



Klasifikasi Citra Biji Kopi Sangrai Arabika dan Robusta Menggunakan Convolutional Neural Network

Muhammad Rafi Al Firdaus^{1,*}, Rodhiyah Mardhiyyah², Fadil Indra Sanjaya³

¹ Fakultas Sains & Teknologi, Program Studi Informatika, Universitas Teknologi Yogyakarta, Yogyakarta, Indonesia

² Fakultas Sains & Teknologi, Program Studi Teknik Komputer, Universitas Teknologi Yogyakarta, Yogyakarta, Indonesia

³ Fakultas Sains & Teknologi, Program Studi Data Sains, Universitas Teknologi Yogyakarta, Yogyakarta, Indonesia

Email: ^{1,*}mrafi.af.mraf@gmail.com, ²rodhiyah.mardhiyyah@uty.ac.id, ³fadil.indra@staff.uty.ac.id

Email Penulis Korespondensi: mrafi.af.mraf@gmail.com

Abstrak—Kopi merupakan salah satu komoditas unggulan di Indonesia yang memiliki dua varietas utama, yaitu Arabika dan Robusta. Perbedaan karakteristik kedua jenis kopi tersebut, seperti bentuk biji, warna, dan tekstur, sering kali sulit dibedakan secara visual, terutama bagi masyarakat awam. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi otomatis yang mampu membedakan biji kopi Arabika dan Robusta menggunakan metode Convolutional Neural Network (CNN) dengan penerapan transfer learning berbasis arsitektur MobileNetV2. Dataset yang digunakan terdiri atas 210 citra biji kopi hasil pemotretan menggunakan kamera smartphone dengan berbagai variasi posisi dan pencahayaan, yang kemudian dibagi menjadi data latih (60%), data validasi (20%) dan data uji (20%). Sebelum proses pelatihan, dilakukan data augmentation seperti rotasi, zoom, flip, dan penyesuaian kecerahan untuk memperkaya variasi citra dan mengurangi risiko overfitting. Pelatihan dilakukan dengan learning rate sebesar 0,0001, batch size 32, dan optimizer Adam. Hasil penelitian menunjukkan bahwa model CNN dengan transfer learning MobileNetV2 mampu mencapai akurasi pelatihan sebesar 99,21% dan akurasi pengujian 97,62%, dengan nilai loss yang relatif rendah, yaitu 0,0682 untuk data latih dan 0,1333 untuk data pengujian. Penerapan transfer learning berkontribusi dalam meningkatkan stabilitas proses pelatihan karena memanfaatkan bobot pra-latih dari model ImageNet. Berdasarkan hasil tersebut, dapat disimpulkan bahwa metode CNN berbasis MobileNetV2 mampu mengklasifikasikan biji kopi Arabika dan Robusta secara akurat.

Kata Kunci: Klasifikasi Biji Kopi; Kopi Arabika; Kopi Robusta; CNN; *Transfer Learning*; MobileNetV2

Abstract—Coffee is one of Indonesia's leading commodities, with two main varieties: Arabica and Robusta. The differences in characteristics between these two types of coffee, such as bean shape, color, and texture, are often difficult to distinguish visually, especially for the general public. This study aims to develop an automatic classification system capable of distinguishing Arabica and Robusta coffee beans using the Convolutional Neural Network (CNN) method with the application of transfer learning based on the MobileNetV2 architecture. The dataset used consists of 210 images of coffee beans taken using a smartphone camera with various positions and lighting, which were then divided into training data (60%), validation data (20%) and test data (20%). Before the training process, data augmentation such as rotation, zoom, flip, and brightness adjustment was performed to enrich image variation and reduce the risk of overfitting. Training was conducted with a learning rate of 0.0001, a batch size of 32, and an Adam optimizer. The results showed that the CNN model with MobileNetV2 transfer learning was able to achieve a training accuracy of 99.21% and a testing accuracy of 97.62%, with relatively low loss values of 0.0682 for training data and 0.1333 for validation data. The application of transfer learning contributes to improving the stability of the training process by utilizing the pre-trained weights from the ImageNet model. Based on these results, it can be concluded that the MobileNet-based CNN method.

Keywords: Coffee Bean Classification; Arabica Coffee; Robusta Coffee; CNN; Transfer Learning; MobileNetV2

1. PENDAHULUAN

Kopi merupakan salah satu komoditas perkebunan unggulan yang memiliki peran penting dalam perekonomian Indonesia. Selain menjadi minuman yang banyak dikonsumsi masyarakat, kopi juga memiliki nilai ekonomi yang tinggi karena berkontribusi sebagai sumber devisa negara (Alfiantama dkk., 2024). Selain itu, komoditas ini juga menjadi sumber pendapatan utama bagi sebagian besar petani, sehingga memiliki peran strategis terhadap kesejahteraan masyarakat di sektor perkebunan (Santoso dkk., 2025; Sarvina dkk., 2021). Secara global, kopi tetap menjadi salah satu minuman paling populer di dunia, dengan tingkat konsumsi yang terus meningkat setiap tahunnya. Menurut catatan International Coffee Organization (ICO), konsumsi kopi nasional melonjak 174 persen, dari 100,8 metrik ton pada tahun 2000 menjadi 276 metrik ton pada tahun 2023. Hal ini menegaskan bahwa kopi memiliki nilai ekonomi dan sosial yang signifikan di berbagai negara penghasil maupun konsumen (Czarniecka-Skubina dkk., 2021). Berdasarkan data Badan Pusat Statistik (BPS) tahun 2023, sebagian besar produksi kopi di Indonesia mengalami fluktuasi dalam tiga tahun terakhir, di mana pada tahun 2022 terjadi penurunan sebesar 1,43%, yaitu dari 786,19 ribu ton menjadi 774,96 ribu ton, dan kembali menurun pada 2023 sebesar 2,10% atau sekitar 16,24 ribu ton (Badan Pusat Statistik, 2024).

Terdapat dua varietas kopi yang banyak dibudidayakan, yaitu Arabika dan Robusta, yang masing-masing memiliki karakteristik fisik dan cita rasa yang berbeda (Fibrianto dkk., 2020). Kopi Arabika memiliki cita rasa yang lebih halus dan sedikit asam, sedangkan Robusta cenderung lebih pahit dengan kandungan kafein yang lebih tinggi. Namun, bagi individu yang belum berpengalaman dalam menilai kualitas kopi, membedakan kedua jenis kopi ini sering kali sulit dilakukan hanya melalui pengamatan visual (Murinto dkk., 2023). Bentuk biji, warna, dan tekstur keduanya bisa sangat mirip, terutama setelah disangrai (Alfiantama dkk., 2024). Kesulitan tersebut menjadi tantangan tersendiri bagi pelaku industri kopi yang membutuhkan ketepatan dalam proses seleksi khusus, serta memakan waktu yang relatif lama. Oleh karena itu, dibutuhkan suatu sistem yang mampu melakukan deteksi dan klasifikasi jenis biji kopi secara otomatis. Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengklasifikasikan dua jenis biji kopi,



yaitu Arabika dan Robusta, menggunakan metode *Convolutional Neural Network (CNN)*, yang merupakan model komputasi canggih yang terinspirasi dari struktur dan fungsi otak manusia.

Perkembangan teknologi di bidang pengolahan citra digital dan kecerdasan buatan (Artificial Intelligence), khususnya CNN, memberikan peluang besar untuk mengatasi permasalahan tersebut (Yu dkk., 2023). CNN dikenal sangat efektif dalam tugas pengenalan dan klasifikasi citra karena kemampuannya mengekstraksi fitur dari data visual seperti ruang warna dan skala keabuan. Melalui kemampuan tersebut, jaringan syaraf tiruan dapat mengidentifikasi serta membedakan setiap jenis biji kopi secara akurat. Salah satu pendekatan deep learning yang paling populer dan terbukti unggul dalam klasifikasi citra adalah Convolutional Neural Network (CNN), karena arsitekturnya mampu menangkap fitur spesial secara hierarkis dari data gambar (Mienye & Swart, 2024).

Beberapa penelitian sebelumnya telah menunjukkan bahwa metode *machine learning*, khususnya *Convolutional Neural Network (CNN)*, efektif dalam mengklasifikasikan citra biji kopi. Santoso dkk. (2025) mengembangkan model CNN berbasis arsitektur ResNet-101 untuk mengklasifikasikan tiga varietas kopi, yaitu Arabika, Robusta, dan Liberika, menggunakan dataset sebanyak 900 citra dengan masing-masing 300 citra per kelas yang diambil dalam kondisi pencahayaan alami. Penelitian tersebut juga melakukan konversi citra ke grayscale dan menambahkan proses *feature extraction* statistik (*mean*, standar deviasi, *skewness*, *entropy*, *energy*, dan *smoothness*) untuk memperkuat representasi tekstur. Hasil pelatihan menunjukkan akurasi 99,44% pada data latih dan 100% pada data uji. Kelebihan dari penelitian ini terletak pada kombinasi antara *feature extraction* statistik dan arsitektur CNN yang dalam, namun penggunaan citra keabuan mengabaikan informasi warna alami biji kopi yang sebenarnya dapat membantu proses klasifikasi visual. Selain itu, dataset yang digunakan masih terbatas pada latar dan kondisi pencahayaan tertentu sehingga performa model belum teruji untuk variasi citra di lingkungan berbeda.

Penelitian lain dilakukan oleh Ningrum dkk. (2024) yang menggunakan metode CNN untuk klasifikasi penyakit tanaman cabai dengan dataset 162 citra daun dan buah cabai, dibagi menjadi data latih (80%) dan data uji (20%). Model CNN yang dibangun mampu mencapai akurasi 100%, namun performanya menurun drastis menjadi 45% ketika diuji dengan 74 citra baru yang belum pernah digunakan. Hal ini mengindikasikan bahwa model mengalami *overfitting* karena kurangnya variasi data dan tidak adanya penerapan *transfer learning* atau data *augmentation*. Meskipun demikian, penelitian ini memperlihatkan potensi kuat CNN dalam mendeteksi pola kompleks pada citra pertanian dan menjadi dasar bahwa performa model dapat sangat bergantung pada kualitas serta keberagaman dataset yang digunakan.

Sementara itu, Pakaya dkk. (2024) mengembangkan sistem klasifikasi tingkat sangrai biji kopi berbasis CNN dengan arsitektur MobileNet dan mengimplementasikannya ke dalam aplikasi Android. Dataset yang digunakan berjumlah 1.600 citra biji kopi hasil pemotretan menggunakan *smartphone*, yang dibagi menjadi data latih sebanyak 1.200 citra dan data uji 400 citra. Hasil pelatihan menunjukkan akurasi 98% pada data latih dan 88% pada data uji, sedangkan pengujian aplikasi menghasilkan akurasi 93,55%, *precision* 97,06%, dan *recall* 96,67%. Namun fokus klasifikasinya terbatas pada roasting level kopi, bukan pada perbedaan varietas seperti Arabika dan Robusta. Selain itu, penelitian tersebut belum memanfaatkan *transfer learning* untuk meningkatkan stabilitas dan kemampuan generalisasi model.

Selain itu, CNN dikenal sebagai teknik *deep learning* yang menunjukkan kinerja signifikan dalam berbagai tugas klasifikasi dan pengenalan gambar, menjadikannya pilihan ideal untuk aplikasi analisis visual pada objek pertanian maupun industri (Allo dkk., 2025). Metode ini dinilai tepat karena mampu mempelajari pola dan karakteristik kompleks dalam data citra, sehingga menghasilkan tingkat konsistensi yang tinggi dalam proses klasifikasi. Sejumlah penelitian sebelumnya juga telah menerapkan CNN untuk mengklasifikasikan biji kopi berdasarkan data citra multispektral, yang terbukti dapat memperoleh akurasi yang tinggi dalam identifikasi pada proses pengolahan kopi (Santoso dkk., 2025). Selain penerapan CNN, sejumlah penelitian juga menggunakan metode *machine learning* untuk klasifikasi biji kopi. Sebagai contoh, Septiarini dkk. (2024) menggunakan fitur bentuk, warna, dan tekstur dengan teknik Principal Component Analysis (PCA) dan backpropagation Neural Network (BPNN), dan mencapai akurasi sebesar 98,54% menggunakan dataset sebanyak 1.440 citra biji kopi. Penelitian lainnya oleh Fata & Avianto (2024) menerapkan metode Naive Bayes pada sistem klasifikasi kualitas biji kopi Robusta dan memperoleh akurasi sebesar 86% dengan total data sebanyak 220 citra. Hasil-hasil ini menunjukkan bahwa pendekatan berbasis *machine learning* mampu menghasilkan performa tinggi, namun arsitektur *deep learning* seperti CNN memiliki keunggulan utama dalam mengekstraksi fitur kompleks secara otomatis tanpa memerlukan perancangan fitur manual.

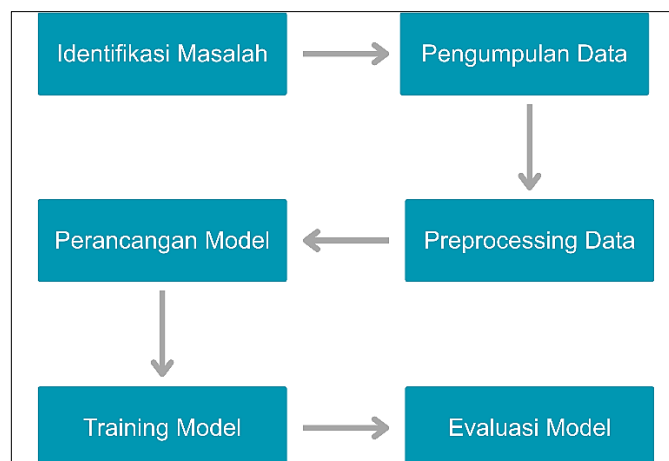
Dari hasil tinjauan terhadap beberapa penelitian sebelumnya, dapat disimpulkan bahwa meskipun metode *machine learning* dan *Convolutional Neural Network (CNN)* telah menunjukkan akurasi tinggi dalam klasifikasi citra biji kopi maupun objek pertanian lainnya, masih terdapat sejumlah keterbatasan yang perlu diperhatikan. Sebagian penelitian menggunakan dataset yang relatif terbatas dan kurang bervariasi dalam hal pencahayaan, latar belakang, serta sudut pengambilan gambar, sehingga model yang dihasilkan cenderung mengalami *overfitting* dan kurang mampu melakukan generalisasi terhadap data baru. Selain itu, beberapa studi belum memanfaatkan *transfer learning* untuk meningkatkan efisiensi pelatihan dan stabilitas model, serta masih mengabaikan informasi warna alami pada citra yang berpotensi meningkatkan akurasi klasifikasi.

Berdasarkan hasil-hasil penelitian tersebut, dapat disimpulkan bahwa CNN memiliki potensi akurasi yang tinggi serta fleksibilitas luas dalam berbagai tugas klasifikasi citra, termasuk identifikasi varietas kopi Arabika dan Robusta. Namun, masih terdapat celah penelitian berupa terbatasnya penggunaan arsitektur yang ringan dan efisien untuk diterapkan pada perangkat berkinerja menengah seperti *smartphone*. Untuk mengatasi kebutuhan tersebut, penelitian ini menggunakan arsitektur MobileNetV2 yang dirancang khusus untuk menghasilkan performa tinggi dengan jumlah

parameter yang jauh lebih kecil dibandingkan arsitektur lain seperti VGG, ResNet, atau EfficientNet. MobileNetV2 memanfaatkan *depthwise separable convolution* dan *inverted residual block* yang terbukti mampu menurunkan kompleksitas komputasi tanpa mengurangi akurasi secara signifikan, sehingga sangat sesuai untuk dataset berukuran kecil dan implementasi pada perangkat edge computing (Kho dkk., 2026; Xu dkk., 2025). Berbeda dari penelitian Santoso dkk. (2025) yang menggunakan citra keabuan serta penelitian Pakaya dkk. (2024) yang hanya fokus pada tingkat sangrai, penelitian ini memanfaatkan citra berwarna biji kopi sangrai hasil pemotretan *smartphone* dengan variasi posisi dan pencahayaan. Selain itu, strategi *transfer learning* MobileNetV2 dengan bobot pra-latih ImageNet dipadukan dengan data *augmentation* (rotasi, zoom, flip, dan penyesuaian kecerahan) dan optimasi *hyperparameter*. Dengan pendekatan tersebut, penelitian ini bertujuan mengembangkan sistem klasifikasi otomatis yang lebih akurat dan stabil dalam membedakan biji kopi sangrai Arabika dan Robusta berdasarkan citra digital.

2. METODOLOGI PENELITIAN

Tahapan penelitian disusun secara sistematis untuk menggambarkan alur pelaksanaan penelitian agar dapat mencapai tujuan, yaitu mengklasifikasikan citra biji kopi Arabika dan Robusta menggunakan metode *Convolutional Neural Network (CNN)*. Berdasarkan Gambar 1, setiap tahap dirancang saling berkaitan dari proses identifikasi masalah hingga implementasi model. Setiap tahapan memiliki peran penting dalam menghasilkan sistem klasifikasi citra biji kopi Arabika dan Robusta yang akurat. Tahapan penelitian ditunjukkan pada Gambar 1, yang dimulai dari proses identifikasi masalah, pengumpulan data citra biji kopi, perancangan sistem, hingga tahapan penelitian dan evaluasi model menggunakan metode *Convolutional Neural Network (CNN)*. Setiap tahap saling terhubung dan berperan penting dalam membangun sistem klasifikasi citra biji kopi yang akurat.



Gambar 1. Tahapan Penelitian







2.1 Identifikasi Masalah

Tahap identifikasi masalah merupakan langkah awal dalam penelitian ini yang bertujuan untuk memahami serta merumuskan permasalahan utama yang akan diselesaikan. Permasalahan yang diangkat dalam penelitian ini adalah kesulitan dalam membedakan jenis biji kopi Arabika dan Robusta secara visual. Kedua varietas kopi tersebut memiliki kemiripan pada bentuk fisik, warna, dan tekstur permukaan biji, sehingga identifikasi manual sering kali tidak akurat dan memerlukan keahlian khusus. Untuk mengatasi hal tersebut, diperlukan sistem klasifikasi otomatis berbasis pengolahan citra digital yang mampu mengenali perbedaan antara kopi Arabika dan Robusta secara lebih objektif, dan akurat. Metode *Convolutional Neural Network (CNN)* dipilih karena memiliki kemampuan tinggi dalam mengekstraksi fitur visual dari citra, seperti tekstur, bentuk, dan pola permukaan biji kopi. Dengan penerapan metode ini, sistem diharapkan dapat mengidentifikasi jenis biji kopi secara otomatis tanpa memerlukan intervensi manual.

2.2 Pengumpulan Data

Data penelitian dikumpulkan dengan cara memotret biji kopi Arabika dan Robusta dengan menggunakan kamera *smartphone*. Setiap jenis biji kopi diambil sebanyak 105 citra, sehingga total terdapat 210 gambar yang digunakan sebagai data penelitian. Pengambilan gambar dilakukan dari berbagai sudut pandang, posisi, dan jarak, untuk memastikan model dapat mengenali pola visual dari beragam kondisi tampilan biji kopi. Selain itu, proses pemotretan juga dilakukan pada bermacam kondisi pencahayaan, baik pencahayaan alami dengan sinar matahari langsung di ruang terbuka dan pencahayaan buatan menggunakan lampu LED *flash smartphone*, guna memperkaya variasi data dan meningkatkan kemampuan model dalam mengenali objek pada kondisi nyata. Seluruh gambar diambil dengan latar belakang berwarna putih dan resolusi yang seragam antara 1080×1920 piksel hingga 224×224 piksel setelah proses *resizing* agar tampilan biji kopi lebih kontras dan bebas dari gangguan visual yang dapat mempengaruhi hasil klasifikasi. Sampel dari data yang telah dikumpulkan dapat dilihat pada Tabel 1.

Tabel 1. Sampel data penelitian

Jenis Kopi	Gambar		
Arabika			
Robusta			

2.3 Preprocessing Data

Sebelum data digunakan untuk pelatihan model *Convolutional Neural Network (CNN)*, dilakukan proses preprocessing data. Tahap ini dilakukan untuk menyiapkan data dan memperbaiki kualitas citra. Proses ini bertujuan agar model dapat mengenali pola visual secara lebih baik, sekaligus mengurangi risiko *overfitting* akibat keterbatasan jumlah data. Pada penelitian ini augmentasi data dilakukan dengan beberapa teknik sebagai berikut.

a. *Rescale*

Seluruh nilai piksel pada citra diubah dari rentang 0-255 menjadi 0-1. Langkah ini bertujuan untuk menormalkan data agar model dapat memproses konvergensi dengan lebih cepat saat pelatihan.

b. *Rotation Range*

Teknik ini memutar gambar secara acak hingga 30 derajat, sehingga model dapat mengenali biji kopi dari berbagai posisi, seperti posisi kopi sedikit miring.

c. *Width dan Height Shift Range*

Citra digeser secara horizontal dan vertikal hingga 30% dari total lebar dan tinggi gambar. Hal ini bertujuan untuk menyimulasikan perbedaan posisi objek dalam *frame*.

d. *Horizontal dan Vertical Flip*

Gambar akan dibalik secara *horizontal* maupun vertikal agar model tidak hanya mengenali biji kopi dari satu arah tampilan saja.

e. *Zoom Range*

Memperbesar atau memperkecil citra hingga 30% untuk meniru kondisi jarak pengambilan gambar yang berbeda.

f. *Shear Range*

Transformasi geser (*shear*) sebesar 0.2 diterapkan untuk menambah variasi bentuk dan sudut pandang objek.

g. *Brightness Range*

Meningkatkan kecerahan citra biji kopi dalam rentang 80% hingga 120% untuk mengantisipasi variasi pencahayaan pada saat pengambilan gambar.

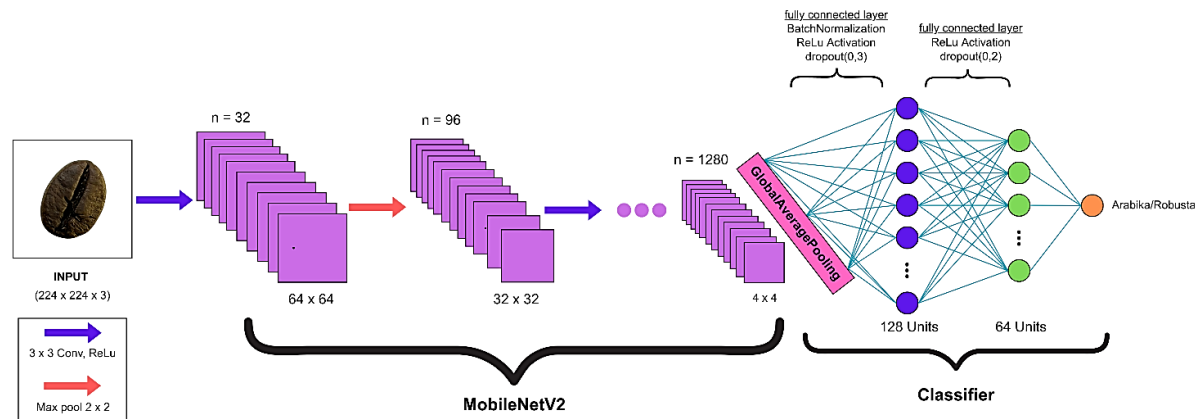
Dari berbagai teknik augmentasi di atas, dataset citra biji kopi menjadi lebih bervariasi dan representatif terhadap kondisi nyata. Hal ini dapat membantu model CNN dalam mempelajari fitur-fitur penting dari biji kopi Arabika dan Robusta secara lebih *robust* serta dapat meningkatkan akurasi dan generalisasi pada proses klasifikasi.

2.4 Perancangan Model

Perancangan arsitektur model dilakukan dengan memanfaatkan MobileNetV2 sebagai *base model* untuk melakukan ekstraksi fitur terhadap citra biji kopi Arabika dan Robusta. Arsitektur CNN terdiri atas beberapa lapisan utama yang bekerja secara hierarkis. Lapisan pertama adalah *input layer* yang menerima data mentah setelah pengolahan, diikuti oleh *convolutional layer* untuk mengekstraksi fitur lokal dan *pooling layer* untuk mereduksi dimensi serta mencegah *overfitting*. Setiap lapisan konvolusi diikuti oleh *activation function* seperti ReLU, Sigmoid, atau Tanh guna menambah sifat *non-linear*. Untuk menjaga kestabilan pelatihan, CNN dilengkapi dengan *batch normalization* dan *dropout layer*, sedangkan pada bagian akhir terdapat *fully connected layer* yang berfungsi menggabungkan hasil ekstraksi fitur menjadi output klasifikasi. Struktur berlapis ini memungkinkan CNN belajar secara *end-to-end* tanpa memerlukan rekayasa fitur manual (Zhao dkk., 2024).

Model yang digunakan merupakan arsitektur *Convolutional Neural Network (CNN)* yang mengadopsi kombinasi *depthwise separable convolution*, *inverted residuals*, dan linear *bottlenecks*, sehingga mampu mengurangi jumlah parameter tanpa menurunkan kinerja klasifikasi secara signifikan (Yong dkk., 2023). MobileNetV2 dipilih karena memiliki desain arsitektur yang sederhana namun tetap menghasilkan performa yang baik pada citra beresolusi

menengah. Selain itu, model ini telah dilatih sebelumnya menggunakan dataset ImageNet (pre-trained model), sehingga proses pelatihan dapat dilakukan lebih cepat dan stabil melalui penerapan teknik *transfer learning*. Arsitektur rancangan CNN yang digunakan dalam penelitian ini ditunjukkan pada Gambar 2.



Gambar 2. Arsitektur CNN

Pada Gambar 2, model menerima citra biji kopi berukuran 224×224 piksel dengan tiga kanal warna (RGB) sebagai input. Citra ini kemudian diproses menggunakan arsitektur MobileNetV2 yang berfungsi sebagai ekstraktor fitur utama. MobileNetV2 merupakan varian jaringan konvolusional yang dirancang dengan pendekatan *depthwise separable convolution* untuk mengoptimalkan proses ekstraksi fitur dengan jumlah parameter yang lebih sedikit dibandingkan CNN konvensional, namun tetap mampu mempertahankan tingkat akurasi yang baik. Arsitektur ini menggunakan blok *inverted residual* dan *linear bottleneck* yang memungkinkan jaringan mempelajari representasi fitur penting dari citra biji kopi pada berbagai tingkat kedalaman. Proses konvolusi awal dilakukan menggunakan kernel berukuran 3×3 dengan aktivasi ReLU, diikuti oleh beberapa tahap *depthwise separable convolution* yang memperkaya representasi fitur citra. Setiap tahap menghasilkan peta fitur dengan jumlah filter berbeda yang secara bertahap merangkum karakteristik visual dari biji kopi Arabika dan Robusta.

Hasil keluaran dari MobileNetV2 diteruskan ke lapisan Global Average Pooling (GAP) yang berfungsi mereduksi hasil keluaran model menjadi representasi vektor sederhana sebelum memasuki tahap klasifikasi. Selanjutnya, hasil dari GAP dihubungkan dengan beberapa lapisan *fully connected (dense layers)* yang berperan dalam proses klasifikasi:

- Lapisan *fully connected* pertama memiliki 128 unit neuron dengan fungsi aktivasi ReLU dan dropout sebesar 0,3 untuk mengurangi risiko overfitting.
- Lapisan *fully connected* kedua memiliki 64 unit neuron dengan ReLU activation dan dropout sebesar 0,2, untuk meningkatkan kemampuan generalisasi model.
- Lapisan *output* menggunakan fungsi aktivasi Sigmoid dengan dua neuron keluaran yang merepresentasikan dua kelas target, yaitu Arabika dan Robusta.

Dengan rancangan arsitektur seperti yang ditunjukkan pada Gambar 2, sistem ini mampu mengklasifikasikan jenis biji kopi Arabika dan Robusta secara otomatis dan akurat. Metode ini diharapkan dapat menghasilkan tingkat akurasi yang baik dengan waktu pelatihan yang relatif singkat.

2.5 Pelatihan Model

Pelatihan model bertujuan untuk mengajarkan *Convolutional Neural Network (CNN)* dalam mengenali pola visual yang membedakan biji kopi Arabika dan Robusta berdasarkan citra. Pada penelitian ini, digunakan pendekatan *transfer learning* dengan memanfaatkan arsitektur MobileNetV2 sebagai *feature extractor*. Arsitektur ini dipilih karena memiliki struktur yang ringan dan efisien, serta mampu menghasilkan representasi fitur yang baik meskipun digunakan pada dataset berukuran kecil.

Sebelum proses pelatihan, dataset dibagi menjadi data latih (60%), data validasi (20%) dan data uji (20%). Data latih digunakan untuk memperbarui bobot pada lapisan klasifikasi, sedangkan data validasi digunakan untuk mengevaluasi performa model selama proses pelatihan dan menjadi acuan bagi *callback* seperti *early stopping* dan *ReduceLROnPlateau*. Sementara itu, data uji digunakan pada tahap akhir untuk mengukur kemampuan generalisasi model terhadap data yang benar-benar belum pernah dilihat sebelumnya.

Pada implementasinya, seluruh lapisan konvolusi dasar MobileNetV2 dibekukan (*frozen*) agar bobot pra-latih dari ImageNet tidak berubah selama pelatihan. Namun, lapisan *Batch Normalization (BN)* tetap dibiarkan aktif (tidak dibekukan). Hal ini dilakukan karena pembekuan BN sering menyebabkan penurunan performa pada dataset baru akibat perbedaan distribusi batch selama pelatihan, sehingga menjaga BN tetap aktif membantu mempertahankan stabilitas dan akurasi model. Setelah base model dibekukan, ditambahkan lapisan klasifikasi (*classification head*) berupa *Global Average Pooling (GAP)* untuk mereduksi dimensi fitur, *Batch Normalization* untuk stabilisasi pelatihan, dua lapisan

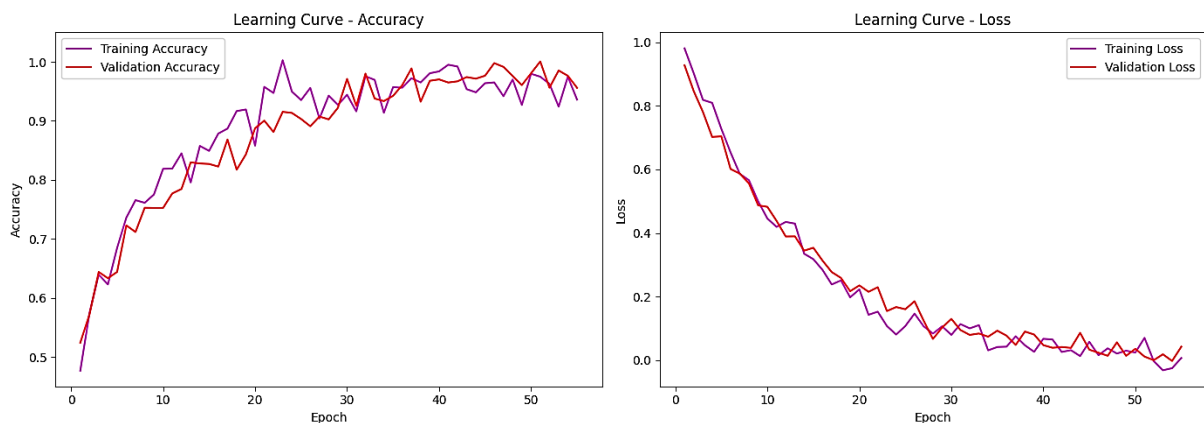
Dense dengan 128 dan 64 neuron beraktivasi ReLU, dua *dropout* berurutan dengan rasio 0,3 dan 0,2 untuk menekan *overfitting*, serta sebuah *output* layer beraktivasi sigmoid yang menghasilkan dua kelas prediksi, yaitu Arabika dan Robusta.

Selama proses pelatihan, digunakan beberapa callback untuk mengoptimalkan kinerja model. *Early stopping* digunakan untuk menghentikan proses pelatihan ketika performa validasi tidak mengalami peningkatan, *ReduceLRonPlateau* menurunkan nilai *learning rate* ketika akurasi validasi stagnan, dan *ModelCheckpoint* digunakan untuk menyimpan bobot model terbaik berdasarkan akurasi validasi tertinggi. Dengan strategi ini, model CNN diharapkan mampu mempelajari karakteristik visual biji kopi Arabika dan Robusta secara lebih efektif serta menghasilkan performa klasifikasi yang optimal.

2.6 Evaluasi Model


Tahap evaluasi model dilakukan untuk menilai kinerja dari model *Convolutional Neural Network (CNN)* yang telah dilatih dalam mengklasifikasikan citra biji kopi Arabika dan Robusta. Evaluasi ini bertujuan untuk mengetahui sejauh mana model mampu mengenali dan membedakan kedua jenis biji kopi secara akurat berdasarkan hasil prediksi yang dihasilkan. Pada penelitian ini, proses evaluasi model dilakukan menggunakan tiga pendekatan utama, yaitu *learning curve*, *confusion matrix*, dan *classification report*.

Learning curve digunakan untuk memantau perkembangan performa model selama proses pelatihan. Grafik ini menggambarkan hubungan antara jumlah *epoch* dengan nilai akurasi dan *loss* pada data pelatihan maupun validasi. Kurva akurasi menunjukkan sejauh mana model meningkatkan dalam mengenali pola data seiring bertambahnya iterasi, sementara kurva *loss* memperlihatkan penurunan tingkat kesalahan prediksi model. Pola *learning curve* yang stabil dan konvergen antara data pelatihan dan validasi menandakan bahwa model telah mencapai kinerja optimal tanpa mengalami *overfitting* atau *underfitting* (Annur dkk., 2023). Contoh visualisasi dari *learning curve* dapat dilihat pada Gambar 3 berikut.



Gambar 3. Contoh *Learning curve*

Confusion Matrix digunakan untuk menilai kinerja model klasifikasi bersama dengan metrik lain seperti akurasi, presisi, *recall*, dan F1-score, sehingga memberikan gambaran yang lebih menyeluruh tentang kemampuan model. *Confusion Matrix* merupakan tabel evaluasi yang berisi empat komponen utama: *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*. Berdasarkan keempat nilai tersebut, berbagai metrik evaluasi seperti akurasi, presisi, dan *recall* dapat dihitung (Rizky Pratama dkk., 2025). *Confusion matrix* dapat dilihat pada Gambar 4.



Gambar 4. Contoh *confusion matrix*

Sementara itu, *classification report* memberikan ringkasan kinerja model berdasarkan beberapa *matrix* utama, yaitu *precision*, *recall*, *F1-score*, dan akurasi. *Precision* menunjukkan tingkat ketepatan model dalam memprediksi kelas positif, *recall* menggambarkan kemampuan model dalam mengenali seluruh data yang benar positif, dan *F1-score*



merupakan nilai rata-rata harmonik antara *precision* dan *recall* (Annur dkk., 2023). *Matrix* evaluasi pada *classification report*. akurasi, *precision*, *recall*, dan *F1-score* dapat dihitung sebagai berikut.

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

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

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

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

2.7 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu jenis jaringan saraf tiruan yang mampu mengekstraksi fitur dari data menggunakan operasi konvolusi. CNN dapat melakukannya secara otomatis melalui pelatihan model, berbeda dengan metode tradisional yang memerlukan proses ekstraksi fitur secara manual. CNN terinspirasi dari sistem persepsi visual manusia, di mana neuron buatan bekerja menyerupai neuron biologis dan kernel konvolusi bertindak sebagai reseptor yang merespons pola fitur tertentu. CNN memiliki keunggulan berupa *local connection*, *weight sharing*, dan *downsampling*, yang menjadikannya efisien dalam komputasi serta efektif dalam mengenali pola kompleks ada data visual (Li dkk., 2022).

2.8 MobileNetV2


MobileNetV2 merupakan arsitektur *Convolutional Neural Network* (CNN) yang dikembangkan oleh Google pada tahun 2018 sebagai penyempurnaan dari MobileNetV1 dengan fokus pada efisiensi komputasi dan ukuran model yang ringan. Arsitektur ini menggabungkan beberapa inovasi utama, yaitu penggunaan *depthwise separable convolution* untuk mengurangi jumlah parameter, serta penerapan struktur *inverted residuals* dan *linear bottleneck* yang memungkinkan transfer informasi lebih efisien antar lapisan jaringan. Pada struktur *inverted residuals*, proses dimulai dari peningkatan dimensi fitur, dilanjutkan dengan *depthwise convolution*, dan diakhiri dengan penurunan dimensi, sehingga model dapat mempertahankan informasi penting sekaligus mengurangi beban komputasi. Selain itu, MobileNetV2 menggunakan fungsi aktivasi ReLU6 untuk mencegah saturasi nilai besar dan fungsi aktivasi linear pada lapisan akhir guna menghindari hilangnya informasi. Kombinasi tersebut menjadikan MobileNetV2 sebagai model yang cepat, ringan, dan tetap memiliki performa tinggi pada berbagai aplikasi visi komputer, terutama pada perangkat dengan keterbatasan sumber daya (Yong dkk., 2023).

3. HASIL DAN PEMBAHASAN

3.1 Preprocessing Data

Langkah awal sebelum dilakukan pelatihan model untuk klasifikasi jenis biji kopi Arabika dan Robusta adalah tahap *preprocessing data*. Tahapan ini bertujuan untuk menyiapkan data agar siap diproses oleh model *Convolutional Neural Network* (CNN). Data citra hasil pemotretan biji kopi Arabika dan Robusta, masing-masing sebanyak 105 gambar, diseragamkan resolusinya dari 1080×1920 menjadi 224×224 piksel. Seluruh citra kemudian dikelompokkan ke dalam dua kelas sesuai dengan jenis biji kopi, dan dilakukan normalisasi piksel agar nilai data berada dalam rentang yang seragam. Normalisasi ini juga memastikan bahwa perbedaan intensitas cahaya pada citra tidak menimbulkan bias terhadap proses pembelajaran model. Selain itu, penyamaan resolusi membantu menjaga konsistensi keterbacaan pola visual pada setiap gambar.

Selanjutnya dilakukan augmentasi data untuk memperkaya variasi citra. Proses augmentasi ini dilakukan secara virtual sehingga tidak menambah jumlah file secara fisik di dalam dataset dan secara *real-time* selama pelatihan, di mana setiap kali citra diambil dari dataset, sistem akan secara acak menerapkan transformasi seperti rotasi, pergeseran posisi (*shift*), *zoom*, *flip horizontal* dan vertikal, perubahan *brightness*, dan transformasi geser (*shear*). Dengan cara ini, model akan melihat versi gambar yang berbeda di setiap *epoch*, sehingga mampu mengenali biji kopi dari berbagai sudut, pencahayaan, dan posisi yang bervariasi. Dengan tahapan ini, akan meningkatkan kualitas dan konsistensi *input* dan memperkuat kemampuan generalisasi model CNN dalam membedakan antara biji kopi Arabika dan Robusta. Augmentasi ini juga berfungsi untuk mencegah model mengalami *overfitting* karena model tidak hanya terpaku pada pola citra asli. Secara keseluruhan, proses ini memastikan bahwa model menjadi lebih robust ketika dihadapkan pada data baru di luar dataset pelatihan. Sampel hasil augmentasi dapat dilihat pada Gambar 5.



Gambar 5. Hasil augmentasi data

3.2 Split Data

Setelah dilakukan tahap *preprocessing*, data citra biji kopi kemudian dibagi menjadi tiga bagian, yaitu data latih (*training*), data validasi (*validation*) dan data uji (*testing*). Pembagian data dilakukan agar model *Convolutional Neural Network* (CNN) dapat dilatih menggunakan sebagian data dan dievaluasi menggunakan data yang belum pernah dilihat sebelumnya, sehingga performanya dapat dinilai secara objektif. Selain itu, disertakannya data validasi bertujuan untuk memantau kinerja model selama proses pelatihan, membantu mendeteksi potensi *overfitting* secara lebih dini, serta memberikan acuan dalam menyesuaikan *hyperparameter* agar model mencapai performa terbaik. Dari total data 210 data, proporsi pembagian data dilakukan dengan perbandingan 60% (126 data) untuk data latih, dan masing-masing 20% (42 data) untuk data validasi dan data uji. Untuk pembagian data dapat dilihat pada Tabel 2.

Tabel 2. Pembagian data *training* dan *testing*

Jenis Data	Jumlah
Training	126
Validation	42
Testing	42
Total	210

Data latih digunakan untuk mengoptimalkan bobot parameter pada model agar mampu mengenal pola visual yang membedakan biji kopi Arabika dan Robusta. Data validasi digunakan untuk memantau kinerja model selama pelatihan, mendeteksi potensi *overfitting*, serta membantu dalam penyesuaian *hyperparameter*. Sementara itu, data uji digunakan untuk mengukur kemampuan model dalam melakukan generalisasi terhadap data baru. Pembagian data dilakukan secara acak untuk memastikan distribusi kedua kelas tetap seimbang pada masing-masing subset.

3.3 Training Model

Pelatihan model dilakukan menggunakan arsitektur *transfer learning* berbasis MobileNetV2 dengan bobot awal dari dataset ImageNet sebagai *feature extractor*. Pada proses ini, seluruh lapisan MobileNetV2 dibekukan (*frozen layer*), sementara bagian classifier dilatih ulang menggunakan dataset citra biji kopi Arabika dan Robusta. Tahap pelatihan bertujuan untuk menyesuaikan lapisan akhir agar mampu mengenali karakteristik visual spesifik dari kedua jenis biji kopi tersebut. Arsitektur classifier terdiri atas lapisan *global average pooling 2D*, diikuti oleh *batch normalization*, *Dropout(0.3)*, *Dense(64, ReLU)*, *Dropout(0.2)*, dan lapisan keluaran *Dense(1, Sigmoid)* untuk klasifikasi biner.

Proses pelatihan dilakukan dengan *epoch* sebanyak 55, *batch size* 32, dan *learning rate* 0,0001 dengan menggunakan algoritma optimasi Adam serta fungsi *loss Binary Cross-Entropy*. Untuk menjaga stabilitas pelatihan model dan mencegah *overfitting*, diterapkan pula dua *callback*, yaitu *early stopping*, dan model *checkpoint*. *Early stopping* akan memantau nilai dari *validation loss* dengan *patience* 10 *epoch* serta mengembalikan bobot terbaik ketika performa model tidak lagi meningkat, sedangkan model *checkpoint* digunakan untuk menyimpan model terbaik selama proses pelatihan. Untuk konfigurasi *hyperparameter* yang digunakan dapat dilihat pada Tabel 3.

Tabel 3. Konfigurasi *hyperparameter* model


Split Data	Batch size	Epoch	Learning Rate	Optimizer	Dense	Dropout
60:20:20	32	55	0,0001	Adam	128, 64	0,3;0,2

Berdasarkan hasil dari pelatihan model dengan *hyperparameter* tersebut, model menunjukkan performa yang baik dengan nilai akurasi *training* sebesar 99,21% dan akurasi *testing* 97,62%. Nilai *loss* model terbilang cukup rendah

tercatat *training loss* sebesar 0,0682, dan untuk *testing loss* sebesar 0,1333. Hasil ini menunjukkan bahwa model telah mampu melakukan generalisasi dengan cukup baik terhadap data validasi tanpa mengalami *overfitting* yang signifikan, di mana akurasi validasi tinggi disertai *loss* yang dalam batas wajar. Selain itu, waktu pelatihan yang dibutuhkan untuk menyelesaikan keseluruhan proses adalah sekitar 29,8 menit. Hal ini membuktikan bahwa kombinasi antara metode *transfer learning* dan konfigurasi *hyperparameter* yang digunakan mampu menghasilkan representasi fitur yang efektif dalam mengklasifikasikan citra biji kopi Arabika dan Robusta.

3.4 Evaluasi Model

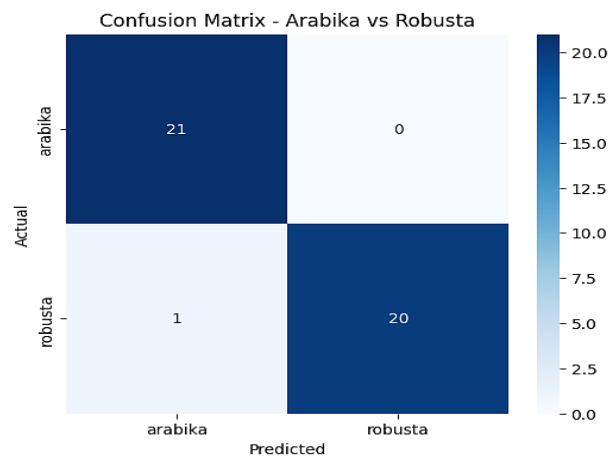
Hasil dari pelatihan model *Convolutional Neural Network (CNN)* dengan *transfer learning* MobileNetV2 menunjukkan bahwa model memiliki kinerja yang baik dalam melakukan klasifikasi biji kopi Arabika dan Robusta, dengan nilai akurasi testing 97,62% dan nilai *loss* yang relatif rendah sebesar 0,1333. Hal ini mengindikasikan bahwa model mampu membedakan fitur visual kedua jenis biji kopi secara efektif tanpa mengalami *overfitting* signifikan. Hal ini didukung dengan hasil evaluasi dari *learning curve*, *confusion matrix*, dan *classification report* model.



Gambar 6. Hasil *learning curve* model

Hasil dari *learning curve* model yang menggambarkan nilai akurasi dan *loss* selama proses pelatihan ditunjukkan pada Gambar 6. Pada bagian grafik akurasi, terlihat bahwa nilai akurasi *training* meningkat secara konsisten seiring dengan bertambahnya *epoch* hingga mendekati kestabilan di atas 90% setelah memasuki pertengahan epoch. Hasil tersebut menunjukkan bahwa model dapat belajar dengan efektif tanpa mengalami gejala *overfitting*.

Sementara itu, pada grafik *loss* memperlihatkan penurunan nilai *training loss* dan *validation loss* secara bertahap. Nilai *validation loss* akhir sebesar 0,1333 mengindikasikan bahwa tingkat kesalahan prediksi pada data validasi relatif kecil. Selisih yang tidak terlalu besar antara *training loss* dan *validation loss* menandakan bahwa model tidak mengalami *overfitting* yang signifikan, sehingga arsitektur dan parameter pelatihan yang digunakan dapat dianggap cukup optimal. Hasil dari *learning curve* menunjukkan bahwa model telah mencapai konvergensi dengan performa yang stabil dan akurasi tinggi dalam melakukan klasifikasi biji kopi Arabika dan Robusta.



Gambar 7. *Confusion matrix* model

Hasil dari *confusion matrix* yang ditunjukkan pada Gambar 7 menunjukkan bahwa model memiliki kemampuan klasifikasi yang sangat baik dalam membedakan biji kopi Arabika dan Robusta. Dari total 42 citra uji, model dapat



mengklasifikasikan 21 citra Arabika dengan benar dan 20 citra Robusta dengan benar, sementara hanya 1 citra Robusta yang salah diprediksi sebagai Arabika. Capaian ini menunjukkan bahwa model berbasis *transfer learning* dengan arsitektur MobileNetV2 mampu mengenali pola visual yang khas pada kedua jenis biji kopi dengan tingkat ketepatan yang tinggi. Pola distribusi nilai diagonal pada *confusion matrix* yang dominan juga mengindikasikan bahwa sebagian besar prediksi model sesuai dengan label aslinya, sehingga proses pembelajaran telah berlangsung secara efektif dan stabil.

Kesalahan klasifikasi yang muncul pada satu citra Robusta menunjukkan adanya sedikit tumpang tindih fitur antar kelas. Hal ini dapat disebabkan oleh kemiripan fitur visual antara biji Robusta dan Arabika, seperti warna dan tekstur permukaan yang serupa akibat perbedaan tingkat sangrai (*roasting level*) maupun pencahayaan saat pengambilan gambar. Walaupun demikian, proporsi kesalahan ini tergolong kecil, dan model tetap menunjukkan kemampuan generalisasi yang baik, dengan tingkat ketepatan prediksi yang tinggi untuk kedua kelas.

Tabel 4. Hasil *classification report*

	Precision	Recall	F1-Score	Support
Arabika	0.95	1.00	0.98	21
Robusta	1.00	0.95	0.98	21
Accuracy			0.98	42
Macro avg	0.98	0.98	0.98	42
Weighted avg	0.98	0.98	0.98	

Classification report pada Tabel 4 memperkuat bukti bahwa model memiliki performa klasifikasi yang sangat baik dan seimbang pada kedua kelas. Nilai *precision*, *recall*, dan *F1-score* untuk Arabika maupun Robusta berada pada kisaran yang sangat tinggi, yaitu 0,95 hingga 1,00, dengan akurasi keseluruhan mencapai 98%. Rata-rata makro (*macro average*) dan rata-rata berbobot (*weighted average*) juga menunjukkan nilai 0,98, yang menandakan bahwa performa model konsisten pada keseluruhan data uji.

Pada kelas Arabika, nilai *precision* sebesar 0,95 dan *recall* sebesar 1,00 mengindikasikan bahwa hampir seluruh citra Arabika berhasil diprediksi dengan benar. Sementara itu, pada kelas Robusta, nilai *precision* sebesar 1,00 dan *recall* sebesar 0,95 mengindikasikan bahwa seluruh prediksi Robusta sangat tepat, meskipun masih terdapat satu citra Robusta yang tidak terdeteksi sebagai kelas tersebut.

Nilai *F1-score* yang seimbang untuk kedua kelas yaitu 0,98, menunjukkan bahwa model tidak hanya akurat tetapi juga konsisten dalam melakukan klasifikasi tanpa bias terhadap salah satu kelas. Selain itu, kesamaan antara *macro average* dan *weighted average* memperlihatkan bahwa model mampu mempertahankan performa yang stabil pada distribusi data uji yang relatif seimbang. Secara keseluruhan, hasil *classification report* ini menegaskan bahwa model berbasis *transfer learning* MobileNetV2 telah mampu melakukan klasifikasi biji kopi Arabika dan Robusta dengan tingkat ketepatan dan generalisasi yang baik.

Hasil evaluasi model model Convolutional Neural Network (CNN) berbasis arsitektur MobileNetV2 menunjukkan performa yang baik dalam membedakan citra biji kopi Arabika dan Robusta. Berdasarkan hasil pelatihan, model mencapai akurasi pelatihan sebesar 99,21% dan akurasi pengujian sebesar 97,62%, dengan training loss sebesar 0,0682 dan *testing loss* sebesar 0,1333. Nilai akurasi yang tinggi dan loss yang rendah menunjukkan bahwa model mampu melakukan generalisasi dengan baik terhadap data validasi tanpa mengalami *overfitting* yang signifikan. Hasil tersebut menandakan bahwa kombinasi *transfer learning* menggunakan MobileNetV2 dengan konfigurasi hyperparameter yang dioptimalkan berhasil menghasilkan representasi fitur yang efektif untuk klasifikasi biji kopi Arabika dan Robusta.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, penelitian ini bertujuan untuk mengembangkan sistem klasifikasi otomatis guna membedakan biji kopi Arabika dan Robusta menggunakan metode *Convolutional Neural Network* (CNN) dengan penerapan *transfer learning* pada arsitektur MobileNetV2. Model yang dikembangkan mampu mencapai akurasi pengujian sebesar 97,62% dengan nilai *loss* 0,1333, yang menunjukkan kemampuan sistem dalam mengenali pola visual yang menjadi pembeda utama antara kedua varietas biji kopi tersebut. Dengan demikian, tujuan penelitian untuk menghasilkan model klasifikasi otomatis yang akurat telah tercapai. Proses pelatihan model berlangsung selama 29,8 menit, menunjukkan waktu pelatihan yang relatif singkat untuk ukuran dataset yang digunakan. Arsitektur MobileNetV2 terbukti sesuai untuk dataset berukuran kecil karena kemampuannya mengekstraksi fitur penting secara efisien tanpa memerlukan proses pelatihan yang kompleks. Penerapan *transfer learning* memungkinkan model memanfaatkan bobot pra-latih ImageNet sehingga proses adaptasi fitur menjadi lebih stabil dan optimal. Meskipun memberikan hasil yang baik, penelitian ini memiliki beberapa keterbatasan. Salah satunya adalah jumlah dataset yang masih terbatas serta variasi citra yang belum sepenuhnya merepresentasikan kondisi nyata di lapangan, seperti perbedaan latar belakang, intensitas cahaya ekstrem, atau kualitas kamera yang berbeda. Kondisi ini berpotensi menimbulkan data bias, sehingga model dapat lebih baik pada jenis citra tertentu tetapi kurang optimal pada citra dengan karakteristik berbeda. Oleh karena itu, penelitian selanjutnya disarankan untuk memperluas jumlah dan keragaman data guna mengurangi bias tersebut, menerapkan teknik *fine-tuning* untuk meningkatkan generalisasi, serta



membandingkan performa dengan arsitektur CNN lain seperti EfficientNet, ResNet, atau VGG. Dengan capaian yang diperoleh, model ini memiliki potensi besar untuk dikembangkan sebagai sistem klasifikasi otomatis berbasis perangkat *edge* seperti *smartphone*, sehingga dapat mendukung proses identifikasi varietas kopi secara akurat, cepat, dan efisien pada kebutuhan industri maupun penelitian di bidang pengolahan citra digital pertanian.

REFERENCES

- Alfiantama, I., Kresnawan, M. I., & Handoko, A. P. (2024). *Klasifikasi Tingkat Roasting Biji Kopi Dengan Metode CNN*. 3. <https://doi.org/https://doi.org/10.29407/182k1t17>
- Allo, Y. M. K., Paendong, I. P., & Saputro, P. H. (2025). Classification of Tomato Ripeness Levels Using Convolutional Neural Network (CNN). *Journal of Intelligent Systems and Information Technology*, 2(2), 80–87. <https://doi.org/10.61971/jisit.v2i2.151>
- Annur, I. F., Umami, J., Annafii, Moch. N., Trisnaningrum, N., & Putra, O. V. (2023). Klasifikasi Tingkat Keparahan Penyakit Leafblast Tanaman Padi Menggunakan MobileNetv2. *Fountain of Informatics Journal*, 8(1), 7–14. <https://doi.org/10.21111/fij.v8i1.9419>
- Badan Pusat Statistik. (2024). *Statistik Kopi Indonesia 2023*. <https://www.bps.go.id/id/publication/2024/11/29/d748d9bf594118fe112fc51e/statistik-kopi-indonesia-2023.html>
- Czarnecka-Skubina, E., Pielak, M., Salek, P., Korzeniowska-Ginter, R., & Owczarek, T. (2021). Consumer Choices and Habits Related to Coffee Consumption by Poles. *International Journal of Environmental Research and Public Health*, 18(8), 3948. <https://doi.org/10.3390/ijerph18083948>
- Fata, M. I. I., & Avianto, D. (2024). Penerapan Metode Naive Bayes pada Sistem Klasifikasi Kualitas Biji Kopi Robusta. *Jurnal Indonesia : Manajemen Informatika dan Komunikasi*, 5(1), 512–524. <https://doi.org/10.35870/jimik.v5i1.515>
- Fibrianto, K., Daryanto, K. A., Sholihah, N., Wahibah, L. Y., Hasyati, N., Al-Baarri, A. N., & Hariyadi, D. M. (2020). Sensory profiling of Robusta and Liberica coffee leaves functional tea by modifying brewing temperature. *IOP Conference Series: Earth and Environmental Science*, 475(1), 012028. <https://doi.org/10.1088/1755-1315/475/1/012028>
- Kho, L. C., Cheng, G., Ngu, S. S., Koh, Q. Z., Joseph, A., & Kipli, K. (2026). An Efficient Distracted Driving Detection Based on MobileNet V2SE Fusion. *Journal of Advanced Research Design Journal homepage*, 145, 149–164. <https://doi.org/10.37934/ard.145.1.149164>
- Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2022). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999–7019. <https://doi.org/10.1109/TNNLS.2021.3084827>
- Mienye, I. D., & Swart, T. G. (2024). A Comprehensive Review of Deep Learning: Architectures, Recent Advances, and Applications. *Information*, 15(12), 755. <https://doi.org/10.3390/info15120755>
- Murinto, M., Rosyda, M., & Melany, M. (2023). Klasifikasi Jenis Biji Kopi Menggunakan Convolutional Neural Network dan Transfer Learning pada Model VGG16 dan MobileNetV2. *JRST (Jurnal Riset Sains dan Teknologi)*, 7(2), 183. <https://doi.org/10.30595/jrst.v7i2.16788>
- Ningrum, B. N. T. C., Ni'mah, E. N., Arifin, M. P., & Dara, M. A. D. W. (2024). Klasifikasi Dan Pengenalan Pola Penyakit Cabai Dengan Metode CNN (Convolution Neural Network). *Seminar Nasional Teknologi & Sains*, 3(1), 125–132. <https://doi.org/10.29407/stains.v3i1.4137>
- Pakaya, I. M., Radi, R., & Purwantana, B. (2024). Classification of Roasting Level of Coffee Beans Using Convolutional Neural Network with MobileNet Architecture for Android Implementation. *Jurnal Teknik Pertanian Lampung (Journal of Agricultural Engineering)*, 13(3), 924. <https://doi.org/10.23960/jtep-l.v13i3.924-932>
- Rizky Pratama, M. H., Akrom, M., Santosa, A. P., Rosyid, M. R., & Mawaddah, L. (2025). Klasifikasi Otomatis Korosi Menggunakan Convolutional Neural Network dan Transfer Learning dengan Model MobileNetV2. *Jurnal Algoritma*, 22(1), 138–148. <https://doi.org/10.33364/algoritma/v.22-1.2182>
- Santoso, B. R., Sari, C. A., & Rachmawanto, E. H. (2025). Coffee Beans Classification Using Convolutional Neural Networks Based On Extraction Value Analysis In Grayscale Color Space. *Journal of Applied Informatics and Computing*, 9(1), 31–37. <https://doi.org/10.30871/jaic.v9i1.8916>
- Sarvina, Y., Juni, T., Sutjahjo, S. H., Nurmalina, R., & Surmaini, E. (2021). Why Should Climate Smart Agriculture Be Promoted IN The Indonesian Coffee Production System? *Journal of Sustainability Science And Management*, 16(7), 347–363. <https://doi.org/10.46754/jssm.2021.10.024>
- Septiarini, A., Hamdani, H., Ery Burhandeny, A., Nurcahyono, D., & Eka Priyatna, S. (2024). Image analysis for classifying coffee bean quality using a multi feature and machine learning approach. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 13(4), 4241. <https://doi.org/10.11591/ijai.v13.i4.pp4241-4248>
- Xu, Y., Li, D., Li, C., Yuan, Z., & Dai, Z. (2025). LiSA-MobileNetV2: an extremely lightweight deep learning model with Swish activation and attention mechanism for accurate rice disease classification. *Frontiers in Plant Science*, 16. <https://doi.org/10.3389/fpls.2025.1619365>
- Yong, L., Ma, L., Sun, D., & Du, L. (2023). Application of MobileNetV2 to waste classification. *PLoS ONE*, 18(3 March). <https://doi.org/10.1371/journal.pone.0282336>



TIN: Terapan Informatika Nusantara

Vol 6, No 7, December 2025, page 969-980

ISSN 2722-7987 (Media Online)

Website <https://ejournal.seminar-id.com/index.php/tin>

DOI 10.47065/tin.v6i7.8695

- Yu, F., Zhang, Q., Xiao, J., Ma, Y., Wang, M., Luan, R., Liu, X., Ping, Y., Nie, Y., Tao, Z., & Zhang, H. (2023). Progress in the Application of CNN-Based Image Classification and Recognition in Whole Crop Growth Cycles. *Remote Sensing*, *15*(12), 2988. <https://doi.org/10.3390/rs15122988>
- Zhao, X., Wang, L., Zhang, Y., Han, X., Deveci, M., & Parmar, M. (2024). A review of convolutional neural networks in computer vision. *Artificial Intelligence Review*, *57*(4). <https://doi.org/10.1007/s10462-024-10721-6>