

# Implementasi Transfer Learning Untuk Klasifikasi Jenis Ras Ayam Menggunakan Arsitektur MobileNetV2

Nagala Wangsa Kencana<sup>1</sup>, Rusydi Umar<sup>2</sup>, Murinto<sup>3</sup>

<sup>1</sup>Program Studi Magister Informatika, Universitas Ahmad Dahlan, Indonesia

<sup>2</sup>Program Studi Informatika, Universitas Ahmad Dahlan, Indonesia

<sup>3</sup>Program Studi Teknik Elektro, Universitas Ahmad Dahlan, Indonesia

<sup>1</sup>wangsanagala@gmail.com, <sup>2</sup>rusydi@mti.uad.ac.id, <sup>3</sup>murintokusno@tif.uad.ac.id

## Abstrak

Ayam diketahui telah berbaaur dengan manusia dan menyebar di berbagai penjuru dunia. Orang awam kebanyakan dalam membedakan jenis ras ayam dengan ayam yang lain berdasarkan ekor, warna, dan bentuk tubuhnya. Dengan memahami perbedaan-perbedaan tersebut, seseorang dapat mengidentifikasi jenis ras ayam yang berbeda. Ras ayam secara umum memiliki tekstur yang hampir sama sehingga ini membuat kesulitan orang untuk menentukan jenis ras ayam, terutama orang awam yang belum mengetahui ciri-ciri serta jenis ras ayam. Pengumpulan data dilakukan dengan mengambil citra pada jenis ras ayam yang digunakan sebagai dataset dengan 12 kelas, yaitu Cemani, Kate, Pelung, Serama, Ketawa, Hutan, Mutiara, Kalkun, Bangkok, Poland, Ketawa, Dong Tao Sistem dianalisis kebutuhannya dari segi data, pengguna, dan sistem itu sendiri. Tahap perancangan dimulai dari pelatihan model yang baik dalam klasifikasi, merancang arsitektur data, dan merancang arsitektur. Berikutnya, transfer learning diimplementasikan kedalam sistem menyesuaikan rancangan yang telah dibuat untuk menghasilkan sistem klasifikasi. Pada penelitian ini transfer learning diimplementasikan menggunakan pre-trained model yang berarsitektur MobileNetV2 sebagai lapisan ekstraksi fitur pada model klasifikasi. Pada penelitian ini transfer learning diimplementasikan menggunakan pre-trained model yang berarsitektur MobileNetV2 sebagai lapisan ekstraksi fitur pada model klasifikasi. Pada tahap pelatihan, model-model klasifikasi dilatih menggunakan 1800 citra dan divalidasi dengan 300 citra. Kemudian, dilakukan pengujian menggunakan 300 citra menggunakan confusion matrix untuk melihat performa model, dan akurasi. Hasil dari penelitian dapat diketahui bahwa model MobileNetV2 yang mendapatkan hasil akurasi pengujian sebesar 95% dengan loss 0,378. Dari hasil tersebut, sistem klasifikasi jenis ras ayam yang dibangun dapat digunakan.

**Kata kunci:** Ayam, Convolutional Neural Network, Deep Learning, Klasifikasi Citra, MobilenetV2.

## 1. Pendahuluan

Ayam merupakan salah satu spesies unggas yang memiliki berbagai jenis ras dengan keragaman genetik, morfologis, fisiologis, dan perilaku yang cukup signifikan. Variasi ini menjadikan ayam sebagai objek penting dalam pemuliaan unggas, baik untuk tujuan komersial seperti produksi daging dan telur, maupun dalam konteks penelitian dan konservasi genetic (Gaho et al., 2024). Identifikasi yang akurat terhadap ras ayam sangat diperlukan dalam rangka pemilihan bibit unggul, pengelolaan kesehatan ternak, serta konservasi genetik, mengingat perbedaan karakteristik antar ras dapat mempengaruhi produktivitas, adaptasi terhadap lingkungan, dan ketahanan terhadap penyakit (Mahesh et al., 2023).

Berbagai ras ayam berkembang di seluruh dunia, dengan ciri-ciri fisik yang khas yang dipengaruhi oleh kondisi lingkungan setempat serta kebutuhan manusia. Di Indonesia, misalnya, terdapat ras ayam seperti Ayam Cemani, Serama, Mutiara, Kalkun, dan Poland, yang dikenal luas karena

karakteristik unik mereka (D. A. P. Oktavia, S. Rizal, 2022). Ras ayam seperti Brahma dan Kalkun memiliki ukuran tubuh yang besar, sedangkan ras seperti Serama dan Kate terkenal sebagai ayam terkecil di dunia. Selain itu, ras-ras ayam ini juga dibedakan berdasarkan warna bulu yang khas, seperti Ayam Cemani dengan bulu hitam pekat, atau Ayam Poland yang dikenali dengan jambul besar di kepalanya (D. A. P. Oktavia, S. Rizal, 2022).

Namun, identifikasi ras ayam masih menjadi tantangan besar, terutama bagi masyarakat awam yang mengandalkan ciri-ciri fisik seperti warna bulu atau bentuk tubuh. Ketidaktahuan ini sering dimanfaatkan oleh pedagang untuk menarik pembeli dengan menjual ayam yang tidak sesuai dengan klaim rasnya (Nguyen Huu et al., 2022). Oleh karena itu, diperlukan suatu metode yang lebih tepat dan efisien dalam mengklasifikasikan ras ayam agar masyarakat dan peternak dapat membuat keputusan yang lebih akurat, terutama dalam konteks pasar yang semakin berkembang (Hasan Fadlun & Hayati, 2024).

Kemajuan teknologi dalam bidang kecerdasan buatan (AI) dan pemrosesan citra menawarkan solusi yang efektif untuk mengatasi permasalahan ini. Salah satu metode yang sangat relevan adalah *Transfer Learning*, yaitu teknik pembelajaran mesin yang memanfaatkan model yang telah dilatih sebelumnya pada dataset besar untuk mengklasifikasikan data baru dengan sedikit penyesuaian (Nguyen Huu et al., 2022). Metode ini sangat efisien, terutama ketika bekerja dengan dataset terbatas, seperti citra ras ayam, karena memungkinkan transfer pengetahuan dari model yang sudah dilatih di domain lain. Salah satu arsitektur yang populer untuk aplikasi pengenalan citra adalah *MobileNetV2*, yang memiliki keunggulan dalam hal efisiensi komputasi dan dapat digunakan pada perangkat mobile dan embedded system (Sandler et al., 2018). Keunggulan utama dari *MobileNetV2* adalah kemampuannya untuk melakukan klasifikasi citra dengan kebutuhan sumber daya yang rendah, sehingga cocok untuk aplikasi yang memerlukan pemrosesan cepat dan efisien.

Berdasarkan latar belakang ini, penelitian ini bertujuan untuk mengimplementasikan *Transfer Learning* dengan menggunakan arsitektur *MobileNetV2* untuk klasifikasi ras ayam. Metode ini diharapkan dapat memberikan solusi yang cepat dan akurat dalam mengenali ras ayam berdasarkan ciri-ciri visual yang ada pada citra tubuhnya. Penelitian ini juga bertujuan untuk mengeksplorasi bagaimana teknologi kecerdasan buatan, khususnya dalam pemrosesan citra, dapat diterapkan untuk meningkatkan efisiensi pengelolaan peternakan ayam, mengurangi kesalahan identifikasi ras ayam di pasar, dan membantu masyarakat serta peternak dalam membuat keputusan yang lebih tepat dalam memilih jenis ayam sesuai dengan tujuan mereka (Nguyen Huu et al., 2022). Dengan penerapan *MobileNetV2* dalam klasifikasi ras ayam, diharapkan dapat tercipta sistem yang tidak hanya akurat, tetapi juga efisien dalam pemrosesan, sehingga dapat diterapkan dalam aplikasi berbasis perangkat mobile dan memberikan manfaat praktis bagi peternak dan konsumen (Sandler et al., 2018).

## 2. Metode

Pada signifikasi studi ini akan dijelaskan Studi Literatur terkait berupa Penelitian Terdahulu, Objek Penelitian, Alat dan Bahan, Dataset, Anotasi Pelabelan, Pelatihan Model dan Evaluasi Model.

### 2.1 Convolutional Neural Network

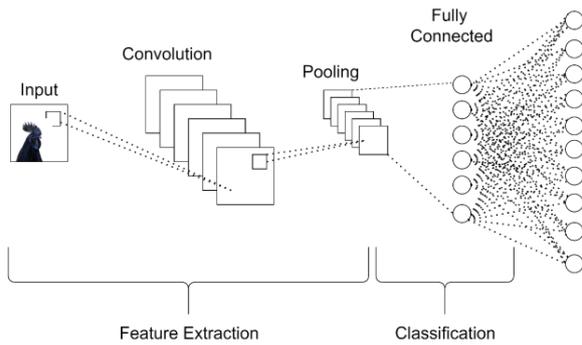
Convolutional Neural Network (CNN) merupakan jenis arsitektur jaringan saraf tiruan yang dirancang khusus untuk memproses data yang memiliki tampilan grid atau grid-like, seperti gambar dan video (Manjula & R, 2021). CNN terinspirasi oleh cara kerja visual manusia dan telah terbukti

sangat efektif dalam tugas-tugas pengenalan pola visual. CNN memiliki struktur yang terdiri dari lapisan-lapisan yang berbeda.

Convolutional Neural Network ada beberapa lapisan yang berbeda termasuk lapisan konvolusi, lapisan pengambilan sampel, dan lapisan sepenuhnya terhubung (Ahsan et al., 2021). Lapisan konvolusi adalah inti dari CNN, di mana operasi konvolusi diterapkan pada input data. Konvolusi melibatkan penggunaan filter atau kernel untuk mengambil fitur-fitur penting dari data input dengan melakukan operasi perkalian dan penjumlahan secara berulang. Setiap filter menghasilkan peta fitur yang menyoroti keberadaan pola tertentu dalam data. Lapisan pengambilan sampel, seperti lapisan max pooling, digunakan untuk mereduksi dimensi spasial dari peta fitur yang dihasilkan oleh lapisan konvolusi. Dalam jaringan, hal ini berkontribusi untuk mengurangi jumlah parameter dan komputasi yang dibutuhkan, serta juga mendukung ekstraksi fitur yang lebih invariant terhadap pergeseran dan variasi kecil dalam data input (Ramayanti et al., 2022). Setelah melewati lapisan konvolusi dan pengambilan sampel, peta fitur yang dihasilkan kemudian diteruskan ke lapisan sepenuhnya terhubung atau lapisan dense. Lapisan dense terdiri dari neuron-neuron yang terhubung penuh dan bertanggung jawab untuk melakukan klasifikasi akhir dengan fully connected layer atau tugas-tugas lainnya dengan output seperti pengenalan objek dalam gambar yang dapat ditentukan.

### 2.2 MobilenetV2

MobileNetV2 adalah arsitektur Convolutional Neural Network (CNN) yang dikembangkan oleh Google AI pada tahun 2018 untuk mendukung aplikasi pembelajaran mendalam di perangkat dengan sumber daya komputasi terbatas, seperti ponsel pintar, perangkat IoT, dan edge computing (Ridhovan & Suharso, 2022). MobileNetV2 dirancang untuk memberikan keseimbangan optimal antara akurasi dan efisiensi komputasi, memungkinkan model ini digunakan dalam berbagai aplikasi real-time tanpa memerlukan perangkat keras yang mahal. Salah satu inovasi utama dalam arsitektur ini adalah penggunaan *depthwise separable convolution*, sebuah teknik yang memisahkan proses ekstraksi fitur spasial dan kombinasi fitur menjadi dua tahap: *depthwise convolution*, yang memproses setiap kanal secara terpisah, dan *pointwise convolution*, yang menggabungkan informasi dari berbagai kanal melalui konvolusi 1x1. Teknik ini secara signifikan mengurangi jumlah parameter dan operasi komputasi dibandingkan dengan konvolusi standar, tanpa mengorbankan kemampuan model untuk mengenali pola yang kompleks (Aufar & Kaloka, 2022).



Gambar 1. Arsitektur MobilenetV2

Pada Gambar 1, arsitektur MobileNetV2 terdiri dari Beberapa Komponen Convolution, Inverted Residuals, dan Linear Bottleneck. Depthwise separable convolution membagi proses konvolusi menjadi dua tahap, yaitu depthwise convolution yang mengekstrak fitur spasial dari setiap kanal secara independen, dan pointwise convolution yang menggabungkan kanal-kanal tersebut dengan konvolusi 1x1. Teknik ini secara signifikan mengurangi jumlah operasi matematika dan parameter, sehingga meningkatkan efisiensi tanpa mengorbankan akurasi (Dhimas et al). Inverted residuals memungkinkan model memperluas dimensi fitur di lapisan tengah (expansion layer) sebelum mengurangnya kembali, menangkap informasi kompleks tanpa membutuhkan banyak parameter. Linear bottleneck digunakan di akhir setiap blok untuk memastikan kompresi fitur tetap mempertahankan informasi penting, sehingga mendukung generalisasi model yang lebih baik.

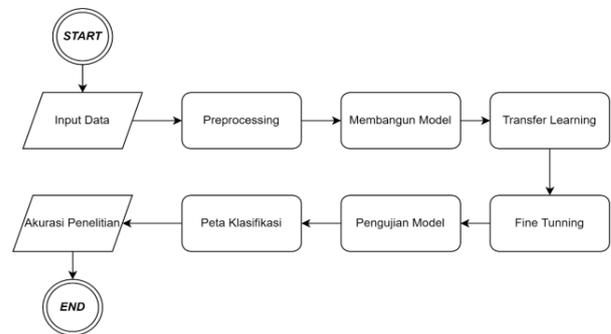
Proses kerja MobileNetV2 dimulai dengan menerima input gambar berukuran 224x224 piksel, yang telah melalui tahap normalisasi untuk memastikan nilai piksel berada dalam rentang 0 hingga 1. Citra tersebut kemudian diproses melalui lapisan awal berupa konvolusi standar, dilanjutkan dengan blok inverted residuals untuk mengekstraksi fitur pada berbagai skala. Pada akhir arsitektur, lapisan fully connected dan softmax digunakan untuk memprediksi label kelas pada tugas klasifikasi. MobileNetV2 juga sering digunakan dalam transfer learning, di mana model pre-trained yang telah dilatih pada dataset besar seperti ImageNet dimanfaatkan untuk ekstraksi fitur pada dataset yang lebih kecil. Pendekatan ini meningkatkan efisiensi pelatihan dan akurasi pada aplikasi spesifik.

Dalam implementasinya, MobileNetV2 telah diaplikasikan pada berbagai penelitian yang menunjukkan hasil yang menjanjikan. Penelitian oleh (Ma et al., 2022) menggunakan MobileNetV2 untuk klasifikasi penyakit tanaman padi, mencapai akurasi hingga 92% dengan dataset berisi 5000 citra. Penelitian lain oleh (Dipura et al., 2024), menggunakan MobileNetV2 untuk mendeteksi wajah manusia di lingkungan dengan pencahayaan rendah, menghasilkan tingkat akurasi sebesar 89%.

Selain itu, (Shidiq et al., 2022) memanfaatkan arsitektur ini untuk mengenali pola kain batik dengan akurasi mencapai 94%. Dengan efisiensi dan fleksibilitasnya, MobileNetV2 terus menjadi pilihan utama untuk berbagai aplikasi berbasis visi komputer, khususnya di perangkat dengan sumber daya komputasi terbatas.

### 2.3 Kerangka penelitian

Diagram alur klasifikasi jenis ras ayam yang diusulkan menggunakan transfer learning model CNN ditunjukkan pada Gambar 1. Metode ini terdiri dari pengumpulan data, preprocessing, membangun model, transfer pembelajaran dari model CNN praterlatih, fine-tuning, dan evaluasi kinerja. Detail setiap langkah dijelaskan pada Gambar 1.



Gambar 2. Metodologi Penelitian

### 2.4 Alat Dan Bahan

Pelaksanaan penelitian ini membutuhkan beberapa alat dan software. Adapun spesifikasi yang dibutuhkan untuk melaksanakan penelitian dapat dilihat pada Tabel 1.

Tabel 1. Alat dan Bahan Penelitian

No	Perangkat	Sistem Operasi	Kegunaan
1	Laptop Ideapad L340 Gaming	Windows 10	Menjalankan sistem
2	Python 3.10.12		Running Program
3	Goggle Coolab		Alat Training
4	Tensorflow 2.6.0		Mengembangkan Model Yang Akan Digunakan
5	Draw IO		Desain Arsitektur

### 2.5 Transfer Learning Dan Fine-Tuning

Transfer learning menggunakan model yang telah dilatih pada satu tugas atau dataset untuk mempercepat proses pembelajaran pada tugas atau dataset yang berbeda, terkait, atau serupa. Dengan memanfaatkan pengetahuan yang diperoleh oleh model dari sumber sebelumnya, pembelajaran transfer dapat membantu mengatasi keterbatasan data dan mempercepat konvergensi saat melatih model pada tugas baru. Singkatnya, transfer

learning melibatkan mengambil fitur yang dipelajari dari satu masalah dan menerapkannya pada masalah baru atau serupa. Pembelajaran transfer menggunakan model pra-terlatih yang sudah dilatih pada kumpulan data besar seperti ImageNet . Dalam proses pelatihan, semua lapisan ekstraksi fitur dibekukan dan hanya lapisan klasifikasi yang dilatih karena lapisan konvolusional dasar dari model pra-terlatih sudah dapat mengekstrak fitur yang berguna untuk klasifikasi gambar (Gunawan et al., 2021). Setelah transfer learning, parameter model disesuaikan menggunakan metode fine-tuning. Semua lapisan ekstraksi fitur dibekukan dan disertakan dalam pelatihan. Metode ini akan menyesuaikan representasi fitur dari model dasar agar sesuai dengan himpunan data. Proses inidilakukan dengan tingkat pembelajaran yang lebih kecil untuk meningkatkan akurasi model.

### 2.6 Evaluasi Matrix

Kinerja model klasifikasi multi-kelas dapat dinilai melalui beberapa metrik yaitu akurasi, ingatan, presisi, dan skor F1. Untuk menghitung metrik ini, matriks yang dikenal sebagai matriks kebingungan diperlukan.(Demir et al., 2020) Persamaan akurasi, presisi, ingatan, dan skor F1 ditunjukkan dalam Persamaan (1), (2), (3), dan (4) masing-masing di mana TP adalah *true* positif, TN adalah *true negative*, FP adalah *false positive*, dan FN adalah *false negative*.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \tag{1}$$

$$Precision = \frac{TP}{TP + FP} \tag{2}$$

$$Recall = \frac{TP}{TP + FN} \tag{3}$$

$$F1\ Score = \frac{precision \cdot recall}{precision + recall} \tag{4}$$

### 3. Pembahasan

Pada penelitian ini, implementasi klasifikasi ras ayam dilakukan dengan menggunakan model *MobileNetV2* yang dilatih melalui metode *Transfer Learning* dan *Fine-Tuning*. Semua eksperimen dan pengujian dilakukan menggunakan Python, dengan pustaka tambahan seperti TensorFlow, OpenCV, dan Scikit-learn, yang berjalan pada platform komputasi awan Google Colab menggunakan GPU T4 untuk mempercepat pelatihan model. Pemilihan alat dan teknologi ini didasarkan pada efisiensi dan kapabilitasnya dalam menangani pemrosesan citra yang besar.

#### 3.1 Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 12 kelas ras ayam yang mencakup

Ayam Cemani, Kate, Pelung, Serama, Ketawa, Hutan, Mutiara, Kalkun, Bangkok, Poland, Brahma, dan Dong Tao. Setiap kelas terdiri dari 150 gambar, dengan total gambar yang digunakan dalam penelitian ini mencapai 1.800 citra. Pembagian dataset dilakukan secara proporsional, yaitu 900 citra untuk pelatihan dan 300 citra untuk validasi.



Gambar 3. Dataset Ayam

Pada Gambar 3, terlihat dataset yang diperoleh dengan kualitas yang bervariasi, yang menantang model untuk dapat mengenali ciri khas dari masing-masing ras ayam meskipun terdapat variasi dalam pencahayaan, sudut pengambilan gambar, dan resolusi gambar. Proses augmentasi digunakan untuk memperbesar dataset dan meningkatkan keberagaman gambar.

#### 3.2 Proses Augmentasi Data

Proses preprocessing data sangat penting untuk memastikan bahwa dataset yang digunakan siap untuk pelatihan model. Tahap pertama dalam preprocessing adalah perubahan ukuran gambar dengan menggunakan padding, yang bertujuan untuk mempertahankan rasio aspek gambar agar tidak terdistorsi saat gambar diubah ukurannya menjadi 224x224x3 (ukuran standar input untuk *MobileNetV2*). Gambar asli diproses dengan menambahkan piksel nol di sekitar gambar untuk menjaga rasio aspek tanpa merubah dimensi asli.



Gambar 4. Hasil Perubahan Padding

Gambar 4 menunjukkan hasil perubahan ukuran gambar dengan padding, yang menjamin konsistensi rasio gambar meskipun ukuran inputnya diubah.



Gambar 5. Hasil augmentasi Data

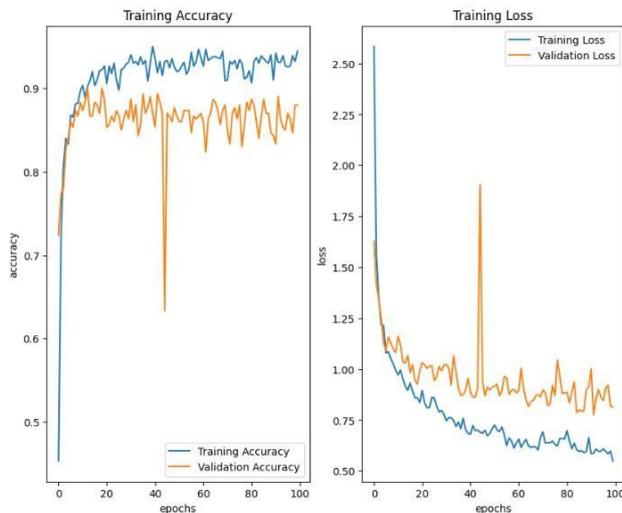
Selanjutnya, pada Gambar 5 augmentasi data diterapkan pada gambar untuk meningkatkan jumlah dan keberagaman data latih. Teknik augmentasi yang digunakan termasuk rotasi dengan kisaran 20

derajat dan pembalikan horizontal, yang bertujuan untuk memberikan variasi pada data dan meningkatkan kemampuan model dalam mengenali ayam dari berbagai sudut pandang. Augmentasi data ini mengurangi kemungkinan overfitting dan membuat model lebih generalisatif terhadap variasi citra yang mungkin ditemukan di dunia nyata. Setelah augmentasi, dataset meningkat menjadi 1.800 gambar.

Setiap citra yang telah diproses melalui augmentasi selanjutnya distandarisasi ke rentang [0, 1] untuk mempersiapkan input ke dalam *MobileNetV2*, yang memiliki konfigurasi pra-pelatihan untuk menerima input dalam rentang nilai ini.

### 3.3 Hasil Transfer Learning

Pada tahap transfer learning, model *MobileNetV2* yang telah dilatih sebelumnya pada dataset ImageNet digunakan sebagai model dasar. Transfer learning memungkinkan pemanfaatan pengetahuan yang sudah ada pada model, sehingga mengurangi waktu pelatihan dan memungkinkan model untuk belajar lebih cepat dari dataset yang lebih kecil.



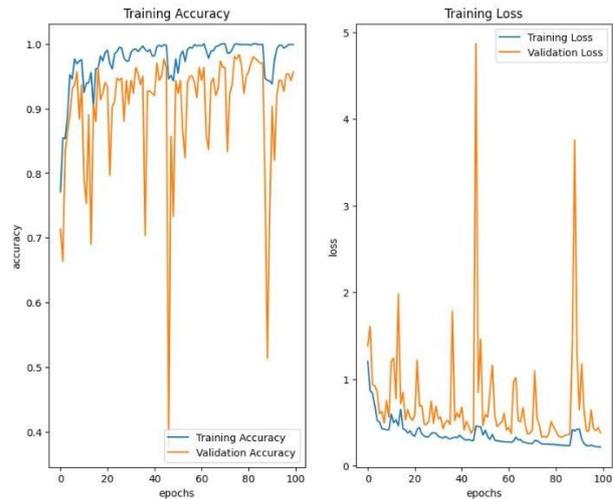
Gambar 6. Grafik Pelatihan Transfer Learning Model *MobileNetV2*

Proses pelatihan menggunakan tingkat pembelajaran 0,001 selama 100 epoch menghasilkan akurasi pelatihan sebesar 86% dan akurasi validasi sebesar 90%. Evaluasi lebih lanjut pada data uji menghasilkan akurasi 86,66%.

Meskipun hasil ini menunjukkan kinerja yang baik, terdapat sedikit overfitting yang dapat dilihat dari grafik pelatihan pada Gambar 6. Overfitting ini terjadi karena model memiliki kecenderungan untuk terlalu menyesuaikan diri dengan data pelatihan, namun masih dapat menggeneralisasi dengan baik pada data validasi.

### 3.4 Hasil Fine-Tuning

Setelah tahap transfer learning, proses fine-tuning dilakukan untuk menyesuaikan lebih lanjut parameter model agar lebih optimal dengan dataset ras ayam yang spesifik. Fine-tuning adalah proses penting dalam transfer learning, di mana beberapa lapisan terakhir dari model diperbaharui untuk mempelajari ciri khas dari data baru secara lebih mendalam.



Gambar 7. Grafik Pelatihan Dari Hasil Fine-Tuning Model *MobileNetV2*

Gambar 7 menunjukkan grafik pelatihan dari hasil fine-tuning, yang memperlihatkan peningkatan signifikan dalam akurasi pelatihan. Pada tahap fine-tuning, tingkat pembelajaran diturunkan menjadi 0,0001 untuk menghindari perubahan besar pada bobot model yang sudah terlatih. Hasil fine-tuning menunjukkan akurasi pelatihan yang sangat meningkat, mencapai 95,55%, namun akurasi validasi menurun menjadi 37,82%. Hal ini dapat terjadi karena adanya *overfitting* pada data pelatihan, sementara model kesulitan untuk menggeneralisasi pada data validasi yang memiliki karakteristik berbeda dari data pelatihan. Namun, akurasi evaluasi pada data uji tetap sangat tinggi, mencapai 95,67%.

### 3.5 Hasil Performa Model

Dalam mengevaluasi kinerja akhir model, matriks kebingungannya digunakan untuk mengukur seberapa baik model dapat mengklasifikasikan gambar ayam berdasarkan kelas yang telah ditentukan. Tabel 1 menunjukkan hasil evaluasi dari model *MobileNetV2* pada data uji. Performa model terbaik tercatat pada kelas *Dong Tao*, *Brahma*, dan *Cemani*, yang memiliki akurasi mencapai 100%. Sementara itu, kelas ayam *Kate* memiliki akurasi terendah dengan 90%, kemungkinan disebabkan oleh variasi kualitas

gambar yang buruk pada beberapa contoh dalam kelas tersebut.

Tabel 2. Hasil Prediksi MobilenetV2

No	Jenis Ayam	Jumlah Data	Hasil Akurasi
1	Dong Tao	150	100%
2	Ketawa	150	93%
3	Pelung	150	93%
4	Brahma	150	100%
5	Bangkok	150	93%
6	Kate	150	90%
7	Serama	150	93%
8	Poland	150	93%
9	Cemani	150	100%
10	Hutan	150	93%
11	Pelung	150	93%
12	Kalkun	150	96%

Tabel 2 menunjukkan akurasi yang dicapai oleh model untuk setiap kelas ras ayam, di mana *MobileNetV2* menunjukkan hasil yang cukup memuaskan untuk hampir semua kelas. Secara keseluruhan, model *MobileNetV2* memberikan akurasi sebesar 95,55% pada data pelatihan dan 95,67% pada data uji. Meskipun ada penurunan akurasi pada validasi selama fine-tuning, model ini berhasil memberikan kinerja yang sangat baik pada data uji, membuktikan efektivitas teknik transfer learning dan fine-tuning dalam klasifikasi ras ayam berdasarkan citra.

### 3.6 Peforma MobileNetV2 dalam Klasifikasi Citra Ras Ayam

Pemilihan arsitektur *MobileNetV2* dalam penelitian ini didasarkan pada serangkaian keuntungan teknis yang membuatnya lebih unggul dibandingkan dengan model CNN tradisional untuk tugas klasifikasi citra, terutama pada dataset yang terbatas. *MobileNetV2* mengadopsi *depthwise separable convolutions*, yang secara signifikan mengurangi jumlah parameter dan operasi komputasi dibandingkan dengan model CNN yang lebih besar seperti *VGG* dan *ResNet*. Pendekatan ini memungkinkan *MobileNetV2* untuk lebih efisien dalam hal waktu pelatihan dan penggunaan memori, yang penting saat bekerja dengan sumber daya terbatas pada perangkat atau platform komputasi awan seperti Google Colab (Baumgartl et al., 2021).

Selain itu, *MobileNetV2* sangat efektif dalam skenario *transfer learning*, di mana model yang telah dilatih pada dataset besar seperti *ImageNet* dapat diterapkan pada dataset yang lebih kecil namun spesifik, seperti dataset ras ayam dalam penelitian ini. Teknik *transfer learning* memungkinkan model untuk memanfaatkan pengetahuan yang sudah ada untuk menyelesaikan tugas baru dengan jumlah data yang lebih sedikit, mengurangi kebutuhan akan dataset besar (Ahsan et al., 2021). Keunggulan ini sangat relevan dalam konteks penelitian ini, mengingat jumlah citra yang terbatas untuk masing-masing ras ayam.

Selain itu, ukuran model yang relatif kecil pada *MobileNetV2* membuatnya lebih efisien dalam hal penyimpanan dan penggunaan sumber daya, serta memungkinkan penerapan pada perangkat mobile atau sistem dengan kapasitas terbatas. Pengurangan ukuran model ini menjadikan *MobileNetV2* pilihan yang lebih praktis dan hemat biaya dalam aplikasi dunia nyata yang memerlukan pemrosesan citra secara real-time (Sanjaya & Adi Rakhmawan, 2020). Hal ini sangat penting mengingat penerapan model pada perangkat dengan kapasitas penyimpanan dan pemrosesan terbatas.

Dengan kombinasi efisiensi komputasi, kemampuan *transfer learning*, dan ukuran model yang kecil, *MobileNetV2* menjadi pilihan optimal untuk klasifikasi citra ras ayam, memberikan hasil yang cepat, akurat, dan hemat biaya.

## 4. Kesimpulan

Berdasarkan hasil yang diperoleh, dapat disimpulkan bahwa metode yang diusulkan, yang menggunakan model CNN *MobileNetV2* melalui penerapan transfer learning dan fine-tuning, mampu mengklasifikasikan jenis ras ayam dari gambar dengan akurasi yang tinggi. Dataset yang digunakan terdiri dari 1.800 gambar ayam dari 12 kelas ras, yang terbagi menjadi 900 data pelatihan dan 300 data pengujian. Setelah melakukan fine-tuning, model *MobileNetV2* berhasil mencapai akurasi pelatihan sebesar 95,55%. Namun, pada pengujian data, model ini menghasilkan kinerja yang sangat baik dengan presisi 95%, recall 94%, F1-score 93%, dan akurasi 90%.

Hasil evaluasi tersebut menunjukkan bahwa *MobileNetV2* sangat efektif dalam mengklasifikasikan gambar ayam, bahkan dengan dataset yang terbatas. Evaluasi kinerja yang baik ini menunjukkan potensi aplikasi metode yang diusulkan dalam sistem berbasis mobile, yang dapat memberikan informasi tentang jenis ayam hanya melalui gambar yang diambil.

Namun, meskipun hasil yang dicapai cukup memuaskan, terdapat beberapa keterbatasan yang perlu diperhatikan. Salah satunya adalah ketergantungan pada kualitas gambar, di mana gambar dengan pencahayaan buruk atau sudut yang tidak tepat dapat mengurangi akurasi klasifikasi. Selain itu, model ini terbatas pada 12 kelas ras ayam yang ada dalam dataset, sehingga untuk aplikasi yang lebih luas, perlu dilakukan perluasan jumlah kelas atau penambahan dataset yang lebih beragam.

Peluang pengembangan lebih lanjut dapat meliputi peningkatan kualitas dataset melalui teknik augmentasi data yang lebih beragam, serta penerapan model yang lebih kompleks atau arsitektur yang lebih dalam seperti *EfficientNet* untuk meningkatkan performa. Selain itu, integrasi model ini dengan aplikasi berbasis edge computing atau perangkat IoT untuk klasifikasi real-time di

lapangan dapat menjadi area pengembangan yang menarik, memungkinkan aplikasi yang lebih praktis dalam industri peternakan dan pertanian.

#### Daftar Pustaka:

- Ahsan, M. M., Nazim, R., Siddique, Z., & Huebner, P. (2021). Detection of COVID-19 Patients from CT Scan and Chest X-ray Data Using Modified MobileNetV2 and LIME. *Healthcare*, 9(9), 1099. <https://doi.org/10.3390/healthcare9091099>
- Aufar, Y., & Kaloka, T. P. (2022). Robusta coffee leaf diseases detection based on MobileNetV2 model. *International Journal of Electrical and Computer Engineering (IJECE)*, 12(6), 6675. <https://doi.org/10.11591/ijece.v12i6.pp6675-6683>
- Baumgartl, H., Sauter, D., Schenk, C., Atik, C., & Buettner, R. (2021). Vision-based Hand Gesture Recognition for Human-Computer Interaction using MobileNetV2. *2021 IEEE 45th Annual Computers, Software, and Applications Conference (COMPSAC)*, 1667–1674. <https://doi.org/10.1109/COMPSAC51774.2021.00249>
- D. A. P. Oktavia, S. Rizal, and N. K. C. P. (2022). Klasifikasi Gejala Defisiensi Nutrisi Pada Tanaman Padi Menggunakan CNN Dengan Arsitektur Resnet-50. *E-Proceeding Eng.*, 8(6), 3171–3175.
- Demir, F., Abdullah, D. A., & Sengur, A. (2020). A New Deep CNN Model for Environmental Sound Classification. *IEEE Access*, 8, 66529–66537. <https://doi.org/10.1109/ACCESS.2020.2984903>
- Dhimas, D., Putra, P., Kurnia Anaga, G., & Fitriyana, W. T. (2024). Implementasi Algoritma Convolutional Neural Network Arsitektur Mobilenetv2 Untuk Klasifikasi Ekspresi Wajah Pada Dataset FER. *Prosiding Seminar Nasional Teknologi Dan Sains*, 3(1), 291–297.
- Dipura, G. P. A., Amanda, F., Firmansyah, M. R., Rizky, M. R., & Jamal, M. N. K. (2024). Teknologi Komputer Vision dalam Kamera Pengawas. *Karimah Tauhid*, 3(3), 3754–3760. <https://doi.org/10.30997/karimahtauhid.v3i3.12292>
- Gaho, R. L., Ali, I. T., & Prakasa, E. (2024). Klasifikasi Kualitas Permukaan Jalan Raya menggunakan Metode CNN Berbasis Arsitektur Xception. *Inovtek Polbeng - Seri Informatika*, 9(1). <https://doi.org/10.35314/isi.v9i1.4213>
- Gunawan, I. K., Bayupati, I. P. A., Wibawa, K. S., Sukarsa, I. M., & Kurniawan, L. A. (2021). Indonesian Plate Number Identification Using YOLACT and Mobilenetv2 in the Parking Management System. *JUITA: Jurnal Informatika*, 9(1), 69. <https://doi.org/10.30595/juita.v9i1.9230>
- Hasan Fadlun, M., & Hayati, U. (2024). *Jurnal Informatika dan Rekayasa Perangkat Lunak Klasifikasi Tumor Otak menggunakan Convolutional Neural Network dan Transfer Learning*. 6(1), 289–295.
- Ma, R., Wang, J., Zhao, W., Guo, H., Dai, D., Yun, Y., Li, L., Hao, F., Bai, J., & Ma, D. (2022). Identification of Maize Seed Varieties Using MobileNetV2 with Improved Attention Mechanism CBAM. *Agriculture*, 13(1), 11. <https://doi.org/10.3390/agriculture13010011>
- Mahesh, T. R., Vinoth Kumar, V., Sivakami, R., Manimozhi, I., Krishnamoorthy, N., & Swapna, B. (2023). Early Predictive Model for Detection of Plant Leaf Diseases Using MobileNetV2 Architecture. *International Journal of Intelligent Systems and Applications in Engineering*, 11(2), 46–54.
- Manjula, S., & R, V. K. (2021). Real World Face Mask Detection using MobileNetV2 and Raspberry Pi. *International Journal of Engineering Research and Applications Wwww.Ijera.Com*, 11(10), 26–32. <https://doi.org/10.9790/9622-1110012632>
- Nguyen Huu, P., Nguyen Thi, N., & Ngoc, T. P. (2022). Proposing Posture Recognition System Combining MobilenetV2 and LSTM for Medical Surveillance. *IEEE Access*, 10, 1839–1849. <https://doi.org/10.1109/ACCESS.2021.3138778>
- Ramayanti, D., Sri Dianing Asri, & Lionie Lionie. (2022). Implementasi Model Arsitektur VGG16 dan MobileNetV2 Untuk Klasifikasi Citra Kupu-Kupu. *JSAI (Journal Scientific and Applied Informatics)*, 5(3), 182–187. <https://doi.org/10.36085/jsai.v5i3.2864>
- Ridhovan, A., & Suharso, A. (2022). Penerapan Metode Residual Network (Resnet) Dalam Klasifikasi Penyakit Pada Daun Gandum. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 7(1), 58–65. <https://doi.org/10.29100/jupi.v7i1.2410>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 4510–4520. <https://doi.org/10.1109/CVPR.2018.00474>
- Sanjaya, S. A., & Adi Rakhmawan, S. (2020). Face Mask Detection Using MobileNetV2 in The Era of COVID-19 Pandemic. *2020 International Conference on Data Analytics for Business and Industry: Way Towards a Sustainable Economy (ICDABI)*, 1–5. <https://doi.org/10.1109/ICDABI51230.2020.9325631>

Shidiq, A. L. A., SUhartono, E., & Saidah, S. (2022). Klasifikasi Kecacatan Ban Untuk Mengendalikan Kualitas Produk Menggunakan Model CNN Dengan Arsitektur

VGG-16 Classification Of Tire Defect To Control Product Quality Using Cnn Model With VGG-16 Architecture. *E-Proceeding of Engineering*, 8(6), 3216–3225.