



Determination of Copra Quality Based on Contour Image Using the Canny Edge Detection Method

Penentuan Kualitas Kopro Berbasis Citra Kontur Menggunakan Metode Canny Edge Detection

Chandra Wisnu Nugroho^{1*}, Ingrid Nurtanio², Abdul Jalil³

^{1,3}Pascasarjana Magister Sistem Komputer Universitas Handayani Makassar, Indonesia

²Teknik Informatika, Universitas Hasanuddin, Indonesia

E-mail: ¹chandra.nugroho7@gmail.com, ²ingrid@unhas.ac.id, ³abdul.jalil@handayani.ac.id

Received Nov 12th 2024; Revised Dec 29th 2024; Accepted Jan 22th 2025; Available Online Jan 30th 2025, Published Jan 30th 2025

Corresponding Author: Chandra Wisnu Nugroho

Copyright © 2025 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

UD Cendrawasih, located in Motoboi Kecil Village, South Kotamobagu District, North Sulawesi, is a long-established copra trading business. Currently, the quality assessment of copra is conducted manually through visual inspection by experienced workers. While reliable, this method suffers from subjectivity, leading to inconsistent results and lengthy evaluation times. This study implements the Canny Edge Detection method with a Canny-Inception model to automate and enhance the accuracy of copra quality assessment. The model classifies copra into three main categories: "wet" (high moisture content), "dry" (well-dried copra), and "moldy" (characterized by discoloration and odor). Data were divided using three configurations: Model A (80:10:10), Model B (70:20:10), and Model C (60:30:10). The findings revealed that Model C achieved the best performance with a validation accuracy of 87.50% at epoch 9 and a validation loss of 40.27%. Confusion Matrix analysis showed that Model A excelled in the "wet" category (81%), Model B in the "dry" category (62%), and Model C in the "moldy" category (76%). With an overall accuracy of 87.50%, Model C is deemed the most effective for accurately and consistently classifying copra quality.

Keywords: Canny Edge Detection, Copra Classification, Model, Moldy, Wet

Abstrak

UD Cendrawasih, yang berlokasi di Kelurahan Motoboi Kecil, Kotamobagu Selatan, Sulawesi Utara, adalah usaha jual beli kopra yang telah beroperasi lama. Proses penilaian kualitas kopra saat ini masih manual melalui inspeksi visual, yang meskipun andal, sering kali menghadirkan subjektivitas dan kurang konsisten. Penelitian ini bertujuan mengotomatiskan dan meningkatkan akurasi penilaian kualitas kopra menggunakan metode Canny Edge Detection dengan model Canny-Inception. Model ini mengklasifikasikan kopra menjadi tiga kelas: "basah" (kadar air tinggi), "kering" (kopra yang telah dikeringkan), dan "berjamur" (ditandai oleh warna dan bau). Data dibagi dalam tiga model: Model A (80:10:10), Model B (70:20:10), dan Model C (60:30:10). Hasil penelitian menunjukkan Model C memberikan performa terbaik dengan akurasi validasi 87,50% pada epoch ke-9 dan validation loss 40,27%. Analisis menggunakan Confusion Matrix mengungkapkan Model A unggul pada kelas basah (81%), Model B pada kelas kering (62%), dan Model C pada kelas berjamur (76%). Dengan akurasi keseluruhan 87,50%, Model C dinilai paling efektif untuk klasifikasi kualitas kopra secara akurat dan konsisten.

Kata kunci: Basah, Berjamur, Canny Edge Detection, Klasifikasi Kopra, Model

1. PENDAHULUAN

Industri kelapa merupakan salah satu sektor penting dalam perekonomian Indonesia Khususnya dibidang pertanian, termasuk di Kota Kotamobagu. Tanaman Kelapa (*Cocos Nucifera*) merupakan jenis tanaman yang memiliki nilai ekonomis yang tinggi karena hampir semua bagian tanaman kelapa dapat memberikan manfaat bagi manusia mulai dari buah, daun, batang, sampai akarnya. Buah kelapa adalah bagian pohon kelapa yang sering dimanfaatkan untuk kehidupan manusia yaitu kehidupan pangan. Daunnya sering dimanfaatkan untuk pembuatan kerajinan tangan di beberapa daerah. Batangnya sering digunakan untuk bahan

bangunan. Selain itu buah kelapa juga bisa diolah menjadi minyak kelapa. Bahkan kelapa juga dijadikan bahan baku pada sejumlah industri penting seperti kosmetik, sabun, dan lain-lain [1].

Keunggulan tanaman kelapa tidak hanya terdapat pada dagingnya yang dapat diolah menjadi santan, kopra, dan minyak kelapa, tetapi juga pada seluruh bagian tanaman sehingga mendapat julukan “Pohon Kehidupan”. Kopra merupakan salah satu hasil olahan dari kelapa, memiliki peran krusial dalam industri ini. Kopra merupakan bahan baku utama dalam produksi minyak kelapa dan berbagai produk turunannya. Kualitas kopra menjadi faktor penentu utama dalam menentukan nilai jualnya. Kopra merupakan salah satu produk turunan kelapa yang sangat penting karena setelah kakao merupakan komoditas terpenting di subsektor perkebunan Sulawesi Utara [2].

Usaha Dagang (UD) Cendrawasih yang beralamat Kelurahan Motoboi Kecil Kecamatan Kotamobagu Selatan Kota Kotamobagu Sulawesi Utara telah lama bergerak dalam bidang usaha jual beli kopra. Kopra merupakan salah satu komoditas utama dari industri kelapa, yang sangat penting bagi perekonomian lokal dan nasional [3]. Sebagai salah satu pelaku utama dalam sektor ini, UD Cendrawasih sangat bergantung pada penilaian kualitas kopra yang akurat dan efisien untuk memastikan produk yang diperdagangkan memenuhi standar yang diinginkan oleh pasar. Saat ini, proses penilaian kualitas kopra di UD Cendrawasih masih dilakukan secara manual, dengan metode pemeriksaan visual oleh tenaga kerja yang berpengalaman. Meski metode ini cukup andal, terdapat sejumlah kelemahan yang perlu diperhatikan, antara lain subjektivitas penilaian yang dapat menghasilkan variasi hasil yang tidak seragam dan kurang konsisten. Selain itu, waktu yang dibutuhkan untuk menilai kopra secara menyeluruh juga cukup lama, terutama mengingat besarnya volume kopra yang harus diperiksa setiap harinya. Hal ini membuat metode penilaian manual kurang efisien, terlebih jika mempertimbangkan bahwa ketepatan penilaian sangat penting dalam menjaga standar kualitas kopra yang dihasilkan [4].

Setiap harinya, UD Cendrawasih menerima pasokan kopra dalam jumlah yang cukup besar, yakni antara 500 kilogram hingga 2 ton. Dengan jumlah karyawan sebanyak 6 orang, proses penyortiran kualitas kopra ini memakan waktu yang cukup lama, rata-rata 6 hingga 9 jam per orang. Beban kerja yang tinggi dan waktu pemeriksaan yang panjang berpotensi menimbulkan kesalahan dalam penilaian kualitas, yang pada akhirnya dapat berdampak pada kualitas produk akhir [5]. Oleh karena itu, diperlukan inovasi atau metode penilaian baru yang lebih cepat dan akurat untuk meningkatkan efisiensi sekaligus menjaga konsistensi kualitas kopra yang dihasilkan oleh UD Cendrawasih.

Berdasarkan hasil riset awal bahwa dengan adanya perkembangan teknologi, khususnya dalam bidang pengolahan citra digital, terdapat peluang untuk meningkatkan proses penilaian kualitas kopra di UD Cendrawasih. Salah satu metode yang dapat digunakan adalah *Canny Edge Detection*, sebuah teknik yang dikenal untuk keakuratannya dalam mendeteksi tepi objek pada citra digital [6][7]. Metode ini dapat membantu dalam mengidentifikasi kontur kopra secara otomatis, sehingga dapat memberikan penilaian yang lebih objektif dan konsisten dibandingkan dengan metode manual.

Metode *Canny Edge Detection* adalah salah satu teknik dalam pengolahan citra yang sangat berpengaruh karena kemampuannya dalam mendeteksi tepi dengan baik. Metode ini menggunakan serangkaian algoritma untuk menemukan garis-garis tepi pada gambar, yang kemudian dapat diinterpretasikan untuk mengidentifikasi ciri-ciri kualitas kopra [8][9][10]. Penerapan metode ini dalam penentuan kualitas kopra diharapkan dapat memberikan hasil yang lebih konsisten dan obyektif.

Penerapan Metode *Canny Edge Detection* dalam penentuan kualitas kopra di UD Cendrawasih tidak hanya akan meningkatkan efisiensi dan akurasi proses penilaian, tetapi juga berpotensi meningkatkan daya saing usaha dengan menyediakan produk yang kualitasnya terjamin. Dengan demikian, penelitian ini membuat sistem penilaian kualitas kopra berbasis citra kontur menggunakan Metode *Canny Edge Detection*, yang diharapkan dapat memberikan kontribusi positif bagi peningkatan kualitas dan efisiensi operasional di UD Cendrawasih [11][12][13][14].

Beberapa penelitian sebelumnya telah menunjukkan potensi teknik pengolahan citra digital dalam berbagai aplikasi. Tribuana et al. (2024) dalam penelitiannya yang berjudul *Image Preprocessing Approaches Toward Better Learning Performance with Convolutional Neural Network (CNN)* menunjukkan bahwa proses pra-proses citra dapat meningkatkan performa pembelajaran pada model CNN [15]. Selain itu, Tribuana et al. (2024) juga mengembangkan sistem pengenalan wajah berbasis CNN untuk keamanan akses pintu pintar, yang menunjukkan kemampuan teknik pengolahan citra dalam mendeteksi pola secara efisien [16]. Penelitian oleh Riswanto et al. (2024) yang berjudul *Calorie Detection of Traditional Indonesian Food Using the Single Shot Multibox Detector (SSD) Method* menunjukkan aplikasi metode deteksi objek pada pengenalan makanan tradisional Indonesia, yang membuktikan kemampuan metode berbasis pengolahan citra untuk mendukung berbagai kebutuhan analisis objek [17].

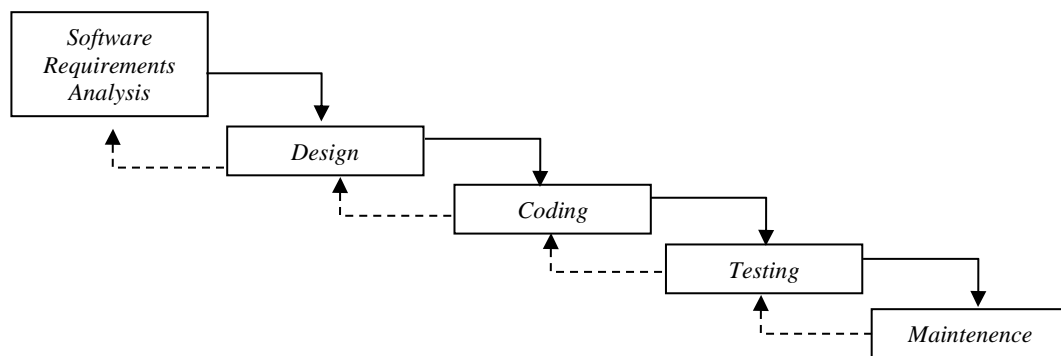
Sebelumnya juga telah dilakukan penelitian oleh Batubara et al. (2020) dengan judul penelitian *Perancangan Aplikasi Pengolahan Citra Digital Untuk Menentukan Bibit Unggul Biji Kopi dengan Metode Canny Edge Detection*. Penelitian ini menghasilkan Algoritma *canny* dapat mendeteksi tepi pada citra biji kopi dan proses pengenalan untuk deteksi tepi perlu dilakukan sebelum mendeteksi objek yang penting, untuk memudahkan dalam proses deteksi tepi citra biji kopi [18] dan penelitian yang kedua terkait dengan penelitian

tentang kopra yaitu penelitian oleh Lahay et al. (2023) dengan judul Penentuan Grade Kopra Dengan Penerapan Metode Logika Fuzzy. Penelitian penentuan kualitas kopra merupakan proses penting dalam industri perkebunan kelapa yang bertujuan untuk menentukan kualitas kopra yang dihasilkan. Penelitian ini menerapkan metode logika fuzzy. Penelitian ini bertujuan guna membangun sistem yang bisa menolong dalam penentuan mutu kopra di PT Multi Nabati Sulawesi dengan memanfaatkan logika fuzzy. Hasil dari riset ini menampilkan kalau sistem yang dibentuk bisa menentukan kualitas kopra dengan akurasi sebesar 95% dan memberikan rekomendasi kualitas yang sesuai dengan kondisi sampel yang diuji [19].

Berdasarkan penjelasan pada latar belakang di atas, penggunaan metode tradisional atau manual dalam menilai kualitas kopra memiliki beberapa kelemahan, di antaranya memerlukan waktu yang lama dan sering kali menghasilkan penilaian yang kurang akurat. Oleh karena itu, diperlukan suatu sistem otomatis yang dapat mendeteksi dan menentukan kualitas kopra secara lebih efisien dan objektif. Berbeda dengan penelitian sebelumnya yang umumnya masih menggunakan metode manual atau berbasis fitur warna dan tekstur, penelitian ini mengusulkan pendekatan berbasis *Canny Edge Detection*, yang berfokus pada deteksi kontur citra untuk menilai kualitas kopra dengan lebih akurat. Pendekatan ini diharapkan dapat meningkatkan kecepatan dan konsistensi dalam penentuan kualitas kopra dibandingkan dengan metode konvensional yang lebih subjektif. Selain itu, penelitian ini mengintegrasikan teknik pemrosesan citra digital untuk menghasilkan sistem yang lebih otomatis dan independen dari penilaian manusia, sehingga dapat menjadi solusi yang lebih efisien dalam industri kopra.

2. METODE PENELITIAN

Jenis penelitian yang digunakan dalam penelitian ini adalah R&D/*Research and Development*. Alasan menggunakan metode ini adalah karena Metode *Waterfall* melakukan pendekatan secara sistematis dan berurutan dalam membangun suatu sistem. Proses Metode *Waterfall* yaitu pada pengerjaan dari suatu sistem dilakukan secara berurutan. Sistem yang dihasilkan akan berkualitas baik, dikarenakan pelaksanaannya secara bertahap sehingga tidak terfokus pada tahapan tertentu. Tahapan dari Metode *Waterfall* adalah:



Gambar 1. Model Waterfall

Tahap analisis kebutuhan dilakukan dengan menganalisa kebutuhan *user*, analisa perangkat lunak dan perangkat keras yang dibutuhkan dalam pengembangan sistem serta kebutuhan lain dalam pembuatan basis data. Tahap selanjutnya yaitu mendesain sistem. Tahap ini dibuat sebelum tahap pengkodean. Tujuan dari tahap ini adalah memberikan gambaran tentang apa yang akan dikerjakan dan bagaimana tampilannya. Tahap ini memenuhi semua kebutuhan pengguna sesuai dengan hasil yang dianalisa seperti rancangan tampilan pengembangan sistem ujian *online* di sekolah, dan membantu mendefinisikan arsitektur sistem secara keseluruhan. Aktivitas selanjutnya yang dilakukan adalah pengkodean sistem. Penulisan kode program merupakan tahap penerjemahan desain sistem yang telah dibuat ke dalam bentuk perintah-perintah yang dimengerti komputer dengan mempergunakan bahasa pemrograman. Tahapan ini merupakan tahapan secara nyata dalam mengerjakan suatu sistem. Sistem ini bahasa pemrograman yang dipakai adalah PHP dan database MySQL. Selanjutnya, pengujian dilakukan untuk memastikan bahwa *software* yang dibuat telah sesuai dengan desainnya dan semua fungsi dapat dipergunakan dengan baik tanpa ada kesalahan. Serta tahapan terakhir adalah Pemeliharaan, tahap ini merupakan tahap terakhir dalam Metode *Waterfall*. Sistem dapat diimplementasikan. Pemeliharaan mencakup koreksi dari berbagai *error* yang tidak ditemukan pada tahap-tahap terdahulu, perbaikan atas implementasi dan pengembangan unit sistem, serta pemeliharaan program. Pemeliharaan sistem dapat dilakukan oleh seorang administrator untuk meningkatkan kualitas sistem agar jauh lebih baik.

2.1 Sumber Data

Data Primer dalam penelitian ini adalah data utama yang akan digunakan sebagai data yang akan diproses dalam sistem ini. Data tersebut adalah dataset citra kopra. Sedangkan Data sekunder dalam penelitian

ini adalah berupa data pelengkap yang terkait dengan data penelitian ini yaitu penelitian-penelitian sejenis yang bisa menjadi rujukan dan panduan.

2.2 Kajian Teoritis

2.2.1 Canny Edge Detection

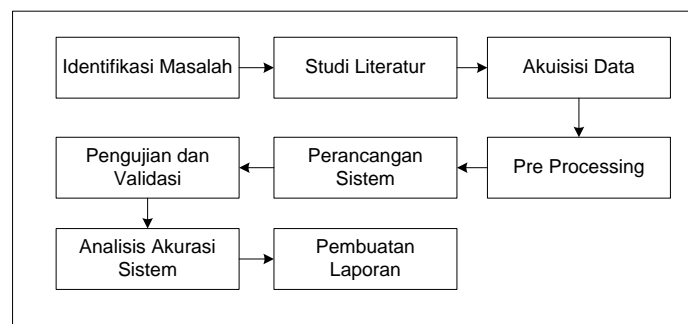
Deteksi tepi (*edge detection*) adalah teknik penting dalam pemrosesan citra digital yang digunakan untuk mengidentifikasi batas objek dalam gambar. Salah satu algoritma deteksi tepi yang paling berpengaruh dan banyak digunakan adalah *Canny Edge Detection*, yang diperkenalkan oleh John F. Canny pada tahun 1986. Algoritma ini dirancang untuk memenuhi tiga kriteria utama: deteksi yang baik (*good detection*), lokalisasi yang baik (*good localization*), dan memastikan hanya ada satu respons untuk setiap tepi [20].

Proses deteksi tepi Canny terdiri dari beberapa tahapan. Pertama, gambar dihaluskan menggunakan filter Gaussian untuk mengurangi noise. Selanjutnya, gradien intensitas gambar dihitung untuk menyoroti area dengan perubahan intensitas yang tinggi. Setelah itu, dilakukan non-maximum suppression untuk menipiskan tepi yang terdeteksi sehingga hanya puncak gradien yang dipertahankan. Terakhir, algoritma menerapkan hysteresis thresholding dengan dua ambang batas untuk menentukan tepi akhir, memastikan bahwa tepi yang lemah namun terhubung dengan tepi yang kuat tetap dipertahankan [21].

Keunggulan utama dari Algoritma Canny adalah kemampuannya dalam mendeteksi tepi dengan akurasi tinggi dan ketahanan terhadap noise. Hal ini menjadikannya pilihan populer dalam berbagai aplikasi, seperti pengenalan objek, analisis citra medis, dan sistem penglihatan komputer. Meskipun telah ada berbagai metode deteksi tepi yang dikembangkan, algoritma Canny tetap menjadi standar emas dalam bidang ini karena kinerjanya yang andal dan konsisten [22].

Dalam beberapa tahun terakhir, penelitian telah berfokus pada peningkatan algoritma Canny dengan menggabungkan teknik pembelajaran mendalam (*deep learning*) untuk meningkatkan adaptabilitas dan akurasinya dalam kondisi yang lebih kompleks. Pendekatan ini bertujuan untuk mempertahankan keunggulan asli dari algoritma Canny sambil meningkatkan kemampuannya dalam menghadapi tantangan pemrosesan citra modern [23].

2.2.2 Tahapan Penelitian



Gambar 2. Tahapan Penelitian

Gambar 2 menunjukkan tahapan penelitian yang dilakukan dalam penelitian ini. Tahapan pertama adalah Identifikasi Masalah, di mana penelitian dimulai dengan mengidentifikasi permasalahan utama yang berkaitan dengan objek penelitian serta mengumpulkan teori yang relevan. Selanjutnya, dilakukan Studi Literatur, yaitu proses mengumpulkan referensi dari berbagai sumber seperti jurnal penelitian, artikel ilmiah, laman web, dan buku. Studi literatur ini bertujuan untuk memahami konsep dasar pengolahan citra dan segmentasi citra sapi serta merancang penelitian awal sebagai acuan dalam tahap selanjutnya.

Tahap berikutnya adalah Akuisisi Data, di mana data yang digunakan dalam penelitian ini dikumpulkan dari berbagai sumber, termasuk dataset gambar kopra hasil pemotretan langsung serta data yang diperoleh melalui *crawling* gambar dari Google dan referensi lain yang tersedia di *cloud*. Setelah data terkumpul, dilakukan *Pre-Processing Data*, yang mencakup analisis, normalisasi, dan pra-pemrosesan untuk memastikan data dalam format yang seragam, berkualitas, dan siap digunakan dalam proses ekstraksi citra kopra.

Selanjutnya, dilakukan Perancangan Sistem, di mana sistem dirancang menggunakan *flowchart* dan diagram sistem untuk mendukung proses klasifikasi citra kopra. Perancangan ini mencakup definisi input, seperti dataset yang digunakan, serta skenario uji coba yang bertujuan menghasilkan nilai akurasi pengujian secara terukur. Setelah perancangan selesai, tahap Pengujian dan Validasi dilakukan untuk mengevaluasi performa sistem dalam tugas klasifikasi. Pengujian menggunakan data uji untuk mengukur kinerja sistem, sementara validasi bertujuan memastikan model mampu memberikan hasil yang konsisten dan dapat diandalkan.

Hasil dari pengujian dan validasi kemudian dianalisis pada tahap Analisis Akurasi Sistem dengan mengevaluasi parameter-parameter yang mempengaruhi tingkat akurasi klasifikasi. Terakhir, penelitian ini didokumentasikan dalam tahap Pembuatan Laporan, di mana seluruh proses dan hasil penelitian dicatat secara sistematis sebagai bukti dan referensi bagi penelitian selanjutnya.

2.2.3 Teknik Pengumpulan data


Teknik pengumpulan data dalam penelitian ini dilakukan melalui tiga metode utama, yaitu observasi, wawancara, dan studi pustaka. Observasi dilakukan dengan cara mengamati langsung objek penelitian, yaitu kopra, guna memahami karakteristik fisiknya serta faktor-faktor yang mempengaruhi kualitasnya. Pengamatan ini bertujuan untuk memperoleh data yang lebih akurat mengenai kondisi nyata di lapangan, termasuk bagaimana kopra diklasifikasikan berdasarkan kualitasnya. Selain itu, observasi juga memungkinkan peneliti untuk mencatat berbagai faktor eksternal yang mungkin mempengaruhi hasil penelitian, seperti metode pengolahan kopra, kondisi lingkungan, serta teknik yang digunakan oleh pelaku usaha dalam menentukan kualitas kopra. Dengan demikian, observasi memberikan gambaran awal yang penting sebagai dasar dalam analisis lebih lanjut.

Selain observasi, penelitian ini juga menggunakan wawancara sebagai metode pengumpulan data dengan berkomunikasi langsung dengan pemilik usaha kopra, yaitu UD Cendrawasih yang berlokasi di Kotamobagu, Sulawesi Utara. Wawancara dilakukan secara mendalam untuk memperoleh wawasan langsung dari pelaku usaha mengenai metode tradisional yang digunakan dalam menentukan kualitas kopra, tantangan yang dihadapi, serta harapan mereka terhadap sistem otomatis yang diusulkan dalam penelitian ini. Informasi dari wawancara ini sangat penting untuk memahami praktik yang telah berlangsung dan membandingkannya dengan pendekatan berbasis teknologi yang akan dikembangkan. Sementara itu, studi pustaka dilakukan dengan mengumpulkan berbagai referensi tertulis, seperti jurnal ilmiah, buku, artikel, serta laporan penelitian sebelumnya yang relevan dengan topik ini. Studi pustaka bertujuan untuk memperoleh dasar teoritis yang kuat dalam memahami metode pengolahan citra digital serta teknik segmentasi gambar yang digunakan dalam penelitian ini, khususnya *Canny Edge Detection*. Melalui kombinasi ketiga metode ini, penelitian dapat mengumpulkan data yang komprehensif dan memiliki dasar yang kuat dalam menyusun analisis serta pengembangan sistem penentuan kualitas kopra berbasis citra.

3. HASIL DAN PEMBAHASAN

3.1. Dataset

Pada tahap ini, dilakukan pengumpulan dataset berupa gambar kopra dengan berbagai kondisi basah, kering, dan berjamur yang akan digunakan untuk melatih dan menguji Model *Canny Edge Detection*. Dataset ini mencakup variasi kondisi kopra untuk memastikan model dapat mengenali kontur dari berbagai karakteristik visual yang berkaitan dengan kualitas kopra. Berikut ini merupakan *dataset* yang telah dikumpulkan, ditunjukkan pada gambar 3.



Gambar 3. Dataset Kopra

Gambar 3. merupakan dataset citra kopra dimana Gambar-gambar kopra tersebut dikumpulkan dalam format file yang mendukung kualitas tinggi, seperti PNG, JPG, JPEG, GIF, TIFF, WEBP, dan JFIF, agar citra yang digunakan tetap jelas dan detailnya optimal. Format gambar yang bervariasi ini membantu meningkatkan fleksibilitas dataset, memungkinkan model untuk belajar dari kondisi citra yang berbeda-beda dalam hal resolusi, warna, dan detail kontur. Total citra kopra yang dikumpulkan sebanyak 600 citra kopra berjumlah 200 berdasarkan masing-masing kategori yaitu kopra basah, kopra kering, dan kopra berjamur. Setelah mengumpulkan dataset kemudian dilakukan labeling dataset yang berfungsi memberi label pada setiap gambar kopra basah, kering, dan berjamur.

3.1.1 Pengujian Sistem

Pada tahap ini untuk bagi data training dan validasi beserta bagian testing digunakan bahasa pemrograman *Python*. Uji training dan validasi dilakukan dengan membagi data menjadi subset pelatihan,

validasi, dan pengujian dengan proporsi yang sesuai, seperti 70% untuk training, 20% untuk validasi, dan 10% untuk testing serta untuk uji coba testing dapat digunakan citra training dan validasi beserta citra baru. Pada bagian training dan validasi dilakukan 3 model uji coba. Uji coba pertama dilakukan preprocessing dengan uji coba pembagian data Model A data taining 80%, 10% data validasi dan 10% data testing, Model B data taining 70%, 20% data validasi dan 10% data testing dan Model C data taining 60%, 30% data validasi dan 10% data testing.

Sistem *training* dan validasi dimulai dari mempersiapkan dataset citra kopra sebanyak 200 dari masing-masing kategori kopra basah, kering dan berjamur. dataset cita kopra dipanggil sesuai tempat file dari masing-masing folder gambar kemudian data disimpan untuk proses canny model inception. Pada uji coba training dan validasi dilakukan 10 epoch didapatkan hasil:

Tabel 2. Uji Coba *Training* dan Validasi


Uji Coba	Model	Epoch	Training loss	Training accuracy	Validasi loss	Validasi accuracy	Keterangan
1	A:80:10:10	10	62.13%	67.86%	54.51%	76.19%	Hasil Akhir
2	A:80:10:10	9	63.12%	69.25%	59.24%	76.19%	Hasil Max
3	B:70:20:10	10	77.14%	66.44%	69.21%	77.78%	Hasil Akhir
4	B:70:20:10	6	86.66%	51.93%	72.51%	73.02%	Hasil Max
5	C:60:30:10	10	50.44%	73.81%	48.41%	75.00%	Hasil Akhir
6	C:60:30:10	9	53.24%	74.60%	40.27%	87.50%	Hasil Max

Catatan: Hasil Max didapatkan pada nilai akurasi validasi tertinggi

Pada tabel Uji Coba *Trainig* dan validasi berikut ini penjelasan dari Loss dan Akurasi *training* pada uji coba ke 4 dengan Model B dengan 6 *epochs* menunjukkan nilai training menunjukkan nilai *training loss* tertinggi (86.66%) dan akurasi *training* yang rendah (51.93%). sehingga mengindikasikan kemungkinan model mengalami *overfitting* dengan jumlah *epoch* yang lebih sedikit atau konfigurasi yang tidak optimal untuk tugas ini. Pada uji Coba ke 6 Model C dengan 9 *epochs* memiliki *training loss* yang moderat (53.24%) dengan akurasi *training* yang tinggi (74.60%), tetapi tampil sangat baik pada akurasi validasi (87.50%), yang menunjukkan kemampuan generalisasi yang lebih baik. Sedangkan berdasarkan tabel diatas untuk Loss dan Akurasi Validasi untuk uji coba 3 model B cenderung memiliki akurasi validasi yang lebih baik (77.78%), meskipun training loss-nya lebih tinggi. Serta uji Coba 6 model C Model ini menunjukkan akurasi validasi tertinggi sebesar 87.50%, yang berarti model ini mampu mengklasifikasikan data validasi dengan sangat baik, mengidentifikasi kondisi kopra (basah, kering, atau berjamur) dengan tingkat akurasi yang lebih tinggi dibandingkan model lainnya. Selain itu, loss validasi yang relatif rendah (40.27%) menunjukkan bahwa model ini tidak hanya memiliki akurasi yang tinggi, tetapi juga memiliki kesalahan prediksi yang lebih kecil pada data validasi, yang menunjukkan bahwa model ini lebih dapat diandalkan dalam mengklasifikasikan kondisi kopra yang belum terlihat sebelumnya.

Berikut ini hasil *output* pada uji coba testing dengan menggunakan konfigurasi *training* & validasi pada uji coba 3 Model Uji. Uji coba pertama dilakukan preprocessing dengan uji coba pembagian data Model A data taining 80%, 10% data validasi dan 10% *data testing*, Model B *data taining* 70%, 20% data validasi dan 10% *data testing* dan Model C *data taining* 60%, 30% data validasi dan 10% *data testing*.

1. Uji Coba Model A

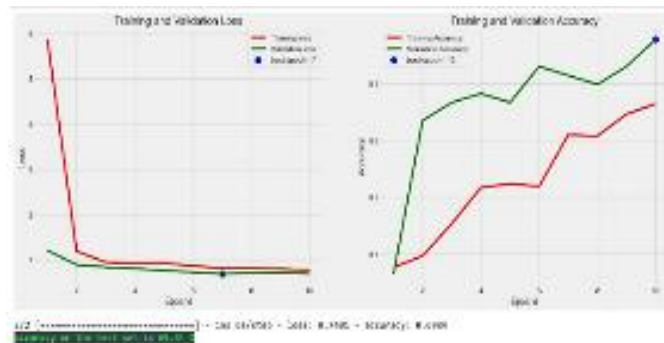


Gambar 4. Uji Coba Model A

Gambar 4 Pada grafik sebelah kiri (*Training and Validation Loss*), terlihat bahwa loss untuk data pelatihan (garis merah) turun tajam di awal pelatihan dan mencapai nilai yang stabil setelah sekitar epoch kedua, sementara loss untuk data validasi (garis hijau) juga menunjukkan penurunan tajam di awal dan stabil mulai epoch kedua, dengan titik terbaik pada epoch ke-10 (ditandai dengan titik biru). Selain itu pada grafik

sebelah kanan (Training and Validation Accuracy), akurasi pelatihan (garis merah) dan validasi (garis hijau) mengalami fluktuasi pada awal pelatihan namun terus meningkat hingga mencapai nilai tertinggi pada epoch ke-9 untuk validasi (ditandai dengan titik biru), meskipun masih ada sedikit perbedaan antara keduanya. Hasil evaluasi model pada test set menunjukkan nilai loss sebesar 57.09 dan akurasi 80.95%, yang menunjukkan performa yang cukup baik dalam pelatihan.

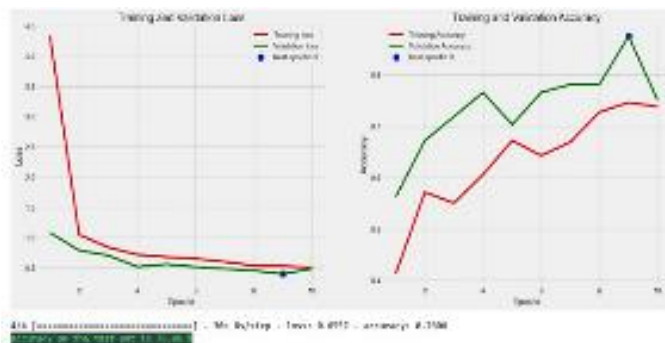
2. Uji Coba Model B



Gambar 5. Uji Coba Model B

Gambar 5 Pada grafik sebelah kiri (*Training and Validation Loss*), terlihat bahwa *loss* untuk data pelatihan (garis merah) turun tajam di awal pelatihan dan mencapai nilai yang stabil setelah sekitar *epoch* kedua, sementara *loss* untuk data validasi (garis hijau) juga menunjukkan penurunan tajam di awal dan stabil mulai *epoch* kedua, dengan titik terbaik pada *epoch* ke-7 (ditandai dengan titik biru). Selain itu pada grafik sebelah kanan (*Training and Validation Accuracy*), akurasi pelatihan (garis merah) dan validasi (garis hijau) mengalami fluktuasi pada awal pelatihan namun terus meningkat hingga mencapai nilai tertinggi pada *epoch* ke-10 untuk validasi (ditandai dengan titik biru), meskipun masih ada sedikit perbedaan antara keduanya. Hasil evaluasi model pada test set menunjukkan nilai loss sebesar 74.01% dan akurasi 69.84%, yang menunjukkan performa yang cukup memadai dalam pelatihan.

3. Uji Coba Model C



Gambar 6. Uji Coba Model C


Gambar 6 Pada grafik sebelah kiri (*Training and Validation Loss*), terlihat bahwa *loss* untuk data pelatihan (garis merah) turun tajam di awal pelatihan dan mencapai nilai yang stabil setelah sekitar *epoch* kedua, sementara *loss* untuk data validasi (garis hijau) juga menunjukkan penurunan tajam di awal dan stabil mulai *epoch* kedua, dengan titik terbaik pada *epoch* ke-9 (ditandai dengan titik biru). Selain itu pada grafik sebelah kanan (*Training and Validation Accuracy*), akurasi pelatihan (garis merah) dan validasi (garis hijau) mengalami fluktuasi pada awal pelatihan namun terus meningkat hingga mencapai nilai tertinggi pada *epoch* ke-9 untuk validasi (ditandai dengan titik biru), meskipun masih ada sedikit perbedaan antara keduanya. Hasil evaluasi model pada test set menunjukkan nilai loss sebesar 65.57% dan akurasi 76.06%, yang menunjukkan performa yang cukup baik dalam pelatihan.

3.1.1 Evaluasi Model

Untuk mengetahui performa dari algoritma Canny, dilakukan pengujian terhadap model. Hasil klasifikasi akan ditampilkan dalam bentuk Confusion Matrix seperti berikut ini:

1. Evaluasi Model A

Gambar 7 ini adalah Confusion Matrix yang menunjukkan hasil prediksi model klasifikasi untuk tiga kelas kopra: basah, berjamur, dan kering, memperlihatkan jumlah sampel yang diklasifikasikan dengan benar dan salah. Pada kelas "basah," sebanyak 23 sampel diklasifikasikan dengan benar, sementara 3 sampel salah diklasifikasikan sebagai "kering." Untuk kelas "berjamur," 12 sampel diklasifikasikan dengan benar, tetapi 2 sampel salah diklasifikasikan sebagai "basah" dan 2 sampel sebagai "kering." Di kelas "kering," sebanyak 16 sampel diklasifikasikan dengan benar, sedangkan 3 sampel salah diklasifikasikan sebagai "basah" dan 2 sampel sebagai "berjamur." Secara keseluruhan, model menunjukkan kinerja yang baik terutama pada kelas "basah," meskipun ada beberapa kesalahan klasifikasi terutama antara kelas "kering" dan "basah."



Gambar 7. Evaluasi Model A Confusion matrix

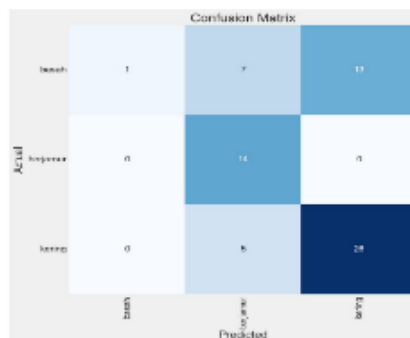
Evaluasi model A *confusion matrix* menampilkan hasil nilai akurasi confusion matrix 3x3 seperti dan menghasilkan hasil pengujian akurasi seperti pada tabel 3.

Tabel 3. Pengujian Model A Confusion matrix

Kelas	Precision	Recall	F1-Score
Basah	0.82	0.88	0.85
Berjamur	0.86	0.75	0.80
Kering	0.76	0.76	0.76
	Accuracy		0.81

Pengujian Model A dengan perbandingan data 80:10:10 memiliki performa yang cukup baik dengan akurasi sebesar 81%, dan performa tertinggi pada kelas "basah." Model lebih baik dalam mendeteksi kelas "basah" dan "berjamur" dibandingkan kelas "kering," yang memiliki recall dan f1-score sedikit lebih rendah.

2. Evaluasi Model B



Gambar 8. Evaluasi Model B Confusion matrix

Gambar 8 ini adalah *Confusion Matrix* yang menunjukkan hasil prediksi model klasifikasi untuk tiga kelas kopra: basah, berjamur, dan kering, memperlihatkan jumlah sampel yang diklasifikasikan dengan benar dan salah. Pada kelas "basah," sebanyak 13 sampel diklasifikasikan dengan benar, sementara 7 sampel salah diklasifikasikan sebagai "berjamur." dan 1 sampel salah diklasifikasikan sebagai "basah", " Untuk kelas "berjamur," 14 sampel diklasifikasikan dengan benar. Di kelas "kering," sebanyak 26 sampel diklasifikasikan dengan benar, sedangkan 6 sampel salah diklasifikasikan sebagai "berjamur" dan Secara keseluruhan, model menunjukkan kinerja yang baik terutama pada kelas "kering," meskipun ada beberapa kesalahan klasifikasi terutama kelas


berjamur. Evaluasi model B confusion matriks menampilkan hasil nilai akurasi confusion matrix 3x3 seperti dan menghasilkan hasil pengujian akurasi seperti pada tabel 4.

Tabel 4. Pengujian Model B Confusion matrix

Kelas	Precision	Recall	F1-Score
Basah	1.0	0.05	0.09
Berjamur	0.54	1.00	0.70
Kering	0.67	0.84	0.74
Accuracy			0.62

Pengujian Model B dengan perbandingan data 70:20:10 memiliki performa yang cukup baik dengan akurasi sebesar 62%, dan performa tertinggi pada kelas "kering" Model lebih baik dalam mendeteksi kelas "kering" dan "berjamur" dibandingkan kelas "basah," yang memiliki recall dan f1-score sedikit lebih rendah.

3. Evaluasi Model C



Gambar 9. Evaluasi Model C Confusion matrix

Gambar 9 adalah *Confusion Matrix* yang menunjukkan hasil prediksi model klasifikasi untuk tiga kelas kopra: basah, berjamur, dan kering, memperlihatkan jumlah sampel yang diklasifikasikan dengan benar dan salah. Pada kelas "basah," sebanyak 52 sampel diklasifikasikan dengan benar, sementara 1 sampel salah diklasifikasikan sebagai "berjamur," dan 12 sampel salah diklasifikasikan "kering". Untuk kelas "berjamur," 48 sampel diklasifikasikan dengan benar, 5 sampel diklasifikasikan salah di kelas "basah", dan 3 sampel diklasifikasikan salah di kelas "kering". Di kelas "kering," sebanyak 43 sampel diklasifikasikan dengan benar, sedangkan 17 sampel salah diklasifikasikan sebagai "basah" dan 7 sampel diklasifikasikan salah di kelas "berjamur" serta secara keseluruhan, model menunjukkan kinerja yang baik terutama pada kelas "kering," meskipun ada beberapa kesalahan klasifikasi terutama kelas berjamur

Evaluasi model B confusion matriks menampilkan hasil nilai akurasi confusion matrix 3x3 seperti dan menghasilkan hasil pengujian akurasi seperti pada tabel 5.

Tabel 5. Pengujian Model C Confusion matrix

Kelas	Precision	Recall	F1-Score
Basah	0.70	0.80	0.75
Berjamur	0.86	0.86	0.86
Kering	0.74	0.64	0.69
Accuracy			0.76

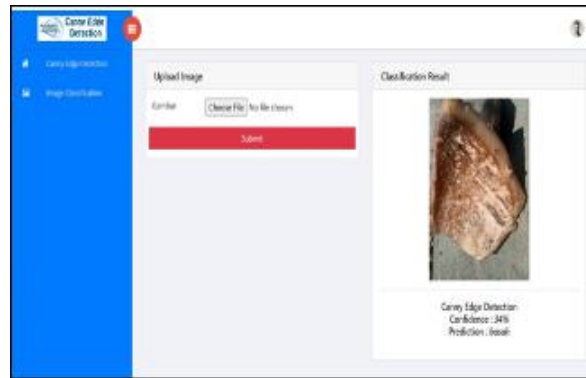
Pengujian Model C dengan perbandingan data 60:30:10 memiliki performa yang cukup baik dengan akurasi sebesar 76%, dan performa tertinggi pada kelas "berjamur" Model lebih baik dalam mendeteksi kelas "basah" dan "berjamur" dibandingkan kelas "kering," yang memiliki recall dan f1-score sedikit lebih rendah.

3.1.2 Deployment

Setelah tahap pengujian selesai dan model menunjukkan kinerja yang baik atau memadai, model kemudian di-deploy dalam bentuk aplikasi dan diimplementasikan agar dapat digunakan oleh pengguna secara langsung. Berikut adalah langkah-langkah dalam tahap deployment ini:

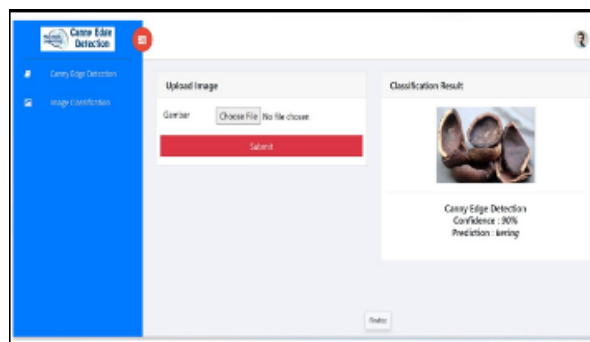
1. Model dikonversi ke format TensorFlow dan Model yang sudah dikonversi kemudian diintegrasikan ke dalam aplikasi website yang responsive dapat digunakan dan dijalankan pada smartphone

2. Aplikasi diuji ulang untuk memastikan model bekerja dengan baik, berikut ini tampilan uji klasifikasi berdasarkan 3 kategori kelas yaitu Kopra basah, kopra kering dan berjamur.



Gambar 10. Tampilan Uji Klasifikasi Kopra Basah

Gambar 10 menampilkan antarmuka website yang digunakan untuk menguji model klasifikasi pada dataset baru. Setelah gambar dataset diunggah, sistem akan menampilkan hasil klasifikasi. Pada uji coba di gambar tersebut, model mengidentifikasi gambar kopra dengan tingkat kepercayaan (confidence) sebesar 34%, menunjukkan keyakinan model terhadap prediksi yang diberikan. Berdasarkan hasil klasifikasi, jenis kopra ini diprediksi sebagai "Basah."
















Gambar 11. Tampilan Uji Klasifikasi Kopra Kering








Gambar 11 menampilkan antarmuka website yang digunakan untuk menguji model klasifikasi pada dataset baru. Setelah gambar dataset diunggah, sistem akan menampilkan hasil klasifikasi. Pada uji coba di gambar tersebut, model mengidentifikasi gambar kopra dengan tingkat kepercayaan (confidence) sebesar 90%, menunjukkan keyakinan model terhadap prediksi yang diberikan. Berdasarkan hasil klasifikasi, jenis kopra ini diprediksi sebagai "Kering".

3. Hasil Uji Coba Akurasi

Tabel 6. Hasil Uji Coba Akurasi

Uji Coba	Hasil	Keterangan
Citra kopra 1	 <p>Canny Edge Detection Confidence : 75% Prediction : berjamur</p>	High Confidence
Citra kopra 2	 <p>Canny Edge Detection Confidence : 37% Prediction : berjamur</p>	Low Confidence

Uji Coba	Hasil	Keterangan
Citra kopra 3	 Canny Edge Detection Confidence : 36% Prediction : <i>berjamur</i>	Low Confidence
Citra kopra 4	 Canny Edge Detection Confidence : 38% Prediction : <i>berjamur</i>	Low Confidence
Citra kopra 5	 Canny Edge Detection Confidence : 35% Prediction : <i>kering</i>	Low Confidence
Citra kopra 6	 Canny Edge Detection Confidence : 43% Prediction : <i>kering</i>	Low Confidence
Citra kopra 7	 Canny Edge Detection Confidence : 38% Prediction : <i>berjamur</i>	Low Confidence
Citra kopra 8	 Canny Edge Detection Confidence : 72% Prediction : <i>kering</i>	High Confidence
Citra kopra 9	 Canny Edge Detection Confidence : 93% Prediction : <i>kering</i>	Very High Confidence
Citra kopra 10	 Canny Edge Detection Confidence : 90% Prediction : <i>kering</i>	Very High Confidence
Citra kopra 11	 Canny Edge Detection Confidence : 34% Prediction : <i>basah</i>	Low Confidence
Citra kopra 12	 Canny Edge Detection Confidence : 57% Prediction : <i>kering</i>	Moderate Confidence
Citra kopra 13	 Canny Edge Detection Confidence : 67% Prediction : <i>berjamur</i>	Moderate Confidence

Uji Coba	Hasil	Keterangan
Citra kopra 14	 Canny Edge Detection Confidence : 75% Prediction : <i>berjamur</i>	High Confidence
Citra kopra 15	 Canny Edge Detection Confidence : 76% Prediction : <i>berjamur</i>	High Confidence
Citra kopra 16	 Canny Edge Detection Confidence : 71% Prediction : <i>berjamur</i>	High Confidence
Citra kopra 17	 Canny Edge Detection Confidence : 39% Prediction : <i>berjamur</i>	Low Confidence
Citra kopra 18	 Canny Edge Detection Confidence : 34% Prediction : <i>basah</i>	Low Confidence
Citra kopra 19	 Canny Edge Detection Confidence : 58% Prediction : <i>kering</i>	Moderate Confidence
Citra kopra 20	 Canny Edge Detection Confidence : 36% Prediction : <i>basah</i>	Low Confidence

3.1.3 PEMBAHASAN

1. Uji Coba Training dan Validasi

Pada tabel Uji Coba Traing dan validasi berikut ini penjelasan dari Loss dan Akurasi training pada uji coba ke 4 dengan Model B dengan 6 epochs menunjukkan nilai training menunjukkan nilai training loss tertinggi (86.66%) dan akurasi training yang rendah (51.93%). sehingga mengindikasikan kemungkinan model mengalami overfitting dengan jumlah epoch yang lebih sedikit atau konfigurasi yang tidak optimal untuk tugas ini. Pada uji Coba ke 6 Model C dengan 9 epochs memiliki training loss yang moderat (53.24%) dengan akurasi training yang tinggi (74.60%), tetapi tampil sangat baik pada akurasi validasi (87.50%), yang menunjukkan kemampuan generalisasi yang lebih baik. Sedangkan berdasarkan tabel diatas untuk Loss dan Akurasi Validasi untuk uji coba 3 model B cenderung memiliki akurasi validasi yang lebih baik (77.78%), meskipun training loss-nya lebih tinggi. Serta uji Coba 6 model C Model ini menunjukkan akurasi validasi tertinggi sebesar 87.50%, yang berarti model ini mampu mengklasifikasikan data validasi dengan sangat baik, mengidentifikasi kondisi kopra (basah, kering, atau berjamur) dengan tingkat akurasi yang lebih tinggi dibandingkan model lainnya. Selain itu, loss validasi yang relatif rendah (40.27%) menunjukkan bahwa model ini tidak hanya memiliki akurasi yang tinggi, tetapi juga memiliki kesalahan prediksi yang lebih kecil pada data validasi, yang menunjukkan bahwa model ini lebih dapat diandalkan dalam mengklasifikasikan kondisi kopra yang belum terlihat sebelumnya.

Berdasarkan hasil uji coba model A, B, dan C dengan pembagian data yang berbeda, dapat disimpulkan bahwa Model C dengan pembagian data 60% untuk pelatihan, 30% untuk validasi, dan 10% untuk pengujian memberikan performa terbaik. Model C mencapai akurasi validasi tertinggi sebesar 87.50% pada epoch ke-9, dengan validation loss yang rendah (40.27%), menunjukkan kemampuan generalisasi model yang sangat baik.

Hasil ini menunjukkan bahwa alokasi data yang lebih besar untuk validasi (30%) membantu model untuk lebih memahami pola data baru di luar data pelatihan. Pada Model A dan B, yang menggunakan 10% dan 20% data validasi, akurasi validasi maksimal yang dicapai lebih rendah, dengan loss yang lebih tinggi, yang mengindikasikan model kurang optimal dalam mempelajari pola generalisasi dari data yang tidak dilatih secara langsung. Penggunaan 30% data validasi pada Model C juga memungkinkan model untuk melakukan penyesuaian yang lebih baik selama pelatihan, sehingga model tidak hanya "hafal" terhadap data pelatihan tetapi juga lebih tanggap terhadap variasi data validasi. Sementara itu, Model A dan B mungkin kurang stabil karena data validasi yang lebih sedikit menyebabkan fluktuasi dalam hasil akurasi dan loss. Dalam konteks implementasi model klasifikasi kopra, Model C adalah pilihan terbaik untuk diterapkan karena memberikan hasil yang paling konsisten dan akurat. Dengan akurasi validasi yang tinggi dan loss yang rendah, Model C menunjukkan bahwa model tersebut lebih siap digunakan pada data baru dan berpotensi memberikan prediksi yang lebih andal dalam praktik. Secara keseluruhan, kesimpulan dari pengujian ini adalah bahwa pemilihan proporsi data yang optimal antara pelatihan, validasi, dan pengujian sangat memengaruhi performa model. Model yang mendapatkan data validasi lebih banyak cenderung lebih baik dalam hal generalisasi dan stabilitas performa.

2. Evaluasi Pengujian Confusion Matrix A

Pengujian Confusion Matrix yang menunjukkan hasil prediksi model klasifikasi untuk tiga kelas kopra: basah, berjamur, dan kering, memperlihatkan jumlah sampel yang diklasifikasikan dengan benar dan salah. Pada kelas "basah," sebanyak 23 sampel diklasifikasikan dengan benar, sementara 3 sampel salah diklasifikasikan sebagai "kering." Untuk kelas "berjamur," 12 sampel diklasifikasikan dengan benar, tetapi 2 sampel salah diklasifikasikan sebagai "basah" dan 2 sampel sebagai "kering." Di kelas "kering," sebanyak 16 sampel diklasifikasikan dengan benar, sedangkan 3 sampel salah diklasifikasikan sebagai "basah" dan 2 sampel sebagai "berjamur." Secara keseluruhan, model menunjukkan kinerja yang baik terutama pada kelas "basah," meskipun ada beberapa kesalahan klasifikasi terutama antara kelas "kering" dan "basah". Berdasarkan analisis Confusion Matrix, model klasifikasi menunjukkan hasil yang cukup baik dalam mengklasifikasikan tiga kelas kopra: "basah," "berjamur," dan "kering," dengan akurasi yang relatif tinggi pada beberapa kelas. Namun, terdapat beberapa area di mana model perlu ditingkatkan untuk mencapai hasil yang lebih optimal dengan Menambahkan lebih banyak data pelatihan, terutama untuk kelas yang memiliki banyak kesalahan klasifikasi, dapat membantu model untuk belajar membedakan antara kelas-kelas tersebut.

3. Evaluasi Pengujian Confusion Matrix B

Pengujian Confusion Matrix yang menunjukkan hasil prediksi model klasifikasi untuk tiga kelas kopra: basah, berjamur, dan kering, memperlihatkan jumlah sampel yang diklasifikasikan dengan benar dan salah. Pada kelas "basah," sebanyak 13 sampel diklasifikasikan dengan benar, sementara 7 sampel salah diklasifikasikan sebagai "berjamur." dan 1 sampel salah diklasifikasikan sebagai "basah". Untuk kelas "berjamur," 14 sampel diklasifikasikan dengan benar. Di kelas "kering," sebanyak 26 sampel diklasifikasikan dengan benar, sedangkan 6 sampel salah diklasifikasikan sebagai "berjamur." dan Secara keseluruhan, model menunjukkan kinerja yang baik terutama pada kelas "kering," meskipun ada beberapa kesalahan klasifikasi terutama kelas berjamur. Confusion Matrix adalah sebagai alat evaluasi yang sangat penting dalam penelitian model klasifikasi karena memberikan gambaran jelas tentang kinerja model dalam mengklasifikasikan data ke dalam kategori yang telah ditentukan. Dalam penelitian ini, Confusion Matrix digunakan untuk menguji hasil prediksi model klasifikasi pada tiga kelas kopra: "basah," "berjamur," dan "kering." Hasil yang diperoleh menunjukkan bahwa model memiliki kinerja yang cukup baik, namun juga ada beberapa kesalahan klasifikasi yang perlu dianalisis lebih lanjut. Beberapa kesalahan klasifikasi, terutama antara kelas "basah" dan "berjamur," menunjukkan adanya area yang perlu diperbaiki. Kesalahan ini menunjukkan bahwa model memiliki kesulitan membedakan antara kopra yang memiliki kemiripan tekstur atau kelembaban yang tinggi, seperti pada kelas "basah" dan "berjamur," sehingga untuk meningkatkan hasil yang lebih baik maka Meningkatkan jumlah sampel, khususnya yang mengalami kesalahan klasifikasi, dapat membantu model dalam membedakan antara kelas-kelas yang sulit dipisahkan.

4. Evaluasi Pengujian Confusion Matrix C

Pengujian Confusion Matrix yang menunjukkan hasil prediksi model klasifikasi untuk tiga kelas kopra: basah, berjamur, dan kering, memperlihatkan jumlah sampel yang diklasifikasikan dengan benar dan salah. Pada kelas "basah," sebanyak 52 sampel diklasifikasikan dengan benar, sementara 1 sampel salah diklasifikasikan sebagai "berjamur," dan 12 sampel salah diklasifikasikan sebagai "kering". Untuk kelas "berjamur," 48 sampel diklasifikasikan dengan benar, 5 sampel diklasifikasikan salah di kelas "basah", dan 3 sampel diklasifikasikan salah di kelas "kering". Di kelas "kering," sebanyak 43 sampel diklasifikasikan dengan benar, sedangkan 17 sampel salah diklasifikasikan sebagai "basah" dan 7 sampel diklasifikasikan salah di kelas "berjamur" serta secara keseluruhan, model menunjukkan kinerja yang baik terutama pada kelas "kering," meskipun ada beberapa kesalahan klasifikasi terutama kelas berjamur. Secara keseluruhan, Confusion Matrix

menunjukkan bahwa model memiliki performa yang cukup baik dalam mengklasifikasikan ketiga jenis kopra, tetapi ada beberapa area yang perlu diperhatikan untuk meningkatkan akurasi, terutama pada kesalahan klasifikasi antara kelas "basah" dan "kering." Kesalahan klasifikasi antara kelas-kelas ini mungkin disebabkan oleh kesamaan fitur visual pada beberapa sampel, yang membuat model sulit membedakan antara kopra basah dan kering. Selain itu, kesalahan klasifikasi di kelas "berjamur" relatif lebih rendah, yang menunjukkan bahwa model lebih baik dalam mengenali pola jamur pada kopra dibandingkan dengan pola basah dan kering. Analisis performance model menunjukkan bahwa kelas "kering" dan "basah" memiliki tingkat klasifikasi yang benar yang tinggi, menandakan bahwa model dapat mengenali kopra dengan baik pada kedua kelas ini. Sementara itu, model juga cukup efektif dalam mengenali kopra berjamur, meskipun masih ada beberapa kesalahan klasifikasi yang mungkin disebabkan oleh kesamaan fitur antara kopra berjamur dan jenis lainnya dalam kondisi tertentu. Untuk meningkatkan kinerja, terutama dalam membedakan antara kelas "basah" dan "kering," disarankan untuk menambahkan lebih banyak data pelatihan dengan variasi yang lebih luas dalam hal tekstur dan warna, atau menggunakan teknik pra-pemrosesan tambahan seperti peningkatan kontras atau segmentasi, yang dapat membantu model menangkap perbedaan kecil antar kelas dengan lebih baik.

4. KESIMPULAN

Berdasarkan hasil dan pembahasan yang telah diuraikan pada maka dapat diambil kesimpulan bahwa penelitian ini mengimplementasikan Metode *Canny Edge Detection* dengan Model Canny-Inception untuk otomatisasi dan peningkatan akurasi dalam menentukan kualitas kopra. Model ini mengklasifikasikan kopra ke dalam tiga kelas utama: "Basah," "Kering," dan "Berjamur." Kelas basah mencakup kopra dengan kadar air tinggi, kelas kering terdiri dari kopra yang telah melalui proses pengeringan dengan baik, Kelas berjamur mencakup kopra yang terkontaminasi jamur, yang dapat dikenali melalui warna dan baunya. Penelitian ini menggunakan tiga model pembagian data: Model A (80:10:10), Model B (70:20:10), dan Model C (60:30:10), Berdasarkan hasil uji coba model A (80:10:10) , B(70:20:10), dan C (60:30:10) dengan pembagian data yang berbeda, dapat disimpulkan bahwa Model C dengan pembagian data 60% untuk pelatihan, 30% untuk validasi, dan 10% untuk pengujian, mencapai performa terbaik dengan akurasi validasi sebesar 87,50% pada epoch = 9 dan nilai validation loss sebesar 40,27%, menandakan kemampuan generalisasi yang baik. Evaluasi pengujian confusion Matriks berdasarkan pembagian model pengujian Model A, Model B dan Model C memperoleh hasil Akurasi untuk Model A 81% untuk Kelas Basah, hasil akurasi model B sebesar 62% untuk performa kering dan hasil akurasi model C sebesar 76% untuk kelas berjamur.

REFERENSI

- [1] M. Z. Muzakkar *et al.*, "Pemberdayaan Masyarakat Pesisir Petoaha Dalam Pembuatan Bio-Briket Terdoping Smart Liquid TiO₂ Berkualitas Tinggi," 2023. doi: 10.35311/jmpm.v4i2.304.
- [2] R. U. Hanafi and N. Tinaprilla, "Daya Saing Komoditas Kakao Indonesia Di Perdagangan Internasional," 2017. doi: 10.29244/fagb.7.1.1-20.
- [3] O. Lawolo, B. A. Waruwu, K. F. Pelawi, and B. G. Saragih, "Analisis Potensi, Tantangan Dan Strategi Pengembangan Pertanian Di Kabupaten Nias, Provinsi Sumatera Utara," 2022. doi: 10.55606/jurrit.v1i2.431.
- [4] I. Zaldy, U. L. Khairat, and Maslan, "Sistem Deteksi Kualitas Kopra Berdasarkan Warna dan Tekstur," *Buletin Poltanesa*, vol. 23, no. 1, pp. 403–408, 2022, doi: 10.51967/tanesa.v23i1.
- [5] S. A. Batubara, "Perancangan Aplikasi Pengolahan Citra Digital Untuk Menentukan Bibit Unggul Biji Kopi dengan Metode Canny Edge Detection," *JURIKOM (Jurnal Riset Komputer)*, vol. 7, no. 3, p. 421, Jun. 2020, doi: 10.30865/jurikom.v7i3.2206.
- [6] H. Alam, Y. Manurung, H. Widya, and W. H. Nanda, "Penggunaan Metode Canny Edge Detection Untuk Mendeteksi Tepi Uang Kertas Asli Berbasis Java," In *Semnastek Uisu*, 2023, pp. 177–181.
- [7] A. Abdullah, U. Usman, and M. Efendi, "Copra Quality Classification System Based on Color and Texture Using Nearest Mean Classifier (NMC) Method," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 4, no. 4, p. 297, Dec. 2017, doi: 10.25126/jtiik.201744479.
- [8] M. F. H. Dermawan, D. Winarsyah, and H. Fakhruroja, "Penerapan Image Processing untuk Mengetahui Tingkat Kematangan Kopi Menggunakan Algoritma K-Nearest Neighbor (KNN) pada Perkebunan Kopi Malabar Bandung," *e-Proceeding of Engineering*, vol. 10, no. 3, pp. 3246–3252, 2023.
- [9] I. H. Lahay, J. Darusalam Giu, and M. Bawole, "Penentuan Grade Kopra Dengan Penerapan Metode Logika Fuzzy," *Jambura Journal of Electrical and Electronics Engineering*, vol. 5, no. 1, pp. 122–129, 2023, doi: 10.37905/jjee.v5i1.17073.
- [10] L. Maximillian, Y. Finsensia Riti, M. Anugraha, and Y. J. Palis, "Perbandingan Algoritma Sobel Dan Canny Untuk Deteksi Tepi Citra Daun Lidah Buaya," *KOMPUTA : Jurnal Ilmiah Komputer dan Informatika*, vol. 12, no. 2, 2023, doi: 10.34010/komputa.v12i2.10997.
- [11] M. R. Pratama and I. F. Hanif, "Implementasi Metode Canny dalam Deteksi Tepi pada Aplikasi OMR (Optical Mark Recognition) Menggunakan Pengembangan Sistem Waterfall," *Edunity : Kajian Ilmu Sosial dan Pendidikan*, 2023, [Online]. Available: <https://api.semanticscholar.org/CorpusID:257359380>

-
- [12] A. Mustafid and S. Uyun, "Segmentasi Citra Sapi Berbasis Deteksi Tepi Menggunakan Algoritma Canny Edge Detection," *J Biomed Inform*, vol. 8, 2017, [Online]. Available: <https://api.semanticscholar.org/CorpusID:67054379>
- [13] N. Panjaitan, "Segmentasi Citra Digital Dengan Menggunakan Algoritma Khutlang," *Journal of Information System Research (JOSH)*, vol. 1, no. 4, Jul. 2020, [Online]. Available: <https://ejurnal.seminar-id.com/index.php/josh/article/view/154>
- [14] R. Rahayu Marlis, F. Yunita, and Abdullah, "Sistem Prediksi Kualitas Kopra Putih Menggunakan k-Nearest Neighbor (k-NN)," *SISTEMASI: Jurnal Sistem Informasi*, vol. 10, no. 2, pp. 290–299, 2021, [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [15] D. Tribuana, Hazriani, and A. Latief Arda, "Image Preprocessing Approaches Toward Better Learning Performance with CNN," *JOURNAL RESTI (Rekayasa Sistem Teknologi Informasi)*, vol. 8, no. 1, pp. 1–9, 2024, doi: 10.29207/resti.v8i1.5417.
- [16] D. Tribuana, H. Hazriani, and A. Latief Arda, "Face recognition for smart door security access with convolutional neural network method," *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, vol. 22, no. 3, pp. 702–710, Jun. 2024, doi: 10.12928/telkomnika.v22i3.25946.
- [17] Riswanto, A. Ahmad, Hazriani, and D. Tribuana, "Calorie Detection of Traditional Indonesian Food Using the Single Shot Multibox Detector (SSD) Method," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 3, pp. 819–829, 2024, doi: 10.57152/malcom.v4i3.1332.
- [18] S. A. Batubara, "Perancangan Aplikasi Pengolahan Citra Digital Untuk Menentukan Bibit Unggul Biji Kopi dengan Metode Canny Edge Detection," *JURIKOM (Jurnal Riset Komputer)*, vol. 7, no. 3, p. 421, 2020, doi: 10.30865/jurikom.v7i3.2206.
- [19] I. H. Lahay, H. Hasanuddin, J. D. Giu, and M. G. Bawole, "Penentuan Grade Kopra Dengan Penerapan Metode Logika Fuzzy," *Jambura Journal of Electrical and Electronics Engineering*, vol. 5, no. 1, pp. 122–129, 2023, doi: 10.37905/jjee.v5i1.17073.
- [20] Md. A. Rahman, M. F. I. Amin, and M. Hamada, "Edge Detection Technique by Histogram Processing with Canny Edge Detector," in *2020 3rd IEEE International Conference on Knowledge Innovation and Invention (ICKII)*, 2020, pp. 128–131. doi: 10.1109/ICKII50300.2020.9318922.
- [21] T. Pinandita, O. T. Rasdianto, and S. Sugiyanto, "Implementation of the canny edge detection algorithm on mobile cameras," *AIP Conf Proc*, vol. 2578, no. 1, p. 060013, Nov. 2022, doi: 10.1063/5.0119148.
- [22] K. Muhammad Rizky Alditra Utama, R. Umar, and A. Yuhdana, "Edge detection comparative analysis using Roberts, Sobel, Prewitt, and Canny methods," *Jurnal Teknologi dan Sistem Komputer*, vol. 10, no. 2, pp. 67–71, 2022, doi: 10.14710/jtsiskom.2022.14209.
- [23] D. Sundani, S. Widiyanto, Y. Karyanti, and D. T. Wardani, "Identification of Image Edge Using Quantum Canny Edge Detection Algorithm," *Journal of ICT Research and Applications*, vol. 13, no. 2, pp. 133–144, Sep. 2019, doi: 10.5614/itbj.ict.res.appl.2019.13.2.4.