

## Klasifikasi Citra Biji Kopi Temanggung Menggunakan Residual Network (ResNet-50)

Thimoty Pascal Munthe<sup>1</sup>, Mutaqin Akbar<sup>2</sup>

Informatika, Fakultas Teknologi Informasi, Universitas Mercu Buana Yogyakarta,

<sup>1</sup>thimotypascal986@gmail.com, <sup>2</sup>mutaqin@mercubuana-yogya.ac.id

### Abstract

*This article discusses the application of deep learning methods using the Residual Network (ResNet-50) architecture to classify three types of coffee beans from Temanggung, namely Arabica, Excelsa, and Robusta. The dataset used consists of 1,350 images, each class is balanced. The pre-processing stage includes resizing the image to 224x224 pixels, normalizing pixel values, and dividing the dataset into training, validation, and test data. Model training was carried out using the Adam algorithm with a learning rate of 0.0001, batch size 32, and 20 epochs. Model performance evaluation was carried out through a confusion matrix and classification metrics such as accuracy, precision, recall, and F1-score. The results showed that the ResNet-50 model was able to accurately classify coffee bean types, with an accuracy of 96% and a macro F1-score value that also reached 96%. This achievement shows that the visual features of coffee beans can be effectively recognized by the model. These findings prove that deep learning-based approaches, especially using ResNet-50, are effective in automatic coffee bean classification systems and have great potential to support the efficiency of agricultural product identification in the coffee industry sector.*

*Keywords: Deep Learning, ResNet-50, image classification, Temanggung coffee, CNN*

### Abstrak

Artikel ini membahas penerapan metode deep learning dengan menggunakan arsitektur Residual Network (ResNet-50) untuk mengklasifikasikan tiga jenis biji kopi dari Temanggung, yaitu Arabika, Excelsa, dan Robusta. Dataset yang digunakan terdiri dari 1.350 citra, masing-masing kelas berjumlah seimbang. Tahap pra-pemrosesan meliputi perubahan ukuran gambar menjadi 224x224 piksel, normalisasi nilai piksel, serta pembagian dataset menjadi data latih, validasi, dan uji. Pelatihan model dilakukan menggunakan algoritma Adam dengan learning rate 0.0001, batch size 32, dan 20 epoch. Evaluasi kinerja model dilakukan melalui confusion matrix serta metrik klasifikasi seperti akurasi, precision, recall, dan F1-score. Hasil penelitian menunjukkan bahwa model ResNet-50 mampu melakukan klasifikasi jenis biji kopi secara akurat, dengan akurasi sebesar 96% dan nilai macro F1-score yang juga mencapai 96%. Capaian ini menunjukkan bahwa fitur visual dari biji kopi dapat dikenali secara efektif oleh model. Temuan ini membuktikan bahwa pendekatan berbasis deep learning, khususnya menggunakan ResNet-50, efektif digunakan dalam sistem klasifikasi otomatis biji kopi dan berpotensi besar untuk mendukung efisiensi identifikasi produk pertanian di sektor industri kopi.

Kata Kunci : Deep Learning, ResNet-50, Klasifikasi Citra, Kopi Temanggung, CNN

© 2025 Author

Creative Commons Attribution 4.0 International License



## 1. Pendahuluan

Kopi merupakan salah satu komoditas pertanian unggulan di Indonesia yang memiliki nilai ekonomi tinggi baik di pasar dalam negeri maupun luar negeri. Berdasarkan data dari Badan Pusat Statistik (BPS) tahun 2023, produksi biji kopi Indonesia mencapai 758,7 ribu ton. Selain itu, luas lahan perkebunan kopi di Indonesia juga mengalami peningkatan, yakni bertambah 918 hektar dari 1.265,93 ribu hektar pada tahun 2022 menjadi 1.266,85 ribu hektar pada tahun 2023, atau naik sekitar 0,05 persen dibandingkan tahun sebelumnya.

Temanggung, merupakan kabupaten yang terletak di Jawa Tengah, Indonesia, dikenal sebagai salah satu daerah penghasil kopi unggulan di tanah air. Dengan latar belakang sejarah yang kuat, letak geografis yang ideal, serta cita rasa yang unik, kopi dari Temanggung menjadi kebanggaan bagi para pencinta kopi. Mayoritas petani di Kabupaten Temanggung masih memasarkan hasil panen kopinya dalam bentuk biji mentah. Komoditas tanaman perkebunan rakyat yang menonjol meliputi kopi arabika, kopi robusta, dan kopi excelsa. Perkebunan Kopi Temanggung memiliki luas tanah sekitar 14.500 hektare, yang dimana 12.000 hektare untuk kopi robusta dan sekitar 2.800 hektare untuk kopi arabika[1].

Biji kopi dapat diklasifikasikan berdasarkan karakteristik yang dimilikinya, di mana pengelompokan jenis kopi tersebut memiliki pengaruh yang signifikan terhadap cita rasa dan aroma yang dihasilkan saat proses pengolahan lanjutan. Kualitas biji kopi berperan signifikan dalam menentukan cita rasa dan nilai jual produk akhir, sehingga tahap klasifikasi biji kopi menjadi elemen krusial dalam rantai produksi. Klasifikasi merupakan proses pengelompokan objek ke dalam kategori tertentu berdasarkan ciri atau atribut yang dimiliki. Dalam konteks ini, klasifikasi biji kopi bertujuan untuk mengidentifikasi serta membedakan mutu dan jenis kopi berdasarkan karakteristik visual seperti warna, ukuran, dan tekstur permukaannya.

Mengetahui jenis biji kopi merupakan aspek yang krusial. Namun demikian, tidak semua petani atau pemilik kedai kopi memiliki keterampilan untuk mengenalinya hanya berdasarkan pengamatan visual secara langsung. Hal itu dibahas dalam Penelitian yang dilakukan oleh Nugroho dan Sebatubun berjudul “*Klasifikasi Varietas Kopi Berdasarkan Green Bean Coffee Menggunakan Metode Machine Learning*” menunjukkan bahwa setiap varietas kopi memiliki nilai jual yang berbeda-beda. Namun, masih banyak petani dan pemilik kedai kopi yang kesulitan dalam mengidentifikasi varietas kopi hanya melalui pengamatan visual terhadap biji kopi hijau, yang pada akhirnya dapat menimbulkan kesalahan dalam proses klasifikasi jenis kopi[2]. Dalam studi yang dilakukan oleh Hafifah et al. berjudul “*Perbandingan Kinerja Deep Learning dalam Pendeteksian Kerusakan Biji*

*Kopi*”, diungkapkan bahwa metode pemilahan biji kopi yang mengandalkan pengamatan visual berisiko menimbulkan ketidakakuratan. Risiko tersebut muncul akibat faktor-faktor seperti pencahayaan yang tidak konsisten serta perbedaan tingkat ketajaman penglihatan masing-masing individu. Maka dari itu diperlukan sistem yang baik untuk menganalisis dari jenis biji kopi dengan akurat[3].

Dengan berkembangnya teknologi telah membuka peluang bagi mesin untuk mengambil alih berbagai tugas, termasuk klasifikasi citra dengan menggunakan sistem berbasis kecerdasan buatan. Machine Learning dan Deep Learning, yang merupakan bagian dari artificial intelligence, memberikan kemampuan bagi sistem untuk belajar secara otomatis dan mengambil keputusan tanpa perlu pemrograman yang berulang. Klasifikasi citra bertujuan untuk mengidentifikasi dan mengelompokkan gambar ke dalam kelas tertentu dengan memanfaatkan fitur visual seperti warna, tekstur, bentuk, dan pola. Proses ini memungkinkan identifikasi objek dalam citra dilakukan secara otomatis, lebih tepat, dan efisien, serta dapat diterapkan dalam berbagai sektor seperti pertanian, medis, industri, hingga sistem keamanan[4].

Berbagai algoritma telah diterapkan dalam proses klasifikasi citra, salah satunya adalah Support Vector Machine (SVM), yang merupakan metode klasifikasi linear berbasis fungsi kernel dan teori optimisasi. SVM berfungsi untuk menemukan hyperplane optimal yang mampu memisahkan data berdasarkan kelas yang berbeda.[5]. SVM memaksimalkan margin antara hyperplane dan support vector[6]. Walaupun SVM dirancang untuk menentukan hyperplane paling optimal dalam memisahkan data menjadi dua kelas, algoritma ini cenderung kurang efektif ketika digunakan pada masalah klasifikasi dengan struktur kelas yang lebih kompleks.[7]. Penerapan algoritma yang lainnya seperti KNN yang juga dapat dilakukan untuk citra, terdapat dalam “Perbandingan Kinerja Algoritma Naives Bayes dan K-Nearest Neighbor (KNN) untuk prediksi harga rumah oleh Vania Ariyani Prilia Putri, Agung Budi Prasetyo, Dania Eridani yang menjelaskan bahwa KNN termasuk dalam kategori pembelajaran berbasis instance (instance-based learning) dan digolongkan sebagai teknik lazy learning[8]. Proses algoritma ini dilakukan dengan mencari k data pelatihan yang paling mirip dengan data uji atau data baru. Oleh karena itu, diperlukan sebuah sistem klasifikasi yang mampu menemukan informasi tersebut[9]. Salah satu keunggulan algoritma KNN adalah kemampuannya dalam menangani data latih yang mengandung noise serta kinerjanya yang tetap efisien ketika diterapkan pada dataset berukuran besar[10]. Namun, keharusan untuk menetapkan berbagai parameter dalam KNN menjadi kelemahan dari algoritma ini, karena hal tersebut dapat menambah kompleksitas dan kebingungannya dalam menemukan parameter yang

paling sesuai untuk sistem[11]. SVM dan KNN merupakan algoritma machine learning, namun deep learning kini dianggap lebih unggul karena mampu mengolah data dalam jumlah besar.

Deep Learning (DL) yang memiliki kemampuan luar biasa dalam mengenali pola dan melakukan analisis terhadap data berukuran besar dan kompleks. Kemudian performa deep learning sangat bergantung pada kualitas data pelatihan. Data yang bias atau bising dapat menghasilkan model yang tidak akurat. Berbagai sistem kini tersedia untuk membantu identifikasi jenis kopi, salah satunya menggunakan Convolutional Neural Network (CNN)[12]. CNN memiliki beragam arsitektur seperti LeNet[13], AlexNet[14], ResNet[15], GoogleNet[16], dan SqueezeNet[17] yang terus berkembang. Setiap arsitektur memiliki keunikan dalam proses komputasi dan tingkat akurasi. Contohnya ResNet (Residual Network) adalah salah satu arsitektur dalam CNN yang dibuat untuk mempermudah proses pelatihan jaringan saraf berlapis-lapis, dengan menerapkan konsep *residual learning* melalui penambahan jalur pintas (*shortcut connection*) yang melewati beberapa layer pada jaringan. Dengan kata lain, ResNet mempercepat dan mempermudah proses pelatihan jaringan melalui konsep shortcut connection. Persamaan  $y=F(x)+x$  menggambarkan koneksi ini, di mana output dari blok sebelumnya langsung ditambahkan ke output blok berikutnya. Fungsi residual  $F(x)$  dalam ResNet terdiri dari dua lapisan konvolusi, batch normalization, dan aktivasi ReLU[18].

Penelitian berjudul "*Implementasi Convolutional Neural Network dalam Klasifikasi Jenis Kopi Temanggung*" oleh Putri Adella Maharani dan Mutaqin Akbar memanfaatkan sebanyak 1.350 citra, masing-masing terdiri dari 450 gambar untuk setiap jenis biji kopi. Penelitian ini menerapkan metode Convolutional Neural Network (CNN) dan berhasil memperoleh akurasi sebesar 99,26% dengan ukuran citra input sebesar 50x50x3. Selain itu, hasil penelitian menunjukkan bahwa memperbesar ukuran citra input tidak memberikan peningkatan akurasi yang signifikan dalam proses pelatihan klasifikasi biji kopi Temanggung menggunakan CNN.[19].

A. A. Hibatullah, Asriyanik, dan W. Apriandari melakukan penelitian berjudul "*Klasifikasi Kualitas Jenis Kopi Halus Robusta Menggunakan Convolutional Neural Network (CNN) dan MobileNet-V2*". Dalam penelitian ini terdapat 2,268 citra kopi halus dengan 3 kualitas yang diklasifikasi dengan mobilenet-v2. Metode yang digunakan dalam penelitian ini adalah *Convolutional Neural Network* (CNN). Hasil dari penelitian ini dengan akurasi validasi sebesar 99,82%, *recall score* sebesar 0,9982 *precision* 0,9982 dan *F1 Score* 0,99[20].

Berikutnya Murinto, M. Rosyda, dan M. Melany dalam penelitian yang berjudul "*Klasifikasi Jenis Biji*

*Kopi Menggunakan Convolutional Neural Network dan Transfer Learning pada Model VGG16 dan GLCM 47e954*". Dalam penelitian ini terdapat 1600 citra biji kopi, penelitian ini mempunyai 3 model yang diujikan CNN transfer learning, VGG16 dan juga GLCM 47e954, metode yang digunakan dalam penelitian ini yaitu Convolutional Neural Network, setelah melakukan klasifikasi terdapat hasil bahwa akurasi yang paling tinggi didapatkan 96% menggunakan CNN-transfer learning model GLCM 47e954 [21].

Suprihanto et al. dalam penelitiannya yang berjudul "*Analisis Kinerja ResNet-50 Dalam Klasifikasi Penyakit Pada Daun Kopi Robusta*" memfokuskan studi pada dua skenario klasifikasi, yaitu *binary class* dan *multiclass*. Pada kasus *binary class*, model berhasil mencapai akurasi sebesar 92,68% dan F1-score sebesar 92,88%. Sementara itu, untuk kasus *multiclass*, akurasi yang diperoleh adalah 88,98% dengan F1-score sebesar 88,84%. [22].

Penelitian berjudul "*Penerapan Metode Residual Network (ResNet) dalam Klasifikasi Penyakit pada Daun Gandum*". Penelitian ini mempunyai 407 dataset berupa gambar, dengan ResNet tidak memerlukan untuk melatih data dari awal maka dari itu dapat mempersingkat waktu. Hasil dari penelitian didapatkan 98% akurasi dengan perbandingan data latih sebesar 90:10 dan nilai confusion matrix sebesar 0.35, sehingga dapat disimpulkan bahwa ResNet dapat mengidentifikasi penyakit pada daun gandum[23].

Merujuk pada permasalahan dan latar belakang yang telah dipaparkan, penelitian ini bertujuan untuk melakukan klasifikasi terhadap tiga varietas biji kopi asal Temanggung yakni arabika, excelsa, dan robusta dengan menggunakan metode Convolutional Neural Network (CNN) berbasis arsitektur ResNet. Penelitian ini bertujuan untuk menilai performa klasifikasi serta akurasi yang dicapai dalam membedakan ketiga jenis biji kopi tersebut melalui pendekatan ResNet.

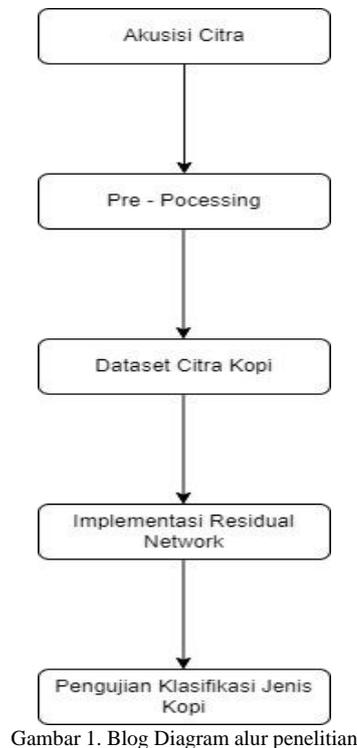
## 2. Metode Penelitian

Proses klasifikasi terhadap tiga jenis biji kopi Temanggung menggunakan Residual Network (ResNet) melibatkan beberapa tahapan. Alur penelitian tersebut dapat dilihat pada blok diagram yang disajikan pada Gambar 1.

### 2.1 Akuisisi

Dataset yang digunakan dalam penelitian ini merupakan dataset sekunder yang digunakan pada penelitian [19]. Dataset ini mencakup tiga kategori utama biji kopi, yaitu Arabika, Excelsa, dan Robusta, dengan jumlah citra 1,350 dengan 450 setiap kelasnya, dengan citra yang memadai serta variasi dalam sudut pengambilan gambar dan kondisi

pencapaian, sehingga dapat merepresentasikan karakteristik visual dari masing-masing jenis kopi.



Gambar 1. Blog Diagram alur penelitian

## 2.2 Pre-processing

Pre-processing dilakukan setelah seluruh citra berhasil dikumpulkan. Karena setiap gambar biji kopi memiliki resolusi asli 2992x2992 piksel dengan ukuran file sekitar 2,5 MB, maka dilakukan pengecilan ukuran (resize) untuk mempercepat proses pelatihan model selanjutnya. Proses resize dilakukan menggunakan Google Colaboratory, menghasilkan citra berukuran 224x224 piksel dengan ukuran file sekitar 250 KB per gambar. Semua citra yang diresize disesuaikan dengan ukuran input yang dibutuhkan oleh model ResNet.

## 2.3 Dataset Citra Kopi

Dataset citra kopi Temanggung terdiri dari tiga jenis biji kopi, yaitu arabika, excelsa, dan robusta, dengan total 1.350 citra, masing-masing sebanyak 450 citra per jenis. Setelah proses resize, data dibagi menjadi dua bagian, yaitu data latih dan data uji, dengan perbandingan 70:15, dimana 70% digunakan untuk pelatihan dan 15% untuk pengujian.

## 2.4 Residual Network (ResNet-50)

Residual Network (ResNet) merupakan arsitektur deep learning yang dirancang untuk mengatasi masalah degradasi performa pada jaringan yang semakin dalam. ResNet memperkenalkan konsep residual learning melalui shortcut connection yang

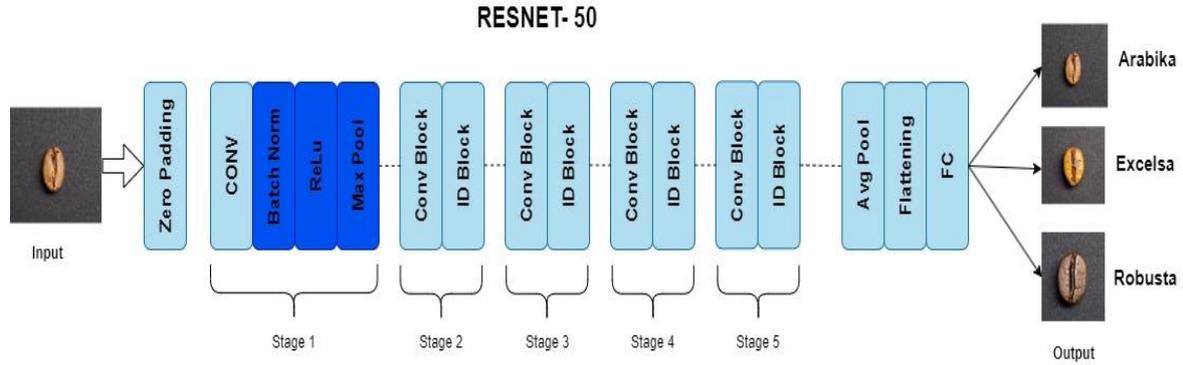
melewati satu atau lebih layer. Ini memungkinkan jaringan melatih lapisan yang sangat dalam tanpa kehilangan performa karena vanishing gradient.

Dalam penelitian ini, digunakan arsitektur ResNet-50, yaitu versi lebih dalam dari ResNet dengan 50 layer. ResNet-50 menggunakan kombinasi bottleneck blocks yang lebih efisien dalam hal komputasi namun tetap menjaga akurasi tinggi. Struktur dan komponen dari ResNet-50 yaitu setiap blok residual, terdapat beberapa lapisan konvolusi yang disusun secara bertingkat, dengan pola bottleneck yang umumnya terdiri dari filter berukuran 1x1, 3x3, dan 1x1 untuk meningkatkan efisiensi pemrosesan. Di bagian akhir jaringan, diterapkan teknik global average pooling untuk merangkum informasi fitur yang telah diekstraksi sebelum dikirim ke lapisan fully connected sebagai output klasifikasi. Desain ini terbukti mampu bekerja secara optimal dalam berbagai aplikasi pengenalan citra karena kemampuannya mengeksplorasi fitur secara mendalam tanpa mengganggu stabilitas proses pelatihan.

Dalam penerapan arsitektur ResNet-50 pada program klasifikasi citra biji kopi, beberapa hyperparameter utama diatur secara bawaan oleh pustaka torchvision.models. Pada lapisan pertama, Conv1, digunakan filter dengan ukuran 7x7 dan jumlah filter sebanyak 64, serta stride 2 yang menghasilkan output berukuran 112x112 piksel. Selanjutnya, dilakukan proses max pooling dengan kernel berukuran 3x3, stride 2, dan padding 1, sehingga menghasilkan peta fitur dengan ukuran 56x56 piksel tanpa mengubah jumlah channel yang tetap 64.

Arsitektur ini terdiri dari empat blok residual utama yaitu Layer1, Layer2, Layer3, dan Layer4, yang masing-masing dibangun menggunakan bottleneck block dengan tiga lapisan konvolusi: 1x1, 3x3, dan 1x1. Secara detail, Layer1 menghasilkan output dengan ukuran 56x56 dan 256 channel, Layer2 menghasilkan output 28x28 dengan 512 channel, Layer3 memberikan output 14x14 dengan 1024 channel, dan Layer4 menghasilkan output 7x7 dengan 2048 channel. Pada setiap blok tersebut, filter konvolusi berukuran 1x1 digunakan untuk mengurangi dimensi, filter 3x3 untuk menangkap fitur spasial, dan filter 1x1 kembali untuk memperluas jumlah channel.

Setelah melewati blok residual terakhir, dilakukan average pooling global dengan ukuran kernel 7x7 yang mengubah seluruh dimensi spasial menjadi ukuran 1x1 dengan 2048 channel. Hasil pooling ini kemudian masuk ke layer fully connected (FC) yang menghasilkan output sejumlah neuron sesuai dengan jumlah kelas yang ingin diklasifikasikan, yaitu 3 jenis biji kopi temanggung.



Gambar 2. Arsitektur ResNet – 50

Dalam proses pelatihan, model diatur dengan learning rate sebesar 0.0001 dan batch size sebanyak 32, serta menggunakan optimizer Adam. Pelatihan dilakukan selama sejumlah epoch 20. Untuk mengukur performa model, digunakan fungsi loss CrossEntropyLoss yang cocok untuk klasifikasi multi-kelas.

## 2.5 Pengujian Klasifikasi

Setelah proses pelatihan dan pengujian model menggunakan ResNet-50 selesai dilakukan, langkah berikutnya adalah menghitung *confusion matrix*. Confusion matrix merupakan alat ukur performa model klasifikasi dalam machine learning, baik untuk dua kelas maupun lebih. Terdapat empat komponen utama yang menggambarkan hasil klasifikasi, yaitu *true positive*, *true negative*, *false positive*, dan *false negative*. Setelah memperoleh hasil klasifikasi dari confusion matrix, tahap selanjutnya adalah mengevaluasi performa model dengan menghitung sejumlah metrik evaluasi seperti akurasi, presisi, *recall*, *specificity*, dan *F1-Score*, yang umum digunakan dalam klasifikasi biner.

$$Accuracy = \frac{TP+TN}{TP+TN+FN+FP} * 100\% \quad (1)$$

$$Precision = \frac{TP}{TP+FP} * 100\% \quad (2)$$

$$Recall = \frac{TP}{TP+FN} * 100\% \quad (3)$$

$$Specificity = \frac{TN}{TN+TP} * 100\% \quad (4)$$

$$F1 - Score = \frac{2*(Recall * Precision)}{(Recall+Precision)} * 100\% \quad (5)$$

Keterangan:

TP: *True Positive*

TN: *True Negative*

FP: *False Positive*

FN: *False Negative*

Dalam evaluasi performa pada kasus klasifikasi multikelas, *specificity* tidak menjadi fokus utama. Sebaliknya, untuk menghitung *precision*, *recall*, dan *F1-score*, digunakan pendekatan *macro average*, yaitu dengan mengambil rata-rata nilai metrik dari setiap kelas dan membaginya berdasarkan jumlah total kelas. Sementara itu, rumus akurasi dan rata-rata metrik kinerja lainnya dapat dilihat pada rumus berikut ini.

$$MAP = \frac{\sum_{k=1}^K Precision_k}{K} * 100\% \quad (7)$$

$$MAR = \frac{\sum_{k=1}^K Recall_k}{K} * 100\% \quad (8)$$

$$MAP = \frac{\sum_{k=1}^K F1Score_k}{K} * 100\% \quad (9)$$

Keterangan:

MAP: *Macro Average Precision*

MAR: *Macro Average Recall*

MAF: *Macro Average F1-Score*

K: Jumlah kelas pada sistem klasifikasi *multiclass*

## 3. Hasil dan Pembahasan

### 3.1 Hasil Penelitian

Dalam penelitian ini, digunakan metode klasifikasi citra menggunakan pendekatan deep learning dengan memanfaatkan arsitektur ResNet-50 (Residual Network 50). ResNet-50 adalah salah satu jenis jaringan ResNet yang memiliki 50 lapisan dan dikenal efektif dalam mengatasi permasalahan penurunan akurasi pada jaringan yang sangat dalam. Model ini dilatih untuk mengelompokkan citra biji kopi temanggung ke dalam beberapa kelas sesuai dengan jenisnya.

Pada saat pembuatan sistem data ini membutuhkan 3 jenis biji kopi temanggung lalu dilakukan klasifikasi dengan menggunakan Residual Network (ResNet-50). Agar program sistem ini dapat bekerja dalam menentukan sebuah tingkat akurasi yang tinggi dibutuhkan menyiapkan sebuah dataset yang terdiri

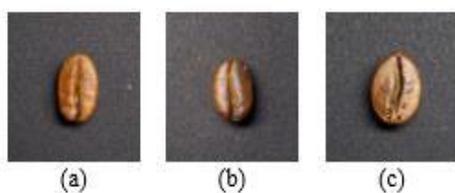
dari 3 jenis biji kopi temanggung yaitu Robusta, Excelsa, Arabika yang mempunyai citra yang baik tentunya, lalu melalui tahapan preprocessing seperti resize, normalisasi piksel, dan augmentasi data.

Output dari sistem ini berupa hasil klasifikasi dari setiap gambar uji, yang ditunjukkan dalam bentuk nilai probabilitas untuk masing-masing kelas serta label prediksi akhir. Selain itu, dilakukan juga evaluasi performa model menggunakan metrik-metrik seperti akurasi, precision, recall, dan confusion matrix untuk melihat seberapa baik model mengenali masing-masing jenis kopi.

Secara keseluruhan, hasil yang diperoleh menunjukkan bahwa model mampu mengklasifikasikan citra biji kopi dengan tingkat akurasi yang tinggi. Hal ini menandakan bahwa fitur visual dari masing-masing jenis biji kopi dapat dikenali secara efektif oleh model, sehingga pendekatan deep learning berbasis ResNet-50 dapat dijadikan solusi yang andal dalam proses identifikasi jenis biji kopi secara otomatis.

### 3.1.1 Hasil Akuisisi

Tahap awal yang dilakukan adalah mengumpulkan citra dari tiga varietas biji kopi Temanggung dengan tingkat pangangan alami. Pemotretan dilakukan dengan latar belakang hitam agar fokus tertuju pada objek serta warna dan tekstur biji kopi terlihat lebih jelas. Pengambilan gambar menggunakan kamera smartphone Samsung A12 menghasilkan citra berukuran 2992x2992 piksel dengan ukuran file sekitar 2,5 MB per citra. Contoh citra jenis kopi Temanggung dapat dilihat pada Gambar 3 berikut ini.



Gambar 3. Jenis biji kopi a. arabika b. excelsa c. robusta

### 3.1.2 Hasil Pre-Processing

Pada tahap preprocessing, dilakukan berbagai transformasi terhadap citra biji kopi agar sesuai dengan format input yang dibutuhkan oleh model ResNet-50. Transformasi ini meliputi perubahan ukuran gambar, konversi menjadi tensor, serta normalisasi nilai piksel berdasarkan mean dan standar deviasi yang digunakan pada model ResNet yang telah dilatih sebelumnya.

Langkah pertama yang dilakukan adalah mengubah seluruh gambar menjadi berukuran 224x224 piksel dengan memanfaatkan `transforms.Resize`. Ukuran ini dipilih karena merupakan dimensi input default pada arsitektur ResNet-50. Setelah itu, gambar dikonversi

menjadi tensor menggunakan `transforms.ToTensor()`, yang secara otomatis mengubah skala piksel dari 0–255 menjadi 0–1. Proses `resize` dilakukan secara otomatis melalui pipeline transformasi PyTorch. Gambar asli tidak diubah secara permanen, namun saat dimuat oleh `DataLoader`, gambar langsung diubah ukurannya menjadi 224x224 piksel sebelum masuk ke model.

Kemudian, gambar dinormalisasi menggunakan nilai mean [0.485, 0.456, 0.406] dan standar deviasi [0.229, 0.224, 0.225], yang merupakan nilai referensi dari dataset ImageNet. Normalisasi ini dilakukan agar distribusi data input sesuai dengan karakteristik data yang digunakan saat model ResNet-50 dilatih pertama kali, sehingga diharapkan dapat meningkatkan efektivitas dan performa model selama proses pelatihan.

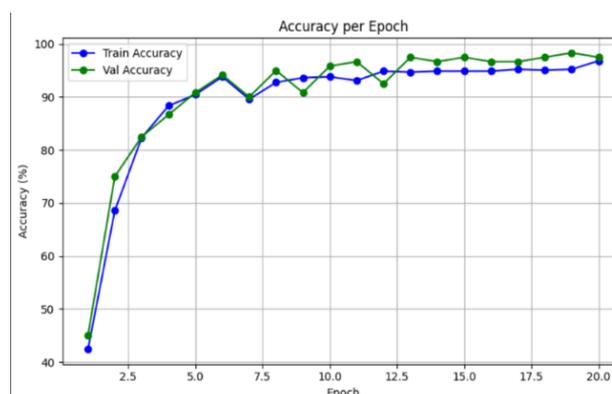
Setelah proses transformasi dilakukan, dataset kemudian dibagi menjadi tiga bagian utama, yaitu: Data latih (training set) sebesar 70% digunakan untuk melatih model. Data validasi (validation set) sebesar 15% digunakan untuk mengevaluasi performa model selama pelatihan. Data uji (test set) sebesar 15% digunakan untuk menguji performa akhir model setelah proses pelatihan selesai. Pembagian ini dilakukan secara terpisah dalam tiga direktori berbeda (train, val, dan test) untuk mempermudah pengelolaan dan pemanggilan dataset menggunakan `ImageFolder` pada library PyTorch.

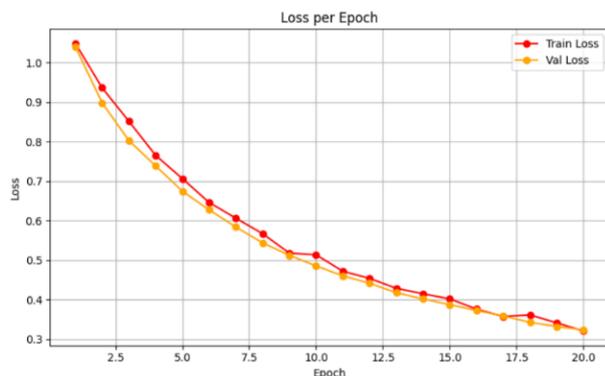
Dengan melakukan preprocessing ini, citra biji kopi yang semula memiliki ukuran dan distribusi warna yang tidak seragam menjadi lebih terstandarisasi dan siap digunakan dalam proses pelatihan model klasifikasi berbasis Convolutional Neural Network (CNN), khususnya ResNet-50.

## 3.2 Analisis dan Pembahasan

### 3.2.1 Analisis Akurasi dan Loss

Pada proses pelatihan model klasifikasi biji kopi menggunakan arsitektur ResNet-50, dilakukan pelatihan selama sejumlah epoch dengan memantau dua metrik utama yaitu akurasi dan loss untuk data training dan validation. Grafik hasil pelatihan ditampilkan pada Gambar 4.

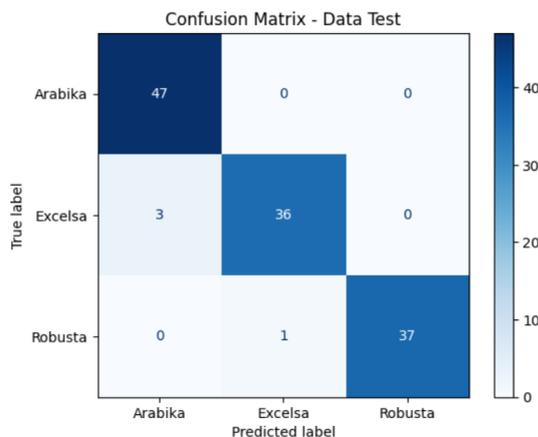




Gambar 4. Grafik Akurasi dan Loss pada Training dan Validasi

Berdasarkan grafik pada Gambar 4, dapat dilihat bahwa akurasi training meningkat secara konsisten seiring bertambahnya jumlah epoch, dan mencapai nilai mendekati 100% pada akhir pelatihan. Sementara itu, akurasi pada data validation juga menunjukkan tren peningkatan. Hal ini juga didukung oleh grafik loss di mana loss pada data training terus menurun, sedangkan loss pada data validation penurunan juga sehingga tidak overfitting setelah beberapa epoch.

### 3.2.2 Confusion Matrix



Gambar 5. Confusion Matrix

Gambar 5 menyajikan confusion matrix yang dihasilkan dari pengujian model klasifikasi citra biji kopi, yang terdiri atas tiga kategori utama, yaitu Arabika, Excelsa, dan Robusta. Berdasarkan matriks tersebut, dapat diketahui bahwa model menunjukkan performa klasifikasi yang sangat baik. Untuk kelas Arabika, seluruh 47 citra berhasil diklasifikasikan dengan benar tanpa adanya kesalahan prediksi. Pada kelas Excelsa, sebanyak 36 citra berhasil dikenali dengan benar, sementara 3 citra lainnya mengalami misklasifikasi sebagai Arabika. Adapun untuk kelas Robusta, model mampu mengklasifikasikan 37 citra secara tepat, dengan hanya 1 citra yang keliru diprediksi sebagai Excelsa.

Secara keseluruhan, model menunjukkan tingkat akurasi yang tinggi dalam mengklasifikasikan ketiga jenis biji kopi. Jumlah kesalahan klasifikasi yang terjadi tergolong rendah, yang mengindikasikan bahwa fitur visual yang diolah oleh model, seperti warna, tekstur, dan bentuk biji kopi, telah cukup efektif dalam membedakan antar kelas. Oleh karena itu, confusion matrix ini memperkuat bukti bahwa arsitektur ResNet-50 yang digunakan mampu mempelajari dan mengenali pola visual pada data uji dengan baik.

### 3.2.3 Pengujian

Selain menggunakan akurasi dan confusion matrix, evaluasi performa model klasifikasi biji kopi juga dilakukan dengan metrik tambahan, yaitu Precision, Recall, dan F1-Score. Ketiga metrik ini memberikan gambaran yang lebih menyeluruh terhadap kemampuan model dalam mengklasifikasikan setiap kelas secara individual, khususnya pada permasalahan data yang tidak seimbang.

Tabel 1. Tabel Precision, Recall, F1-Score

Kelas	Precision	Recall	F1_score
Arabika	0.94	1.00	0.97
Excelsa	0.97	0.92	0.95
Robusta	1.00	0.97	0.99

Penelitian ini menunjukkan keterkaitan dengan penelitian yang dilakukan oleh [19]. Kedua penelitian sama-sama difokuskan pada proses klasifikasi citra biji kopi Temanggung ke dalam tiga kelas utama, yaitu Arabika, Excelsa, dan Robusta, dengan menggunakan pendekatan teknologi deep learning. Walaupun memiliki kesamaan dalam hal objek dan tujuan, terdapat perbedaan penting dalam hal metode yang diterapkan, pengaturan parameter saat pelatihan model, struktur arsitektur jaringan yang digunakan, serta pendekatan evaluasi performa model yang dihasilkan. Penelitian [19] menggunakan arsitektur CNN standar dengan 12 lapisan yang dibangun manual. Sementara itu, penelitian ini memakai ResNet-50, model CNN yang lebih dalam dan canggih dengan 50 lapisan serta shortcut connection untuk mengatasi vanishing gradient. Selain itu, ResNet-50 mendukung transfer learning, sehingga pelatihan lebih cepat dan akurasi meningkat.

Dalam aspek data dan tahap pre-processing, kedua penelitian memanfaatkan dataset yang identik, yakni sebanyak 1.350 citra biji kopi Temanggung dengan jumlah yang merata untuk setiap kelas. Meskipun demikian, terdapat perbedaan dalam penentuan ukuran citra yang dijadikan input. Penelitian yang dilakukan oleh Putri Adella Maharani menguji tiga variasi resolusi citra, yaitu 50x50x3, 100x100x3, dan 150x150x3, dengan hasil optimal diperoleh pada ukuran terkecil, yakni 50x50 piksel. Sementara itu, penelitian ini secara konsisten menggunakan ukuran

citra sebesar 224x224 piksel, yang merupakan ukuran baku dalam pengolahan citra pada arsitektur ResNet.

Perbedaan mencolok terlihat pada parameter pelatihan dan hasil yang diperoleh. Penelitian Putri Adella Maharani menggunakan optimizer SGDM dengan 20 epoch dan learning rate 0,01, sedangkan penelitian ini menggunakan optimizer Adam dengan learning rate 0,0001 dan jumlah epoch yang sama. Penelitian Putri mencapai akurasi pelatihan tertinggi sebesar 99,26%, sementara penelitian ini memperoleh akurasi dan F1-score sebesar 96%. Meskipun CNN memiliki akurasi yang lebih tinggi, ResNet-50 memberikan evaluasi yang lebih menyeluruh serta memiliki kemampuan generalisasi yang lebih baik terhadap data pengujian.

Oleh karena itu, dapat disimpulkan bahwa meskipun kedua studi memiliki tujuan yang sejalan, perbedaan dalam pendekatan teknis menghasilkan keunggulan masing-masing. Penelitian yang dilakukan oleh Putri Adella Maharani membuktikan bahwa CNN sederhana dapat bekerja secara efektif dalam lingkungan eksperimental yang terkontrol dengan input citra beresolusi rendah. Sementara itu, penelitian ini menyoroti kelebihan penggunaan arsitektur ResNet-50 dalam melakukan klasifikasi citra berdasarkan ekstraksi fitur visual yang lebih kompleks, serta memberikan evaluasi performa model yang lebih lengkap dan mendalam.

#### 4. Kesimpulan

Penelitian ini berhasil menerapkan metode *deep learning* dengan menggunakan arsitektur Residual Network (ResNet-50) untuk melakukan klasifikasi terhadap tiga jenis biji kopi asal Temanggung, yaitu Arabika, Excelsa, dan Robusta. Dengan memanfaatkan total 1.350 citra yang telah melewati tahap *pre-processing* dan pelatihan model, sistem yang dikembangkan mampu mencapai akurasi sebesar 96% serta skor F1 makro sebesar 96%. Capaian ini mengindikasikan bahwa model memiliki kinerja yang sangat baik dalam membedakan ketiga varietas kopi berdasarkan karakteristik visualnya. Hasil evaluasi menggunakan *confusion matrix* juga menunjukkan tingkat kesalahan klasifikasi yang sangat rendah, yang menandakan kemampuan ResNet-50 dalam mengenali pola visual secara akurat dan konsisten. Secara keseluruhan, pendekatan ini terbukti efektif dan efisien sebagai solusi otomatis dalam mengidentifikasi jenis biji kopi, yang berpotensi besar untuk diterapkan dalam sektor pertanian dan industri kopi. Namun demikian, akurasi yang diperoleh dalam penelitian ini masih belum melampaui hasil dari penelitian sebelumnya yang mencatat akurasi sebesar 99,26%.

#### Daftar Rujukan

[1] A. S. Arifin and M. Millaty, "Mimbar Agribisnis : Jurnal Pemikiran Masyarakat Ilmiah Berwawasan Agribisnis

Analisis Faktor-faktor yang Memengaruhi Produksi Kopi Robusta ( *Coffea canephora* ) di Kecamatan Kandungan Kabupaten Temanggung Analysis of Factors that Influence the Production o," vol. 10, pp. 2501–2510, 2024.

- [2] M. A. Nugroho and M. M. Sebatubun, "Klasifikasi Varietas Kopi Berdasarkan Green Bean Coffee Menggunakan Metode Machine Learning," *Journal of Information System Management (JOISM)*, vol. 1, no. 2, pp. 1–5, 2020, doi: 10.24076/joism.2020v1i2.24.
- [3] Y. Hafifah, K. Mughtar, A. Ahmadiar, and S. Esabella, "Perbandingan Kinerja Deep Learning Dalam Pendeteksian Kerusakan Biji Kopi," *JURIKOM (Jurnal Riset Komputer)*, vol. 9, no. 6, p. 1928, 2022, doi: 10.30865/jurikom.v9i6.5151.
- [4] N. Putri *et al.*, "IMPLEMENTASI OBJECT DETECTION UNTUK DETEKSI," vol. 06, no. 01, pp. 215–223, 2025.
- [5] L. Rofiqi and M. Akbar, "Analisis Sentimen Terkait RUU Perampasan Aset dengan Support Vector Machine," *JKN*, vol. 4, no. 3, pp. 529–538, Aug. 2024, doi: 10.58794/jekin.v4i3.824.
- [6] D. MARGARITA, "Klasifikasi Penyakit Daun Padi Menggunakan Support Vector Machine Berdasarkan Fitur Mendalam (Deep Feature)," vol. 9, no. 4, pp. 1–21, 2024.
- [7] R. I. Borman, I. Ahmad, and Y. Rahmanto, "Klasifikasi Citra Tanaman Perdu Liar Berkhasiat Obat Menggunakan Jaringan Syaraf Tiruan Radial Basis Function," *Bulletin of Informatics and Data Science*, vol. 1, no. 1, p. 6, 2022, doi: 10.61944/bids.v1i1.3.
- [8] V. Ariyani, P. Putri, A. B. Prasetijo, and D. Eridani, "Perbandingan Kinerja Algoritme Naïve Bayes Dan K-Nearest Neighbor (Knn) Untuk Prediksi Harga Rumah," *Jurnal Ilmiah Teknik Elektro*, vol. 24, no. 2, pp. 162–171, 2022.
- [9] Hasran, "Klasifikasi Penyakit Jantung Menggunakan Metode K-Nearest Neighbor," *Indonesia Journal of Data and Science*, vol. 1, no. 1, pp. 6–10, 2020.
- [10] R. E. Pawening, W. J. Shudiq, and W. Wahyuni, "KLASIFIKASI KUALITAS JERUK LOKAL BERDASARKAN TEKSTUR DAN BENTUK MENGGUNAKAN METODE k-NEAREST NEIGHBOR (k-NN)," *COREAI: Jurnal Kecerdasan Buatan, Komputasi dan Teknologi Informasi*, vol. 1, no. 1, pp. 10–17, 2020, doi: 10.33650/coreai.v1i1.1640.
- [11] S. A. Suryaman, R. Magdalena, and S. Sa'adah, "Klasifikasi Cuaca Menggunakan Metode VGG-16, Principal Component Analysis Dan K-Nearest Neighbor," *Jurnal Ilmu Komputer dan Informatika*, vol. 1, no. 1, pp. 1–8, 2021, doi: 10.54082/jiki.1.
- [12] M. Akbar, A. S. Purnomo, and S. Supatman, "Multi-Scale Convolutional Networks untuk Pengenalan Rambu Lalu Lintas di Indonesia," *SISFOKOM*, vol. 11, no. 3, pp. 310–315, Dec. 2022, doi: 10.32736/sisfokom.v11i3.1452.
- [13] Y. LeCun *et al.*, "Backpropagation Applied to Handwritten Zip Code Recognition," *Neural Computation*, vol. 1, no. 4, pp. 541–551, Dec. 1989, doi: 10.1162/neco.1989.1.4.541.
- [14] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Commun. ACM*, vol. 60, no. 6, pp. 84–90, May 2017, doi: 10.1145/3065386.
- [15] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," 2015, *arXiv*. doi: 10.48550/ARXIV.1512.03385.
- [16] C. Szegedy *et al.*, "Going Deeper with Convolutions," 2014, *arXiv*. doi: 10.48550/ARXIV.1409.4842.

- [17] F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size," Nov. 04, 2016, *arXiv*: arXiv:1602.07360. doi: 10.48550/arXiv.1602.07360.
- [18] M. Kevin Santosa, M. Hanindia Prami Swari, and A. Nugroho Sihananto, "Implementasi Arsitektur Alexnet Dan Resnet34 Pada Klasifikasi Citra Penyakit Daun Kentang Menggunakan Transfer Learning," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 5, pp. 3293–3301, 2024, doi: 10.36040/jati.v7i5.7337.
- [19] P. Adella Maharani and M. Akbar, "Implementasi Convolutional Neural Network Dalam Klasifikasi Jenis Kopi Temanggung," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 3, pp. 3030–3037, 2024, doi: 10.36040/jati.v8i3.9582.
- [20] A. A. Hibatullah and W. Apriandari, "KLASIFIKASI KUALITAS JENIS KOPI HALUS ROBUSTA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK ( CNN ) DAN MOBILENET-V2," vol. 8, no. 5, pp. 8650–8657, 2024.
- [21] N. Dan, T. Learning, P. Model, and V. G. G. Dan, "SENASTIKA Universitas Malikussaleh," pp. 1–11.
- [22] S. Suprihanto, I. Awaludin, M. Fadhil, and M. A. Z. Zulfikor, "Analisis Kinerja ResNet-50 dalam Klasifikasi Penyakit pada Daun Kopi Robusta," *Jurnal Informatika*, vol. 9, no. 2, pp. 116–122, 2022, doi: 10.31294/inf.v9i1.13049.
- [23] A. Ridhovan and A. Suharso, "Penerapan Metode Residual Network (Resnet) Dalam Klasifikasi Penyakit Pada Daun Gandum," *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 7, no. 1, pp. 58–65, 2022, doi: 10.29100/jupi.v7i1.2410.