalam pengelolaan usaha peternakan [2]. Ternak sapi menjadi salah satu komoditas ekonomi yang memberikan keuntungan yang sangat besar bagi masyarakat [3]. Sapi menjadi sumber daya genetik ternak yang penting karena berkontribusi besar dalam menghasilkan daging dan susu sebagai sumber protein hewani bagi masyarakat.

Selain itu, sapi juga berfungsi sebagai sumber tenaga kerja dan penghasil pupuk [4].

Sapi secara umum dibedakan menjadi dua kategori utama, yaitu sapi perah dan sapi potong. Jenis sapi perah, seperti Holstein, memiliki ciri khas tertentu yang membedakannya dari sapi potong, seperti sapi Angus. Namun, karena beberapa jenis sapi memiliki kesamaan fisik, bagi mereka yang belum berpengalaman, hal ini dapat mengarah pada kesalahan dalam proses identifikasi [5]. Metode tradisional dalam klasifikasi ras sapi, seperti penandaan telinga (*ear tagging*), pemotongan telinga (*ear notching*), dan penggunaan perangkat elektronik, telah umum digunakan untuk identifikasi individu. Namun, pendekatan-pendekatan ini memiliki sejumlah keterbatasan, termasuk risiko kehilangan atau kerusakan alat, potensi duplikasi identitas, serta kemungkinan terjadinya pemalsuan nomor identifikasi [6]. Kesalahan dalam identifikasi dapat menyebabkan

penurunan produktivitas, pengelolaan pakan yang kurang efisien, serta potensi terjadinya persilangan yang tidak diinginkan, yang pada akhirnya memengaruhi kualitas hasil peternakan secara keseluruhan. Hal ini menjadi lebih signifikan pada peternak yang masih menggunakan metode tradisional secara intensif [7].

Berbagai algoritma klasifikasi konvensional telah banyak diterapkan dalam identifikasi objek berbasis citra, termasuk dalam mengenali jenis atau ras hewan ternak seperti sapi. Salah satu metode yang paling sederhana namun cukup efektif adalah *K-Nearest Neighbor* (KNN), yang mengklasifikasikan sampel baru berdasarkan kemiripan fitur dengan sejumlah tetangga terdekat dari data latih. Popularitas algoritma ini didukung oleh kemudahan implementasinya dan karena tidak memerlukan proses pelatihan model yang kompleks. Dalam penelitian yang dilakukan oleh Kuswati et al. (2024), KNN digunakan untuk mengklasifikasikan ras sapi Madura berdasarkan ciri morfometrik seperti tinggi pundak, panjang tubuh, dan lingkar dada. Hasilnya menunjukkan bahwa KNN mampu membedakan ras sapi secara akurat dengan akurasi 88,89%, meskipun hanya menggunakan data numerik non-citra [8].

Selain KNN, algoritma lain yang juga sering digunakan adalah *Support Vector Machine* (SVM). SVM bekerja dengan mencari *hyperplane* optimal yang memisahkan data ke dalam kelas yang berbeda. Algoritma ini dikenal efektif untuk data berdimensi tinggi dan jumlah sampel yang terbatas. Samudra et al. (2023) memanfaatkan SVM bersama KNN dan regresi logistik untuk mengklasifikasikan jenis hewan berdasarkan citra, menggunakan fitur yang diambil dari model *pre-trained* VGG16. Model gabungan ini berhasil mencapai akurasi hingga 84% [9], menunjukkan bahwa metode konvensional seperti SVM masih memiliki relevansi dalam tugas klasifikasi citra, terutama jika dikombinasikan dengan teknik ekstraksi fitur yang tepat. Namun, pendekatan konvensional memiliki keterbatasan, terutama karena bergantung pada ekstraksi fitur secara manual dan cenderung sensitif terhadap perubahan pencahayaan, orientasi, dan latar belakang citra. Keakuratan klasifikasi sangat bergantung pada kualitas fitur yang diperoleh secara eksplisit, sementara tidak semua informasi visual kompleks dapat direpresentasikan dengan baik melalui teknik manual.

Hal ini mendorong perlunya pendekatan yang mampu melakukan ekstraksi fitur secara otomatis, yang kemudian membuka jalan bagi pemanfaatan arsitektur *Convolutional Neural Network* (CNN) dalam berbagai penelitian klasifikasi citra, termasuk dalam pengenalan ras sapi. CNN sebagai bagian dari teknologi *deep learning* memiliki kemampuan dalam mengekstraksi fitur visual kompleks dari citra digital sapi, yang kemudian digunakan untuk klasifikasi ras dengan akurasi tinggi [10], [12]. Dalam konteks populasi sapi, CNN mampu mengekstraksi fitur visual

seperti bentuk kepala, warna kulit, dan pola moncong yang menjadi pembeda utama antar ras [13]. Beberapa studi mendukung efektivitas CNN, seperti penelitian Michael dan Wijang Widhiarso (2023) yang menggunakan ResNet-50 untuk klasifikasi 14 spesies ikan hiu dan mencapai akurasi 96,16% [14]. Penelitian oleh Raihan Maulana et al. (2023) pada 30 spesies burung mencapai akurasi 96,30% pada data pelatihan dan 81,33% pada data validasi [15], sementara Cut Agusniar dan Della Adelia (2024) melaporkan akurasi 99,17% pada pelatihan dan 88,13% pada validasi untuk klasifikasi 12 ras kucing [16]. Studi oleh Budi Hartanto dan Teguh Susyanto (2023) menggunakan *transfer learning* dengan ResNet-50 untuk mengenali hewan Samoyed, dan mencapai akurasi 97% [17].

Melihat urgensi kebutuhan akan sistem identifikasi ras sapi yang akurat, cepat, dan adaptif terhadap populasi yang beragam, serta efektivitas CNN dalam tugas klasifikasi berbasis citra, maka penelitian ini dilakukan untuk mengembangkan model klasifikasi ras sapi berbasis CNN. Diharapkan hasil dari penelitian ini dapat mendukung digitalisasi sistem peternakan, khususnya dalam otomasi identifikasi dan pengelompokan ras, yang pada akhirnya meningkatkan efisiensi dan produktivitas peternakan sapi. Selain itu, kontribusi penelitian ini juga dapat memperkuat ekosistem teknologi peternakan presisi di era revolusi industri 4.0..

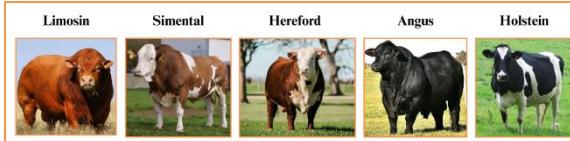
## 2. MATERIAL AND METHODS

### 2.1 Materials

#### 2.1.1 Sapi (Bos)

Sapi merupakan hewan ternak yang termasuk dalam genus *Bos*, famili *Bovidae*. Sapi domestik modern telah menyebar ke seluruh dunia dan mendiami lingkungan yang bervariasi dan tidak dapat diprediksi[18]. Menurut Maignel et al. (2021), sapi domestik modern berasal dari aurochs, spesies hewan liar yang menghuni hutan Eropa dan Asia di masa lalu. Hasil studi genetik menunjukkan bahwa populasi sapi dunia berasal dari 80 ekor aurochs betina yang didomestikasi di wilayah Turki tenggara saat ini. Setelah 10.500 tahun, populasi bovine di seluruh dunia telah melebihi 1,4 miliar dengan dua subspecies utama.[19]

Secara taksonomi, sapi domestik modern umumnya diklasifikasikan ke dalam dua spesies utama yaitu *Bos taurus* (sapi taurine) dan *Bos indicus* (sapi zebu). Menurut penelitian terbaru, kedua bentuk sapi ini saat ini diklasifikasikan sebagai *Bos taurus* dan *Bos indicus* dan dibedakan terutama berdasarkan ada atau tidaknya punuk [20]. *Bos taurus* merupakan sapi tanpa punuk dengan telinga yang relatif pendek dan umumnya beradaptasi dengan iklim dingin hingga sedang.



Gambar 1. Sapi Bos taurus (Sumber: Pixabay.com)

Sementara itu, *Bos indicus* memiliki ciri khas punuk yang menonjol di bagian pundak, telinga yang panjang dan menggantung, serta kemampuan adaptasi yang baik terhadap iklim panas dan tropis.



Gambar 2. Sapi Bos indicus (Sumber: Pixabay.com)

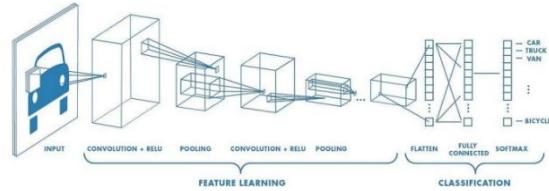
### 2.1.2 Computer vision

Computer vision merupakan cabang ilmu komputer yang berfokus pada kemampuan mesin untuk secara otomatis memahami dan menafsirkan informasi visual dari gambar atau video. Teknologi ini telah digunakan dalam berbagai bidang, seperti pengenalan wajah, deteksi objek, dan analisis citra medis. Berkat perkembangan machine learning dan deep learning, kemampuan sistem untuk mengenali pola visual yang kompleks semakin meningkat secara signifikan. Saat ini, computer vision telah menjadi komponen penting dalam berbagai sektor, termasuk sistem keamanan, kendaraan otonom, dan layanan kesehatan, menjadikannya salah satu teknologi utama dalam mendukung otomatisasi dan transformasi digital[21].

### 2.1.3 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan algoritma pembelajaran yang dirancang untuk mengenali dan memahami informasi visual dari sebuah citra. CNN telah terbukti efektif dalam berbagai tugas pengolahan citra, seperti segmentasi, klasifikasi, deteksi objek, dan aplikasi serupa lainnya[22]. CNN termasuk dalam kelompok Deep Neural Networks dan dirancang khusus untuk menangani data visual seperti gambar. Keunggulan utama Convolutional Neural Network (CNN) adalah kemampuannya memanfaatkan fitur-fitur dari berbagai tingkat baik tingkat rendah maupun tinggi secara bersamaan dalam proses klasifikasi. Kemampuan ini berkontribusi signifikan terhadap peningkatan akurasi dalam mengenali objek[23]. Kemampuan ini juga menjadikan CNN sangat efektif dalam tugas klasifikasi citra dan berbagai aplikasi visual lainnya[24]. Salah satu kelebihan utama CNN terletak pada kemampuannya dalam mengklasifikasikan citra secara akurat. Keakuratan ini didukung oleh struktur arsitektur yang efisien dalam mengurangi jumlah parameter bebas serta kemampuannya untuk menangani berbagai bentuk deformasi pada citra input, seperti translasi, rotasi, dan

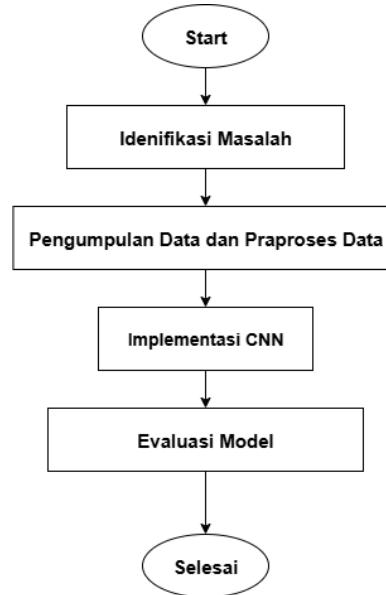
perubahan skala. Selain itu, penggunaan metode optimasi seperti Adaptive Moment Estimation (Adam) turut berkontribusi dalam meningkatkan performa model secara signifikan[25].



Gambar 3. Arsitektur CNN[26].

### 2.2 Methods

Penelitian ini dilaksanakan melalui tahapan-tahapan yang dirancang secara terstruktur dan saling mendukung satu sama lain. Setiap tahap disusun dengan cermat agar proses penelitian berlangsung secara sistematis, efisien, dan tetap sejalan dengan tujuan yang telah ditetapkan sejak awal. Alur kerja yang tersusun dengan baik menjadi dasar penting bagi kelancaran seluruh rangkaian kegiatan penelitian.



Gambar 4. Alur Penelitian

#### 2.2.1 Identifikasi masalah

Penelitian ini diawali dengan pengenalan permasalahan terkait kebutuhan akan sistem otomatis dalam mengklasifikasikan ras sapi. Kebutuhan ini muncul seiring dengan keterbatasan metode konvensional yang kurang efisien dan tidak konsisten dalam melakukan identifikasi. Pendekatan manual sering kali dipengaruhi oleh subjektivitas individu dan memerlukan keahlian khusus, sehingga kurang dapat diandalkan dalam skala besar.

Untuk menjawab tantangan tersebut, diterapkan pendekatan berbasis kecerdasan buatan, khususnya Convolutional Neural Network (CNN), yang telah terbukti handal dalam pengolahan citra dan memiliki potensi tinggi dalam meningkatkan akurasi klasifikasi

secara otomatis. CNN mampu mengenali pola visual secara mendalam melalui proses pembelajaran fitur secara hierarkis, yang sangat sesuai untuk tugas klasifikasi gambar seperti identifikasi ras sapi.

Sebagai landasan pengembangan model, dilakukan kajian pustaka terhadap berbagai penelitian terdahulu yang relevan, khususnya yang menerapkan deep learning dalam klasifikasi citra hewan. Kajian ini difokuskan pada pemahaman mengenai teknik pra-pemrosesan data, arsitektur CNN yang terbukti efektif, serta algoritma yang umum digunakan dalam klasifikasi gambar. Penelaahan dilakukan melalui berbagai sumber ilmiah seperti jurnal dan artikel akademik, dengan tujuan memperkuat pemahaman terhadap konsep dasar CNN serta menjadikan hasil penelitian sebelumnya sebagai acuan dalam merancang model klasifikasi ras sapi yang optimal.

## 2.2.2 Pengumpulan data dan Praprose data

Tahap pengumpulan data dalam penelitian ini mencakup lima kategori ras sapi, yaitu Bali, Brahma, Angus, Holstein, dan Beefmaster. Data citra untuk kelas Sapi Bali diperoleh melalui dokumentasi lapangan di peternakan Sapi Kali Jeruk, Yogyakarta, menggunakan kamera ponsel Oppo A92 beresolusi 48 megapiksel. Sementara itu, gambar untuk empat kelas lainnya Brahma[27], Angus, Beefmaster[28], dan Beefmaster[29], diperoleh dari dataset publik yang tersedia di platform Kaggle. Setiap kelas terdiri dari 300 citra, sehingga total keseluruhan dataset yang digunakan dalam penelitian ini berjumlah 1.500 gambar. Tabel berikut menunjukkan distribusi citra pada masing-masing kelas:

Tabel 1. Distribusi citra Ras sapi setiap kelas

Kelas Sapi	Citra Sapi	Jumlah Citra
Brahma		300
Holstein		300
Angus		300
Bali		300
Beefmaster		300

Setelah proses pengumpulan data selesai, langkah berikutnya adalah melakukan pra-pemrosesan data dilakukan menggunakan *ImageDataGenerator* dari Keras untuk menyesuaikan gambar dengan kebutuhan model. Seluruh citra diubah ukurannya menjadi  $224 \times 224$  piksel dan dibaca dalam batch berukuran 32 dari DataFrame yang telah disiapkan. Untuk data pelatihan dan validasi, dilakukan augmentasi berupa rotasi  $20^\circ$ , pergeseran horizontal dan vertikal sebesar 0.1, zoom sebesar 0.15, dan pembalikan horizontal guna meningkatkan variasi data dan mencegah overfitting. Augmentasi dilakukan secara langsung saat proses pelatihan tanpa menyimpan salinan baru. Sementara itu, data uji hanya mengalami proses normalisasi tanpa augmentasi untuk menjaga objektivitas evaluasi. Seluruh gambar diproses dalam format RGB. Pengacakan urutan gambar diaktifkan pada data pelatihan dan validasi, namun dinonaktifkan pada data uji untuk menjaga konsistensi hasil evaluasi.

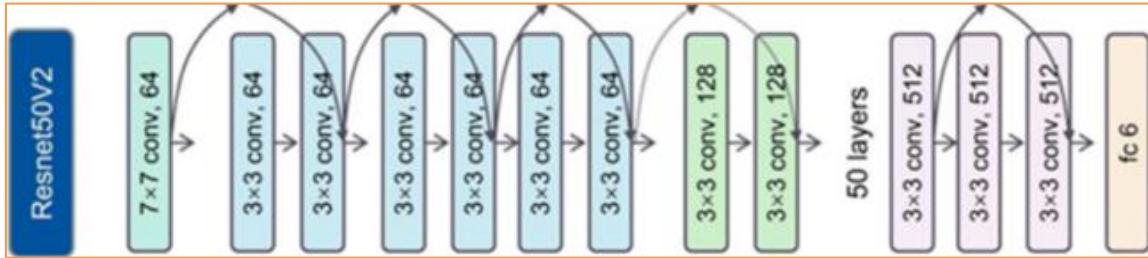
## 2.2.3 Implementasi Convolutional Neural Network

Model Convolutional Neural Network (CNN) yang digunakan dalam penelitian ini adalah ResNet50V2. Model ResNet50V2 merupakan salah satu model *pre-trained* yang telah melalui proses pelatihan awal pada dataset berskala besar, sehingga penggunaannya tidak memerlukan pengaturan ulang terhadap arsitektur lapisan internalnya. ResNet, singkatan dari *Residual Network*, adalah jenis jaringan saraf konvolisional yang dirancang untuk mengatasi permasalahan *degradasi akurasi* pada jaringan yang sangat dalam[30].

Arsitektur ResNet50V2 dirancang dengan memanfaatkan lapisan konvolisional yang sangat dalam serta koneksi residual, yang berfungsi untuk mengatasi permasalahan *vanishing gradient* dan meningkatkan stabilitas saat melatih model berskala besar. Pendekatan ini memungkinkan jaringan untuk belajar secara lebih efisien tanpa mengalami penurunan performa meskipun kedalaman arsitektur bertambah.

Setelah proses ekstraksi fitur melalui lapisan konvolusi, model ini dilengkapi dengan lapisan Global Average Pooling (GAP) yang berfungsi untuk mereduksi dimensi fitur secara signifikan. Reduksi ini tidak hanya meningkatkan efisiensi komputasi, tetapi juga membantu menghasilkan representasi fitur yang lebih ringkas dan informatif. Selanjutnya, representasi tersebut diteruskan ke beberapa lapisan Dense yang bertugas memproses informasi dan menghasilkan output akhir dalam bentuk prediksi kelas.

Pemilihan ResNet50V2 sebagai model dasar dalam penelitian ini didasarkan pada kemampuannya yang telah terbukti efektif dalam mengekstraksi fitur penting dari citra dan kemampuannya dalam menangani pelatihan pada jaringan yang sangat dalam secara lebih optimal[31].



Gambar 5. Arsiekjur Resnet 50V2

#### 2.2.4 Evaluasi model

Setelah proses pelatihan selesai, model dievaluasi dengan data uji untuk mengukur kemampuannya dalam mengenali citra yang belum pernah dilihat. Evaluasi ini menggunakan metrik seperti akurasi, presisi, recall, dan F1-score untuk menilai performa klasifikasi pada setiap kategori ras sapi. Selain itu, confusion matrix digunakan untuk mengidentifikasi pola kesalahan dalam prediksi antar kelas. Selama pelatihan, grafik *validation loss* dan *validation accuracy* dipantau guna mendeteksi potensi overfitting maupun underfitting. Akurasi, presisi, recall, dan F1-score dihitung menggunakan rumus berikut ini:

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

Akurasi mengukur seberapa sering model menghasilkan prediksi yang benar dibandingkan dengan total data yang diuji.

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

Presisi menunjukkan proporsi prediksi positif yang benar-benar tepat, dan penting saat kesalahan positif perlu diminimalka.

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

Recall mengukur kemampuan model dalam menemukan seluruh data yang benar-benar termasuk dalam kelas positif.

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

F1-score adalah rata-rata harmonis dari presisi dan recall, berguna untuk mengevaluasi model saat data antar kelas tidak seimbang.

### 3 RESULTS AND DISCUSSION

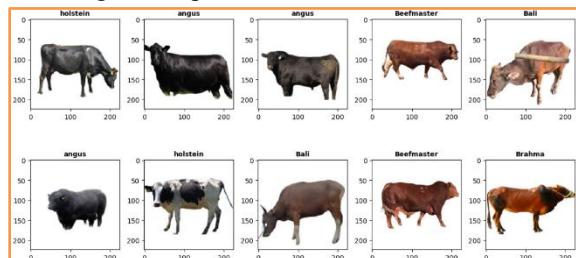
Penelitian ini menggunakan arsitektur ResNet50V2 untuk mengklasifikasikan lima ras sapi, yaitu Bali, Brahman, Angus, Holstein, dan Beefmaster. Dataset yang digunakan terdiri dari 1.500 citra, dengan distribusi merata sebanyak 300 gambar

untuk setiap kelas. Data untuk kelas sapi Bali dikumpulkan secara langsung melalui dokumentasi lapangan di peternakan Kali Jeruk, Yogyakarta, sedangkan data untuk empat kelas lainnya diperoleh dari dataset publik di platform Kaggle.

#### 3.1 Hasil pelatihan model

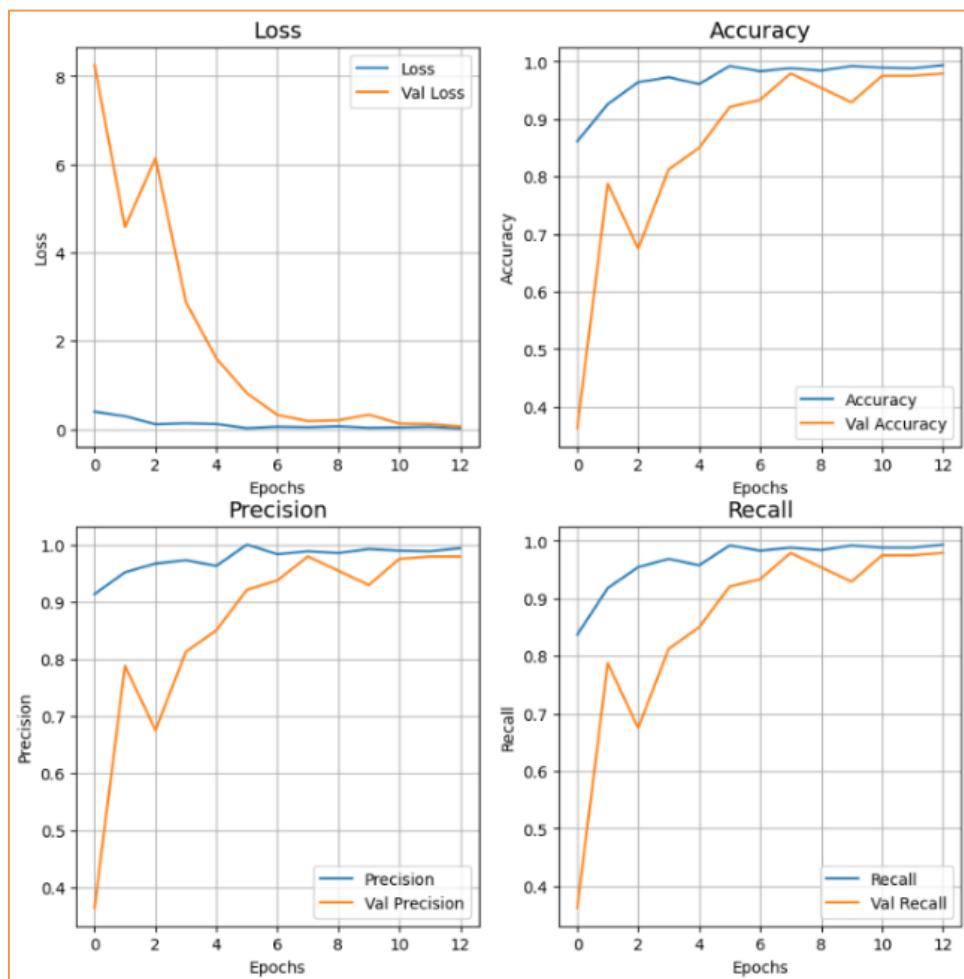
Proses pelatihan dalam penelitian ini menggunakan model Convolutional Neural Network (CNN) dengan arsitektur ResNet50V2. Model ini dipilih karena kemampuannya yang baik dalam mengekstraksi fitur dari citra beresolusi tinggi melalui residual learning yang efisien.

Sebelum pelatihan dimulai, data citra yang terdiri atas 1.500 gambar masing-masing 300 gambar untuk lima kelas sapi: Brahma, Bali, Holstein, Angus, dan Beefmaster dibagi secara acak menggunakan fungsi *train\_test\_split*. Dataset terbagi menjadi tiga bagian: data pelatihan sebesar 80%, data validasi sebesar 16%, dan data pengujian sebesar 4%. Pembagian ini memastikan distribusi kelas tetap seimbang di setiap subset.



Gambar 6. Citra sapi setelah dilakukan rescall, split data dan resize

Pada gambar 6, Menampilkan citra yang digunakan dalam pelatihan yang diubah ukurannya menjadi 224×224 piksel, sesuai dengan kebutuhan input pada ResNet50V2. Selain itu, dilakukan proses augmentasi data seperti rotasi acak, zoom, translasi horizontal dan vertikal, serta flipping horizontal, yang bertujuan untuk memperkaya variasi data dan meningkatkan kemampuan generalisasi model. Seluruh citra kemudian dinormalisasi menggunakan fungsi *preprocess\_input* dari ResNet50V2 untuk menyamakan skala nilai piksel dengan standar input pretrained model.



Gambar 7. Grafik evaluasi model

### 3.1.1 Grafik Pelatihan

Grafik pelatihan model menampilkan perkembangan empat metrik utama selama 20 epoch, yaitu *loss*, *accuracy*, *precision*, dan *recall*, baik pada data pelatihan maupun data validasi.

Gambar 7. menampilkan empat grafik utama yang digunakan untuk mengevaluasi performa model ResNet50V2 selama proses pelatihan: *loss*, *accuracy*, *precision*, dan *recall*, baik pada data pelatihan (training) maupun data validasi (validation).

#### a. Grafik loss

Grafik loss menunjukkan bahwa pada epoch pertama, nilai *training loss* berada di sekitar 0.5, sedangkan *validation loss* sangat tinggi, mencapai sekitar 8.5 dengan fluktuasi yang signifikan di epoch-epoch awal. Hal ini menandakan bahwa pada awal pelatihan, model belum mampu mempelajari pola data validasi dengan baik dan mengalami ketidakstabilan. Namun, seiring bertambahnya epoch, *training loss* terus menurun secara konsisten dan stabil mendekati 0 pada akhir pelatihan. *Validation loss* mengalami penurunan drastis setelah epoch ke-3, dari nilai tinggi menjadi stabil di bawah 1.0, dan akhirnya mendekati *training loss* meskipun masih sedikit lebih tinggi. Pola ini menunjukkan bahwa model berhasil

meminimalkan kesalahan prediksi, namun terdapat sedikit gap antara performa training dan validation yang mengindikasikan adanya mild overfitting.

#### b. Grafik akurasi

Akurasi pelatihan mulai dari angka sekitar 85-87% pada epoch awal, lalu meningkat pesat hingga mencapai 98-99% pada epoch ke-6, dan bertahan stabil hingga akhir pelatihan. Sementara itu, akurasi validasi mengalami peningkatan yang lebih dramatis, dimulai dari sekitar 40% pada epoch pertama (sangat rendah), kemudian melonjak signifikan dan mencapai sekitar 95-97% pada epoch ke-12. Gap yang terlihat antara training accuracy (99%) dan validation accuracy (95-97%) menunjukkan bahwa model mengalami slight overfitting, di mana performa pada data training sedikit lebih baik dibandingkan data validation. Meskipun demikian, validation accuracy yang tinggi menunjukkan bahwa model masih mampu menggeneralisasi dengan baik.

#### c. Grafik precision

Precision menggambarkan seberapa tepat model dalam memberikan label positif pada data yang benar-benar sesuai. Nilai *training precision* sudah tinggi sejak awal, berada di atas 0.9 dan konsisten meningkat mendekati 1.0 sepanjang epoch. *Validation precision*

menunjukkan pola yang lebih fluktuatif, dimulai dari nilai rendah sekitar 0.4 pada epoch pertama, kemudian mengalami peningkatan bertahap dengan beberapa fluktuasi hingga epoch ke-4, dan akhirnya menstabil di atas 0.9 pada epoch-epoch terakhir. Pola ini menunjukkan bahwa model membutuhkan waktu untuk mempelajari karakteristik setiap kelas sapi dengan tepat, namun pada akhirnya berhasil mencapai precision yang tinggi.

#### d. Grafik recall

Recall mengukur kemampuan model dalam menemukan semua sampel positif dari setiap kelas. *Training recall* menunjukkan peningkatan yang konsisten sejak awal, dimulai dari sekitar 85% dan mencapai mendekati 100% pada epoch-epoch terakhir dengan stabilitas yang baik. *Validation recall* memiliki pola serupa dengan precision, dimulai dari nilai rendah di bawah 60% pada epoch pertama, kemudian mengalami peningkatan signifikan dan mencapai di atas 95% di akhir pelatihan. Ini menunjukkan bahwa model mampu mengenali hampir seluruh objek yang relevan di data validasi setelah proses pembelajaran yang cukup.

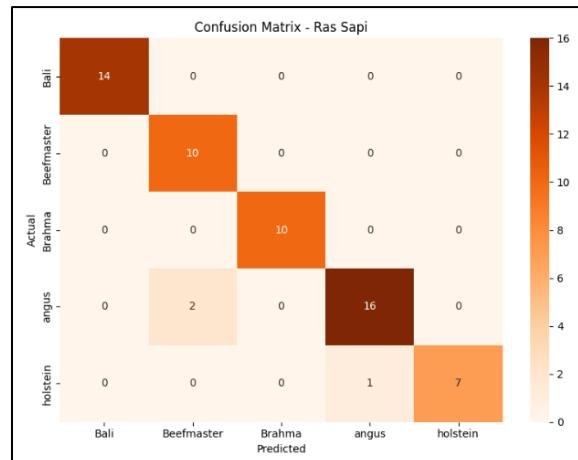
Secara keseluruhan, grafik menunjukkan bahwa model ResNet50V2 berhasil mencapai performa yang sangat baik dengan nilai akurasi, precision, dan recall di atas 95% pada data validation. Namun, terdapat indikasi *mild overfitting* yang ditunjukkan oleh gap antara training dan validation metrics, terutama pada accuracy (gap 2-4%). Meskipun demikian, overfitting ini masih dalam kategori ringan dan model tetap menunjukkan kemampuan generalisasi yang baik pada data validation.

### 3.2 Hasil pengujian model

Setelah melalui proses pelatihan menggunakan arsitektur ResNet50V2, tahap selanjutnya adalah mengevaluasi sejauh mana kemampuannya dalam mengenali dan mengklasifikasikan citra ras sapi. Evaluasi model bertujuan untuk menilai performa berdasarkan hasil pelatihan model seperti akurasi, presisi, dan recall. Selain itu, visualisasi berupa grafik pelatihan, confusion matrix, serta hasil prediksi terhadap gambar acak digunakan untuk memperkuat analisis performa model.

#### 3.2.1 Confusion matrix

Confusion matrix merupakan alat evaluasi yang digunakan untuk menilai kinerja model klasifikasi dengan membandingkan antara label aktual dan prediksi model. Setiap baris dalam matriks menunjukkan data aktual, sedangkan kolom menunjukkan hasil prediksi. Nilai-nilai pada diagonal utama menunjukkan jumlah sampel yang berhasil diklasifikasikan secara benar, sementara nilai di luar diagonal utama menunjukkan jumlah kesalahan klasifikasi.



Gambar 8. Confusion matrix

Berdasarkan confusion matrix pada Gambar 8, terlihat bahwa model klasifikasi yang menggunakan arsitektur ResNet50V2 mampu mengklasifikasikan sebagian besar citra ras sapi dengan sangat baik. Tiga kelas utama, yaitu Bali, Beefmaster, dan Brahma, berhasil diklasifikasikan dengan akurasi sempurna. Seluruh citra dari ketiga kelas tersebut berada tepat di diagonal utama, yang berarti tidak ada kesalahan klasifikasi yang terjadi pada kelas-kelas ini.

Sementara itu, pada kelas Angus, terdapat 2 citra yang salah diklasifikasikan sebagai Beefmaster, meskipun sebagian besar (16 dari 18 citra) berhasil dikenali dengan tepat. Kesalahan ini mengindikasikan adanya kesamaan karakteristik visual tertentu antara citra Angus dan Beefmaster yang mungkin membingungkan model. Hal serupa juga terjadi pada kelas Holstein, di mana satu dari delapan citra salah diklasifikasikan sebagai Angus.

Nilai-nilai pada sel-sel di luar diagonal utama secara umum tetap rendah, yang berarti bahwa kesalahan klasifikasi relatif jarang terjadi. Kondisi ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan tidak hanya mengenali pola pada data latih, tetapi juga dapat mengaplikasikannya secara efektif pada data uji.

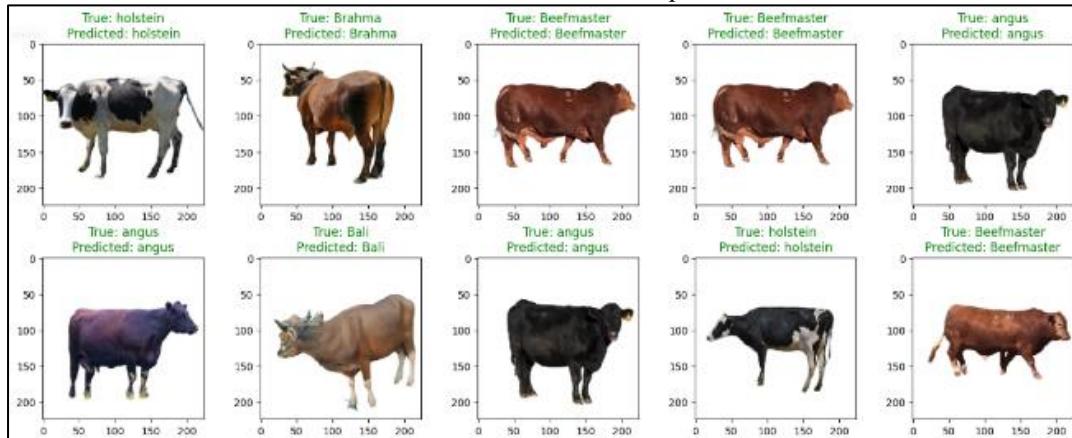
Secara keseluruhan, hasil confusion matrix menunjukkan bahwa model yang digunakan mampu mengidentifikasi ras sapi dengan akurasi tinggi. Hanya terdapat sedikit kesalahan klasifikasi, terutama pada kelas yang memiliki kemiripan visual. Hal ini membuka ruang untuk pengembangan lebih lanjut, misalnya melalui pemanfaatan segmentasi lokal atau fine-tuning dengan data tambahan, guna lebih memperkuat ketepatan klasifikasi pada kelas yang rawan tertukar.

#### 3.2.2 Classification report

Setelah proses pelatihan selesai, model diuji menggunakan data uji untuk menilai performa klasifikasi terhadap citra yang tidak pernah dilihat sebelumnya. Berdasarkan hasil evaluasi pada data uji sebanyak 60 citra, model ResNet50V2 menunjukkan performa yang sangat baik dengan akurasi

	precision	recall	f1-score	support
Bali	1.00	1.00	1.00	14
Beefmaster	0.83	1.00	0.91	10
Brahma	1.00	1.00	1.00	10
angus	0.94	0.89	0.91	18
holstein	1.00	0.88	0.93	8
accuracy			0.95	60
macro avg	0.95	0.95	0.95	60
weighted avg	0.95	0.95	0.95	60

Gambar 9. Classification report



Gambar 10. Hasil prediksi

keseluruhan mencapai 95%. Selain akurasi, metrik lain seperti precision, recall, dan f1-score juga memberikan gambaran mendalam terkait kinerja model pada tiap kelas.

Pada gambar 9, Model berhasil mengklasifikasikan kelas Bali dan Brahma secara sempurna, dengan nilai precision, recall, dan f1-score masing-masing sebesar 1.00, yang berarti semua gambar dalam dua kelas tersebut terprediksi dengan benar tanpa kesalahan. Sementara itu, pada kelas Beefmaster, recall mencapai 1.00, menandakan seluruh gambar dalam kelas ini dikenali dengan benar oleh model, meskipun nilai precision-nya sedikit lebih rendah, yaitu 0.83. Hal ini menunjukkan bahwa ada beberapa prediksi model ke kelas Beefmaster yang tidak tepat.

Untuk kelas Angus dan Holstein, model tetap menunjukkan performa yang tinggi, dengan nilai precision dan recall di atas 0.88. Pada kelas Angus, precision sebesar 0.94 dan recall 0.89, menghasilkan f1-score 0.91. Sedangkan untuk kelas Holstein, precision mencapai 1.00 dan recall 0.88, dengan f1-score sebesar 0.93.

Secara keseluruhan, nilai macro average dan weighted average dari semua metrik utama (precision, recall, f1-score) adalah 0.95, menunjukkan bahwa model mampu menjaga konsistensi performa di seluruh kelas, tanpa berat sebelah terhadap kelas tertentu. Capaian ini mencerminkan kemampuan generalisasi model yang kuat serta efektivitas pendekatan pelatihan yang diterapkan.

### 3.2.3 Prediksi

Untuk menguji performa model pada data yang belum pernah dilihat sebelumnya, dilakukan prediksi terhadap sepuluh citra acak yang diambil dari subset data uji (testing set). Pemilihan citra dilakukan secara acak dari batch data uji yang telah dipisahkan sejak awal dan tidak digunakan selama proses pelatihan maupun validasi.

Setiap citra yang dipilih diproses melalui tahap normalisasi dan kemudian diprediksi oleh model klasifikasi berbasis ResNet50V2. Hasil prediksi dibandingkan dengan label asli untuk mengevaluasi ketepatan klasifikasi. Visualisasi hasil prediksi ditampilkan dalam bentuk grid, di mana setiap gambar disertai informasi label asli (true label) dan hasil prediksi model. Warna hijau digunakan untuk menandai prediksi yang benar, sedangkan merah digunakan untuk menandai prediksi yang salah.

Berdasarkan visualisasi pada gambar 10, yang ditampilkan, model berhasil melakukan prediksi yang tepat pada seluruh gambar yang diuji secara acak. Artinya, model menunjukkan performa yang konsisten dan akurat terhadap data uji, bahkan saat dipilih secara acak. Hasil ini memperkuat temuan sebelumnya bahwa model memiliki kemampuan klasifikasi yang baik pada data yang belum pernah dilihat selama pelatihan. Keberhasilan ini juga menjadi indikasi bahwa model tidak hanya menghafal pola pada data pelatihan, melainkan benar-benar memahami karakteristik visual dari masing-masing kelas ras sapi,

seperti bentuk tubuh, pola warna, atau kontur tertentu yang khas dari masing-masing ras.

#### 4 CONCLUSION

Penelitian ini bertujuan untuk mengembangkan model klasifikasi citra guna membedakan lima jenis ras sapi, yaitu Brahma, Bali, Holstein, Angus, dan Beefmaster, dengan menggunakan arsitektur Convolutional Neural Network (CNN) ResNet50V2. Dataset yang digunakan terdiri atas 1.500 citra, yang telah dibagi secara proporsional ke dalam data latih, validasi, dan uji. Model dilatih melalui teknik augmentasi data dan optimisasi menggunakan *optimizer* Adamax dengan fungsi aktivasi *softmax* pada layer output. Hasil pengujian menunjukkan bahwa model mampu mencapai akurasi evaluasi sebesar 98,45% pada data latih, 98,21% pada data validasi, dan 95,63% pada data uji. Evaluasi metrik lainnya seperti precision, recall, dan f1-score juga menunjukkan nilai yang tinggi secara konsisten di semua kelas, dengan rata-rata nilai f1-score mencapai 0.95, menandakan performa klasifikasi yang sangat baik dan seimbang. Visualisasi berupa grafik evaluasi pelatihan dan confusion matrix memperkuat bahwa model tidak mengalami overfitting secara signifikan, serta mampu mengenali pola dari setiap ras sapi secara akurat.

Untuk pengembangan lebih lanjut, disarankan agar dataset diperluas dengan variasi latar, sudut pandang, dan pencahayaan yang lebih beragam guna meningkatkan kemampuan generalisasi model. Selain itu, pengujian pada sistem nyata seperti perangkat mobile atau edge device dapat memberikan gambaran lebih menyeluruh mengenai kinerja model di lapangan. Peneliti selanjutnya juga dapat membandingkan performa ResNet50V2 dengan arsitektur CNN lain, seperti EfficientNet atau MobileNet, guna mengevaluasi efisiensi dan akurasi model sesuai kebutuhan implementasi.

#### REFERENCES

- [1] S. F. A. Wijaya, K. Koredianto, dan S. Saidah, "Analisis Perbandingan K-Nearest Neighbor dan Support Vector Machine pada Klasifikasi Jenis Sapi dengan Metode Gray Level Cocurrence Matrix," *Jurnal Ilmu Komputer dan Informatika*, vol. 2, no. 2, hlm. 93–102, Mar 2022, doi: 10.54082/jiki.27.
- [2] A. Ramadhan Siregar, S. Rohani, S. Nurani Sirajuddin, P. Astaman, dan dan Muhammad Darwis, "Analisis Komparasi Pendapatan pada Usaha Pembibitan dan Penggemukan Sapi Potong Income Comparison Analysis of Cattle Breeding and Fattening," *Jurnal Peternakan Lokal*, vol. 5, no. 2, 2023.
- [3] I. Telur Fasciola sp Berdasarkan Pemeriksaan Koprologi dan Efektivitas Albendazole pada Sapi Limosin, S. Salas Sholekhah, dan S. Kusumarini, "ShareAlike 4.0 International License (CC-BY-SA) STUDI KASUS/CASE STUDY (Identification of Fasciola sp. Eggs based on Coprological Examination and Albendazole Effectiveness in Limosin Cattle)", doi: 10.29244/jvetbiomed.1.2.59-64.
- [4] 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.
- [5] 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.
- [6] M. E. Hossain, M. A. Kabir, L. Zheng, D. L. Swain, S. McGrath, dan J. Medway, "A systematic review of machine learning techniques for cattle identification: Datasets, methods and future directions," 1 Januari 2022, *KeAi Communications Co*. doi: 10.1016/j.aiia.2022.09.002.
- [7] M. E. Hossain, M. A. Kabir, L. Zheng, D. L. Swain, S. McGrath, dan J. Medway, "A systematic review of machine learning techniques for cattle identification: Datasets, methods and future directions," 1 Januari 2022, *KeAi Communications Co*. doi: 10.1016/j.aiia.2022.09.002.
- [8] R. A. Sucipto, "KLASIFIKASI SAPI MADURA BERDASARKAN UKURAN TUBUH MENGGUNAKAN METODE SUPPORT VECTOR MACHINE DAN K-NEAREST NEIGHBORS," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 1, Jan 2025, doi: 10.23960/jitet.v13i1.5739.
- [9] J. T. Samudra, R. Rosnelly, Z. Situmorang, dan P. S. Ramadhan, "Model Klasifikasi Jenis Hewan Dengan SVM, KNN, Logistic Regression Menggunakan Pre-Trained VGG 16," 2023, [Daring]. Tersedia pada: <https://ojs.trigunadharma.ac.id/index.php/jis/index>
- [10] F. Nurona Cahya dkk., "SISTEMASI: Jurnal Sistem Informasi Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN)." [Daring]. Tersedia pada: <http://sistemasit.ftik.unisi.ac.id>
- [11] A. Leovincent, "Klasifikasi Ras Anjing Berdasarkan Citra Menggunakan Convolutional Neural Network," vol. 3, no. 2, hlm. 160–169, 2023, doi: 10.35957/algoritme.xxxx.
- [12] 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.
- [13] S. Zamroni dkk., "Sistemasi: Jurnal Sistem Informasi Identifikasi Moncong Sapi menggunakan Metode Jaringan Saraf Tiruan Konvolusional (CNN) Recognizing Cow Muzzle Patterns using the Convolution Neural Network (CNN) Algorithm." [Daring]. Tersedia pada: <http://sistemasit.ftik.unisi.ac.id>
- [14] W. Widhiarso, "3 RD MDP STUDENT CONFERENCE (MSC) 2024 Klasifikasi Jenis Spesies Ikan Hiu Menggunakan Metode Convolutional Neural Network (CNN)," [Daring]. Tersedia pada: <https://www.kaggle.com/datasets/larusso94/shark-species>.
- [15] Raihan Maulana, Raisya Dwi Zahra Putri, Sindy Fitriani Margareth Sihaloho, dan Sri Mulyana, "Implementasi Algoritma Convolutional Neural Network Dalam Mengklasifikasi Jenis Burung," *Journal of Creative Student Research*, vol. 1, no. 6, hlm. 221–231, Nov 2023, doi: 10.55606/jesrpolutama.v1i6.2966.
- [16] C. Agusniar dan D. Adelia, "Penerapan Convolutional Neural Network pada Klasifikasi Jenis Ras Kucing Menggunakan ResNet50V2," 2024.
- [17] B. Hartanto dan T. Susyanto, "PENERAPAN IMAGE RECOGNITION DALAM PENGENALAN OBJEK MENGGUNAKAN MODEL RESNET-50," vol. 2, no. 2, 2023, [Daring]. Tersedia pada: <https://ojs.unsiq.ac.id/index.php/biner>
- [18] N. R. Janke dkk., "Global phylogenomic diversity of Brucella abortus: spread of a dominant lineage," *Front Microbiol*, vol. 14, 2023, doi: 10.3389/fmicb.2023.1287046.
- [19] P. Guliński, "Cattle breeds – contemporary views on their origin and criteria for classification: a review," *Acta*

- Scientiarum Polonorum Zootechnica*, vol. 20, no. 2, hlm. 3–18, Jan 2022, doi: 10.21005/asp.2021.20.2.01.
- [20] M. Al Kalaldeh *dkk.*, “Detection of genomic regions that differentiate Bos indicus from Bos taurus ancestral breeds for milk yield in Indian crossbred cows,” *Front Genet*, vol. 13, Jan 2023, doi: 10.3389/fgene.2022.1082802.
  - [21] N. Eka Budiyanta *dkk.*, “Sistem Deteksi Kemurnian Beras berbasis Computer Vision dengan Pendekatan Algoritma YOLO,” vol. 6, no. 1, 2021.
  - [22] Mutaqin Akbar, “Traffic sign recognition using convolutional neural networks,” *International Journal of Electrical Engineering and Technology*, vol. 11, no. 3, hlm. 210–217, Apr 2021, doi: 10.14710/jtsiskom.2021.13959.
  - [23] 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.
  - [24] A. Titania *dkk.*, “Analisis Klasifikasi Mobil Pada Gardu Tol Otomatis (GTO) Menggunakan Convolutional Neural Network (CNN),” 2022.
  - [25] Sandy Andika Maulana, Shabrina Husna Batubara, Tasya Ade Amelia, dan Yohanna Permata Putri Pasaribu, “Penerapan Metode CNN (Convolutional Neural Network) Dalam Mengklasifikasi Jenis Ubur-Ubur,” *Jurnal Penelitian Rumpun Ilmu Teknik*, vol. 2, no. 4, hlm. 122–130, Des 2023, doi: 10.55606/juprit.v2i4.3084.
  - [26] K. R. Wardani dan L. Leonardi, “Klasifikasi Penyakit pada Daun Anggur menggunakan Metode Convolutional Neural Network,” *Jurnal Tekno Insentif*, vol. 17, no. 2, hlm. 112–126, Okt 2023, doi: 10.36787/jti.v17i2.1130.
  - [27] Zaid Ahmed, “Cow Breed Classification Dataset,” Kaggle. Diakses: 17 Juni 2025. [Daring]. Tersedia pada: <https://www.kaggle.com/datasets/zaidworks0508/cow-breed-classification-dataset>
  - [28] Jordano Isaías Garza Murillo, “Bovine Cattle Images,” Kaggle. Diakses: 17 Juni 2025. [Daring]. Tersedia pada: <https://www.kaggle.com/datasets/jordanogarza/bovine-cattle-images>
  - [29] Lawrence Jembere, “Cow Images for Milk Yield Prediction,” Kaggle. Diakses: 17 Juni 2025. [Daring]. Tersedia pada: <https://www.kaggle.com/datasets/lawrencejembere/cow-images-for-milk-yield-prediction>
  - [30] A. Ridhovan *dkk.*, “PENERAPAN METODE RESIDUAL NETWORK (RESNET) DALAM KLASIFIKASI PENYAKIT PADA DAUN GANDUM.”
  - [31] Y. F. Riti, Y. Wahyuningsih, J. Roosandriantini, dan P. W. Siswanto, “Perbandingan Algoritma Convolutional Neural Network dan Capsule Network Dalam Klasifikasi Jenis Rumah Adat,” *Teknika*, vol. 12, no. 3, hlm. 243–251, Nov 2023, doi: 10.34148/teknika.v12i3.702.