

Analisis Optimasi Algoritma *Convolutional Neural Network*(CNN) untuk Deteksi Dini Penyakit Tanaman pada Perangkat Mobile Berbasis *Edge Computing*

Iin Tarsini

Politeknik Siber Cerdika Internasional, Indonesia

Email: iin_tarsini@poltek.ac.id

Abstrak

Penyakit tanaman merupakan ancaman serius terhadap ketahanan pangan global, namun sistem deteksi berbasis cloud yang ada saat ini tidak efektif di wilayah pertanian dengan keterbatasan akses internet. Penelitian ini bertujuan mengevaluasi efektivitas optimasi algoritma Convolutional Neural Network (CNN) berbasis arsitektur MobileNetV2 yang diimplementasikan pada perangkat mobile melalui pendekatan edge computing untuk mendukung deteksi dini penyakit tanaman secara offline dan mandiri. Penelitian menggunakan desain eksperimental kuantitatif berbasis komputasi dengan dataset PlantVillage yang mencakup ±54.000 citra dari tiga komoditas strategis (tomat, kentang, jagung) dengan 15 kelas penyakit. Model dikembangkan menggunakan depthwise separable convolutions dan transfer learning dari ImageNet, dilatih dengan optimizer Adam (learning rate 0.0001), kemudian dikonversi ke format TensorFlow Lite untuk deployment pada aplikasi Android. Evaluasi menghasilkan akurasi 94,5%, precision 94,1%, recall 93,8%, dan F1-score 94,0%, dengan ukuran model 14 MB dan waktu inferensi rata-rata 120 milidetik pada smartphone RAM 4 GB. Dibandingkan VGG16 (akurasi 95,1%, ukuran 528 MB), MobileNetV2 jauh lebih efisien tanpa mengorbankan akurasi secara signifikan. Pendekatan ini berimplikasi pada tersedianya solusi deteksi penyakit tanaman yang akurat, ringan, dan dapat dioperasikan tanpa konektivitas internet, sehingga berpotensi mendukung pengambilan keputusan dini oleh petani dan meningkatkan produktivitas pertanian secara berkelanjutan.

Kata Kunci: *artificial intelligence*; CNN; deteksi penyakit tanaman; *edge computing*; MobileNetV2; *tensorflow lite*; *transfer learning*

Abstract

Plant diseases pose a serious threat to global food security, yet existing cloud-based detection systems are ineffective in rural farming areas with limited internet access. This study aimed to evaluate the effectiveness of Convolutional Neural Network (CNN) optimization using the MobileNetV2 architecture deployed on mobile devices via an edge computing approach to enable offline, autonomous plant disease detection. A quantitative computational experimental design was employed using the PlantVillage dataset comprising approximately 54,000 images across 15

disease classes from tomato, potato, and maize crops. The model utilized depthwise separable convolutions and ImageNet transfer learning, trained with Adam optimizer (learning rate 0.0001), and converted to TensorFlow Lite for Android deployment. Evaluation yielded an accuracy of 94.5%, precision of 94.1%, recall of 93.8%, and F1-score of 94.0%, with a compact model size of 14 MB and an average inference time of 120 milliseconds on a mid-range smartphone (4 GB RAM). Compared to VGG16 (accuracy 95.1%, size 528 MB), MobileNetV2 delivered substantially greater computational efficiency with negligible accuracy trade-off. These findings imply that CNN-based edge computing constitutes a practical, lightweight, and connectivity-independent solution for early plant disease identification, with significant potential to support timely farmer decision-making and contribute to sustainable agricultural productivity.

Keywords: artificial intelligence; CNN; edge computing; MobileNetV2; plant disease detection; tensorflow lite; transfer learning

PENDAHULUAN

Identifikasi dini penyakit tanaman merupakan salah satu faktor kunci dalam menjaga stabilitas produksi pertanian dan keberlanjutan ketahanan pangan, khususnya di negara agraris seperti Indonesia. Penyakit tanaman yang tidak terdeteksi sejak awal dapat menyebabkan penurunan kualitas dan kuantitas hasil panen secara signifikan, bahkan berujung pada kegagalan panen. Kondisi ini secara nyata tercermin pada sektor pertanian padi, di mana “produktivitas panen padi di Indonesia masih terganggu oleh penyakit daun yang sulit dikenali secara visual” (Farihah et al., 2025). Ketergantungan pada pengamatan visual semata tidak lagi memadai untuk menghadapi kompleksitas penyakit tanaman yang semakin beragam. Secara konvensional, identifikasi penyakit tanaman masih sangat bergantung pada pengalaman dan keahlian manusia. Proses ini tidak hanya memerlukan tenaga ahli yang terbatas jumlahnya, tetapi juga cenderung memakan waktu serta biaya yang tinggi. Li et al., (2021) menegaskan bahwa deteksi penyakit tanaman secara manual memiliki keterbatasan signifikan dalam hal skalabilitas dan konsistensi hasil, sehingga mendorong pengembangan pendekatan berbasis deep learning yang mampu mengotomatisasi proses identifikasi secara lebih efisien.

Pangestu et al., (2025) secara langsung menyatakan bahwa “identifikasi penyakit tanaman biasanya memerlukan ahli yang berpengalaman, namun proses ini memakan waktu dan biaya yang signifikan.” Selain itu, pendekatan manual memiliki tingkat subjektivitas yang tinggi, karena persepsi visual setiap individu dapat berbeda. Penyakit seperti *early blight* dan *late blight* memang dapat dikenali melalui karakteristik visual pada permukaan daun, namun proses identifikasi manual bersifat subjektif dan membutuhkan waktu yang relatif lama (Prasetyo, P. et.al, 2025). Akibatnya, keterlambatan dalam pengambilan keputusan pengendalian penyakit sering kali tidak terhindarkan.

Perkembangan teknologi pengolahan citra digital membuka peluang baru dalam mengatasi keterbatasan tersebut. Pengolahan citra digital telah berkembang pesat dan kini berperan penting di berbagai sektor, termasuk pertanian, khususnya dalam deteksi penyakit tanaman (Prasetyo, P. et.al, 2025). Melalui pendekatan berbasis komputasi, citra daun

tanaman dapat dianalisis secara objektif dan konsisten. Jackulin et al., (2022) dalam tinjauan komprehensifnya menyoroti bahwa penerapan teknik machine learning dan deep learning telah secara signifikan meningkatkan akurasi deteksi penyakit tanaman dibandingkan metode konvensional berbasis inspeksi visual. Fariyah et al., (2025) menjelaskan bahwa pemanfaatan pengolahan citra digital dengan metode ekstraksi fitur seperti *Gray Level Co-occurrence Matrix* (GLCM) yang dikombinasikan dengan algoritma klasifikasi KNN mampu membedakan daun padi yang sehat dan terinfeksi secara efektif, sehingga mendukung peningkatan kualitas panen secara dini dan akurat. Meskipun demikian, metode ekstraksi fitur manual memiliki keterbatasan dalam menangkap kompleksitas pola visual pada citra daun yang bervariasi.

Convolutional Neural Network (CNN) hadir sebagai pendekatan *deep learning* yang unggul dalam analisis citra. CNN mampu melakukan ekstraksi fitur secara otomatis dan hierarkis langsung dari data citra mentah. Prasetyo, P. et.al, (2025) menyatakan bahwa penggunaan CNN dengan pendekatan *transfer learning* pada citra daun kentang dapat mengatasi keterbatasan deteksi manual serta meningkatkan efektivitas identifikasi jenis penyakit tanaman secara otomatis dengan tingkat akurasi yang tinggi. Hal ini konsisten dengan tinjauan sistematis Shoaib et al., (2023) yang mengonfirmasi bahwa model deep learning,

khususnya CNN, mampu mencapai tingkat akurasi yang sangat tinggi dalam identifikasi penyakit tanaman pada berbagai dataset benchmark. Namun, sebagian besar implementasi CNN konvensional masih bergantung pada arsitektur yang kompleks dan berorientasi pada komputasi berbasis *cloud*, sehingga menimbulkan kendala baru berupa latensi tinggi, ketergantungan pada konektivitas jaringan, serta risiko privasi data, terutama di wilayah pedesaan dengan infrastruktur internet yang terbatas. Memasuki tahun 2026, paradigma *edge computing* menjadi solusi strategis dalam mendesentralisasikan kecerdasan buatan. Pendekatan ini memungkinkan proses inferensi dijalankan langsung pada perangkat pengguna, seperti smartphone, tanpa harus bergantung pada server *cloud*.

Urgensi penelitian ini menjadi semakin nyata mengingat populasi petani di Indonesia yang mayoritas berada di wilayah pedesaan dengan akses internet yang terbatas dan tingkat literasi teknologi yang beragam. Berdasarkan data Badan Pusat Statistik (2023), lebih dari 60% lahan pertanian di Indonesia berada di luar jangkauan jaringan internet yang stabil, sehingga sistem berbasis cloud tidak dapat diandalkan sebagai solusi deteksi penyakit yang inklusif. Sementara itu, penetrasi smartphone di kalangan petani terus meningkat, menciptakan peluang strategis untuk mengembangkan sistem kecerdasan buatan berbasis perangkat mobile yang dapat beroperasi secara mandiri tanpa konektivitas jaringan.

Ahmad et al., (2023) juga merekomendasikan pengembangan alat deteksi penyakit tanaman yang dapat dioperasikan pada perangkat dengan sumber daya terbatas sebagai solusi atas ketergantungan pada infrastruktur cloud yang tidak selalu tersedia di wilayah pertanian. Tanpa solusi deteksi berbasis edge yang handal, kerugian akibat penyakit tanaman yang terlambat teridentifikasi akan terus membebani sektor pertanian nasional, mengancam ketahanan pangan, dan memperlebar kesenjangan teknologi antara petani besar dan petani kecil.

Kebaruan penelitian ini terletak pada integrasi tiga komponen optimasi secara terpadu penggunaan arsitektur MobileNetV2 dengan mekanisme depthwise separable convolutions yang dirancang khusus untuk lingkungan komputasi terbatas, penerapan teknik transfer learning dari dataset ImageNet yang dikombinasikan dengan fine-tuning pada dataset PlantVillage untuk meningkatkan generalisasi model pada domain penyakit tanaman dan (3) konversi model ke format TensorFlow Lite disertai kuantisasi bobot untuk meminimalkan ukuran model dan latensi inferensi pada perangkat mobile. Kombinasi ketiga komponen ini, yang dievaluasi secara komprehensif pada perangkat smartphone kelas menengah dalam lingkungan edge computing yang sesungguhnya, membedakan penelitian ini dari studi-studi sebelumnya yang umumnya hanya mengevaluasi akurasi model tanpa mempertimbangkan kelayakan implementasi pada perangkat terbatas secara bersamaan.

Khan et al., (2023) telah menunjukkan bahwa model deteksi penyakit tanaman yang dirancang khusus untuk perangkat edge computing mampu memberikan performa yang kompetitif dengan model berbasis server, namun belum mengintegrasikan evaluasi komprehensif pada perangkat smartphone kelas menengah sebagaimana dilakukan dalam penelitian ini. Penelitian Sandler et al., (2018) memperkenalkan arsitektur MobileNetV2, namun tidak secara spesifik mengkaji penerapannya dalam konteks deteksi penyakit tanaman berbasis edge computing. Demikian pula, studi-studi terdahulu seperti Mifthauddin et al., (2025); Qur & Bahri, (2024) memfokuskan evaluasi pada akurasi klasifikasi tanpa mengintegrasikan pengujian performa inferensi di lingkungan mobile nyata.

Berdasarkan latar belakang dan identifikasi kesenjangan penelitian di atas, penelitian ini memiliki tujuan utama sebagai berikut: (1) mengevaluasi efektivitas optimasi algoritma CNN berbasis arsitektur MobileNetV2 dalam mendeteksi penyakit tanaman secara akurat menggunakan dataset PlantVillage, diukur melalui metrik akurasi, precision, recall, dan F1-score; (2) menganalisis kelayakan implementasi model yang telah dioptimasi pada perangkat mobile kelas menengah dalam lingkungan edge computing, meliputi konsumsi memori RAM, ukuran model, dan waktu inferensi; serta (3) membandingkan performa MobileNetV2 yang telah dioptimasi dengan model CNN konvensional (VGG16) dalam konteks efisiensi komputasi untuk penggunaan di lapangan.

Manfaat praktis penelitian ini adalah tersedianya sistem deteksi dini penyakit tanaman yang dapat berjalan secara offline di smartphone petani, sehingga mendukung pengambilan keputusan pengendalian penyakit yang cepat dan tepat tanpa ketergantungan infrastruktur internet. Secara ilmiah, penelitian ini berkontribusi pada pengembangan literatur mengenai implementasi edge AI untuk pertanian cerdas (smart agriculture), khususnya dalam aspek optimasi model deep learning untuk perangkat dengan sumber daya terbatas. Implikasi jangka panjang dari penelitian ini mencakup potensi integrasi sistem ke dalam program penyuluhan pertanian digital yang dapat diakses oleh jutaan petani kecil di Indonesia dan negara berkembang lainnya.

METODE

Jenis dan Desain Penelitian

Penelitian ini merupakan penelitian eksperimental kuantitatif berbasis komputasi (computational experimental research) dengan pendekatan desain pengembangan model (model development design). Tujuan utama penelitian adalah mengembangkan, mengoptimasi, dan mengevaluasi model deep learning untuk klasifikasi penyakit tanaman dalam lingkungan edge computing. Penelitian ini tidak melibatkan intervensi di lapangan secara langsung, melainkan berfokus pada perancangan sistem perangkat lunak yang dapat divalidasi secara empiris melalui eksperimen terkontrol menggunakan dataset benchmark yang terstandar.

Dataset yang digunakan adalah PlantVillage (Hughes & Salathe, 2015), yang diakses melalui repositori publik Kaggle. Dataset ini terdiri dari 87.000 citra daun tanaman yang mencakup 38 kelas kondisi (sehat dan terinfeksi penyakit) dari berbagai komoditas pertanian. Dalam penelitian ini, fokus diberikan pada tiga komoditas strategis, yaitu tomat (*Solanum lycopersicum*), kentang (*Solanum tuberosum*), dan jagung (*Zea mays*), yang meliputi total 15 kelas penyakit dan kondisi sehat. Total citra yang digunakan setelah seleksi berjumlah ±54.000 citra.

Seluruh citra dikonversi ke format RGB dan di-resize ke dimensi 224×224 piksel sesuai kebutuhan input arsitektur MobileNetV2. Pembagian dataset dilakukan dengan proporsi 70% data latih (training set), 15% data validasi (validation set), dan 15% data uji (test set). Instrumen perangkat lunak yang digunakan meliputi Python 3.10, TensorFlow 2.13, Keras, dan TensorFlow Lite untuk proses konversi dan deployment model. Instrumen perangkat keras pengujian mobile terdiri dari smartphone Android dengan RAM 4 GB dan chipset kelas menengah (Snapdragon 680 atau setara), yang dipilih sebagai representasi perangkat yang umum digunakan oleh petani di Indonesia.

Tabel 1. Konfigurasi Hiperparameter Pelatihan Model

Parameter	Nilai
Arsitektur Model	MobileNetV2 + Transfer Learning (ImageNet)
Optimizer	Adam
Learning Rate	0.0001
Fungsi Loss	Categorical Crossentropy
Jumlah Epoch	50 (dengan EarlyStopping)
Batch Size	32
Ukuran Input	224 × 224 piksel (RGB)
Pembagian Data	70% latih / 15% validasi / 15% uji

Metrik Evaluasi	Akurasi, Precision, Recall, F1-Score
Format Deployment	TensorFlow Lite (.tflite) dengan kuantisasi

Sumber: Data diolah

Arsitektur MobileNetV2 dan Transfer Learning

Penelitian ini mengadopsi arsitektur MobileNetV2 sebagai dasar pengembangan model *Convolutional Neural Network* (CNN) karena dirancang khusus untuk lingkungan komputasi terbatas seperti perangkat mobile berbasis *edge computing*. MobileNetV2 memanfaatkan konsep Inverted Residuals dan Linear Bottlenecks, yang memungkinkan aliran informasi tetap efisien meskipun jumlah parameter model ditekan seminimal mungkin. Berbeda dengan konvolusi standar yang bersifat komputasi-intensif, MobileNetV2 memecah proses konvolusi menjadi *depthwise convolution* untuk mengekstraksi fitur spasial dan *pointwise convolution* untuk menggabungkan fitur antar kanal, sehingga secara signifikan mengurangi beban komputasi dan penggunaan memori. Untuk meningkatkan kinerja model tanpa harus melatih jaringan dari awal, pendekatan transfer learning diterapkan dengan memanfaatkan bobot pra-latih dari dataset berskala besar.

Strategi ini memungkinkan model belajar pola visual dasar secara lebih cepat dan stabil. Dalam metodologi pelatihan, penelitian sebelumnya menunjukkan bahwa “penelitian ini menggunakan ImageDataGenerator untuk normalisasi, augmentasi, serta pembagian data latih dan validasi dalam pelatihan model MobileNetV2” (Qur & Bahri, 2024). Secara tidak langsung, Qur & Bahri, (2024) menegaskan bahwa tahapan preprocessing yang terstruktur mampu meningkatkan kualitas pelatihan dan generalisasi model. Selain itu, Mifthauddin et al., (2025) menjelaskan bahwa pembagian dataset yang tepat serta penerapan mekanisme *EarlyStopping* efektif dalam mengurangi risiko *overfitting* pada pelatihan MobileNetV2 berbasis *transfer learning*.

Alur Penelitian

Alur penelitian dirancang secara sistematis untuk memastikan keterkaitan yang kuat antara tahap pengolahan data, pelatihan model, hingga implementasi pada perangkat mobile. Tahap awal dimulai dengan akuisisi data, yaitu menggunakan dataset PlantVillage yang telah banyak dijadikan acuan dalam penelitian deteksi penyakit tanaman, dengan fokus pada komoditas strategis seperti tomat, kentang, dan jagung. Dataset ini dipilih karena memiliki variasi citra penyakit yang representatif dan relevan dengan kondisi pertanian. Tahap berikutnya adalah preprocessing data, di mana seluruh citra dikonversi ke format RGB dan di-*resize* menjadi ukuran $224 \times 224 \times 224$ piksel agar sesuai dengan kebutuhan input MobileNetV2.

Proses augmentasi, seperti *random rotation* dan *horizontal flipping*, diterapkan untuk meningkatkan keragaman data dan menekan potensi *overfitting*. Pendekatan ini sejalan dengan temuan Qur & Bahri, (2024) yang menjelaskan bahwa augmentasi, normalisasi, serta pembagian data latih dan validasi menggunakan *ImageDataGenerator* berperan penting dalam meningkatkan kualitas pelatihan model CNN. Pada tahap pelatihan model, digunakan *optimizer* Adam dengan *learning rate* sebesar 0.0001 dan fungsi *loss categorical*

crossentropy untuk mengoptimalkan proses pembelajaran multi-kelas. Untuk menjaga stabilitas pelatihan, mekanisme *EarlyStopping* diterapkan sebagaimana direkomendasikan oleh (Mifthauddin et al., 2025). Tahap akhir adalah deployment, di mana model terlatih dikonversi ke format TensorFlow Lite (tflite) dan diintegrasikan ke dalam aplikasi Android, sehingga seluruh proses inferensi dapat dijalankan secara lokal pada perangkat mobile berbasis *edge computing*.

HASIL DAN PEMBAHASAN

Evaluasi Model

Evaluasi kinerja model convolutional neural network (CNN) berbasis MobileNetV2 dalam penelitian ini difokuskan pada kemampuan sistem untuk melakukan klasifikasi penyakit tanaman secara akurat, stabil, dan dapat diandalkan dalam berbagai kondisi data. Proses evaluasi tidak hanya bertujuan untuk melihat tingkat ketepatan prediksi, tetapi juga untuk menilai konsistensi model dalam mengenali pola visual penyakit pada daun tanaman secara berulang. Model MobileNetV2 dilatih menggunakan dataset yang telah melalui tahap pra-proses, dengan jumlah iterasi pelatihan ditetapkan sebanyak 50 epochs. Selama proses ini, performa model dipantau secara kontinu melalui metrik akurasi dan nilai loss baik pada data latih maupun data validasi. Pemilihan jumlah epoch tersebut didasarkan pada pertimbangan keseimbangan antara kecukupan pembelajaran fitur dan efisiensi waktu pelatihan. Dengan jumlah epoch yang memadai, model memiliki kesempatan yang cukup untuk mempelajari representasi visual penyakit tanaman tanpa harus mengalami pelatihan berlebihan yang berpotensi menurunkan kemampuan generalisasi.

Berdasarkan grafik pembelajaran yang dihasilkan selama proses training, terlihat bahwa kurva akurasi dan loss menunjukkan pola yang relatif stabil setelah memasuki epoch ke-35. Pada fase ini, peningkatan akurasi mulai melambat dan nilai loss cenderung konvergen, baik pada data latih maupun data validasi. Pola konvergensi tersebut mengindikasikan bahwa model telah mencapai titik keseimbangan optimal antara kemampuan mempelajari fitur spesifik dari data pelatihan dan kemampuannya untuk menggeneralisasi pengetahuan tersebut pada data yang belum pernah dilihat sebelumnya. Stabilitas konvergensi ini menjadi indikator penting bahwa konfigurasi hiperparameter yang digunakan, seperti learning rate, ukuran batch, dan arsitektur model, telah disesuaikan secara tepat dengan karakteristik dataset.

Ketika hiperparameter tidak dikonfigurasi dengan baik, model cenderung mengalami overfitting atau underfitting, yang ditandai dengan perbedaan mencolok antara performa pada data latih dan data validasi. Namun, dalam penelitian ini, keselarasan antara kedua kurva tersebut menunjukkan bahwa model mampu mempelajari pola penting tanpa menghafal data secara berlebihan, sekaligus tidak gagal menangkap kompleksitas fitur penyakit tanaman.

Kondisi konvergensi yang dicapai setelah epoch ke-35 juga mencerminkan efektivitas strategi pelatihan yang diterapkan, termasuk penggunaan augmentasi data dan regularisasi implisit dari arsitektur MobileNetV2. Arsitektur ini memang dirancang untuk menekan kompleksitas komputasi melalui penggunaan depthwise separable convolution, sehingga

model tetap efisien tanpa mengorbankan kemampuan ekstraksi fitur penting. MobileNetV2 mampu mempertahankan performa yang stabil meskipun dijalankan pada dataset dengan variasi visual yang cukup tinggi, sebagaimana lazim ditemui pada citra tanaman di lingkungan alami.

Pemilihan arsitektur CNN yang ringan namun representatif sangat berpengaruh terhadap keberhasilan sistem klasifikasi berbasis citra. MobileNetV2 dikenal memiliki trade-off yang baik antara akurasi dan efisiensi, sehingga sering digunakan dalam skenario edge computing dan aplikasi mobile. Temuan ini sejalan dengan tinjauan Tugrul et al., (2022) yang mengonfirmasi bahwa arsitektur CNN merupakan pendekatan yang paling efektif untuk deteksi penyakit daun tanaman berdasarkan analisis citra, dengan arsitektur ringan seperti MobileNet yang menunjukkan keunggulan dalam hal efisiensi komputasi. Dalam klasifikasi penyakit tanaman, kemampuan model untuk mencapai konvergensi yang stabil menunjukkan bahwa arsitektur tersebut mampu menangkap ciri visual penting seperti perubahan warna daun, pola bercak, dan tekstur permukaan yang menjadi indikator utama penyakit.

Selain itu, kestabilan performa model juga mencerminkan bahwa distribusi data latih dan data validasi telah disusun secara proporsional dan representatif. Pemisahan data yang tidak seimbang sering kali menyebabkan bias dalam proses evaluasi, sehingga model tampak memiliki akurasi tinggi pada data latih tetapi gagal mempertahankan performa pada data baru. Namun, hasil evaluasi dalam penelitian ini menunjukkan bahwa model MobileNetV2 mampu mempertahankan konsistensi prediksi pada kedua jenis data tersebut, yang mengindikasikan kualitas dataset dan proses pembagian data yang baik.

Dari sudut pandang implementasi praktis, hasil evaluasi ini memiliki implikasi penting bagi penerapan sistem deteksi penyakit tanaman berbasis mobile. Model yang telah mencapai konvergensi stabil dan tidak menunjukkan gejala overfitting atau underfitting memiliki peluang lebih besar untuk memberikan prediksi yang andal ketika digunakan oleh pengguna akhir, seperti petani atau penyuluh pertanian. Keandalan ini menjadi faktor krusial, karena kesalahan klasifikasi dapat berdampak langsung pada keputusan penanganan tanaman dan produktivitas pertanian.

Evaluasi kinerja model klasifikasi citra dalam penelitian ini dilakukan dengan menggunakan seperangkat metrik yang lazim digunakan dalam studi pengenalan pola berbasis deep learning, yaitu precision, recall, dan F1-score. Penggunaan ketiga metrik ini dipilih secara sadar untuk memberikan gambaran yang lebih menyeluruh mengenai performa model, khususnya dalam klasifikasi penyakit tanaman yang melibatkan lebih dari satu kelas. Dalam kasus multikelas, akurasi saja sering kali tidak cukup representatif, karena model dapat terlihat memiliki performa tinggi meskipun gagal mengenali kelas tertentu secara konsisten. Precision digunakan untuk mengukur sejauh mana prediksi positif yang dihasilkan oleh model benar-benar sesuai dengan kelas yang semestinya. Dalam klasifikasi penyakit tanaman, metrik ini berperan penting untuk memastikan bahwa ketika sistem mengidentifikasi suatu penyakit tertentu, hasil tersebut memang akurat dan tidak menyesatkan pengguna. Precision yang tinggi menunjukkan bahwa tingkat kesalahan

prediksi positif relatif rendah, sehingga risiko salah diagnosis akibat kesalahan klasifikasi dapat diminimalkan.

Sementara itu, recall digunakan untuk menilai kemampuan model dalam mendeteksi seluruh sampel yang benar-benar termasuk ke dalam suatu kelas penyakit. Recall mencerminkan tingkat sensitivitas model terhadap keberadaan penyakit tertentu pada citra daun. Dalam aplikasi deteksi penyakit tanaman, recall yang tinggi sangat penting karena kegagalan mendeteksi penyakit yang sebenarnya ada dapat menyebabkan keterlambatan penanganan dan berpotensi menurunkan hasil panen. Metrik ini memberikan informasi penting mengenai seberapa baik model mampu menangkap seluruh variasi visual penyakit yang terdapat dalam dataset. F1-score kemudian digunakan sebagai metrik gabungan yang menyeimbangkan precision dan recall. Nilai F1-score memberikan gambaran menyeluruh tentang performa model dengan mempertimbangkan trade-off antara ketepatan prediksi dan sensitivitas deteksi. Penggunaan F1-score menjadi relevan ketika kedua metrik tersebut sama-sama penting dan tidak dapat diprioritaskan secara sepihak. Dalam penelitian ini, F1-score berfungsi sebagai indikator utama untuk menilai stabilitas dan konsistensi kinerja model dalam mengklasifikasikan berbagai jenis penyakit tanaman secara simultan.

Berdasarkan hasil evaluasi yang diperoleh, model klasifikasi berbasis CNN menunjukkan performa yang sangat baik dengan capaian precision sebesar 94,1%, recall sebesar 93,8%, dan F1-score sebesar 94,0%. Nilai-nilai ini menunjukkan bahwa model tidak hanya mampu menghasilkan prediksi yang akurat, tetapi juga memiliki kemampuan deteksi yang tinggi terhadap berbagai kelas penyakit tanaman. Tingginya precision mengindikasikan bahwa sebagian besar prediksi yang dihasilkan oleh model sesuai dengan kondisi sebenarnya, sedangkan nilai recall yang hampir seimbang menunjukkan bahwa model jarang melewatkan kasus penyakit yang seharusnya terdeteksi.

Capaian metrik yang relatif seimbang antara precision dan recall mencerminkan bahwa model tidak condong pada satu aspek performa saja. Model yang terlalu menekankan precision sering kali menjadi terlalu konservatif dalam memberikan prediksi, sementara model yang terlalu fokus pada recall berpotensi menghasilkan banyak kesalahan klasifikasi. Namun, dalam penelitian ini, keseimbangan antara kedua metrik tersebut menghasilkan F1-score yang tinggi, yang menunjukkan bahwa model mampu menjaga akurasi prediksi tanpa mengorbankan sensitivitas deteksi.

Hasil evaluasi ini juga sejalan dengan temuan dalam literatur yang menyatakan bahwa penggunaan metrik evaluasi yang komprehensif sangat penting dalam pengembangan sistem klasifikasi citra medis maupun pertanian. Dalam penyakit tanaman, beberapa kelas penyakit sering kali memiliki jumlah sampel yang lebih sedikit, sehingga evaluasi berbasis akurasi dapat memberikan gambaran yang bias terhadap performa model. Nilai F1-score yang tinggi juga menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data uji.

Shafik et al., (2023) dalam tinjauan sistematisnya juga menekankan pentingnya penggunaan metrik evaluasi yang komprehensif dan beragam dalam sistem deteksi penyakit tanaman untuk memastikan keandalan model ketika diterapkan di berbagai kondisi lapangan yang bervariasi. Kemampuan ini sangat penting ketika sistem diterapkan di lingkungan nyata,

di mana variasi kondisi citra tidak selalu identik dengan data pelatihan. Dengan performa yang stabil pada berbagai metrik evaluasi, model diharapkan mampu memberikan hasil klasifikasi yang andal meskipun dihadapkan pada perbedaan intensitas cahaya, latar belakang daun, maupun tingkat keparahan penyakit yang beragam.

Selain itu, Sari, (2024) menegaskan bahwa dalam bagian hasil dan pembahasan, kinerja model CNN umumnya diukur menggunakan metrik evaluasi standar seperti akurasi, presisi, recall, dan F1-score untuk menilai kemampuan klasifikasi citra secara akurat. Capaian metrik pada penelitian ini menunjukkan bahwa model MobileNetV2 yang dioptimasi berada pada tingkat performa yang kompetitif dan relevan dengan standar evaluasi yang berlaku dalam penelitian CNN.

Analisis Performa pada Perangkat *Mobile*

Selain capaian akurasi klasifikasi yang tinggi, penelitian ini memberikan perhatian serius pada aspek performa sistem ketika dijalankan langsung pada perangkat mobile. Fokus ini menjadi sangat relevan karena seluruh proses inferensi dirancang untuk berlangsung pada lingkungan *edge computing*, di mana ketersediaan sumber daya komputasi, memori, dan daya relatif terbatas dibandingkan sistem berbasis server. Dalam pertanian, pendekatan ini dipilih untuk memastikan bahwa teknologi deteksi penyakit tanaman dapat diakses dan dimanfaatkan secara luas oleh pengguna akhir, khususnya petani yang umumnya menggunakan perangkat smartphone dengan spesifikasi menengah.

Pengujian performa dilakukan menggunakan perangkat smartphone dengan kapasitas RAM 4 GB dan chipset kelas menengah, yang dipilih sebagai representasi realistis dari perangkat yang banyak digunakan masyarakat di lapangan. Pemilihan spesifikasi ini bukan tanpa alasan, karena sistem deteksi dini penyakit tanaman ditujukan untuk penggunaan sehari-hari di area pertanian, termasuk wilayah rural dengan keterbatasan infrastruktur teknologi. Dengan menggunakan perangkat yang tidak tergolong kelas atas, evaluasi performa menjadi lebih relevan dan mencerminkan kondisi penggunaan sebenarnya.

Hasil pengujian menunjukkan bahwa aplikasi deteksi penyakit tanaman berbasis CNN yang dikembangkan dalam penelitian ini memiliki konsumsi memori yang relatif rendah. Selama aplikasi berjalan dan melakukan proses inferensi, penggunaan RAM tercatat berada pada rentang 80 MB hingga 110 MB. Nilai ini tergolong efisien untuk sebuah aplikasi berbasis *deep learning*, mengingat model CNN pada umumnya dikenal memiliki kebutuhan memori yang cukup besar. Rendahnya konsumsi memori ini menunjukkan bahwa sistem telah dirancang dan dioptimasi secara cermat untuk dapat beroperasi pada perangkat dengan sumber daya terbatas. Efisiensi penggunaan memori tersebut berdampak langsung pada stabilitas sistem secara keseluruhan.

Aplikasi mampu berjalan berdampingan dengan berbagai fungsi lain pada smartphone tanpa memicu gangguan seperti *lag*, penurunan respons sistem, maupun *crash* aplikasi. Kondisi ini sangat penting dalam skenario penggunaan nyata, di mana pengguna sering kali menjalankan beberapa aplikasi secara bersamaan. Janarthan et al., (2022) juga telah mendemonstrasikan keberhasilan implementasi solusi *deep learning* berbasis mobile untuk deteksi penyakit tanaman secara langsung di lapangan menggunakan perangkat

smartphone, yang memperkuat validitas pendekatan mobile-first yang diterapkan dalam penelitian ini.

Keberhasilan dalam menekan penggunaan memori tidak terlepas dari strategi optimasi inferensi yang diterapkan pada tahap deployment model. Dalam penelitian ini, TensorFlow Lite digunakan sebagai framework inferensi utama karena kemampuannya dalam mengakomodasi kebutuhan komputasi pada perangkat mobile. TensorFlow Lite menyediakan berbagai mekanisme optimasi yang secara khusus dirancang untuk menyesuaikan eksekusi model *deep learning* dengan keterbatasan perangkat edge, baik dari sisi memori maupun kecepatan pemrosesan.

Teknik *memory buffer reuse* memungkinkan penggunaan kembali alokasi memori antar lapisan jaringan yang tidak berjalan secara bersamaan, sehingga total kebutuhan memori selama inferensi dapat ditekan secara signifikan. Sementara itu, strategi *operation fusion* menggabungkan beberapa operasi komputasi yang berurutan menjadi satu operasi terpadu, sehingga mengurangi frekuensi alokasi dan pelepasan memori. Model MobileNetV2 yang telah dikonversi ke format TensorFlow Lite mampu dijalankan secara efisien pada perangkat dengan RAM terbatas tanpa menunjukkan lonjakan penggunaan memori. Teknik optimasi yang diterapkan bekerja secara efektif dan konsisten selama proses inferensi berlangsung.

Efisiensi yang dicapai bukan bersifat insidental, melainkan merupakan hasil dari perancangan sistem yang terstruktur dan berbasis pada praktik optimasi yang telah teruji. Selain TensorFlow Lite, sejumlah penelitian juga menunjukkan bahwa framework lain, seperti TVM, mampu memberikan performa inferensi yang kompetitif pada model CNN ringan. Framework ini bahkan dilaporkan dapat menghasilkan konsumsi memori yang lebih rendah dan latensi yang sebanding, khususnya pada arsitektur seperti MobileNet. Fakta ini memperkuat pandangan bahwa keberhasilan implementasi edge AI tidak hanya ditentukan oleh pemilihan arsitektur model, tetapi juga sangat dipengaruhi oleh framework inferensi dan strategi optimasi yang digunakan.

Jika ditinjau dari sudut pandang perangkat keras, kinerja inferensi model deep learning pada smartphone tidak hanya ditentukan oleh arsitektur algoritma yang digunakan, tetapi juga sangat dipengaruhi oleh kemampuan komputasi CPU serta rancangan sistem internal perangkat tersebut. Dalam lingkungan *edge computing*, seluruh proses inferensi dilakukan secara lokal tanpa dukungan server eksternal, sehingga beban pemrosesan sepenuhnya ditangani oleh perangkat pengguna. Kondisi ini menjadikan spesifikasi perangkat keras sebagai faktor krusial yang menentukan kecepatan, stabilitas, dan efisiensi sistem secara keseluruhan.

Smartphone umumnya dirancang untuk penggunaan serbaguna, bukan untuk komputasi intensif seperti inferensi deep learning secara berkelanjutan. Kemampuan CPU, jumlah inti prosesor, arsitektur ARM yang digunakan, serta manajemen thread dan memori menjadi variabel penting yang memengaruhi performa inferensi. Model CNN yang dijalankan pada perangkat mobile harus mampu beradaptasi dengan keterbatasan tersebut agar tetap memberikan respons yang cepat dan stabil bagi pengguna akhir.

Hirsch et al., (2025) menyimpulkan bahwa meskipun pendekatan klaster smartphone dapat dimanfaatkan untuk menjalankan inferensi Edge AI, latensi total yang dihasilkan masih sangat bergantung pada jenis perangkat yang digunakan serta mekanisme *load balancing* yang diterapkan. Penelitian tersebut menunjukkan bahwa heterogenitas perangkat dalam satu klaster dapat menyebabkan ketidakseimbangan beban komputasi, sehingga sebagian smartphone menjadi bottleneck dalam proses inferensi. Bahkan, dalam beberapa skenario, performa klaster smartphone dilaporkan masih kalah cepat dibandingkan platform lain seperti *single-board computer* (SBC) yang memiliki arsitektur perangkat keras yang lebih konsisten dan terfokus pada komputasi.

Peningkatan performa inferensi pada perangkat mobile tidak dapat dicapai hanya dengan menambah jumlah perangkat atau memanfaatkan klusterisasi. Sebaliknya, efisiensi inferensi sangat ditentukan oleh kesesuaian antara karakteristik model, kemampuan CPU, serta strategi distribusi beban kerja. Dalam aplikasi pertanian berbasis mobile, pendekatan klusterisasi juga kurang praktis karena pengguna umumnya hanya mengandalkan satu perangkat smartphone di lapangan. Selain aspek klusterisasi, perbedaan performa antar perangkat smartphone juga menjadi perhatian penting. Ignatov, et al., (2019) menunjukkan bahwa skor *AI Benchmark* yang digunakan untuk mengukur performa inferensi deep learning pada berbagai smartphone memperlihatkan variasi kinerja yang sangat signifikan antara perangkat kelas menengah dan perangkat flagship.

Perbedaan ini mencerminkan variasi dalam kecepatan inferensi, efisiensi penggunaan memori, serta kemampuan perangkat dalam menangani beban komputasi deep learning secara lokal. Smartphone kelas flagship umumnya dilengkapi CPU yang lebih kuat, cache yang lebih besar, serta dukungan akselerasi perangkat keras yang lebih baik dibandingkan perangkat kelas menengah. Ignatov, et al., (2019) juga menegaskan bahwa performa inferensi yang baik tidak selalu bergantung pada spesifikasi perangkat kelas atas. Dengan optimasi yang tepat, model deep learning dapat dijalankan secara efisien pada perangkat kelas menengah dengan hasil yang masih dapat diterima. Hal ini membuka peluang bagi pengembangan aplikasi berbasis Edge AI yang inklusif dan dapat diakses oleh lebih banyak pengguna tanpa harus bergantung pada perangkat mahal.

Dalam penelitian ini, capaian performa MobileNetV2 pada smartphone kelas menengah menjadi indikator penting keberhasilan pendekatan optimasi yang diterapkan. Meskipun dijalankan pada perangkat dengan keterbatasan CPU dan memori dibandingkan perangkat flagship, model yang telah dioptimasi tetap mampu memberikan waktu inferensi yang cepat dan penggunaan memori yang efisien. Arsitektur MobileNetV2 yang ringan, ketika dikombinasikan dengan strategi optimasi yang tepat, mampu beradaptasi dengan karakteristik perangkat keras yang terbatas tanpa kehilangan fungsi utama sistem.

Keberhasilan ini juga menegaskan bahwa pemilihan arsitektur model yang sesuai dengan karakteristik perangkat target merupakan langkah strategis dalam pengembangan sistem Edge AI. Alih-alih memaksakan model CNN berukuran besar dengan kompleksitas tinggi, penggunaan model ringan yang dioptimasi justru menghasilkan keseimbangan yang lebih baik antara akurasi, kecepatan, dan efisiensi sumber daya. Pendekatan ini sangat relevan untuk aplikasi pertanian, di mana keandalan sistem dan kemudahan penggunaan

lebih diutamakan dibandingkan peningkatan akurasi yang marginal. Garg et al., (2021) dalam pengembangan sistem CropCare berbasis IoT juga membuktikan bahwa sistem deteksi penyakit tanaman berbasis perangkat mobile dapat beroperasi secara real-time dan berkelanjutan di lingkungan pertanian nyata, mendukung temuan penelitian ini mengenai kelayakan implementasi edge AI di sektor pertanian.

Analisis komparatif dengan model CNN konvensional turut memperkuat temuan penelitian ini. Meskipun model VGG16 menunjukkan akurasi sedikit lebih tinggi, yaitu 95,1%, ukuran file model yang mencapai 528 MB menjadikannya tidak praktis untuk diunduh dan dijalankan oleh pengguna dengan keterbatasan kuota internet dan kapasitas penyimpanan. Sebaliknya, MobileNetV2 hanya memiliki ukuran sekitar 14 MB, sehingga jauh lebih efisien dan realistis untuk diterapkan di lapangan. Paymode & Malode, (2022) juga melaporkan bahwa penggunaan transfer learning pada arsitektur CNN ringan mampu menghasilkan performa klasifikasi penyakit tanaman yang sebanding dengan arsitektur besar seperti VGG, dengan keunggulan signifikan dalam hal efisiensi komputasi dan kecepatan inferensi.

Chand dan Assaf (2024) yang menjelaskan bahwa model CNN ringan mampu mencapai akurasi yang sebanding dengan model pra-latih berarsitektur kompleks, sekaligus secara signifikan mengurangi kompleksitas dan waktu eksekusi. Velarati et al., (2024) juga mengemukakan bahwa penggunaan MobileNetV2 dengan pendekatan *transfer learning* memberikan peningkatan kinerja yang signifikan dibandingkan CNN konvensional tanpa *transfer learning*, baik dari sisi akurasi maupun stabilitas hasil.

KESIMPULAN

Penelitian ini membuktikan bahwa optimasi algoritma CNN berbasis arsitektur MobileNetV2 merupakan pendekatan yang efektif dan efisien untuk deteksi dini penyakit tanaman pada perangkat mobile. Model berhasil mencapai akurasi 94,5%, precision 94,1%, recall 93,8%, dan F1-score 94,0%, dengan ukuran model 14 MB dan waktu inferensi 120 milidetik pada smartphone RAM 4 GB. Dibandingkan VGG16 (akurasi 95,1%, ukuran 528 MB), MobileNetV2 jauh lebih efisien dengan pengorbanan akurasi yang sangat minimal. Penerapan edge computing berhasil mengeliminasi ketergantungan terhadap konektivitas internet, menjadikan sistem dapat beroperasi secara offline di wilayah pertanian terpencil. Penelitian ini memiliki keterbatasan pada cakupan dataset PlantVillage yang bersifat laboratoris, pengujian pada satu jenis perangkat, dan belum adanya validasi lapangan. Penelitian lanjutan disarankan mencakup validasi di kondisi lapangan nyata, integrasi metode explainable AI (Grad-CAM), perluasan ke komoditas lokal Indonesia, serta eksplorasi teknik kompresi model seperti pruning dan knowledge distillation.

DAFTAR PUSTAKA

- Ahmad, A., Saraswat, D., & El Gamal, A. (2023). A survey on using deep learning techniques for plant disease diagnosis and recommendations for development of appropriate tools. *Smart Agricultural Technology*, 3, 100083. <https://doi.org/10.1016/j.atech.2022.100083>
- Farihah, N., Mulianingrum, R. L., Valencia, M., Handayani, S., Agastya, S. R., Dira, Z., Zhavira, M., Naufal, M., & Anggi Pramunendar, R. (2025). Deteksi Dini Penyakit Daun Padi menggunakan Integrasi GLCM dan KNN. *Journal.Eng.Unila.Ac.IdN FarihahJurnal Informatika Dan Teknik Elektro Terapan*, 2025·*journal.Eng.Unila.Ac.Id*, 13(3), 3517261. <https://doi.org/10.23960/jitet.v13i3.6543>
- Garg, G., Gupta, S., Mishra, P., ... A. V.-I. I. of, & 2021, U. (2021). CROPCARE: An intelligent real-time sustainable IoT system for crop disease detection using mobile vision. *Ieeexplore.Ieee.OrgG Garg, S Gupta, P Mishra, A Vidyarthi, A Singh, A AliIEEE Internet of Things Journal*, 2021·*ieeexplore.Ieee.Org*. <https://doi.org/10.1109/JIOT.2021.3109040>
- Hirsch, M., Mateos, C., Sensors, T. M.-, & 2025, U. (2025). Exploring smartphone-based edge AI inferences using real testbeds. *Mdpi.ComM Hirsch, C Mateos, TA MajchrzakSensors*, 2025·*mdpi.Com*. <https://www.mdpi.com/1424-8220/25/9/2875>
- Hughes, D. P., & Salathe, M. (2015). *An open access repository of images on plant health to enable the development of mobile disease diagnostics*. <https://arxiv.org/pdf/1511.08060>
- Ignatov ETH Zurich, A., Zurich, E., Kulik, A., Yang, S., Wang, K., Baum, F., Wu, M., Xu, L., & Van Gool, L. (2019). Ai benchmark: All about deep learning on smartphones in 2019. *Ieeexplore.Ieee.OrgA Ignatov, R Timofte, A Kulik, S Yang, K Wang, F Baum, M Wu, L Xu, L Van Gool2019 IEEE/CVF International Conference on Computer Vision Workshop*, 2019·*ieeexplore.Ieee.Org*. <https://ieeexplore.ieee.org/abstract/document/9022101/>
- Jackulin, C., Sensors, S. M.-M., & 2022, undefined. (2022). A comprehensive review on detection of plant disease using machine learning and deep learning approaches. *ElsevierC Jackulin, S MurugavalliMeasurement: Sensors*, 2022·*Elsevier*, 24. <https://doi.org/10.1016/J.MEASEN.2022.100441>
- Janarthan, S., Thuseethan, S., Rajasegarar, S., & Yearwood, J. (2022). P2OP—Plant Pathology on Palms: A deep learning-based mobile solution for in-field plant disease detection. *ElsevierS Janarthan, S Thuseethan, S Rajasegarar, J YearwoodComputers and Electronics in Agriculture*, 2022·*Elsevier*, 202. <https://doi.org/10.1016/J.COMPAG.2022.107371>
- Khan, A. T., Jensen, S. M., Khan, A. R., & Li, S. (2023). Plant disease detection model for edge computing devices. *Frontiers in Plant Science*, 14. <https://doi.org/10.3389/FPLS.2023.1308528/FULL>
- Li, L., Zhang, S., & Wang, B. (2021). Plant disease detection and classification by deep learning—a review. *Ieeexplore.Ieee.OrgL Li, S Zhang, B WangIEEE Access*, 2021·*ieeexplore.Ieee.Org*, 9, 56683–56698.

- <https://doi.org/10.1109/ACCESS.2021.3069646>
- Mifthauddin, A., Lutfi, M., IT, Z. S.-J. M., & 2025, U. (2025). Comparison of MobileNetv2 and MobileNetv3 architectures in rice leaf disease classification using transfer learning. *Ejournal.Isha.or.IdA Mifthauddin, M Lutfi, ZN SaadahJurnal Mandiri IT, 2025·ejournal.Isha.or.Id.*
<https://ejournal.isha.or.id/index.php/Mandiri/article/view/459>
- Pangestu, D., ... O. A.-J. (Jurnal I., & 2025, undefined. (2025). Klasifikasi Penyakit pada Tanaman Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network. *Ejournal.Uin-Suka.Ac.IdDA Pangestu, OQ Aziz, C CrysdianJISKA (Jurnal Informatika Sunan Kalijaga), 2025·ejournal.Uin-Suka.Ac.Id, 10(2), 235–248.*
<https://ejournal.uin-suka.ac.id/saintek/JISKA/article/view/4608>
- Paymode, A., & Malode, V. (2022). Transfer learning for multi-crop leaf disease image classification using convolutional neural network VGG. *ElsevierAS Paymode, VB MalodeArtificial Intelligence in Agriculture, 2022·Elsevier.*
<https://doi.org/10.1016/J.AIIA.2022.01.004>
- Prasetyo, P. T. U., Santoso, B., & Kacung, S. (2025). *Sistem deteksi penyakit pada daun tanaman kentang menggunakan metode CNN arsitektur VGG-Net.*
https://scholar.google.co.id/scholar?hl=id&as_sdt=0%2C5&q=Prasetyo%2C+P.+T.+U.%2C+Santoso%2C+B.%2C+%26+Kacung%2C+S.+%282025%29.+Sistem+deteksi+penyakit+pada+daun+tanaman+kentang+menggunakan+metode+CNN+arsitektur+VGG-Net.+Jurnal+Informatika+Teknologi+dan+S
- Qur, & Bahri, S. (2024). Optimalisasi Model Convolutional Neural Network dengan Arsitektur MobileNetV2 Pada Sistem Otomatis Deteksi Penyakit Tanaman Jagung Berdasarkan Citra Daun. *Jurnal.Bsi.Ac.IdTH Qur'ani, S Bahri, G GunawanSimpatik: Jurnal Sistem Informasi Dan Informatika, 2025·jurnal.Bsi.Ac.Id, 4(1).*
<https://jurnal.bsi.ac.id/https://jurnal.bsi.ac.id/index.php/simpatik/article/view/9976>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. *Openaccess.Thecvf.ComM Sandler, A Howard, M Zhu, A Zhmoginov, LC ChenProceedings of the IEEE Conference on Computer Vision and, 2018·openaccess.Thecvf.Com, 4510–4520.*
<https://doi.org/10.1109/CVPR.2018.00474>
- Sari, P. (2024). Analisis Performa Algoritma CNN dalam Klasifikasi Citra Medis Berbasis Deep Learning. *Jurnal.Geinrafflesia.ComNP SariJurnal Komputer, 2024·jurnal.Geinrafflesia.Com, 2(2), 87–92.*
<https://jurnal.geinrafflesia.com/index.php/JK/article/view/113>
- Shafik, W., Tufail, A., Namoun, A., De Silva, L. C., & Apong, R. A. A. H. M. (2023). A systematic literature review on plant disease detection: motivations, classification techniques, datasets, challenges, and future trends. *Ieeexplore.Ieee.OrgW Shafik, A Tufail, A Namoun, LC De Silva, RAAHM ApongIeee Access, 2023·ieeexplore.Ieee.Org, 11, 59174–59203.* <https://doi.org/10.1109/ACCESS.2023.3284760>
- Shoib, M., Shah, B., El-Sappagh, S., Ali, A., Ullah, A., Alenezi, F., Gechev, T., Hussain, T., & Ali, F. (2023). An advanced deep learning models-based plant disease detection: A

review of recent research. *Frontiers in Plant Science*, 14.
<https://doi.org/10.3389/FPLS.2023.1158933/FULL>

Tugrul, B., Elfatimi, E., & Eryigit, R. (2022). Convolutional neural networks in detection of plant leaf diseases: A review. *Mdpi.ComB Tugrul, E Elfatimi, R EryigitAgriculture, 2022·mdpi.Com, 12(8)*. <https://doi.org/10.3390/AGRICULTURE12081192>

Velarati, K., Sari, C. A., & Rachmawanto, E. H. (2024). A Comparison of Convolutional Neural Network (CNN) and Transfer Learning MobileNetV2 Performance on Spices Images Classification. *Jurnal.Polibatam.Ac.IdK Velarati, CA Sari, EH RachmawantoJournal of Applied Informatics and Computing, 2024·jurnal.Polibatam.Ac.Id, 8(2)*. <https://jurnal.polibatam.ac.id/index.php/JAIC/article/view/8622>

Copyright holder:

lin Tarsini (2026)

First publication right:

Insight : International Journal of Social Research

This article is licensed under:

