



## *Classification of Dairy and Non-Dairy Cattle Using the Convolutional Neural Network Algorithm*

### **Klasifikasi Sapi Perah dan Non-Perah Menggunakan Algoritma Convolutional Neural Network**

Leonard Maramis<sup>1\*</sup>, Ingrid Nurtanio<sup>2</sup>, Hazriani Zainuddin<sup>3</sup>

<sup>1,3</sup>Pascasarjana Magister Sistem Komputer, Universitas Handayani Makassar, Indonesia

<sup>2</sup>Program Studi Teknik Informatika, Universitas Hasanuddin, Indonesia

E-mail: <sup>1</sup>leonmaramis06@gmail.com, <sup>2</sup>Ingrid@unhas.ac.id, <sup>3</sup>hazriani@handayani.ac.id

Received Dec 12th 2024; Revised Mar 15th 2025; Accepted Mar 24th 2025; Available Online Apr 13th 2025, Published Apr 13th 2025

Corresponding Author: Leonard Maramis

Copyright © 2025 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

#### **Abstract**

*Cattle are one of the main livestock in Indonesia, consisting of dairy and beef cattle. In Kotamobagu and Bolaang Mongondow Raya (BMR), cattle farming is rapidly growing due to increasing purchasing power and the high market value of cattle. However, cattle trading still faces challenges, particularly in distinguishing cattle types, which can lead to errors and potential fraud. This study aims to implement the Convolutional Neural Network (CNN) algorithm with the Xception architecture for classifying dairy and non-dairy cattle. The research process includes collecting cattle image data, labeling, and training the CNN model to recognize the physical characteristics of each cattle type. The test results show that the Xception model achieved 96% accuracy with an 80:20 dataset split, proving its ability to recognize visual patterns effectively. These findings indicate that CNN, particularly with the Xception architecture, can be an effective tool for cattle identification, enhancing security and accuracy in livestock transactions. With further development, this system could be integrated with camera technology for automated monitoring, supporting a more modern and efficient livestock industry.*

*Keywords: Cattle Classification, Convolutional Neural Network (CNN), Dairy Cattle, Kotamobagu, Non-Dairy Cattle*

#### **Abstrak**

Sapi merupakan salah satu hewan ternak utama di Indonesia yang terdiri dari sapi perah dan sapi potong. Di Kotamobagu dan Bolaang Mongondow Raya (BMR), peternakan sapi berkembang pesat seiring dengan meningkatnya daya beli masyarakat dan nilai jual sapi yang tinggi. Namun, transaksi jual-beli sapi masih menghadapi kendala, terutama dalam membedakan jenis sapi yang dapat menyebabkan kesalahan dan potensi penipuan. Penelitian ini bertujuan untuk mengimplementasikan algoritma Convolutional Neural Network (CNN) dengan arsitektur Xception dalam klasifikasi sapi perah dan non-perah. Proses penelitian mencakup pengumpulan data citra sapi, pelabelan, serta pelatihan model CNN untuk mengenali karakteristik fisik masing-masing jenis sapi. Hasil pengujian menunjukkan bahwa model Xception mencapai akurasi 96% dengan pembagian dataset 80:20, membuktikan kemampuannya dalam mengenali pola visual dengan baik. Temuan ini menunjukkan bahwa CNN, khususnya dengan arsitektur Xception, dapat menjadi alat yang efektif dalam identifikasi jenis sapi, sehingga berpotensi meningkatkan keamanan dan keakuratan dalam transaksi ternak. Dengan pengembangan lebih lanjut, sistem ini dapat diintegrasikan dengan teknologi kamera untuk pemantauan otomatis guna mendukung industri peternakan yang lebih modern dan efisien.

Kata Kunci: Convolutional Neural Network (CNN), Klasifikasi Sapi, Kotamobagu, Sapi Non Perah, Sapi Perah

## **1. PENDAHULUAN DAN LITERATURE REVIEW**

### **1.1. Pendahuluan**

Kotamobagu adalah salah satu kota di Provinsi Sulawesi Utara yang berkembang menjadi pusat perdagangan sapi di wilayah Bolaang Mongondow Raya (BMR). Seiring meningkatnya permintaan daging sapi dan tingginya daya beli masyarakat, perdagangan sapi di Kotamobagu semakin pesat [1]. Namun, dalam proses jual beli sapi, sering terjadi kendala, terutama dalam identifikasi jenis sapi, yang dapat menyebabkan kesalahan transaksi atau bahkan penipuan [2], [3].



Sapi secara umum terbagi menjadi dua jenis utama, yaitu sapi perah dan sapi potong. Sapi perah seperti Holstein dan Jersey memiliki karakteristik khusus yang membedakannya dari sapi potong seperti sapi Bali dan sapi Sumba [4], [5]. Namun, kemiripan fisik antara beberapa jenis sapi, terutama bagi mereka yang kurang berpengalaman, dapat menyebabkan kesalahan dalam identifikasi. Penelitian sebelumnya menunjukkan bahwa metode berbasis fitur manual seperti warna, ukuran tubuh, dan bentuk tanduk masih memiliki keterbatasan dalam akurasi klasifikasi sapi [6]. Oleh karena itu, diperlukan pendekatan berbasis kecerdasan buatan yang mampu mengenali pola dan karakteristik sapi secara lebih akurat.

Salah satu metode yang banyak digunakan dalam pengolahan citra untuk klasifikasi objek adalah Convolutional Neural Network (CNN). CNN telah terbukti efektif dalam berbagai penelitian terkait klasifikasi citra, termasuk dalam bidang peternakan [7], [8], [9]. Pada bidang lainnya misalnya, penelitian oleh Riswanto et al. (2024) berhasil menerapkan CNN dalam klasifikasi jenis makanan Indonesia dengan akurasi lebih dari 90% [10]. Studi lain oleh Dhimas Tribuana et al. (2024) menunjukkan bahwa CNN mampu mengatasi tantangan dalam identifikasi objek dengan variasi pencahayaan dan sudut pengambilan gambar [11], [12]. Namun, penelitian yang secara khusus membahas klasifikasi sapi perah dan non-perah masih terbatas, terutama dalam konteks perdagangan sapi di Indonesia.

Penelitian ini bertujuan untuk menerapkan algoritma CNN dalam mengklasifikasikan sapi perah dan non-perah berdasarkan citra digital. Model yang dikembangkan akan dilatih menggunakan dataset citra sapi yang telah dilabeli untuk mengenali karakteristik khas dari masing-masing jenis sapi. Dengan demikian, diharapkan penelitian ini dapat memberikan kontribusi dalam meningkatkan keakuratan identifikasi sapi serta mengurangi potensi kesalahan dalam transaksi jual beli sapi di Kotamobagu dan sekitarnya.

## 1.2. Literature Review

CNN merupakan salah satu jenis arsitektur Deep Learning yang banyak digunakan dalam pengolahan citra digital. CNN terdiri dari beberapa lapisan seperti convolutional layer, pooling layer, dan fully connected layer yang memungkinkan model untuk mengekstraksi fitur dari citra secara otomatis. Keunggulan CNN dibandingkan metode lain seperti Support Vector Machine (SVM) atau K-Nearest Neighbor (K-NN) terletak pada kemampuannya dalam mengenali pola kompleks tanpa memerlukan proses ekstraksi fitur secara manual. Menurut penelitian yang dilakukan oleh Zhang et al. (2020), CNN menunjukkan performa yang lebih unggul dalam klasifikasi objek dibandingkan dengan metode tradisional berbasis machine learning [13]. Selain itu, studi oleh Li et al. (2021) menunjukkan bahwa arsitektur CNN seperti ResNet dan VGG mampu memberikan akurasi yang tinggi dalam berbagai tugas klasifikasi citra [14].

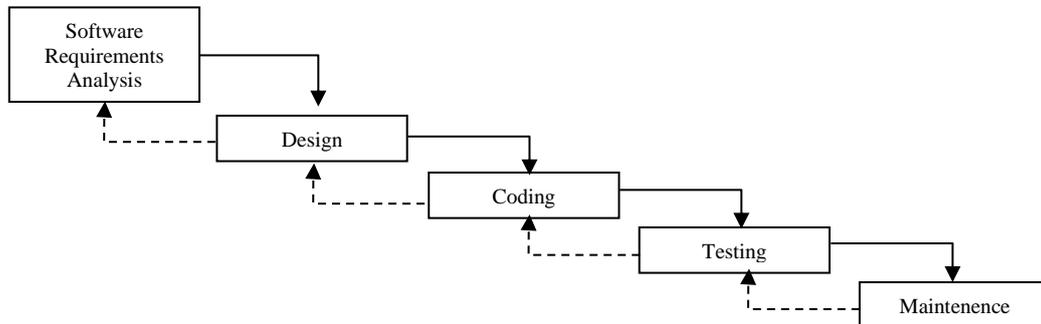
Deep Learning merupakan cabang dari machine learning yang menggunakan jaringan saraf tiruan dengan banyak lapisan untuk mempelajari representasi data yang kompleks. Dalam beberapa tahun terakhir, Deep Learning telah berkembang pesat dan digunakan dalam berbagai bidang seperti pengenalan wajah, kendaraan otonom, serta deteksi penyakit. CNN merupakan salah satu implementasi utama dari Deep Learning yang memiliki keunggulan dalam pemrosesan data visual. Menurut penelitian yang dilakukan oleh Chen et al. (2014), perkembangan teknik Deep Learning, seperti transfer learning dan fine-tuning model, telah meningkatkan efisiensi dalam pengolahan citra dan memungkinkan pelatihan model dengan jumlah data yang lebih sedikit [15]. Selain itu, studi oleh Liang et al. (2025) menyoroti bahwa Deep Learning terus berkembang dengan munculnya arsitektur baru seperti Vision Transformer (ViT) yang menawarkan alternatif dalam analisis citra berbasis Deep Learning [16].

Confusion Matrix merupakan alat evaluasi yang sering digunakan dalam mengukur kinerja model klasifikasi, termasuk CNN dan metode berbasis Deep Learning lainnya. Confusion Matrix menampilkan perbandingan antara prediksi model dengan nilai sebenarnya dalam bentuk tabel matriks, yang terdiri dari True Positive, True Negative, False Positive, dan False Negative. Evaluasi menggunakan Confusion Matrix memungkinkan peneliti untuk menghitung metrik evaluasi seperti akurasi, presisi, recall, dan F1-score. Menurut penelitian oleh Wang et al. (2024), penggunaan Confusion Matrix dalam analisis klasifikasi citra sangat penting untuk mengidentifikasi kelemahan model, terutama dalam kasus ketidakseimbangan data [17]. Selain itu, studi oleh Chen et al. (2024) menunjukkan bahwa kombinasi Confusion Matrix dengan metode lain seperti ROC Curve dan AUC dapat memberikan gambaran yang lebih akurat mengenai performa model klasifikasi [18].

## 2. METODOLOGI PENELITIAN

Metode penelitian yang digunakan dalam penelitian ini adalah Research and Development (R&D) dengan pendekatan model Waterfall. Model ini dipilih karena menyediakan alur pengembangan yang sistematis dan terstruktur dalam membangun sistem, di mana setiap tahap harus diselesaikan sebelum berlanjut ke tahap berikutnya. Berdasarkan gambar, tahapan dalam model Waterfall dimulai dari Software Requirements Analysis, yang bertujuan untuk menganalisis kebutuhan perangkat lunak secara menyeluruh. Selanjutnya, tahap Design dilakukan untuk merancang arsitektur sistem berdasarkan kebutuhan yang telah dianalisis. Setelah desain selesai, proses Coding atau pengkodean dilakukan untuk mengubah rancangan sistem menjadi bentuk program yang dapat dijalankan. Tahap berikutnya adalah Testing, yaitu pengujian sistem untuk

memastikan bahwa perangkat lunak berfungsi sesuai dengan spesifikasi yang telah ditentukan dan bebas dari kesalahan. Terakhir, tahap Maintenance dilakukan setelah sistem diimplementasikan, yang mencakup perbaikan bug, peningkatan fitur, serta pemeliharaan agar sistem tetap berjalan optimal. Pendekatan ini memungkinkan pengembangan sistem yang lebih terkontrol dan berkualitas karena setiap tahapan diselesaikan secara berurutan sebelum melangkah ke tahap berikutnya. Model waterfall dapat dilihat pada gambar 1.

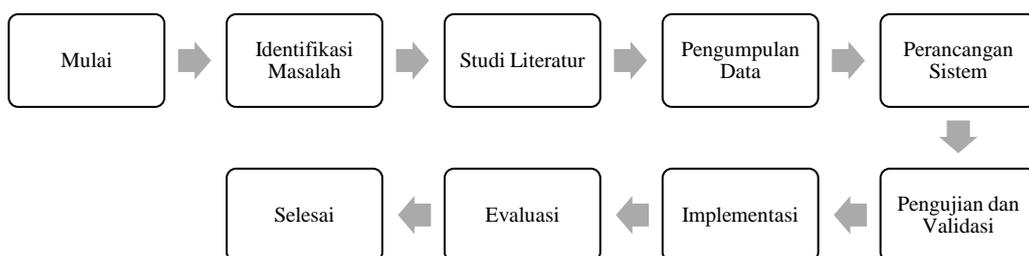


**Gambar 1.** Model Waterfall

### 2.1. Tahapan Penelitian

Metodologi penelitian ini terdiri dari beberapa tahapan utama yang disusun secara sistematis berdasarkan gambar yang ditunjukkan. Proses penelitian diawali dengan Identifikasi Masalah, di mana permasalahan utama dalam penelitian ini dianalisis untuk menentukan fokus kajian. Selanjutnya, dilakukan Studi Literatur dengan mengumpulkan referensi dari jurnal, artikel ilmiah, serta buku yang relevan guna memperkuat dasar teori penelitian. Tahapan berikutnya adalah Pengumpulan Data, yang dilakukan dengan memperoleh dataset terkait klasifikasi citra sapi melalui berbagai sumber, termasuk citra yang telah diambil langsung serta data yang diperoleh dari crawling image. Setelah data terkumpul, dilakukan Perancangan Sistem, yang mencakup desain arsitektur sistem klasifikasi berbasis CNN, termasuk pemilihan model, parameter yang digunakan, serta pengolahan citra yang diperlukan untuk proses klasifikasi.

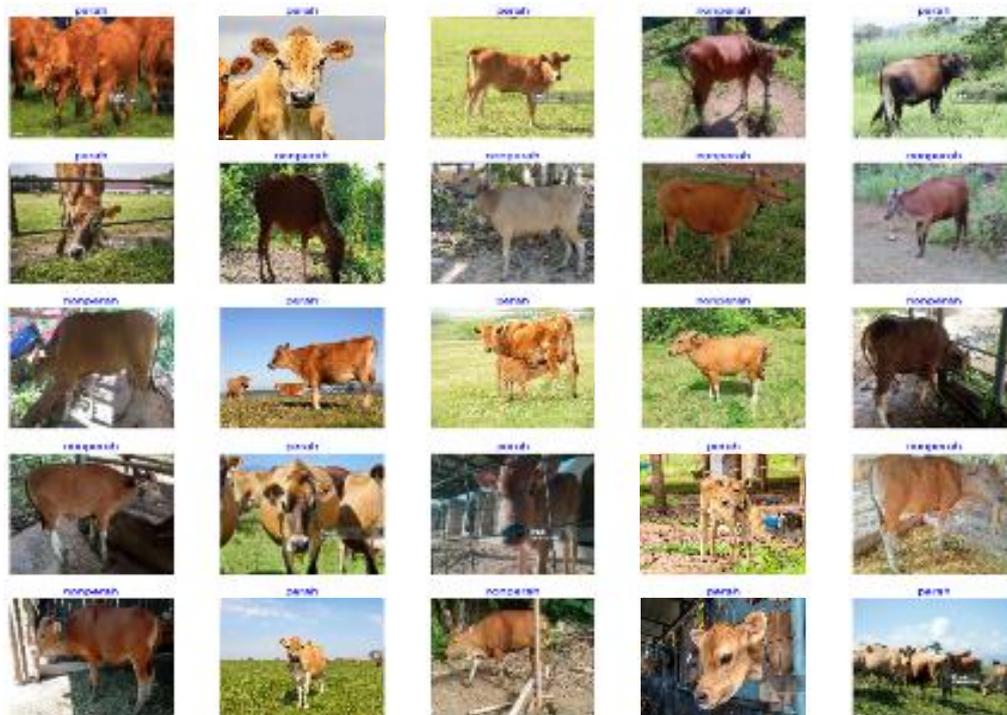
Setelah perancangan selesai, sistem diuji melalui Pengujian dan Validasi guna memastikan bahwa model yang dikembangkan dapat melakukan klasifikasi dengan tingkat akurasi yang optimal. Pengujian ini dilakukan menggunakan data uji, sementara validasi bertujuan untuk mengevaluasi kinerja sistem dalam mengklasifikasikan citra sapi perah dan non-perah. Selanjutnya, pada tahap Implementasi, sistem diterapkan untuk mengolah data secara langsung dan menghasilkan prediksi sesuai dengan model yang telah dikembangkan. Hasil implementasi kemudian dievaluasi dalam tahap Evaluasi, di mana performa sistem dianalisis berdasarkan metrik yang telah ditentukan. Akhir dari proses ini adalah tahap Selesai, yang menandakan bahwa penelitian telah menghasilkan sistem klasifikasi yang dapat digunakan sesuai dengan tujuan penelitian. Diagram tahapan penelitian dapat ditunjukkan pada gambar 1.



**Gambar 2.** Tahapan Penelitian

### 2.2. Dataset dan Arsitektur CNN yang digunakan

Metode yang digunakan dalam penelitian ini dimulai dengan proses pengumpulan dataset yang terdiri dari 166 citra sapi, yang terbagi menjadi 83 citra sapi perah dan 83 citra sapi non-perah. Dataset ini diperoleh melalui berbagai sumber, termasuk pengambilan gambar langsung menggunakan kamera beresolusi tinggi, web scraping dari situs dengan lisensi bebas, serta dataset publik yang tersedia untuk penelitian klasifikasi citra. Setelah dataset terkumpul, dilakukan proses pelabelan secara manual untuk mengklasifikasikan gambar sesuai kategori sapi perah dan non-perah. Selanjutnya, gambar-gambar tersebut disimpan dalam dua folder terpisah agar dapat digunakan dalam proses pelatihan dan pengujian model. Dataset pada penelitian ini sebagai contoh dapat ditunjukkan pada gambar 3.



**Gambar 3.** Dataset

Sebelum digunakan dalam model CNN, dataset mengalami tahapan preprocessing untuk meningkatkan kualitas data. Seluruh gambar diubah ukurannya menjadi  $128 \times 128$  piksel guna menyamakan dimensi input model. Selanjutnya, dilakukan normalisasi dengan mengonversi nilai piksel ke skala 0 hingga 1 agar jaringan saraf konvolusional dapat bekerja lebih optimal. Untuk mengatasi keterbatasan jumlah data, augmentasi citra diterapkan dengan teknik seperti rotasi antara  $-15^\circ$  hingga  $+15^\circ$ , flipping horizontal, zooming hingga 20%, serta penyesuaian kecerahan. Setelah preprocessing selesai, dataset dibagi menjadi dua bagian, yaitu 80% untuk pelatihan dan 20% untuk pengujian guna mengevaluasi performa model.

Arsitektur CNN yang digunakan dalam penelitian ini adalah Xception, yang dikenal sebagai model berbasis CNN dengan depthwise separable convolutions untuk meningkatkan efisiensi dan akurasi. Model ini menggunakan bobot pre-trained dari ImageNet untuk memanfaatkan fitur yang telah dipelajari sebelumnya. Lapisan akhir dari arsitektur Xception dimodifikasi dengan menambahkan lapisan Conv2D, MaxPooling2D, Flatten, dan Dense agar sesuai untuk tugas klasifikasi sapi perah dan non-perah. Aktivasi yang digunakan dalam sebagian besar lapisan adalah ReLU, sementara lapisan output menggunakan aktivasi Softmax untuk menentukan probabilitas dari dua kelas. Proses pelatihan dilakukan dengan optimizer Adam menggunakan learning rate sebesar 0.0001, loss function categorical crossentropy, batch size 32, dan dijalankan selama 50 epoch.

Model dilatih dengan dataset yang telah diproses, dan kinerjanya dievaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score pada data uji. Dengan pendekatan ini, sistem klasifikasi sapi perah dan non-perah dapat dikembangkan dengan tingkat akurasi yang lebih baik. Penjelasan mengenai dataset, preprocessing, arsitektur model, serta parameter yang digunakan telah disusun secara komprehensif agar penelitian ini dapat direplikasi dan hasilnya dapat dipercaya.

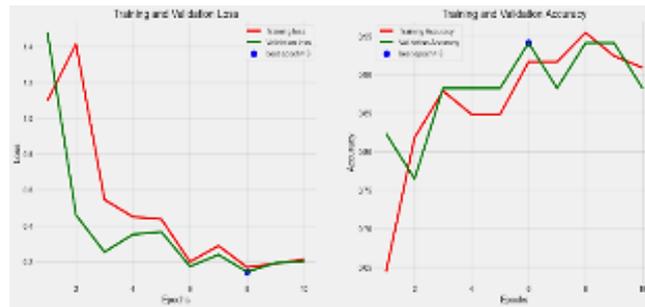
### 3. HASIL DAN PEMBAHASAN

#### 3.1. Proses Analisis Data Training

##### 1. Uji Coba Data A

Pada tahap ini dilakukan uji coba A dengan perbandingan data 80:10:10 yaitu data *training* sebanyak 133 data *testing* 17 dan validasi 17 untuk menghasilkan validasi data *training validation accuracy* dan *validation loss* seperti pada gambar 4.

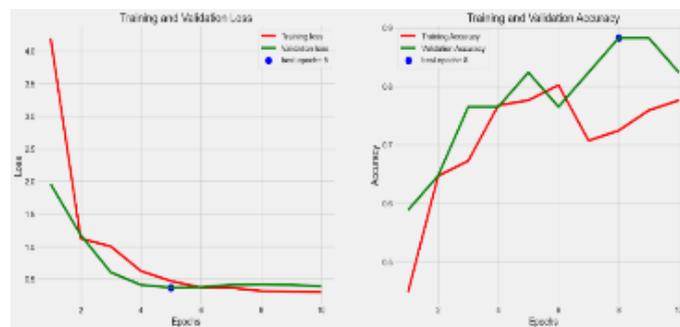
Gambar 4 hasil validasi uji coba pertama dimana hasil uji coba tersebut menampilkan grafik *loss* dari model *Convolution Neural Network* (CNN) yang dibuat dengan tingkat *Loss* pada data *training* (tren merah) memperoleh 0.2% dan data *testing* (tren hijau) memperoleh 0.2% dan *best epoch* 8. dan grafik yang kedua menggambarkan *training* dan *validation accuracy* dimana dalam grafik tersebut dapat disimpulkan bahwa dari hasil uji coba pertama menunjukkan hasil akurasi *training* (tren merah) sebesar 91% hasil akurasi. Grafik dari model CNN yang dibuat dengan tingkat akurasi pada data *training* (tren merah) memperoleh 0.91% dan data *testing* (tren hijau) memperoleh 0.88%.



Gambar 4. Grafik Training Validation A

## 2. Uji Coba Data B

Pada tahap ini dilakukan uji coba B dengan perbandingan data 70:20:10 yaitu data *training* sebanyak 116 data *testing* 33 dan validasi 17 untuk menghasilkan validasi data *training validation accuracy* dan *validation loss* seperti pada gambar 5.

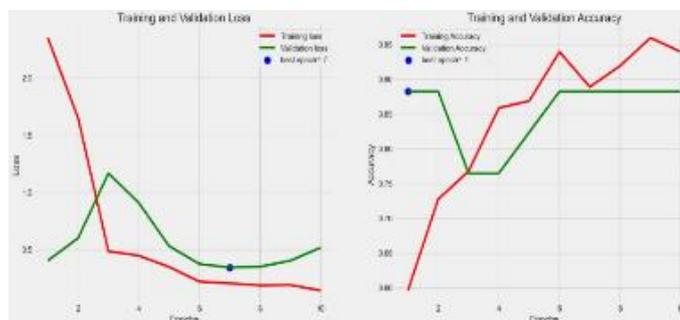


Gambar 5. Grafik Training Validation B

Gambar 5 hasil validasi uji coba pertama dimana hasil uji coba tersebut menampilkan grafik loss dari model CNN yang dibuat dengan tingkat *Loss* pada data *training* (tren merah) memperoleh 0.3% dan data *testing* (tren hijau) memperoleh 0.4% dan *best epoch* 5. dan grafik yang kedua menggambarkan *training* dan *validation accuracy* dimana dalam grafik tersebut dapat disimpulkan bahwa dari hasil uji coba pertama menunjukkan hasil akurasi *training* (tren merah) sebesar 91% hasil akurasi. Grafik dari model CNN yang dibuat dengan tingkat akurasi pada data *training* (tren merah) memperoleh 0.79% dan data *testing* (tren hijau) memperoleh 0.82% serta *best epoch* 8.

## 3. Uji Coba Data C

Pada tahap ini dilakukan uji coba C dengan perbandingan data 60:30:10 yaitu data *training* sebanyak 99 data *testing* 50 dan validasi 17 untuk menghasilkan validasi data *training validation accuracy* dan *validation loss* seperti pada gambar 6.



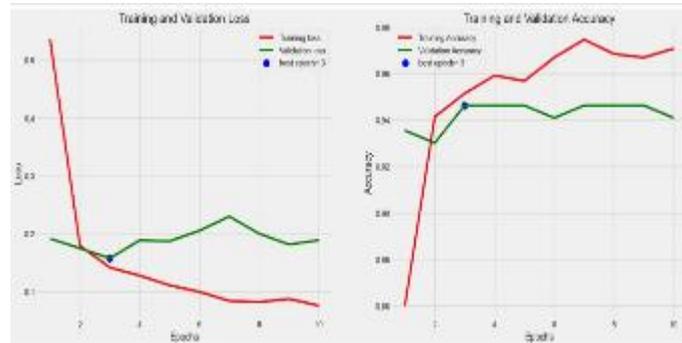
Gambar 6. Grafik Training Validation C

Gambar 6 hasil validasi uji coba pertama dimana hasil ujicoba tersebut menampilkan grafik *loss* dari model CNN yang dibuat dengan tingkat *Loss* pada data *training* (tren merah) memperoleh 0.1% dan data *testing* (tren hijau) memperoleh 0.5% dan *best epoch* 7. dan grafik yang kedua menggambarkan *training* dan *validation accuracy* dimana dalam grafik tersebut dapat disimpulkan bahwa dari hasil uji coba pertama menunjukkan hasil akurasi *training* (tren merah) sebesar 91% hasil akurasi. Grafik dari

model CNN yang dibuat dengan tingkat akurasi pada data *training* (tren merah) memperoleh 0.94% dan data *testing* (tren hijau) memperoleh 0.89% serta *best epoch* 1.

4. Uji Coba Data D

Pada tahap ini dilakukan uji coba D dengan perbandingan data 70:30 untuk menghasilkan validasi data *training validation accuracy* dan *validation loss* seperti pada gambar 7.

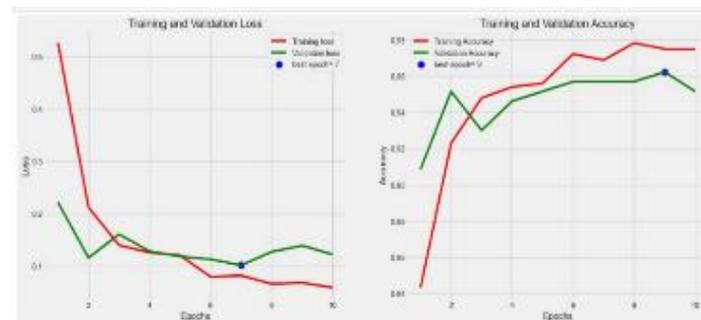


Gambar 7. Grafik Training Validation D

Gambar 7 hasil validasi uji coba pertama dimana hasil ujicoba tersebut menampilkan grafik *loss* dari model CNN yang dibuat dengan tingkat *Loss* pada data *training* (tren merah) memperoleh 0.7% dan data *testing* (tren hijau) memperoleh 0.1% dan *best epoch* 3. dan grafik yang kedua menggambarkan *training* dan *validation accuracy* dimana dalam grafik tersebut dapat disimpulkan bahwa dari hasil uji coba pertama menunjukkan hasil akurasi *training* (tren merah) sebesar 96% hasil akurasi. Grafik dari model CNN yang dibuat dengan tingkat akurasi pada data *training* (tren merah) memperoleh 0.98% dan data *testing* (tren hijau) memperoleh 0.84% serta *best epoch* 3.

5. Uji Coba Data E

Pada tahap ini dilakukan uji coba E dengan perbandingan data 80:20 untuk menghasilkan validasi data *training validation accuracy* dan *validation loss* seperti pada gambar 8.



Gambar 8. Grafik Training Validation E

Gambar 8 hasil validasi uji coba pertama dimana hasil uji coba tersebut menampilkan grafik *loss* dari model CNN yang dibuat dengan tingkat *Loss* pada data *training* (tren merah) memperoleh 0.6% dan data *testing* (tren hijau) memperoleh 0.1% dan *best epoch* 7. dan grafik yang kedua menggambarkan *training* dan *validation accuracy* dimana dalam grafik tersebut dapat disimpulkan bahwa dari hasil uji coba pertama menunjukkan hasil akurasi *training* (tren merah) sebesar 92% hasil akurasi. Grafik dari model CNN yang dibuat dengan tingkat akurasi pada data *training* (tren merah) memperoleh 0.98% dan data *testing* (tren hijau) memperoleh 0.96% serta *best epoch* 9.

Berdasarkan penjelasan uji coba training dan validasi diatas maka hasil tersebut diuraikan pada tabel 1.

Tabel 1. Pengujian data *training* dan validasi

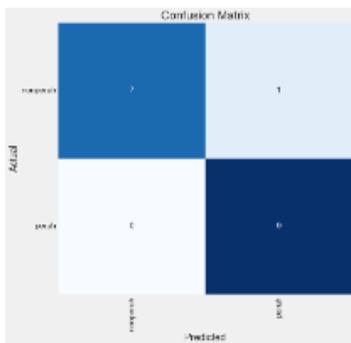
Uji Coba	Model	Training Accuracy	Epoch
1	A: 80:10:10	94%	8
2	B: 70:20:10	89%	8
3	C: 60:30:10	91%	1

Uji Coba	Model	Training Accuracy	Epoch
4	D: 70:30	95%	3
5	E: 80:20	96%	9

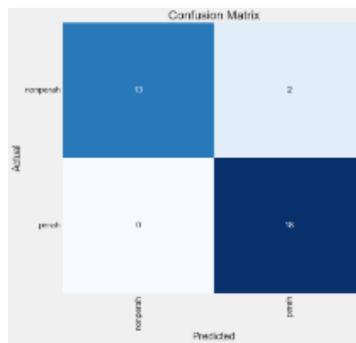
### 3.2. Hasil Pengujian

Untuk mengetahui kinerja dari algoritma CNN maka dilakukan pengujian terhadap model. Hasil klasifikasi akan ditampilkan dalam bentuk *Confusion Matrix*. Berikut ini merupakan pengujian model untuk CNN:

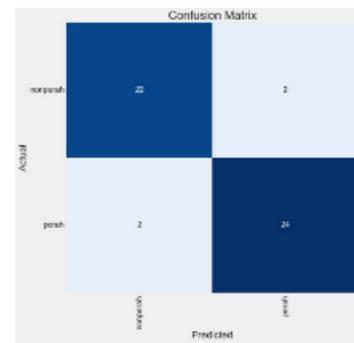
1. Pengujian A: Tahapan proses pengujian model untuk pengujian A dengan perbandingan data 80:10:10 maka akan menampilkan hasil akurasi dan *confusion matrix* 2x2 seperti pada gambar 9. Hasil nilai akurasi yang diperoleh dari pegujian model *Matrix A* sebesar 94% yang proses perhitungannya berdasarkan jumlah nilai dari diagonal *Confusion Matrix* dibagi dengan jumlah seluruh data.
2. Pengujian B: tahapan proses pengujian model untuk pengujian B dengan perbandingan data 70:20:10 maka akan menampilkan hasil akurasi dan *confusion matrix* 2x2 seperti pada gambar 10. Hasil nilai akurasi yang diperoleh dari pegujian model *Matrix B* sebesar 94% yang proses perhitungannya berdasarkan jumlah nilai dari diagonal *Confusion Matrix* dibagi dengan jumlah seluruh data.
3. Pengujian C: tahapan proses pengujian model untuk pengujian C dengan perbandingan data 60:30:10 maka akan menampilkan hasil akurasi dan *confusion matrix* 2x2 seperti pada gambar 11. Hasil nilai akurasi yang diperoleh dari pegujian model *Matrix C* sebesar 92% yang proses perhitungannya berdasarkan jumlah nilai dari diagonal *Confusion Matrix* dibagi dengan jumlah seluruh data.



Gambar 9. Hasil Pengujian A



Gambar 10. Hasil Pengujian B



Gambar 11. Hasil Pengujian C

### 3.3. Evaluasi Model

Setelah Melakukan pengujian model untuk Pengujian A, Pengujian B dan Pengujian C hubungan kemudian dilakukan evaluasi model. Evaluasi model berfungsi untuk menghitung performa dari metode yang digunakan. Hasil dari *precision*, *recall*, dan *f-1 score* di setiap *Class* dapat dilihat dari tabel 2.

Tabel 2. *precision*, *recall*, dan *f-1 score* (CNN)

Pengujian	Class	Precision	Recall	F1-Score
Pengujian A	Non Perah	1.00	0.88	0.93
	Perah	0.99	1.00	0.95
Pengujian B	Non Perah	1.00	0.87	0.93
	Perah	0.90	1.00	0.95
Pengujian C	Non Perah	0.92	0.92	0.92
	Perah	0.92	0.92	0.92

Seperti yang terlihat pada tabel 2 hasil evaluasi model dapat dilihat nilai *Precision*. dan *recall* dari setiap kelas dapat dilihat tingkat kemampuan pemrosesan sistem dalam mencari tingkat ketepatan berdasarkan Pengujian A penentuan jenis sapi dengan kelas non-perah adalah 100% dan non-perah 99% pengujian B penentuan jenis sapi dengan kelas non-perah 100% dan perah 90% dan pengujian C penentuan jenis sapi dengan kelas non-perah 92% dan perah 92%.

Tingkat Keberhasilan dari pemrosesan sistem dalam memperoleh kembali informasi berdasarkan Pengujian A penentuan jenis sapi dengan kelas non-perah adalah 88% dan non perah 100% pengujian B penentuan jenis sapi dengan kelas non perah 87% dan perah 100% dan pengujian C penentuan jenis sapi dengan kelas non perah 92% dan perah 92%.

### 3.4. Implementasi/ Deploy

Setelah tahap pengujian kemudian model di *deploy* dalam bentuk aplikasi dan di Implementasikan sebagai berikut:

### 1. Tampilan Halaman Aplikasi

Gambar 12 menampilkan tampilan *website* untuk menguji model klasifikasi, setelah gambar sapi diupload akan menampilkan hasil klasifikasi, dalam uji coba pada gambar diatas menampilkan gambar seekor sapi berwarna coklat tua kehitaman Model klasifikasi yang digunakan adalah "CNN add Model Xception," yang merupakan model CNN yang dikembangkan untuk meningkatkan akurasi dalam klasifikasi gambar. Tingkat kepercayaan model dalam klasifikasi ini adalah 93%, yang menunjukkan bahwa model sangat yakin dengan prediksi tersebut. Berdasarkan hasil klasifikasi, sapi ini diprediksi sebagai "perah," yang berarti bahwa sapi ini dikategorikan sebagai sapi perah atau sapi yang dipelihara untuk produksi susu.

2. Gambar 13 menampilkan tampilan *website* untuk menguji model klasifikasi, setelah gambar sapi diupload akan menampilkan hasil klasifikasi, dalam uji coba pada gambar diatas menampilkan gambar seekor sapi berwarna coklat tua kehitaman Model klasifikasi yang digunakan adalah "CNN add Model Xception," yang merupakan model CNN yang dikembangkan untuk meningkatkan akurasi dalam klasifikasi gambar. Tingkat kepercayaan model dalam klasifikasi ini adalah 92%, yang menunjukkan bahwa sapi ini dikategorikan sebagai 'potong,' yang berarti sapi tersebut lebih cocok untuk produksi daging daripada susu." Dengan demikian, aplikasi dapat mengidentifikasi jenis pemanfaatan sapi, baik itu perah atau potong, untuk membantu pengguna mengenali klasifikasi sapi secara otomatis sesuai dengan kegunaannya.



**Gambar 12.** Tampilan Uji Klasifikasi Sapi Perah



**Gambar 13.** Tampilan Uji Klasifikasi Sapi Non-Perah

Untuk melakukan klasifikasi gambar menggunakan model CNN. Proses dimulai dengan menerima file gambar yang diunggah pengguna melalui permintaan HTTP dan memvalidasi format file tersebut. File yang valid disimpan sementara dalam direktori yang telah ditentukan, kemudian diubah ke format RGB untuk memastikan kompatibilitas dengan model prediksi. Gambar diproses dengan mengubah ukurannya menjadi 128x128 piksel, diubah ke dalam array numpy, dan dinormalisasi ke rentang nilai [-1, 1]. Selanjutnya, gambar diprediksi menggunakan model deep learning, yaitu model Xception, untuk menghasilkan probabilitas pada setiap kelas target yaitu perah dan non perah. Kelas dengan probabilitas tertinggi diidentifikasi sebagai prediksi, dan tingkat kepercayaannya dihitung sebagai persentase.

### 3.5. Pembahasan

Dalam penelitian ini, model CNN dengan arsitektur Xception digunakan untuk mengklasifikasikan sapi menjadi kategori perah dan non-perah. Hasil pengujian menunjukkan bahwa akurasi model bervariasi tergantung pada pembagian dataset, dengan akurasi tertinggi mencapai 96% pada data training dan 96% pada data testing dalam uji coba E (80:20). Untuk memahami hasil ini secara lebih mendalam, bagian ini akan membahas perbandingan dengan penelitian lain, faktor yang memengaruhi performa model, serta implikasi dari hasil penelitian ini.

Beberapa penelitian sebelumnya yang menggunakan teknik CNN untuk klasifikasi citra ternak atau daging menunjukkan hasil yang beragam tergantung pada arsitektur model dan teknik yang digunakan. Sebuah penelitian yang menggunakan model transfer learning Xception untuk mengklasifikasikan kesegaran daging menunjukkan akurasi sebesar 86,92%. Meskipun perbedaan utama terletak pada jenis data dan tujuan klasifikasi, hasil penelitian ini membuktikan bahwa Xception efektif dalam mengklasifikasikan citra dengan pola visual yang jelas [19]. Penelitian lain yang menggunakan arsitektur EfficientNet-B4 untuk klasifikasi

daging sapi dan babi mencatat akurasi sebesar 95,17%, dengan precision 92,72%, recall 95,5%, dan f1-score 94,09%. Hasil ini sebanding dengan penelitian yang dilakukan, meskipun model yang digunakan berbeda. Hal ini menunjukkan bahwa pemilihan arsitektur yang lebih efisien seperti EfficientNet-B0 dapat memberikan performa yang kompetitif [20]. Selain itu, penelitian lain yang menerapkan EfficientNet-B2 dengan dataset lebih besar dan augmentasi data lebih ekstensif berhasil mencapai akurasi 98,8% dengan precision, recall, dan f1-score yang seimbang. Perbedaan utama dengan penelitian ini adalah penggunaan arsitektur yang lebih ringan dan efisien dibandingkan Xception serta penggunaan dataset yang lebih luas, yang kemungkinan besar berkontribusi pada peningkatan akurasi [21]. Dari ketiga penelitian ini, dapat disimpulkan bahwa performa model CNN sangat bergantung pada pemilihan arsitektur dan metode pemrosesan data.

Beberapa faktor yang mempengaruhi performa model CNN dalam penelitian ini meliputi arsitektur model, ukuran dan distribusi data, teknik augmentasi data, serta pemrosesan citra. Xception merupakan arsitektur yang memiliki performa tinggi dalam klasifikasi citra karena depthwise separable convolution yang memungkinkan model mengekstraksi fitur secara lebih efisien. Meskipun hasil yang diperoleh cukup tinggi, penelitian sebelumnya menunjukkan bahwa arsitektur lain seperti EfficientNet dapat memberikan performa yang lebih optimal dalam beberapa kasus, terutama jika digunakan dengan augmentasi data yang lebih ekstensif. Selain itu, ukuran dan distribusi data sangat berpengaruh terhadap performa model. Pembagian dataset 80:20 dalam uji coba E memberikan hasil terbaik, menunjukkan bahwa model memerlukan proporsi data training yang cukup besar untuk dapat mengenali pola dengan baik. Teknik augmentasi data juga menjadi faktor penting. Jika augmentasi tidak diterapkan, model bisa kesulitan dalam mengenali pola dengan variasi yang lebih luas. Beberapa penelitian sebelumnya membuktikan bahwa augmentasi seperti rotasi, flipping, dan perubahan kontras dapat meningkatkan generalisasi model terhadap data baru. Faktor lain yang tidak kalah penting adalah pemrosesan citra, di mana resolusi dan kualitas citra sangat berpengaruh terhadap performa model. Jika citra memiliki noise atau kualitas yang rendah, model dapat mengalami kesulitan dalam mengekstrak fitur yang relevan.

Hasil yang diperoleh dalam penelitian ini memberikan beberapa implikasi penting dan peluang pengembangan lebih lanjut. Salah satu rekomendasi untuk penelitian mendatang adalah eksplorasi arsitektur yang lebih efisien, seperti EfficientNet atau MobileNet, yang dapat mengurangi ukuran model sambil tetap mempertahankan akurasi yang tinggi. Selain itu, penggunaan dataset yang lebih besar dan lebih bervariasi dapat meningkatkan kemampuan generalisasi model. Penerapan teknik augmentasi data yang lebih kompleks juga dapat meningkatkan performa model dengan memungkinkan model untuk belajar dari lebih banyak variasi pola citra. Evaluasi model juga perlu mempertimbangkan metrik yang lebih luas, seperti precision, recall, dan F1-score, agar mendapatkan gambaran yang lebih komprehensif mengenai performa model.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa Xception mampu memberikan akurasi tinggi dalam klasifikasi sapi perah dan non-perah, sebanding dengan beberapa penelitian sebelumnya yang menggunakan CNN untuk klasifikasi citra terkait. Namun, dengan mempertimbangkan penggunaan arsitektur yang lebih ringan dan optimal seperti EfficientNet, serta penerapan augmentasi data yang lebih luas, ada potensi peningkatan lebih lanjut dalam akurasi dan efisiensi model. Penelitian ini memberikan kontribusi dalam penerapan CNN untuk identifikasi ternak berbasis citra, yang dapat diterapkan dalam industri peternakan untuk otomatisasi proses seleksi sapi perah dan non-perah. Dengan pengembangan lebih lanjut, model ini dapat digunakan dalam sistem berbasis kamera untuk pemantauan dan klasifikasi ternak secara otomatis.

## 5. KESIMPULAN

Penelitian ini berhasil mengimplementasikan model Convolutional Neural Network (CNN) dengan arsitektur Xception untuk mengklasifikasikan sapi menjadi kategori perah dan non-perah berdasarkan citra. Hasil pengujian menunjukkan bahwa model mencapai akurasi tertinggi sebesar 96% pada pembagian dataset 80:20, menunjukkan bahwa model mampu mengidentifikasi pola visual dengan baik. Performa ini sebanding dengan penelitian sebelumnya yang menggunakan arsitektur CNN lain, seperti EfficientNet dan transfer learning, dengan perbedaan pada tingkat akurasi yang dicapai tergantung pada kompleksitas arsitektur dan jumlah data yang digunakan.

Beberapa faktor utama yang mempengaruhi performa model dalam penelitian ini antara lain arsitektur CNN yang digunakan, distribusi dan ukuran dataset, teknik augmentasi data, serta kualitas citra. Xception terbukti efektif dalam mengekstraksi fitur dari citra sapi perah dan non-perah, namun terdapat potensi peningkatan performa dengan eksplorasi model yang lebih efisien. Selain itu, pembagian dataset yang optimal memainkan peran penting dalam mencapai akurasi yang lebih tinggi. Hasil penelitian ini memberikan kontribusi dalam penerapan deep learning untuk klasifikasi ternak berbasis citra, yang dapat diimplementasikan dalam industri peternakan untuk membantu otomatisasi proses identifikasi sapi perah dan non-perah.

Untuk pengembangan lebih lanjut, penelitian ini dapat ditingkatkan dengan mengeksplorasi arsitektur CNN lain yang lebih ringan dan efisien, seperti EfficientNet atau MobileNet, yang memiliki performa tinggi dengan jumlah parameter yang lebih sedikit. Penggunaan dataset yang lebih besar dan lebih bervariasi juga perlu dipertimbangkan untuk meningkatkan kemampuan generalisasi model terhadap berbagai kondisi pencahayaan, sudut pengambilan gambar, dan variasi fisik sapi. Selain itu, penerapan teknik augmentasi data

yang lebih luas, seperti random cropping, adaptive histogram equalization, dan synthetic data generation, dapat membantu meningkatkan ketahanan model terhadap variasi citra yang lebih kompleks. Penelitian di masa depan juga dapat mempertimbangkan penggunaan metode ensemble learning dengan menggabungkan beberapa arsitektur CNN untuk meningkatkan akurasi klasifikasi.

Dari sisi aplikasi, model yang dikembangkan dapat diintegrasikan dengan sistem berbasis kamera real-time untuk otomatisasi pemantauan ternak di peternakan. Penggunaan edge computing atau implementasi dalam perangkat mobile juga dapat menjadi arah penelitian berikutnya agar sistem lebih praktis dan dapat digunakan langsung oleh peternak. Dengan pengembangan lebih lanjut, teknologi ini diharapkan dapat membantu meningkatkan efisiensi dalam industri peternakan dan mendukung otomatisasi berbasis kecerdasan buatan dalam manajemen ternak.

## REFERENSI

- [1] S. H. Syukur, H. Maksun, R. Rahayu, and E. Ardinata, "Respon Kelompok Peternak Terhadap Adanya Bantuan Sapi Potong Di Desa Malonas Kecamatan Dampelas Kabupaten Donggala," *SINERGI : Jurnal Riset Ilmiah*, vol. 1, no. 11, pp. 964–978, 2024, doi: 10.62335/t8sem085.
- [2] R. Subhan, "Jargon dalam Jual Beli Di Pasar Sapi (Studi Komunikasi Transaksi)," *Jurnal Ilmiah FONEMA*, vol. 1, no. 2, pp. 109–121, Nov. 2018, doi: 10.25139/fn.v1i2.1176.
- [3] E. B. David, L. Soegiono, and A. Davianti, "Kerbau Toraja: Harga dan Keberlanjutan," *Perspektif Akuntansi*, vol. 5, no. 2, pp. 083–103, Jul. 2022, doi: 10.24246/persi.v5i2.p083-103.
- [4] D. Ratnasari, A. Atabany, B. P. Purwanto, and L. B. Salma, "Model Pertumbuhan Sapi Perah Friesian Holstein (FH) dari Lahir sampai Beranak Pertama di BBPTU-HPT Sapi Perah Baturraden Menggunakan Model Matematik Logistic," *Jurnal Ilmu Produksi dan Teknologi Hasil Peternakan*, vol. 7, no. 1, pp. 18–31, 2019.
- [5] N. Ginger Budiono, F. Satrija, Y. Ridwan, and D. Nur, "Trematodosis pada Sapi dan Kerbau di Wilayah Endemik Schistosomiasis di Provinsi Sulawesi Tengah, Indonesia (Trematodosis in Cattle and Buffalo Around Schistosomiasis Endemic Areas in Central Sulawesi Province of Indonesia)," *Jurnal Ilmu Pertanian Indonesia (JIPI), Agustus*, vol. 23, no. 2, pp. 112–126, 2018, doi: 10.18343/jipi.23.2.112.
- [6] 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.
- [7] I. DLY, J. Jasril, S. Sanjaya, L. Handayani, and F. Yanto, "Klasifikasi Citra Daging Sapi dan Babi Menggunakan CNN Alexnet dan Augmentasi Data," *Journal of Information System Research (JOSH)*, vol. 4, no. 4, pp. 1176–1185, Jul. 2023, doi: 10.47065/josh.v4i4.3702.
- [8] F. Charli, H. Syaputra, M. Akbar<sup>3</sup>, S. Sauda, and F. Panjaitan, "Implementasi Metode Faster Region Convolutional Neural Network (Faster R-CNN) Untuk Pengenalan Jenis Burung Lovebird," 2020. [Online]. Available: <https://journal-computing.org/index.php/journal-ita/index>
- [9] I. Delfiana, "Sistem Pendukung Keputusan Untuk Pemilihan Sapi Pedaging Impor Terbaik di PT. Juang Jaya Abadi Alam Dengan Menggunakan Metode Multiobjective Optimization On The Basis Of Ratio Analysis (MOORA) Keyword: Sistem Pendukung Keputusan MOORA Sapi Pedaging Impor," *Jurnal CyberTech*, vol. 4, no. 2, 2021, [Online]. Available: <https://ojs.trigunadharma.ac.id/>
- [10] Riswanto, A. Ahmad, Hazriani, and D. Tribuana, "Calorie Detection of Traditional Indonesian Food Using the Single Shot Multibox Detector (SSD) Method," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 3, pp. 819–829, 2024, doi: 10.57152/malcom.v4i3.1332.
- [11] D. Tribuana, Hazriani, and A. Latief Arda, "Image Preprocessing Approaches Toward Better Learning Performance with CNN," *JOURNAL RESTI (Rekayasa Sistem Teknologi Informasi)*, vol. 8, no. 1, pp. 1–9, 2024, doi: 10.29207/resti.v8i1.5417.
- [12] D. Tribuana, H. Hazriani, and A. Latief Arda, "Face recognition for smart door security access with convolutional neural network method," *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, vol. 22, no. 3, pp. 702–710, Jun. 2024, doi: 10.12928/telkomnika.v22i3.25946.
- [13] Y. Zhang, X. Wang, and J. Li, "Fire Detection Using Convolutional Neural Networks," *J Fire Sci*, vol. 38, no. 4, pp. 245–260, 2020.
- [14] Z. Li, F. Liu, W. Yang, S. Peng, and J. Zhou, "A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects," *IEEE Trans Neural Netw Learn Syst*, vol. 33, no. 12, pp. 6999–7019, 2022, doi: 10.1109/TNNLS.2021.3084827.
- [15] Y. Chen, Z. Lin, X. Zhao, G. Wang, and Y. Gu, "Deep Learning-Based Classification of Hyperspectral Data," *IEEE J Sel Top Appl Earth Obs Remote Sens*, vol. 7, no. 6, pp. 2094–2107, 2014, doi: 10.1109/JSTARS.2014.2329330.
- [16] J. Liang, R. He, and T. Tan, "A Comprehensive Survey on Test-Time Adaptation Under Distribution Shifts," *Int J Comput Vis*, vol. 133, no. 1, pp. 31–64, 2025, doi: 10.1007/s11263-024-02181-w.

- [17] J. Wang *et al.*, “Hugs Bring Double Benefits: Unsupervised Cross-Modal Hashing with Multi-granularity Aligned Transformers,” *Int J Comput Vis*, vol. 132, no. 8, pp. 2765–2797, 2024, doi: 10.1007/s11263-024-02009-7.
- [18] X. Chen *et al.*, “Context Autoencoder for Self-supervised Representation Learning,” *Int J Comput Vis*, vol. 132, no. 1, pp. 208–223, 2024, doi: 10.1007/s11263-023-01852-4.
- [19] E. N. Cahyo, E. Susanti, and R. Y. Ariyana, “Model Machine Learning Untuk Klasifikasi Kesegaran Daging Menggunakan Arsitektur Transfer Learning Xception,” *Jurnal Sistem dan Teknologi Informasi (JustIN)*, vol. 11, no. 2, p. 371, Jul. 2023, doi: 10.26418/justin.v11i2.57517.
- [20] A. Paisal, “Klasifikasi Daging Sapi Dan Daging Babi Menggunakan Cnn Dengan Arsitektur Efficientnet-B4 Dan Augmentasi Data,” Universitas Islam Negeri Sultan Syarif Kasim Riau, Pekanbaru, 2023.
- [21] D. Ardianto, “Klasifikasi Citra Daging Sapi Dan Babi Menggunakan Convolutional Neural Network (Cnn) Dengan Arsitektur Efficientnet-B2 Dan Augmentasi Data,” Universitas Islam Negeri Sultan Syarif Kasim Riau, Pekanbaru, 2023.