



Klasifikasi Ras Kelinci Menggunakan Convolutional Neural Network (CNN) untuk Optimasi Sistem Identifikasi Visual

Maasyaril Kirom Mi'Rojul Huda*, Arita Witanti

Fakultas Teknologi Informasi, Program Studi Informatika, Universitas Mercu Buana Yogyakarta, Sleman
Jl. Jembatan Merah No.84C, Soropadan, Condongcatur, Kec. Depok, Kabupaten Sleman, Daerah Istimewa Yogyakarta,
Indonesia

Email: ¹*211110133@student.mercubuana-yogya.ac.id, ²arita@mercubuana-yogya.ac.id

Email Penulis Korespondensi: 211110133@student.mercubuana-yogya.ac.id

Submitted: 06/01/2025; Accepted: 18/01/2025; Published: 18/01/2025

Abstrak—Kelinci merupakan hewan mamalia yang mempunyai berbagai jenis dengan ciri fisik yang unik dan beragam. Membedakan berbagai jenis kelinci, terutama yang memiliki kemiripan fisik dan corak warna, menjadi tantangan tersendiri bagi sebagian orang karena penampilan visualnya yang serupa. Tujuan penelitian ini untuk mengembangkan sistem klasifikasi jenis kelinci berbasis Convolutional Neural Network (CNN) menggunakan arsitektur MobileNetV3. Dataset berisi 1.500 gambar dari tiga jenis kelinci (bligon, hyla, dan new zealand white) diolah melalui resizing, augmentasi, dan normalisasi untuk meningkatkan kualitas data. Model dilatih menggunakan optimizer Adam dengan hasil akurasi 97% pada data validasi dan 90% pada dataset eksternal, menunjukkan kemampuan generalisasi yang baik. Hasil ini menegaskan efektivitas CNN dibanding metode manual dalam pengenalan pola visual, sekaligus mengatasi keterbatasan waktu dan kesalahan manusia. Meski demikian, keterbatasan pada variasi dataset, seperti pencahayaan dan sudut pengambilan gambar, memengaruhi generalisasi model. Penelitian ini tidak hanya mendukung efisiensi pengelolaan peternakan tetapi juga menunjukkan potensi besar penerapan AI di sektor peternakan Indonesia. Pengembangan dataset yang lebih beragam dan eksplorasi arsitektur model lain direkomendasikan untuk peningkatan kinerja di masa depan.

Kata Kunci: Klasifikasi; Kelinci; Convolutional Neural Network; MobileNetV3; TensorFlow; Peternakan

Abstract—Rabbits are mammals that come in many varieties with unique and diverse physical characteristics. Differentiating various types of rabbits, especially those with physical similarities and color patterns, is a challenge for some people because of their similar visual appearance. The purpose of this research is to develop a Convolutional Neural Network (CNN)-based rabbit breed classification system using MobileNetV3 architecture. A dataset of 1,500 images of three rabbit breeds (bligon, hyla, and new zealand white) was processed through resizing, augmentation, and normalization to improve data quality. The model was trained using Adam's optimizer with 97% accuracy on the validation data and 90% on the external dataset, showing good generalization ability. These results confirm the effectiveness of CNNs over manual methods in visual pattern recognition, while overcoming time constraints and human error. However, limitations in dataset variations, such as lighting and image capture angle, affect the generalization of the model. This research not only supports the efficiency of livestock management but also shows the great potential of AI application in Indonesia's livestock sector. Development of more diverse datasets and exploration of other model architectures are recommended for future performance improvements.

Keywords: Classification; Rabbit; Convolutional Neural Network; MobileNetV3; TensorFlow; Farm

1. PENDAHULUAN

Kelinci merupakan salah satu hewan mamalia yang saat ini populasinya semakin banyak di Indonesia. Keberadaan kelinci tidak hanya terbatas di daerah pedesaan, tetapi juga telah menyebar hingga ke perkotaan. Kelinci kini banyak dipelihara sebagai hewan peliharaan maupun ditanamkan untuk tujuan komersial [1]. Dengan permintaan yang terus meningkat, baik untuk konsumsi maupun sebagai hewan peliharaan (hobi), kelinci menjadi komoditas yang menjanjikan di sektor peternakan [2]. Selain itu, budidaya kelinci relatif mudah dan dapat dilakukan dalam berbagai skala, dari skala rumah tangga hingga peternakan komersial besar. Beberapa jenis kelinci yang populer di Indonesia, seperti New Zealand White, Bligon, dan Hyla, memiliki karakteristik yang berbeda, baik dari segi produktivitas maupun penyesuaian terhadap lingkungan. Popularitas kelinci sebagai hewan ternak disebabkan oleh berbagai faktor, termasuk nilai ekonomisnya sebagai sumber protein hewani, dagingnya yang rendah kolesterol, serta kemampuan reproduksinya yang tinggi [3]. Selain itu, kelinci juga memiliki waktu panen yang relatif singkat, sehingga menjadi pilihan yang menguntungkan bagi peternak yang menginginkan hasil cepat. Dalam konteks bisnis, kelinci dapat dimanfaatkan secara multifungsi, mulai dari dagingnya yang bernilai tinggi, bulunya yang bisa dijadikan bahan tekstil, hingga kotorannya yang digunakan sebagai pupuk organik [4].

Namun, mengenali jenis kelinci secara akurat bukanlah tugas yang mudah, terutama bagi peternak atau penghobi yang tidak memiliki pengalaman mendalam. Metode identifikasi manual mengandalkan pengamatan visual langsung yang memerlukan keahlian dan pengalaman untuk mengenali perbedaan karakteristik setiap jenis kelinci. Proses ini tidak cuma menyita waktu tapi juga rentan terhadap kekeliruan, terutama ketika jumlah kelinci yang dikelola cukup besar. Kesalahan dalam identifikasi dapat berujung pada pengelolaan yang kurang optimal, seperti penempatan kelinci yang tidak sesuai dengan kebutuhan atau tujuan pemeliharaan tertentu, misalnya untuk produksi daging atau pengembangbiakan. Tantangan ini semakin terasa di peternakan berskala besar seperti Wusono Farm, di mana efisiensi operasional menjadi prioritas utama. Proses identifikasi manual membutuhkan sumber daya manusia yang memadai dan terampil, yang pada kenyataannya sulit untuk selalu tersedia. Selain itu, kendala waktu menjadi salah satu faktor signifikan dalam pengelolaan harian. Kesalahan identifikasi dapat



berdampak pada penurunan produktivitas, pengelolaan pakan yang tidak efisien, serta potensi terjadinya persilangan yang tidak diinginkan, yang pada akhirnya memengaruhi kualitas hasil peternakan secara keseluruhan. Apalagi para peternak yang memelihara kelinci menggunakan metode tradisional secara intensif [5].

Untuk mengatasi tantangan identifikasi manual jenis kelinci, solusi yang ditawarkan adalah pemanfaatan teknologi Convolutional Neural Network (CNN). CNN ialah salah satu pendekatan dalam deep learning yang dirancang khusus untuk menganalisis data berbentuk gambar [6]. Teknologi ini mampu secara otomatis mengenali pola, fitur, dan karakteristik unik dari gambar dengan tingkat akurasi yang sangat tinggi. Dalam konteks identifikasi jenis kelinci, CNN dapat membantu mengelompokkan kelinci berdasarkan ciri-ciri visual seperti warna, bentuk tubuh, atau pola bulu. Keunggulan utama CNN berada pada keahliannya untuk bekerja secara otomatis dan efisien pada sebuah objek [7]. Teknologi ini tidak memerlukan proses pengolahan gambar yang rumit oleh manusia, karena CNN dapat langsung mengekstraksi informasi penting dari gambar [8]. Selain itu, CNN mampu terus belajar dan meningkatkan akurasinya seiring dengan bertambahnya jumlah data pelatihan [9]. Hal ini menjadikannya sangat cocok untuk diaplikasikan di sektor peternakan yang memerlukan kecepatan dan konsistensi dalam proses identifikasi. Dalam penelitian ini, CNN digunakan untuk membangun sistem klasifikasi visual yang dapat mengenali jenis kelinci secara tepat dan akurat. Program ini dirancang guna membantu peternakan seperti Wusono Farm dalam meningkatkan efisiensi pengelolaan kelinci, mulai dari penempatan yang tepat hingga perencanaan pengembangbiakan yang lebih terarah. Dengan implementasi teknologi ini, diharapkan peternakan dapat meminimalkan kesalahan identifikasi, menghemat waktu, meningkatkan produktivitas secara keseluruhan, dan semakin relevan perkembangan teknologi dalam sektor peternakan.

Berbagai penelitian sebelumnya telah menunjukkan potensi teknologi Convolutional Neural Network (CNN) dalam mengatasi tantangan pengenalan gambar di berbagai bidang. Penelitian terkait yang sudah dilaksanakan sebelumnya diantaranya : menurut (Gunawan, Hanafie, & Elanda, 2024) [10] Penelitian terkait tentang klasifikasi ras kucing menggunakan CNN menunjukkan akurasi pelatihan 77.62% dan validasi 60%, dengan indikasi overfitting akibat dataset kecil (1.500 gambar untuk lima kelas) hasil penelitian ini menunjukkan adanya fluktuasi pada proses pelatihan dan kesenjangan yang signifikan antara akurasi pelatihan dan validasi, yang mengindikasikan kemungkinan terjadinya overfitting. Penelitian (Rhamadiyah & Kusri, 2024) [11], ini menggunakan teknik augmentasi data untuk meningkatkan kemampuan klasifikasi dataset citra apel dengan CNN. Empat kiat augmentasi diterapkan: flipping, rotation, cropping dan noise injection, baik secara individu maupun kombinasi. Teknik noise injection menghasilkan akurasi tertinggi (98,82%), sedangkan cropping memiliki akurasi terendah (67,46%). Kombinasi teknik augmentasi tidak selalu memberikan efek sinergis, terutama jika terjadi konflik antara variasi yang dihasilkan. Adapun penelitian lainnya yaitu yang dilakukan oleh (Malika & Widodo, 2022) [12], penelitian ini menggunakan dataset 300 gambar motif batik Sasambo yang diklasifikasikan ke tiga kategori menggunakan CNN dengan empat lapisan konvolusi. Model mencapai akurasi 100% untuk data pelatihan, tetapi hanya 80% pada data pengujian dan 73,33% pada data baru, menunjukkan keterbatasan generalisasi akibat kemiripan visual antar motif. Penelitian ini menunjukkan potensi CNN untuk pengenalan pola batik dalam pelestarian budaya, namun perlu pengembangan lebih lanjut seperti memperbesar dataset atau menggunakan teknik augmentasi data. Penelitian yang memanfaatkan metode Convolutional Neural Network (CNN) untuk klasifikasi obyek sudah memperlihatkan hasil besar dalam berbagai domain. Misalnya, penelitian oleh Budi Yanto et al. (2021) [13], Penelitian ini menggunakan CNN untuk mengklasifikasikan tingkat kematangan jeruk manis berdasarkan kecerahan warna, mengatasi kelemahan metode manual seperti keterbatasan visual dan waktu. Dengan dataset 100 citra jeruk, model mencapai akurasi 97,52% pada data pelatihan dan 92% pada data pengujian, menunjukkan efektivitas CNN dalam membedakan fitur tekstur dan warna pada citra jeruk. Terdapat juga penelitian yang telah dikerjakan oleh Rahmad Firdaus et al. (2022) [14], Penelitian ini menggunakan CNN untuk mengklasifikasikan jenis kelamin manusia berdasarkan citra mata, dengan dataset 11.525 gambar (6.323 mata pria dan 5.202 mata wanita). Tahapan meliputi prapemrosesan data, pemisahan dataset, dan evaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score. Model CNN mencapai akurasi 94%, dengan presisi 97% untuk label femaleeyes dan 90% untuk maleeyes, serta F1-score masing-masing 94% dan 93%.

Berdasarkan beberapa penelitian yang sudah dilaksanakan, dapat disimpulkan bahwa klasifikasi menggunakan CNN pada objek telah menunjukkan hasil yang signifikan dalam berbagai kasus, CNN terbukti efektif dalam mengekstraksi fitur penting dari gambar dan menghasilkan akurasi tinggi pada data pelatihan. Di Indonesia, penelitian tentang penerapan CNN dalam klasifikasi jenis kelinci masih sangat terbatas. Hal ini menciptakan gap penelitian yang signifikan, mengingat pentingnya identifikasi visual yang cepat dan akurat dalam mendukung pengelolaan peternakan kelinci. Penelitian ini berusaha mengisi gap tersebut dengan mengembangkan sistem berbasis CNN untuk klasifikasi jenis kelinci. Sebagian besar dari penelitian lebih berfokus pada hewan lain atau objek umum.

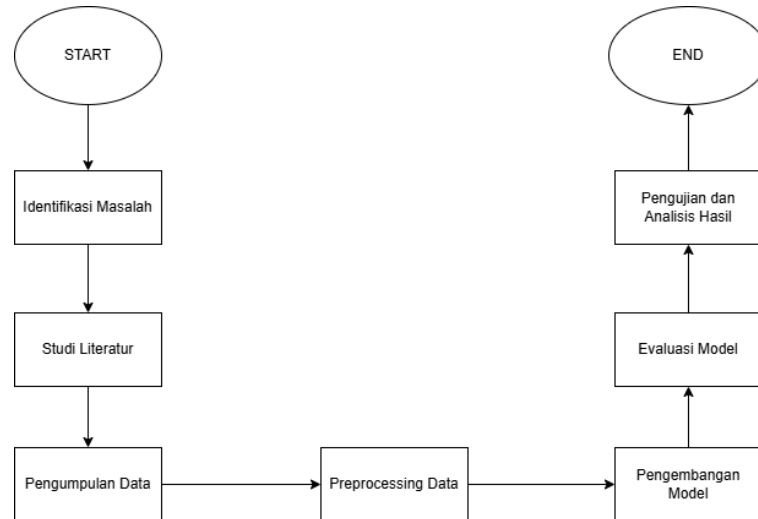
Penelitian ini bertujuan guna mengembangkan sistem identifikasi visual berbasis CNN yang dapat mengklasifikasikan jenis kelinci dengan akurasi yang baik. Kontribusi yang diinginkan dari penelitian ini meliputi: pengembangan dataset citra jenis kelinci yang representatif, implementasi teknologi AI dalam mendukung efisiensi sektor peternakan serta penyediaan solusi praktis untuk mengoptimalkan pengelolaan peternakan, khususnya di Wusono Farm. Dengan demikian, penelitian ini diharapkan dapat memberikan dampak positif bagi pengembangan teknologi di sektor peternakan, sekaligus membuka peluang untuk penelitian lanjutan di bidang klasifikasi hewan menggunakan AI. Dengan memanfaatkan dataset yang relevan dan teknologi terkini, diharapkan

penelitian ini tidak hanya memberikan kontribusi ilmiah, tetapi juga mendukung penerapan teknologi berbasis kecerdasan buatan di sektor peternakan Indonesia.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Supaya studi ini terlaksana dengan baik, sangat penting untuk mengikuti setiap tahapan dan urutan dalam prosesnya. Tahapan penelitian yang dirancang bertujuan untuk menyelesaikan penelitian ini secara menyeluruh. Tahapan tersebut juga digunakan agar proses penelitian dapat berjalan secara terstruktur dan efektif. Adapun seluruh langkah-langkah tersebut dapat diketahui pada Gambar 1 berikut:



Gambar 1. Tahapan penelitian

Penelitian diawali dengan tahap identifikasi masalah, kemudian dilakukan tahapan studi literatur untuk mendalami konteks penelitian. Sesudah itu, dilaksanakan suatu pengumpulan data yang relevan dan preprocessing data untuk mempersiapkan data. Selanjutnya, pengembangan model dilakukan dengan melatih model sesuai metode yang digunakan. Kemudian hasil model dievaluasi pada tahap evaluasi model, diikuti dengan pengujian dan analisis hasil untuk menilai kinerja model dan menyimpulkan hasil penelitian. Tahapan ini dilakukan secara sistematis untuk mencapai tujuan penelitian.

2.1.1 Identifikasi Masalah

Penelitian ini dimulai dengan mengidentifikasi masalah terkait kebutuhan sistem otomatis untuk klasifikasi jenis kelinci menggunakan teknologi modern. Permasalahan ini melatarbelakangi pentingnya penerapan metode berbasis kecerdasan buatan, khususnya CNN, yang telah terbukti efektif dalam pengolahan citra untuk mengatasi keterbatasan tersebut.

2.1.2 Studi Literatur

Mengkaji penelitian sebelumnya tentang deep learning dan CNN yang telah diterapkan pada klasifikasi gambar hewan. Memahami teknik preprocessing data dan model CNN yang efektif untuk klasifikasi. Tahapan ini melibatkan kajian literatur terkait klasifikasi gambar menggunakan CNN, baik dari jurnal maupun dari artikel ilmiah. Studi ini memiliki tujuan untuk memahami konsep dasar metode CNN, algoritma yang relevan, serta penelitian-penelitian sebelumnya yang dapat menjadi sumber acuan dalam membangun model klasifikasi jenis kelinci.

2.1.3 Pengumpulan Data

Proses pengumpulan data berperan penting dalam menentukan keberhasilan tahap pengolahan data berikutnya [15]. Dataset yang dipakai dalam penelitian ini mencakup tiga kategori spesies kelinci yang berbeda, yang diambil secara langsung di Wusono Farm, menggunakan kamera handphone tipe Redmi Note 8 Pro dengan resolusi 64MP. Ketiga kelas berbeda tersebut yaitu kelinci bligon, hyla dan new zealand white. Total data yang diambil berjumlah 1.500 data dengan masing-masing kelas terdiri atas 500 data untuk kelinci bligon, 500 data kelinci hyla dan 500 data kelinci new zealand white. Distribusi data diperiksa secara statistik dan manual untuk memastikan setiap kelas memiliki jumlah gambar yang setara/seimbang. Gambar yang buram atau berkualitas rendah dihapus untuk memastikan dataset memiliki kualitas yang memadai. Proses pengumpulan data menghadapi beberapa tantangan atau potensi limitasi, seperti variasi kualitas gambar akibat penggunaan kamera handphone, pencahayaan dan sudut



pengambilan gambar serta latarbelakang kandang. Keterbatasan ini dapat memengaruhi kualitas data secara keseluruhan. Oleh karena itu, perlu dilakukan tahapan preprocessing data.

2.1.4 Preprocessing Data

Tahapan preprocessing bertujuan untuk mempersiapkan data agar sesuai dengan kebutuhan model CNN. Preprocessing juga dilakukan agar mempermudah dalam pengolahan data sekaligus meningkatkan kualitas data yang akan digunakan [16]. Proses ini meliputi resizing gambar ke ukuran standar, seperti 224x224 piksel, untuk konsistensi input. Dan tiga warna red, green dan blue (RGB) data diproses dengan memanfaatkan ImageDataGenerator dari library Tensorflow Keras. TensorFlow digunakan untuk berbagai tugas dalam kecerdasan buatan, salah satunya pemrosesan gambar [17]. Selanjutnya, dilakukan augmentasi data seperti rotasi, flipping, perubahan pencahayaan, dan translasi untuk meningkatkan keragaman data. Tujuan dari augmentasi data adalah untuk membantu sebuah mesin untuk belajar dan mengenali berbagai jenis citra yang beragam, sekaligus digunakan untuk menambah jumlah data secara virtual [18]. Normalisasi nilai piksel juga diterapkan untuk mempercepat proses pelatihan model.

2.1.5 Pengembangan Model

Pada tahap ini, pengembangan model dilakukan menggunakan Google Colab dengan dukungan GPU Tesla T4 untuk mempercepat proses pelatihan. Perangkat lunak yang digunakan ialah Python 3.10 dengan pustaka TensorFlow versi 2.12 dan Keras sebagai framework utama untuk membangun dan melatih model CNN. Model CNN dirancang dan dikembangkan menggunakan arsitektur yang sesuai dengan karakteristik data. Arsitektur yang dipilih adalah MobileNetV3. Arsitektur CNN ini memberikan akurasi yang tinggi, latensi yang rendah dan efisiensi yang optimal [19]. Arsitektur model mencakup lapisan convolutional untuk ekstraksi fitur, pooling digunakan untuk pengurangan dimensi, serta fully connected layer guna proses klasifikasi. Untuk mengoptimalkan performa model, dilakukan penyesuaian hyperparameter, termasuk learning rate sebesar 0.001, ukuran batch 32 dan jumlah epoch sebanyak 30. Model dilatih menggunakan dataset latih, Dataset dibagi menjadi 70% untuk data latih, 20% untuk data validasi, dan 10% untuk data uji. Serta optimasi Adam, algoritma adam merupakan algoritma optimasi yang berfungsi untuk memperbarui bobot pada jaringan secara bertahap menggunakan data pelatihan [20].

2.1.6 Evaluasi Model

Setelah dilakukan pelatihan, model akan dievaluasi dengan data uji untuk mengetahui serta mengukur performa. Evaluasi dilakukan dengan menggunakan metrik semacam akurasi, presisi, recall, dan F1-score. Metrik-metrik tersebut berguna untuk menilai seberapa bagus model saat mengenali jenis kelinci pada gambar baru. Selain itu, confusion matrix digunakan untuk menganalisis distribusi prediksi dan kesalahan klasifikasi antar kelas. Selama proses pelatihan, grafik validation loss dan accuracy dimonitor secara berkala untuk mengidentifikasi potensi masalah seperti overfitting atau underfitting.

Berikut adalah rumus untuk metrik evaluasi model mencakup akurasi, presisi, recall, dan F1-score:

a. Akurasi (Accuracy)

Akurasi mengukur prosentase prediksi yang benar dari jumlah data yang diuji.

$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Jumlah Data}} \times 100\% \tag{1}$$

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \tag{2}$$

True Positive (TP) mengacu pada prediksi yang benar ketika model berhasil mengidentifikasi kelas positif dengan tepat. True Negative (TN) adalah prediksi yang betul ketika model mengenali kelas negatif secara akurat. False Positive (FP) terjadi ketika model salah mengklasifikasikan kelas negatif sebagai kelas positif. Sementara itu, False Negative (FN) adalah kesalahan prediksi di mana model gagal mengidentifikasi kelas positif dan justru mengklasifikasikannya sebagai kelas negatif.

b. Presisi (Precision)

Presisi untuk mengukur korespondensi prediksi positif yang betul dari seluruh prediksi positif.

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

c. Recall (Sensitivity)

Recall mengukur keahlian model dalam mendeteksi semua data aktual positif.

$$\text{Recall} = \frac{TP}{TP+FN} \times 100\% \tag{4}$$

d. F1-Score

F1-Score ialah rata-rata dari harmonis antara presisi dan recall, yang memberi keseragaman antara kedua metrik tersebut.

$$F1 - \text{Score} = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \tag{5}$$

2.1.7 Pengujian dan Analisis

Tahap terakhir mencakup pengujian model pada data yang tidak dikenal sebelumnya untuk menilai kemampuan generalisasinya. Hasil pengujian kemudian dianalisis untuk menilai keakuratan prediksi serta mengidentifikasi kelebihan dan kekurangan model. Analisis ini memberikan gambaran apakah model sudah memenuhi tujuan penelitian atau masih memerlukan penyempurnaan lebih lanjut. Kesalahan klasifikasi dianalisis untuk mengidentifikasi pola yang sulit dikenali oleh model, seperti gambar dengan kualitas rendah atau kemiripan antar jenis kelinci.

3. HASIL DAN PEMBAHASAN

3.1 Hasil

Penelitian ini dilakukan dengan memanfaatkan dataset yang telah dikumpulkan secara langsung dari Wusono Farm, dataset berisi gambar-gambar dari tiga jenis kelinci yang berbeda, yaitu New Zealand White, Hyla, dan Bligon. Dimana setiap kelas memiliki data sebanyak 500 gambar sehingga total dataset dari ketiga kelas tersebut adalah 1.500. Dataset tersebut disiapkan melalui serangkaian tahap preprocessing guna memastikan kualitas dari data yang optimal sebelum dipergunakan pada proses pelatihan model. Proses preprocessing mencakup resizing gambar ke resolusi standar 224x224 piksel, penerapan teknik augmentasi data juga diterapkan untuk meningkatkan variasi dan jumlah data secara virtual, serta normalisasi nilai piksel untuk menyesuaikan rentang data agar lebih sesuai dengan kebutuhan model. Untuk proses klasifikasi jenis kelinci, digunakan model Convolutional Neural Network (CNN) yang didukung arsitektur MobileNetV3, yang dikenal karena keunggulannya dalam efisiensi komputasi dan akurasi pada tugas-tugas pengenalan objek. Pendekatan ini diharapkan mampu menghasilkan model yang andal dalam mengenali jenis kelinci secara akurat berdasarkan gambar yang tersedia. Hasil dari proses pelatihan model menunjukkan bahwa arsitektur MobileNetV3 mampu memberikan performa yang sangat baik dalam mengklasifikasikan gambar. Hal ini diperoleh karena penggunaan algoritma optimasi Adam yang secara efektif menyesuaikan parameter model selama proses pelatihan. Kombinasi antara keunggulan arsitektur MobileNetV3, yang dirancang untuk efisiensi tinggi dan akurasi optimal, serta kualitas algoritma Adam, menjadikan model ini mampu menghasilkan hasil yang memuaskan dalam tugas klasifikasi yang dilakukan. Berikut Gambar 2 menampilkan hasil classification report bisa dilihat dibawahh:

Classification Report:				
	precision	recall	f1-score	support
Kelinci Bligon	0.98	0.94	0.96	50
Kelinci Hyla	0.98	1.00	0.99	50
Kelinci New Zealand White	0.96	0.98	0.97	50
accuracy			0.97	150
macro avg	0.97	0.97	0.97	150
weighted avg	0.97	0.97	0.97	150


Gambar 2. Clasification report

Laporan klasifikasi di atas menunjukkan performa model dalam mengklasifikasikan tiga jenis kelinci, yaitu Kelinci Bligon, Kelinci Hyla, dan Kelinci New Zealand White. Model berhasil mengklasifikasikan tiga jenis kelinci dengan performa tinggi, mencapai akurasi 97%. Precision untuk setiap kelas berkisar antara 0.96 hingga 0.98, dengan recall terbaik pada Kelinci Hyla sebesar 1.00. Nilai F1-score juga tinggi, yaitu 0.96 hingga 0.99. Rata-rata metrik secara keseluruhan (macro dan weighted) adalah 0.97, menunjukkan model mampu memberikan prediksi yang akurat dan seimbang di semua kelas. Secara keseluruhan, model memperlihatkan keterampilan yang sangat baik dalam mengklasifikasikan tiga jenis kelinci dengan akurasi dan F1-score yang tinggi.

3.2 Pembahasan

Penelitian ini memberikan hasil temuan bahwa model Convolutional Neural Network (CNN) yang sudah dibangun sukses memperoleh tingkat presentasi sebesar 97% pada data validasi. Akurasi tersebut dicapai setelah pelatihan model dilakukan selama 30 epoch, yang memperlihatkan bahwa model bisa belajar secara baik dari data yang tersedia dalam waktu pelatihan yang relatif singkat. Keberhasilan ini mencerminkan efektivitas arsitektur dan parameter yang digunakan dalam membangun model, sekaligus menegaskan potensi model dalam menyelesaikan tugas klasifikasi dengan tingkat keandalan yang tinggi. Dalam penelitian ini, dataset yang digunakan dibagi terlebih dahulu kedalam dua bagian pokok, yaitu data latih (training data) serta data uji (testing data), dengan proporsi pembagian sebesar 70:30. Artinya, 70% dari total dataset digunakan untuk melatih model sehingga mampu mengidentifikasi pola dan karakteristik data, sementara 30% sisanya diperuntukkan untuk mengevaluasi atau menguji kinerja model dalam menciptakan prediksi pada sebuah data yang sama sekali belum pernah

diketahui sebelum nya. Pendekatan ini dirancang guna memastikan bahwa model tidak sekedar mempelajari data secara berlebihan (overfitting), namun mampu menunjukkan kemampuan generalisasi yang akurat pada data yang baru. Pembagian ini merupakan praktik umum dalam pembelajaran mesin untuk mengevaluasi keefektifan model secara objektif. Berikut Gambar 3 menyajikan grafik yang memperlihatkan hasil akurasi dan loss sepanjang proses pelatihan (training) dan validasi.



Gambar 3. Plotting Akurasi dan Loss

Gambar plotting akurasi dan loss memberikan informasi lebih rinci mengenai performa model selama pelatihan. Grafik menunjukkan peningkatan akurasi dan penurunan loss selama 30 epoch, menandakan model belajar dengan baik. Akurasi pelatihan dan validasi meningkat, meski akurasi validasi sedikit fluktuatif. Loss pelatihan dan validasi menurun, meskipun validation loss mengalami beberapa fluktuasi, yang mungkin mengindikasikan potensi overfitting ringan. Secara keseluruhan, model menunjukkan performa yang baik.

Model berbasis MobileNetV3 menunjukkan akurasi tinggi, namun memiliki beberapa keterbatasan. Potensi bias dalam dataset, seperti kurangnya keragaman pencahayaan, sudut, dan pose kelinci, dapat memengaruhi kemampuan model untuk mengenali pola pada data baru. Selain itu, kapasitas MobileNetV3 yang lebih sederhana dibandingkan arsitektur kompleks, seperti ResNet, dapat membatasi performa pada kondisi gambar dengan latar belakang ramai atau resolusi rendah. Keterbatasan ini menunjukkan perlunya peningkatan diversitas dataset dan eksplorasi arsitektur yang lebih kuat untuk meningkatkan generalisasi model.

3.2.1 Evaluasi

Tahap evaluasi bertujuan untuk menilai seberapa efektivitas model yang sudah dipilih untuk proses penelitian. Dalam melakukan evaluasi, dibutuhkan suatu tabel yang akan digunakan untuk menilai performa model klasifikasi pada pembelajaran mesin. Tabel tersebut ialah Confusion Matrix, yang memanfaatkan perpaduan antara nilai aktual dan nilai prediksi. Analisis ini memberikan hasil untuk mengevaluasi kinerja model secara mendalam, termasuk mengidentifikasi kesalahan dalam klasifikasi serta mengukur tingkat akurasi model dalam mengelompokkan data ke kategori yang tepat. Berikut hasil confusion matrix bisa dilihat dalam Gambar 3 dibawah ini.



Gambar 3. Confusion Matrix

Gambar 3 menunjukkan confusion matrix hasil klasifikasi model terhadap tiga jenis kelinci: Bligon, Hyla, dan New Zealand White. Model berhasil mengklasifikasikan 47 dari 50 data kelinci Bligon dengan benar, meskipun terjadi kesalahan pada 3 data (1 diklasifikasikan sebagai New Zealand White dan 2 sebagai Hyla). Untuk kelinci Hyla, model mampu mengklasifikasikan semua data dengan akurat tanpa kesalahan. Sementara itu, kelinci New Zealand White diklasifikasikan dengan benar pada 49 data, dengan satu data kelinci Bligon yang salah dikenali sebagai jenis ini. Confusion matrix ini mengindikasikan performa model yang sangat baik dengan akurasi tinggi dalam tugas klasifikasi.

3.2.2 Pengujian Hasil Klasifikasi Jenis Kelinci dengan Dataset Eksternal

Dataset eksternal digunakan untuk mengevaluasi performa model di luar data latih dan uji yang telah disiapkan. Dataset ini berisi total 150 gambar, terdiri dari 50 gambar untuk setiap kelas: Kelinci Bligon, Hyla, dan New Zealand White. Gambar-gambar tersebut diperoleh dari google dan website Pinterest berikut penulis sertakan link nya <https://id.pinterest.com/>. sehingga terdapat variasi pencahayaan, sudut pengambilan, dan kualitas gambar. Dataset pengujian ini dipilih secara manual untuk memastikan representasi yang seimbang dan mencakup berbagai skenario yang relevan. Pada tahap pengujian, model akan memberikan prediksi berupa kelas atau kategori dari setiap gambar yang diuji. Hasil prediksi ini kemudian akan dibandingkan dengan label sebenarnya untuk mengevaluasi akurasi model dalam mengklasifikasikan jenis kelinci. Pengujian ini menggunakan learning rate sebesar 0.001, ukuran batch 32 dan jumlah epoch 10. Berikut adalah hasil evaluasi model berdasarkan dataset eksternal pada pengujian kelinci jenis bligon. Hasil evaluasi metrik ditampilkan pada Tabel 2 berikut:

Tabel 1. Hasil evaluasi metrik dataset eksternal

Metrik Evaluasi	Nilai (%)
Akurasi	90%
Presisi	100%
Recall	90%
F1-Score	94.7%

Berdasarkan Tabel 2 tersebut menunjukkan bahwa model dapat mengklasifikasikan jenis kelinci bligon dengan tingkat keakuratan yang baik. Hal ini ditunjukkan melalui hasil evaluasi metrik yang mencakup akurasi, presisi, recall, dan F1-Score, yang semuanya menandakan kemampuan yang solid untuk mengidentifikasi jenis kelinci tersebut secara akurat dan konsisten. Berikut adalah perhitungan manual akurasi untuk kasus ini:

Diketahui :

Jumlah data uji = 50

Jumlah prediksi benar = 45

Rumus Akurasi :

$$Akurasi = \frac{Jumlah\ Prediksi\ Benar}{Total\ Jumlah\ Data} \times 100\% \tag{1}$$

Perhitungan :

$$Akurasi = \frac{45}{50} \times 100\% = 0.9\ \text{atau}\ 90\%$$

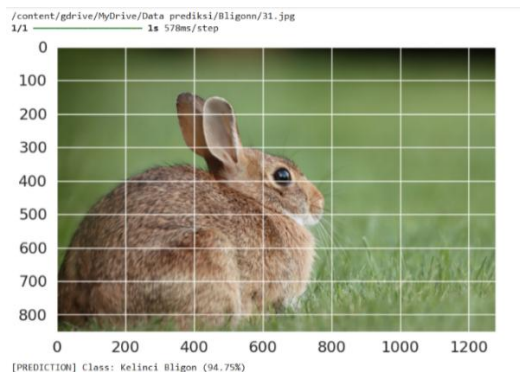
Kesimpulan :

Akurasi model adalah 90%, yang berarti dari 50 data, 45 diprediksi dengan benar.

Berikut adalah hasil lengkap dari pengujian model untuk klasifikasi jenis kelinci:

a. Pengujian pada jenis kelinci bligon

Hasil dari pengujian menggunakan gambar kelinci bligon bisa diketahui pada gambar 4 dibawah berikut:




Gambar 4. Hasil Pengujian Jenis Kelinci Bligon

Dari Gambar 4 membuktikan bahwa model dapat memprediksi class jenis kelinci dalam gambar sebagai “kelinci bligon” dengan benar. Label [Prediction] Class : Kelinci Bligon membuktikan bahwa model tidak

hanya dapat mengenali warna dan bentuk dari jenis kelinci bligon, tetapi juga berhasil mengklasifikasi jenis kelinci ini dengan tepat dan cermat.

b. Pengujian pada jenis kelinci hyla

Hasil dari pengujian menggunakan gambar kelinci hyla bisa ditinjau pada gambar 5 ini:

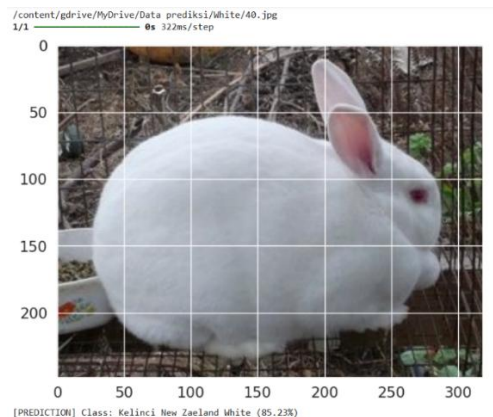


Gambar 5. Hasil Pengujian Jenis Kelinci Hyla

Dari Gambar 5 memperlihatkan bahwa model dapat memprediksi class jenis kelinci dalam gambar sebagai “kelinci hyla” dengan betul. Label [Prediction] Class : Kelinci Hyla membuktikan bahwa model tidak hanya dapat mengenali corak warna dan bentuk dari jenis kelinci hyla, tetapi juga berhasil mengklasifikasi jenis kelinci ini dengan tepat dan akurat.

c. Pengujian pada jenis kelinci new zaeland white

Hasil dari proses pengujian menggunakan gambar kelinci new zaeland white dapat diamati di gambar 6 ini:



Gambar 6. Hasil Pengujian Jenis New Zaeland White

Dari Gambar 6 menunjukkan bahwa model dapat memprediksi class jenis kelinci dalam gambar sebagai “Kelinci New Zaeland White” dengan akurat. label Prediction “ Class : Kelinci New Zaeland White” membuktikan bahwa model tidak hanya dapat mengenali warna dan bentuk dari jenis kelinci new zaeland white, tetapi juga sukses mengklasifikasi jenis kelinci ini dengan benar dan tepat.

Berdasarkan semua hasil pengujian menunjukkan bahwa model sangat akurat dalam mengklasifikasikan jenis kelinci berdasarkan pelatihan sebelumnya. Performa yang baik ini dapat dikaitkan dengan kemampuan model dalam mengenali karakteristik dan ciri khas dari kelinci seperti bentuk, warna corak dan bulu dari kelinci. Keahlian model dalam mengklasifikasikan jenis-jenis kelinci ini memperlihatkan kemampuan dari arsitektur CNN dalam menjalankan tugas identifikasi objek berbasis gambar.

4. KESIMPULAN

Berdasarkan pada hasil dari penelitian yang selesai dikerjakan, bisa di peroleh kesimpulan yaitu penggunaan Convolutional Neural Network (CNN) menggunakan arsitektur MobileNetV3 dan dibantu optimizer adam untuk klasifikasi jenis-jenis kelinci, sistem ini menawarkan solusi yang lebih efisien dan akurat dibandingkan metode manual sebelumnya, terutama dalam mengenali pola visual seperti bentuk tubuh dan warna bulu kelinci. Dengan akurasi sebesar 97% pada data validasi, model ini menunjukkan kinerja yang andal untuk mendukung pengelolaan peternakan secara modern. Model yang dibangun menunjukkan performa yang cukup baik dalam mengenali gambar kelinci dan menghasilkan prediksi yang tepat. Tahapan preprocessing, seperti resizing, augmentasi data,



dan normalisasi, terbukti meningkatkan kualitas data dan kinerja model secara keseluruhan. Sementara itu, pengembangan model dilakukan dengan menggunakan bahasa pemrograman yaitu Python, dan memanfaatkan library atau pustaka TensorFlow dan Keras sebagai perangkat utama. Pada penelitian ini sudah membuktikan bahwa pendekatan Convolutional Neural Network (CNN) cocok untuk menyelesaikan permasalahan identifikasi visual di sektor peternakan. Namun, penelitian ini memiliki keterbatasan pada keberagaman dataset, seperti variasi pencahayaan, sudut pengambilan gambar, dan latar belakang, yang dapat memengaruhi kemampuan generalisasi model menjadi poin penting untuk pengembangan lebih lanjut. Hasil pengujian dengan dataset eksternal menunjukkan akurasi 90%, yang memperkuat klaim bahwa model dapat diterapkan pada data baru, meskipun tetap memerlukan peningkatan untuk mencapai kinerja optimal. Penelitian selanjutnya diharapkan untuk memperluas variasi dataset guna meningkatkan generalisasi model dan menguji arsitektur CNN lain, seperti EfficientNet atau ResNet, untuk membandingkan performanya. Selain itu, pengembangan aplikasi real-time berbasis perangkat mobile diperlukan agar dapat mempermudah peternak dalam mengidentifikasi jenis kelinci secara praktis dan efisien. Penelitian ini diinginkan agar dapat menjadi titik awal di dalam implementasi teknologi kecerdasan buatan untuk mendukung sektor peternakan di Indonesia, khususnya dalam meningkatkan efisiensi dan akurasi proses identifikasi jenis kelinci.

REFERENCES

- [1] F. Roji, F. R. Hasibuan, A. H. M. Siregar, and I. A. Jupani, "Pengaruh Penggunaan Tepung Daun Belimbing Manis sebagai Substitusi Pakan Kelinci terhadap Berat Badan," *El-Mujtama J. Pengabd. Masy.*, vol. 4, no. 1, pp. 25–33, 2023, doi: 10.47467/elmujtama.v4i1.3124.
- [2] R. A. Wardani, D. Indrasanti, and S. Sufiriyanto, "Pengaruh Kepadatan Kandang dan Kebersihan terhadap Tingkat Infeksi Koksidiosis Kelinci di Kecamatan Kembaran Kabupaten Banyumas," *J. Ilm. Ilmu-Ilmu Peternak.*, vol. 24, no. 2, pp. 109–120, 2022, doi: 10.22437/jiip.v24i2.12751.
- [3] E. Wulandari, W. S. Putranto, A. Pratama, H. Yurmiati, and B. K. Mutaqin, "Pelatihan Penanganan dan Pengolahan Daging Kelinci Sebagai Upaya sebagai Alternatif Sumber Protein Hewani di Masa Pandemi COVID-19," *Media Kontak Tani Ternak*, vol. 3, no. 4, p. 115, 2022, doi: 10.24198/mktt.v3i4.36747.
- [4] N. Nurhidayati and A. Basit, "Pemanfaatan Limbah Ternak Kelinci untuk Pembuatan Pupuk Organik Padat dan Cair," *J. Pengabd. Kpd. Masy. (Indonesian J. Community Engag.*, vol. 6, no. 4, pp. 260–266, 2020, doi: 10.22146/jpkm.53322.
- [5] K. Berbagai Umur di Kecamatan Kalibagor Kabupaten Banyumas, R. Arif Pramudya, and D. Indrasanti, "Prevalensi Koksidiosis dan Identifikasi Eimeria sp. Pada Prevalence of Coccidiosis and Identification of Eimeria sp. in Rabbits of Various Ages in Kalibagor Subdistrict Banyumas Regency," 2020.
- [6] A. B. Prakosa, Hendry, and R. Tanone, "Implementasi Model Deep Learning Convolutional Neural Network (CNN) Pada Citra Penyakit Daun Jagung Untuk Klasifikasi Penyakit Tanaman," *J. Pendidik. Teknol. Inf.*, vol. 6, no. 1, pp. 107–116, 2023. [Online]. Available: <https://doi.org/10.37792/jukanti.v6i1.919>
- [7] U. S. Rahmadhani and N. L. Marpaung, "Klasifikasi Jamur Berdasarkan Genus Dengan Menggunakan Metode CNN," *J. Inform. J. Pengemb. IT*, vol. 8, no. 2, pp. 169–173, 2023, doi: 10.30591/jpit.v8i2.5229.
- [8] N. C. N. N. Algorithm, S. Zamroni, G. W. Wiriasto, and B. Kanata, "Identifikasi Moncong Sapi menggunakan Metode Jaringan Saraf Tiruan Konvolusional (CNN) Recognizing Cow Muzzle Patterns using the Convolution Neural," vol. 13, pp. 2479–2493, 2024. [Online]. Available: <https://doi.org/10.32520/stmsi.v13i6.4598>
- [9] A. S. Riyadi, I. P. Wardhani, and S. Widayati, "Klasifikasi Citra Anjing Dan Kucing Menggunakan Metode Convolutional Neural Network (Cnn)," *Semin. Nas. Teknol. Inf. dan Komun. STI&K*, vol. 5, no. 1, pp. 307–311, 2021, [Online]. Available: <https://ejournal.jak-stik.ac.id>. Accessed: Jan. 13, 2025
- [10] R. Gunawan, D. M. I. Hanafie, and A. Elanda, "Klasifikasi Jenis Ras Kucing Dengan Gambar Menggunakan Convolutional Neural Network (CNN)," *J. Interkom J. Publ. Ilm. Bid. Teknol. Inf. dan Komun.*, vol. 18, no. 4, pp. 1–8, 2024, doi: 10.35969/interkom.v18i4.318.
- [11] D. Tsalsabila Rhamadiyahanti and Kusriani, "Analisa Performa Convolutional Neural Network dalam Klasifikasi Citra Apel dengan Data Augmentasi," *J. Kaji. Ilm. Inform. dan Komput.*, vol. 5, no. 1, pp. 154–162, 2024, doi: 10.30865/klik.v5i1.2023.
- [12] M. Malika and E. Widodo, "Implementasi Deep Learning Untuk Klasifikasi Gambar Menggunakan Convolutional Neural Network (Cnn) Pada Batik Sasambo," *Pattimura Proceeding Conf. Sci. Technol.*, pp. 335–340, 2022, doi: 10.30598/pattimurasci.2021.knmxx.335-340.
- [13] B. Yanto, L. Fimawahib, A. Supriyanto, B. H. Hayadi, and R. R. Pratama, "Klasifikasi Tekstur Kematangan Buah Jeruk Manis Berdasarkan Tingkat Kecerahan Warna dengan Metode Deep Learning Convolutional Neural Network," *INOVTEK Polbeng - Seri Inform.*, vol. 6, no. 2, p. 259, 2021, doi: 10.35314/isi.v6i2.2104.
- [14] R. Firdaus, Joni Satria, and B. Baidarus, "Klasifikasi Jenis Kelamin Berdasarkan Gambar Mata Menggunakan Algoritma Convolutional Neural Network (CNN)," *J. CoSciTech (Computer Sci. Inf. Technol.*, vol. 3, no. 3, pp. 267–273, 2022, doi: 10.37859/coscitech.v3i3.4360.
- [15] A. Rizky Fadilla and P. Ayu Wulandari, "Literature Review Analisis Data Kualitatif: Tahap PengumpulanData," *Mitita J. Penelit.*, vol. 1, no. No 3, pp. 34–46, 2023. [Online]. Available: <https://jurnalmitita.univpasifik.ac.id/index.php/mjip/article/view/47>
- [16] R. Prabowo, Y. Heningtyas, machudor Yusman, M. Iqbal, and O. D. E. Wulansari, "Klasifikasi Image Tumbuhan Obat (Keji Beling) Menggunakan Artificial Neural Network," *J. Komputasi*, vol. 9, no. 2541–0350, pp. 88–92, 2021, doi: 10.23960/komputasi.v9i2.2868.
- [17] A. R. Hidayat and V. Lusiana, "Deteksi Jenis Sayuran dengan Tensorflow Dengan Metode Convolutional Neural Network," *J. Sains Komput. Inform. (J-SAKTI*, vol. 6, no. 2, pp. 1032–1040, 2022. <http://dx.doi.org/10.30645/j-sakti.v6i2.512>



- [18] E. Satria Maheswara, A. B. Zuhri, and D. Iskandar Maulana, “Optimization Image Classification Pada Ikan Hiu Dengan Metode Convolutional Neural Network Dan Data Augmentasi,” *J. Tika*, vol. 7, no. 1, pp. 1–11, 2022, doi: 10.51179/tika.v7i1.993.
- [19] W. Bismi, D. Novianti, and M. Qomaruddin, “Analisis Perbandingan Klasifikasi Citra Genus Panthera dengan Pendekatan Deep learning Model MobileNet,” *J. Inform. dan Rekayasa Perangkat Lunak*, vol. 6, no. 1, pp. 1–9, 2024. [Online]. Available: <https://publikasiilmiah.unwahas.ac.id/JINRPL/article/view/9037>
- [20] C. Nisa and F. Candra, “Klasifikasi Jenis Rempah-Rempah Menggunakan Algoritma Convolutional Neural Network,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 1, pp. 78–84, 2023, doi: 10.57152/malcom.v4i1.1018.