

Optimalisasi Model *Convolutional Neural Network* dengan Arsitektur MobileNetV2 Pada Sistem Otomatis Deteksi Penyakit Tanaman Jagung Berdasarkan Citra Daun

Tsaura Halwa Qur'ani¹, Saeful Bahri², Gunawan³

^{1,2,3}Universitas Bina Sarana Informatika

Jl. Kramat Raya No.98, RT.2/RW.9, Kwitang, Kec. Senen, Kota Jakarta Pusat, Daerah Khusus Ibukota Jakarta

e-mail: ¹tsaurahalwa@gmail.com, ²saeful.sel@bsi.ac.id, ³gunawan.gnz@bsi.ac.id

Artikel Info : Diterima : 16-09-2025 | Direvisi : 01-10-2025 | Disetujui : 01-12-2025

Abstrak - Jagung (*Zea mays L.*) merupakan salah satu komoditas pangan utama di Indonesia yang rentan terhadap serangan penyakit daun seperti hawar dan karat. Deteksi penyakit secara manual membutuhkan waktu lama dan berpotensi menimbulkan kesalahan, sehingga diperlukan sistem otomatis berbasis citra digital. Metode *Convolutional Neural Network* (CNN) telah banyak digunakan untuk klasifikasi penyakit daun, namun masih memiliki keterbatasan dalam kebutuhan komputasi dan generalisasi pada perangkat dengan sumber daya terbatas. Untuk mengatasi hal tersebut, penelitian ini mengoptimalkan model CNN dengan memanfaatkan arsitektur MobileNetV2 berbasis transfer *learning*, yang dirancang lebih ringan dan efisien. Dataset yang digunakan berupa citra primer daun jagung dengan latar belakang putih, berjumlah 600 gambar yang terbagi ke dalam tiga kelas: hawar, karat, dan sehat. Proses pelatihan dilakukan dengan *ImageDataGenerator* untuk normalisasi, augmentasi, serta pembagian data latih dan validasi. Evaluasi model menggunakan metrik akurasi, presisi, *recall*, *F1-score*, dan *confusion matrix*. Hasil penelitian menunjukkan bahwa CNN mencapai akurasi 91%, sedangkan MobileNetV2 unggul dengan akurasi 95% serta distribusi prediksi yang lebih seimbang antar kelas. Temuan ini menunjukkan bahwa MobileNetV2 mampu memberikan kinerja lebih baik dibanding CNN standar. Kontribusi penelitian ini tidak hanya memperkuat literatur tentang penerapan MobileNetV2 dalam klasifikasi citra pertanian, tetapi juga memberikan solusi praktis untuk deteksi penyakit jagung secara cepat, akurat, dan dapat diimplementasikan pada perangkat dengan keterbatasan komputasi.

Kata Kunci : CNN, Daun Jagung, Klasifikasi, MobileNetV2, *Transfer Learning*

Abstracts - Maize (*Zea mays L.*) is one of the main food commodities in Indonesia that is vulnerable to leaf diseases such as blight and rust. Manual detection requires a long time and is prone to errors, thus necessitating an automatic system based on digital images. The *Convolutional Neural Network* (CNN) method has been widely applied for leaf disease classification; however, it still faces limitations in terms of computational requirements and generalization on resource-constrained devices. To address this issue, this study optimizes the CNN model by employing the MobileNetV2 architecture with transfer learning, which is designed to be lighter and more efficient. The dataset used consists of primary maize leaf images with a white background, totaling 600 images divided into three classes: blight, rust, and healthy. The training process was conducted using *ImageDataGenerator* for normalization, augmentation, and splitting into training and validation sets. Model evaluation employed accuracy, precision, recall, *F1-score*, and *confusion matrix* metrics. The results show that CNN achieved an accuracy of 91%, while MobileNetV2 outperformed with an accuracy of 95% and a more balanced prediction distribution across classes. These findings indicate that MobileNetV2 provides better performance than standard CNN. The contribution of this research not only strengthens the literature on the application of MobileNetV2 in agricultural image classification but also offers a practical solution for maize disease detection that is fast, accurate, and feasible to implement on devices with limited computational resources.

Keywords : CNN, MobileNetV2, Classification, Maize Leaf, *Transfer Learning*

PENDAHULUAN

Jagung (*Zea mays L.*) merupakan salah satu tanaman pangan utama di Indonesia yang menempati posisi strategis setelah padi, baik dalam konteks ketahanan pangan nasional maupun kontribusinya terhadap sektor ekonomi (Iswantoro & Handayani UN, 2022; Lesmana Hermawan, 2023). Namun demikian, daun jagung sangat rentan terhadap berbagai jenis penyakit, seperti hawar dan karat daun, yang dapat menyebabkan penurunan hasil



panen secara signifikan. Penyakit pada daun umumnya ditandai dengan perubahan warna, bentuk, serta tekstur daun, dan umumnya disebabkan oleh organisme patogen seperti jamur, virus, dan bakteri (Kusumastuti et al., 2024; Setyawan et al., 2022). Secara tradisional, proses identifikasi penyakit daun jagung masih dilakukan secara manual, yang memerlukan waktu cukup lama dan berisiko terhadap kesalahan manusia (Rosadi et al., 2021). Oleh karena itu, diperlukan sistem pengenalan otomatis yang cepat dan akurat untuk mendukung pengambilan keputusan di bidang pertanian (Yusuf et al., 2024).

Salah satu metode yang banyak digunakan dalam klasifikasi berbasis citra adalah *Convolutional Neural Network* (CNN), yang mampu mengenali pola dalam gambar tanpa memerlukan proses ekstraksi fitur secara manual, sehingga mempercepat alur pemrosesan data (Alfarizki et al., 2024). Penelitian sebelumnya, seperti yang dilakukan oleh (Firmansyah & Nafi'iyah, 2024), menunjukkan bahwa CNN mampu mencapai akurasi klasifikasi hingga 84,5% pada dataset penyakit daun jagung.

Meskipun memiliki keunggulan, model CNN ini membutuhkan sumber daya komputasi yang tinggi, waktu pelatihan yang lama, serta cenderung sulit melakukan generalisasi pada data baru. Hal ini menjadi kendala jika diterapkan dengan keterbatasan sumber daya, seperti *smartphone* atau *embedded systems*. Kesenjangan penelitian ini menunjukkan perlunya pendekatan baru yang lebih ringan namun tetap akurat dalam klasifikasi penyakit daun jagung.

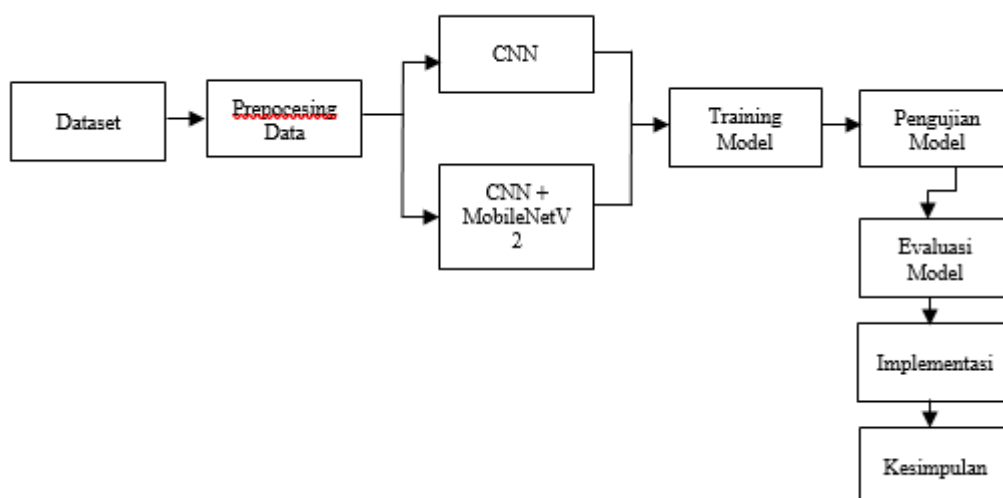
Arsitektur ringan seperti dikembangkan untuk menjawab kebutuhan tersebut. MobileNetV2 merupakan arsitektur CNN yang efisien dan ringan, dirancang khusus untuk perangkat dengan kemampuan komputasi terbatas seperti *smartphone* (Arnandito & Sasongko, 2024; Gulzar, 2023). Efisiensi arsitektur ini berasal dari penggunaan teknik seperti *depthwise separable convolution*, yang menjadikannya cocok untuk sistem tertanam (*embedded systems*) dan aplikasi waktu nyata (*real-time*). Dalam bidang pertanian, MobileNetV2 telah terbukti mampu memproses data secara efisien tanpa mengorbankan akurasi klasifikasi, sehingga ideal untuk sistem deteksi penyakit tanaman berbasis citra digital yang dijalankan pada perangkat dengan sumber daya terbatas (Zheng et al., 2022).

Penelitian ini memberikan dua kontribusi utama. Dari sisi teoretis, penelitian ini memperkuat literatur mengenai penerapan *transfer learning MobileNetV2* dalam klasifikasi citra penyakit tanaman, khususnya daun jagung. Dari sisi praktis, penelitian ini menawarkan solusi yang dapat membantu petani dalam mendeteksi penyakit daun jagung secara cepat, akurat, dan efisien, serta memungkinkan implementasi pada perangkat dengan keterbatasan komputasi.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengoptimalkan model berbasis CNN dengan memanfaatkan arsitektur MobileNetV2 guna meningkatkan kinerja dan efisiensi sistem deteksi otomatis penyakit daun jagung.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimental untuk membangun dan mengevaluasi sistem klasifikasi penyakit daun jagung menggunakan dua model CNN dan CNN berbasis *transfer learning* MobileNetV2. Tahapan metodologi dijelaskan sebagai berikut.



Sumber: Hasil Penelitian (2025)

Gambar 1. Metode Penelitian

1. Pengumpulan Dataset

Citra daun jagung dikumpulkan pada 27 April 2025 di Kampung Sukaresmi menggunakan kamera Vivo V2109. Gambar diambil pada siang hari dengan pencahayaan alami, menggunakan latar belakang kertas putih dan jarak pengambilan sekitar 30 cm. Setiap daun difoto dari beberapa sudut untuk meningkatkan variasi visual. Total dataset terdiri dari 600 citra yang terbagi merata ke dalam tiga kelas utama: hawar daun, karat daun, dan daun sehat. Seluruh citra disimpan di *Google Drive* dan diakses melalui *Google Colab* dengan struktur folder yang disesuaikan berdasarkan label kelas.

2. Pra-pemrosesan Data

Tahap pra-pemrosesan dilakukan untuk menyiapkan citra agar sesuai dengan kebutuhan *input* model dan memastikan efisiensi pelatihan. Adapun tahapan pra-pemrosesan yang diterapkan adalah sebagai berikut:

a. Ubah Ukuran Gambar (Image Resize)

Seluruh citra asli yang memiliki resolusi tinggi (3060×4080 piksel) diubah ukurannya menjadi 224×224 piksel untuk model CNN dan MobileNetV2. Ukuran ini sesuai dengan spesifikasi *input* MobileNetV2 (yang telah dilatih sebelumnya pada ImageNet), dan menjaga konsistensi *input* antar model. Proses ini tetap mempertahankan proporsi informasi spasial penting dari daun sambil mengurangi beban komputasi.

b. Normalisasi Piksel (*Pixel Normalization*)

Setelah gambar di *resize*, nilai piksel pada tiap *channel* RGB (*Red Green Blue*) dinormalisasi dari skala 0–255 menjadi 0–1 dengan membagi setiap nilai piksel dengan 255. Normalisasi ini membantu menstabilkan proses pembelajaran dan mempercepat konvergensi model, sehingga model lebih efektif dalam membedakan fitur visual.

c. Pembagian Data

Dataset sebanyak 600 citra dibagi secara otomatis menggunakan parameter *validation_split=0.2* dari fungsi *ImageDataGenerator* di *TensorFlow*, sehingga 80% digunakan sebagai data latih (480 citra) dan 20% sebagai data validasi (120 citra). Pembagian ini memungkinkan evaluasi performa model terhadap data yang tidak dilatih.

d. Augmentasi Data (*Data Augmentation*)

Untuk meningkatkan ketahanan model dan mencegah *overfitting*, beberapa teknik augmentasi diterapkan secara *real-time* pada data latih, yaitu:

- 1) Rotasi acak antara -30° hingga $+30^\circ$ untuk mengenalkan variasi orientasi objek
- 2) *Zoom* acak hingga $\pm 20\%$ untuk meniru skenario perubahan skala dan efek *cropping*.
- 3) *Flipping* horizontal untuk menambah kemampuan model dalam mengenali citra dengan orientasi kiri/kanan terbalik.

e. *One-Hot Encoding*

Label kelas (hawar, karat, sehat) dikonversi secara otomatis ke dalam format vektor biner (*one-hot encoding*), misalnya: hawar = [1,0,0], karat = [0,1,0], sehat = [0,0,1]. Format ini digunakan untuk mencocokkan *output* fungsi aktivasi *softmax* dan fungsi *loss categorical crossentropy* dalam klasifikasi multi-kelas.

f. Pengacakan (*Shuffling*)

Data diacak selama proses pelatihan (*shuffle=True*) untuk mencegah model mempelajari pola urutan data. Sebaliknya, data validasi tidak diacak (*shuffle=False*) agar evaluasi model tetap konsisten dan dapat direproduksi.

g. *Batching*

Data diproses dalam kelompok (*batch*) berukuran 32 citra per iterasi pelatihan (*batch_size=32*) untuk mengoptimalkan penggunaan memori dan efisiensi komputasi selama proses *training*.

3. Arsitektur Model

a. CNN di bangun secara *custom* terdiri dari dua Conv2D + ReLU, dua MaxPooling2D, *Flatten*, satu *Dense* (128 neuron), dan *output layer softmax* (3 neuron).

b. *MobileNetV2* menggunakan *pretrained weights* dari *ImageNet*. Lapisan dasar dibekukan. Ditambahkan *GlobalAveragePooling2D* dan *Dense* (3 neuron *softmax*) sebagai *classifier*.

4. Pelatihan Model

Kedua model dilatih selama 50 *epoch* dengan *batch size* 32 menggunakan fungsi aktivasi ReLU (hidden) dan *softmax* (*output*), optimasi Adam, dan *loss function categorical crossentropy*. Augmentasi data diterapkan secara *real-time*. Seluruh proses pelatihan dilakukan di *Google Colab* dengan dukungan GPU (*Graphics Processing Unit*).

5. Evaluasi Model


Evaluasi dilakukan terhadap data validasi menggunakan metrik: akurasi, presisi, *recall*, *F1-score*, dan *confusion matrix*. Perhitungan metrik dilakukan otomatis menggunakan *classification_report* dan *confusion_matrix* dari pustaka *sklearn*. Evaluasi dilakukan untuk masing-masing kelas: hawar, karat, dan sehat. Hasil evaluasi ditampilkan dalam bentuk tabel dan *heatmap* untuk analisis performa klasifikasi.

HASIL DAN PEMBAHASAN

Bab ini memaparkan hasil penelitian dan pengujian dua model klasifikasi citra daun jagung, yaitu CNN dan MobileNetV2. Pembahasan mencakup visualisasi grafik akurasi dan *loss*, analisis *confusion matrix*, serta perbandingan kinerja kedua model berdasarkan metrik evaluasi seperti *precision*, *recall*, dan *F1-score*.

1. Hasil Penelitian


A. Grafik Akurasi dan Loss CNN



Sumber: Hasil Penelitian (2025)

Gambar 2. Grafik Akurasi CNN

Model CNN menunjukkan peningkatan akurasi pelatihan yang signifikan dan mencapai lebih dari 90% setelah sekitar 25 *epoch*. Namun, akurasi validasi terlihat tidak stabil dan lebih rendah, yang mengindikasikan gejala *overfitting*. Sementara itu, nilai *loss* pelatihan terus menurun, tetapi *loss* validasi mengalami fluktuasi, memperkuat dugaan bahwa model kesulitan melakukan generalisasi terhadap data baru.




Sumber: Hasil Penelitian (2025)

Gambar 1. Grafik Akurasi MobileNetV2

Loss pada data pelatihan menurun secara konsisten, menandakan bahwa model berhasil meminimalkan kesalahan pada data yang dilatih. Namun, *loss* pada data validasi bersifat fluktuatif dan cenderung tetap tinggi, menunjukkan ketidakmampuan model dalam mempertahankan performa saat diuji dengan data baru. Pola ini memperkuat indikasi terjadinya *overfitting* pada model CNN.

B. Grafik Akurasi dan Loss MobileNetV2




Sumber: Hasil Penelitian (2025)

Gambar 2. Grafik Akurasi MobileNetV2

Model *MobileNetV2* menunjukkan akurasi pelatihan dan validasi yang tinggi dan stabil sejak awal,

dengan rata-rata di atas 90%. Perbedaan akurasi antar data pelatihan dan validasi relatif kecil, menandakan kemampuan generalisasi yang baik tanpa *overfitting*. Hal ini mencerminkan efisiensi pembelajaran dari pendekatan transfer *learning* yang digunakan.



Sumber: Hasil Penelitian (2025)

Gambar 3. Grafik Loss MobileNetV2

Loss pelatihan pada MobileNetV2 menurun secara stabil, menunjukkan proses pembelajaran yang efektif. Sementara itu, *loss* validasi mengalami sedikit kenaikan bertahap mulai pertengahan *epoch*, namun tetap dalam batas wajar. Hal ini mengindikasikan *overfitting* ringan, tetapi secara keseluruhan performa model tetap konsisten dan akurat.

2. Hasil Pengujian

Evaluasi kedua model menggunakan data validasi dilakukan dengan metrik akurasi, presisi, *recall*, *F1-score*, dan *confusion matrix* untuk klasifikasi tiga kelas daun jagung.


A. Hasil Grafik Perbandingan Kedua Model



Sumber: Hasil Penelitian (2025)

Gambar 4. Perbandingan Akurasi Kedua Model

Gambar 4.7 memperlihatkan perbandingan akurasi pelatihan dan validasi antara model CNN dan *MobileNetV2*. Model CNN menunjukkan peningkatan akurasi pelatihan, namun akurasi validasinya fluktuatif dan tertinggal, mengindikasikan *overfitting*. Sebaliknya, *MobileNetV2* tampil stabil dengan akurasi pelatihan dan validasi di atas 90% serta gap yang kecil, mencerminkan kemampuan generalisasi yang baik.

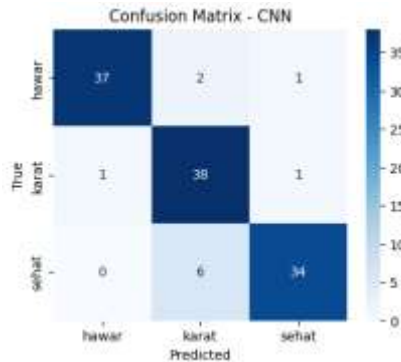


Sumber: Hasil Penelitian (2025)

Gambar 5. Perbandingan Loss Kedua Model

Grafik perbandingan *loss* menunjukkan bahwa model CNN mengalami penurunan *loss* pelatihan secara konsisten, namun *loss* validasinya fluktuatif dan tetap tinggi, mengindikasikan *overfitting*. Sebaliknya, *MobileNetV2* menghasilkan *loss* pelatihan dan validasi yang lebih rendah dan stabil. Kenaikan ringan pada *loss* validasi di akhir pelatihan masih dalam batas wajar, menandakan performa yang lebih efisien dan stabil dibandingkan CNN.

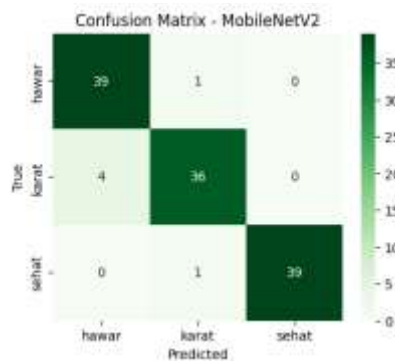
B. Hasil Confusion Matrix



Sumber: Hasil Penelitian (2025)

Gambar 6. Confusion Matrix CNN

Confusion matrix model CNN menunjukkan bahwa kelas hawar diklasifikasikan dengan baik (37/40 benar), meskipun terdapat sedikit kesalahan ke kelas karat dan sehat. Kelas karat juga tampil kuat dengan 38/40 prediksi benar. Namun, kelas sehat hanya 34 dari 40 yang diklasifikasikan dengan benar, dan 6 sisanya keliru sebagai karat. Hal ini menunjukkan bahwa model CNN mengalami kesulitan membedakan fitur visual antara kelas sehat dan karat.



Sumber: Hasil Penelitian (2025)

Gambar 7. Confusion Matrix MobileNetV2

Confusion matrix model MobileNetV2 menunjukkan hasil klasifikasi yang sangat baik. Kelas hawar dan sehat masing-masing memiliki 39 prediksi benar dari 40 data, dengan hanya 1 kesalahan ke kelas karat. Kelas karat menunjukkan 36 prediksi benar dan 4 kesalahan ke kelas hawar. Secara keseluruhan, jumlah kesalahan lebih sedikit dibandingkan model CNN, menandakan kemampuan MobileNetV2 yang lebih akurat dalam mengenali fitur visual antar kelas.

C. Classification Report

- 1) Hasil Model CNN

CNN Classification Report:				
	precision	recall	f1-score	support
hawar	0.97	0.93	0.95	40
karat	0.83	0.95	0.88	40
sehat	0.94	0.85	0.89	40
accuracy			0.91	120
macro avg	0.91	0.91	0.91	120
weighted avg	0.91	0.91	0.91	120

Sumber: Hasil Penelitian (2025)

Gambar 8. *Classification Report CNN*

Berdasarkan tabel *Classification Report* model CNN, diperoleh nilai akurasi keseluruhan sebesar 91%. Pada kelas hawar, model menunjukkan kinerja sangat baik dengan *precision* sebesar 0.97 dan *recall* sebesar 0.93, menghasilkan *f1-score* sebesar 0.95. Untuk kelas karat, nilai *recall* cukup tinggi sebesar 0.95, namun *precision* nya lebih rendah hanya 0.83, sehingga menghasilkan *f1-score* sebesar 0.88. Hal ini menunjukkan bahwa model cenderung melakukan over-prediksi terhadap kelas karat. Pada kelas sehat, nilai *precision* cukup tinggi dengan nilai 0.94 namun *recall* nya sedikit lebih rendah 0.85 sehingga *f1-score*nya menjadi 0.89

Secara umum, nilai rata-rata makro dan rata-rata berbobot pada semua metrik berada pada angka 0.91, yang menunjukkan bahwa model CNN memiliki performa yang baik dalam klasifikasi multi-kelas, namun masih terdapat ketidakseimbangan performa antar kelas.

2) Hasil Model MobileNetV2

MobileNetV2 Classification Report:				
	precision	recall	f1-score	support
hawar	0.91	0.97	0.94	40
karat	0.95	0.90	0.92	40
sehat	1.00	0.97	0.99	40
accuracy			0.95	120
macro avg	0.95	0.95	0.95	120
weighted avg	0.95	0.95	0.95	120

Sumber: Hasil Penelitian (2025)

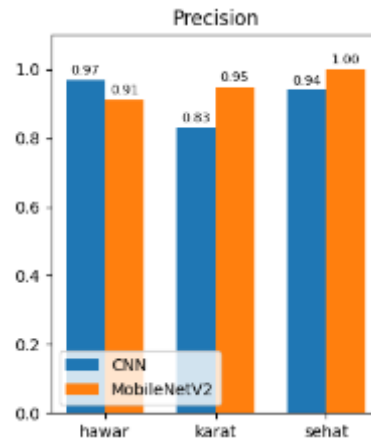
Gambar 9. *Classification Report MobileNetV2*

Sementara itu, model MobileNetV2 menunjukkan performa yang lebih unggul dengan akurasi keseluruhan sebesar 95%. Kelas hawar memiliki *precision* sebesar 0.91 dan *recall* sebesar 0.97 dengan *f1-score* sebesar 0.94. Kelas karat memiliki nilai *precision* 0.95 dan *recall* 0.90 dengan *f1-score* sebesar 0.92. Performa terbaik dicapai pada kelas sehat, di mana *precision* mencapai 1.00 *recall* sebesar 0.97, dengan *f1-score* mendekati sempurna sebesar 0.99.

Rata-rata makro dan berbobot dari *precision*, *recall*, dan *f1-score* seluruhnya adalah 0.95, menunjukkan bahwa MobileNetV2 mampu menjaga kestabilan performa klasifikasi di seluruh kelas. Hal ini juga mengindikasikan bahwa pendekatan transfer *learning* yang diterapkan pada MobileNetV2 memberikan keuntungan signifikan dalam mengenali fitur visual pada citra daun jagung, dibandingkan dengan model CNN.

D. Hasil Evaluasi

1. Precision

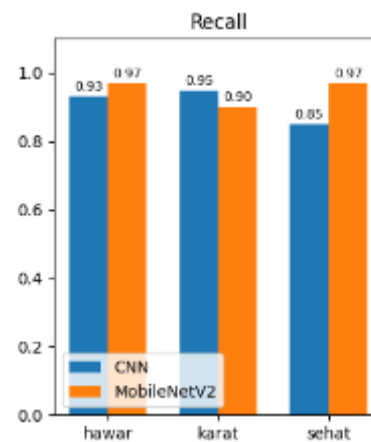


Sumber: Hasil Penelitian (2025)

Gambar 10. Grafik Perbandingan *Precision*

Nilai *precision* antara model CNN dan MobileNetV2 pada setiap kelas. *Precision* mengindikasikan seberapa tepat model dalam mengidentifikasi prediksi positif. Pada kelas *hawar*, model CNN memperoleh nilai *precision* yang lebih tinggi dibandingkan MobileNetV2, menandakan akurasi prediksi yang lebih baik untuk kelas tersebut. Namun, pada kelas *karat* dan *sehat*, MobileNetV2 menunjukkan *precision* yang lebih tinggi. Secara umum, MobileNetV2 memberikan performa *precision* yang lebih merata di seluruh kelas, sedangkan CNN menunjukkan ketidak konsistenan antar kelas.

2. *Recall*




Sumber: Hasil Penelitian (2025)

Gambar 11. Grafik Perbandingan *Recall*

Recall digunakan untuk mengukur kemampuan model dalam mengidentifikasi seluruh *instance* positif dari suatu kelas. Pada kelas *hawar* dan *sehat*, MobileNetV2 menghasilkan nilai *recall* yang lebih tinggi, yang menunjukkan sensitivitas model yang lebih baik dalam mendeteksi kedua kelas tersebut. Sebaliknya, pada kelas *karat*, CNN memiliki keunggulan *recall* yang sedikit lebih tinggi. Secara keseluruhan, MobileNetV2 menunjukkan kecenderungan nilai *recall* yang lebih stabil pada seluruh kelas.

3. *F1-Score*



Sumber: Hasil Penelitian (2025)

Gambar 12. Grafik Perbandingan F1-score

F1-score memberikan evaluasi yang seimbang antara ketepatan dan sensitivitas prediksi model. Pada kelas *karat* dan *sehat*, *MobileNetV2* mencatatkan *F1-score* yang lebih tinggi dibandingkan *CNN*, khususnya pada kelas *sehat* dengan nilai yang hampir mendekati sempurna. Untuk kelas *hawar*, kedua model menunjukkan performa yang sebanding. Temuan ini mengindikasikan bahwa *MobileNetV2* memiliki keunggulan dalam hal konsistensi dan stabilitas performa klasifikasi citra daun jagung dibandingkan model *CNN*.

KESIMPULAN

Berdasarkan hasil penelitian mengenai optimalisasi model *CNN* menggunakan arsitektur *MobileNetV2* untuk klasifikasi penyakit daun jagung, diperoleh beberapa kesimpulan:

1. Model *CNN* menghasilkan akurasi sebesar 91% dengan performa baik terutama pada kelas *hawar*, namun terdapat ketidakseimbangan pada kelas *sehat* dan *karat*.
2. Penggunaan arsitektur *MobileNetV2* melalui transfer *learning* meningkatkan akurasi menjadi 95%, dengan metrik evaluasi yang lebih stabil dan merata pada ketiga kelas.
3. *MobileNetV2* terbukti lebih efisien secara komputasi dan minim *overfitting*, menunjukkan performa yang lebih konsisten pada data pelatihan dan validasi.
4. Implementasi ke dalam aplikasi web memungkinkan prediksi citra daun jagung secara *real-time* serta penyediaan rekomendasi perawatan sesuai hasil klasifikasi.

REFERENSI

- Alfarizki, M. R., Adi Prayoga, D., & Dwi Cahyono, A. (2024). KLASIFIKASI KUALITAS DAUN SEHAT DAN TIDAK SEHAT PADA TANAMAN JAGUNG DENGAN MENGGUNAKAN METODE MORFOLOGI GRADIEN DI PYTHON. *Jurnal Sistem Informasi Aplikasi Teknologi Informasi*, 1(2). <https://doi.org/10.53567/josiati.v1i2.15>
- Arnandito, S., & Sasongko, T. B. (2024). Comparison of EfficientNetB7 and MobileNetV2 in Herbal Plant Species Classification Using Convolutional Neural Networks. In *Journal of Applied Informatics and Computing (JAIC)* (Vol. 8, Issue 1). <http://jurnal.polibatam.ac.id/index.php/JAIC>
- Firmansyah, R., & Nafi'iyah, N. (2024). Identifying Types of Corn Leaf Diseases with Deep Learning. *Journal of Intelligent System and Computation*, 6(1), 18–23. <https://doi.org/10.52985/insyst.v6i1.347>
- Gulzar, Y. (2023). Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique. *Sustainability (Switzerland)*, 15(3). <https://doi.org/10.3390/su15031906>
- Iswantoro, D., & Handayani UN, D. (2022). Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Ilmiah Universitas Batanghari Jambi*, 22(2), 900. <https://doi.org/10.33087/jjubj.v22i2.2065>
- Kusumastuti, R., Dwi Putra, T., Zulfahmi Yudam Klasifikasi Citra Penyakit Daun Jagung Menggunakan Algoritma CNN EfficientNet, Z., Zulfahmi Yudam, Z., AMIKOM Surakarta, S., & Jawa Tengah, S. (2024). KLASIFIKASI CITRA PENYAKIT DAUN JAGUNG MENGGUNAKAN ALGORITMA CNN EFFICIENTNET. *Multitek Indonesia: Jurnal Ilmiah*, 2, 1907–6223. <http://journal.umpo.ac.id/index.php/multitek>

- Lesmana Hermawan, A. (2023). Klasifikasi Penyakit Daun Jagung Menggunakan Lightweight Convolutional Neural Network. *JIFKOM (Jurnal Ilmiah Informatika & Komputer) STTR Cebu*.
- Rosadi, M. I., Lutfi, M., & Artikel, S. (2021). Identifikasi Jenis Penyakit Daun Jagung Menggunakan Deep Learning Pre-Trained Model INFO ARTIKEL ABSTRAK. *JURNAL KEILMUAN DAN APLIKASI TEKNIK INFORMATIKA*. <https://doi.org/10.35891/explorit>
- Setyawan, M. A., Kasih, P., Ayu, M., & Widyadara, D. (2022). *Klasifikasi Penyakit Daun Jagung Berdasarkan Ruang Warna HSV dan Fitur Tekstur Dengan Algoritma K-NN*.
- Yusuf, M., Kurniawan, D., & Agustin, T. (2024). KLASIFIKASI PENYAKIT TANAMAN JAGUNG DENGAN KECERDASAN BUATAN BERBASIS CNN. *SEMINAR NASIONAL AMIKOM SURAKARTA (SEMNAS) 2024*.
- Zheng, M., You, S., Huang, L., Wang, F., Qian, C., & Xu, C. (2022). *SimMatch: Semi-supervised Learning with Similarity Matching*.