

Identifikasi Kualitas dan Jenis Buah Cabai Menggunakan *Algoritma Deep Learning*

Tahir Supu^{1*}, Syahrial², Rizal Lamusu³, Widya Eka Pranata⁴

^{1,2,3,4}Ilmu Komputer Universitas Muhammadiyah Gorontalo

Corresponding: tahirsupul@gmail.com

Submitted: 05-07-2025; Accepted: 30-10-2025; Published: 31-10-2025

ABSTRACT

The objectives of this study are (1) to automatically identify the quality and type of chili peppers using deep learning algorithms, and (2) to improve the accuracy of the chili pepper quality and type identification system by optimizing the application of deep learning algorithms. Deep learning is a layered artificial neural network architecture for efficiently processing and analyzing large-scale data to solve various complex problems. Deep learning is a branch of machine learning whose algorithms are designed to adopt the architecture of the human biological neural network, known as artificial neural networks. One of the most commonly used Deep Learning architectures in image analysis is the Convolutional Neural Network (CNN). In this study, the data sample consisted of 1,500 image data divided into four classes, namely: fresh curly chili peppers, non-fresh curly chili peppers, fresh cayenne peppers, and non-fresh cayenne peppers. After that, it will be divided into two data sets, namely train and validation. The graph above shows the relationship between the training-testing data ratio and model accuracy at an image size of 400x400 pixels. It can be seen that model accuracy tends to increase as the proportion of training data increases, with peak accuracy occurring at 80:20, reaching around 98%. The CabaiNet CNN model developed in this study is capable of classifying the type and quality of chili peppers into four classes (fresh curly chili peppers, non-fresh curly chili peppers, fresh cayenne peppers, and non-fresh cayenne peppers) with a high level of accuracy, reaching 99% in the best configuration. This answers the first problem statement regarding how to identify the quality and type of chili peppers using a deep learning algorithm, namely by utilizing a special CNN architecture designed to extract visual features from images of chili peppers.

Keywords: Deep Learning Algorithm; Fruit Quality; Types of Chili Fruit; CNN

ABSTRAK

Tujuan penelitian ini adalah (1) Mengidentifikasi kualitas dan jenis buah cabai secara otomatis menggunakan Algoritma deep learning. (2) Meningkatkan Akurasi sistem identifikasi kualitas dan jenis buah cabai dengan mengoptimalkan penerapan Algoritma deep learning. Deep Learning adalah arsitektur jaringan saraf tiruan berlapis untuk memproses dan menganalisis data dalam skala besar secara efisien guna menyelesaikan berbagai permasalahan kompleks. Deep Learning merupakan cabang dari Machine Learning yang algoritmanya dirancang mengadopsi arsitektur jaringan saraf biologis manusia, yang dikenal sebagai Artificial Neural Networks. Salah satu, arsitektur Deep Learning yang paling umum digunakan dalam analisis gambar adalah Convolutional Neural Network (CNN). Pada penelitian ini, sampel data yang didapatkan berjumlah 1500 data gambar yang dibagi 4 kelas, yaitu: Cabai keriting segar, Cabai keriting tidak segar, Cabai rawit segar dan Cabai rawit tidak segar. Setelah itu akan di bagi menjadi dua data yaitu train dan validasi. Gambar grafik di atas tersebut menunjukkan hubungan antara rasio data latih-uji dengan Akurasi model pada ukuran citra 400x400 piksel. Terlihat bahwa Akurasi model cenderung meningkat seiring bertambahnya proporsi data latih, dengan puncak Akurasi terjadi pada 80:20, mencapai sekitar 98%. Model CNN CabaiNet yang dikembangkan dalam penelitian ini mampu mengklasifikasikan jenis dan kualitas buah cabai ke dalam empat kelas (cabai keriting segar, cabai keriting tidak segar, cabai rawit segar, dan cabai rawit tidak segar) dengan tingkat Akurasi tinggi, mencapai 99% pada konfigurasi terbaik. Hal ini menjawab rumusan masalah pertama terkait bagaimana mengidentifikasi kualitas dan jenis buah cabai dengan Algoritma deep learning, yaitu dengan memanfaatkan arsitektur CNN khusus yang dirancang untuk mengekstraksi fitur visual dari citra buah cabai.

Keywords: Algoritma Deep Learning; Kualitas Buah; Jenis Buah Cabai; CNN

1. PENDAHULUAN

Cabai merupakan salah satu komoditas pertanian utama di Indonesia yang memiliki nilai ekonomi strategis. Dengan permintaan yang tinggi, tiga jenis cabai yang paling banyak dipasarkan adalah cabai besar cabai rawit, cabai hijau dan cabai keriting. Selain menjadi bahan utama dalam berbagai masakan, cabai juga memegang peran penting dalam sektor agribisnis[1]. Wilayah Asia merupakan salah satu wilayah utama penghasil cabai dengan presentase sebesar 21.2% dimana jumlah produksi cabai di India sebesar 2 juta ton dan Thailand sebesar 349.614 ton. Di Indonesia sendiri cabai merupakan komoditas sayuran yang mempunyai nilai


ekonomi yang tinggi[2]. Cabai memiliki prospek yang menjanjikan untuk dipasarkan pada pasar lokal. Selain nilai ekonomi yang tinggi, produksi cabai di Indonesia sangat besar karena banyak dibutuhkan untuk memenuhi kebutuhan konsumsi harian. Hal tersebut juga menunjukkan peran penting cabai dalam berbagai jenis makanan lokal, Salah satu masakan tradisional Indonesia yang menggunakan bahan dasar cabai[3]. Selain itu, cabai juga dimanfaatkan sebagai bahan baku dalam industri farmasi dan makanan karena mengandung capsaicin, vitamin A dan C, serta oleoresin[4]. Klasifikasi cabai berdasarkan warna, bentuk dan tekstur adalah salah satu pendekatan yang paling efektif untuk membedakan jenis cabai[5]. Namun, identifikasi jenis cabai seringkali dilakukan secara manual, proses identifikasi buah cabai dengan cara manual membutuhkan waktu yang cukup lama[6]. Kondisi ini menjadi tantangan tersendiri bagi petani dan pelaku usaha untuk memastikan kualitas dan jenis cabai yang sesuai dengan kebutuhan pasar[1]. Cabai yang berkualitas tinggi biasanya memiliki permintaan yang lebih tinggi dan dapat memperkuat posisi pasar dari produsen atau eksportir. Selain itu juga dalam bidang pangan konsumen mengandalkan kualitas cabai sebagai salah satu faktor penting dalam menentukan keamanan pangan. Kualitas cabai yang buruk dapat mengandung bahan kimia berbahaya atau bakteri yang dapat membahayakan kesehatan manusia[7]. Sehingga Kemajuan dalam bidang kecerdasan buatan (*Artificial Intelligence/AI*) membuka peluang signifikan untuk mengatasi berbagai kendala dalam klasifikasi *citra*. Salah satu pendekatan AI yang telah terbukti *efektif* dalam pengenalan pola visual berdasarkan fitur *citra* adalah *Convolutional Neural Network* (CNN). CNN memiliki kemampuan untuk mengekstraksi dan mengenali pola visual secara otomatis dengan tingkat *Akurasi* yang tinggi, sehingga sangat cocok diterapkan dalam tugas klasifikasi *citra* secara otomatis. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi otomatis jenis cabai dengan memanfaatkan integrasi fitur warna, bentuk, dan tekstur melalui penerapan CNN[1]. Convolutional Neural Network (CNN) adalah model Deep Learning yang digunakan untuk analisis gambar, dengan mengandalkan pembagian bobot untuk mengurangi parameter pelatihan dan mencegah overfitting. CNN menonjol dalam identifikasi objek dan deteksi pola visual yang kompleks, mengekstrak elemen-elemen penting dari gambar sambil meningkatkan efisiensi komputasi. Kemampuan CNN dalam membagi bobot membuatnya sangat sesuai untuk tugas- tugas pemrosesan gambar real-time, seperti dalam aplikasi mobil otonom dan pengenalan wajah. Meskipun demikian, implementasi yang efektif memerlukan pertimbangan yang hati-hati terhadap desain arsitektur, pemilihan parameter, dan manajemen data pelatihan. Dengan penelitian lebih lanjut, CNN telah menjadi alat yang tak tergantikan dalam literatur ilmiah terkait pemrosesan gambar dan pemahaman visual. Kelebihan CNN terlihat dalam kemampuannya untuk menentukan kebenaran klasifikasi objek, dengan memanfaatkan konsep pembagian bobot untuk mengurangi jumlah parameter dan mencegah overfitting. Selanjutnya, CNN digunakan dalam klasifikasi tanaman pada Citra Resolusi Tinggi dengan mengimplementasikan algoritma CNN yang dapat membedakan 5 jenis tanaman, seperti padi, bawang merah, kelapa, pisang, dan cabai [8].

2. METODE PENELITIAN

Penelitian ini dilaksanakan di lahan milik petani Pak Aswan Yusuf yang berlokasi di Desa Wanggarasi, Kecamatan Wanggarasi, Kabupaten Pohuwato, dan di Pasar Sentral Limboto di seorang pedagang yang bernama Pak Memet Posuma. menggunakan metode wawancara dan observasi untuk pengumpulan data. Data yang dikumpulkan terbagi menjadi data primer dan data sekunder.

- a) Data primer dikumpulkan melalui wawancara mendalam dan observasi langsung kepada petani cabai guna memperoleh informasi terkait varietas serta mutu cabai yang dihasilkan. Selain itu, dilakukan pengambilan *citra* cabai dengan kategori kualitas segar dan tidak segar yang kemudian digunakan sebagai *dataset* untuk pelatihan model pembelajaran mendalam (*deep learning*).
- b) Data Sekunder, berasal dari jurnal, buku, dan referensi lain yang relevan dengan penelitian ini.

2.1. Tahapan Penelitian



Gambar 1 diagram flowchart

1. Pengumpulan Data Cabai. Penelitian ini memanfaatkan kumpulan data *citra* digital cabai yang diklasifikasikan ke dalam dua kategori jenis, yakni *Capsicum frutescens* (cabai rawit) dan *Capsicum annuum* (cabai keriting), serta dua kategori kualitas, yaitu segar dan tidak segar. Berdasarkan kombinasi dari kedua dimensi tersebut, *dataset* dibagi menjadi empat kelas sebagai berikut:
 - a) Cabai keriting segar
 - b) Cabai rawit segar
 - c) Cabai keriting tidak segar
 - d) Cabai rawit tidak segarTotal jumlah *citra* yang dikumpulkan sebanyak 1.500 gambar, yang kemudian dibagi secara merata ke dalam masing-masing kelas, sehingga setiap kelas terdiri dari 375 gambar. Pembagian yang seimbang ini bertujuan untuk menjaga proporsionalitas data dan menghindari ketimpangan kelas (*class imbalance*), yang dapat memengaruhi performa model selama Proses pelatihan. Data cabai rawit dan keriting diperoleh melalui pengambilan gambar menggunakan kamera ponsel beresolusi 108 megapiksel, dengan pengambilan dari berbagai sudut pandang serta latar belakang berwarna hijau untuk mempertahankan *konsistensi visual*.
2. Pemrosesan Data yang Sudah Dikumpulkan. Setelah data *citra* dikumpulkan, dilakukan tahap pra-pemrosesan untuk memastikan bahwa seluruh data memenuhi standar kualitas yang diperlukan dalam proses pelatihan model. Prosedur ini meliputi pemeriksaan format gambar, *validasi* visual terhadap kualitas *citra*, penyesuaian dimensi gambar (*resizing*), serta normalisasi pencahayaan dan kontras warna guna mempertahankan homogenitas antar *citra*. Gambar yang tidak layak, seperti gambar yang buram atau terlalu gelap, akan disingkirkan atau diperbaiki untuk menghindari bias dan menurunkan *Akurasi* model. Tujuan dari tahap ini adalah untuk memastikan bahwa *dataset* yang digunakan berada dalam kondisi optimal untuk diolah oleh model pembelajaran mesin.
3. Perencanaan dan pelatihan sistem. Model klasifikasi dikembangkan dengan menerapkan *Algoritma Convolutional Neural Network* (CNN), yang dikenal *efektif* dalam mengolah data visual dan mengenali pola spasial seperti warna, bentuk, serta tekstur objek. *CNN* dirancang untuk mampu membedakan karakteristik visual antara berbagai jenis dan kualitas cabai. Setelah struktur *arsitektur* model disusun, proses pelatihan dilakukan dengan menggunakan *dataset* yang telah diproses sebelumnya. Apabila model

belum mencapai performa yang diharapkan, maka dilakukan penyesuaian terhadap *arsitektur* atau *parameter* pelatihan dan model akan dilatih ulang hingga mencapai tingkat *Akurasi* yang optimal.

4. Menguji Sistem yang Sudah Dibuat. Langkah akhir dari penelitian ini adalah melakukan evaluasi terhadap sistem klasifikasi yang telah dilatih. Pengujian dilakukan dengan menggunakan data uji yang sebelumnya tidak dilibatkan dalam proses pelatihan untuk mengukur generalisasi dan keakuratan model dalam mengenali *citra* cabai. Evaluasi dilakukan menggunakan metrik performa seperti *Akurasi*, presisi, recall, dan confusion matrix. Apabila hasil pengujian menunjukkan bahwa sistem mampu mengklasifikasikan jenis dan kualitas cabai dengan akurat, maka sistem dinyatakan layak untuk diterapkan dalam skenario nyata, misalnya pada proses sortasi otomatis di sektor pertanian atau industri pangan.

2.2. Pembagian Dataset

Gambar yang digunakan sebagai *dataset Training* dan *Testing* memiliki ukuran 400 x 400 piksel. Data ini dibagi menjadi dua bagian, yaitu data *training* dan data *testing*. Pembagian ini bertujuan untuk memastikan bahwa model dapat belajar dengan baik dari data latih dan diuji dengan data uji yang representatif. Tabel berikut menunjukkan pembagian *dataset* berdasarkan proporsi data latih dan uji:

Table 1. Pembagian *dataset* cabai

Ukuran <i>Citra</i>	Pembagian data	
	Data Latih	Data Uji
400 x 400	90%	10%
	80%	20%
	70%	30%
	60%	40%
	50%	50%


2.3. Algoritma Deep Learning

Deep learning merupakan salah satu bidang dari *Machine Learning* yang memanfaatkan jaringan syaraf tiruan untuk implementasi permasalahan dengan dataset yang besar. Teknik *Deep Learning* memberikan arsitektur yang sangat kuat untuk *Supervised Learning*. Dengan menambahkan lebih banyak lapisan maka model pembelajaran tersebut bisa mewakili data citra berlabel dengan lebih baik [9]. Deep Learning, sebagai bagian dari kecerdasan buatan, memiliki aplikasi praktis dalam pengenalan wajah, citra, suara, klasifikasi teks, dan tugas lainnya. Metode ini mengajarkan komputer untuk memproses data seperti otak manusia, menghasilkan wawasan dan prediksi akurat [10]. Selain itu, *Deep Learning* merupakan cabang khusus dari *Machine Learning* yang algoritmanya dirancang dengan mengadopsi *arsitektur* jaringan saraf biologis manusia, yang dikenal sebagai *Artificial Neural Networks (ANN)*. Salah satu, arsitektur *deep learning* yang paling umum digunakan dalam analisis gambar adalah Convolutional Neural Network (CNN) [11], karena Convolutional Neural Network (CNN) adalah pembelajaran yang mendalam, metode yang dirancang khusus untuk klasifikasi gambar dan pengakuan berdasarkan jaringan saraf multi-layer dan CNN memiliki daya tahan tinggi terhadap penskalaan, kemiringan, dan deformasi visual lainnya.[12]

2.4. Model Identifikasi CNN

Pada tahapan ini, sistem akan menjalani proses pelatihan (*training*) terhadap *dataset citra* buah cabai dengan memanfaatkan pendekatan *Convolutional Neural Network (CNN)*, Hal tersebut dikarenakan CNN berusaha meniru sistem pengenalan citra pada visual cortex manusia sehingga memiliki kemampuan mengolah informasi citra yang dirancang untuk mengekstraksi dan mengenali pola visual dari setiap gambar[13]. CNN terdiri atas serangkaian layer tersebut terdiri atas input layer, convolution layer, non-linear layer, pooling layer, dan fully

connected layer. Layer-layer tersebut adalah proses jalannya algoritma untuk mengenali sebuah objek dalam sebuah citra[14]. Tujuan dari proses pelatihan ini adalah untuk mengevaluasi dan membandingkan performa model berdasarkan tingkat *Akurasi* klasifikasi yang dihasilkan, sehingga dapat diperoleh konfigurasi *arsitektur* jaringan yang paling optimal. Melalui pendekatan ini, sistem diharapkan mampu melakukan identifikasi terhadap jenis dan kualitas cabai secara otomatis dengan tingkat presisi tinggi menggunakan *Algoritma* deep learning. Berikut ini disajikan rancangan *arsitektur CNN* yang digunakan dalam penelitian sebagai landasan proses pelatihan dan evaluasi model.



Gambar 2. Rancangan model CNN

Berikut penjelasan *arsitektur* pada gambar 2 di atas:

1. *Input Gambar*. *Dataset* yang digunakan terdiri dari gambar beresolusi 100x100, 200x200, 300x300, 400x400 dan 500x500 piksel dan telah melalui proses augmentasi untuk meningkatkan keragaman data pelatihan. Setiap *citra* terdiri atas tiga kanal warna (RGB), sehingga dimensi masukan menjadi $400 \times 400 \times 3$ piksel.
2. *Lapisan Convolutional Pertama*. Lapisan konvolusi pertama menerapkan filter berukuran 3×3 untuk mengekstraksi fitur lokal dari *citra*. Fungsi aktivasi ReLU (Rectified Linear Unit) digunakan untuk memperkenalkan non-linearitas ke dalam model, dengan mengubah nilai negatif menjadi nol dan mempertahankan nilai positif. Hasil dari proses ini adalah 32 *feature maps* yang masing-masing menangkap pola visual spesifik dari gambar input.
3. *Lapisan MaxPooling Pertama*. Operasi *max Pooling* dengan ukuran 2×2 diaplikasikan untuk mereduksi dimensi spasial *feature maps* tanpa menghilangkan informasi utama. Reduksi ini meningkatkan efisiensi

komputasi sekaligus membantu model menjadi lebih toleran terhadap translasi lokal dari fitur.

4. Lapisan *Convolutional* Kedua. Pada lapisan ini, kembali diterapkan kernel 3×3 untuk mendeteksi fitur yang lebih kompleks dari hasil sebelumnya. Jumlah filter ditingkatkan menjadi 64, memungkinkan model belajar mengenali pola seperti kontur, tekstur, dan struktur bagian dari objek yang lebih rinci.
5. Lapisan *MaxPooling* Kedua, Seperti tahap sebelumnya, *max Pooling* 2×2 kembali diterapkan untuk menyederhanakan representasi fitur. proses ini mempertahankan karakteristik penting sekaligus mempercepat proses pelatihan dan mengurangi risiko *overfitting*.
6. Lapisan *Convolutional* Ketiga. Pada tahap ini, jumlah filter ditingkatkan menjadi 128, dengan ukuran kernel tetap 3×3 . Lapisan ini difungsikan untuk mengidentifikasi representasi fitur yang lebih abstrak, seperti keseluruhan bentuk objek atau pola tekstur global.
7. Lapisan *MaxPooling* Ketiga. Penggunaan *Pooling* 2×2 pada tahap ini bertujuan mengompresi representasi fitur lebih lanjut. Selain mengurangi dimensi, lapisan ini turut berperan dalam generalisasi model dengan menghindari ketergantungan terhadap fitur yang tidak relevan.
8. Lapisan *Flatten*, *Feature maps* berdimensi dua dari lapisan konvolusi dikonversi menjadi vektor satu dimensi. Transformasi ini diperlukan agar data dapat digunakan sebagai *input* untuk lapisan *fully connected* pada tahap klasifikasi
9. Lapisan *Fully Connecte*. Lapisan ini mengintegrasikan semua informasi dari lapisan sebelumnya dan berfungsi sebagai pengambil keputusan akhir dalam proses klasifikasi. Jumlah neuron pada lapisan ini disesuaikan dengan kompleksitas klasifikasi yang dilakukan dan jumlah kelas yang ditentukan.
10. Lapisan *Output* dengan *SoftMax*. Lapisan akhir menerapkan fungsi aktivasi *SoftMax* yang mengonversi *output* menjadi distribusi probabilitas terhadap setiap kelas. *Output* ini memungkinkan sistem untuk mengklasifikasikan *citra* ke dalam kategori jenis dan kualitas cabai dengan *Akurasi* interpretatif yang tinggi.

2.5. Confusion Matrix

Dalam proses evaluasi model, pengukuran *Akurasi* dilakukan untuk mengetahui seberapa baik model dalam mengidentifikasi kualitas cabai berdasarkan *citra*. Evaluasi ini menggunakan metode *confusion matrix*, yaitu sebuah tabel yang membandingkan hasil prediksi model dengan label sebenarnya.

Model ini dikembangkan untuk mengenali dua jenis cabai (Rawit dan Keriting) serta dua kategori kualitas (Segar dan Tidak Segar), menghasilkan total 4 kelas:

- a) Cabai Keriting Segar
- b) Cabai Rawit Segar
- c) Cabai Keriting Tidak Segar
- d) Cabai Rawit Tidak Segar

Tabel 2. *Confusion matrix*

Aktual/Prediksi	Keriting Segar	Rawit Segar	Keriting Tidak Segar	Rawit Tidak Segar
Keriting Segar	150	5	3	2
Rawit Segar	6	160	2	2
Keriting Tidak Segar	5	3	200	7
Rawit Tidak Segar	4	6	5	190

Berdasarkan tabel 4 maka dalam hal ini, untuk menghitung nilai *Akurasi* pada confusion matrix dapat digunakannya rumus *Akurasi* sebagai berikut:

$$Akurasi = \frac{\text{Jumlah prediksi benar}}{\text{Total Data Uji}}$$

Sehingga untuk menghitung nilai *Akurasi* dari model klasifikasi berdasarkan tabel 4, yaitu

Diketahui :

Total prediksi benar = 150 + 160 + 200 + 190 = 700


Total data uji = 750

$$Akurasi = \frac{150 + 160 + 200 + 190}{750} * 100\% = \frac{700}{750} * 100\% = 93.33\%$$

3. HASIL DAN PEMBAHASAN

3.1 Hasil

Hasil dari proses pengujian ini meliputi ukuran *citra* 400x400 karena memberikan hasil yang paling stabil dan akurat dibandingkan ukuran 100x100, 200x200, 300x300, dan 500x500. Ukuran ini menghasilkan *Akurasi* yang tinggi dan *konsisten*, terutama pada *rasio* pembagian data latih dan uji 80:20, yang lazim digunakan dalam pelatihan model. Oleh karena itu, *citra* berukuran 400x400 dianggap sebagai pilihan paling tepat untuk mencapai kinerja optimal dalam proses klasifikasi cabai.




Gambar 3. Proses ukuran gambar 400x400

Gambar grafik akurasi di atas tersebut menunjukkan hubungan antara rasio data latih-uji dengan *Akurasi* model pada ukuran *citra* 400x400 piksel. Terlihat bahwa *Akurasi* model cenderung meningkat seiring bertambahnya proporsi data latih, dengan puncak *Akurasi* terjadi pada 80:20, dan 60:40 mencapai 98%. secara umum *Akurasi* lain tetap berada pada tingkat yang tinggi di atas 90%, menandakan bahwa model cukup stabil terhadap perubahan proporsi data latih dan uji pada resolusi *citra* ini. sedangkan grafik *loss* tersebut memperlihatkan nilai *Loss* pada berbagai rasio data latih dan uji dengan ukuran *citra* 400x400 piksel. Terlihat bahwa *Loss* tertinggi terjadi pada rasio 50:50, sementara nilai terendah muncul saat rasio 80:20. Meskipun terdapat sedikit peningkatan pada rasio 70:30 dan 90:10, secara umum *tren* menunjukkan bahwa semakin besar proporsi data latih, semakin rendah nilai *Loss* yang dihasilkan.

3.2. Pembahasan

Pada proses pengujian parameter yang digunakan untuk mengukur akurasi meliputi ukuran gambar, yaitu (400 x 400) serta menggunakan nilai epoch 100. Hasil dari proses pengujian ini adalah sebagai berikut: Berdasarkan gambar 4 tersebut, menunjukkan akurasi dan *loss* model selama proses pelatihan dan pengujian untuk epoch 100. Berikut adalah penjelasan untuk masing – masing grafik:



Gambar 4. Pengujian model

a) *Akurasi*

Akurasi pada data pelatihan mengalami lonjakan cepat dan mendekati angka sempurna sejak awal pelatihan, tepatnya setelah *epoch* ke-10. Hal ini mencerminkan bahwa model berhasil memahami pola yang terdapat dalam data pelatihan secara *efektif*. *Akurasi* pada data *validasi* pun terjaga dengan baik, berkisar pada angka 98%, meskipun terdapat sedikit variasi di beberapa *epoch* terakhir. Stabilitas ini menunjukkan bahwa model mampu menjaga keseimbangan antara pelatihan dan pengujian, tanpa indikasi kuat terjadinya *overfitting*.

b) *Loss*

Grafik *Loss* memperlihatkan penurunan yang signifikan pada fase awal pelatihan, kemudian perlahan-lahan mendekati kestabilan. Nilai *Loss* untuk data pelatihan berada di kisaran 0,42, sementara *Loss* pada data *validasi* sedikit lebih tinggi di sekitar 0,44. Pola penurunan yang selaras antara keduanya menunjukkan bahwa proses pelatihan berlangsung efisien dan model memiliki daya generalisasi yang baik terhadap data baru.

Tabel 3. Confusion matrix

Aktual/Prediksi	Keriting	Rawit Segar	Keriting	Rawit Tidak
	Segar		Tidak Segar	Segar
Keriting Segar	76	0	0	0
Rawit Segar	0	68	0	0
Keriting Tidak Segar	0	0	86	0
Rawit Tidak Segar	0	1	0	69

Tabel 3 di atas menggambarkan hasil prediksi model terhadap empat kelas cabai, yaitu Keriting Segar, Rawit Segar, Keriting Tidak Segar, dan Rawit Tidak Segar. Sebagian besar data diklasifikasikan dengan tepat oleh model, ditandai oleh nilai diagonal utama yang tinggi. Dari 300 total data, hanya satu kesalahan terjadi, yakni satu sampel "Rawit Tidak Segar" yang keliru diprediksi sebagai "Rawit Segar". Sisanya, semua data terklasifikasi dengan benar sesuai kelas aslinya. Hal ini mencerminkan bahwa model memiliki kinerja yang sangat baik dalam membedakan jenis dan kualitas cabai.

4. KESIMPULAN.

Model CNN bernama CabaiNet yang dikembangkan berhasil mengklasifikasikan jenis dan kualitas buah cabai ke dalam empat kelas dengan akurasi hingga 98% pada konfigurasi terbaik. Ini menjawab rumusan masalah pertama terkait identifikasi cabai menggunakan arsitektur CNN khusus. Proses klasifikasi dilakukan secara otomatis dengan pelatihan model CNN menggunakan citra sebagai input. Model mempelajari ciri visual seperti bentuk, tekstur, dan warna untuk mengenali tiap kelas. Ukuran citra berpengaruh terhadap kinerja model. Ukuran 400x400 piksel memberikan hasil paling seimbang, dengan akurasi tinggi, nilai loss rendah, dan waktu pelatihan yang efisien. Rasio data latih dan uji juga memengaruhi performa. Rasio 80:20 menghasilkan hasil terbaik, sedangkan rasio ekstrem seperti 90:10 atau 70:30 cenderung menyebabkan overfitting. Pemilihan rasio data yang tepat penting untuk meningkatkan akurasi, sesuai dengan rumusan masalah kedua.

DAFTAR PUSTAKA

- [1] R. A. Rohman, M. Dasuki, L. A. Muharom, and M. Rahman, "Penerapan Algoritma Convolution Neural Network untuk Klasifikasi Jenis Cabai Berdasarkan Warna dan Bentuk buah," vol. 6, no. 2, pp. 345–351, 2024.
- [2] M. V. Zamzami, Z. E. Fitri, A. Madjid, and A. M. N. Imron, "Application of Computer Vision for Digital Encyclopedia of Chili Varieties (*Capsicum* spp.)," *J. Educ. Eng. Environ.*, vol. 3, no. 1, pp. 34–39, 2024, doi: 10.36526/jeee.v3i1.3831.
- [3] A. B. Kaswar, F. Adiba, and D. D. Andayani, "Sistem Klasifikasi Tingkat Kematangan Buah Cabai Katokkon Berdasarkan Fitur Warna LAB Menggunakan Artificial Neural Network Backpropagation," *J. Embed. Syst. Secur. Intell. Syst.*, vol. 4, no. November, pp. 149–157, 2023, doi: 10.59562/jessi.v4i2.996.
- [4] Ristiana Betris Tosi, Helena dorothea Mbura, and Yampi R Kaesmetan, "Implementasi CNN Dalam Mengidentifikasi Kematangan Cabai Berdasarkan Warna," *Indones. J. Educ. Comput. Sci.*, vol. 2, no. 1, pp. 34–42, 2024, doi: 10.60076/indotech.v2i1.385.
- [5] "View of Penerapan K-Means Clustering untuk Klasifikasi Citra Cabai Keriting_ Studi Ekstraksi Warna dan Tekstur GLCM.pdf."

- [6] I. Perlindungan and Risnawati, "Pengenalan Tanaman Cabai Dengan Teknik Klasifikasi Menggunakan Metode CNN," *Semin. Nas. Mhs. ilmu Komput. dan Apl.*, pp. 15–22, 2020.
- [7] U. Mahdiyah, "Klasifikasi Kualitas Citra Cabai Dengan Menggunakan Algoritma Gradien Boosting," *JAMI J. Ahli Muda Indones.*, vol. 4, no. 1, pp. 61–69, 2023, doi: 10.46510/jami.v4i1.137.
- [8] R. Ardianto and S. K. Wibisono, "Analisis Deep Learning Metode Convolutional Neural Network Dalam Klasifikasi Varietas Gandum," *J. Kolaboratif Sains(JKS)*, vol. 6, no. 12, pp. 2081–2092, 2023, doi: 10.56338/jks.v6i12.4938.
- [9] M. I. Abas, S. Syarif, I. Nurtanio, and Z. Tahir, "Detection of corn plant diseases using convolutional neural network: A review," *AIP Conf. Proc.*, vol. 2952, no. 1, p. 40001, Jul. 2024, doi: 10.1063/5.0211960.
- [10] M. I. Abas, Syafruddin Syarif, Ingrid Nurtanio, and Zulkifli Tahir, "Comparison of Convolutional Neural Network Methods for the Classification of Maize Plant Diseases," *Regist. J. Ilm. Teknol. Sist. Inf.*, vol. 10, no. 1, pp. 46–59, Mar. 2024, doi: 10.26594/register.v10i1.3656.
- [11] A. Raup, W. Ridwan, Y. Khoeriyah, S. Supiana, and Q. Y. Zaqiah, "Deep Learning dan Penerapannya dalam Pembelajaran," *JiIP - J. Ilm. Ilmu Pendidik.*, vol. 5, no. 9, pp. 3258–3267, 2022, doi: 10.54371/jiip.v5i9.805.
- [12] T. Setiawan and D. Avianto, "Implementasi Convolutional Neural Network Untuk Pengenalan Warna Kendaraan," *Naskah Publ.*, vol. FTIE, p. Universitas Teknologi Yogyakarta, 2020.
- [13] P. A. Nugroho, I. Fenriana, and R. Arijanto, "Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) Pada Ekspresi Manusia," *Algor*, vol. 2, no. 1, pp. 12–21, 2020.
- [14] Y. A. Suwitono and F. J. Kaunang, "Implementasi Algoritma Convolutional Neural Network (CNN) Untuk Klasifikasi Daun Dengan Metode Data Mining SEMMA Menggunakan Keras," *J. Komtika (Komputasi dan Inform.)*, vol. 6, no. 2, pp. 109–121, 2022, doi: 10.31603/komtika.v6i2.8054.