

Klasifikasi Mutu Biji Kopi Menggunakan Metode CNN-SVM Berdasarkan Cacat Fisik dan Warna

DOI: <http://dx.doi.org/10.35889/progresif.v22i1.3344>

Creative Commons License 4.0 (CC BY –NC)



Michael Gunawan^{1*}, Daniel Udjulawa²

Informatika, Universitas Multi Data Palembang, Palembang, Indonesia

*e-mail Corresponding Author: michaelgunawan_2226250062@mhs.mdp.ac.id

Abstract

The determination of coffee bean quality in Indonesia is generally still done manually based on physical defects and color, which is subjective and time-consuming. This study aims to develop a digital image-based green coffee bean quality classification model using the Convolutional Neural Network and Support Vector Machine (CNN-SVM) method. CNN is used as a feature extractor with a ResNet-50 architecture, while SVM functions as a classifier using a Radial Basis Function (RBF) kernel. The dataset consists of 10 classes of coffee bean defects and is divided into 80% training data and 20% test data. The test results show an accuracy value of 77.68%, precision of 80.04%, recall of 77.15%, and f1-score of 77.47%. This approach proves that the combination of CNN and SVM can improve the accuracy and stability of the model. This finding is a novelty in the development of an efficient and objective artificial intelligence-based automatic coffee quality sorting system.

Keywords: Coffee Bean Classification; CNN-SVM; ResNet-50

Abstrak

Penentuan mutu biji kopi di Indonesia umumnya masih dilakukan secara manual berdasarkan cacat fisik dan warna, yang bersifat subjektif dan memerlukan waktu lama. Penelitian ini bertujuan untuk mengembangkan model klasifikasi mutu biji kopi hijau berbasis citra digital menggunakan metode *Convolutional Neural Network* dan *Support Vector Machine* (CNN-SVM). CNN digunakan untuk ekstraksi fitur dengan arsitektur *ResNet-50*, sedangkan SVM berfungsi untuk klasifikasi menggunakan kernel *Radial Basis Function* (RBF). Dataset terdiri dari 10 kelas cacat biji kopi dan dibagi menjadi 80% data latih serta 20% data uji. Hasil pengujian menunjukkan nilai akurasi sebesar 77,68%, presisi 80,04%, *recall* 77,15%, dan *f1-score* 77,47%. Pendekatan ini membuktikan bahwa kombinasi CNN dan SVM mampu meningkatkan akurasi dan stabilitas model. Temuan ini menjadi kebaruan dalam pengembangan sistem sortasi mutu kopi otomatis yang efisien dan objektif berbasis kecerdasan buatan.

Kata kunci: Klasifikasi Biji Kopi; CNN-SVM; ResNet-50

1. Pendahuluan

Indonesia termasuk negara terbesar dalam mengekspor kopi di dunia terutama ke Amerika Serikat, Jerman, Jepang, Italia, dan Malaysia. Berdasarkan Badan Pusat Statistik Indonesia, volume ekspor kopi di Indonesia pada tahun 2024 mencapai 312.900 ton, meningkat sebesar 36.000 Ton dari tahun 2023 [1]. Peningkatan ini menunjukkan bahwa industri kopi di Indonesia memiliki potensi untuk berkembang dan berdaya saing tinggi di pasar internasional.

Seiring meningkatnya volume ekspor, biji kopi yang diproduksi harus lolos Standar Nasional Indonesia tentang biji kopi sesuai yang di atur di SNI-01-2907-2008 [2]. Perbedaan mutu berdasarkan cacat ini akan mempengaruhi penjualan seperti pengurangan harga yang sesuai dengan kesepakatan penjual dan pembeli. Namun, praktik sortasi mutu biji kopi hingga kini masih banyak dilakukan secara manual dengan memisahkan kopi yang terlihat bagus dengan kopi yang cacat [3].

Pada era modern saat ini, mendorong pemanfaatan teknologi *computer vision* dan *machine learning* untuk mengklasifikasi mutu biji kopi. Berbagai penelitian telah mengimplementasikan metode klasifikasi berbasis citra digital seperti metode CNN yang sering digunakan. Peneliti terdahulu mengimplementasikan CNN untuk klasifikasi citra makanan khas Indonesia, mendapatkan nilai akurasi sebesar 91% [4]. Peneliti terdahulu lainnya menunjukkan bahwa CNN berbasis analisis warna dan tekstur kopi mampu mencapai akurasi 94,44% menggunakan data latih 210 citra dan data uji 90 citra [5]. Penelitian-penelitian tersebut sudah cukup membuktikan atas keunggulan yang dimiliki oleh metode CNN, tetapi terdapat kelemahan yang ada di metode CNN dimana pengklasifikasian citra yang dilakukan CNN sangat baik dengan data yang sangat banyak. Namun, memerlukan waktu yang sangat banyak dan memiliki kemungkinan *overfitting* [6].

Support Vector Machines (SVM) dapat melengkapi kekurangan CNN dalam tugas klasifikasi [6]. Pekerjaan yang fokus pada fitur warna, bentuk, dan ukuran untuk menentukan kualitas biji kopi robusta mencapai akurasi lebih dari 90% [7]. Pekerjaan lain yang menerapkan optimasi pencarian grid pada SVM untuk mengenali biji kopi robusta dari fitur kekasaran mencapai akurasi 94% [8]. Ini menunjukkan bahwa SVM berkinerja sangat baik dalam tugas klasifikasi ketika fitur visual yang sesuai diekstrak.

Penelitian ini bertujuan menghasilkan sistem yang mampu melakukan klasifikasi secara otomatis, efisien, dan konsisten, sehingga dapat mengurangi subjektivitas penilaian manual yang masih umum digunakan dalam proses sortasi mutu kopi. Selain itu, penelitian ini juga dimaksudkan untuk menunjukkan bahwa perpaduan CNN sebagai ekstraktor fitur dan SVM sebagai klasifikator, dapat memperbaiki kinerja model dalam hal generalisasi dan stabilitas hasil prediksi pada data citra dengan variasi visual yang tinggi.

Penelitian ini penting dilakukan karena secara teoritis memberikan kontribusi terhadap pengembangan metode klasifikasi mutu biji kopi berbasis citra digital dengan kombinasi CNN dan SVM yang mampu meningkatkan akurasi serta mengurangi risiko *overfitting*. Secara praktis, hasil penelitian ini dapat mendukung industri kopi dalam melakukan proses sortasi mutu otomatis yang lebih objektif, cepat, dan konsisten dibandingkan penilaian manual. Dengan demikian, penerapan metode CNN-SVM berbasis *ResNet-50* menjadi alternatif yang efektif untuk meningkatkan efisiensi dan kualitas pengendalian mutu biji kopi di Indonesia.

2. Tinjauan Pustaka

Penelitian-penelitian terdahulu menunjukkan bahwa teknik *computer vision* dan *deep learning* memiliki peran penting dalam klasifikasi citra biji kopi. Munthe dan Akbar [9] mengembangkan model *ResNet-50* yang membedakan tiga varietas kopi dari Temanggung, yaitu Arabika, Robusta, dan Excelsa, menggunakan dataset 1.350 citra dengan proses *pre-processing* berupa *resizing*, normalisasi, dan pembagian data, serta menghasilkan akurasi mencapai 96% melalui evaluasi *confusion matrix* yang meliputi *accuracy*, *precision*, *recall*, dan *F1-score*, sehingga membuktikan efektivitas arsitektur *ResNet* dalam mengenali fitur visual biji kopi secara akurat.

Selanjutnya, penelitian oleh Amanina dan Saraswati [10] menerapkan metode *K-Nearest Neighbor* (KNN) dengan ekstraksi fitur warna RGB untuk mengklasifikasikan mutu *green bean* Arabika berdasarkan grade, menggunakan 300 citra latih dan uji yang menghasilkan akurasi sebesar 80%, sehingga menunjukkan bahwa pemrosesan citra berbasis warna dapat digunakan untuk membedakan kualitas biji kopi meskipun akurasinya masih bergantung pada model dan parameter yang digunakan.

Penelitian lain oleh Pakaya et al. [11] mengembangkan sistem klasifikasi tingkat *roasting* biji kopi memanfaatkan arsitektur *MobileNet* berbasis CNN, yang dilatih dengan 1.600 citra biji kopi berlabel *light*, *medium*, dan *dark*. Hasil pengujian memperlihatkan akurasi tertinggi 98–99%, dengan performa aplikasi mencapai 93,55% sehingga membuktikan bahwa arsitektur ringan seperti *MobileNet* sangat efektif untuk implementasi pada perangkat Android dan kebutuhan real-time dalam industri kopi.


Sementara itu, Murinto et al. [12] melakukan klasifikasi tiga jenis biji kopi Arabika, Robusta, dan Liberica menggunakan transfer learning pada model VGG16 dan *MobileNetV2*. Dari 1.600 citra yang digunakan, model *MobileNetV2* memberikan akurasi tertinggi sebesar 96%, membuktikan bahwa transfer learning mempercepat proses pelatihan sekaligus meningkatkan akurasi dibandingkan CNN biasa.

Selanjutnya, Arwatchananukul et al. [13] mengembangkan model klasifikasi 17 jenis cacat green bean Arabika menggunakan berbagai arsitektur CNN seperti *MobileNetV3*, *EfficientNetV2*, dan *ResNetV2*. Melalui augmentasi rotasi yang memperluas dataset dari 979 menjadi 6.853 citra, *MobileNetV3* terbukti paling unggul dengan akurasi 98,78–99,84% pada *cross-validation* dan akurasi 88,63% pada data uji nyata, serta berhasil diimplementasikan ke dalam aplikasi web untuk deteksi cacat secara real-time. Hasil ini menegaskan bahwa pemanfaatan CNN mampu memberikan kinerja tinggi dalam klasifikasi cacat biji kopi yang kompleks dan beragam.

Berdasarkan penjelasan dari berbagai penelitian terdahulu, penelitian ini menerapkan CNN sebagai ekstraktor fitur dan SVM sebagai klasifikator dinilai efektif dan akurat untuk klasifikasi citra biji kopi. Perbedaan penelitian ini terletak pada dua penelitian sebelumnya yang menggunakan metode tunggal yaitu CNN dan penelitian lainnya juga menggunakan metode berbeda seperti KNN, sedangkan penelitian ini menggunakan dua metode yang memanfaatkan kekuatan CNN dalam mengekstraksi fitur warna dan cacat fisik, tetapi juga mengoptimalkan pemisahan kelas melalui SVM. Selain itu, pada penelitian sebelumnya yang melakukan klasifikasi jenis kopi dan penelitian terakhir yang melakukan penelitian klasifikasi cacat fisik tetapi melakukan perbandingan antara arsitektur di satu metode saja yaitu CNN.

3. Metodologi

Pada Gambar 1 menampilkan tahapan metode penelitian yang digunakan dalam mengklasifikasi mutu biji kopi, mulai dari pengolahan data, hingga pembangunan model klasifikasi menggunakan algoritma CNN-SVM.



Gambar 1. Tahapan Metodologi Penelitian

3.1. Dataset Penelitian

Dataset yang digunakan berupa citra biji kopi hijau yang berasal dari public dataset yang tersedia di platform Kaggle dengan judul “Coffee Green Bean with 17 Defects (Original)”. Dataset ini berisi citra biji kopi hijau yang telah dilabel berdasarkan jenis cacatnya. Dari total 17 kelas cacat yang tersedia, penelitian ini difokuskan pada 10 kelas cacat berisi 558 citra yang berkaitan dengan cacat warna yang terdiri dari 6 kelas, yaitu *Full Black*, *Fade*, *Dry Cherry*, *Partial Black*, *Full Sour*, *Partial Sour*, dan fisik yang terdiri dari 4 kelas, yaitu *Broken*, *Cut*, *Shell*, dan *Husk*.

3.2. Preprocessing

Pada tahap ini, setiap citra kemudian melalui tahap praproses untuk memastikan keseragaman data dan meningkatkan kualitas fitur yang diekstraksi. Tahapan praproses meliputi, resize citra ke resolusi tetap menjadi 224×224 piksel agar sesuai dengan arsitektur *ResNet-50* dan normalisasi piksel dengan mengubah nilai RGB ke rentang [0, 1] untuk menstabilkan distribusi intensitas warna.

3.3. Pembagian Dataset

Dalam penelitian ini, dataset citra biji kopi terbagi menjadi dua kelompok utama, yakni 80% sebagai data latih dan 20% sebagai data uji dari total keseluruhan citra. Data latih digunakan dalam proses pembelajaran model yang meliputi tahap augmentasi citra, ekstraksi fitur menggunakan CNN berbasis *ResNet-50*, serta klasifikasi menggunakan SVM. Data uji berfungsi untuk menilai kemampuan generalisasi model terhadap citra yang sebelumnya tidak pernah dikenali. Pembagian dataset ini bertujuan agar model tidak hanya menghafal pola dari data latih, tetapi juga mampu mengenali pola baru secara akurat pada data uji, sehingga hasil klasifikasi mutu biji kopi yang diperoleh lebih objektif dan dapat diandalkan.

3.4. Augmentasi Data

Proses augmentasi data pada penelitian ini bertujuan untuk menambah variasi citra tanpa menambah jumlah data asli, sehingga model dapat belajar terhadap perubahan visual. Augmentasi dilakukan dengan transformasi sederhana seperti rotasi, pembalikan horizontal dan vertikal dan zoom yang diterapkan pada data latih. Teknik ini membantu mencegah *overfitting* serta meningkatkan kemampuan generalisasi model CNN-SVM dalam mengenali berbagai kondisi visual biji kopi. Teknik augmentasi yang digunakan meliputi rotasi citra hingga 12 derajat, pembalikan horizontal (*horizontal flip*), pergeseran citra secara horizontal dan vertikal sebesar 4%, serta zoom sebesar 10%. Contoh hasil gambar setelah dilakukan augmentasi dapat dilihat di Gambar 2.




Gambar 2. Hasil Augmentasi

3.5. Model

3.5.1. CNN


Penelitian ini menggunakan jaringan saraf tiruan konvolusi (CNN) dengan arsitektur ResNet-50 untuk mengekstraksi fitur dari gambar. CNN adalah salah satu jenis algoritma pembelajaran mendalam yang termasuk dalam kategori jaringan saraf *feed-forward*. CNN dirancang khusus untuk memproses data berbentuk dua dimensi seperti gambar digital, dengan kemampuan membentuk representasi hierarkis dari fitur visual. Arsitektur CNN terdiri dari beberapa lapisan utama, yaitu lapisan input, lapisan konvolusi, lapisan *pooling*, lapisan aktivasi (ReLU), lapisan terhubung penuh, dan lapisan output. Proses konvolusi dilakukan dengan menggunakan filter kernel untuk mengekstraksi fitur penting dari gambar, sedangkan lapisan *pooling* berfungsi untuk mengurangi ukuran data tanpa menghilangkan karakteristik utama gambar, sehingga model menjadi lebih efisien dan tidak mengalami *overfitting* [14]. Proses ini dapat dilihat di Gambar 3.



Gambar 3. Convolution Neural Network

3.5.2. SVM


Penelitian ini menggunakan SVM dengan kernel RBF sebagai klasifikator untuk vektor yang dihasilkan oleh CNN. *Support Vector Machine* (SVM) adalah algoritma pembelajaran *supervised* yang digunakan untuk tugas klasifikasi dan *regresi*. SVM bekerja dengan mencari *hyperplane* terbaik yang mampu memisahkan data dari berbagai kelas dengan jarak maksimum. Keunggulan utama SVM terletak pada kemampuannya mengatasi masalah data berdimensi tinggi serta menghasilkan generalisasi yang baik pada data uji baru. Proses klasifikasi dilakukan dengan mengukur jarak antara *support vector* dan batas keputusan (*decision boundary*), di mana semakin besar jarak tersebut, semakin baik model dalam memisahkan kelas [14]. Contoh *hyperplane* dapat dilihat di Gambar 4.



Gambar 4. Hyperplane Support Vector Machine

3.5.3. CNN-SVM

Model CNN-SVM merupakan pendekatan yang menggabungkan kekuatan CNN sebagai ekstraktor fitur dan SVM sebagai klasifikator. Pada arsitektur ini, lapisan output dari CNN yang biasanya menggunakan *softmax classifier* digantikan oleh *SVM classifier*. CNN digunakan untuk mengekstraksi fitur dari citra melalui lapisan konvolusi dan *pooling*, sedangkan SVM menerima hasil keluaran dari *hidden layer* CNN dalam bentuk vektor fitur untuk proses klasifikasi. Penggabungan dua metode ini mampu mengatasi kelemahan CNN yang cenderung mengalami *overfitting* pada dataset kecil serta meningkatkan ketepatan dalam pemisahan kelas [15]. Gabungan model ini dapat dilihat di Gambar 5.



Gambar 5. Cara Kerja CNN-SVM

3.6. Evaluasi

Pada penelitian ini akan dilakukan pengujian terhadap 2 model yaitu model CNN dengan arsitektur ResNet-50 tanpa menggunakan SVM dan model penelitian ini yaitu CNN-SVM yang telah diuji menggunakan data uji. Hasil prediksi dibandingkan dengan label sebenarnya, kemudian disusun dalam *confusion matrix* untuk setiap kelas cacat biji kopi. Dari confusion matrix dihitung nilai *precision*, *recall*, *accuracy*, dan *F1-Score* sesuai dengan Persamaan (1), (2), (3), dan (4).

Presisi mengukur seberapa tepat sistem dalam mengenali data, yaitu seberapa besar prediksi positif yang benar-benar termasuk ke dalam kategori positif. Nilai ini menggambarkan sensitivitas sistem terhadap ketepatan informasi yang diberikan [16]

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (1)$$

Recall adalah ukuran keberhasilan sistem dalam mengenali seluruh data dari kelas yang sebenarnya positif. Nilai ini menunjukkan kemampuan model untuk menemukan kembali informasi yang benar dari keseluruhan data positif [16][17]

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (2)$$

Akurasi adalah nilai rasio antara jumlah data yang benar terdeteksi dengan keseluruhan data pengujian. Nilai ini menunjukkan tingkat kedekatan antara hasil prediksi sistem dengan nilai sebenarnya[16]

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (3)$$

F1-Score merupakan ukuran gabungan dari *precision* dan *recall* dalam bentuk rata-rata harmonis, yang memberikan penilaian seimbang antara ketepatan dan kelengkapan prediksi model[16]

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \times 100\% \quad (4)$$

4. Hasil dan Pembahasan

4.1. Pra-proses Data

Tahap pra-proses data dilakukan agar gambar biji kopi siap digunakan dalam pelatihan model dengan memiliki kualitas dan karakteristik yang sama. Proses ini meliputi resize 224×224 piksel, serta normalisasi warna agar pencahayaan dan intensitas warna biji kopi lebih merata. Setelah tahap tersebut, dilakukan augmentasi data berupa rotasi, pembalikan horizontal, pergeseran, dan *zoom* agar model mampu beradaptasi terhadap berbagai variasi bentuk dan orientasi citra.

Gambar 6 menunjukkan contoh hasil pra-proses dan augmentasi yang telah diterapkan pada beberapa kelas biji kopi. Hasil pra-proses memperlihatkan bahwa warna biji kopi menjadi lebih tajam dan kontras meningkat sehingga tekstur permukaan biji kopi tampak lebih jelas. Selain itu, hasil augmentasi menghasilkan variasi posisi dan sudut pandang citra tanpa mengubah karakteristik utama objek, sehingga model dapat mempelajari fitur secara lebih menyeluruh. Tahapan ini terbukti penting untuk meningkatkan kualitas data masukan serta mengurangi risiko overfitting pada proses pelatihan model CNN-SVM.




Gambar 6. Hasil Pra-proses Data

4.2. Pelatihan Data

Proses pelatihan model CNN menggunakan arsitektur *ResNet-50* dilakukan selama 25 *epoch* dengan memanfaatkan data latih yang telah melalui tahap pra-proses dan augmentasi. Berdasarkan grafik yang ada di Gambar 7, terlihat bahwa akurasi pelatihan meningkat secara bertahap dari sekitar 9% pada epoch awal hingga mencapai lebih dari 55% pada *epoch* ke-25. Akurasi validasi juga mengalami peningkatan yang konsisten, bahkan menunjukkan performa yang lebih stabil dibandingkan akurasi pelatihan, yang menandakan bahwa model mampu mempelajari pola visual biji kopi dengan baik tanpa mengalami *overfitting* yang signifikan.

Sementara itu, grafik menunjukkan penurunan nilai *loss* baik pada data latih maupun validasi, dari nilai awal sekitar 3.3 menjadi sekitar 1.1 pada akhir pelatihan. Penurunan *loss* yang konsisten mengindikasikan bahwa proses optimasi berjalan efektif dan model mampu mengurangi kesalahan prediksi selama pelatihan. Perbedaan yang relatif kecil antara *train loss* dan *validation loss* juga memperlihatkan bahwa generalisasi model berada pada tingkat yang baik. Secara keseluruhan, hasil pelatihan ini menunjukkan bahwa model CNN berhasil mempelajari fitur penting seperti tekstur, bentuk, dan intensitas warna dari biji kopi sehingga dapat digunakan sebagai *extractor* fitur yang kuat sebelum tahap klasifikasi menggunakan SVM.



Gambar 7. Grafik *Train vs Validation*


Hasil pelatihan data dapat dilihat di Gambar 8, pada data pelatihan menunjukkan bahwa model CNN-SVM memberikan performa yang sangat tinggi, dengan akurasi mencapai 99,78% serta nilai *macro precision*, *recall*, dan *f1-score* yang hampir sempurna. Hampir seluruh kelas, seperti *Broken*, *Cut*, *Dry Cherry*, *Full Black*, *Full Sour*, *Husk*, *Partial Black*, dan *Shell*, berhasil diklasifikasikan dengan *precision*, *recall*, dan *f1-score* sebesar 1.00, menandakan bahwa SVM mampu memisahkan seluruh fitur yang diekstraksi CNN dengan sangat baik pada data latih. Hanya sedikit variasi kecil terjadi pada kelas *Fade* dan *Partial Sour*, masing-masing dengan *F1-score* 0.98 dan 1.00, namun tetap menunjukkan performa yang sangat tinggi. Secara keseluruhan, hasil ini mengindikasikan bahwa integrasi CNN sebagai *extractor fitur* dan SVM sebagai *classifier* menghasilkan model yang sangat optimal pada fase pelatihan, di mana SVM mampu membentuk *decision boundary* yang jelas dan memaksimalkan margin antar kelas sehingga kesalahan klasifikasi hampir tidak terjadi.

[TRAIN CNN+SVM] Acc=0.9978 Macro P=0.9966 R=0.9975 F1=0.9970				
	precision	recall	f1-score	support
Broken	1.00	1.00	1.00	49
Cut	1.00	1.00	1.00	53
Dry Cherry	1.00	1.00	1.00	43
Fade	0.97	1.00	0.98	28
Full Black	1.00	1.00	1.00	33
Full Sour	1.00	1.00	1.00	60
Husk	1.00	1.00	1.00	42
Partial Black	1.00	1.00	1.00	52
Partial Sour	1.00	0.97	0.99	40
Shell	1.00	1.00	1.00	46
accuracy			1.00	446
macro avg	1.00	1.00	1.00	446
weighted avg	1.00	1.00	1.00	446

Gambar 8. Hasil Pelatihan Data

Untuk memastikan bahwa model benar-benar mempelajari pola visual dari tiap kelas cacat, beberapa sampel hasil klasifikasi pada data latih ditampilkan sebagaimana terlihat pada gambar. Setiap sampel menunjukkan *True Label* atau label sebenarnya, serta *Predicted Label* atau kelas yang diprediksi oleh model. Berdasarkan contoh yang ditampilkan, model mampu mengenali beragam kategori cacat seperti *Broken*, *Dry Cherry*, *Cut*, dan *Fade* dengan benar, yang menunjukkan bahwa fitur yang dipelajari CNN selama pelatihan telah dapat dijadikan dasar yang kuat bagi SVM dalam melakukan pemisahan kelas. Penyajian sampel hasil klasifikasi ini membuktikan bahwa proses pelatihan berjalan secara efektif, di mana model mampu

mempelajari hubungan antara karakteristik visual biji kopi dengan label kelasnya sebelum digunakan pada tahap pengujian.




Gambar 8. Sampel Hasil Pelatihan Data

4.3. Pengujian

Pada tahap pengujian, model CNN dan CNN-SVM dievaluasi menggunakan 20% data uji yang terdiri dari citra biji kopi berbagai kelas cacat, antara lain *Broken*, *Cut*, *Dry Cherry*, *Fade*, *Full Black*, *Full Sour*, *Husk*, *Partial Black*, *Partial Sour*, dan *Shell*. Seluruh citra uji diproses melalui tahapan *preprocessing* yang sama seperti pada data latih, kemudian diprediksi oleh kedua model untuk melihat performa klasifikasinya di kondisi nyata. Hasil pengujian ditunjukkan pada Gambar 9 dan 10, di mana setiap citra diperlihatkan bersama label sebenarnya (T: True) dan label prediksi model (P: Predicted).



Gambar 8. Sampel Hasil Pengujian Data CNN



Gambar 9. Sampel Hasil Pelatihan Data CNN-SVM

4.3.1. Pengujian CNN

Berdasarkan hasil pengujian pada Gambar 10, metode CNN dengan arsitektur *ResNet-50* menghasilkan akurasi sebesar 64,29%, *precision* rata-rata 66%, *recall* 63%, dan *F1-score* 63%. Hasil ini menunjukkan bahwa model mampu mengenali sebagian kelas dengan tingkat ketepatan yang cukup baik, meskipun performanya belum konsisten pada seluruh kategori cacat


biji kopi. Nilai precision tertinggi diperoleh pada kelas *Dry Cherry*, *Full Black*, dan *Shell* yang masing-masing mencapai sekitar 0,88–0,86, menandakan bahwa prediksi model pada kelas-kelas tersebut relatif akurat dan jarang menghasilkan kesalahan prediksi. Sementara itu, kelas dengan recall tertinggi yaitu *Broken* sebesar 1,00, yang menunjukkan bahwa seluruh citra pada kelas tersebut berhasil terdeteksi dengan benar oleh model.

Namun demikian, terdapat kelas yang menunjukkan performa rendah, seperti *Fade* dengan F1-score 0,50 dan *Partial Sour* dengan F1-score 0,41, yang mengindikasikan bahwa model masih kesulitan dalam mengenali pola visual pada kelas tersebut. Faktor penyebabnya dapat berupa kemiripan tekstur dan warna antar kelas serta jumlah citra yang tidak merata, yang dapat memengaruhi kualitas pembelajaran model. Secara keseluruhan, hasil ini menunjukkan bahwa CNN sebagai classifier masih memiliki keterbatasan dalam memisahkan kelas dengan karakteristik visual yang saling berdekatan.

[TEST-CNN] Acc = 0.6428571428571429				
	precision	recall	f1-score	support
Broken	0.68	1.00	0.81	13
Cut	0.48	0.85	0.61	13
Dry Cherry	0.88	0.64	0.74	11
Fade	0.60	0.43	0.50	7
Full Black	0.86	0.75	0.80	8
Full Sour	0.55	0.40	0.46	15
Husk	0.75	0.82	0.78	11
Partial Black	0.69	0.69	0.69	13
Partial Sour	0.29	0.20	0.24	10
Shell	0.86	0.55	0.67	11
accuracy			0.64	112
macro avg	0.66	0.63	0.63	112
weighted avg	0.66	0.64	0.63	112

Gambar 10. Hasil Pengujian CNN

Berdasarkan hasil confusion matrix pada Gambar 11, model CNN dengan arsitektur *ResNet-50* menunjukkan kemampuan yang cukup baik dalam mengenali beberapa kelas dengan ciri visual yang kuat, seperti *Broken* dan *Cut*. Pada kelas *Broken*, seluruh 13 citra terklasifikasi benar, sementara kelas *Cut* juga mencapai 11 prediksi benar dari total 13 sampel. Kelas *Dry Cherry*, *Full Black*, *Husk*, dan *Shell* juga menunjukkan performa yang relatif baik dengan jumlah prediksi benar yang menonjol pada diagonal matriks. Namun, model masih mengalami kesalahan klasifikasi pada kelas-kelas yang memiliki kemiripan warna, bentuk, atau tekstur, seperti *Fade*, *Full Sour*, dan *Partial Sour*, yang sering diprediksi sebagai kelas lain.



Gambar 11. Confusion Matrix CNN

4.3.2. Pengujian CNN-SVM

Berdasarkan hasil pengujian pada Gambar 12, metode CNN-SVM dengan arsitektur *ResNet-50* menunjukkan peningkatan performa dibandingkan CNN murni, dengan akurasi


sebesar 77,68%, precision rata-rata 80,04%, recall 77,15%, dan f1-score 77,47%. Hasil ini memperlihatkan bahwa menunjukkan bahwa perpaduan CNN sebagai ekstraktor fitur dan SVM sebagai klasifikator mampu meningkatkan kemampuan model dalam mengenali berbagai kelas cacat biji kopi. Beberapa kelas seperti *Dry Cherry*, *Full Black*, *Husk*, dan *Shell* memiliki nilai *F1-score* tertinggi, berada pada kisaran 0,88-1,00, yang menunjukkan bahwa model dapat mendeteksi kelas-kelas tersebut dengan sangat baik dan konsisten.

Sementara itu, kelas seperti *Fade* dan *Partial Sour* masih menunjukkan nilai *F1-score* yang lebih rendah, masing-masing sebesar 0,55 dan 0,42, sehingga mengindikasikan bahwa model masih mengalami kesulitan dalam membedakan biji kopi dengan karakteristik visual yang serupa atau dengan tekstur yang kurang tegas. Meskipun demikian, peningkatan nilai *macro average* dan *weighted average* pada seluruh metrik menunjukkan bahwa integrasi CNN-SVM berhasil memperbaiki generalisasi model dibandingkan CNN murni, terutama dalam meminimalkan kesalahan prediksi pada kelas yang sebelumnya sulit ditemukan. Dengan demikian, penerapan metode CNN-SVM terbukti lebih efektif dan stabil dalam mengklasifikasikan mutu biji kopi berdasarkan tekstur dan warna dibandingkan CNN saja.

[TEST CNN+SVM] Acc=0.7768 Macro P=0.8004 R=0.7715 F1=0.7747				
	precision	recall	f1-score	support
Broken	0.89	0.62	0.73	13
Cut	0.67	0.62	0.64	13
Dry Cherry	1.00	0.91	0.95	11
Fade	0.75	0.43	0.55	7
Full Black	0.89	1.00	0.94	8
Full Sour	0.67	0.80	0.73	15
Husk	1.00	1.00	1.00	11
Partial Black	1.00	0.85	0.92	13
Partial Sour	0.36	0.50	0.42	10
Shell	0.79	1.00	0.88	11
accuracy			0.78	112
macro avg	0.80	0.77	0.77	112
weighted avg	0.80	0.78	0.78	112

Gambar 12. Hasil Pengujian CNN-SVM

Berdasarkan hasil *confusion matrix* pada Gambar 13, model CNN-SVM dengan arsitektur ResNet-50 menunjukkan kemampuan klasifikasi yang lebih akurat dan stabil dibandingkan CNN murni. Beberapa kelas seperti *Dry Cherry*, *Husk*, dan *Shell* berhasil dikenali dengan sangat baik, masing-masing menghasilkan 10, 11, dan 11 prediksi benar tanpa adanya kesalahan ke kelas lain. Kelas seperti *Full Sour* dan *Partial Black* juga menunjukkan performa kuat dengan 12 dan 11 prediksi benar, menegaskan bahwa kombinasi fitur CNN dan margin klasifikasi SVM memberikan keputusan yang konsisten pada kelas dengan pola tekstur yang jelas.



Gambar 13. Confusion Matrix CNN-SVM

4.4. Analisis Pembahasan

Hasil pengujian terhadap dua metode klasifikasi citra biji kopi, yaitu CNN murni dan CNN-SVM, menunjukkan adanya perbedaan kinerja yang cukup jelas pada setiap metrik evaluasi. Model CNN murni menghasilkan akurasi sebesar 64,29%, sedangkan model CNN-SVM mencapai akurasi sebesar 77,68%. Peningkatan sebesar 13,39% ini menunjukkan bahwa penggantian lapisan klasifikasi *Softmax* dengan *Support Vector Machine* (SVM) mampu meningkatkan kemampuan model dalam membedakan citra antar kelas dengan lebih baik dan lebih konsisten.

Perbedaan performa ini dapat dijelaskan melalui mekanisme klasifikasi dari masing-masing metode. Pada CNN murni, proses klasifikasi dilakukan oleh lapisan *fully connected* dan *Softmax* yang bekerja optimal pada data berukuran besar dengan distribusi kelas yang seimbang. Namun, pada dataset biji kopi yang relatif terbatas dan memiliki kemiripan visual tinggi seperti antara *Full Sour* dan *Partial Sour* atau antara *Fade* dan *Partial Black*, *Softmax* sering mengalami kesulitan dalam memisahkan batas antar kelas secara tegas. Sebaliknya, metode SVM bekerja dengan mencari hyperplane optimal yang memaksimalkan margin antar kelas di ruang fitur hasil ekstraksi CNN. Pendekatan ini membantu model CNN-SVM untuk mempertahankan kemampuan klasifikasi yang baik meskipun data pelatihan terbatas dan variasi visual antar kelas sangat mirip.

Penelitian ini juga mendukung beberapa penelitian terdahulu, Mujiono et al. [6] menerapkan metode kombinasi CNN-SVM untuk mengklasifikasikan kondisi kesegaran daging ayam dari citra, dengan mencapai akurasi hingga 95%, yang menekankan keunggulan CNN-SVM dalam menangani data terbatas dan variasi visual, penelitian ini memperkuat aspek tersebut dengan menerapkan metode serupa pada biji kopi. Selain itu, Munthe et al. [9] menerapkan ResNet-50 untuk membedakan tiga jenis biji kopi Temanggung (Arabica, Excelsa, dan Robusta) dan mencapai akurasi 96%, yang menunjukkan efektivitas arsitektur residual dalam dataset seimbang, meskipun akurasi lebih rendah yaitu 77,68% karena menangani lebih banyak kelas cacat yang kompleks. Sementara itu, Arwatchananukul et al. [13] menggunakan MobileNetV3 untuk mengklasifikasikan 17 jenis cacat biji kopi Arabica Thailand dan memperoleh akurasi 88,63%, yang lebih tinggi dari penelitian ini. Namun, pendekatan CNN-SVM kami memberikan penguatan pada aspek efisiensi komputasi untuk dataset terbatas. Dengan demikian, penelitian ini memperkuat bukti bahwa pendekatan CNN-SVM tetap memberikan performa terbaik untuk klasifikasi citra biji kopi pada dataset terbatas dengan kemiripan visual tinggi.

5. Simpulan

Dengan merujuk pada hasil penelitian yang telah dilakukan, dapat dinyatakan bahwa penerapan metode CNN-SVM dengan arsitektur ResNet-50 mampu menghasilkan performa yang lebih unggul dibandingkan dengan metode CNN konvensional dalam mengklasifikasikan mutu biji kopi berdasarkan jenis cacat dan warna. Model CNN biasa memiliki akurasi sebesar 64,29%, sedangkan model CNN-SVM mencapai 77,68%, sehingga peningkatan akurasi mencapai 13,39%. Nilai *precision*, *recall*, dan *F1-score* pada model CNN-SVM juga menunjukkan peningkatan dibandingkan model CNN biasa, yang menegaskan bahwa pendekatan ini lebih stabil dan akurat dalam mengenali berbagai jenis cacat biji kopi. Penelitian ini masih memiliki peluang untuk dikembangkan lebih lanjut, antara lain melalui penambahan jumlah data latih, pengoptimalan parameter kernel pada SVM, serta penerapan teknik augmentasi data yang lebih beragam guna meningkatkan ketepatan hasil klasifikasi.

Daftar Referensi

- [1] Badan Pusat Statistik, "Ekspor Kopi Menurut Negara Tujuan Utama, 2000-2024," Badan Pusat Statistik.
- [2] M. P. Sirappa, R. Heryanto, and Y. R. Silitonga, "Standardisasi Pengolahan Biji Kopi Berkualitas," *Warta BSIP Perkebunan*, 2024.
- [3] K. K. Rangga and N. Pardani, "Analisis Proses Pascapanen Kopi di Pusat Pelatihan Pertanian dan Pedesaan Swadaya (P4S) Kopi Gunung Ikamaja Kecamatan Sumberjaya Kabupaten Lampung Barat," *Jurnal Agro Industri Perkebunan*, pp. 117–128, Jul. 2024, doi: 10.25181/JAIP.V12I2.3481.
- [4] M. D. Darajat, Y. A. Sari, and R. C. Wihandika, "Convolutional Neural Network for Indonesian Special Food Classification," *Jurnal Pengembangan Teknologi Informasi dan*

- Ilmu Komputer*, vol. 5, no. 11, pp. 4764–4769, Oct. 2021, Accessed: Oct. 17, 2025. [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/10096>
- [5] K. U. Putra, A. Ramadhanu, and S. Arlis, "Identifikasi Varietas Kopi Berdasarkan Analisis Warna dan Tekstur Menggunakan Metode Convolutional Neural Network," *Bulletin of Computer Science Research*, vol. 5, no. 5, pp. 1188–1194, Aug. 2025, doi: 10.47065/BULLETCSR.V5I5.759.
- [6] A. Agung Mujiono, E. Yulia Puspaningrum Informatika, U. Pembangunan Nasional, J. Timur Ji Raya Rungkut Madya, and G. Anyar, "Implementasi Model Hybrid CNN-SVM pada Klasifikasi Kondisi Kesegaran Daging Ayam," *Jurnal Mahasiswa Teknik Informatika*, vol. 8, no. 1, pp. 756–763, Mar. 2024.
- [7] D. Gusmaliza and S. Aminah, "Sistem Identifikasi Kualitas Biji Kopi Robusta berbasis Image Processing dengan Support Vector Machine," *Edumatic: Jurnal Pendidikan Informatika*, vol. 8, no. 2, pp. 744–753, Dec. 2024, doi: 10.29408/EDUMATIC.V8I2.28008.
- [8] H. Apriani, J. H. Jaman, and R. I. Adam, "SVM optimization using a grid search algorithm to identify robusta coffee bean images based on circularity and eccentricity," *Jurnal Teknologi dan Sistem Komputer*, vol. 10, no. 1, pp. 12–19, Jan. 2022, doi: 10.14710/jtsiskom.2021.13807.
- [9] T. Pascal Munthe, M. Akbar, F. Teknologi Informasi, and U. Mercu Buana Yogyakarta, "Klasifikasi Citra Biji Kopi Temanggung Menggunakan Residual Network (ResNet-50)," *Jurnal Pustaka Data (Pusat Akses Kajian Database, Analisa Teknologi, dan Arsitektur Komputer)*, vol. 5, no. 1, pp. 94–102, Jun. 2025, doi: 10.55382/JURNALPUSTAKADATA.V5I1.1028.
- [10] N. N. Amanina and G. W. Saraswati, "Classification of Arabica Coffee Green Beans Using Digital Image Processing Using the K-Nearest Neighbor Method," *(JAIS) Journal of Applied Intelligent System*, vol. 7, no. 2, pp. 111–119, Sep. 2022, doi: 10.33633/JAIS.V7I2.6449.
- [11] I. M. Pakaya, R. Radi, and B. Purwantana, "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)*, vol. 13, no. 3, pp. 924–932, Aug. 2024, doi: 10.23960/JTEP-L.V13I3.924-932.
- [12] M. Murinto, M. Rosyda, and M. Melany, "Klasifikasi Jenis Biji Kopi Menggunakan Convolutional Neural Network dan Transfer Learning pada Model VGG16 dan MobileNetV2," *JRST (Jurnal Riset Sains dan Teknologi)*, vol. 7, no. 2, p. 183, Sep. 2023, doi: 10.30595/JRST.V7I2.16788.
- [13] S. Arwatchananukul, D. Xu, P. Charoenkwan, S. Aung Moon, and R. Saengrayap, "Implementing a deep learning model for defect classification in Thai Arabica green coffee beans," *Smart Agricultural Technology*, vol. 9, p. 100680, Dec. 2024, doi: 10.1016/J.ATECH.2024.100680.
- [14] R. Yohannes and M. E. Al Rifan, "Klasifikasi Jenis Kanker Kulit Menggunakan CNN-SVM," *Algoritme Jurnal Mahasiswa Teknik Informatika*, vol. 2, no. 2, pp. 133–144, Apr. 2022, doi: 10.35957/ALGORITME.V2I2.2363.
- [15] Y. Yohannes, D. Udjulawa, and F. Febbiola, "Klasifikasi Lukisan Karya Van Gogh Menggunakan Convolutional Neural Network-Support Vector Machine," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 7, no. 1, pp. 2443–2229, Apr. 2021, doi: 10.28932/JUTISI.V7I1.3399.
- [16] M. Azhari, Z. Situmorang, and R. Rosnelly, "Perbandingan Akurasi, Recall, dan Presisi Klasifikasi pada Algoritma C4.5, Random Forest, SVM dan Naive Bayes," *Jurnal Media Informatika Budidarma*, vol. 5, no. 2, pp. 640–651, Apr. 2021, doi: 10.30865/MIB.V5I2.2937.
- [17] A.A. Asyer, & M. A. I. P. I. Pakereng, "Analisis Sentimen Tweet Pengguna Twitter Terkait Diabetes Menggunakan Metode Naive Bayes." *Jutisi: Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, vol. 12, no. 2, pp. 627-636, 2023. doi: <http://dx.doi.org/10.35889/jutisi.v12i2.1234>