

Perbandingan Akurasi Metode Convolutional Neural Network (CNN) dan Sobel untuk Klasifikasi Buah Rambutan melalui Pengolahan Citra

Satria Abel^{*1}, Abdi Mulia Pranidana², Lailil Qasos³, Nuriana⁴, Munirul Ula⁵

Teknik Informatika, Universitas Malikussaleh, Lhokseumawe, Aceh

Email: ¹satria.210170115@mhs.unimal.ac.id, ²Abdi.210170110@mhs.unimal.ac.id,
³lailil.210170120@mhs.unimal.ac.id, ⁴nuriana.210170089@mhs.unimal.ac.id, ⁵munirulula@unimal.ac.id

Abstract

The automatic determination of rambutan fruit ripeness is a crucial step in enhancing efficiency in the agricultural sector. This study compares two image processing methods, namely Sobel and Convolutional Neural Network (CNN), for the classification of rambutan fruit ripeness. The Sobel method was used for edge detection with an accuracy of 75.32%, while CNN was applied to recognize complex visual patterns, achieving an accuracy of 98.09%. The dataset used consisted of 1,416 rambutan images categorized into four ripeness stages: unripe, semi-ripe, ripe, and rotten. The CNN model training process was conducted over several epochs, resulting in a training accuracy of 99% and a validation accuracy of 100%. The results of this study indicate that CNN outperforms Sobel in handling more complex image classification tasks, with a significant difference in accuracy. These findings provide a valuable contribution to the development of automatic classification systems to support quality improvement of fruits in the agricultural industry.

Keywords: Image Processing, Rambutan, CNN (Convolution Neural Network), Sobel, Classification

Abstrak

Penentuan kematangan buah rambutan secara otomatis merupakan langkah penting untuk meningkatkan efisiensi di sektor pertanian. Penelitian ini membandingkan dua metode pengolahan citra, yaitu Sobel dan Convolutional Neural Network (CNN), untuk klasifikasi kematangan buah rambutan. Metode Sobel digunakan untuk deteksi tepi dengan akurasi sebesar 75,32%, sedangkan Convolutional Neural Network (CNN) diaplikasikan untuk mengenali pola visual kompleks, menghasilkan akurasi sebesar 98,09%. Dataset yang digunakan terdiri dari 1416 gambar rambutan yang dikelompokkan ke dalam empat kategori kematangan: mentah, setengah matang, matang, dan busuk. Proses pelatihan model Convolutional Neural Network (CNN) dilakukan selama beberapa epoch, dengan akurasi pelatihan mencapai 99% dan akurasi validasi sebesar 100%. Hasil penelitian ini menunjukkan bahwa Convolutional Neural Network (CNN) lebih unggul dalam menangani klasifikasi citra yang lebih rumit dibandingkan Sobel, dengan perbedaan signifikan dalam akurasi. Temuan ini memberikan kontribusi penting dalam pengembangan sistem klasifikasi otomatis untuk mendukung peningkatan kualitas buah di industri pertanian.

Kata Kunci: Pengolahan Citra, Rambutan, CNN, Sobel, Klasifikasi

1. PENDAHULUAN

Rambutan (*Nephelium lappaceum* L.) merupakan buah tropis asli Indonesia dengan produksi tahunan mencapai 350.000 ton, yang tidak hanya dikonsumsi dalam negeri tetapi juga diekspor ke luar negeri. [1] Penentuan kematangan rambutan tradisional umumnya dilakukan secara visual berdasarkan perubahan warna kulit, mulai dari hijau (mentah), kuning (setengah matang), merah (matang), hingga hitam (busuk). Namun, metode ini seringkali kurang akurat karena bergantung pada penilaian subjektif, yang menyebabkan inkonsistensi dalam hasil.


Kemajuan teknologi pengolahan citra menawarkan solusi lebih objektif dan efisien. Dalam penelitian ini, dua metode pengolahan citra dibandingkan untuk klasifikasi kematangan rambutan, yaitu metode Sobel dan Convolutional Neural Network (CNN). Sobel, yang terkenal karena kesederhanaannya, digunakan untuk mendeteksi perubahan warna dengan menghitung gradien pada gambar. metode deteksi tepi yang diterapkan memanfaatkan gradien, yang merupakan konsep matematis yang dikenal sebagai turunan pertama. Konsep ini dapat digunakan dalam fungsi untuk mendeteksi tepi [2]. Convolutional Neural Network (CNN) merupakan metode deep learning yang secara otomatis dapat mengenali pola visual lebih rumit seperti bentuk dan tekstur. Convolutional Neural Network (CNN) lebih unggul dalam menangkap detail yang lebih kompleks, tetapi membutuhkan komputasi yang tinggi dan data yang lebih banyak. [3]

Penelitian ini bertujuan membandingkan kinerja Sobel dan Convolutional Neural Network (CNN) dalam mengklasifikasikan kematangan rambutan. Hasilnya diharapkan memberikan wawasan mengenai efektivitas kedua metode, serta membuka peluang pengembangan sistem klasifikasi otomatis yang lebih akurat dan efisien di sektor pertanian.

2. METODE PENELITIAN

Pada penelitian ini terdapat tahapan – tahapan yang dilakukan, dapat dilihat melalui diagram alir seperti yang ditunjukkan pada ditunjukkan pada Gambar 1.

Sobel



Gambar 1. Diagram Alir Sobel 1

a. Sobel

Terdapat lima langkah yang akan dilaksanakan dalam penelitian ini yaitu :

1. Citra Input
Tahap pertama dalam penelitian ini adalah pengambilan citra buah rambutan menggunakan kamera digital. Citra diambil dari buah dengan berbagai tingkat kematangan, yaitu mentah, setengah matang, matang, dan busuk. Setiap gambar diambil dalam kondisi pencahayaan yang seragam untuk menjaga konsistensi data.
2. Konversi ke Grayscale
Setelah citra diambil, langkah selanjutnya adalah mengonversi citra dari format RGB ke grayscale. Konversi ini dilakukan untuk menyederhanakan data warna menjadi intensitas cahaya, yang akan mempermudah proses deteksi tepi. Citra grayscale ini menyimpan informasi penting tentang perubahan intensitas di berbagai bagian buah.
3. Deteksi Tepi Menggunakan Metode Sobel
Lalu berikutnya adalah melakukan detection dengan operator sobel. Tujuan dari tahapan ini adalah untuk mendapatkan batas antara satu obyek
4. Citra Output
Hasil dari proses deteksi tepi Sobel adalah citra yang memperlihatkan kontur dan perubahan signifikan pada kulit buah rambutan. Citra output ini akan digunakan untuk memisahkan area yang relevan untuk analisis lebih lanjut, seperti segmentasi warna atau fitur lainnya.
5. Evaluasi
Tahap terakhir dalam metode ini adalah evaluasi hasil klasifikasi. Citra output yang dihasilkan akan dianalisis dan dibandingkan dengan citra ground truth yang telah dinilai secara manual oleh ahli. Kinerja sistem diukur berdasarkan tingkat akurasi dalam mengklasifikasikan kematangan buah rambutan ke dalam kategori yang ditetapkan, yaitu mentah, setengah matang, matang, dan busuk.

b. CNN

1. Mulai, Proses klasifikasi dimulai dengan menyiapkan seluruh data dan perangkat yang dibutuhkan.

2. Pengumpulan Mengumpulkan citra buah rambutan pada berbagai tingkat kematangan. Data ini menjadi input utama dalam sistem klasifikasi
3. Pra-pemrosesan Data
 - a. Penyesuaian Ukuran : Setiap citra diubah ukurannya agar seragam, biasanya ke resolusi yang diinginkan oleh model Convolutional Neural Network (CNN).
 - b. Normalisasi: Nilai piksel citra dinormalisasi ke skala 0-1 untuk mempercepat proses pelatihan.
 - c. Augmentasi Data: Dilakukan augmentasi seperti rotasi, flipping, dan zoom untuk memperkaya variasi data guna menghindari overfitting.
4. Pembagian Data Latih dan Uji (Train/Test Split)
Dataset dibagi menjadi dua, data latih (80%) untuk melatih model dan data uji (20%) untuk mengevaluasi performa model.
5. Kompilasi Model Convolutional Neural Network (CNN)
Model Convolutional Neural Network (CNN) dibangun dengan arsitektur yang mencakup lapisan konvolusi, pooling, dan fully connected. Model dikompilasi menggunakan fungsi loss yang tepat dan optimizer seperti Adam.
6. Klasifikasi
Model dilatih menggunakan data latih selama beberapa epoch, memungkinkan model untuk mengenali pola visual yang terkait dengan kematangan buah rambutan.
7. Evaluasi Model
Kinerja model diuji menggunakan data uji untuk mengukur akurasi dalam mengklasifikasikan tingkat kematangan buah rambutan.

2.1 Data Set

Penelitian ini menggunakan dataset yang terdiri dari citra buah rambutan, yang dipilih untuk mengeksplorasi berbagai tahap kematangan buah ini. Rambutan adalah buah tropis yang dikenal dengan rasa manis dan tekstur unik, serta memiliki perbedaan visual yang signifikan tergantung pada tingkat kematangannya[4]. Dalam dataset ini, kami mengkategorikan buah rambutan ke dalam empat tahap kematangan: rambutan mentah, hampir matang, matang, dan busuk.

Jumlah total citra yang dikumpulkan dalam penelitian ini adalah 1416, dengan 66 data train. Pemilihan jumlah dan kategori ini dirancang untuk menciptakan representasi yang menyeluruh mengenai variasi visual serta karakteristik yang muncul pada setiap tahap kematangan. Citra rambutan mentah biasanya ditandai dengan warna hijau pucat dan kulit yang keras, sedangkan rambutan yang hampir matang menunjukkan warna yang mulai berubah, mendekati kuning atau merah muda. Buah rambutan yang sudah matang memiliki warna merah atau kuning cerah dengan tampilan yang segar, sementara rambutan busuk menunjukkan perubahan warna yang signifikan dan tekstur yang lembek, menandakan bahwa buah tersebut sudah tidak layak konsumsi.

Dataset ini sangat penting untuk analisis dan pengembangan model dalam penelitian ini, karena memberikan gambaran yang jelas tentang perbedaan visual yang dapat digunakan untuk tujuan klasifikasi atau identifikasi otomatis. Beberapa contoh citra dari dataset ini dapat dilihat pada Gambar 2, yang memperlihatkan perbedaan karakteristik visual dari masing-masing kategori, serta memberikan konteks yang lebih baik mengenai variasi yang ada pada buah rambutan. Melalui penggunaan dataset ini, diharapkan dapat diperoleh hasil yang lebih akurat dan representatif dalam penelitian ini.



Gambar 2. Dataset Rambutan

3. HASIL DAN PEMBAHASAN

3.1 Operator Sobel

Operator Sobel diperkenalkan oleh Irwin Sobel pada tahun 1970 dan merupakan salah satu metode deteksi tepi yang termasuk dalam kategori gradient edge detector. Metode ini menggunakan sebuah matriks atau jendela berukuran 3x3 piksel untuk menghitung gradien citra dalam arah vertikal dan horizontal[5]. Proses ini dilakukan dengan melakukan konvolusi antara matriks Sobel dan citra asli, di mana hasilnya adalah estimasi gradien dalam kedua arah tersebut.

Deteksi tepi dilakukan dengan cara membandingkan nilai gradien yang dihasilkan dengan sebuah threshold yang ditetapkan sebelumnya. Pixel akan dianggap sebagai tepi (edge) jika nilai gradiennya melebihi nilai threshold tersebut. Dengan pendekatan ini, operator Sobel mampu mengidentifikasi perubahan tajam dalam intensitas citra, yang sering menandakan adanya tepi objek dalam gambar.

3.1.1 Convert Greyscale

```

1 # Aplikasi operator Sobel pada kanal grayscale
2 gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)
3 sobelx = cv2.Sobel(gray, cv2.CV_64F, 1, 0, ksize=5)
4 sobely = cv2.Sobel(gray, cv2.CV_64F, 0, 1, ksize=5)
5 magnitude = np.sqrt(sobelx**2 + sobely**2)
6
7 # Menyimpan hasil deteksi tepi dan warna buah rambutan
8 edges = magnitude.astype(np.uint8)
9 detected_color_busuk = cv2.bitwise_and(mask_busuk, mask_busuk, mask=edges)
10 detected_color_mentah = cv2.bitwise_and(mask_mentah, mask_mentah, mask=edges)
11 detected_color_setengah_matang = cv2.bitwise_and(mask_setengah_matang, mask_setengah_matang, mask=edges)
12 detected_color_matang = cv2.bitwise_and(mask_matang, mask_matang, mask=edges)
13
14 # Menentukan kondisi buah rambutan berdasarkan deteksi warna
15 jumlah_busuk = cv2.countNonZero(detected_color_busuk)
16 jumlah_mentah = cv2.countNonZero(detected_color_mentah)
17 jumlah_setengah_matang = cv2.countNonZero(detected_color_setengah_matang)
18 jumlah_matang = cv2.countNonZero(detected_color_matang)
19
20 if jumlah_matang > max(jumlah_busuk, jumlah_mentah, jumlah_setengah_matang):
21     status_text = "MAIANG"
22     text_color = (0, 0, 255) # warna teks merah untuk buah rambutan matang
23 elif jumlah_setengah_matang > max(jumlah_busuk, jumlah_mentah, jumlah_matang):
24     status_text = "HAMPIR MAIANG"
25     text_color = (0, 165, 255) # warna teks orange untuk buah rambutan setengah matang
26 elif jumlah_mentah > max(jumlah_busuk, jumlah_setengah_matang, jumlah_matang):
27     status_text = "MUDA"
28     text_color = (0, 255, 0) # warna teks hijau untuk buah rambutan mentah
29 else:
30     status_text = "BUSUK"
31     text_color = (0, 0, 0) # warna teks hitam untuk buah rambutan busuk
32

```

Gambar 3 Algoritma *Convert Grayscale*

Program yang diberikan mengimplementasikan deteksi kematangan buah rambutan menggunakan operator Sobel pada citra grayscale. Pertama, citra berwarna diubah menjadi citra grayscale menggunakan konversi `cv2.cvtColor()`. Selanjutnya, operator Sobel diterapkan untuk menghitung gradien horizontal dan vertikal dari citra grayscale, yang dihitung menjadi magnitudo gradien dengan rumus Pythagoras. Hasil magnitudo ini digunakan sebagai citra yang menunjukkan lokasi tepi-tepi signifikan dalam citra grayscale. Selanjutnya, hasil deteksi tepi tersebut diterapkan pada masker warna yang mewakili berbagai tingkat Halaman| 3 kematangan buah rambutan (busuk, mentah, setengah matang, dan matang) menggunakan operasi bitwise AND. Penghitungan jumlah piksel non-nol dalam setiap masker memberikan indikasi jumlah piksel yang sesuai dengan setiap tingkat kematangan[6]. Berdasarkan perbandingan jumlah piksel yang sesuai, program menentukan status kematangan buah rambutan (matang, hampir matang, mentah, atau busuk) dan menetapkan warna teks yang sesuai untuk ditampilkan pada gambar hasil. Dengan pendekatan ini, program mampu mengklasifikasikan kematangan buah rambutan secara otomatis berdasarkan analisis tepi pada citra grayscale yang telah diproses.

3.1.2 Edge Detection

Proses deteksi tepi dengan metode sobel dilakukan pada semua citra penampang kayu berwarna grayscale. Edge detection berfungsi mendeteksi garis/tepi pada semua obyek yang ada di dalam Gambar 4.

```

1 Fungsi untuk mendeteksi warna buah rambutan menggunakan metode Sobel
2 def detect_rambutan_color(image_path):
3     # Load gambar
4     img = cv2.imread(image_path)
5     if img is None:
6         print(f"Gambar {image_path} tidak dapat dimuat. Pastikan path benar.")
7         return
8
9     # Simpan salinan asli gambar untuk ditampilkan nantinya
10    original = img.copy()
11
12    # Konversi warna BGR ke HSV
13    hsv = cv2.cvtColor(img, cv2.COLOR_BGR2HSV)
14
15    # Definisi batas-batas warna untuk buah rambutan busuk (hitam)
16    lower_busuk = np.array([0, 0, 0])
17    upper_busuk = np.array([180, 255, 50])
18
19    # Definisi batas-batas warna untuk buah rambutan mentah (hijau)
20    lower_mentah = np.array([35, 50, 50])
21    upper_mentah = np.array([85, 255, 255])
22
23    # Definisi batas-batas warna untuk buah rambutan setengah matang (kuning)
24    lower_setengah_matang = np.array([20, 50, 50])
25    upper_setengah_matang = np.array([30, 255, 255])
26
27    # Definisi batas-batas warna untuk buah rambutan matang (merah)
28    lower_matang = np.array([0, 50, 50])
29    upper_matang = np.array([10, 255, 255])
30
31    # Membuat mask dari gambar HSV menggunakan batas warna
32    mask_busuk = cv2.inRange(hsv, lower_busuk, upper_busuk)
33    mask_mentah = cv2.inRange(hsv, lower_mentah, upper_mentah)
34    mask_setengah_matang = cv2.inRange(hsv, lower_setengah_matang, upper_setengah_matang)
35    mask_matang = cv2.inRange(hsv, lower_matang, upper_matang)

```

Gambar 4. Proses Edge Detection

Fungsi “detect_rambutan_color” bertujuan untuk mengenali buah rambutan dalam gambar berdasarkan warnanya menggunakan ruang warna HSV[7]. Pertama, gambar dimuat dari path yang ditentukan. Jika gagal dimuat, fungsi memberikan pesan kesalahan. Gambar asli disalin untuk tujuan visualisasi. Selanjutnya, gambar dikonversi dari BGR ke HSV untuk mempermudah deteksi warna berdasarkan hue, saturation, dan value. Batas-batas warna untuk buah rambutan dalam berbagai tahap kematangan (busuk, mentah, setengah matang, matang) ditetapkan dalam HSV. Mask digunakan untuk memisahkan area gambar yang sesuai dengan setiap tahap kematangan berdasarkan warna. Ini adalah proses penting dalam aplikasi deteksi warna untuk analisis buah berdasarkan tingkat kematangan mereka.

3.1.3 Pemrosesan HSV

Sistem warna HSV (Hue, Saturation, Value) adalah metode yang intuitif untuk menggambarkan dan mengelompokkan warna dalam pengolahan citra dan grafika komputer[8]. Hue mengacu pada tona warna murni seperti merah, hijau, dan biru, diukur dalam skala lingkaran warna dari 0 hingga 360 derajat. Saturation menentukan kemurnian warna, dengan nilai tinggi menunjukkan warna yang lebih jelas dan nilai rendah mendekati warna abu-abu. Value mengukur kecerahan warna, di mana nilai tinggi menunjukkan warna yang lebih terang dan nilai rendah menunjukkan warna yang lebih gelap. Dengan kombinasi tiga komponen ini, sistem HSV memberikan fleksibilitas dalam analisis dan manipulasi warna dalam konteks pengolahan citra

Tabel.1. Dataset HSV

No	Hue mean(%)	Saturation mean(%)	Value mean(%)	Status
1	14.03%	9.39%	70.69%	Mentah
2	12.15%	8.55%	76.31%	Hampir Matang
3	26.55%	6.02%	72.90%	Matang
4	17.29%	2,69%	68.89%	Busuk

3.1.4 Pengujian Metode Sobel

Pada proses ini dilakukan pengujian terhadap 4 foto atau gambar rambutan. Proses pengujian ini dapat dilihat Gambar5 pada Gambar6, Gambar7, Gambar 8



Gambar5 Hasil Proses Rambutan Mentah



Gambar6 Hasil Proses Rambutan Hampir Matang



Gambar7 Hasil Proses Rambutan Matang



Gambar8 Hasil Proses Rambutan Hampir Matang


Berdasarkan hasil dari pengujian model yang telah dilakukan, metode Sobel berhasil batik pada sebuah foto dengan hasil seperti di atas.

3.2 Convolutional Neural network


Convolutional Neural Network (CNN) adalah salah satu algoritma deep learning yang dikembangkan berdasarkan konsep Multi Layer Perceptron (MLP), dan dirancang khusus untuk memproses data yang umumnya berbentuk dua dimensi[9].

3.2.1 Penghimpunan Data


Data citra Buah Rambutan yang digunakan dalam penelitian ini diambil dari repositori Kaggle. Total terdapat 1416 citra yang diperoleh. Format gambar adalah JPEG dengan resolusi 100 x 600 piksel. Sebanyak 1350 citra digunakan sebagai data uji, sedangkan 66 citra lainnya digunakan sebagai data latih untuk praproses data dan pengembangan model klasifikasi. Data yang di gunakan yaitu berupa gambar. Dataset ini berisi citra buah rambutan yang dikelompokkan ke dalam empat kategori kematangan, yaitu mentah, setengah matang, matang, dan busuk. Ukuran dataset tergolong kecil. Klasifikasi dilakukan untuk membedakan tingkat kematangan buah rambutan berdasarkan keempat kategori tersebut. Contoh gambar untuk setiap kategori dapat dilihat pada Gambar 8, 9, 10, dan 11, yang masing-masing mewakili citra rambutan dalam kondisi mentah, setengah matang, matang, dan busuk.




Gambar 8. Rambutan Mentah



Gambar 9. Setengah Matang



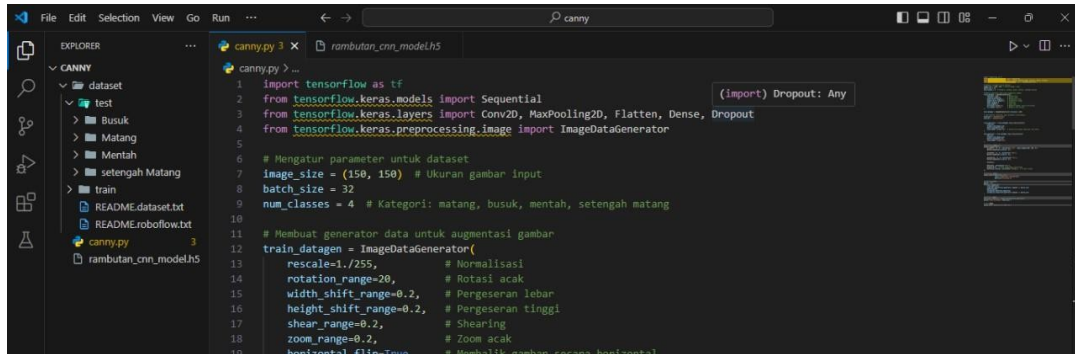
Gambar 10. Matang



Gambar 11. Busuk

3.2.2 CNN Model

Pada tahap ini, penerapan Convolutional Neural Network (CNN) dilakukan menggunakan Visual Studio Code sebagai platform pengembangan. Untuk membangun model jaringan syaraf tiruan, library TensorFlow dan Keras yang dikenal luas di ranah deep learning digunakan. Kedua library ini menyediakan abstraksi tingkat tinggi yang memudahkan pengembang untuk merancang, mengembangkan, dan melatih model Convolutional Neural Network (CNN) dengan lebih efisien. Selain itu, teknik augmentasi data diterapkan untuk memperkaya variasi dataset, yang bertujuan meningkatkan kinerja model dalam mengklasifikasikan tingkat kematangan buah rambutan[10]. Gambar 12 memperlihatkan proses impor library TensorFlow dan Keras, serta penentuan direktori path untuk dataset yang digunakan dalam pelatihan model ini.



Gambar 12. Proses Impor Library

Pada Gambar 12, ditunjukkan penggunaan Visual Studio Code sebagai platform pengembangan untuk membangun model CNN yang memanfaatkan library TensorFlow dan Keras. Kode dalam gambar tersebut memperlihatkan bagaimana pengaturan parameter dataset, seperti ukuran gambar dan jumlah batch yang digunakan selama proses pelatihan. Dengan menggunakan Image Data Generator dari Keras, proses augmentasi data diterapkan untuk memperkaya dataset dengan variasi tambahan melalui rotasi, pergeseran, zoom, dan pembalikan gambar secara horizontal, yang bertujuan meningkatkan kinerja model.

Pengaturan direktori path yang ditampilkan sangat penting untuk mengorganisir dan mengelola data yang digunakan dalam pelatihan dan pengujian model CNN. Folder-folder seperti "Busuk", "Matang", "Mentah", dan "Setengah Matang" berfungsi sebagai label kategori untuk klasifikasi tingkat kematangan buah rambutan. Gambar ini juga memperlihatkan proses augmentasi dan praproses gambar, di mana teknik augmentasi berperan dalam meningkatkan variasi data dan membantu model dalam mengenali pola pada data yang berbeda, yang dapat meningkatkan akurasi prediksi model.



Gambar 13. Augmentasi

Kode ini menggunakan "ImageDataGenerator" untuk melakukan augmentasi data gambar pelatihan dengan transformasi seperti normalisasi, rotasi, pergeseran, shear, zoom, dan pembalikan horizontal guna meningkatkan variasi data. Data pengujian hanya dinormalisasi. Kemudian, "train_generator" dan "test_generator" memuat data dari direktori dataset/train dan dataset/test untuk digunakan dalam pelatihan dan pengujian model klasifikasi gambar.

Sebagai lanjutan dari proses augmentasi dan persiapan data, langkah berikutnya adalah pelatihan model CNN yang dilakukan dengan menggunakan data gambar yang telah diproses. Hasil dari pelatihan model CNN dapat dilihat pada Gambar 14 di mana terlihat bahwa proses pelatihan dilakukan selama beberapa epoch.

```

[[[mode IteratorGetNext]]]
44/64 1s 26s/step - accuracy: 0.8125 - loss: 0.5725 - val_accuracy: 1.0000 - val_loss: 0.0400
44/64 2s 48s/step - accuracy: 0.8844 - loss: 0.2893 - val_accuracy: 1.0000 - val_loss: 0.0400
44/64 3s 72s/step - accuracy: 0.9375 - loss: 0.25430814-10-01 15:25:28.760479: I tensorflow/core/framework/local_rendevous.cc:404] Local rendevous is aborting with status: OUT_OF_RANGE: end of sequence
[[[mode IteratorGetNext]]]
44/64 4s 96s/step - accuracy: 0.9375 - loss: 0.2554 - val_accuracy: 1.0000 - val_loss: 0.0601
44/64 5s 120s/step - accuracy: 0.9240 - loss: 0.2638 - val_accuracy: 1.0000 - val_loss: 0.0271
44/64 6s 144s/step - accuracy: 0.9802 - loss: 0.1837 - val_accuracy: 1.0000 - val_loss: 0.0013
44/64 7s 168s/step - accuracy: 0.9421 - loss: 0.1828 - val_accuracy: 0.9511 - val_loss: 0.1634
44/64 8s 192s/step - accuracy: 0.8750 - loss: 0.26773034-10-01 15:26:12.865624: I tensorflow/core/framework/local_rendevous.cc:404] Local rendevous is aborting with status: OUT_OF_RANGE: end of sequence
[[[mode IteratorGetNext]]]
44/64 9s 216s/step - accuracy: 0.8750 - loss: 0.2677 - val_accuracy: 1.0000 - val_loss: 0.0408
44/64 10s 240s/step - accuracy: 0.9438 - loss: 0.1622 - val_accuracy: 0.9544 - val_loss: 0.0393
44/64 11s 264s/step - accuracy: 0.9688 - loss: 0.0907 - val_accuracy: 1.0000 - val_loss: 0.12076-01
44/64 12s 288s/step - accuracy: 0.9577 - loss: 0.0971 - val_accuracy: 0.9844 - val_loss: 0.0937
44/64 13s 312s/step - accuracy: 0.9688 - loss: 0.0417 - val_accuracy: 1.0000 - val_loss: 0.0013
44/64 14s 336s/step - accuracy: 0.9647 - loss: 0.0401 - val_accuracy: 0.9844 - val_loss: 0.0213
44/64 15s 360s/step - accuracy: 1.0000 - loss: 0.0568 - val_accuracy: 1.0000 - val_loss: 1.0930e-04
44/64 16s 384s/step - accuracy: 0.9555 - loss: 0.1162 - val_accuracy: 1.0000 - val_loss: 0.0005
44/64 17s 408s/step - accuracy: 0.9375 - loss: 0.10402014-10-01 15:27:36.480910: I tensorflow/core/framework/local_rendevous.cc:404] Local rendevous is aborting with status: OUT_OF_RANGE: end of sequence
[[[mode IteratorGetNext]]]
44/64 18s 432s/step - accuracy: 0.9375 - loss: 0.1046 - val_accuracy: 0.9800 - val_loss: 0.9386
44/64 19s 456s/step - accuracy: 0.9622 - loss: 0.1096 - val_accuracy: 1.0000 - val_loss: 0.0012
44/64 20s 480s/step - accuracy: 0.9688 - loss: 0.1127 - val_accuracy: 1.0000 - val_loss: 5.2462e-06
44/64 21s 504s/step - accuracy: 0.9625 - loss: 0.1175 - val_accuracy: 0.9844 - val_loss: 0.0013
44/64 22s 528s/step - accuracy: 0.9802 - loss: 0.1021 - val_accuracy: 1.0000 - val_loss: 0.0007
44/64 23s 552s/step - accuracy: 0.9624 - loss: 0.1238 - val_accuracy: 1.0000 - val_loss: 0.0006
44/64 24s 576s/step - accuracy: 0.9688 - loss: 0.0616 - val_accuracy: 1.0000 - val_loss: 0.0005
44/64 25s 600s/step - accuracy: 0.9824 - loss: 0.0611 - val_accuracy: 0.9844 - val_loss: 0.0113
44/64 26s 624s/step - accuracy: 0.9688 - loss: 0.1079 - val_accuracy: 1.0000 - val_loss: 0.0140
44/64 27s 648s/step - accuracy: 0.9688 - loss: 0.1079 - val_accuracy: 1.0000 - val_loss: 0.0140
44/64 28s 672s/step - accuracy: 0.9688 - loss: 0.1079 - val_accuracy: 1.0000 - val_loss: 0.0140
44/64 29s 696s/step - accuracy: 0.9762 - loss: 0.0698 - val_accuracy: 0.9688 - val_loss: 0.0008
44/64 30s 720s/step - accuracy: 0.9809 - loss: 0.0725

```

Gambar 14. hasil training model CNN

Secara keseluruhan, model menunjukkan peningkatan akurasi yang konsisten pada setiap epoch, dengan nilai akurasi pelatihan (training accuracy) mencapai lebih dari 99%, dan akurasi validasi (validation accuracy) juga mencapai 100% di akhir pelatihan. Hal ini menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam mempelajari pola dari data pelatihan. Selain itu, nilai loss baik pada data pelatihan maupun data validasi terus menurun seiring berjalannya epoch, menunjukkan bahwa model semakin mampu meminimalkan kesalahan prediksi. Namun, perlu diperhatikan juga bahwa pencapaian akurasi yang sangat tinggi dan loss yang sangat rendah ini mungkin menunjukkan potensi overfitting, terutama jika perbedaan antara akurasi pelatihan dan validasi terlalu besar atau jika performa pada data uji nanti tidak sebaik hasil ini.

Setelah tahap pelatihan selesai, model CNN kemudian dievaluasi menggunakan data pengujian untuk mengukur performanya terhadap data yang belum pernah dilihat selama pelatihan.


```

77 # Evaluasi model
78 test_loss, test_acc = model.evaluate(test_generator)
79 print(f'Test accuracy: {test_acc}')
80
PROBLEMS 3 OUTPUT DEBUG CONSOLE TERMINAL PORTS
3/3 0s 57ms/step - accuracy: 0.9809 - loss: 0.0725
3/3 0s 57ms/step - accuracy: 0.9809 - loss: 0.0725
Test accuracy: 0.9696969985961914
Test accuracy: 0.9696969985961914

```


Gambar 15. Evaluasi

Hasil dari evaluasi mengindikasikan bahwa model memperoleh akurasi sebesar 98.09% dan nilai loss 0.0725. Ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik pada data pengujian, yang mengarah pada kesimpulan bahwa model ini berfungsi dengan sangat baik dalam mengklasifikasikan data gambar dengan tingkat kesalahan yang minimal.



Gambar 16. Grafik Akurasi Model

Grafik akurasi menunjukkan bahwa model secara konsisten meningkatkan kemampuannya dalam memprediksi data seiring bertambahnya epoch. Diawali dengan akurasi pelatihan sekitar 50% pada epoch pertama, model ini terus mengalami peningkatan hingga hampir mencapai 100% di akhir pelatihan, yang menandakan bahwa pemahaman model terhadap pola data pelatihan semakin baik. Akurasi validasi, yang menunjukkan performa model pada data yang tidak terlihat selama pelatihan, juga meningkat dengan tren yang serupa. Meskipun pada beberapa titik akurasi validasi sedikit di bawah akurasi pelatihan, keduanya berakhir pada tingkat yang sangat tinggi, mendekati 100%. Ini menunjukkan bahwa model menunjukkan kemampuan generalisasi yang baik terhadap data yang belum pernah dijumpai sebelumnya.



Gambar 17. Grafik Loss Model

Grafik loss menggambarkan penurunan yang signifikan dalam nilai kerugian, yang merupakan indikator seberapa baik model melakukan prediksi dibandingkan dengan label yang sebenarnya. Pada awal pelatihan, loss pelatihan berada di kisaran 120%, namun secara bertahap menurun hingga di bawah 30% pada epoch terakhir, yang menunjukkan bahwa model semakin efektif dalam mengidentifikasi kelas yang tepat. Loss validasi juga menunjukkan penurunan yang stabil, meskipun terdapat fluktuasi yang lebih besar dibandingkan dengan loss pelatihan. Pada akhir proses pelatihan, loss validasi tercatat sekitar 38%, yang menunjukkan kemampuan model dalam menangani data validasi dengan baik, meskipun variasi tersebut dapat disebabkan oleh kompleksitas data validasi yang lebih tinggi.

Secara keseluruhan, grafik ini mencerminkan performa model yang sangat baik, ditandai dengan akurasi yang tinggi dan penurunan nilai loss yang signifikan pada kedua jenis data, pelatihan dan validasi. Namun, ada indikasi adanya potensi overfitting, karena akurasi hampir mencapai 100% sementara loss untuk pelatihan dan validasi berada pada tingkat yang sangat rendah, yang menunjukkan bahwa model mungkin telah terlalu menyesuaikan diri dengan data pelatihan.

3.3 Diskusi

Penelitian ini membandingkan metode Sobel dan CNN untuk klasifikasi kematangan buah rambutan. Metode Sobel, yang berfokus pada deteksi tepi, menunjukkan keterbatasan dalam menangkap detail tekstur dan variasi warna, menghasilkan akurasi 75.32%. Metode ini efisien secara komputasi, namun tidak cocok untuk klasifikasi yang kompleks.

Sebaliknya, CNN mampu mengenali pola visual yang lebih rumit dengan akurasi 98.09%, berkat kemampuannya dalam mengekstrak fitur secara otomatis. Namun, risiko overfitting menjadi perhatian, mengingat tingginya akurasi pelatihan dan validasi. Pengujian lebih lanjut dengan dataset yang lebih beragam diperlukan untuk memastikan kemampuan generalisasi CNN. Meskipun CNN lebih akurat, Sobel tetap memiliki keunggulan dalam kecepatan dan efisiensi, sehingga lebih cocok untuk aplikasi sederhana atau real-time.

4. KESIMPULAN

kematangan buah rambutan. CNN mampu mengenali pola visual yang lebih kompleks seperti tekstur dan variasi warna pada buah rambutan, menghasilkan akurasi yang sangat tinggi, yaitu 98.09%. Di sisi lain, metode Sobel, meskipun sederhana dan efisien secara komputasi, kurang mampu menangkap detail halus yang dibutuhkan untuk klasifikasi citra dengan tekstur yang lebih kompleks, dengan akurasi hanya sebesar 75.32%. Oleh karena itu, CNN lebih sesuai untuk digunakan dalam aplikasi yang membutuhkan akurasi tinggi, sedangkan Sobel dapat digunakan pada tugas-tugas yang lebih sederhana dengan kebutuhan komputasi yang lebih rendah. Hasil penelitian ini dapat berkontribusi pada pengembangan sistem otomatis yang lebih akurat dalam menentukan tingkat kematangan buah di sektor pertanian, terutama untuk meningkatkan efisiensi dan konsistensi dalam proses klasifikasi buah.

DAFTAR PUSTAKA

- [1] A. Dalimunthe, "Deteksi Kematangan Buah Manggis Berdasarkan Fitur Warna Citra Kulit Menggunakan Metode Transformasi Ruang Warna HSV," *Skripsi*, p. 89, 2021.
- [2] B. W. Kurniadi, H. Prasetyo, G. L. Ahmad, B. Aditya Wibisono, and D. Sandya Prasvita, "Analisis Perbandingan Algoritma SVM dan CNN untuk Klasifikasi Buah," *Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya (SENAMIKA) Jakarta-Indonesia*, no. September, pp. 1–11, 2021.
- [3] I. A. Sabilla, "Arsitektur Convolutional Neural Network (Cnn) Untuk Klasifikasi Jenis Dan Kesegaran Buah Pada Neraca Buah," *Tesis*, no. 201510370311144, pp. 1–119, 2020.
- [4] Ilmi, M. H. Razka, D. S. Wiratomo, and D. S. Prasvita, "Klasifikasi Tingkat Kematangan Buah Apel Berdasarkan Fitur Warna Menggunakan Algoritma KNN dan Ekstraksi Warna HSV," *Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya (SENAMIKA)*, no. September, pp. 176–182, 2021.
- [5] I. Zeger, S. Grgic, J. Vukovic, and G. Sisul, "Grayscale Image Colorization Methods: Overview and Evaluation," *IEEE Access*, vol. 9, pp. 113326–113346, 2021, doi: 10.1109/ACCESS.2021.3104515.
- [6] L. Boyano-Orozco, T. Gallardo-Velázquez, O. G. Meza-Márquez, and G. Osorio-Revilla, "Microencapsulation of Rambutan Peel Extract by Spray Drying," *Foods*, vol. 9, no. 7, p. 899, Jul. 2020, doi: 10.3390/foods9070899.
- [7] N. P. Sutrisna *et al.*, "Deteksi Tingkat Kematangan Buah Pepaya menggunakan Model Convolutional Neural Network," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 3, pp. 569–578, Jul. 2024, doi: 10.25126/jtiik.938119.
- [8] Supiyandi Supiyandi, Trisatin Panggabean, Nuzul Ramadhan, Sri Ratna Dewi, and Salsabila Yusra, "Deteksi Tepi Sederhana Pada Citra Menggunakan Operator Sobel," *Repeater : Publikasi Teknik Informatika dan Jaringan*, vol. 2, no. 3, pp. 43–56, 2024, doi: 10.62951/repeater.v2i3.90.
- [9] Wicaksono Yuli Sulisty, Imam Riadi, and Anton Yudhana, "Comparative Analysis of Image Quality Values on Edge Detection Methods," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 4, no. 2, pp. 345–351, Apr. 2020, doi: 10.29207/resti.v4i2.1827.
- [10] Yuwan Jumaryadi, Alif Muhammad Ihsan, and Bagus Priambodo, "Klasifikasi Jenis Buah-Buahan Menggunakan Citra Digital Dengan Metode Convolutional Neural Networks," *djournals.com*, Sep. 2023.