

KLASIFIKASI PENYAKIT DAN KONDISI KESEHATAN TANAMAN CABAI BERBASIS DEEP LEARNING SEBAGAI PENDUKUNG SMART NURSERY PERTANIAN BERKELANJUTAN

¹⁾Titan Attariq Al Fatah, ²⁾Muhamad Fuat Asnawi, ³⁾Restu Rahma Riandhita, ⁴⁾Panggah Dwi Santoso, ⁵⁾Zayyana Maulida, ⁶⁾Riskha Suheila Kirmalani, ⁷⁾Nurrohmat Furkon, ⁸⁾Ahmad Latif Hendrawan, ⁹⁾Aurielia Chandra Febrina, ¹⁰⁾Gennaro Wibisana, ¹¹⁾Febri Dwi Saputra, ¹²⁾Rafif Phalosa, ¹³⁾Muhammad Irvan Asy'ari, ¹⁴⁾Syahrul Maulana Rozaki, ¹⁵⁾Dzidni Imron Fadhilah, ¹⁶⁾Muhammad Nabil Al Faqih.

1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16) Fakultas Teknik dan Ilmu Komputer, Universitas Sains Al-Qur'an
¹⁾ titanattariq09@gmail.com, ²⁾ fuatasnawi@unsiq.ac.id

INFO ARTIKEL

Riwayat Artikel :

Diterima : 2 Agustus 2026

Disetujui : 31 Agustus 2026

Kata Kunci :

deep learning, klasifikasi tanaman, cabai, MobileNetV3Small, smart nursery.

ABSTRAK

Tanaman cabai (*Capsicum annuum L.*) merupakan komoditas hortikultura bernilai ekonomi tinggi yang memerlukan pemantauan kesehatan tanaman secara cepat dan akurat sejak tahap pembibitan. Proses identifikasi penyakit dan kondisi tanaman yang masih dilakukan secara manual memiliki keterbatasan karena bergantung pada pengalaman petani dan berpotensi menyebabkan keterlambatan pengendalian. Penelitian ini bertujuan mengembangkan model klasifikasi kondisi kesehatan tanaman cabai berbasis *deep learning* sebagai pendukung sistem *smart nursery* pertanian berkelanjutan. Metode penelitian dilakukan melalui tahapan pengumpulan dataset citra daun cabai, *preprocessing*, augmentasi data, pembangunan model, pelatihan, pengujian, dan evaluasi performa. Dataset terdiri dari lima kategori kondisi tanaman, yaitu *healthy*, *leaf curl*, *leaf spot*, *whitefly*, dan *yellowish*, dengan total 500 citra yang dibagi menjadi data pelatihan, validasi, dan pengujian. Tiga model dibandingkan, yaitu Convolutional Neural Network (CNN), MobileNetV3Small, dan EfficientNet-B0 menggunakan parameter evaluasi *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil penelitian menunjukkan bahwa MobileNetV3Small memberikan performa terbaik dengan akurasi 88%, *precision* 0,91, *recall* 0,88, dan *F1-score* 0,88, serta memiliki jumlah parameter paling rendah dibandingkan model lainnya. Model tersebut berpotensi diterapkan pada sistem *smart nursery* berbasis kamera dan perangkat komputasi terbatas untuk mendukung deteksi dini kesehatan bibit cabai secara cepat, objektif, dan berkelanjutan.

ARTICLE INFO

Article History :

Received : Aug 2, 2026

Accepted : Aug 31, 2026

Keywords:

deep learning, plant classification, chili plant, MobileNetV3Small, smart nursery.

ABSTRACT

Chili (*Capsicum annuum L.*) is a high-value horticultural crop that requires rapid and accurate plant health monitoring, particularly during the nursery stage. Conventional identification of plant diseases and health conditions relies heavily on farmers' visual observations, which are subjective and may delay disease control. This study aims to develop a deep learning-based classification model for chili plant health conditions to support sustainable smart nursery systems. The research was conducted through several stages, including image dataset collection, preprocessing, data augmentation, model

development, training, testing, and performance evaluation. The dataset consisted of five chili plant condition classes: healthy, leaf curl, leaf spot, whitefly, and yellowish, containing 500 images divided into training, validation, and testing datasets. Three deep learning models were evaluated, namely Convolutional Neural Network (CNN), MobileNetV3Small, and EfficientNet-B0, using accuracy, precision, recall, and F1-score metrics. The experimental results showed that MobileNetV3Small achieved the best performance with an accuracy of 88%, precision of 0.91, recall of 0.88, and F1-score of 0.88, while also having the lowest number of parameters among the evaluated models. The proposed model demonstrates strong potential for integration into camera-based smart nursery systems with limited computational resources to enable rapid, objective, and sustainable early detection of chili seedling health conditions.

1. PENDAHULUAN

Tanaman cabai (*Capsicum annuum* L.) merupakan salah satu komoditas hortikultura penting yang memiliki nilai ekonomi tinggi serta banyak dibudidayakan oleh masyarakat Indonesia. Produktivitas tanaman cabai sangat dipengaruhi oleh kualitas bibit dan kemampuan petani dalam melakukan pemantauan kesehatan tanaman sejak fase awal pertumbuhan. Namun, proses identifikasi gangguan tanaman seperti perubahan warna daun, serangan hama, dan penyakit masih banyak dilakukan secara manual berdasarkan pengamatan visual petani. Metode tersebut memiliki keterbatasan karena membutuhkan pengalaman khusus, bersifat subjektif, serta berpotensi menyebabkan keterlambatan dalam pengendalian penyakit yang dapat menurunkan produktivitas tanaman (Gautam et al., 2022).

Penyakit dan gangguan kesehatan tanaman umumnya menunjukkan gejala awal pada perubahan karakteristik visual daun, seperti perubahan warna, pola bercak, deformasi permukaan, maupun perubahan struktur jaringan daun. Oleh karena itu, pendekatan berbasis citra digital menjadi salah satu solusi yang banyak dikembangkan untuk mendukung sistem pertanian presisi (*precision agriculture*). Teknologi pengolahan citra memungkinkan proses identifikasi kondisi tanaman dilakukan secara otomatis melalui ekstraksi fitur visual, sehingga dapat membantu petani melakukan tindakan pencegahan secara lebih cepat dan akurat (Tunio et al., 2024). Implementasi teknologi tersebut menjadi semakin relevan dalam konsep *smart nursery*, yaitu sistem pembibitan cerdas yang mengintegrasikan

teknologi digital untuk meningkatkan efisiensi produksi tanaman.

Perkembangan kecerdasan buatan (*Artificial Intelligence/AI*) khususnya *deep learning* telah memberikan kemajuan signifikan dalam bidang klasifikasi citra tanaman. Berbeda dengan metode konvensional yang memerlukan ekstraksi fitur secara manual, metode *Convolutional Neural Network* (CNN) mampu melakukan pembelajaran fitur secara otomatis melalui lapisan konvolusi sehingga efektif digunakan untuk mengenali pola kompleks pada citra daun tanaman. Berbagai penelitian menunjukkan bahwa pendekatan berbasis CNN mampu meningkatkan akurasi identifikasi penyakit tanaman dibandingkan metode berbasis fitur tradisional (Gautam et al., 2022; Ma et al., 2024).

Meskipun CNN memiliki kemampuan klasifikasi yang baik, penerapan model *deep learning* pada sistem pertanian nyata masih menghadapi beberapa tantangan, terutama terkait kebutuhan komputasi, jumlah dataset, dan efisiensi model. Untuk mengatasi keterbatasan tersebut, pendekatan *transfer learning* menggunakan model prelatih (*pre-trained model*) seperti MobileNet dan EfficientNet banyak digunakan karena mampu memanfaatkan fitur yang telah dipelajari dari dataset besar seperti ImageNet. MobileNetV3 dikembangkan dengan konsep arsitektur ringan yang memiliki efisiensi parameter tinggi sehingga sesuai untuk implementasi pada perangkat dengan sumber daya terbatas seperti perangkat IoT pertanian atau sistem monitoring lapangan (Mathew et al., 2025).

Selain MobileNetV3, EfficientNet merupakan salah satu arsitektur *deep learning* yang banyak digunakan karena menawarkan keseimbangan antara kompleksitas model dan akurasi melalui pendekatan *compound scaling*. Model ini mampu meningkatkan kemampuan ekstraksi fitur dengan jumlah parameter yang relatif efisien dibandingkan arsitektur CNN konvensional. Penelitian terkait klasifikasi penyakit tanaman menunjukkan bahwa model berbasis transfer learning dan arsitektur modern mampu menghasilkan performa tinggi dalam mengenali berbagai kelas penyakit berdasarkan citra tanaman (Khan et al., 2024; Ozturk et al., 2025).

Namun demikian, sebagian besar penelitian terdahulu masih berfokus pada klasifikasi penyakit tanaman tertentu, seperti tomat, teh, atau tanaman pangan lainnya, sedangkan penelitian yang mengintegrasikan klasifikasi kondisi kesehatan tanaman cabai dengan kebutuhan sistem *smart nursery* masih relatif terbatas. Selain itu, penelitian sebelumnya sering hanya mengevaluasi satu model sehingga belum memberikan gambaran mengenai keseimbangan antara akurasi dan efisiensi komputasi. Padahal, pada sistem pembibitan cerdas, model yang memiliki akurasi tinggi tetapi membutuhkan sumber daya komputasi besar belum tentu menjadi pilihan terbaik untuk implementasi lapangan (Mathew et al., 2025).


Berdasarkan permasalahan tersebut, penelitian ini mengembangkan sistem klasifikasi kondisi kesehatan tanaman cabai berbasis *deep learning* dengan membandingkan tiga pendekatan, yaitu CNN sebagai model dasar (*baseline*), MobileNetV3Small sebagai model ringan untuk mendukung implementasi *smart nursery*, serta EfficientNet-B0 sebagai model dengan kemampuan ekstraksi fitur yang lebih kompleks. Dataset yang digunakan terdiri dari lima kategori kondisi tanaman cabai, yaitu *healthy*, *leaf curl*, *leaf spot*, *whitefly*, dan *yellowish*. Perbandingan dilakukan berdasarkan parameter evaluasi seperti akurasi, *precision*, *recall*, dan *F1-score* untuk menentukan model paling optimal.

Kontribusi utama penelitian ini adalah menghasilkan model klasifikasi otomatis kondisi kesehatan tanaman cabai yang tidak hanya mempertimbangkan aspek akurasi, tetapi juga

efisiensi model untuk mendukung penerapan pertanian berkelanjutan. Model terbaik yang diperoleh diharapkan dapat menjadi komponen kecerdasan buatan dalam sistem *smart nursery* terintegrasi energi terbarukan, khususnya untuk membantu kelompok tani dalam melakukan monitoring awal kesehatan bibit cabai secara cepat, objektif, dan berkelanjutan.

2. METODE

Gambar 1 menunjukkan tahapan penelitian klasifikasi penyakit dan kondisi kesehatan tanaman cabai berbasis *deep learning* sebagai pendukung sistem *smart nursery* pertanian berkelanjutan.



Gambar 1. Alur Penelitian

Berdasarkan Gambar 1, penelitian ini dilakukan melalui enam tahapan utama, yaitu pengumpulan dataset, *preprocessing* dan augmentasi citra, pembangunan model *deep learning*, proses pelatihan dan pengujian model, evaluasi performa, serta analisis pemilihan model terbaik untuk implementasi pada sistem *smart nursery*. Pendekatan berbasis *deep learning* dipilih karena mampu melakukan ekstraksi fitur citra secara otomatis melalui proses pembelajaran berlapis sehingga efektif digunakan untuk mengenali pola visual penyakit tanaman (LeCun et al., 2015).

Tahap pertama adalah pengumpulan dataset citra daun tanaman cabai. Dataset yang digunakan terdiri dari lima kategori kondisi kesehatan tanaman, yaitu **healthy**, **leaf curl**, **leaf spot**, **whitefly**, dan **yellowish**. Dataset kemudian dibagi menjadi tiga bagian, yaitu data pelatihan

(*training set*) sebanyak 400 citra (80%), data validasi (*validation set*) sebanyak 50 citra (10%), dan data pengujian (*testing set*) sebanyak 50 citra (10%). Pembagian dataset tersebut bertujuan agar model mampu melakukan proses pembelajaran, optimasi parameter, serta pengujian terhadap data yang belum pernah digunakan selama proses pelatihan (Goodfellow et al., 2016).

Tahap kedua adalah proses *preprocessing* dan augmentasi citra. Seluruh citra dilakukan proses perubahan ukuran menjadi 224×224 piksel dan normalisasi nilai piksel sebelum digunakan sebagai masukan model. Selain itu, dilakukan augmentasi data pada dataset pelatihan berupa rotasi, pergeseran horizontal dan vertikal, *zoom*, *shear transformation*, serta *horizontal flip*. Teknik augmentasi digunakan untuk meningkatkan variasi data sehingga model memiliki kemampuan generalisasi lebih baik terhadap perubahan kondisi citra seperti posisi daun, pencahayaan, dan variasi bentuk tanaman (Shorten dan Khoshgoftaar, 2019).

Tahap ketiga adalah pembangunan tiga model klasifikasi berbasis *deep learning*, yaitu CNN, MobileNetV3Small, dan EfficientNet-B0. Model CNN digunakan sebagai model dasar (*baseline*) untuk mengetahui kemampuan klasifikasi menggunakan ekstraksi fitur konvensional berbasis lapisan konvolusi. CNN telah banyak digunakan dalam bidang pertanian karena mampu mengenali karakteristik visual seperti pola bercak, perubahan warna, dan struktur permukaan daun secara otomatis (Mohanty et al., 2016).

Selanjutnya, MobileNetV3Small dan EfficientNet-B0 digunakan sebagai pendekatan *transfer learning*. MobileNetV3Small dipilih karena memiliki arsitektur ringan dengan jumlah parameter lebih sedikit sehingga sesuai untuk implementasi pada perangkat dengan keterbatasan sumber daya seperti sistem IoT pertanian (*edge device*) (Howard et al., 2019). Sementara itu, EfficientNet-B0 digunakan karena mampu meningkatkan performa ekstraksi fitur melalui pendekatan *compound scaling* yang mengoptimalkan keseimbangan antara kedalaman jaringan, ukuran model, dan akurasi klasifikasi (Tan dan Le, 2019).

Tahap keempat adalah proses pelatihan dan pengujian model. Ketiga model dilatih

menggunakan konfigurasi parameter yang sama untuk menjaga objektivitas perbandingan. Parameter pelatihan yang digunakan yaitu optimizer Adam, *learning rate* 0,0001, fungsi kehilangan (*loss function*) categorical cross entropy, ukuran *batch* 16, dan jumlah epoch sebanyak 50. Setelah proses pelatihan selesai, setiap model diuji menggunakan dataset pengujian untuk memperoleh nilai performa klasifikasi.

Tahap terakhir adalah evaluasi dan pemilihan model terbaik. Evaluasi dilakukan menggunakan parameter akurasi (*accuracy*), presisi (*precision*), sensitivitas (*recall*), nilai F1 (*F1-score*), serta *confusion matrix*. Penggunaan beberapa metrik evaluasi diperlukan karena akurasi saja belum cukup untuk menggambarkan kemampuan model terutama pada klasifikasi multi-kelas (Sokolova dan Lapalme, 2009). Model dengan keseimbangan terbaik antara akurasi dan efisiensi komputasi kemudian dipilih sebagai kandidat implementasi pada sistem *smart nursery* terintegrasi energi surya dan biochar bambu untuk membantu kelompok tani Desa Reco dalam melakukan monitoring kesehatan bibit cabai.

3. HASIL DAN PEMBAHASAN

3.1. Hasil Pelatihan Model Deep Learning

Penelitian ini melakukan pengujian terhadap tiga model *deep learning*, yaitu Convolutional Neural Network (CNN), MobileNetV3Small, dan EfficientNet-B0 untuk melakukan klasifikasi kondisi kesehatan tanaman cabai berdasarkan citra daun. Ketiga model dilatih menggunakan dataset yang sama dengan jumlah 400 citra pelatihan, 50 citra validasi, dan 50 citra pengujian. Penggunaan dataset yang sama bertujuan agar perbandingan performa antar model dapat dilakukan secara objektif.

Hasil proses pelatihan menunjukkan bahwa ketiga model mampu mempelajari karakteristik visual tanaman cabai, namun memiliki pola konvergensi yang berbeda. Model CNN sebagai model dasar mengalami peningkatan akurasi secara bertahap dari kondisi awal dengan akurasi rendah hingga mencapai performa akhir yang lebih stabil. Namun, karena CNN melakukan pembelajaran fitur dari awal (*from scratch*), kemampuan ekstraksi fitur masih terbatas ketika jumlah dataset relatif kecil.

Sementara itu, model berbasis *transfer learning*, yaitu MobileNetV3Small dan EfficientNet-B0, menunjukkan proses pembelajaran yang lebih cepat karena telah memiliki bobot awal hasil pelatihan pada dataset ImageNet. Pendekatan *transfer learning* terbukti mampu meningkatkan kemampuan klasifikasi terutama ketika dataset spesifik yang digunakan memiliki jumlah data terbatas (Tan dan Le, 2019).

3.2. Perbandingan Performa Model

Klasifikasi

Perbandingan hasil pengujian ketiga model ditunjukkan pada Tabel 2.

Tabel 2. Perbandingan Performa Model Deep Learning

Model	Accuracy	Precision	Recall	F1-score
CNN	72%	0,73	0,72	0,71
MobileNetV3Small	88%	0,91	0,88	0,88
EfficientNet-B0	82%	0,84	0,82	0,82

Berdasarkan Tabel 2, model MobileNetV3Small menghasilkan performa terbaik dengan akurasi pengujian sebesar **88%**, precision sebesar **0,91**, recall sebesar **0,88**, dan F1-score sebesar **0,88**. Model EfficientNet-B0 berada pada urutan kedua dengan akurasi 82%, sedangkan CNN memperoleh akurasi terendah yaitu 72%.

Peningkatan performa MobileNetV3Small dibandingkan CNN menunjukkan bahwa penggunaan arsitektur *transfer learning* memberikan keuntungan signifikan pada klasifikasi citra tanaman. MobileNetV3Small mampu memanfaatkan fitur visual tingkat rendah dan menengah yang telah dipelajari sebelumnya, seperti tekstur, pola bercak, dan perubahan warna daun, kemudian melakukan penyesuaian terhadap karakteristik penyakit tanaman cabai.

Hasil ini sejalan dengan penelitian Howard et al. (2019) yang menjelaskan bahwa MobileNetV3 dirancang untuk memperoleh keseimbangan antara akurasi dan efisiensi komputasi melalui penggunaan *depthwise separable convolution* dan optimasi arsitektur. Pendekatan tersebut membuat MobileNetV3 sesuai digunakan pada aplikasi berbasis perangkat terbatas seperti sistem monitoring pertanian berbasis IoT.

3.3. Analisis Akurasi Model terhadap Kompleksitas Jaringan

Selain akurasi, kompleksitas model menjadi faktor penting dalam implementasi *smart nursery*. Tabel 3 menunjukkan perbandingan jumlah parameter dari masing-masing model.

Tabel 3. Kompleksitas Model

Model	Total Parameter
CNN	9,82 juta
MobileNetV3Small	1,08 juta
EfficientNet-B0	4,37 juta

Berdasarkan Tabel 3, MobileNetV3Small memiliki jumlah parameter paling rendah yaitu sekitar 1,08 juta parameter, sedangkan CNN memiliki jumlah parameter terbesar yaitu 9,82 juta parameter. Kondisi ini menunjukkan bahwa MobileNetV3Small mampu menghasilkan performa klasifikasi yang lebih baik dengan ukuran model yang lebih kecil.

Fenomena tersebut menunjukkan bahwa peningkatan kompleksitas jaringan tidak selalu menghasilkan peningkatan akurasi. EfficientNet-B0 memiliki jumlah parameter lebih besar dibandingkan MobileNetV3Small, tetapi menghasilkan akurasi lebih rendah. Hal ini dapat terjadi karena jumlah dataset yang digunakan relatif terbatas sehingga model dengan kompleksitas tinggi memiliki kemungkinan lebih besar mengalami *overfitting*. EfficientNet dikembangkan untuk memperoleh efisiensi melalui pendekatan *compound scaling* yang mengatur kedalaman, lebar, dan resolusi jaringan secara bersamaan (Tan dan Le, 2019). Namun, pada dataset kecil seperti penelitian ini, arsitektur yang lebih ringan dapat memberikan kemampuan generalisasi yang lebih baik.

3.4. Analisis Performa Berdasarkan Kelas Kondisi Tanaman Cabai

Analisis lebih detail dilakukan berdasarkan hasil klasifikasi setiap kelas menggunakan MobileNetV3Small sebagai model terbaik.

Tabel 4. Performa Klasifikasi Setiap Kelas

Kelas	Precision	Recall	F1-score
Healthy	1,00	0,80	0,89
Leaf curl	0,83	1,00	0,91
Leaf spot	0,71	1,00	0,83
Whitefly	1,00	1,00	1,00
Yellowish	1,00	0,60	0,75

Berdasarkan Tabel 4, kelas **whitefly** memperoleh performa terbaik dengan nilai


precision, recall, dan F1-score sebesar 1,00. Hal tersebut menunjukkan bahwa karakteristik visual serangan *whitefly* memiliki pola yang cukup khas sehingga mudah dikenali oleh model. Pola perubahan warna dan keberadaan struktur tertentu pada permukaan daun memberikan fitur yang kuat bagi jaringan CNN dalam melakukan klasifikasi.

Kelas *leaf curl* dan *leaf spot* juga menunjukkan nilai recall sebesar 1,00 yang berarti seluruh sampel pengujian berhasil ditemukan oleh model. Namun, nilai precision pada kelas *leaf spot* lebih rendah dibandingkan kelas lainnya. Hal ini kemungkinan disebabkan oleh adanya kemiripan pola visual antara bercak penyakit daun dengan perubahan warna akibat kondisi fisiologis tanaman.

Sementara itu, kelas *yellowish* memiliki nilai recall terendah sebesar 0,60. Kondisi ini menunjukkan bahwa perubahan warna kekuningan pada daun lebih sulit dibedakan dibandingkan gejala penyakit lainnya. Perubahan warna daun dapat dipengaruhi oleh berbagai faktor seperti kekurangan nutrisi, stres lingkungan, atau fase pertumbuhan tanaman sehingga membutuhkan variasi dataset yang lebih banyak untuk meningkatkan kemampuan model.

3.5. Analisis Confusion Matrix Model Terbaik (MobileNetV3Small)

Selain evaluasi menggunakan nilai *accuracy*, *precision*, *recall*, dan *F1-score*, analisis lebih lanjut dilakukan menggunakan *confusion matrix* untuk mengetahui distribusi hasil prediksi pada setiap kelas kondisi tanaman cabai. Confusion matrix memberikan informasi mengenai jumlah klasifikasi yang benar maupun kesalahan prediksi antar kelas sehingga dapat digunakan untuk mengevaluasi kemampuan model dalam mengenali pola visual masing-masing kategori tanaman (Sokolova & Lapalme, 2009). Pada penelitian ini, confusion matrix dianalisis menggunakan model MobileNetV3Small karena menghasilkan performa terbaik dibandingkan CNN dan EfficientNet-B0.



Gambar 5. Confusion Matrix Model MobileNetV3Small

Berdasarkan Gambar 5, model MobileNetV3Small menunjukkan kemampuan klasifikasi yang baik pada sebagian besar kategori kondisi tanaman cabai. Dari 50 citra pengujian, sebanyak 34 citra berhasil diklasifikasikan secara tepat pada kelas diagonal utama. Model mampu mengenali kelas *leaf curl*, *leaf spot*, dan *whitefly* dengan tingkat akurasi klasifikasi sempurna, yaitu seluruh citra pengujian pada masing-masing kelas berhasil diprediksi dengan benar. Hasil tersebut menunjukkan bahwa karakteristik visual ketiga kategori tersebut memiliki pola yang relatif jelas dan mudah dipelajari oleh jaringan deep learning.

Kelas *whitefly* menunjukkan performa paling stabil dengan seluruh sampel berhasil diklasifikasikan secara tepat. Hal ini disebabkan oleh karakteristik serangan *whitefly* yang memiliki pola visual lebih spesifik dibandingkan kelas lainnya, seperti perubahan warna dan tekstur permukaan daun akibat aktivitas hama. Kemampuan CNN dalam mengenali pola tekstur dan fitur lokal pada citra menjadi faktor penting dalam keberhasilan klasifikasi tersebut (Mohanty et al., 2016).

Pada kelas *healthy*, terdapat dua citra yang salah diklasifikasikan sebagai *leaf spot*. Kesalahan ini menunjukkan bahwa terdapat kemiripan karakteristik visual antara daun sehat dengan gejala awal bercak daun. Perubahan kecil pada tekstur atau warna daun dapat menyebabkan model memberikan prediksi yang berbeda, terutama ketika jumlah dataset masih

terbatas. Kondisi tersebut sesuai dengan penelitian sebelumnya yang menyatakan bahwa variasi pencahayaan, sudut pengambilan gambar, dan perubahan fisiologis tanaman menjadi tantangan utama pada klasifikasi penyakit tanaman berbasis citra (Ma et al., 2024).

Sementara itu, kelas *yellowish* menjadi kelas dengan tingkat kesalahan klasifikasi paling tinggi. Dari 10 citra pengujian, sebanyak 6 citra berhasil diprediksi dengan benar, sedangkan sebagian lainnya mengalami kesalahan prediksi menjadi kelas *leaf curl* dan *leaf spot*. Kondisi ini menunjukkan bahwa perubahan warna kekuningan pada daun memiliki karakteristik visual yang lebih kompleks dibandingkan gejala penyakit lainnya. Warna kuning pada daun tidak selalu menunjukkan jenis gangguan tertentu, tetapi dapat disebabkan oleh beberapa faktor seperti kekurangan unsur hara, stres lingkungan, umur tanaman, maupun tahap awal infeksi penyakit.

Hasil tersebut menjelaskan mengapa nilai *recall* kelas *yellowish* hanya mencapai 0,60 dibandingkan kelas lainnya. Untuk meningkatkan kemampuan model dalam mengenali kelas tersebut, diperlukan penambahan variasi dataset dengan kondisi tanaman yang lebih beragam, termasuk variasi tingkat kekuningan, intensitas cahaya, fase pertumbuhan, dan kondisi lingkungan. Penelitian terkait *smart agriculture* juga menunjukkan bahwa model deep learning membutuhkan dataset yang representatif agar mampu melakukan generalisasi dengan baik pada kondisi lapangan yang dinamis (Tunio et al., 2024).

Meskipun masih terdapat kesalahan pada kelas *yellowish*, secara keseluruhan MobileNetV3Small tetap menunjukkan performa yang unggul dengan akurasi 88%, precision 0,91, recall 0,88, dan F1-score 0,88. Hasil confusion matrix memperkuat bahwa MobileNetV3Small tidak hanya memiliki tingkat akurasi tinggi, tetapi juga mampu mempertahankan kemampuan klasifikasi pada berbagai kategori kondisi tanaman. Dengan jumlah parameter yang relatif kecil, model ini memiliki potensi besar untuk diterapkan pada perangkat *edge computing* berbasis kamera

dalam sistem *smart nursery* yang membutuhkan efisiensi komputasi tinggi (Mathew et al., 2025).

3.6. Implementasi Model untuk Smart Nursery Pertanian Berkelanjutan

Hasil penelitian menunjukkan bahwa MobileNetV3Small merupakan model paling potensial untuk diterapkan pada sistem *smart nursery* tanaman cabai. Keunggulan model tidak hanya terlihat dari akurasi klasifikasi tertinggi, tetapi juga dari ukuran model yang lebih ringan sehingga memungkinkan integrasi dengan perangkat monitoring berbasis kamera dan sistem komputasi terbatas.

Dalam konteks program **Smart Nursery Energi Surya Terintegrasi Biochar Bambu: Inovasi Pemberdayaan Kelompok Tani dalam Meningkatkan Produktivitas Pembibitan Cabai Desa Reco**, model klasifikasi ini dapat menjadi bagian dari sistem monitoring otomatis untuk mendeteksi kondisi kesehatan bibit sejak tahap awal. Integrasi antara sensor lingkungan, kamera digital, energi surya, dan kecerdasan buatan dapat membantu petani melakukan pengambilan keputusan secara lebih cepat dan akurat.

Pendekatan berbasis kecerdasan buatan pada sektor pertanian telah berkembang sebagai bagian dari konsep pertanian presisi (*precision agriculture*), yaitu pemanfaatan teknologi digital untuk meningkatkan efisiensi penggunaan sumber daya dan produktivitas tanaman (Ferentinos, 2018). Oleh karena itu, hasil penelitian ini memberikan kontribusi dalam pengembangan sistem pembibitan cerdas yang lebih adaptif, efisien, dan berkelanjutan.

3.7. Ucapan Terima Kasih

Artikel ini merupakan salah satu luaran dari kegiatan Program Penguatan Kapasitas Organisasi Kemahasiswaan (PPK Ormawa) Tahun 2026 dengan judul program “Smart Nursery Energi Surya Terintegrasi Biochar Bambu: Inovasi Pemberdayaan Kelompok Tani dalam Meningkatkan Produktivitas Pembibitan Cabai Desa Reco.” Kami menyampaikan terima kasih dan apresiasi kepada Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi Republik Indonesia atas dukungan, kepercayaan, dan pendanaan yang telah diberikan sehingga program ini dapat terlaksana. Dukungan tersebut

menjadi bagian penting dalam mendorong inovasi mahasiswa melalui penerapan teknologi deep learning untuk mendukung pertanian berkelanjutan serta memberikan manfaat nyata bagi kelompok tani Desa Reco.

4. PENUTUP

4.1. Kesimpulan

Penelitian ini berhasil mengembangkan dan mengevaluasi model klasifikasi kondisi kesehatan tanaman cabai berbasis *deep learning* sebagai pendukung sistem *smart nursery* pertanian berkelanjutan. Perbandingan tiga model, yaitu CNN sebagai model dasar, MobileNetV3Small, dan EfficientNet-B0 menunjukkan bahwa MobileNetV3Small memberikan performa terbaik dengan akurasi pengujian sebesar **88%**, nilai *precision* 0,91, *recall* 0,88, dan *F1-score* 0,88. Model tersebut mampu mengungguli CNN dengan akurasi 72% dan EfficientNet-B0 dengan akurasi 82%, serta memiliki jumlah parameter paling rendah sehingga lebih efisien untuk implementasi pada sistem monitoring berbasis perangkat terbatas. Hasil penelitian menunjukkan bahwa pendekatan *transfer learning* mampu meningkatkan kemampuan klasifikasi citra daun cabai, terutama pada dataset dengan jumlah terbatas. Model MobileNetV3Small berpotensi dikembangkan sebagai komponen kecerdasan buatan dalam sistem *smart nursery* terintegrasi energi surya dan biochar bambu untuk membantu kelompok tani Desa Reco melakukan deteksi awal kesehatan bibit cabai secara cepat, objektif, dan berkelanjutan. Analisis confusion matrix menunjukkan bahwa MobileNetV3Small mampu melakukan klasifikasi sangat baik pada kategori *leaf curl*, *leaf spot*, dan *whitefly*, sedangkan kelas *yellowish* masih menjadi tantangan utama akibat tingginya variasi karakteristik visual. Oleh karena itu, peningkatan jumlah dataset dan diversifikasi kondisi lingkungan diperlukan untuk meningkatkan kemampuan generalisasi model pada implementasi lapangan.

4.2. Saran

Pengembangan penelitian selanjutnya disarankan untuk memperluas jumlah dan variasi dataset dengan menambahkan citra tanaman cabai dari kondisi lapangan yang lebih beragam,

seperti perbedaan intensitas cahaya, fase pertumbuhan tanaman, varietas cabai, serta tingkat keparahan penyakit. Selain itu, model terbaik yang diperoleh perlu diintegrasikan secara langsung dengan perangkat *smart nursery* seperti kamera pemantauan berbasis IoT, sistem energi surya, dan aplikasi monitoring digital agar dapat diuji pada lingkungan pertanian nyata. Penelitian lanjutan juga dapat mengeksplorasi metode optimasi model seperti *fine tuning*, *ensemble learning*, atau pendekatan *explainable artificial intelligence* (XAI) untuk meningkatkan akurasi, interpretabilitas, dan kepercayaan pengguna terhadap sistem klasifikasi penyakit tanaman berbasis kecerdasan buatan. Penelitian selanjutnya perlu memperluas dataset khususnya untuk kategori perubahan fisiologis seperti *yellowish* dengan menambahkan variasi kondisi tanaman berdasarkan tingkat kekuningan, umur tanaman, kondisi nutrisi, serta variasi pencahayaan. Selain itu, penerapan metode optimasi seperti *fine tuning*, *attention mechanism*, atau *explainable artificial intelligence* (XAI) dapat digunakan untuk meningkatkan interpretabilitas keputusan model dalam sistem *smart nursery*.

5. DAFTAR PUSTAKA

- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318. <https://doi.org/10.1016/j.compag.2018.01.009>
- Gautam, S., Kumari, S., Sharma, R., & Kumar, A. (2022). Deep learning-based plant disease detection and classification: A comprehensive review. *Artificial Intelligence in Agriculture*, 6, 34–45.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Howard, A., Sandler, M., Chu, G., Chen, L. C., Chen, B., Tan, M., Wang, W., Zhu, Y., Pang, R., Vasudevan, V., Le, Q. V., & Adam, H. (2019). Searching for MobileNetV3. In *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)* (pp. 1314–1324). <https://doi.org/10.1109/ICCV.2019.00140>

- Khan, A., Iqbal, M., Ahmad, S., & Hussain, A. (2024). Transfer learning-based deep neural networks for automated plant disease classification using leaf images. *Computers and Electronics in Agriculture*, 218, 108703.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521, 436–444. <https://doi.org/10.1038/nature14539>
- Ma, J., Du, K., Zheng, F., Zhang, L., Gong, Z., & Sun, Z. (2024). Plant disease recognition based on deep learning and image processing: A review. *Plant Methods*, 20, Article 15.
- Mathew, M. P., Singh, P., & Kumar, R. (2025). Lightweight deep learning models for edge-based smart agriculture applications. *Computers and Electronics in Agriculture*, 230, 109845.
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, Article 1419. <https://doi.org/10.3389/fpls.2016.01419>
- Ozturk, S., Akdemir, B., & Kaya, Y. (2025). Efficient deep learning architectures for plant disease classification using transfer learning approaches. *Engineering Applications of Artificial Intelligence*, 139, 109452.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6, Article 60. <https://doi.org/10.1186/s40537-019-0197-0>
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. In *Proceedings of the 36th International Conference on Machine Learning (ICML)* (pp. 6105–6114).
- Tunio, M. H., Gao, J., Shaikh, S. A., & Li, J. (2024). Computer vision and artificial intelligence applications for precision agriculture: A review. *Smart Agricultural Technology*, 8, 100456.