

Klasifikasi Kualitas Biji Kopi Secara Otomatis Berbasis Citra Visual Menggunakan *Convolutional Neural Network (CNN)*

Raihan Rifandi¹, Erni Rouza¹, Al-Khawarizmi¹, Alzianda Putra Desmara¹, Muhammad Noersyal¹, Muhammad Ikhsan Alfajri¹

¹ Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pasir Pengaraian, Rokan Hulu, Indonesia
Jl. Raya Kumu, Rambah, Rokan Hulu, Riau, 28557, Indonesia.

Email: ¹reyrifandi27@gmail.com, ²ernirouzait@gmail.com, ³rizminst128@gmail.com, ⁴nandaputramelayu@gmail.com,
⁵muhammadnurshal09@gmail.com, ⁶muhammadikhsanalfajri2022@gmail.com

(* : coressponding author)

Abstrak—Kualitas biji kopi merupakan faktor penting yang menentukan nilai jual dan mutu produk kopi. Pada praktiknya, proses penilaian kualitas biji kopi masih banyak dilakukan secara manual melalui pengamatan visual, sehingga berpotensi menimbulkan subjektivitas dan tidak konsisten hasil. Oleh karena itu, penelitian ini bertujuan untuk menerapkan *metode Convolutional Neural Network (CNN)* dalam mengklasifikasikan kualitas biji kopi secara otomatis berdasarkan citra visual. Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen komputasional. *Dataset* yang digunakan berupa 90 citra biji kopi yang dikelompokkan ke dalam tiga kelas kualitas, yaitu baik, sedang, dan buruk, dengan masing-masing kelas berjumlah 30 citra. Seluruh citra melalui tahap pra-pemrosesan yang meliputi *resizing* citra menjadi 150×150 piksel, normalisasi nilai piksel, serta penerapan data *augmentation*. Model CNN dibangun menggunakan *framework TensorFlow* dan Keras pada platform Google Colab, serta dilatih menggunakan optimizer Adam dan fungsi *loss categorical crossentropy* dengan jumlah *epoch* optimal sebanyak 20 *epoch*. Hasil penelitian menunjukkan bahwa model CNN mampu mempelajari pola visual dasar biji kopi secara bertahap, yang ditandai dengan peningkatan nilai akurasi dan penurunan nilai *loss* selama proses pelatihan. Namun, hasil evaluasi menggunakan *confusion matrix* menunjukkan bahwa model masih mengalami kesulitan dalam membedakan beberapa kategori kualitas yang memiliki kemiripan karakteristik visual, khususnya antara kelas baik, sedang, dan buruk. Meskipun demikian, penelitian ini membuktikan bahwa CNN memiliki potensi sebagai pendekatan awal dalam pengembangan sistem otomatis untuk membantu proses klasifikasi kualitas biji kopi secara objektif dan konsisten.

Kata Kunci: Biji Kopi; Klasifikasi Citra; Convolutional Neural Network; Deep Learning; Computer Vision.

Abstract—Coffee bean quality is a crucial factor that determines the commercial value and overall quality of coffee products. In practice, coffee bean quality assessment is still largely performed manually through visual inspection, which may lead to subjectivity and inconsistent results. Therefore, this study aims to apply a Convolutional Neural Network (CNN) method to automatically classify coffee bean quality based on visual images. This study employs a quantitative approach using a computational experimental method. The dataset consists of 90 coffee bean images categorized into three quality classes, namely good, medium, and poor, with 30 images in each class. All images undergo preprocessing stages, including image resizing to 150×150 pixels, pixel value normalization, and data augmentation. The CNN model is developed using the TensorFlow and Keras frameworks on the Google Colab platform and trained using the Adam optimizer and categorical crossentropy loss function with an optimal number of 20 epochs. The results show that the CNN model is able to learn basic visual patterns of coffee beans progressively, as indicated by an increase in accuracy and a decrease in loss values during the training process. However, evaluation using a confusion matrix reveals that the model still faces difficulties in distinguishing between quality classes with similar visual characteristics, particularly between the good, medium, and poor categories. Nevertheless, this study demonstrates that CNN has strong potential as an initial approach for developing an automated system to support objective and consistent coffee bean quality classification.

Keywords: Coffee Beans; Image Classification; Convolutional Neural Network; Deep Learning; Computer Vision.

1. PENDAHULUAN

Kopi merupakan salah satu komoditas pertanian unggulan yang memiliki nilai ekonomi tinggi dan peran strategis dalam perdagangan global. Permintaan kopi terus meningkat seiring dengan pertumbuhan industri minuman, perubahan gaya hidup masyarakat, serta meningkatnya konsumsi kopi di berbagai negara. Dalam industri kopi, kualitas biji kopi menjadi faktor utama yang menentukan harga jual, daya saing produk, dan tingkat kepuasan konsumen. Oleh karena itu, proses penilaian dan pengendalian kualitas biji kopi memegang peranan penting dalam menjaga mutu produk serta keberlanjutan industri kopi secara keseluruhan [1], [2].

Penilaian kualitas biji kopi pada umumnya dilakukan berdasarkan karakteristik fisik dan visual, seperti warna permukaan, ukuran biji, bentuk, tingkat kecacatan, serta keseragaman. Namun, dalam praktiknya proses sortasi dan klasifikasi kualitas biji kopi masih banyak dilakukan secara manual melalui pengamatan visual oleh tenaga ahli. Pendekatan manual tersebut memiliki sejumlah keterbatasan, antara lain bersifat subjektif, membutuhkan waktu yang relatif lama, serta berpotensi menghasilkan penilaian yang tidak konsisten, terutama ketika diterapkan pada skala produksi yang besar [3], [4]. Kondisi ini mendorong perlunya pengembangan sistem otomatis yang mampu melakukan klasifikasi kualitas biji kopi secara objektif dan efisien.

Perkembangan teknologi kecerdasan buatan (*artificial intelligence*) dan pengolahan citra digital (*computer vision*) telah membuka peluang baru dalam analisis kualitas produk pertanian. Pendekatan berbasis citra memungkinkan sistem untuk mengekstraksi informasi visual secara sistematis dan terukur, sehingga dapat digunakan sebagai dasar pengambilan keputusan yang lebih akurat dibandingkan pengamatan manual [5], [6]. Dalam konteks biji kopi, citra visual dapat

merepresentasikan perbedaan kualitas melalui variasi warna, tekstur permukaan, dan bentuk biji, yang menjadi indikator penting dalam proses klasifikasi kualitas [7].

Berbagai metode *machine learning* telah diterapkan dalam penelitian klasifikasi kualitas produk pertanian, termasuk biji kopi. Metode seperti *Support Vector Machine* (SVM), *k-Nearest Neighbor* (k-NN), dan *decision tree* telah digunakan untuk mengklasifikasikan kualitas biji kopi berdasarkan fitur visual tertentu [8], [9]. Meskipun demikian, metode konvensional tersebut umumnya memerlukan proses ekstraksi fitur secara manual, sehingga performa sistem sangat bergantung pada kualitas fitur yang dirancang oleh peneliti. Selain itu, metode tersebut cenderung kurang optimal dalam menangani kompleksitas visual yang tinggi serta variasi data citra yang beragam [10].

Sebagai alternatif, pendekatan *deep learning* semakin banyak digunakan dalam bidang pengolahan citra, khususnya untuk tugas klasifikasi objek. Salah satu arsitektur *deep learning* yang paling umum digunakan adalah *Convolutional Neural Network* (CNN). CNN memiliki kemampuan untuk mempelajari fitur visual secara otomatis melalui proses pembelajaran berlapis tanpa memerlukan perancangan fitur secara eksplisit. Kemampuan ini menjadikan CNN efektif dalam menangani citra dengan kompleksitas tinggi dan variasi visual yang luas [11], [12]. CNN mampu mengekstraksi fitur tingkat rendah hingga tingkat tinggi secara hierarkis langsung dari citra mentah.

Dalam penelitian kontemporer, banyak penyelidikan telah menunjukkan bahwa *Convolutional Neural Networks* (CNN) menunjukkan kinerja yang unggul dibandingkan dengan teknik pembelajaran mesin tradisional dalam kategorisasi gambar yang berkaitan dengan komoditas pertanian. CNN telah berhasil diterapkan pada klasifikasi kualitas buah, sayuran, biji-bijian, serta deteksi cacat produk pertanian dengan tingkat akurasi yang tinggi [13], [14]. Pada konteks biji kopi, penelitian berbasis CNN menunjukkan kemampuan model dalam mengenali perbedaan kualitas biji kopi berdasarkan karakteristik visual permukaan biji [15], [16].

Meskipun demikian, beberapa penelitian juga melaporkan bahwa CNN masih menghadapi tantangan dalam membedakan kelas kualitas yang memiliki kemiripan visual tinggi, terutama ketika jumlah dan variasi *dataset* yang digunakan relatif terbatas [17], [18]. Keterbatasan data latih dapat menyebabkan model mengalami kesulitan dalam membentuk batas keputusan yang optimal antar kelas kualitas. Selain itu, sebagian penelitian sebelumnya masih berfokus pada klasifikasi dua kelas kualitas atau menggunakan *dataset* dengan skema pelabelan yang sederhana, sedangkan dalam praktik industri kopi, kualitas biji kopi umumnya diklasifikasikan ke dalam lebih dari dua kategori, seperti baik, sedang, dan buruk, yang memiliki perbedaan visual yang tidak selalu tegas [19].

Berdasarkan telaah penelitian terdahulu, dapat diidentifikasi adanya *research gap* terkait penerapan CNN sebagai model dasar (*baseline*) dalam klasifikasi kualitas biji kopi multi-kelas pada *dataset* dengan jumlah dan variasi citra yang terbatas [20]. Sebagian besar penelitian berfokus pada penggunaan arsitektur CNN yang kompleks atau *dataset* berskala besar, sementara analisis kinerja CNN pada skenario data terbatas, termasuk pola kesalahan klasifikasi antar kelas, masih belum banyak dibahas secara mendalam. Oleh karena itu, diperlukan penelitian yang mengevaluasi kemampuan CNN sebagai pendekatan awal yang sistematis dan terukur dalam klasifikasi kualitas biji kopi berbasis citra visual.

Berdasarkan latar belakang dan kesenjangan penelitian tersebut, tujuan penelitian ini adalah untuk menerapkan metode *Convolutional Neural Network* (CNN) sebagai pendekatan awal dalam mengklasifikasikan kualitas biji kopi secara otomatis berdasarkan citra visual. Penelitian ini bertujuan untuk mengevaluasi kemampuan CNN dalam mempelajari pola visual biji kopi pada skema klasifikasi multi-kelas, yaitu kualitas baik, sedang, dan buruk, serta menganalisis kinerja model menggunakan metrik akurasi dan *confusion matrix*. Selain itu, penelitian ini juga bertujuan untuk mengidentifikasi keterbatasan model CNN pada dataset dengan jumlah dan variasi citra yang terbatas sebagai dasar pengembangan penelitian selanjutnya. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem otomatis untuk klasifikasi kualitas biji kopi yang lebih objektif dan konsisten, serta menjadi acuan awal bagi penelitian selanjutnya dalam penerapan *deep learning* pada klasifikasi kualitas produk pertanian berbasis citra visual.

2. METODOLOGI PENELITIAN

Penelitian ini menerapkan pendekatan kuantitatif melalui skema eksperimen komputasional untuk melakukan klasifikasi kualitas biji kopi berbasis citra visual. Algoritma utama yang digunakan adalah *Convolutional Neural Network* (CNN), yaitu salah satu arsitektur *deep learning* yang banyak digunakan dalam pengolahan citra karena kemampuannya dalam melakukan pembelajaran fitur visual secara otomatis tanpa memerlukan proses ekstraksi fitur manual [21], [11]. Penyusunan metodologi penelitian difokuskan pada pemaparan tahapan penelitian yang terstruktur serta pembahasan penerapan CNN sebagai metode inti dalam menyelesaikan permasalahan klasifikasi kualitas biji kopi.

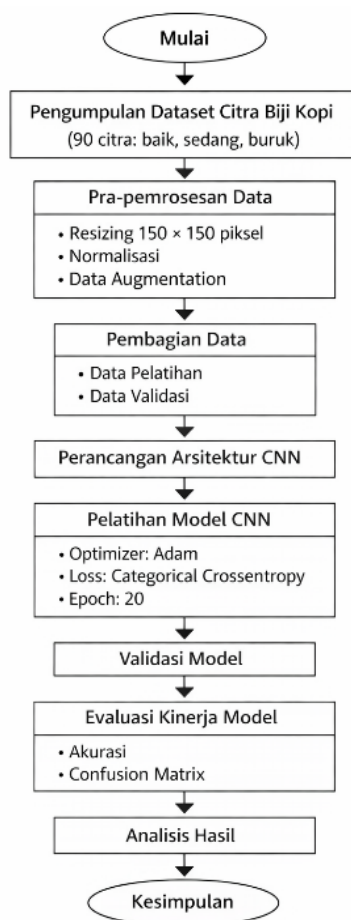
2.1 Tahapan Penelitian

Tahapan penelitian dimulai dengan kegiatan pengumpulan dan penyusunan dataset citra biji kopi yang dibagi ke dalam tiga kategori kualitas, yaitu baik, sedang, dan buruk. Penyusunan dataset dilakukan secara seimbang pada setiap kelas kualitas agar distribusi data tetap proporsional, sehingga potensi bias model selama proses pembelajaran dapat diminimalkan dan setiap kelas memiliki peran yang setara dalam proses pelatihan jaringan saraf [16]. Setelah *dataset* tersusun, seluruh citra selanjutnya melalui tahapan pra-pemrosesan (*preprocessing*) untuk menyesuaikan karakteristik data dengan spesifikasi *input* model *Convolutional Neural Network* (CNN). Pada tahap ini dilakukan beberapa proses utama, antara lain perubahan ukuran citra menjadi 150×150 piksel, normalisasi nilai piksel ke dalam rentang 0 hingga

1, serta penerapan teknik *augmentasi* data seperti rotasi dan pembalikan citra (*flipping*). Penerapan *augmentasi* data bertujuan untuk memperkaya variasi citra latih dan meningkatkan kemampuan generalisasi model, khususnya pada kondisi *dataset* dengan jumlah citra yang terbatas, sehingga risiko terjadinya *overfitting* dapat dikurangi [15], [17].

Tahap selanjutnya adalah perancangan arsitektur CNN dan proses pelatihan model menggunakan data latih yang telah dipra-pemrosesan. Proses pelatihan dilakukan secara berulang (*iteratif*) dengan mekanisme penyesuaian bobot dan bias jaringan untuk menurunkan nilai fungsi *loss*. Penentuan jumlah *epoch* tidak ditetapkan secara langsung, melainkan diperoleh melalui eksperimen awal dengan mengamati kecenderungan perubahan nilai akurasi dan *loss* hingga model mencapai kondisi pembelajaran yang stabil dan konvergen. Setelah pelatihan selesai, model diuji menggunakan data validasi untuk mengevaluasi kemampuan generalisasi terhadap data yang tidak terlibat dalam proses pelatihan.

Tahap akhir penelitian berfokus pada evaluasi kinerja model dengan menggunakan metrik akurasi serta analisis *confusion matrix*. Analisis *confusion matrix* digunakan untuk mengidentifikasi pola kesalahan klasifikasi antar kelas kualitas biji kopi sekaligus menilai keseimbangan performa model pada setiap kategori kualitas [22]. Secara keseluruhan, rangkaian tahapan penelitian tersebut disajikan dalam bentuk diagram alir pada Gambar 1, menggambarkan alur penelitian secara runtut mulai dari pengumpulan data hingga evaluasi hasil klasifikasi.



Gambar 1. Flowchart Tahapan Penelitian

Gambar 1 menggambarkan fase berurutan dari penelitian yang dilakukan secara metodis. Tahap awal melibatkan akuisisi kumpulan data gambar biji kopi, yang dikategorikan ke dalam tiga klasifikasi kualitas yang berbeda: tinggi, sedang, dan rendah. Selanjutnya, data gambar mengalami fase pra-pemrosesan yang memerlukan pengubahan ukuran, normalisasi nilai *piksel*, dan teknik *augmentasi* data. Setelah ini, *dataset* dipartisi menjadi data pelatihan dan data validasi untuk memfasilitasi desain dan pelatihan model *Convolutional Neural Network*. Fase penutup dari penyelidikan meliputi validasi model dan penilaian kinerja menggunakan metrik akurasi dan matriks kebingungan, yang mendukung analisis hasil dan perumusan kesimpulan.

2.2 Arsitektur Model *Convolutional Neural Network*

Model *Convolutional Neural Network* (*CNN*) yang diterapkan dalam penelitian ini dibangun menggunakan beberapa komponen lapisan utama yang saling terhubung, yaitu *convolution layer*, *pooling layer*, dan *fully connected layer*. Lapisan konvolusi berperan sebagai tahap awal dalam proses ekstraksi fitur, di mana karakteristik visual dasar dari citra biji kopi, seperti tepi, tekstur permukaan, dan pola bentuk, dipelajari secara bertahap. Proses pembelajaran fitur ini berlangsung secara hierarkis, dimulai dari representasi visual tingkat rendah hingga fitur yang lebih kompleks pada lapisan berikutnya [11], [12]. Untuk mendukung proses pembelajaran yang lebih efisien, setiap lapisan konvolusi dilengkapi dengan fungsi

aktivasi *Rectified Linear Unit (ReLU)*. Penggunaan fungsi aktivasi ini bertujuan untuk mempercepat konvergensi model sekaligus meminimalkan permasalahan *vanishing gradient* yang umum terjadi pada jaringan saraf dalam. Selanjutnya, hasil ekstraksi fitur dari lapisan konvolusi diteruskan ke *pooling layer*, yang berfungsi untuk mereduksi dimensi fitur, menekan beban komputasi, serta meningkatkan ketahanan model terhadap variasi kecil pada citra masukan [23].

Fitur-fitur yang telah melalui proses konvolusi dan pooling kemudian diratakan melalui proses *flattening* sebelum diproses pada *fully connected layer*. Lapisan ini berfungsi sebagai tahap klasifikasi akhir dengan mengombinasikan seluruh fitur hasil ekstraksi untuk menentukan kelas kualitas biji kopi. Pada lapisan keluaran digunakan fungsi *aktivasi softmax* guna menghasilkan nilai probabilitas untuk setiap kelas kualitas, yaitu baik, sedang, dan buruk. Proses pelatihan jaringan dilakukan dengan menggunakan *optimizer Adam* dan fungsi *loss categorical crossentropy*, yang dikenal efektif dan stabil untuk permasalahan klasifikasi multi-kelas berbasis citra [13], [14].

Konfigurasi parameter pelatihan model CNN yang digunakan dalam penelitian ini dirangkum pada Tabel 1, yang mencakup ukuran citra *input*, jumlah kelas keluaran, jenis fungsi *aktivasi*, *optimizer*, fungsi *loss*, jumlah *epoch*, ukuran *batch*, serta teknik *augmentasi* data. Penentuan parameter tersebut didasarkan pada praktik umum dalam penelitian *deep learning* serta hasil pengujian awal, dengan tujuan memperoleh keseimbangan antara stabilitas proses pelatihan dan performa klasifikasi model.

Tabel 1. Parameter Pelatihan Model CNN

Parameter	Konfigurasi
Ukuran Input Citra	150 × 150 piksel
Jumlah Kelas Output	3 (baik, sedang, buruk)
Arsitektur Model	Convolutional Neural Network ReLU
Fungsi Aktivasi (Hidden)	Softmax
Fungsi Aktivasi (Output)	Adam
Optimizer	Categorical Crossentropy
Fungsi Loss	20
Jumlah Epoch	8
Batch Size	Rotasi, flipping
Teknik Augmentasi Data	Google Colab
Platform Implementasi	Python, TensorFlow, Keras
Bahasa & Framework	

Tabel 1 menunjukkan parameter pelatihan model CNN yang digunakan dalam penelitian ini. Pemilihan parameter dilakukan berdasarkan praktik umum dalam klasifikasi citra berbasis *deep learning* serta hasil eksperimen awal untuk memperoleh keseimbangan antara stabilitas pembelajaran dan performa model. Jumlah *epoch* ditentukan berdasarkan kondisi konvergensi model, sedangkan penggunaan *optimizer Adam* dan fungsi *loss categorical crossentropy* bertujuan untuk meningkatkan efektivitas pelatihan pada permasalahan klasifikasi multi-kelas.

2.3 Dataset Penelitian

Dataset yang digunakan dalam penelitian ini berupa citra biji kopi yang diperoleh dari *dataset* publik dan diseleksi secara cermat sesuai dengan kebutuhan serta tujuan penelitian. *Dataset* tersebut terdiri dari 90 citra biji kopi yang diklasifikasikan ke dalam tiga kelas kualitas, yaitu baik, sedang, dan buruk, dengan masing-masing kelas berjumlah 30 citra. Penyusunan *dataset* dilakukan secara seimbang untuk menghindari bias model selama proses pelatihan dan klasifikasi, sehingga model yang dibangun mampu mempelajari karakteristik visual setiap kelas kualitas secara proporsional dan menghasilkan kinerja klasifikasi yang lebih objektif. Dalam penelitian ini, penentuan kelas kualitas biji kopi dilakukan dengan mengacu pada ciri-ciri visual yang dapat diamati secara langsung, seperti warna permukaan biji, tingkat keseragaman bentuk, dan kondisi cacat fisik.

Penggunaan citra visual sebagai dasar penilaian kualitas sejalan dengan pandangan Chandra yang menyatakan bahwa pemrosesan citra digital memungkinkan karakteristik fisik biji kopi direpresentasikan dalam bentuk data kuantitatif yang objektif, sehingga mendukung proses klasifikasi yang lebih akurat dibandingkan pendekatan manual.

Tabel 2. Distribusi *Dataset* Penelitian

Kelas Biji Kopi	Jumlah Citra
Baik	30
Sedang	30
Buruk	30


Tabel 2 menunjukkan distribusi *dataset* citra biji kopi yang digunakan dalam penelitian ini. *Dataset* terdiri dari tiga kelas kualitas, yaitu baik, sedang, dan buruk, dengan jumlah citra yang sama pada setiap kelas, masing-masing sebanyak 30 citra. Penyusunan *dataset* secara seimbang dilakukan untuk menghindari bias model selama proses pelatihan dan memastikan bahwa setiap kelas kualitas memiliki kontribusi yang setara dalam pembelajaran model.

3. HASIL DAN PEMBAHASAN

3.1 Tahapan Metode *Convolutional Neural Network*

Pada bagian ini dijelaskan secara komprehensif tahapan penerapan metode *Convolutional Neural Network* (CNN) dalam menyelesaikan permasalahan klasifikasi kualitas biji kopi berbasis citra visual. Uraian disusun mengikuti alur pemrosesan CNN secara sistematis, dimulai dari tahap masukan data hingga diperoleh keluaran berupa prediksi kelas kualitas biji kopi. Proses implementasi diawali dengan penggunaan citra digital biji kopi yang telah dikumpulkan dan dikelompokkan ke dalam tiga kategori kualitas, yaitu baik, sedang, dan buruk. Setiap citra memiliki karakteristik visual yang beragam, seperti tekstur permukaan, bentuk biji, serta indikasi cacat fisik, yang menjadi sumber informasi utama dalam proses pembelajaran jaringan saraf tiruan. Selanjutnya, citra masukan dipersiapkan melalui tahap pra-pemrosesan (*preprocessing*) agar sesuai dengan spesifikasi input model CNN. Tahap ini meliputi penyesuaian ukuran citra menjadi 150×150 piksel untuk menyeragamkan dimensi data, normalisasi nilai piksel ke rentang 0 hingga 1 guna meningkatkan stabilitas dan kecepatan konvergensi selama pelatihan, serta penerapan teknik *data augmentation* seperti rotasi dan pembalikan citra. Teknik augmentasi ini bertujuan memperkaya variasi data latih sekaligus mengurangi potensi terjadinya *overfitting* akibat keterbatasan jumlah dataset.

Citra yang telah melalui tahap pra-pemrosesan kemudian diproses pada lapisan konvolusi (*convolution layer*). Pada tahap ini, filter konvolusi diterapkan untuk mengekstraksi fitur visual awal, seperti pola tepi, tekstur, dan struktur permukaan biji kopi. Untuk meningkatkan kemampuan model dalam mempelajari hubungan non-linear, fungsi aktivasi *Rectified Linear Unit* (ReLU) digunakan pada setiap hasil konvolusi. Keluaran dari lapisan konvolusi selanjutnya diteruskan ke lapisan *pooling*, yang berfungsi mereduksi ukuran fitur, menekan kompleksitas komputasi, serta meningkatkan ketahanan model terhadap variasi kecil pada citra masukan. Tahap berikutnya adalah proses klasifikasi melalui lapisan *fully connected*, di mana seluruh fitur hasil ekstraksi digabungkan untuk menentukan kategori kualitas biji kopi. Pada lapisan keluaran digunakan fungsi aktivasi *softmax* untuk menghasilkan nilai probabilitas pada masing-masing kelas kualitas, yaitu baik, sedang, dan buruk. Seluruh rangkaian tahapan implementasi CNN tersebut dirangkum dalam bentuk diagram alir untuk memperjelas alur pemrosesan dari tahap awal hingga diperoleh hasil klasifikasi akhir.



Gambar 2. Grafik Akurasi dan *Loss* Selama Proses Pelatihan Model CNN

Gambar 2 memperlihatkan skema penerapan metode *Convolutional Neural Network* (CNN) dalam sistem klasifikasi kualitas biji kopi berbasis citra. Alur proses dimulai dari citra biji kopi sebagai data masukan yang merepresentasikan kondisi visual sesuai kategori kualitas yang telah ditentukan sebelumnya. Citra masukan selanjutnya diproses melalui tahap pra-pemrosesan, yang mencakup penyesuaian ukuran citra, normalisasi intensitas piksel, serta penerapan teknik augmentasi data untuk meningkatkan keberagaman data latih. Tahapan ini bertujuan untuk memastikan keseragaman input sekaligus memperkuat kemampuan model dalam mengenali variasi visual biji kopi. Tahap berikutnya adalah proses ekstraksi fitur yang dilakukan pada lapisan konvolusi.

Pada tahap ini, CNN mempelajari pola visual utama melalui penerapan filter konvolusi yang dikombinasikan dengan fungsi aktivasi ReLU. Proses ini diikuti oleh lapisan *pooling* yang berfungsi menyederhanakan representasi fitur dengan tetap mempertahankan informasi penting. Fitur yang telah diproses kemudian diratakan dan diteruskan ke lapisan

fully connected sebagai tahap akhir klasifikasi. Pada lapisan keluaran, fungsi aktivasi *softmax* digunakan untuk menghasilkan probabilitas prediksi terhadap masing-masing kelas kualitas biji kopi.

3.2 Proses Pelatihan Model *Convolutional Neural Network*

Tahap pelatihan model *Convolutional Neural Network* (CNN) dilaksanakan setelah seluruh data citra melewati proses pra-pemrosesan. Pada tahap ini, *dataset* yang telah disiapkan dipisahkan menjadi dua bagian utama, yaitu data pelatihan dan data validasi. Pemisahan ini dilakukan untuk memastikan bahwa kinerja model tidak hanya bergantung pada data yang digunakan untuk melatih jaringan, tetapi juga mampu diuji kemampuannya dalam mengenali pola pada data yang belum pernah dipelajari sebelumnya. Dengan demikian, kemampuan generalisasi model dapat dievaluasi secara lebih objektif. Proses pelatihan jaringan CNN dalam penelitian ini menggunakan *optimizer* Adam, yang dipilih karena kemampuannya dalam menyesuaikan nilai laju pembelajaran secara dinamis pada setiap parameter jaringan. *Optimizer* ini mengintegrasikan konsep momentum dan penyesuaian *learning rate* adaptif, sehingga dapat mempercepat proses konvergensi sekaligus menjaga kestabilan pembelajaran.

Untuk mengukur kesalahan prediksi model, digunakan fungsi *loss categorical crossentropy*, yang sesuai untuk permasalahan klasifikasi citra dengan lebih dari dua kelas. Fungsi *loss* ini berperan dalam menghitung selisih antara probabilitas prediksi yang dihasilkan model dengan label kelas sebenarnya pada setiap citra biji kopi. Model CNN dilatih selama 20 *epoch*. Penentuan jumlah *epoch* tersebut didasarkan pada eksperimen awal dengan mengamati pola perubahan nilai akurasi dan *loss* selama proses pelatihan berlangsung. Jumlah *epoch* dipilih pada kondisi ketika model menunjukkan kecenderungan pembelajaran yang stabil, yang ditandai dengan peningkatan akurasi serta penurunan *loss* secara bertahap dan konsisten. Selama setiap iterasi pelatihan, bobot dan bias jaringan diperbarui secara berulang untuk meminimalkan nilai *loss* yang dihasilkan. Untuk memantau kinerja model secara visual, perkembangan proses pelatihan ditampilkan dalam bentuk grafik akurasi dan *loss*.

Grafik akurasi menggambarkan tingkat ketepatan model dalam memprediksi kelas kualitas biji kopi pada setiap *epoch*, sedangkan grafik *loss* menunjukkan besarnya kesalahan prediksi yang terjadi. Pola peningkatan akurasi yang diikuti oleh penurunan nilai *loss* mengindikasikan bahwa model berhasil mempelajari karakteristik visual citra biji kopi secara bertahap. Selain itu, visualisasi ini juga dimanfaatkan untuk mendeteksi potensi permasalahan selama pelatihan, seperti *overfitting* atau *underfitting*. Dalam penelitian ini, perbandingan antara kinerja pada data pelatihan dan data validasi menunjukkan pola yang relatif seimbang, sehingga dapat disimpulkan bahwa model CNN memiliki proses pembelajaran yang cukup stabil dan mampu melakukan generalisasi dengan baik.



Gambar 3. Grafik Akurasi dan *Loss* Selama Proses Pelatihan Model CNN

Gambar 3 menggambarkan variasi dalam metrik akurasi dan kerugian sepanjang fase pelatihan model *Convolutional Neural Network* (CNN). Diamati bahwa metrik akurasi untuk kumpulan data pelatihan dan validasi menunjukkan lintasan ke atas bersamaan dengan perkembangan zaman, sedangkan metrik kerugian menunjukkan tren menurun, menandakan bahwa proses pembelajaran model berjalan secara efektif.

3.3 Evaluasi Kinerja Model *Confusion Matrix*

Evaluasi kinerja model (CNN) dilakukan untuk menilai tingkat ketepatan dan konsistensi model dalam mengklasifikasikan kualitas biji kopi berdasarkan citra visual. Pada penelitian ini, evaluasi performa tidak hanya didasarkan pada nilai akurasi, tetapi juga diperkuat dengan analisis *confusion matrix* sebagai alat evaluasi yang lebih komprehensif untuk permasalahan klasifikasi multi-kelas. Nilai akurasi digunakan untuk menggambarkan proporsi prediksi yang sesuai dengan label sebenarnya terhadap keseluruhan data uji, namun metrik ini belum mampu menjelaskan secara rinci distribusi kesalahan klasifikasi pada masing-masing kelas kualitas. Oleh karena itu, *confusion matrix* ternormalisasi digunakan untuk menganalisis pola hasil prediksi model secara lebih mendalam.

Confusion matrix menyajikan hubungan antara kelas aktual dan kelas hasil prediksi, di mana setiap baris merepresentasikan kelas sebenarnya dan setiap kolom menunjukkan kelas prediksi yang dihasilkan oleh model. Nilai

yang terdapat pada setiap sel menggambarkan proporsi data yang diklasifikasikan ke dalam kelas tertentu, sehingga memudahkan dalam mengidentifikasi tingkat keberhasilan maupun kesalahan klasifikasi pada setiap kategori kualitas biji kopi.

Berdasarkan hasil *confusion matrix*, dapat diamati bahwa model CNN memiliki performa yang lebih baik dalam mengenali kelas kualitas buruk dibandingkan kelas kualitas baik dan sedang. Hal ini menunjukkan bahwa karakteristik visual pada kelas buruk relatif lebih mudah dibedakan oleh model. Ciri-ciri seperti cacat fisik yang lebih jelas, tekstur permukaan yang tidak merata, serta bentuk biji yang kurang seragam memungkinkan model CNN mengekstraksi fitur yang lebih diskriminatif pada kelas tersebut. Sebaliknya, pada kelas kualitas baik dan sedang, masih ditemukan tingkat kesalahan klasifikasi yang cukup tinggi. Kesalahan ini menunjukkan adanya tumpang tindih karakteristik visual antar kelas, sehingga model mengalami kesulitan dalam membedakan kedua kelas tersebut secara tegas. Analisis *confusion matrix* ini memberikan wawasan penting mengenai pola kesalahan model dan menjadi dasar dalam mengevaluasi keterbatasan serta potensi pengembangan model pada penelitian selanjutnya.

	Baik			
True Label	Baik	4 / 30	2 / 30	24 / 30
	Sedang	1 / 30	3 / 30	26 / 30
	Buruk	5 / 30	2 / 30	23 / 30
		Baik	Sedang	Buruk
		Predicted Label		

Gambar 4. *Confusion Matrix* Ternormalisasi

Gambar 4 menampilkan *confusion matrix* ternormalisasi yang digunakan untuk mengevaluasi kinerja model *Convolutional Neural Network* (CNN) dalam mengklasifikasikan kualitas biji kopi ke dalam tiga kelas, yaitu baik, sedang, dan buruk. Setiap baris merepresentasikan kelas sebenarnya, sedangkan setiap kolom menunjukkan hasil prediksi model. Nilai pada setiap sel menunjukkan proporsi hasil klasifikasi terhadap total data pada kelas terkait. Hasil evaluasi menunjukkan bahwa model memiliki tingkat pengenalan yang lebih baik pada kelas kualitas buruk dibandingkan kelas baik dan sedang. Sebaliknya, pada kelas baik dan sedang masih ditemukan kesalahan klasifikasi yang cukup signifikan, yang mengindikasikan adanya kemiripan karakteristik visual antar kelas. Temuan ini menunjukkan bahwa meskipun model CNN mampu melakukan klasifikasi secara otomatis, pemisahan antar kelas kualitas biji kopi masih perlu ditingkatkan.

3.4 Pembahasan Hasil Klasifikasi

Berdasarkan hasil pelatihan dan evaluasi yang telah dilakukan, model *Convolutional Neural Network* (CNN) menunjukkan kemampuan dalam melakukan klasifikasi kualitas biji kopi secara otomatis dengan pola pembelajaran yang relatif stabil. Stabilitas proses pembelajaran ini ditunjukkan oleh tren peningkatan nilai akurasi serta penurunan nilai *loss* selama proses pelatihan berlangsung. Kondisi tersebut mengindikasikan bahwa model CNN mampu menyesuaikan bobot dan parameter internalnya secara bertahap untuk mempelajari pola visual dasar yang terdapat pada citra biji kopi, seperti tekstur permukaan, bentuk biji, serta karakteristik visual lain yang berkaitan dengan kualitas biji kopi. Temuan ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa CNN efektif dalam mengekstraksi fitur visual secara hierarkis pada permasalahan klasifikasi citra [12].

Meskipun demikian, hasil evaluasi menggunakan *confusion matrix* menunjukkan bahwa performa klasifikasi model belum sepenuhnya optimal pada seluruh kelas kualitas. Model cenderung memiliki performa yang lebih baik dalam mengenali kelas kualitas buruk dibandingkan kelas kualitas baik dan sedang. Hal ini mengindikasikan bahwa karakteristik visual biji kopi pada kelas buruk relatif lebih mudah dibedakan oleh model CNN. Ciri visual seperti cacat fisik yang lebih jelas, tekstur permukaan yang tidak merata, serta perbedaan bentuk yang lebih kontras memungkinkan model untuk mengekstraksi fitur yang lebih diskriminatif pada kelas tersebut. Hasil ini konsisten dengan temuan Q. Xu, L. Zhu, X. Cheng, dan B. Jiang, yang menunjukkan bahwa kelas dengan karakteristik visual ekstrem cenderung lebih mudah dikenali oleh model *deep learning* dibandingkan kelas dengan perbedaan visual yang subtil [24].

Sebaliknya, pada kelas kualitas baik dan sedang masih ditemukan tingkat kesalahan klasifikasi yang cukup tinggi. Kondisi ini menunjukkan bahwa model CNN mengalami kesulitan dalam membedakan kelas-kelas dengan tingkat kemiripan visual yang tinggi. Dalam konteks biji kopi, perbedaan antara kualitas baik dan sedang sering kali bersifat halus dan tidak selalu memiliki batas visual yang tegas. Variasi kecil pada warna permukaan, tingkat keseragaman bentuk,

atau tekstur biji kopi dapat menyebabkan tumpang tindih karakteristik visual antar kelas. Akibatnya, model kesulitan membentuk representasi fitur yang benar-benar diskriminatif untuk setiap kelas kualitas. Fenomena ini juga dilaporkan dalam penelitian lain yang menyoroti tantangan klasifikasi multi-kelas pada citra dengan kemiripan visual tinggi [18], [19]. Keterbatasan performa klasifikasi tersebut tidak terlepas dari faktor jumlah dan variasi *dataset* yang digunakan dalam penelitian ini.

Dataset yang terdiri dari 90 citra biji kopi dengan pembagian tiga kelas kualitas memberikan ruang pembelajaran yang relatif terbatas bagi model CNN. Dengan jumlah data yang terbatas, variasi pola visual yang dapat dipelajari oleh model menjadi kurang beragam, sehingga kemampuan model dalam menangkap kompleksitas karakteristik visual biji kopi pada setiap kelas kualitas belum optimal. Kondisi ini berdampak pada kemampuan generalisasi model, khususnya dalam membedakan kelas-kelas dengan karakteristik visual yang saling berdekatan. Hal ini sejalan dengan temuan Miranda dan Rubio-Manzano yang menyatakan bahwa performa model *deep learning* pada *dataset* berukuran kecil cenderung tidak seimbang antar kelas dan memerlukan analisis kesalahan yang lebih mendalam [20].

Meskipun terdapat keterbatasan tersebut, hasil penelitian ini tetap menunjukkan bahwa CNN memiliki potensi yang signifikan sebagai pendekatan awal (*baseline*) dalam pengembangan sistem otomatis untuk klasifikasi kualitas biji kopi berbasis citra visual. Model CNN mampu melakukan proses pembelajaran secara konsisten serta menghasilkan prediksi kelas kualitas biji kopi tanpa memerlukan proses ekstraksi fitur manual. Hal ini memperkuat temuan penelitian sebelumnya yang menyatakan bahwa CNN merupakan pendekatan yang efektif dan fleksibel dalam pengolahan citra produk pertanian [16].

Untuk meningkatkan performa klasifikasi pada penelitian selanjutnya, beberapa strategi pengembangan dapat dipertimbangkan. Peningkatan jumlah dan keragaman *dataset* citra biji kopi menjadi faktor utama untuk memperkaya variasi pola visual yang dipelajari oleh model. Selain itu, penerapan teknik *data augmentation* yang lebih beragam, penggunaan arsitektur CNN yang lebih dalam, atau pemanfaatan pendekatan *transfer learning* berpotensi meningkatkan kemampuan model dalam membedakan kelas kualitas biji kopi yang memiliki kemiripan visual tinggi. Dengan pengembangan tersebut, sistem klasifikasi kualitas biji kopi berbasis CNN diharapkan mampu menghasilkan performa yang lebih seimbang dan akurat pada seluruh kelas kualitas.

4. KESIMPULAN

Penelitian ini berhasil menerapkan metode *Convolutional Neural Network* (CNN) sebagai pendekatan otomatis dalam mengklasifikasikan kualitas biji kopi berbasis citra visual ke dalam tiga kategori, yaitu baik, sedang, dan buruk. Berdasarkan hasil pelatihan dan evaluasi model, CNN mampu mempelajari pola visual dasar dari citra biji kopi secara bertahap, yang ditunjukkan oleh peningkatan nilai akurasi serta penurunan nilai *loss* selama proses pelatihan berlangsung. Tahapan implementasi CNN yang mencakup pra-pemrosesan data, ekstraksi fitur melalui lapisan konvolusi dan *pooling*, serta proses klasifikasi menggunakan lapisan *fully connected* terbukti dapat dijalankan secara sistematis dan konsisten. Namun demikian, hasil evaluasi menggunakan *confusion matrix* menunjukkan bahwa performa klasifikasi model belum optimal, khususnya pada kelas kualitas baik dan sedang, yang memiliki karakteristik visual saling menyerupai. Keterbatasan ini terutama dipengaruhi oleh jumlah dan variasi *dataset* citra biji kopi yang relatif terbatas, sehingga model belum mampu membentuk representasi fitur yang cukup kuat untuk membedakan seluruh kelas secara seimbang. Meskipun demikian, penelitian ini menunjukkan bahwa CNN memiliki potensi yang signifikan sebagai pendekatan awal dalam pengembangan sistem otomatis untuk membantu proses sortasi dan penilaian kualitas biji kopi secara objektif dan konsisten. Untuk penelitian selanjutnya, disarankan dilakukan peningkatan jumlah dan keragaman *dataset*, pengembangan arsitektur CNN yang lebih kompleks, serta eksplorasi teknik pra-pemrosesan lanjutan guna meningkatkan performa klasifikasi dan kemampuan generalisasi model secara keseluruhan.

REFERENCES

- [1] R. Paterek, S. Geoghegan, B. S. Creaven, and A. Power, "Coffee: Lighting Its Complex Ground Truth and Percolating Its Molecular Brew," *Beverages*, vol. 10, no. 4, p. 119, Dec. 2024, doi: 10.3390/beverages10040119.
- [2] D. W. Lachenmeier *et al.*, "Shaping the Future of Coffee: Climate Resilience, Liberica's Rise, and By-Product Innovation—Highlights from the International Coffee Convention 2023 (ICC2023)," *Foods*, vol. 13, no. 6, p. 832, Mar. 2024, doi: 10.3390/foods13060832.
- [3] M. A. Valles-Coral, C. I. Bernales-del-Aguila, E. Benavides-Cuvas, and L. Cabanillas-Pardo, "Effectiveness of a cherry coffee sorter prototype with image recognition using machine learning," *Rev. Bras. Ciênc. Agrár. - Braz. J. Agric. Sci.*, vol. 18, no. 1, pp. 1–7, Mar. 2023, doi: 10.5039/agraria.v18i1a2586.
- [4] A. Fadjeri, "Klasifikasi Biji Kopi Berdasarkan Bentuk Menggunakan Image Processing dan K-NN," *J. Ilm. SINUS*, vol. 21, no. 2, p. 55, July 2023, doi: 10.30646/sinus.v21i2.726.
- [5] K. Yu *et al.*, "Advances in Computer Vision and Spectroscopy Techniques for Non-Destructive Quality Assessment of Citrus Fruits: A Comprehensive Review," *Foods*, vol. 14, no. 3, p. 386, Jan. 2025, doi: 10.3390/foods14030386.
- [6] A. Hayat, F. Morgado-Dias, T. Choudhury, T. P. Singh, and K. Kotecha, "FruitVision: A deep learning based automatic fruit grading system," *Open Agric.*, vol. 9, no. 1, p. 20220276, May 2024, doi: 10.1515/opag-2022-0276.
- [7] A. Lavanya, M. Arakeri, and B. J. Ambika, "Advancements in Coffee Bean Quality Assessment Using Computer Vision and Deep Learning Techniques," in *2025 International Conference on Next Generation Communication & Information Processing (INCIP)*, Bangalore, India: IEEE, Jan. 2025, pp. 758–763. doi: 10.1109/INCIP64058.2025.11019029.

- [8] N. O. Adiwijaya, H. I. Romadhon, J. A. Putra, and D. P. Kuswanto, "The quality of coffee bean classification system based on color by using k-nearest neighbor method," *J. Phys. Conf. Ser.*, vol. 2157, no. 1, p. 012034, Jan. 2022, doi: 10.1088/1742-6596/2157/1/012034.
- [9] C. B. R. S, and S. R., "Upgrading Coffee Bean Quality Using K-nearest Algorithm over Future Selection and Extraction to Reduce Dimensionality of Data," in *2024 8th International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)*, Kirtipur, Nepal: IEEE, Oct. 2024, pp. 938–943. doi: 10.1109/I-SMAC61858.2024.10714790.
- [10] M. Wu, J. Zhou, Y. Peng, S. Wang, and Y. Zhang, "Deep Learning for Image Classification: A Review," in *Proceedings of 2023 International Conference on Medical Imaging and Computer-Aided Diagnosis (MICAD 2023)*, vol. 1166, R. Su, Y.-D. Zhang, and A. F. Frangi, Eds., in Lecture Notes in Electrical Engineering, vol. 1166. , Singapore: Springer Nature Singapore, 2024, pp. 352–362. doi: 10.1007/978-981-97-1335-6_31.
- [11] A. C. S., "Advancements in CNN Architectures for Computer Vision: A Comprehensive Review," in *2023 Annual International Conference on Emerging Research Areas: International Conference on Intelligent Systems (AICERA/ICIS)*, Kanjirapally, India: IEEE, Nov. 2023, pp. 1–7. doi: 10.1109/AICERA/ICIS59538.2023.10420413.
- [12] I. D. Mienye, T. G. Swart, G. Obaido, M. Jordan, and P. Iloilo, "Deep Convolutional Neural Networks: A Comprehensive Review," Aug. 19, 2024, *Computer Science and Mathematics*. doi: 10.20944/preprints202408.1288.v1.
- [13] K. S, V. T, A. S, G. D J, A. K, and S. Madhumitha, "Comparative Analysis of CNN-based Feature Extraction Techniques and Conventional Machine Learning Models for Quality Assessment in Agricultural Produce," *SSRN Electron. J.*, 2025, doi: 10.2139/ssrn.5089073.
- [14] M. K. Goel and G. Singh, "Optimizing Vegetable Classification with Convolutional Neural Networks Model," in *2024 Second International Conference on Intelligent Cyber Physical Systems and Internet of Things (ICoICI)*, Coimbatore, India: IEEE, Aug. 2024, pp. 1171–1175. doi: 10.1109/ICoICI62503.2024.10696858.
- [15] 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 Agric. Technol.*, vol. 9, p. 100680, Dec. 2024, doi: 10.1016/j.atech.2024.100680.
- [16] K. Przybył *et al.*, "Application of Machine Learning to Assess the Quality of Food Products—Case Study: Coffee Bean," *Appl. Sci.*, vol. 13, no. 19, p. 10786, Sept. 2023, doi: 10.3390/app131910786.
- [17] Y. K. Molla and E. A. Mitiku, "CNN-HOG based hybrid feature mining for classification of coffee bean varieties using image processing," *Multimed. Tools Appl.*, vol. 84, no. 2, pp. 749–764, Apr. 2024, doi: 10.1007/s11042-024-18952-z.
- [18] R. E. G. Rivas, P. L. L. Bertarini, and H. Fernandes, "Automated Coffee Roast Level Classification Using Machine Learning and Deep Learning Models," *J. Food Sci.*, vol. 90, no. 9, p. e70532, Sept. 2025, doi: 10.1111/1750-3841.70532.
- [19] S. Muhammad Syadham and M. Akbar, "Klasifikasi Citra Biji Kopi Temanggung Menggunakan Gray Level Co-Occurrence Matrix – Convolutional Neural Network," *J. Inform. Dan Tek. Elektro Terap.*, vol. 13, no. 3, July 2025, doi: 10.23960/jitet.v13i3.7274.
- [20] G. Miranda and C. Rubio-Manzano, "Image Classification Using Deep and Classical Machine Learning on Small Datasets: A Complete Comparative," Jan. 25, 2022, *Mathematics & Computer Science*. doi: 10.20944/preprints202201.0367.v1.
- [21] Y. Yang, "Fruit Image Classification Using Convolution Neural Networks," *Highlights Sci. Eng. Technol.*, vol. 34, pp. 110–119, Feb. 2023, doi: 10.54097/hset.v34i.5430.
- [22] F. O. A. Hashim *et al.*, "Comparative analysis of deep learning models for post-roasting coffee bean classification," *Edelweiss Appl. Sci. Technol.*, vol. 9, no. 8, pp. 624–640, Aug. 2025, doi: 10.55214/2576-8484.v9i8.9393.
- [23] G. Cai, "Advanced Image Classification Using Convolutional Neural Networks," *Sci. Technol. Eng. Chem. Environ. Prot.*, vol. 1, no. 9, Oct. 2024, doi: 10.61173/117trk02.
- [24] Q. Xu, L. Zhu, X. Cheng, and B. Jiang, "Beyond Frequency: Seeing Subtle Cues Through the Lens of Spatial Decomposition for Fine-Grained Visual Classification," 2025, *arXiv*. doi: 10.48550/ARXIV.2508.06959.