

Klasifikasi Kualitas Cengkeh menggunakan Arsitektur ResNet50V2

Clove Quality Classification using the ResNet50V2 Architecture

¹Muhamad Nurfaizi Linggama*, ²Dhani Ariatmanto

^{1,2}Informatika Program Magister, Universitas Amikom Yogyakarta

^{1,2}Jl. Ring Road Utara, Ngringin, Condongcatu, Kec. Depok, Kabupaten Sleman, Daerah Istimewa Yogyakarta 55281, Indonesia

*e-mail: muhamadnurfaizilinggama@students.amikom.ac.id

(received: 10 February 2025, revised: 17 February 2025, accepted: 18 February 2025)

Abstrak

Perkembangan kecerdasan buatan (AI) dan *computer vision* telah membuka peluang baru dalam industri pertanian, termasuk dalam klasifikasi kualitas cengkeh. Kualitas cengkeh berpengaruh terhadap nilai jual dan standar ekspor, namun klasifikasinya masih menghadapi tantangan, seperti kemiripan bentuk, ukuran, dan warna, serta variabilitas pencahayaan dan latar belakang gambar yang dapat menurunkan akurasi model klasifikasi. Untuk mengatasi tantangan ini, penelitian ini mengembangkan sistem klasifikasi kualitas cengkeh menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur ResNet50V2, yang terbukti unggul dalam pengolahan citra. Dataset yang digunakan terdiri dari 1250 gambar cengkeh yang diproses melalui tahapan *remove background*, *crop image*, dan *resize image to 224x224 pixels* agar sesuai dengan kebutuhan model. Data dibagi menjadi 80% untuk *training* dan 20% untuk *testing*. Model dilatih menggunakan teknik *deep learning*, dengan parameter yang dioptimalkan untuk meningkatkan performa klasifikasi. Hasil penelitian menunjukkan bahwa model ResNet50V2 mencapai akurasi 98,80%, dengan *precision*, *recall*, dan *F1-score* yang sangat tinggi. Grafik *accuracy* dan *loss* menunjukkan bahwa model bekerja dengan stabil tanpa mengalami *overfitting*, sementara *confusion matrix* menunjukkan tingkat kesalahan prediksi yang sangat rendah. Hasil ini membuktikan bahwa ResNet50V2 efektif dalam mengklasifikasikan kualitas cengkeh.

Kata kunci: klasifikasi, kualitas cengkeh, resnet50v2, *computer vision*, *deep learning*

Abstract

The development of artificial intelligence (AI) and computer vision has opened new opportunities in the agricultural industry, including in clove quality classification. The quality of cloves affects their market value and export standards; however, classification still faces challenges such as similarities in shape, size, and color, as well as variability in lighting and background images that can reduce the accuracy of classification models. To address these challenges, this study develops a clove quality classification system using a Convolutional Neural Network (CNN) with the ResNet50V2 architecture, which has proven to be superior in image processing. The dataset used consists of 1,250 images of cloves that were processed through stages of background removal, image cropping, and resizing to 224x224 pixels to meet the model's requirements. The data is divided into 80% for training and 20% for testing. The model is trained using deep learning techniques, with parameters optimized to enhance classification performance. The results show that the ResNet50V2 model achieves an accuracy of 98.80%, with very high precision, recall, and F1-score. The accuracy and loss graphs indicate that the model operates stably without experiencing overfitting, while the confusion matrix shows a very low prediction error rate. These results demonstrate that ResNet50V2 is effective in classifying clove quality.

Keywords: classification, clove quality, resnet50v2, computer vision, deep learning

1 Pendahuluan

Perkembangan kecerdasan buatan (AI) dan visi komputer (computer vision) telah membuka peluang besar dalam mengatasi berbagai tantangan di berbagai sektor industri, termasuk pertanian. Salah satu tantangan utama dalam industri pertanian adalah klasifikasi kualitas produk, seperti cengkeh, yang dapat mempengaruhi nilai jual dan standar ekspor. Cengkeh (*Syzygium aromaticum*) merupakan komoditas pertanian bernilai ekonomi tinggi yang memiliki peranan penting di pasar internasional [1].

Dalam penerapan *computer vision*, terdapat beberapa permasalahan yang sering dihadapi dalam klasifikasi gambar. Salah satu masalah utama adalah variabilitas kondisi pencahayaan dan latar belakang gambar, yang dapat memengaruhi akurasi deteksi dan pengenalan fitur [2]. Cengkeh, sebagai tanaman buah kecil, memiliki ukuran, bentuk, dan warna yang hampir serupa, sehingga sulit dibedakan oleh algoritma komputer [3].

Selain itu, model algoritma *computer vision* sering menghadapi gangguan atau cacat pada gambar yang dapat mempengaruhi hasil klasifikasi. Sebagai contoh, cengkeh yang memiliki warna yang hampir serupa atau mengalami kerusakan fisik, dapat menciptakan kesan visual yang menyesatkan, sehingga menyulitkan model dalam membuat keputusan klasifikasi yang akurat [4]. Penyesuaian dan penyempurnaan model, serta penerapan teknik augmentasi data, menjadi strategi penting untuk mengatasi tantangan ini dan meningkatkan akurasi sistem klasifikasi gambar [5].

Penggunaan model *deep learning* canggih, seperti *Convolutional Neural Networks* (CNN), telah terbukti meningkatkan kemampuan pengenalan pola visual dan menghasilkan klasifikasi gambar yang lebih akurat [6]. Salah satu arsitektur CNN yang menonjol adalah ResNet50V2 (Residual Network 50 Version 2) [7]. ResNet50V2 merupakan arsitektur *deep learning* yang telah banyak digunakan dan terbukti efektif dalam berbagai tugas klasifikasi citra [8]. Keunggulan utama ResNet50V2 terletak pada penerapan *residual connections*. Dibandingkan dengan VGG19 dan MobileNetV2, ResNet50V2 memiliki keunggulan dalam *residual learning*, yang memungkinkan jaringan lebih dalam tanpa kehilangan informasi penting [9]. Hal ini memungkinkan model untuk mempelajari representasi fitur yang lebih baik tanpa menghadapi masalah degradasi atau *vanishing gradient*. Arsitektur ini, yang terdiri dari 50 lapisan, juga menggunakan teknik seperti *batch normalization* dan *ReLU activation* untuk mempercepat proses pelatihan [10]. Dengan keunggulan ini, ResNet50V2 lebih efisien dan efektif dibandingkan dengan model CNN konvensional dalam pengolahan citra [8].

Penelitian ini bertujuan untuk mengembangkan model klasifikasi kualitas cengkeh dengan menggunakan arsitektur ResNet50V2. Diharapkan, model ini dapat mengklasifikasikan kualitas cengkeh berdasarkan kelas dengan tingkat akurasi yang tinggi, sehingga memberikan kontribusi signifikan dalam pengembangan teknik klasifikasi citra dan peningkatan metode penelitian di bidang ini.

2 Tinjauan Literatur

Penelitian Tempola dkk [1] memfokuskan peningkatan klasifikasi jenis cengkeh memanfaatkan pengolahan citra digital menggunakan teknik *deep learning* dengan memodifikasi arsitektur ResNet50. Modifikasi model arsitektur tersebut berhasil meningkatkan akurasi dalam mengklasifikasikan tiga jenis cengkeh: cengkeh utuh, cengkeh tanpa kepala, dan cengkeh induk, hasilnya mencapai akurasi sebesar 90,22%. Hasil pada penelitian ini menunjukkan potensi untuk meningkatkan akurasi model dengan menambahkan lapisan pada arsitektur yang sudah ada.

Penelitian Prayogi dkk [11] mengklasifikasikan kualitas bunga cengkeh kering menggunakan metode *deep learning* dengan algoritma CNN dan melakukan analisis sensitivitas terhadap *hyperparameter* CNN untuk memperoleh model terbaik. Kualitas cengkeh ditentukan berdasarkan standar SNI 3392-1994. Sebanyak 1.600 gambar bunga cengkeh dibagi menjadi empat kelas kualitas, dengan 225 data pelatihan, 75 data validasi, dan 100 data uji untuk setiap kelas. Model CNN pertama menghasilkan akurasi 65,25%, namun setelah dilakukan analisis sensitivitas dan penyesuaian hiperparameter, akurasi uji meningkat menjadi 87,75%, menunjukkan perbaikan yang signifikan pada klasifikasi kualitas cengkeh.

Penelitian Nasuli dkk [12] berfokus pada membahas penggunaan pemrosesan citra digital berbasis *Support Vector Machine* (SVM) untuk mengidentifikasi kualitas biji kopi Arabika. Penelitian ini berfokus pada pengembangan sistem untuk mengklasifikasikan kualitas dan ukuran biji kopi

<http://sistemasi.ftik.unisi.ac.id>

dengan menggunakan pemrosesan gambar untuk menganalisis fitur morfologi. Sistem ini mencapai tingkat akurasi 95% dalam mengidentifikasi kualitas dan ukuran biji kopi. Penelitian ini juga membahas metode yang digunakan untuk akuisisi, pra-pemrosesan, dan segmentasi gambar. Penelitian ini membahas proses 7 ekstraksi gambar, khususnya dalam konteks menganalisis gambar biji kopi. Ini mencakup teknik ekstraksi manual dan otomatis, serta penggunaan fitur morfologi dan pengklasifikasi SVM untuk analisis. Hasilnya menunjukkan potensi metode yang diusulkan untuk mengevaluasi kualitas biji kopi.

Penelitian Yaspin dkk [13] melakukan pengklasifikasian mutu cengkeh dengan mendeteksi ukuran dan warna cengkeh menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM). Proses deteksi ukuran dilakukan dengan membandingkan nilai threshold dari citra kulit cengkeh berwarna coklat, sedangkan deteksi warna dilakukan dengan citra berwarna putih. Threshold untuk mendeteksi ukuran yang baik berkisar antara 0.01 hingga 0.07 dan 0.1 hingga 0.6, sedangkan untuk warna putih antara 0.6 hingga 1 dan 0 hingga 0.15. Sistem ini menghasilkan keakuratan 92,50%, dengan 29 sampel benar dari 32 sampel cengkeh yang diuji.

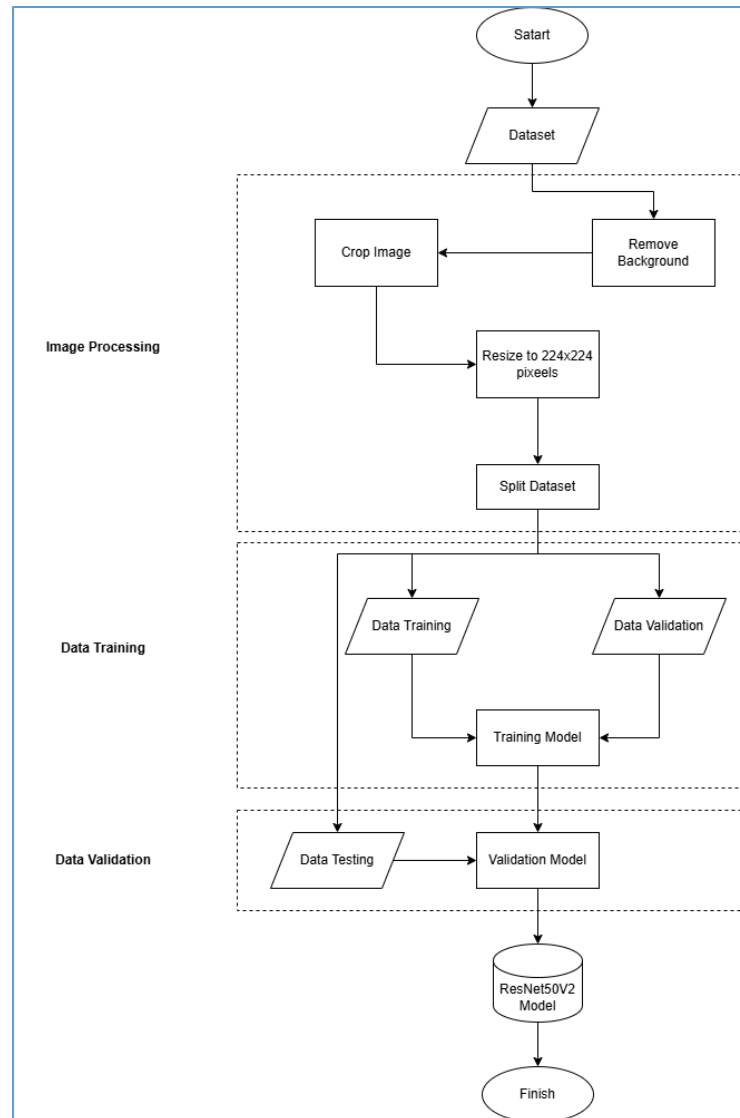
Dalam penelitian Chalik dkk [14] menggunakan arsitektur CNN dengan beberapa kombinasi, yaitu jumlah konvolusi, jumlah lapisan dense, dan ukuran lapisan. Arsitektur CNN dilatih menggunakan variasi ruang warna dan metode segmentasi gambar untuk mengklasifikasikan kualitas cengkeh. Penelitian ini menggunakan tiga ruang warna (RGB, HSV, dan YCbCr) serta dua metode segmentasi (segmentasi Otsu dan segmentasi warna HSV). Akurasi terbaik diperoleh dengan menggunakan ruang warna HSV, dataset asli, dan arsitektur E-5C-64LS-4D, yang mencapai akurasi 96% pada metrik accuracy, precision, recall, dan F1-score. Untuk memperoleh model yang lebih baik, metode segmentasi gambar yang tepat dan pemilihan ruang warna yang sesuai digunakan untuk meningkatkan kinerja arsitektur CNN.

Penelitian Fitriyani dkk [8] melakukan penerapan model deep learning untuk mendeteksi COVID-19 pada gambar chest X-ray (CXR). Masalah utama yang dihadapi adalah kesulitan membedakan COVID-19 dari penyakit lain dengan gejala serupa pada gambar CXR. Untuk itu, peneliti mengembangkan sistem computer-aided diagnosis (CAD) yang memanfaatkan kombinasi dua arsitektur CNN, yaitu Xception dan ResNet50V2, untuk meningkatkan kemampuan ekstraksi fitur. Hasil penelitian menunjukkan model yang diusulkan mencapai performa yang sangat baik dengan akurasi 93,41%, presisi 96,6%, recall 99,6%, dan F1-Score 98%, memberikan solusi yang efektif dan efisien untuk diagnosis klinis COVID-19.

Beberapa penelitian sebelumnya telah melakukan klasifikasi cengkeh menggunakan CNN. Misalnya, penelitian Tempola dkk [1] menggunakan modifikasi ResNet50 yang meningkatkan akurasi hingga 90,22%. Penelitian lain menggunakan metode GLCM untuk deteksi ukuran dan warna cengkeh dengan akurasi 92,50% [13]. Namun, pendekatan tersebut masih memiliki keterbatasan dalam menangani variasi latar belakang dan pencahayaan, yang dapat memengaruhi akurasi klasifikasi. Oleh karena itu, penelitian ini melakukan beberapa pendekatan dibandingkan dengan penelitian sebelumnya dengan melakukan proses *image processing* pada gambar cengkeh untuk memastikan bahwa gambar cengkeh yang digunakan sebagai dataset memiliki kualitas yang optimal untuk pelatihan model ResNet50V2.

3 Metode Penelitian

Model yang akan dibuat dalam penelitian ini adalah model arsitektur ResNet50V2 dengan mengikuti alur diagram yang dimulai dari *image processing* (dataset, *remove background*, *crop image*, *resize image to 224x224*, dan *split dataset*), dilanjutkan dengan data *training* (data *training*, data *validation*, dan *training model*), serta data *validation* (data *testing* dan data *validation*) hingga model ResNet50V2 dapat dilihat pada Gambar 1.



Gambar 1 Tahapan Model ResNet50V2.

3.1 Pengumpulan Data






Pada penelitian ini, dataset yang digunakan diperoleh melalui observasi dengan jumlah data sebanyak 1250 gambar yang diambil menggunakan kamera ponsel dengan resolusi 12 megapiksel, dengan latar belakang kertas HVS putih, jarak pengambilan gambar sekitar 20 cm, ukuran gambar 3 megabyte (MB), disimpan dalam format gambar JPG dan diambil dengan pencahayaan yang konsisten. Data dibagi menjadi dua bagian, yaitu data pelatihan (training) sebesar 80% dan data pengujian (testing) sebesar 20%, yang terdiri dari lima kelas, yaitu *Good Clove* (GC), *Good Clove Without Petal* (GCWP), *Dead Seed Clove* (DSC), *Dead Seed Clove Without Petal* (DSCWP), dan *Mother Clove* (MC). Berikut adalah Gambar 2, Tabel 1 dan Tabel 2 yang menunjukkan sampel kumpulan data cengkeh berdasarkan kelas.



Gambar 2. Original gambar cengkeh

Gambar 2 menunjukkan sampel data cengkeh asli yang diambil menggunakan kamera ponsel dengan resolusi 12 megapiksel, dengan latar belakang kertas HVS putih, pada jarak sekitar 20 cm, ukuran gambar 3 MB, disimpan dalam format JPG dan diambil dengan pencahayaan yang konsisten. Selanjutnya, Tabel 1 dan Tabel 2 di bawah ini menunjukkan sampel data cengkeh yang telah diperbesar untuk memperjelas sampel gambar.

Tabel 1. Sampel data cengkeh

GC	GCWP	DCS	DSCWP	MC
				

Tabel 2. Detail jumlah dataset

Class	Training	Testing
GC	200	50
GCWP	200	50
DCS	200	50
DSCWP	200	50
MC	200	50



3.2 Image Processing

Tahapan pertama yang dilakukan setelah data sudah siap adalah dengan melakukan *image processing*. Data cengkeh diolah dengan melalui beberapa taghapan yaitu *remove background*, *crop image*, dan *resize image to 224x224 pixels*.

3.2.1 Remove Background

Proses *remove background* pada kode ini dilakukan menggunakan library *rembg*, yang memanfaatkan model *deep learning* untuk mendeteksi dan menghapus latar belakang gambar secara otomatis. Ketika gambar dimasukkan ke dalam fungsi *remove*, model AI menganalisis citra dan mengidentifikasi objek utama dalam gambar, seperti produk atau objek yang ingin dipertahankan, sementara latar belakang yang tidak diinginkan dihapus. Hasilnya adalah gambar dengan objek yang terisolasi tanpa gangguan latar belakang. Implementasi *remove background* dilakukan pada setiap gambar yang ada dalam data, yang dapat dilihat pada contoh di Tabel 2.




Tabel 2. Remove background

Gambar Asli	Remove Background
	

3.2.2 Crop Image

Proses *crop image* bertujuan untuk memotong gambar secara otomatis berdasarkan *bounding box*, kemudian memperbesar gambar hasil *crop* menjadi bentuk persegi dengan objek utama berada di tengah. Dimulai dengan membaca gambar-gambar dalam folder sebelumnya yaitu *remove background*, setiap gambar dianalisis untuk mendapatkan area objek utama menggunakan metode *getbbox()* yang menghasilkan *bounding box*. Gambar kemudian dipotong sesuai dengan area ini. Selanjutnya, kode ini menentukan ukuran gambar baru yang berbentuk persegi, di mana sisi persegi disesuaikan dengan dimensi terbesar antara lebar atau tinggi gambar. Gambar hasil *crop* kemudian diposisikan di tengah gambar persegi yang baru dengan perhitungan koordinat tertentu, agar objek tetap terpusat. Berikut Tabel 2 *crop image*.

Tabel 3. Crop image

Gambar Asli	Remove Background	Crop Image
		

3.2.3 Resize Image to 224x224 Pixels

Proses *resize* untuk mengubah ukuran gambar secara otomatis setelah melakukan *crop image* yang telah diproses sebelumnya. Fungsi utama dari *resize* ini adalah untuk mengubah ukuran gambar dalam folder yang telah ditentukan menjadi ukuran yang seragam 224x224 piksel. Dengan menggunakan metode *resizing*, proses dimulai dengan membaca gambar-gambar dari folder input, kemudian setiap gambar diubah ukurannya menggunakan fungsi *resize()* dengan pilihan metode resampling *LANCZOS* yang memberikan kualitas tinggi dalam perubahan ukuran gambar. Gambar yang telah diubah ukurannya kemudian disimpan ke folder output dan setelahnya data bisa digunakan untuk pelatihan pada model ResNet50V2. Setelah proses *resizing*, gambar yang awalnya memiliki resolusi sebesar 3 MB diubah menjadi 3 kilobyte (KB), sehingga dalam proses pelatihan tidak memakan waktu yang lama karena ukuran gambar sudah tidak terlalu besar dan berat.

3.3 Data Traing

Pada bagian data *training*, dataset dibagi menjadi tiga bagian utama: data *training*, data *validation*, dan data *testing*. Data *training* digunakan untuk melatih model, sementara data *validation* digunakan untuk memantau performa model selama pelatihan dan mencegah *overfitting*. Data *validation* diambil dari 20% data *training*, sementara data *testing* digunakan hanya untuk evaluasi akhir setelah pelatihan selesai. Model yang digunakan adalah ResNet50V2. Pelatihan model dilakukan dengan menggunakan data *training*, sedangkan data *validation* digunakan untuk memantau apakah model mengalami *overfitting*. Teknik *augmentasi* data, seperti *rotasi*, *flipping*, dan *normalisasi*, diterapkan untuk meningkatkan generalisasi model. Selama proses pelatihan, model dilatih dengan menggunakan beberapa *epoch* dan menggunakan *callback* seperti *EarlyStopping* untuk menghentikan pelatihan lebih awal jika validasi tidak menunjukkan peningkatan, dan *ModelCheckpoint* untuk menyimpan model terbaik berdasarkan hasil validasi [15].

Tabel 4 Parameter yang digunakan pada model resnet50v2

Nama Parameter	Nilai
Optimizer	Adam
Batch Size	32
Epoch	50
Learning Rate	0.0001
Dropout Rate	0.3
EarlyStopping	5

3.4 Data Validation

Pada bagian alur data *validation* dalam pengujian model ResNet50V2, data *testing* digunakan untuk mengevaluasi kinerja model setelah dilatih. Data *testing* ini digunakan untuk menunjukkan seberapa baik model dalam mengklasifikasikan data yang belum pernah dilihat sebelumnya. Setelah model selesai dilatih menggunakan data *training*, data *testing* yang sudah dipersiapkan akan diuji oleh model untuk menghasilkan prediksi. Selanjutnya, hasil prediksi ini dibandingkan dengan label atau kategori yang benar dari data *testing*. Salah satu cara untuk mengevaluasi performa model adalah dengan menggunakan *confusion matrix*, Matriks ini memuat informasi tentang *true positives*, *true negatives*, *false positives*, dan *false negatives*, yang dapat digunakan untuk menghitung berbagai metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score* [16]. Perhitungan dari *confusion matrix* dapat dilihat dari persamaan 1, 2, 3 dan 4. Dari hasil ini, kita dapat menilai seberapa baik model dalam mengenali pola pada data dan mengklasifikasikan objek dengan benar. Dengan demikian, data *testing* dan *validation* membantu memastikan bahwa model ResNet50V2 dapat memberikan hasil yang jelas mengenai kinerja dalam klasifikasi kualitas cengkeh berdasarkan kelasnya.

<http://sistemasi.ftik.unisi.ac.id>

$$Accuracy = (TP + TN) / (TP + TN + FP + FN) \quad (1)$$

$$Precision = TP / (TP + FP) \quad (2)$$

$$Recall = TP / (TP + FN) \quad (3)$$

$$F1\ Score = (Precision \times Recall) / (Precision + Recall) \quad (4)$$

4 Hasil dan Pembahasan


Penelitian ini dilakukan dengan menggunakan model arsitektur ResNet50V2. Setelah melalui proses *pre-processing* data dan pembuatan model ResNet50V2, langkah selanjutnya adalah menjalankan model yang telah dibuat, seperti yang ditunjukkan pada Tabel 4. Model dijalankan menggunakan 1250 data gambar cengkeh yang telah dibagi seperti yang ditampilkan pada Tabel 2 dan dijelaskan pada tahap data training maka didapatkan hasil akurasi sebesar 98.80%.

Classification Report:				
	precision	recall	f1-score	support
Dead Seed Clove	0.98	1.00	0.99	50
Dead Seed Clove Without Petal	0.98	1.00	0.99	50
Good Clove	1.00	0.96	0.98	50
Good Clove Without Petal	0.98	0.98	0.98	50
Mother Clove	1.00	1.00	1.00	50
accuracy			0.99	250
macro avg	0.99	0.99	0.99	250
weighted avg	0.99	0.99	0.99	250

Accuracy: 98.80%
Precision: 98.82%
Recall: 98.80%
F1-Score: 98.80%


Gambar 3. Classification report

Gambar 3 menunjukkan hasil kinerja model ResNet50V2 dalam mengenali lima jenis kelas kualitas cengkeh: *Dead Seed Clove*, *Dead Seed Clove Without Petal*, *Good Clove*, *Good Clove Without Petal*, dan *Mother Clove*, dengan data *testing* sebanyak 250 gambar. Model bekerja sangat baik, dengan nilai *precision*, *recall*, dan *f1-score* semuanya sangat tinggi (rata-rata sekitar 98% hingga 100%). Nilai *precision* 98.82%, *recall* 98.80% dan *f1-score* 98.80%. Ketiga nilai tersebut menunjukkan bahwa model memiliki kinerja yang sangat baik, hampir semua prediksi benar (*precision*), hampir tidak ada data penting yang terlewat (*recall*), dan keseimbangan antara keduanya sangat baik (*F1-score*). Secara keseluruhan, nilai *accuracy* model sangat tinggi, yaitu 98.80%, menunjukkan model dapat mengenali kualitas cengkeh dengan sangat baik.



Gambar 4, Grafik accuracy dan loss

Gambar 4 menunjukkan bagaimana akurasi dan loss (kesalahan) model berubah selama proses *training* dan *validation*. Grafik di kiri menunjukkan bahwa akurasi pelatihan (garis biru) terus meningkat hingga mendekati 100% (98.80%), sementara akurasi validasi (garis oranye) mencapai puncaknya sekitar epoch ke-5 dan kemudian stabil. Grafik di kanan menunjukkan bahwa nilai loss (garis biru untuk pelatihan, oranye untuk validasi) turun drastis di awal, yang berarti model semakin baik dalam memprediksi. Setelah beberapa *epoch*, nilai *loss* validasi sangat kecil, menandakan model bekerja dengan baik tanpa *overfit*. Secara keseluruhan, model ini menunjukkan hasil yang sangat baik.



Gambar 5. Confusion matrix

Pada Gambar 5, *confusion matrix* menunjukkan bahwa model ResNet50V2 bekerja dengan sangat baik dalam memprediksi data. Dari 250 data testing yang digunakan dalam evaluasi model, hanya ada 3 prediksi yang salah, yang menunjukkan bahwa model ini memiliki tingkat akurasi yang sangat tinggi. Sebagian besar hasil prediksi yang dihasilkan sudah sangat sesuai dengan label asli yang ada pada dataset, yang terlihat jelas dari angka-angka yang terdapat pada *confusion matrix*. Angka-angka tersebut menunjukkan bahwa model ini mampu mengklasifikasikan data dengan tingkat kesalahan yang sangat rendah. Hal ini mencerminkan bahwa model ResNet50V2 yang telah dibangun dan dilatih bekerja dengan sangat optimal, serta mampu mengenali data dengan sangat baik. Dengan sedikitnya kesalahan prediksi, model ini dapat diandalkan untuk memecahkan masalah klasifikasi gambar secara efisien. Dengan hasil ini juga mengindikasikan bahwa model ResNet50V2 sangat cocok digunakan untuk tugas-tugas klasifikasi yang membutuhkan akurasi tinggi dan ketepatan dalam pengenalan pola. Secara keseluruhan, hasil dari confusion matrix ini menunjukkan bahwa model yang dikembangkan telah mencapai kinerja yang sangat baik.



Gambar 6. Sampel hasil klasifikasi yang benar



Gambar 7. Klasifikasi yang salah

Seperti yang terlihat pada Gambar 5 *confusion matrix*, dari 250 data uji yang digunakan untuk menguji model, 247 data berhasil diklasifikasikan dengan benar, sementara 3 data lainnya salah. Contoh data yang benar bisa dilihat di Gambar 6, sedangkan 3 data yang salah ditampilkan di Gambar 7. Pada gambar-gambar yang salah ini, model membuat kesalahan dalam memprediksi atau mengklasifikasikan gambar. Misalnya, ada gambar yang seharusnya dikategorikan sebagai *Good Clove*, namun salah diprediksi sebagai *Good Clove Without Petal*. Tetapi secara keseluruhan, model ResNet50V2 menunjukkan kinerja yang sangat baik dalam mengklasifikasikan kualitas cengkeh berdasarkan kelasnya dengan mencapai akurasi tertinggi sebesar 98.80%.

5 Kesimpulan

Penelitian ini menggunakan model ResNet50V2 untuk mengklasifikasikan lima jenis kualitas cengkeh. Setelah melakukan proses *pre-processing* data dan pembuatan model, model diuji dengan 1250 gambar yang dibagi menjadi data *training* dan *testing*. Hasilnya, model ini mencapai *accuracy*, *precision*, *recall*, dan *f1-score* sangat tinggi yakni rata-rata sekitar 98.80%, yang berarti model ini sangat akurat dalam memprediksi kualitas cengkeh. Analisis lebih lanjut menunjukkan bahwa model ResNet50V2 dapat mengklasifikasikan data dengan baik. Grafik *accuracy* dan *loss* selama pelatihan menunjukkan peningkatan yang stabil tanpa adanya masalah *overfitting*. *Confusion matrix* juga menunjukkan bahwa hanya 3 data dari 250 yang salah diprediksi, yang menunjukkan tingkat kesalahan yang sangat rendah dan akurasi yang sangat tinggi. Dengan demikian, model ini dapat diandalkan untuk tugas klasifikasi yang membutuhkan akurasi yang tinggi. Secara keseluruhan, hasil

penelitian ini menunjukkan bahwa model ResNet50V2 sangat efektif untuk mengklasifikasikan kualitas cengkeh dengan akurasi 98.80%. Penelitian ini dapat dilanjutkan dengan menggunakan model *deep learning* lainnya, serta menerapkan model *transfer learning* dan menambahkan dataset yang lebih besar dan bervariasi.

Referensi

- [1] F. Tempola, R. Wardoyo, A. Musdholifah, Rosihan, and A. K. Nugroho, "Implementation of Deep Learning with Resnet50 Modification for Clove Classification," *Proceeding - IEEE 9th Inf. Technol. Int. Semin. ITIS 2023*, pp. 1–4, 2023, doi: 10.1109/ITIS59651.2023.10419960.
- [2] T. Anjali Dompeipen, S. R. U. . Sompie, and M. E. . Najooan, "Computer Vision Implementation for Detection and Counting the Number of Humans," *J. Tek. Inform. vol. 16 no. 1*, vol. 16, no. 1, pp. 65–76, 2021.
- [3] M. Fauzi, A. Ilhami, and S. Wibisono, "Klasifikasi Rimpang menggunakan Metode Jaringan Saraf Konvolusi dengan Arsitektur Alexnet Rhizome Classification using Convolutional Neural Network Method with Alexnet Architecture," *J. Inf. Technol. Comput. Sci.*, vol. 6, no. 2, 2023.
- [4] M. A. Tamayo-Monsalve *et al.*, "Coffee Maturity Classification using Convolutional Neural Networks and Transfer Learning," *IEEE Access*, vol. 10, no. January, pp. 42971–42982, 2022, doi: 10.1109/ACCESS.2022.3166515.
- [5] M. A. Leonardi and A. Y. Chandra, "Analisis Perbandingan CNN dan Vision Transformer untuk Klasifikasi Biji Kopi Hasil Sangrai," *J. Media Inform. Budidarma*, vol. 8, no. 3, p. 1398, 2024, doi: 10.30865/mib.v8i3.7732.
- [6] A. Shanthini, G. Manogaran, and G. Vadivu, *Deep Convolutional Neural Network for The Prognosis of Diabetic Retinopathy*. 2023. [Online]. Available: [https://doi.org/10.1007/978-981-19-3877-1](https://doi.org/10.1007/978-981-19-3877-1%0Ahttps://link.springer.com/10.1007/978-981-19-3877-1)
- [7] D. Hastari, S. Winanda, A. R. Pratama, N. Nurhaliza, and E. S. Ginting, "Application of Convolutional Neural Network ResNet-50 V2 on Image Classification of Rice Plant Disease," *Public Res. J. Eng. Data Technol. Comput. Sci.*, vol. 1, no. 2, pp. 71–77, 2024, doi: 10.57152/predatecs.v1i2.865.
- [8] H. I. Fitriyani and M. Rizkinia, "Improvement of Xception-ResNet50V2 Concatenation for COVID-19 Detection on Chest X-Ray Images," *3rd 2021 East Indones. Conf. Comput. Inf. Technol. EIConCIT 2021*, pp. 343–347, 2021, doi: 10.1109/EIConCIT50028.2021.9431916.
- [9] M. Harahap, Em Manuel Laia, Lilis Suryani Sitanggang, Melda Sinaga, Daniel Franci Sihombing, and Amir Mahmud Husein, "Deteksi Penyakit Covid-19 pada Citra X-Ray dengan Pendekatan Convolutional Neural Network (CNN)," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 6, no. 1, pp. 70–77, 2022, doi: 10.29207/resti.v6i1.3373.
- [10] A. K. Das, S. Ghosh, S. Thunder, R. Dutta, S. Agarwal, and A. Chakrabarti, "Automatic COVID-19 Detection from X-ray Images using Ensemble Learning with Convolutional Neural Network," *Pattern Anal. Appl.*, vol. 24, no. 3, pp. 1111–1124, 2021, doi: 10.1007/s10044-021-00970-4.
- [11] I. Y. Prayogi, Sandra, and Y. Hendrawan, "Image Classification of Different Clove (*Syzygium Aromaticum*) Quality using Deep Learning Method with Convolutional Neural Network Algorithm," *IOP Conf. Ser. Earth Environ. Sci.*, vol. 905, no. 1, 2021, doi: 10.1088/1755-1315/905/1/012018.
- [12] J. A. T. Nasuli, J. P. Lumbis, and E. R. Arboleda, "Arabica Coffee Bean Quality Identification using Support Vector Machine-based Digital Image Processing," no. June, 2023, doi: 10.13140/RG.2.2.19015.47522.
- [13] Y. N. Yaspin, D. W. Widodo, and J. Sulaksono, "Klasifikasi Kualitas Bunga Cengkeh untuk meningkatkan Mutu dengan Pemanfaatan Ciri Gray Level Co-Occurrence Matrix (GLCM)," *Semin. Nas. Inov. Teknol.*, pp. 149–154, 2020, [Online]. Available: <https://proceeding.unpkediri.ac.id/index.php/inotek/article/view/78>
- [14] F. A. Chalik and W. F. Al Maki, "Classification of Dried Clove Flower Quality using Convolutional Neural Network," *2021 Int. Conf. Data Sci. Artif. Intell. Bus. Anal. DATABIA 2021 - Proc.*, pp. 40–45, 2021, doi: 10.1109/DATABIA53375.2021.9650199.

- [15] S. Samidin and A. Fadjeri, "Klasifikasi Gambar Batu-Kertas-Gunting menggunakan *Convolutional Neural Network* dengan Fungsi *Callback* untuk mencegah *Overfitting*," *J. Penelit. Inov.*, vol. 4, no. 2, pp. 785–794, 2024, doi: 10.54082/jupin.413.
- [16] B. Rostami, D. M. Anisuzzaman, C. Wang, S. Gopalakrishnan, J. Niezgoda, and Z. Yu, "Multiclass Wound Image Classification using an Ensemble Deep CNN-based Classifier," *Comput. Biol. Med.*, vol. 134, no. May, p. 104536, 2021, doi: 10.1016/j.combiomed.2021.104536.