



Perbandingan Performa CNN MobileNetV2 dan K-Nearest Neighbors untuk Klasifikasi Kondisi Tanaman Cabai

Tegar Wahyu Adi Saputra^{1,*}, Rodhiyah Mardhiyyah²

¹Fakultas Sains & Teknologi, Program Studi Informatika, Universitas Teknologi Yogyakarta, Yogyakarta, Indonesia

²Fakultas Sains & Teknologi, Program Studi Teknik Komputer, Universitas Teknologi Yogyakarta, Yogyakarta, Indonesia

Email: ^{1,*}TegarWahy09@gmail.com, ²Rodhiyah.Mardhiyyah@uty.ac.id,

Email Penulis Korespondensi: TegarWahy09@gmail.com

Abstrak—Penyakit dan hama pada tanaman cabai dapat menurunkan kualitas serta produktivitas hasil panen apabila tidak dideteksi sejak dini. Proses identifikasi kondisi tanaman masih banyak dilakukan secara manual melalui pengamatan visual sehingga rentan terhadap kesalahan diagnosis dan membutuhkan waktu yang relatif lama. Penelitian ini bertujuan membandingkan performa *Convolutional Neural Network* (CNN) berbasis *MobileNetV2* dan *K-Nearest Neighbors* (KNN) dalam klasifikasi kondisi tanaman cabai menggunakan citra digital. Dataset terdiri dari 7.991 data latih, 515 data validasi, dan 355 data uji yang dihasilkan melalui proses *cropping* berdasarkan anotasi *bounding box* pada tujuh kategori kondisi tanaman cabai, yaitu *Anthracnose*, *Aphid*, *Armyworm*, *Healthy*, *Leaf Spot*, *Whitefly*, dan *Yellowish*. Tahap preprocessing meliputi *resize* citra menjadi 128×128 piksel dan normalisasi data. CNN menggunakan arsitektur *MobileNetV2* berbasis *transfer learning*, sedangkan KNN menggunakan kombinasi fitur manual *Histogram of Oriented Gradients* (HOG), *Local Binary Pattern* (LBP), dan *Color Histogram*. Evaluasi dilakukan menggunakan *confusion matrix*, *accuracy*, *precision*, *recall*, dan *F1-score* dengan pendekatan *weighted average*. Hasil menunjukkan bahwa CNN memperoleh *accuracy* sebesar 81,69%, *precision* sebesar 86,28%, *recall* sebesar 81,69%, dan *F1-score* sebesar 81,34%. Sedangkan KNN memperoleh *accuracy* sebesar 45,63%, *precision* sebesar 66,80%, *recall* sebesar 45,63%, dan *F1-score* sebesar 42,24%. Kontribusi penelitian ini terletak pada analisis komparatif antara pendekatan deep learning dan machine learning tradisional pada dataset yang mencakup penyakit, hama, dan kondisi sehat dalam skenario klasifikasi yang sama. Hasil penelitian menunjukkan bahwa kemampuan ekstraksi fitur otomatis pada CNN menghasilkan representasi visual yang lebih efektif dibandingkan fitur manual pada KNN.

Kata Kunci: CNN; Klasifikasi Kondisi Tanaman Cabai; KNN; MobileNetV2; Pengolahan Citra

Abstract—Diseases and pests affecting chili plants can reduce crop quality and productivity if not detected at an early stage. The identification of plant conditions is still commonly performed through manual visual observation, making the process prone to diagnostic errors and time-consuming. This study aims to compare the performance of a MobileNetV2-based Convolutional Neural Network (CNN) and K-Nearest Neighbors (KNN) for chili plant condition classification using digital images. The dataset consisted of 7,991 training images, 515 validation images, and 355 testing images generated through a cropping process based on bounding-box annotations, covering seven categories of chili plant conditions: Anthracnose, Aphid, Armyworm, Healthy, Leaf Spot, Whitefly, and Yellowish. Preprocessing included image resizing to 128×128 pixels and normalization. The CNN model employed a MobileNetV2 architecture with transfer learning, while the KNN model utilized manually extracted features consisting of Histogram of Oriented Gradients (HOG), Local Binary Pattern (LBP), and Color Histogram. Model performance was evaluated using a confusion matrix, accuracy, precision, recall, and F1-score with a weighted-average approach. The results show that CNN outperformed KNN, achieving an accuracy of 81.69%, precision of 86.28%, recall of 81.69%, and F1-score of 81.34%, whereas KNN achieved an accuracy of 45.63%, precision of 66.80%, recall of 45.63%, and F1-score of 42.24%. The contribution of this study lies in providing a comparative analysis between deep learning and traditional machine learning approaches on a dataset encompassing diseases, pests, and healthy conditions within the same classification scenario. The findings indicate that CNN's automatic feature extraction capability produces more effective visual representations than the manually engineered features used by KNN.

Keywords: CNN; Chili Plant Condition Classification; KNN; MobileNetV2; Image Processing

1. PENDAHULUAN

Tanaman cabai (*Capsicum annuum L.*) merupakan salah satu komoditas hortikultura yang memiliki peran penting dalam sektor pertanian di Indonesia. Selain menjadi bahan pangan yang banyak digunakan dalam berbagai masakan, cabai juga memiliki nilai ekonomi yang tinggi karena berkontribusi terhadap pendapatan petani serta sektor agribisnis nasional (Rahman et al., 2021). Permintaan cabai yang terus meningkat menyebabkan komoditas ini banyak dibudidayakan di berbagai daerah. Namun demikian, produktivitas tanaman cabai sering mengalami penurunan akibat serangan penyakit tanaman yang dapat menurunkan kualitas serta hasil panen secara signifikan (Sundari et al., 2021). Kondisi tersebut mendorong perlunya pengembangan sistem deteksi penyakit tanaman yang mampu bekerja secara cepat dan akurat menggunakan teknologi digital modern (Liu & Wang, 2021).

Berbagai gangguan yang umum ditemukan pada tanaman cabai meliputi penyakit seperti *Anthracnose*, *Leaf Spot*, dan *Yellowish Disease*, serta serangan hama seperti *Aphid*, *Whitefly*, dan *Armyworm*. Gangguan tersebut dapat menyerang berbagai bagian tanaman, mulai dari daun, batang, hingga buah cabai. Penelitian menunjukkan bahwa keterlambatan deteksi penyakit tanaman dapat berdampak pada meningkatnya tingkat kerusakan tanaman serta penurunan kualitas hasil panen secara signifikan (Pandian, Kumar, et al., 2022) (Leite et al., 2025). Oleh karena itu, proses identifikasi kondisi tanaman cabai sejak tahap awal menjadi langkah penting dalam mendukung pengendalian dan penanganan yang tepat. Pada praktik budidaya di lapangan, proses identifikasi penyakit dan hama masih banyak dilakukan melalui pengamatan visual oleh petani atau tenaga ahli pertanian. Pendekatan tersebut memiliki beberapa



keterbatasan karena sangat bergantung pada pengalaman pengamat, rentan terhadap kesalahan diagnosis, serta membutuhkan waktu yang relatif lama terutama pada area budidaya yang luas (Falaschetti et al., 2022). Selain itu, beberapa jenis penyakit dan hama memiliki karakteristik visual yang serupa sehingga menyulitkan proses identifikasi secara manual. Kondisi tersebut menyebabkan perlunya sistem otomatis yang mampu melakukan klasifikasi kondisi tanaman secara objektif dan konsisten.

Perkembangan teknologi *computer vision* dan *Artificial Intelligence* memberikan peluang besar dalam pengembangan sistem identifikasi penyakit tanaman berbasis citra digital. Salah satu pendekatan yang banyak digunakan adalah *Convolutional Neural Network* (CNN), yaitu metode deep learning yang mampu melakukan ekstraksi fitur secara otomatis dari citra tanpa memerlukan proses perancangan fitur secara manual. CNN telah banyak digunakan dalam berbagai penelitian klasifikasi citra tanaman karena kemampuannya dalam mempelajari karakteristik visual yang kompleks dan beragam (Lu et al., 2021) (Borhani et al., 2022).

Pemanfaatan CNN dalam klasifikasi penyakit tanaman berbasis citra telah banyak diterapkan karena kemampuannya dalam melakukan ekstraksi fitur otomatis. (Pandian, Kanchanadevi, et al., 2022) menerapkan model CNN pada dataset citra daun tanaman yang telah melalui tahap preprocessing dan augmentasi untuk meningkatkan variasi data. Model yang dihasilkan mampu mencapai tingkat akurasi yang tinggi dalam proses klasifikasi karena tidak memerlukan ekstraksi fitur manual. Namun, pendekatan ini memiliki keterbatasan pada kebutuhan komputasi yang relatif besar serta kompleksitas model yang tinggi, sehingga kurang efisien apabila diterapkan pada perangkat dengan sumber daya terbatas (Ashurov et al., 2024). Penelitian lain yang dilakukan oleh (Dai et al., 2023) menunjukkan bahwa CNN mampu mempertahankan tingkat akurasi yang baik meskipun citra diperoleh dari kondisi pencahayaan dan latar belakang yang berbeda. Selain itu, (Odounfa et al., 2025) melaporkan bahwa pendekatan berbasis CNN memiliki kemampuan yang baik dalam mengenali pola penyakit pada tanaman cabai dengan tingkat konsistensi yang tinggi. Meskipun demikian, sebagian besar penelitian tersebut hanya berfokus pada satu metode klasifikasi sehingga belum memberikan gambaran yang jelas mengenai keunggulan metode tersebut dibandingkan pendekatan lain yang lebih sederhana.

Di sisi lain, metode K-Nearest Neighbors (KNN) merupakan salah satu algoritma machine learning yang banyak digunakan pada permasalahan klasifikasi karena memiliki konsep yang sederhana dan mudah diimplementasikan. KNN melakukan klasifikasi berdasarkan kedekatan jarak antar sampel dalam ruang fitur. Penelitian yang dilakukan oleh (Ms. Lolakshi P. K. et al., 2023) menunjukkan bahwa KNN mampu memberikan performa yang cukup baik dalam klasifikasi penyakit tanaman ketika menggunakan fitur citra yang representatif. Namun demikian, performa KNN sangat dipengaruhi oleh kualitas fitur yang digunakan karena algoritma ini tidak memiliki kemampuan ekstraksi fitur otomatis sebagaimana CNN (Demilie, 2024). Oleh karena itu, pemilihan metode ekstraksi fitur menjadi faktor penting yang menentukan keberhasilan klasifikasi menggunakan KNN.

Penggunaan KNN dalam klasifikasi penyakit tanaman juga umumnya diuji pada dataset dengan kompleksitas yang relatif rendah, seperti citra dengan latar belakang sederhana, variasi pencahayaan yang minim, serta perbedaan visual antar kelas yang cukup jelas. Kondisi tersebut menyebabkan kemampuan metode dalam menangani pola citra yang lebih kompleks menjadi terbatas. Berbeda dengan CNN yang mampu mempelajari representasi fitur secara otomatis dari data citra, KNN tidak memiliki mekanisme pembelajaran fitur sehingga sangat bergantung pada kualitas fitur yang digunakan. Di sisi lain, CNN memiliki keunggulan dalam mengenali pola visual yang kompleks dan mampu melakukan ekstraksi fitur secara otomatis, namun membutuhkan jumlah data yang lebih besar, waktu pelatihan yang lebih lama, serta kebutuhan komputasi yang lebih tinggi dibandingkan KNN (Balaji et al., 2023). Perbedaan karakteristik tersebut menjadikan kedua metode menarik untuk dibandingkan pada permasalahan klasifikasi kondisi tanaman cabai berbasis citra.

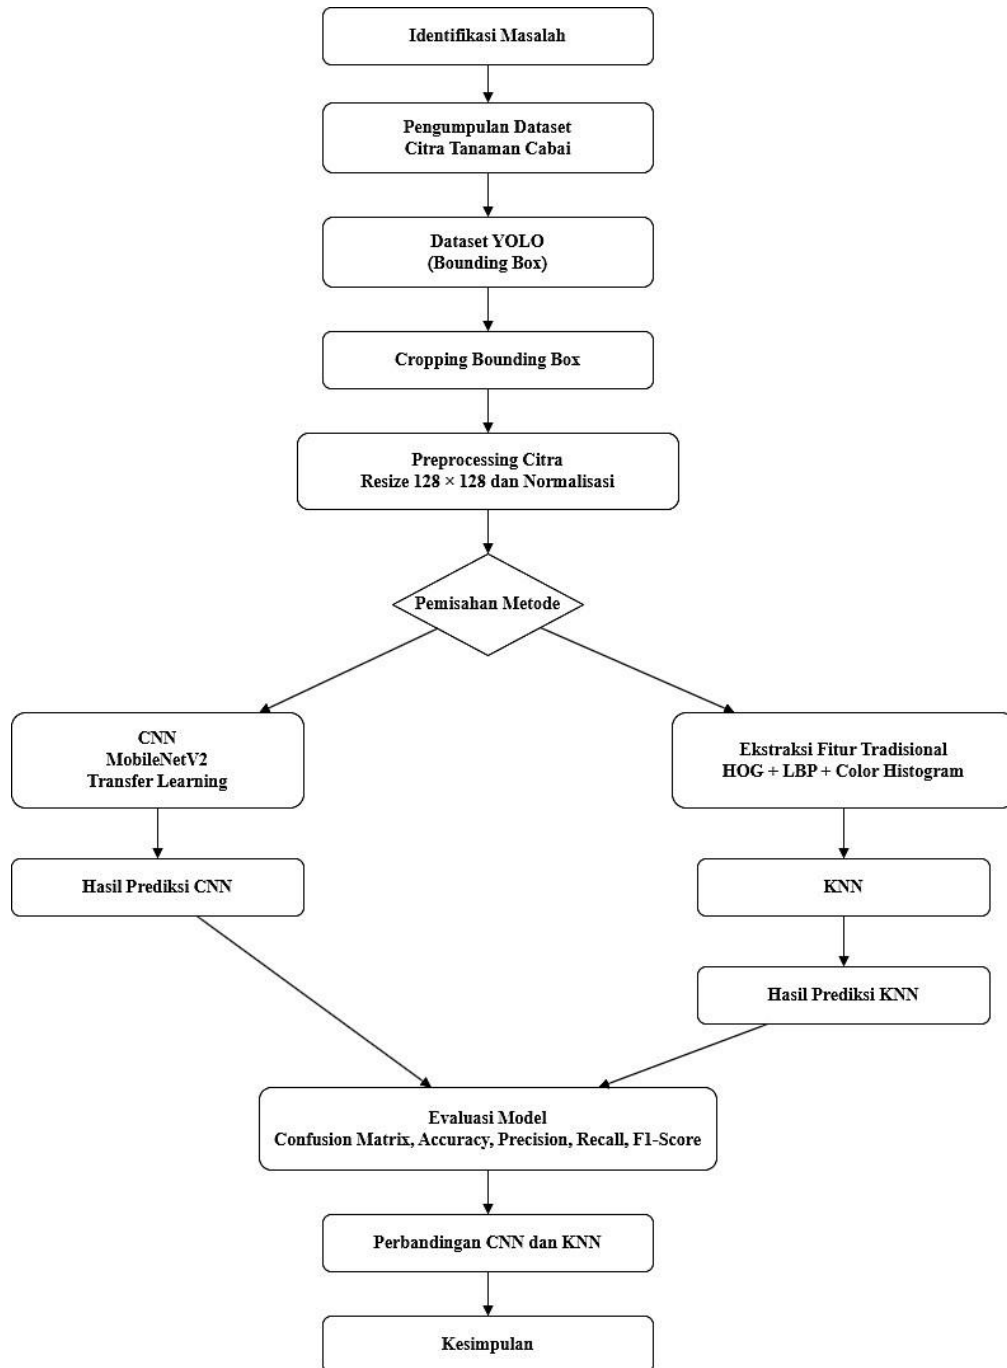
Berdasarkan beberapa penelitian sebelumnya, sebagian besar penelitian hanya berfokus pada penggunaan satu metode klasifikasi tanpa melakukan analisis perbandingan performa antar metode pada dataset yang sama. Selain itu, penelitian terkait perbandingan CNN dan KNN pada klasifikasi penyakit tanaman cabai berbasis citra masih relatif terbatas, khususnya pada kategori penyakit seperti *Anthracoze*, *Yellowish*, dan *Leaf Spot* (Pacal et al., 2024). Penelitian terdahulu juga umumnya menggunakan dataset dengan jumlah kelas yang lebih sedikit atau hanya berfokus pada penyakit tertentu sehingga belum mampu merepresentasikan berbagai kondisi yang dapat terjadi pada tanaman cabai. Oleh karena itu, masih terdapat kebutuhan untuk melakukan evaluasi yang lebih komprehensif terhadap performa CNN dan KNN menggunakan dataset yang mencakup penyakit, hama, serta kondisi sehat tanaman cabai dalam satu skenario klasifikasi yang sama.

Berdasarkan kesenjangan penelitian tersebut, penelitian ini dilakukan untuk membandingkan performa metode *Convolutional Neural Network* (CNN) berbasis *MobileNetV2* dan *K-Nearest Neighbors* (KNN) dalam klasifikasi kondisi tanaman cabai menggunakan citra digital. Pada metode KNN digunakan kombinasi fitur *Histogram of Oriented Gradients* (HOG), *Local Binary Pattern* (LBP), dan *Color Histogram* sebagai representasi karakteristik visual citra, sedangkan metode CNN memanfaatkan kemampuan ekstraksi fitur otomatis melalui arsitektur *MobileNetV2* berbasis *transfer learning*. Kontribusi penelitian ini terletak pada penyediaan analisis komparatif antara pendekatan *deep learning* dan *machine learning* tradisional pada dataset kondisi tanaman cabai yang mencakup penyakit, hama, dan kondisi sehat dalam skenario klasifikasi yang sama. Selain itu, penelitian ini memberikan evaluasi komprehensif menggunakan *metrix accuracy*, *precision*, *recall*, dan *F1-score* untuk memberikan gambaran yang lebih jelas mengenai kelebihan dan keterbatasan masing-masing metode. Hasil penelitian diharapkan dapat menjadi referensi dalam

pemilihan metode klasifikasi citra yang lebih efektif untuk mendukung pengembangan sistem identifikasi kondisi tanaman cabai secara otomatis.

2. METODOLOGI PENELITIAN

2.1 Kerangka Dasar Penelitian



Gambar 1. Tahap Penelitian

Kerangka dasar penelitian yang digunakan pada penelitian ini ditunjukkan pada Gambar 1. Penelitian diawali dengan identifikasi masalah dan pengumpulan dataset citra tanaman cabai yang telah dianotasi menggunakan format YOLO (*You Only Look Once*). Dataset kemudian diproses melalui tahap *cropping* berdasarkan koordinat *bounding box* untuk menghasilkan sampel citra klasifikasi, dilanjutkan dengan tahap preprocessing berupa *resize* citra menjadi 128×128 piksel dan normalisasi data.

Proses klasifikasi dilakukan menggunakan dua pendekatan yang berbeda. Pendekatan pertama menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNetV2* berbasis *transfer learning*, sedangkan pendekatan kedua menggunakan metode *K-Nearest Neighbors* (KNN) dengan kombinasi fitur *Histogram of Oriented*



Gradients (HOG), Local Binary Pattern (*LBP*), dan Color Histogram. Hasil klasifikasi dari kedua metode kemudian dievaluasi menggunakan *confusion matrix*, *accuracy*, *precision*, *recall*, dan *F1-score* untuk mengetahui metode yang memiliki performa terbaik dalam klasifikasi kondisi tanaman cabai. Selanjutnya dilakukan analisis perbandingan performa untuk menentukan metode yang memberikan hasil terbaik dalam klasifikasi kondisi tanaman cabai.

2.1 Identifikasi Masalah

Tahap identifikasi masalah dilakukan untuk mengetahui permasalahan yang menjadi dasar penelitian. Proses identifikasi penyakit dan hama pada tanaman cabai umumnya masih dilakukan secara manual melalui pengamatan visual oleh petani atau tenaga ahli. Metode tersebut memerlukan waktu yang relatif lama serta sangat bergantung pada pengalaman pengamat sehingga berpotensi menimbulkan kesalahan identifikasi, terutama ketika terdapat kemiripan gejala antar penyakit maupun hama.

Perkembangan teknologi pengolahan citra dan kecerdasan buatan memungkinkan proses identifikasi dilakukan secara otomatis menggunakan citra digital. Namun, pemilihan metode klasifikasi yang tepat masih menjadi tantangan karena setiap metode memiliki karakteristik dan performa yang berbeda. Oleh karena itu, penelitian ini dilakukan untuk membandingkan performa metode Convolutional Neural Network (*CNN*) dan K-Nearest Neighbors (*KNN*) dalam klasifikasi kondisi tanaman cabai yang mencakup kategori penyakit, hama, dan kondisi sehat berdasarkan citra digital.

2.2 Pengumpulan Dataset Citra

Dataset yang digunakan dalam penelitian ini berupa citra tanaman cabai yang diperoleh dari platform Roboflow dan telah dianotasi menggunakan format YOLO (*You Only Look Once*). Dataset terdiri atas tujuh kelas, yaitu *Anthracnose*, *Aphid*, *Armyworm*, *Healthy*, *Leaf Spot*, *Whitefly*, dan *Yellowish*. Distribusi dataset yang digunakan dalam penelitian ini ditunjukkan pada Tabel 1.

Tabel 1. Distribusi Dataset Penelitian

Class	Training	Validation	Testing
Anthracnose	530	7	46
Aphid	543	60	29
Armyworm	342	0	10
Healthy	1085	58	49
Leaf Spot	2628	204	112
Whitefly	2662	177	100
Yellowish	201	9	9
Total	7991	515	355

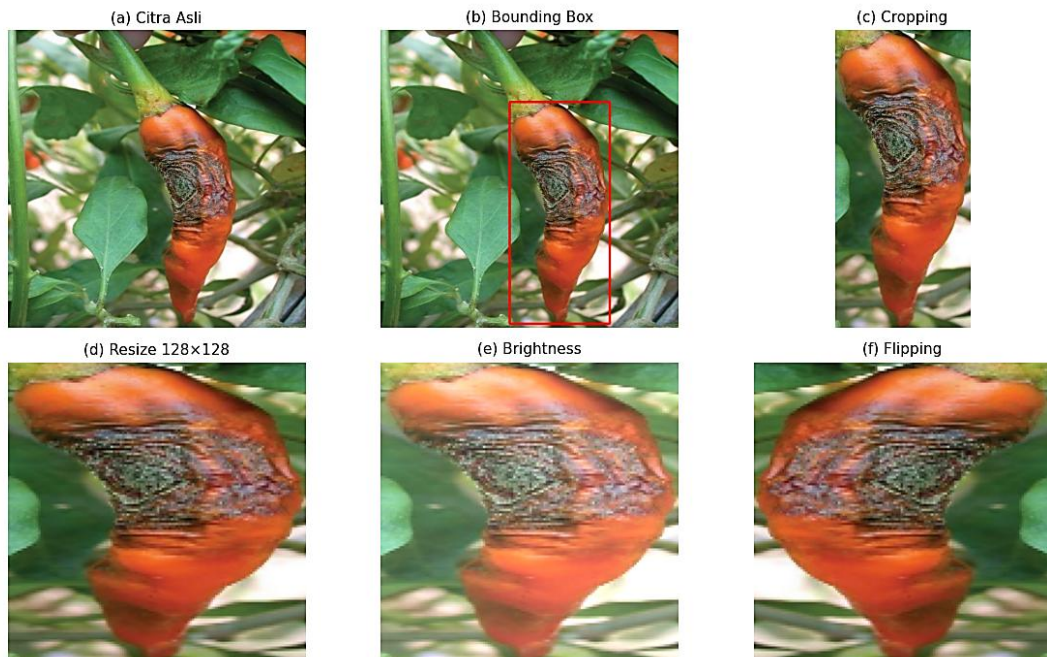
Dataset dibagi menjadi tiga subset, yaitu data latih (*training*), data validasi (*validation*), dan data uji (*testing*). Setiap citra memiliki file anotasi yang berisi informasi kelas objek dan koordinat bounding box yang menunjukkan lokasi objek pada citra. Pada penelitian ini, anotasi bounding box digunakan untuk memperoleh area objek yang menjadi fokus penelitian sebelum dilakukan proses klasifikasi. Pemanfaatan anotasi tersebut memungkinkan setiap objek yang telah ditandai pada citra dapat diproses lebih lanjut pada tahap preprocessing.

Berdasarkan Tabel 1, jumlah sampel pada setiap kelas tidak sepenuhnya seimbang. Pada kelas *Armyworm* tidak tersedia data validasi karena keterbatasan jumlah sampel pada dataset yang digunakan. Perbedaan distribusi data tersebut merupakan karakteristik dataset yang diperoleh dari sumber data dan dapat memengaruhi performa model pada beberapa kelas tertentu. Oleh karena itu, evaluasi model tidak hanya menggunakan *accuracy*, tetapi juga *precision*, *recall*, dan *F1-score* dengan pendekatan *weighted average* untuk memberikan penilaian yang lebih representatif terhadap seluruh kelas.

2.3 Preprocessing Citra

Tahap preprocessing dilakukan untuk menyiapkan citra sebelum digunakan pada proses klasifikasi menggunakan metode CNN dan KNN. Proses diawali dengan melakukan cropping berdasarkan koordinat *bounding box* yang diperoleh dari anotasi dataset sehingga setiap objek menghasilkan satu sampel citra klasifikasi. Hasil *cropping* kemudian diubah ukurannya menjadi 128×128 piksel untuk menghasilkan dimensi citra yang seragam. Selanjutnya dilakukan normalisasi nilai piksel ke rentang 0–1 agar proses pelatihan model menjadi lebih stabil dan efisien (Ummah et al., 2022).

Pada metode CNN, data latih diberikan proses augmentasi untuk meningkatkan variasi data dan mengurangi risiko *overfitting*. Augmentasi yang diterapkan meliputi *horizontal flip*, *vertical flip*, perubahan *brightness*, *contrast*, dan *saturation*. Sementara itu, pada metode KNN, citra hasil preprocessing digunakan sebagai masukan pada tahap ekstraksi fitur HOG, LBP, dan Color Histogram sebelum dilakukan proses klasifikasi. Tahapan preprocessing yang digunakan dalam penelitian ini ditunjukkan pada Gambar 2.



Gambar 2. Tahapan preprocessing citra

2.4 Pemilihan Model CNN dan KNN

Tahap pemilihan model dilakukan untuk menentukan metode yang digunakan dalam proses klasifikasi citra kondisi tanaman cabai. Dua pendekatan yang dipilih dalam penelitian ini adalah *Convolutional Neural Network* (CNN) dan *K-Nearest Neighbors* (KNN). CNN dipilih karena memiliki kemampuan untuk mempelajari dan mengekstraksi fitur citra secara otomatis melalui proses pembelajaran berlapis sehingga efektif dalam mengenali pola visual yang kompleks. Selain itu, penggunaan arsitektur *MobileNetV2* berbasis transfer learning telah banyak digunakan pada berbagai penelitian klasifikasi citra karena mampu menghasilkan performa yang baik dengan kebutuhan komputasi yang relatif efisien (Hajar et al., 2025). Sementara itu, KNN dipilih sebagai metode pembandingan karena merupakan algoritma machine learning yang sederhana dan bekerja berdasarkan kedekatan jarak antar data pada ruang fitur. Berbeda dengan CNN yang melakukan pembelajaran fitur secara otomatis, KNN memerlukan representasi fitur yang diperoleh melalui proses ekstraksi fitur sebelum dilakukan klasifikasi (Ms. Lolakshi P. K. et al., 2023). Pemilihan kedua metode tersebut bertujuan untuk membandingkan performa pendekatan *deep learning* dan *machine learning* tradisional dalam klasifikasi kondisi tanaman cabai menggunakan dataset yang sama. Hasil perbandingan diharapkan dapat memberikan gambaran mengenai efektivitas masing-masing metode dalam mengidentifikasi kondisi tanaman cabai berbasis citra digital.

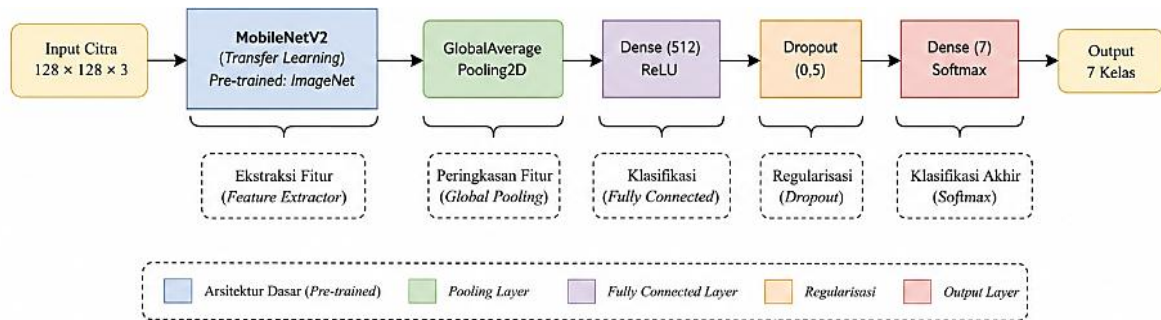
2.5 Pelatihan Model CNN

Tahap pelatihan model CNN dilakukan untuk membangun model klasifikasi yang mampu mengenali pola visual pada citra kondisi tanaman cabai. Pada penelitian ini digunakan arsitektur *MobileNetV2* yang memanfaatkan pendekatan transfer learning dengan bobot awal (*pre-trained weights*) dari dataset *ImageNet*. *MobileNetV2* dipilih karena memiliki arsitektur yang ringan dan efisien sehingga mampu menghasilkan performa klasifikasi yang baik dengan kebutuhan komputasi yang lebih rendah dibandingkan beberapa arsitektur CNN yang lebih kompleks (Hajar et al., 2025).

Input model berupa citra berukuran 128×128 piksel yang telah melalui tahap preprocessing. Citra kemudian diproses oleh *MobileNetV2* sebagai *feature extractor* untuk mempelajari representasi fitur secara otomatis melalui serangkaian lapisan konvolusi. Hasil ekstraksi fitur selanjutnya diringkas menggunakan lapisan *GlobalAveragePooling2D* sehingga diperoleh vektor fitur yang merepresentasikan informasi penting dari citra.

Vektor fitur yang dihasilkan diteruskan ke lapisan klasifikasi yang terdiri dari Dense sebanyak 512 neuron dengan fungsi aktivasi *ReLU*. Untuk mengurangi risiko *overfitting*, digunakan lapisan Dropout dengan nilai 0,5 yang menonaktifkan sebagian neuron secara acak selama proses pelatihan. Lapisan keluaran menggunakan Dense sebanyak tujuh neuron sesuai jumlah kelas yang digunakan pada penelitian ini dengan fungsi aktivasi Softmax untuk menghasilkan probabilitas klasifikasi pada setiap kelas.

Model dilatih menggunakan optimizer Adam dengan learning rate 0,001 dan *loss function categorical crossentropy*. Proses pelatihan dilakukan menggunakan data latih, sedangkan data validasi digunakan untuk memantau performa model selama proses pembelajaran. Arsitektur CNN (*MobileNetV2*) yang digunakan dalam penelitian ini ditunjukkan pada Gambar 3.



Gambar 3. Arsitektur CNN berbasis (MobileNetV2) yang digunakan dalam penelitian untuk klasifikasi kondisi tanaman cabai.

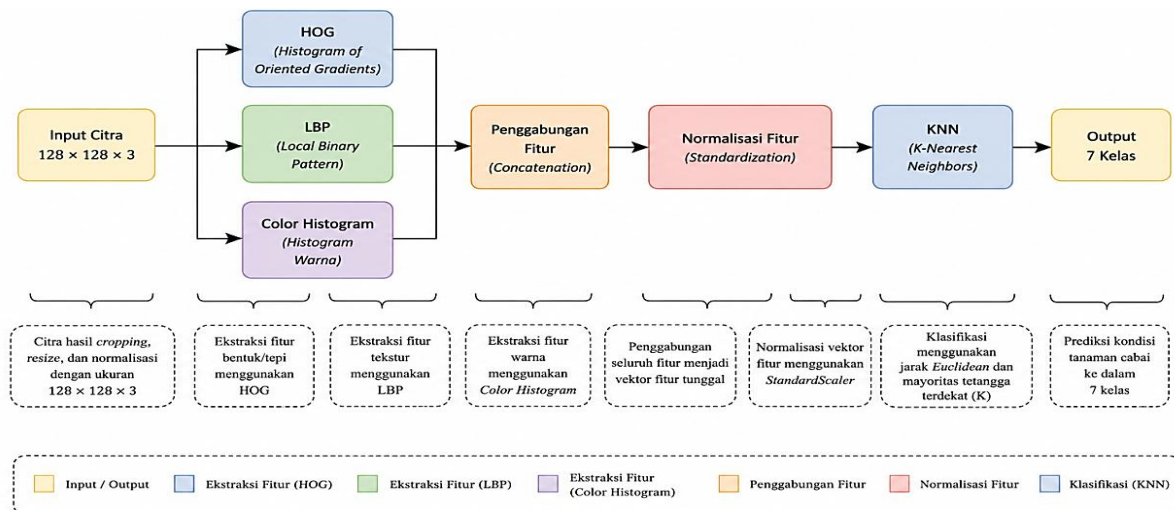
2.6 Pelatihan dan Klasifikasi KNN

Metode *K-Nearest Neighbors* (KNN) digunakan sebagai pendekatan machine learning tradisional untuk melakukan klasifikasi kondisi tanaman cabai berdasarkan karakteristik visual citra. Berbeda dengan CNN yang mampu melakukan ekstraksi fitur secara otomatis, metode KNN memerlukan proses ekstraksi fitur terlebih dahulu sebelum proses klasifikasi dilakukan.

Pada penelitian ini, citra hasil preprocessing dengan ukuran 128×128 piksel digunakan sebagai masukan untuk proses ekstraksi fitur. Tiga jenis fitur digunakan, yaitu *Histogram of Oriented Gradients* (HOG), *Local Binary Pattern* (LBP), dan *Color Histogram*. Fitur HOG digunakan untuk merepresentasikan informasi bentuk dan arah tepi objek, sedangkan LBP digunakan untuk merepresentasikan karakteristik tekstur citra. HOG mampu menangkap informasi bentuk dan struktur objek melalui distribusi arah gradien, sedangkan LBP efektif dalam merepresentasikan pola tekstur lokal pada citra (Ozturk & Yildirim, 2025). Sementara itu, Color Histogram digunakan untuk menggambarkan distribusi warna pada citra tanaman cabai.

Fitur yang diperoleh dari HOG, LBP, dan Color Histogram kemudian digabungkan menjadi satu vektor fitur untuk menghasilkan representasi citra yang lebih lengkap. Selanjutnya dilakukan normalisasi fitur menggunakan *StandardScaler* agar setiap fitur memiliki skala yang seragam sebelum digunakan pada proses klasifikasi.

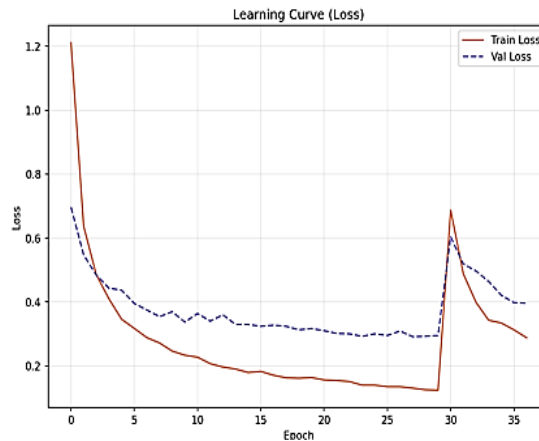
Proses klasifikasi dilakukan menggunakan algoritma *K-Nearest Neighbors* (KNN) dengan menghitung jarak Euclidean antara data uji dan data latih. Kelas data uji ditentukan berdasarkan mayoritas label dari sejumlah tetangga terdekat sesuai nilai K yang digunakan pada model. Metode KNN banyak digunakan pada klasifikasi citra karena memiliki mekanisme klasifikasi yang sederhana dan mampu bekerja dengan baik pada data yang telah direpresentasikan dalam bentuk fitur numerik (Zahirah et al., 2024). Arsitektur pelatihan dan klasifikasi KNN yang digunakan dalam penelitian ini ditunjukkan pada Gambar 4.



Gambar 3. Arsitektur Klasifikasi KNN Menggunakan HOG, LBP, dan Histogram Warna

2.7 Evaluasi Model

Evaluasi model dilakukan untuk mengukur performa metode CNN dan KNN dalam mengklasifikasikan kondisi tanaman cabai. Pada model CNN, evaluasi selama proses pelatihan dilakukan menggunakan metrik *training loss* dan *validation loss* yang divisualisasikan melalui grafik *learning curve*. Grafik tersebut digunakan untuk memantau perubahan nilai *loss* terhadap jumlah *epoch* selama proses pelatihan berlangsung (Balaji et al., 2023; Pacal et al., 2024). Grafik *learning curve* yang digunakan dalam penelitian ini ditunjukkan pada Gambar 5.



Gambar 4. Grafik *Learning Curve* Berdasarkan Training Loss dan Validation Loss

Pada Gambar 5, kurva *training loss* menunjukkan tingkat kesalahan model terhadap data latih, sedangkan *validation loss* menunjukkan kemampuan model dalam melakukan generalisasi terhadap data yang belum pernah dilihat sebelumnya. Penurunan nilai loss pada kedua kurva mengindikasikan bahwa model mampu mempelajari pola dari data secara bertahap. Selain itu, selisih antara training loss dan validation loss dapat digunakan untuk mengidentifikasi potensi *overfitting* maupun *underfitting* selama proses pelatihan model.

Berbeda dengan CNN, metode KNN tidak memiliki proses pelatihan berbasis *epoch* sehingga tidak menghasilkan *training loss* maupun *validation loss*. Evaluasi pada metode KNN dilakukan langsung pada tahap pengujian menggunakan data uji yang telah diproses melalui ekstraksi fitur HOG, LBP, dan Color Histogram. Selanjutnya, performa klasifikasi CNN dan KNN dievaluasi menggunakan *confusion matrix*, *accuracy*, *precision*, *recall*, dan *F1-score*. Penggunaan beberapa metrik evaluasi tersebut bertujuan untuk memberikan penilaian yang lebih komprehensif terhadap kemampuan model dalam mengklasifikasikan kondisi tanaman cabai pada seluruh kelas yang digunakan dalam penelitian (Rainio et al., 2024).

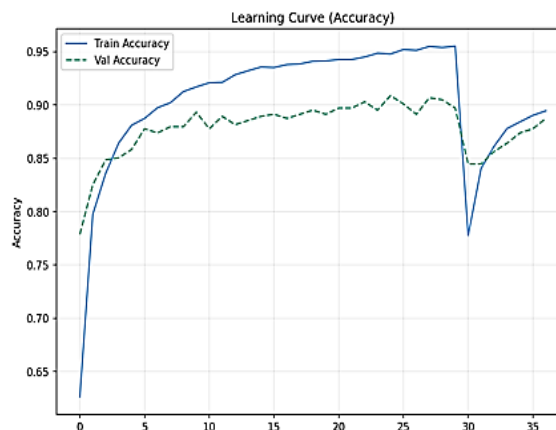
Pada penelitian ini, nilai precision, recall, dan F1-score dihitung menggunakan pendekatan weighted average. Pendekatan ini dipilih karena distribusi jumlah data pada setiap kelas tidak seimbang, sehingga kontribusi masing-masing kelas dalam perhitungan metrik evaluasi disesuaikan dengan jumlah sampel yang dimiliki. Dengan demikian, hasil evaluasi yang diperoleh dapat menggambarkan performa model secara lebih representatif terhadap keseluruhan dataset dibandingkan penggunaan macro average maupun micro average.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Model CNN

3.1.1 Hasil Pelatihan Model CNN

Grafik *learning curve (accuracy)* digunakan untuk menunjukkan perkembangan performa model CNN selama proses pelatihan. Grafik ini memperlihatkan perubahan nilai akurasi pada data latih (*training*) dan data validasi (*validation*) terhadap jumlah *epoch*.



Gambar 5. Grafik Akurasi Pelatihan dan Validasi Model CNN

Berdasarkan Gambar 6, terlihat bahwa akurasi pada data latih mengalami peningkatan yang cukup signifikan pada awal proses pelatihan, kemudian meningkat secara bertahap hingga mencapai nilai di atas 95%. Sementara itu, akurasi pada data validasi juga menunjukkan tren peningkatan yang stabil, meskipun nilainya sedikit lebih rendah

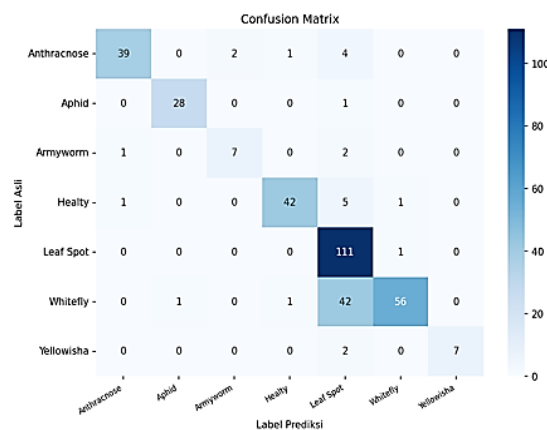
dibandingkan data latih. Hal ini menunjukkan bahwa model mampu mempelajari pola dari data dengan baik serta memiliki kemampuan generalisasi yang cukup baik terhadap data yang belum pernah dilihat sebelumnya.

Namun, terdapat selisih antara akurasi data latih dan performa model pada data pengujian yang memperoleh akurasi sebesar 81,69%. Kondisi ini mengindikasikan adanya kecenderungan overfitting ringan, di mana model mampu mengenali pola pada data latih dengan sangat baik tetapi performanya menurun ketika dihadapkan pada data baru. Meskipun demikian, perbedaan tersebut masih berada pada batas yang dapat diterima karena kurva akurasi validasi tetap menunjukkan tren yang stabil dan tidak mengalami penurunan yang signifikan selama proses pelatihan.

Selain itu, pada sekitar epoch ke-30 terlihat adanya penurunan akurasi pada data latih. Kondisi ini dapat disebabkan oleh proses penyesuaian bobot model selama pelatihan serta variasi karakteristik data yang dipelajari pada setiap epoch. Setelah itu, akurasi kembali meningkat dan menunjukkan kestabilan hingga akhir proses pelatihan, yang mengindikasikan bahwa model masih mampu mencapai konvergensi dengan baik.

3.1.2 Evaluasi Model CNN (Confusion Matrix)

Confusion matrix digunakan untuk mengevaluasi performa model CNN dalam mengklasifikasikan setiap kategori penyakit tanaman cabai. Berdasarkan hasil yang diperoleh, sebagian besar data berhasil diklasifikasikan dengan benar, terutama pada kelas *Healthy* dan *Leaf Spot* yang memiliki jumlah prediksi benar relatif tinggi. Hasil ini menunjukkan bahwa model mampu mengenali karakteristik visual utama dari kedua kelas tersebut dengan cukup baik. *Confusion Matrix* model CNN ditunjukkan pada Gambar 7.



Gambar 6. Confusion Matrix Model CNN

Meskipun demikian, masih terdapat beberapa kesalahan klasifikasi pada beberapa kelas tertentu. Salah satu misklasifikasi yang paling sering terjadi adalah antara kelas *Whitefly* dan *Leaf Spot*. Kondisi ini diduga disebabkan oleh adanya kemiripan karakteristik visual pada daun yang terinfeksi, seperti munculnya bercak berwarna kekuningan hingga kecokelatan, perubahan tekstur permukaan daun, serta variasi tingkat kerusakan daun yang relatif serupa pada beberapa citra. Selain itu, perbedaan pencahayaan, sudut pengambilan gambar, dan variasi kondisi daun pada dataset juga dapat memengaruhi kemampuan model dalam membedakan kedua kelas tersebut secara konsisten.

Secara keseluruhan, hasil *confusion matrix* menunjukkan bahwa sebagian besar citra berhasil diklasifikasikan ke kelas yang sesuai. Meskipun masih terdapat beberapa misklasifikasi pada kelas yang memiliki karakteristik visual yang mirip, distribusi prediksi yang dihasilkan menunjukkan bahwa model telah mampu membedakan sebagian besar kategori penyakit tanaman cabai dengan cukup baik.

3.1.3 Ringkasan Hasil Evaluasi CNN

Berdasarkan hasil evaluasi menggunakan pendekatan weighted average, model CNN memperoleh nilai accuracy sebesar 81,69%, precision sebesar 86,28%, recall sebesar 81,69%, dan F1-score sebesar 81,34%. Nilai precision yang lebih tinggi menunjukkan bahwa model memiliki kemampuan yang baik dalam meminimalkan kesalahan prediksi pada setiap kelas penyakit. Sementara itu, nilai *recall* yang relatif tinggi menunjukkan bahwa sebagian besar citra pada masing-masing kelas berhasil dikenali dengan baik oleh model.

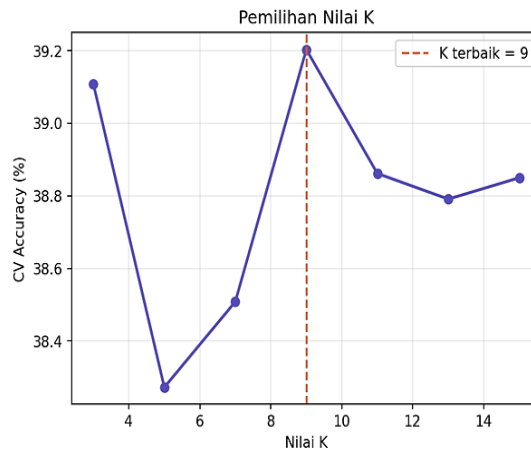
Perbedaan yang relatif kecil antara nilai *accuracy*, *recall*, dan *F1-score* menunjukkan bahwa performa model cukup seimbang dalam melakukan klasifikasi pada seluruh kelas yang digunakan dalam penelitian. Hasil ini juga didukung oleh *confusion matrix* yang menunjukkan bahwa sebagian besar data berhasil diklasifikasikan dengan benar, meskipun masih terdapat beberapa kesalahan prediksi pada kelas yang memiliki karakteristik visual yang mirip.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa model CNN mampu mempertahankan performa yang cukup seimbang pada seluruh metrik pengujian. Nilai *accuracy*, *precision*, *recall*, dan *F1-score* yang relatif tinggi menunjukkan bahwa model memiliki kemampuan yang baik dalam mengenali berbagai kondisi tanaman cabai pada proses klasifikasi multikelas.

3.2 Hasil Model KNN

3.2.1 Pemilihan Nilai K

Pemilihan nilai K merupakan tahap penting dalam metode *K-Nearest Neighbors* (KNN) karena mempengaruhi hasil klasifikasi. Berdasarkan grafik yang diperoleh, nilai K terbaik berada pada $K = 9$, yang menghasilkan nilai akurasi tertinggi dibandingkan dengan nilai K lainnya.

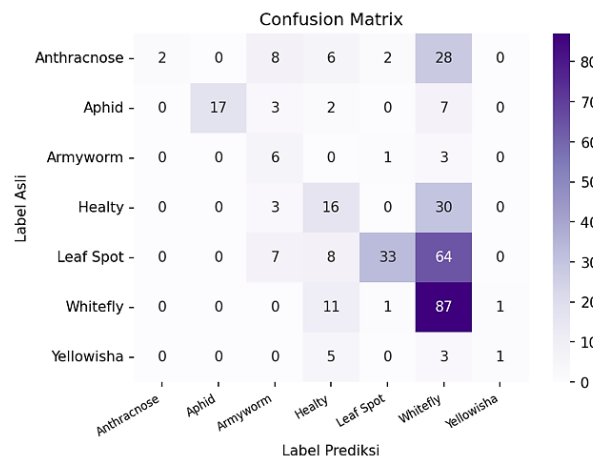


Gambar 7. Grafik Pemilihan Nilai K Terbaik pada Model KNN

Berdasarkan Gambar 8, nilai $K = 9$ menghasilkan tingkat akurasi tertinggi dibandingkan dengan nilai K lainnya sehingga dipilih sebagai parameter terbaik pada model KNN. Hasil tersebut menunjukkan bahwa penggunaan sembilan tetangga terdekat mampu memberikan keseimbangan yang baik antara sensitivitas terhadap variasi data dan kemampuan generalisasi model. Nilai K yang terlalu kecil dapat menyebabkan model lebih sensitif terhadap *noise*, sedangkan nilai K yang terlalu besar dapat mengurangi kemampuan model dalam membedakan karakteristik setiap kelas secara spesifik.

3.2.2 Evaluasi Model KNN (Confusion Matrix)

Confusion matrix digunakan untuk mengevaluasi kemampuan model KNN dalam mengklasifikasikan setiap kategori penyakit tanaman cabai berdasarkan fitur yang telah diekstraksi. Berdasarkan hasil yang diperoleh, masih terdapat cukup banyak kesalahan klasifikasi pada beberapa kelas penyakit. Salah satu misklasifikasi yang paling sering terjadi adalah pada kelas *Leaf Spot* yang diprediksi sebagai *Whitefly*, *Confusion Matrix* model KNN ditunjukkan pada Gambar 9.



Gambar 8. Confusion Matrix Model KNN

Selain itu, beberapa kelas lain seperti *Anthracnose* dan *Healthy* juga menunjukkan jumlah prediksi yang kurang tepat. Kondisi ini menunjukkan bahwa model mengalami kesulitan dalam membedakan beberapa kelas yang memiliki karakteristik visual yang serupa. Kemiripan pola warna, tekstur, dan bentuk gejala pada daun menyebabkan representasi fitur antar kelas menjadi saling berdekatan sehingga meningkatkan kemungkinan terjadinya kesalahan klasifikasi. Secara keseluruhan, hasil *confusion matrix* menunjukkan bahwa model KNN masih mengalami keterbatasan dalam membedakan seluruh kategori penyakit tanaman cabai secara konsisten. Hal ini terlihat dari distribusi prediksi yang masih menyebar pada beberapa kelas dan tingginya jumlah misklasifikasi dibandingkan kelas yang berhasil diprediksi dengan benar.



3.2.3 Ringkasan Hasil Evaluasi KNN

Berdasarkan hasil evaluasi menggunakan pendekatan weighted average, model KNN memperoleh nilai akurasi sebesar 45.63%, precision sebesar 66.80%, recall sebesar 45.63%, dan F1-score sebesar 42.24%. Nilai *accuracy* dan *recall* yang relatif rendah menunjukkan bahwa model masih mengalami kesulitan dalam mengenali sebagian besar kategori penyakit tanaman cabai secara tepat. Meskipun nilai precision lebih tinggi dibandingkan metrik lainnya, performa keseluruhan model masih belum optimal untuk digunakan pada klasifikasi multikelas.

Rendahnya performa KNN diduga disebabkan oleh keterbatasan representasi fitur yang digunakan dalam menggambarkan karakteristik penyakit tanaman cabai. Meskipun kombinasi fitur HOG, LBP, dan Color Histogram mampu merepresentasikan informasi bentuk, tekstur, dan warna, fitur-fitur tersebut belum sepenuhnya mampu menangkap pola visual yang kompleks pada setiap kelas penyakit. Selain itu, beberapa kategori penyakit memiliki gejala yang serupa, seperti perubahan warna daun, bercak, dan kerusakan permukaan daun, sehingga menyebabkan jarak antar kelas dalam ruang fitur menjadi saling berdekatan.

Karena KNN melakukan klasifikasi berdasarkan kedekatan jarak antar data tanpa proses pembelajaran fitur secara mendalam, kemampuan model sangat bergantung pada kualitas representasi fitur yang digunakan. Kondisi ini menyebabkan model mengalami kesulitan dalam membedakan kelas-kelas yang memiliki karakteristik visual yang mirip, sehingga menghasilkan tingkat akurasi yang lebih rendah dibandingkan metode CNN.

3.3 Pembahasan

Untuk mengetahui metode yang memberikan performa terbaik dalam klasifikasi penyakit tanaman cabai, dilakukan perbandingan hasil evaluasi antara model CNN dan KNN menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil perbandingan performa kedua metode ditunjukkan pada Tabel 2.

Tabel 2. Perbandingan Hasil Evaluasi CNN dan KNN

Metode	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
CNN (MobileNetV2)	81,69	86,28	81,69	81,34
KNN (HOG + LBP + Color Histogram)	45,63	66,80	45,63	42,24

Berdasarkan Tabel 2, metode CNN berbasis *MobileNetV2* memperoleh performa yang lebih baik dibandingkan metode K-Nearest Neighbors (KNN) pada seluruh metrik evaluasi. CNN menghasilkan *accuracy* sebesar 81,69%, sedangkan KNN hanya memperoleh *accuracy* sebesar 45,63%. Perbedaan tersebut menunjukkan bahwa kemampuan ekstraksi fitur otomatis pada CNN mampu menghasilkan representasi visual yang lebih baik dibandingkan pendekatan ekstraksi fitur manual menggunakan kombinasi fitur HOG, LBP, dan Color Histogram pada metode KNN.

Hasil penelitian ini sejalan dengan penelitian yang dilakukan oleh (Zahirah et al., 2024). yang membandingkan metode CNN dan KNN berbasis ekstraksi fitur GLCM pada klasifikasi citra daun herbal. Penelitian tersebut menunjukkan bahwa metode CNN memperoleh performa yang lebih tinggi dengan *accuracy* sebesar 96%, sedangkan metode KNN menghasilkan *accuracy* yang lebih rendah. Temuan tersebut memperkuat hasil penelitian ini bahwa pendekatan CNN memiliki kemampuan yang lebih baik dalam melakukan klasifikasi citra dibandingkan metode KNN berbasis fitur manual.

Selain itu, hasil penelitian ini juga sejalan dengan penelitian (Odounfa et al., 2025). yang menggunakan berbagai arsitektur deep learning untuk klasifikasi penyakit tanaman cabai. Pada penelitian tersebut, *MobileNetV2* mencapai *accuracy* sebesar 96,25% dan termasuk salah satu model dengan performa terbaik dalam klasifikasi penyakit cabai. Hasil tersebut menunjukkan bahwa *MobileNetV2* memiliki kemampuan yang baik dalam mempelajari karakteristik visual penyakit tanaman melalui proses ekstraksi fitur otomatis.

Sebaliknya, performa KNN yang lebih rendah pada penelitian ini diduga dipengaruhi oleh ketergantungannya terhadap kualitas fitur hasil ekstraksi HOG, LBP, dan Color Histogram. Meskipun kombinasi fitur tersebut mampu merepresentasikan informasi bentuk, tekstur, dan warna citra, karakteristik visual antar kelas pada dataset kondisi tanaman cabai memiliki tingkat kemiripan yang cukup tinggi sehingga menyebabkan terjadinya misklasifikasi pada beberapa kelas. Berdasarkan hasil tersebut, CNN berbasis *MobileNetV2* dapat dipertimbangkan sebagai metode yang lebih efektif untuk pengembangan sistem klasifikasi kondisi tanaman cabai berbasis citra digital.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, metode *Convolutional Neural Network* (CNN) berbasis *MobileNetV2* menunjukkan performa yang lebih baik dibandingkan *K-Nearest Neighbors* (KNN) dalam klasifikasi penyakit tanaman cabai menggunakan citra digital. Hasil penelitian menunjukkan bahwa kemampuan ekstraksi fitur otomatis pada CNN lebih efektif dalam merepresentasikan karakteristik visual penyakit tanaman cabai dibandingkan pendekatan KNN yang menggunakan fitur manual berupa *Histogram of Oriented Gradients* (HOG), *Local Binary Pattern* (LBP), dan Color Histogram. Pada dataset yang terdiri dari tujuh kategori kondisi daun tanaman cabai, CNN mampu mempelajari pola visual yang lebih kompleks sehingga menghasilkan performa klasifikasi yang lebih baik dibandingkan KNN. Meskipun demikian, hasil pengujian menunjukkan bahwa masih terdapat beberapa misklasifikasi pada kelas yang memiliki karakteristik visual yang mirip, seperti *Whitefly* dan *Leaf Spot*, yang menunjukkan bahwa tantangan klasifikasi masih



ditemukan pada beberapa kategori penyakit. Selain itu, rendahnya performa KNN mengindikasikan bahwa penggunaan fitur manual belum mampu merepresentasikan seluruh karakteristik visual penyakit tanaman cabai secara optimal sehingga proses klasifikasi menjadi kurang akurat pada beberapa kelas penyakit. Kontribusi penelitian ini terletak pada penyediaan analisis komparatif antara pendekatan deep learning berbasis *MobileNetV2* dan *machine learning* tradisional berbasis kombinasi fitur HOG, LBP, dan Color Histogram pada dataset kondisi tanaman cabai yang mencakup penyakit, hama, dan kondisi sehat dalam skenario klasifikasi yang sama. Hasil penelitian ini memberikan gambaran yang lebih jelas mengenai kelebihan dan keterbatasan masing-masing metode sehingga dapat menjadi referensi dalam pemilihan metode klasifikasi citra tanaman cabai yang lebih efektif. Temuan ini menunjukkan bahwa pemilihan metode klasifikasi memiliki pengaruh yang signifikan terhadap kualitas identifikasi penyakit tanaman cabai berbasis citra digital, terutama pada dataset yang memiliki kompleksitas visual tinggi. Penelitian ini juga membuktikan bahwa pendekatan deep learning lebih mampu menangani variasi warna, tekstur, dan bentuk gejala penyakit dibandingkan metode *machine learning* konvensional yang bergantung pada representasi fitur yang telah ditentukan sebelumnya. Meskipun demikian, penelitian ini masih memiliki keterbatasan pada variasi data dan kondisi lingkungan yang digunakan dalam proses pengambilan citra, sehingga kemampuan generalisasi model masih dapat ditingkatkan. Oleh karena itu, penelitian selanjutnya dapat mempertimbangkan penggunaan dataset yang lebih beragam, optimasi *hyperparameter* yang lebih mendalam, penerapan teknik augmentasi yang lebih bervariasi, serta perbandingan dengan arsitektur *deep learning* lain seperti *EfficientNet*, *ResNet*, maupun *Vision Transformer* untuk meningkatkan kemampuan generalisasi dan performa klasifikasi model pada berbagai kondisi lingkungan yang berbeda.

REFERENCES

- Ashurov, A. Y., Al-Gaashani, M. S. A. M., Samee, N. A., Alkanhel, R., Atteia, G., Abdallah, H. A., & Saleh Ali Muthanna, M. (2024). Enhancing plant disease detection through deep learning: a Depthwise CNN with squeeze and excitation integration and residual skip connections. *Frontiers in Plant Science*, *15*. <https://doi.org/10.3389/fpls.2024.1505857>
- Balaji, B., Satyanarayana Murthy, T., & Kuchipudi, R. (2023). A Comparative Study on Plant Disease Detection and Classification Using Deep Learning Approaches. *International Journal of Image, Graphics and Signal Processing*, *15*(3), 48–59. <https://doi.org/10.5815/ijigsp.2023.03.04>
- Borhani, Y., Khoramdel, J., & Najafi, E. (2022). A deep learning based approach for automated plant disease classification using vision transformer. *Scientific Reports*, *12*(1). <https://doi.org/10.1038/s41598-022-15163-0>
- Dai, M., Sun, W., Wang, L., Dorjoy, M. M. H., Zhang, S., Miao, H., Han, L., Zhang, X., & Wang, M. (2023). Pepper leaf disease recognition based on enhanced lightweight convolutional neural networks. *Frontiers in Plant Science*, *14*. <https://doi.org/10.3389/fpls.2023.1230886>
- Demilie, W. B. (2024). Plant disease detection and classification techniques: a comparative study of the performances. *Journal of Big Data*, *11*(1). <https://doi.org/10.1186/s40537-023-00863-9>
- Falascetti, L., Manoni, L., Leo, D. Di, Pau, D., Tomaselli, V., & Turchetti, C. (2022). A CNN-based image detector for plant leaf diseases classification. *HardwareX*, *12*, e00363. <https://doi.org/10.17605/OSF.IO/UCM8D>
- Hajar, S., Murinto, M., & Yudhana, A. (2025). Comparison of Transfer Learning Strategies Using MobileNetV2 and ResNet50 for Ecoprint Leaf Classification. *Jurnal Teknik Informatika (Jutif)*, *6*(5), 3251–3264. <https://doi.org/10.52436/1.jutif.2025.6.5.5266>
- Leite, D. V., de Brito, A. V., Faccioli, G. G., & Haddad Souza Vieira, G. (2025). Deep Learning Models for Detection and Severity Assessment of Cercospora Leaf Spot (*Cercospora capsici*) in Chili Peppers Under Natural Conditions. *Plants*, *14*(13). <https://doi.org/10.3390/plants14132011>
- Liu, J., & Wang, X. (2021). Plant diseases and pests detection based on deep learning: a review. In *Plant Methods* (Vol. 17, Number 1). BioMed Central Ltd. <https://doi.org/10.1186/s13007-021-00722-9>
- Lu, J., Tan, L., & Jiang, H. (2021). Review on convolutional neural network (CNN) applied to plant leaf disease classification. In *Agriculture (Switzerland)* (Vol. 11, Number 8). MDPI AG. <https://doi.org/10.3390/agriculture11080707>
- Ms. Lolakshi P. K., Ananya H S, Prathiksha L Shetty, Prakyath S Shetty, & Vibha M. (2023). Plant Leaf Disease Detection using KNN Algorithm. *International Journal of Advanced Research in Science, Communication and Technology*, 21–25. <https://doi.org/10.48175/ijarsct-7828>
- Odounfa, M. G. F., Hounmenou, C. G., Salako, V. K., Affokpon, A., & Kakai, R. L. G. (2025). Deep learning enables precision agriculture for sustainable chili pepper disease detection in Benin. *Discover Artificial Intelligence*, *5*(1). <https://doi.org/10.1007/s44163-025-00583-4>
- Ozturk, A. I., & Yildirim, O. (2025). A comparative analysis of HOG and LBP feature extraction techniques in AdaBoost for image recognition. *International Journal of Innovative Research and Scientific Studies*, *8*(2), 696–703. <https://doi.org/10.53894/ijirss.v8i2.5290>
- Pacal, I., Kunduracioglu, I., Alma, M. H., Deveci, M., Kadry, S., Nedoma, J., Slany, V., & Martinek, R. (2024). A systematic review of deep learning techniques for plant diseases. *Artificial Intelligence Review*, *57*(11). <https://doi.org/10.1007/s10462-024-10944-7>



- Pandian, J. A., Kanchanadevi, K., Kumar, V. D., Jasińska, E., Goño, R., Leonowicz, Z., & Jasiński, M. (2022). A Five Convolutional Layer Deep Convolutional Neural Network for Plant Leaf Disease Detection. *Electronics (Switzerland)*, 11(8). <https://doi.org/10.3390/electronics11081266>
- Pandian, J. A., Kumar, V. D., Geman, O., Hnatiuc, M., Arif, M., & Kanchanadevi, K. (2022). Plant Disease Detection Using Deep Convolutional Neural Network. *Applied Sciences (Switzerland)*, 12(14). <https://doi.org/10.3390/app12146982>
- Rahman, A., Subekti, S., & Rokhani. (2021). Adaptation of cayenne pepper farmers (*Capsicum frutescens* L.) on climate change in Jelbuk Subdistrict Jember. *IOP Conference Series: Earth and Environmental Science*, 892(1). <https://doi.org/10.1088/1755-1315/892/1/012037>
- Rainio, O., Teuho, J., & Klén, R. (2024). Evaluation metrics and statistical tests for machine learning. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-56706-x>
- Sundari, M. T., Darsono, Sutrisno, J., & Antriyandarti, E. (2021). Analysis of chili farming in Indonesia. *IOP Conference Series: Earth and Environmental Science*, 905(1). <https://doi.org/10.1088/1755-1315/905/1/012046>
- Zahirah, D., Purnawansyah, P., Kurniati, N., & Darwis, H. (2024). Digital Image Classification Of Herbal Leaves Using Knn And Cnn With Glcm Features. *Jurnal Teknik Informatika (Jutif)*, 5(1), 61–67. <https://doi.org/10.52436/1.jutif.2024.5.1.1162>