



Implementasi Metode CNN Dan K-Nearest Neighbor Untuk Klasifikasi Tingkat Kematangan Tanaman Cabai Rawit

Muhammad Rifki Bahrul Ulum¹; Basuki Rahmat²; Made Hanindia Prami Swari³
Universitas Pembangunan Nasional “Veteran” Jawa Timur, Indonesia

Address: Jl. Rungkut Madya No.1, Gn. Anyar, Kec. Gn. Anyar, Surabaya, Jawa Timur 60294

Corresponding author: 20081010149@student.upnjatim.ac.id¹

Abstract: *The process of identifying the ripeness level of cayenne peppers is an important step in cultivation and post-harvest handling. Dependence on the quality factors of farmers, such as visual diversity and differences in ripeness perception, results in subjective harvest outcomes. This manual process is also prone to inconsistent results, as humans have time limitations, fatigue, and sometimes lack concentration when sorting for long periods. To minimize these issues, technological intervention is needed to mechanically classify the ripeness level of cayenne peppers. This research aims to develop a classification model for the maturity level of cayenne pepper plants. This research proposes the use of the CNN method for feature extraction and KNN for data classification based on the features extracted by CNN. From the test scenarios carried out, the classification carried out by KNN based on CNN feature extraction got the best accuracy of 99.33%, while the CNN classification model got the best accuracy of 87.33%.*

Keywords: *Cayenne Pepper, Classification, CNN, KNN, CNN-KNN.*

Abstrak: Proses identifikasi tingkat kematangan cabai adalah langkah penting dalam budidaya dan penanganan pasca panen. Ketergantungan pada faktor kualitas petani, seperti keragaman visual dan perbedaan persepsi tingkat matang, menyebabkan hasil panen bersifat subjektif. Proses manual ini juga rentan terhadap ketidak konsistenan hasil, karena manusia memiliki keterbatasan waktu, kelelahan, dan kadang-kadang kurang konsentrasi saat melakukan kegiatan penyortiran dalam jangka waktu yang lama. Sehingga untuk meminimalisir masalah tersebut, diperlukan sentuhan teknologi yang dapat mengklasifikasikan tingkat kematangan tanaman cabai rawit secara mekanis. Penelitian ini bertujuan untuk mengembangkan model klasifikasi tingkat kematangan tanaman cabai rawit. Penelitian ini mengusulkan penggunaan metode CNN untuk ekstraksi fitur dan KNN untuk klasifikasi data berdasarkan fitur yang diekstrak oleh CNN. Dari skenario pengujian yang dilakukan, klasifikasi yang dilakukan oleh KNN berdasarkan ekstraksi fitur CNN mendapatkan akurasi terbaik sebesar 99,33%, sedangkan model klasifikasi CNN mendapatkan akurasi terbaik sebesar 87,33%.

Kata kunci: Cabai Rawit, Klasifikasi, CNN, KNN, CNN-KNN.

1. LATAR BELAKANG

Cabai rawit merupakan salah satu komoditas pertanian yang sangat penting dan populer di Indonesia. Tingginya konsumsi cabai rawit menjadikannya komoditas dengan permintaan yang selalu tinggi, sehingga memiliki nilai ekonomi yang signifikan bagi para petani. Namun, harga cabai rawit sering mengalami fluktuasi yang disebabkan oleh beberapa faktor. Faktor-faktor seperti perubahan musim dapat memengaruhi produksi dan ketersediaan cabai rawit di pasar (Fitri et al., 2020). Dalam situasi di mana harga cabai rawit tinggi, petani mungkin lebih cenderung untuk melakukan panen lebih awal untuk mendapatkan keuntungan maksimal tanpa memikirkan tingkat kematangan untuk memenuhi kebutuhan pasar. Proses identifikasi tingkat kematangan cabai adalah langkah penting dalam budidaya dan penanganan pasca panen (Kaswar et al., 2023). Proses panen cabai rawit yang dilakukan

secara manual sering menghasilkan produk dengan tingkat kematangan yang kurang terstandarisasi, karena bergantung pada penilaian visual petani yang bersifat subjektif. Ketergantungan pada kemampuan individu membuat hasil panen tidak konsisten, terutama karena faktor kelelahan dan keterbatasan waktu manusia. Sehingga untuk meminimalisir masalah tersebut, diperlukan sentuhan teknologi yang dapat mengklasifikasikan tingkat kematangan tanaman cabai rawit secara mekanis.

Dalam penelitian sebelumnya, telah dilakukan klasifikasi tingkat kematangan buah dan sayuran. Penelitian oleh (Cahyaputra & Rahmadewi, 2024) menggunakan metode K-Nearest Neighbor (KNN) untuk klasifikasi kematangan buah paprika dan mencapai akurasi 90% dengan $k=5$. Penelitian lain oleh (Saragih & Emanuel, 2021) mengklasifikasikan kematangan buah pisang menggunakan Convolutional Neural Network (CNN) dengan arsitektur MobileNet V2, mencapai akurasi 96,81%. Penelitian lainnya oleh (Sri et al., 2020) juga mengklasifikasikan kematangan buah pisang menggunakan CNN dan memperoleh akurasi 80%. Beberapa penelitian menggunakan kombinasi CNN untuk ekstraksi fitur dan KNN untuk klasifikasi. Penelitian oleh (Nugroho et al., 2023) menemukan bahwa kombinasi CNN-KNN memberikan akurasi 92,5% dalam deteksi bakteri *Mycobacterium tuberculosis*, sedangkan CNN mencapai akurasi sebesar 90%. Dalam penelitian lain, (Sejuti & Islam, 2023) menggunakan model hybrid CNN-KNN untuk identifikasi COVID-19 dengan bantuan cross validation sebanyak 5 kali memperoleh akurasi validasi rata-rata sebesar 98,26% dibandingkan dengan CNN yang memperoleh akurasi sebesar 93,12%.

Berdasarkan pemaparan di atas, penelitian ini mengusulkan sebuah model yang dapat mengekstrak fitur dari input citra tanaman cabai rawit menggunakan CNN. Hasil ekstraksi fitur kemudian digunakan oleh metode KNN untuk proses klasifikasi. Penerapan metode CNN sebagai ekstraksi fitur dan KNN sebagai pengklasifikasi pada klasifikasi tingkat kematangan tanaman cabai rawit belum banyak diteliti sebelumnya. Hal ini memberikan tantangan baru karena karakteristik data yang berbeda dari citra medis.

2. KAJIAN TEORITIS

Machine Learning

Teknologi machine learning atau pembelajaran mesin adalah bidang studi dalam mengembangkan sebuah mesin untuk dapat belajar suatu hal dengan sendirinya tanpa harus diatur secara spesifik (Pratama, 2020).

Deep Learning

Deep learning adalah subbidang dari machine learning atau pembelajaran mesin yang terinspirasi oleh struktur otak (Sejuti & Islam, 2023).

Convolutional Neural Network

Convolutional Neural Networks atau Jaringan Saraf Konvolusi (CNN) merupakan varian yang paling umum digunakan dari Jaringan Saraf Tiruan (ANN) ketika melakukan analisis pada citra visual. CNN adalah jenis jaringan saraf tiruan feedforward yang merupakan teknik klasifikasi populer yang menghasilkan hasil yang menjanjikan dan akurat (Aziz et al., 2021). Algoritma pengenalan ini efisien dan umum digunakan dalam pengenalan pola dan pengolahan gambar, memiliki struktur sederhana, jumlah parameter pelatihan yang sedikit, dan adaptabilitas yang tinggi. CNN juga menggabungkan pengenalan gambar dengan struktur jaringan berbagi bobot, menyerupai jaringan saraf biologis dan pada akhirnya mengurangi kompleksitas model dan jumlah bobot (Liu et al., 2015).

K-Nearest Neighbor

Algoritma K-Nearest Neighbors (KNN) adalah salah satu algoritma yang sederhana dan populer dalam pembelajaran mesin (machine learning) untuk klasifikasi dan regresi. K-Nearest Neighbor (KNN) adalah algoritma supervised learning di mana klasifikasi instance baru ditentukan berdasarkan mayoritas dari kategori k-tetangga terdekat, dengan tujuan untuk mengklasifikasikan objek baru berdasarkan atribut dan sampel dari data latih. Pemilihan parameter K merupakan tahap krusial dalam algoritma KNN karena menentukan jumlah tetangga terdekat yang akan digunakan untuk menentukan label klasifikasi data uji (Mputu et al., 2024). Penentuan nilai K optimal dalam algoritma KNN didasarkan pada data yang ada, dimana nilai K yang tinggi dapat mengurangi efek noise pada klasifikasi, tetapi juga dapat menyebabkan batasan antara setiap klasifikasi menjadi lebih kabur (Anshori et al., 2018). Berikut adalah proses algoritma KNN:

1. Menentukan nilai parameter K (jumlah tetangga terdekat).
2. Menghitung jarak antara data uji tersebut dengan setiap data latih menggunakan metrik jarak.
3. Mengurutkan dan mengidentifikasi K tetangga terdekat (dengan jarak terpendek) dari data uji.
4. Menentukan label dan/atau kategori (kelas) dengan menggunakan mayoritas voting dari label tetangga terdekat untuk menentukan label data uji.

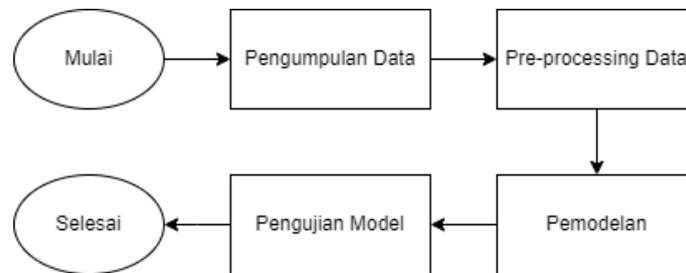
Euclidean Distance

Jarak Euclidean adalah salah satu metode perhitungan jarak yang digunakan untuk mengukur jarak dari 2 (dua) titik dalam ruang n-dimensi (Kurniawan et al., 2022). Perhitungan jarak euclidean dapat menggunakan persamaan berikut:

$$D(d_x, d_y) = \sqrt{(f_{x,1} - f_{y,1})^2 + \dots + (f_{x,n} - f_{y,n})^2}$$

3. METODE PENELITIAN

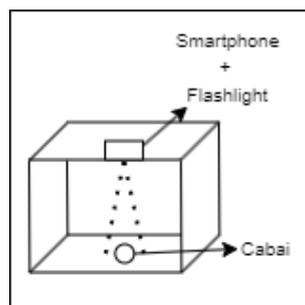
Dalam melakukan penelitian dibutuhkan sebuah metodologi yang terstruktur dan jelas untuk memandu jalannya proses penelitian. Tahapan-tahapan penelitian merupakan langkah-langkah yang ditempuh dari awal hingga akhir penelitian untuk mencapai tujuan yang telah ditetapkan



Gambar 2.1. Tahapan Penelitian

Pengumpulan Data

Pengumpulan data citra cabai rawit dilakukan sebanyak 750 data yang terdiri dari tiga kategori, yaitu mentah, setengah matang, dan matang. Proses pengumpulan data diambil secara langsung dengan menggunakan kamera *smartphone* dengan penggunaan flash. Cabai rawit diletakan di atas alas putih dengan posisi kamera diatas sejajar. Alasan memilih warna putih sebagai alas cabai rawit untuk memudahkan dalam proses penghapusan background dalam tahap pre-processing data (Karki et al., 2023). Pada setiap pengambilan citra, cabai rawit juga diputar sebesar 90 derajat untuk mendapatkan variasi sudut pengambilan yang berbeda.



Gambar 2.2. Cara Pengambilan Data

Pre-Processing Data

Tahap pre-processing data dilakukan dalam beberapa alur tahapan untuk mengolah hasil dari data yang sudah dikumpulkan pada tahap sebelumnya, antara lain menghapus background, pembagian rasio dataset, resize, dan scaling.

1) Menghapus Background

Tahap ini dilakukan untuk menghilangkan background yang terdapat pada citra, sehingga data citra dapat berfokus pada bentuk, tekstur, dan karakteristik penting dari objek citra cabai rawit.

2) Pembagian Rasio Dataset

Tahap ini dilakukan pembagian dataset menjadi data latih dan data tes terhadap setiap kategori. Tahap pembagian data uji dan data latih dilakukan sebanyak tiga kali dengan rasio 60%:40%, 70%:30%, dan 80%:20%. Hasil dari pembagian data kemudian disimpan ke dalam folder terpisah pada setiap kategori.

3) Resizing

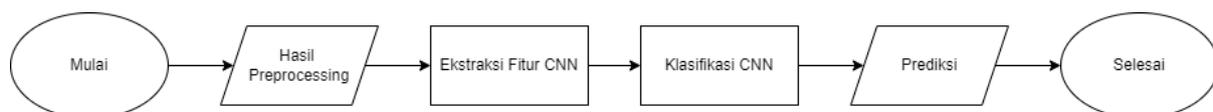
Proses resizing bertujuan mengurangi ukuran gambar dari kamera smartphone untuk meringankan komputasi dan menstandarkan ukuran citra (Ahmad et al., 2020). Adapun ukuran citra yang akan digunakan dalam penelitian adalah sebesar 224x224 piksel (Suha & Sanam, 2022).

4) Scaling

Pada tahap akhir, citra tanaman cabai rawit diskalakan ke rentang 0-1 dengan membagi setiap nilai piksel dengan 255 untuk memastikan data lebih stabil dan efektif diproses oleh model (Ambarwari et al., 2020).

Pemodelan

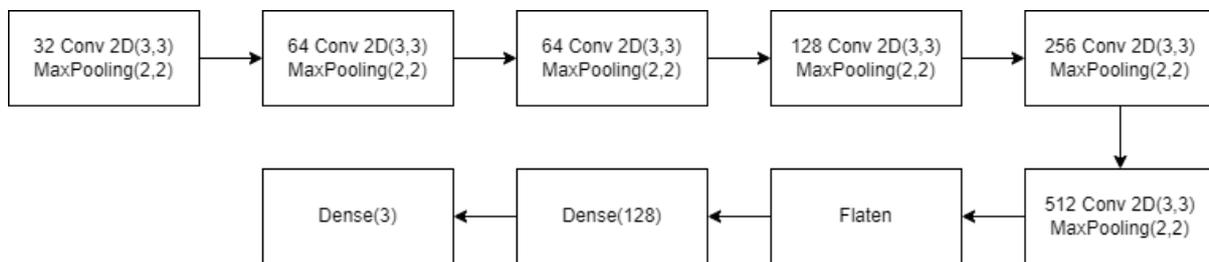
Tahap pemodelan dilakukan serangkaian langkah-langkah untuk merancang model kombinasi dua algoritma, yaitu CNN dan KNN. Proses dimulai dengan menginputkan data hasil pre-processing sebelumnya ke dalam model CNN untuk ekstraksi fitur, yang terdiri dari lapisan konvolusi, ReLU, pooling, flatten, dan dense layer. Feature map dari lapisan flatten kemudian diklasifikasikan menggunakan metode KNN. Pelatihan dan pengujian dilakukan pada model CNN-KNN dengan berbagai nilai K untuk mendapatkan akurasi tertinggi.



Gambar 2.3. Blok Diagram Pemodelan

1) Model CNN

Arsitektur dari model CNN yang akan dibuat terbagi menjadi dua bagian besar, yaitu ekstraksi fitur dan fully connected layer. Lapisan pertama model menambahkan lapisan konvolusi menggunakan 32 filter berukuran 3×3 , dengan menerima input data berukuran 224×224 piksel dan memiliki 3 kanal warna (RGB). Lapisan kedua sampai keenam model menambahkan lapisan konvolusi menggunakan filter 64, 64, 128, 256 dan 512 secara berurutan dengan ukuran kernel 3×3 . Setiap lapisan konvolusi diikuti lapisan maxpooling dengan ukuran 2×2 . Hasil konvolusi diratakan menjadi vektor satu dimensi oleh lapisan flatten, yang kemudian diteruskan ke lapisan fully connected dan dilatih sebanyak 10 epoch.



Gambar 2.4. Arsitektur CNN

2) Ekstraksi Fitur

Pada tahap ini dilakukan proses identifikasi pada data citra tanaman cabai rawit untuk mengekstraksi fitur-fitur penting yang ada pada data citra tanaman cabai rawit. Proses dimulai dengan melatih model CNN menggunakan dataset citra tanaman cabai rawit. Model CNN ini terdiri dari beberapa lapisan konvolusi dan pooling yang telah didefinisikan sebelumnya, yang bertugas mengekstraksi fitur-fitur penting dari gambar (Ab Wahab et al., 2021). Lapisan flatten pada model CNN digunakan untuk mengubah output dari lapisan konvolusi terakhir menjadi vektor satu dimensi (Firmansyah et al., 2023). Vektor fitur yang dihasilkan dari lapisan flatten kemudian diekstrak dan disimpan, menjadi input untuk model KNN.

3) Model KNN

Pada tahap ini, langkah dimulai dengan memasukkan ekstraksi fitur dari lapisan flatten. Langkah selanjutnya menentukan nilai K , yakni $k=5$, $k=10$, $k=15$, $k=20$, $k=25$. Selanjutnya, jarak antara data uji dan data latih dihitung menggunakan metrik euclidean distance. Hasil perhitungan jarak kemudian diurutkan dari yang terkecil hingga terbesar, dan dilakukan pembobotan terhadap tetangga berdasarkan jaraknya. Berdasarkan pembobotan, hasil klasifikasi diperoleh. Proses berakhir dengan hasil klasifikasi tersebut.

Pengujian Model

Skenario pengujian pertama dilakukan terhadap pembagian dataset dengan rasio 60%:40%, 70%:30%, dan 80%:20%. Hasil akurasi terbaik yang telah diperoleh dari rasio pembagian dataset, akan dilakukan pengujian kedua terhadap nilai k dengan variasi dari $k = 5$, $k = 10$, $k = 15$, $k = 20$, dan $k = 25$. Setelah mendapatkan nilai k dengan akurasi terbaik, pengujian selanjutnya dilakukan untuk membandingkan model CNN itu sendiri dengan model KNN yang menggunakan ekstraksi fitur dari model CNN. Perbandingan ini dilakukan pada rasio pembagian dataset yang sebelumnya memberikan hasil akurasi terbaik.

3. HASIL DAN PEMBAHASAN

Pengumpulan Data

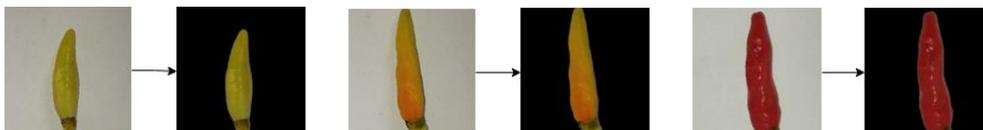
Data yang digunakan dalam penelitian ini adalah gambar tanaman cabai rawit yang terdiri dari tiga kategori, yakni mentah, setengah matang, dan matang. Data diambil secara manual menggunakan kamera smartphone dengan metode pengambilan data seperti pada gambar 2. Data tersebut memiliki total gambar sebanyak 750 yang terdiri dari 250 mentah, 250 setengah matang, dan 250 matang.



Gambar 3.1. Contoh Data Cabai Rawit Mentah, Setengah Matang, Matang

Pre-Processing Data

Tahap pre-processing data merupakan tahap untuk mengolah data mentah menjadi data yang siap digunakan dalam proses pembuatan model. Data yang diolah adalah data citra tanaman cabai rawit dengan tiga kategori tingkat kematangan. Langkah pertama yang dilakukan adalah menghapus background pada seluruh citra cabai rawit di setiap kategori (Liantoni & Annisa, 2018).



Gambar 3.2. Hasil remove Background

Langkah kedua dilakukan pembagian dataset menjadi data latih dan data uji yang akan diletakkan pada folder terpisah pada setiap kategori. Pembagian dataset dilakukan sebanyak tiga kali dengan rasio 60%:40%, 70%:30%, dan 80%:20%. Hasil persebaran data akan ditampilkan pada tabel 3.1.

Tabel 3.1. Persebaran Dataset

Rasio Dataset	Data Latih	Data Uji
60:40	450	300
70:30	525	225
80:20	600	150

Langkah ketiga melakukan standarisasi ukuran citra dengan mengubah ukuran citra menjadi 224x224 piksel. Mengubah ukuran citra juga berdampak pada waktu komputasi, citra dengan ukuran yang relative lebih kecil daripada ukuran citra aslinya akan lebih meringankan beban waktu komputasi. Langkah keempat melakukan scaling apda data pelatihan dan data pengujian. Proses ini melibatkan transformasi data sehingga fitur-fitur tersebut berada dalam rentang tertentu dengan tujuan untuk memastikan bahwa semua fitur berkontribusi secara merata pada model dan menghindari fitur dengan nilai lebih besar menjadi dominan. Tahap scaling memiliki hubungan yang sangat penting dengan algoritma KNN karena sifat cara kerja KNN yang berbasis jarak dan sangat bergantung pada jarak antar titik data untuk membuat prediksi.

Pengujian Model

Skenario Pengujian Pertama

Pengujian pada skenario pertama dilakukan menggunakan rasio pembagian data yang telah dijelaskan sebelumnya. Pengujian terlebih dahulu dilakukan pada model CNN dan dilanjutkan dengan model KNN yang menggunakan ekstraksi fitur dari model CNN dengan parameter nilai $k=5$ untuk setiap rasio pembagian data. Pada skenario pertama diperoleh hasil akurasi dari model CNN yang akan disajikan pada tabel 3.2 dibawah ini.

Tabel 3.2. Akurasi CNN Skenario 1

Rasio	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
60%:40%	81,33	84,37	81,33	80,56
70%:30%	85,78	89,92	85,78	85,11
80%:20%	87,33	90,52	87,33	86,77

Adapun hasil akurasi dari model KNN yang menggunakan ekstraksi fitur dari model CNN dengan parameter nilai $k=5$ pada skenario pertama pada tabel 3.3 di bawah ini.

Tabel 3.3. Akurasi CNN-KNN Skenario 1

Rasio	K	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
60%:40%	5	93,51	93,51	93,33	93,32
70%:30%	5	98,22	98,28	98,22	98,21
80%:20%	5	99,33	99,35	99,33	99,33

Berdasarkan rangkuman pada tabel 2 dan pada tabel 3, hasil akurasi terbaik dari kedua model terdapat pada rasio pembagian data 80:20. Sehingga disimpulkan bahwa pada

pengujian selanjutnya rasio pembagian data 80:20 akan dilakukan pengujian terhadap nilai k yang telah didefinisikan sebelumnya.

Skenario Pengujian Kedua

Pengujian pada skenario kedua adalah melakukan pengujian terhadap setiap nilai k tetangga terdekat yang sudah didefinisikan sebelumnya. Pengujian ini dilakukan menggunakan rasio pembagian data yang memiliki akurasi terbaik berdasarkan hasil dari pengujian pertama, yakni rasio 80:20. Berikut merupakan hasil dari pengujian terhadap nilai k dengan variasi dari k = 5, k = 10, k = 15, k = 20, dan k = 25 yang akan disajikan pada tabel 4.

Tabel 3.4. Akurasi CNN-KNN Skenario 2

Rasio Dataset	K	Akruasi (%)	Presisi (%)	Recal (%)	F1-Score (%)
80:20	5	99,33	99,35	99,33	99,33
	10	98,67	98,69	98,67	98,66
	15	98	98,06	98	97,99
	20	97,33	97,46	97,33	97,31
	25	97,33	97,46	97,33	97,31

Berdasarkan hasil akurasi pada tabel 3.4 didapatkan nilai akurasi tertinggi pada k = 5 dengan akurasi sebesar 99,33%. Berdasarkan hasil analisis, nilai k=5 memberikan hasil akurasi tertinggi dari pengujian ini dan akan dilakukan perbandingan dengan metode CNN itu sendiri.

Skenario Pengujian Ketiga

Pada tahap akhir ini dilakukan skenario pengujian yang telah dijelaskan sebelumnya. Klasifikasi model CNN akan dibandingkan dengan klasifikasi model CNN-KNN yang menggunakan ekstraksi fitur dari CNN. Perbandingan kedua model dilakukan dengan rasio pembagian data 80:20 (600 data latih : 150 data uji) dan mendapatkan hasil akurasi terbaik pada skenario pengujian kedua sebelumnya.

Tabel 3.5. Perbandingan Akurasi

Model	Rasio	Akurasi (%)	Presisi (%)	Recal (%)	F1-Score (%)
CNN	80:20	87,33	90,52	87,33	86,77
CNN-KNN (k=5)	80:20	99,33	99,35	99,33	99,33

Berdasarkan pada tabel 3.5, terjadi peningkatan hasil akurasi dari klasifikasi yang dilakukan oleh model CNN-KNN yang menggunakan ekstraksi fitur dari CNN dibandingkan dengan klasifikasi yang dilakukan oleh model CNN. Pada model CNN-KNN yang menggunakan ekstraksi fitur dari CNN, proses pengujian dengan nilai k = 5 mendapatkan hasil akurasi terbaik dengan angka 99,33%. Sedangkan klasifikasi yang dilakukan oleh CNN itu sendiri mendapatkan hasil akurasi terbaik dengan angka 87,33%. Hal ini menunjukkan

bahwa penggunaan ekstraksi fitur dari CNN dengan klasifikasi menggunakan KNN dapat memberikan hasil yang lebih baik daripada klasifikasi yang dilakukan dengan CNN itu sendiri.

KESIMPULAN DAN SARAN

Berdasarkan penelitian yang dilakukan, model CNN-KNN yang menggunakan ekstraksi fitur dari CNN tidak hanya meningkatkan akurasi tetapi juga memperbaiki presisi, recall, dan F1-score dibandingkan dengan model CNN. Pola dari setiap rasio pembagian dataset juga sangat berpengaruh pada hasil akurasi yang dibuktikan dengan semakin banyaknya jumlah data pelatihan akurasi yang didapatkan semakin tinggi. Saran untuk penelitian selanjutnya adalah menambah jumlah dataset dengan berbagai jenis kondisi pencahayaan, sudut pengambilan, dan faktor-faktor lain yang dapat meningkatkan generalisasi model. Penambahan variasi dalam pembagian dataset juga dapat dilakukan untuk dapat lebih memahami pola-pola lain pada rasio dataset yang berbeda.

DAFTAR REFERENSI

- Ab-Wahab, M.N., et al. (2021). Efficientnet-Lite and Hybrid CNN-KNN Implementation for Facial Expression Recognition on Raspberry Pi. *IEEE Access*, 9, 134065–134080. <https://doi.org/10.1109/ACCESS.2021.3113337>
- Ahmad, K.A., et al. (2020). Classification of Starfruit Ripeness using Neural Network Technique. *Proceedings - 10th IEEE International Conference on Control System, Computing and Engineering, ICCSCE 2020, August*, 163–168. <https://doi.org/10.1109/ICCSCE50387.2020.9204929>
- Ambarwari, A., Adrian, Q.J., & Herdiyeni, Y. (2020). Analysis of the Effect of Data Scaling on the Performance of the Machine Learning Algorithm for Plant Identification. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 4(1), 117–122. <https://doi.org/10.29207/resti.v4i1.1517>
- Anshori, L., Putri, R. R. M., & Tibyani. (2018). Implementasi Metode K-Nearest Neighbor untuk Rekomendasi Keminatan Studi (Studi Kasus : Jurusan Teknik Informatika Universitas Brawijaya). *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer (J-PTIHK)*, 2(7), 2745–2753. https://www.researchgate.net/publication/321097020_Implementasi_Metode_K-Nearest_Neighbor_untuk_Rekomendasi_Keminatan_Studi_Studi_Kasus_Jurusan_Teknik_Informatika_Universitas_Brawijaya
- Aziz, M. A., et al. (2021). Chili Ripeness Grading Simulation Using Machine Learning Approach. *2021 IEEE International Conference on Computing, ICOCO 2021*, 253–258. <https://doi.org/10.1109/ICOCO53166.2021.9673572>
- Cahyaputra, H. R., & Rahmadewi, R. (2024). KLASIFIKASI TINGKAT KEMATANGAN

BUAH PAPRIKA MENGGUNAKAN METODE K-NEAREST NEIGHBOR BERDASARKAN WARNA RGB MELALUI APLIKASI MATLAB. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 9(1), 242–249. <https://doi.org/10.29100/jipi.v9i1.4440>

Firmansyah, A., et al. (2023). Sistem Absensi Mahasiswa Menggunakan Face Recognition Dengan Algoritma CNN. *Jurnal AI Dan SPK : Jurnal Artificial Intelligent Dan Sistem Penunjang Keputusan*, 1(4), 250–258.

Fitri, Z.E., et al. (2020). Penentuan Tingkat Kematangan Cabe Rawit (*Capsicum frutescens* L.) Berdasarkan Gray Level Co-Occurrence Matrix. *Jurnal Teknologi Informasi Dan Terapan*, 7(1), 1–5. <https://doi.org/10.25047/jtit.v7i1.121>

Karki, S., et al. (2023). Classification of strawberry ripeness stages using machine learning algorithms and colour spaces. *Horticulture Environment and Biotechnology*, 0123456789. <https://doi.org/10.1007/s13580-023-00559-2>

Kaswar, A.B., Adiba, F., & Andayani, D.D. (2023). Sistem Klasifikasi Tingkat Kematangan Buah Cabai Katokkon Berdasarkan Fitur Warna LAB Menggunakan Artificial Neural Network Backpropagation. 4(November), 149–157.

Kurniawan, D., et al. (2022). Comparison of Euclidean Distance, Canberra Distance, and Chebychev Distance in K-Means Algorithm Based on Dbi Evaluation. *Jurnal Mantik*, 5(36), 2830–2838.

Liantoni, F., & Annisa, F. N. (2018). Fuzzy K-Nearest Neighbor Pada Klasifikasi Kematangan Cabai Berdasarkan Fitur Hsv Citra. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 3(2), 101–108. <https://doi.org/10.29100/jipi.v3i2.851>

Liu, T., et al. (2015). *Implementation of Training Convolutional Neural Networks*. <http://arxiv.org/abs/1506.01195>

Mputu, H.S., Abdel-mawgood, A., & Shimada, A. (2024). Tomato Quality Classification Based on Transfer Learning Feature Extraction and Machine Learning Algorithm Classifiers. *IEEE Access*, 12(January), 8283–8295. <https://doi.org/10.1109/ACCESS.2024.3352745>

Nugroho, W., Isnanto, R. R., & Rochim, A. F. (2023). Comparison of Mycobacterium Tuberculosis Image Detection Accuracy Using CNN and Combination CNN-KNN. *JURNAL RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(158), 80–86.

Pratama, R.R. (2020). Analisis Model Machine Learning Terhadap Pengenalan Aktifitas Manusia. *MATRIK : Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, 19(2), 302–311. <https://doi.org/10.30812/matrik.v19i2.688>

Saragih, R.E., & Emanuel, A.W.R. (2021). Banana Ripeness Classification Based on Deep Learning using Convolutional Neural Network. *3rd 2021 East Indonesia Conference on Computer and Information Technology, EIconCIT 2021*, 85–89. <https://doi.org/10.1109/EIconCIT50028.2021.9431928>

Sejuti, Z.A., & Islam, M.S. (2023). A hybrid CNN–KNN approach for identification of COVID-19 with 5-fold cross validation. *Sensors International*, 4(January), 100229.

<https://doi.org/10.1016/j.sintl.2023.100229>

Sri, M.K., Saikrishna, K., & Kumar, V. V. (2020). Classification of Ripening of Banana Fruit Using Convolutional Neural Networks. *SSRN Electronic Journal*, 1–6. <https://doi.org/10.2139/ssrn.3558355>

Suha, S.A., & Sanam, T.F. (2022). A deep convolutional neural network-based approach for detecting burn severity from skin burn images. *Machine Learning with Applications*, 9(April), 100371. <https://doi.org/10.1016/j.mlwa.2022.100371>