

Klasifikasi Penyakit Tanaman Cabai Rawit Menggunakan CNN Berbasis MobileNetV2 dan SE-Attention

Tarwoto^{1*}, Nur Fadhillah² Indri Vitriana³ Eldas Puspitarini⁴ Fira Nur Zianti⁵

^{1*,2,3,4,5} Program Studi Sistem Informasi, STMIK Widya Utama, Kabupaten Banyumas, Jawa Tengah, Indonesia.

Corresponding Email: tarwoto@swu.ac.id^{1*}

Histori Artikel:

Dikirim 21 Agustus 2026; Diterima dalam bentuk revisi 04 September 2026; Diterima 11 September 2026; Diterbitkan 28 September 2026. Semua hak dilindungi oleh Lembaga Penelitian dan Pengabdian Masyarakat (LPPM) STMIK Indonesia Banda Aceh.

Abstrak

Penyakit pada daun cabai rawit (*Capsicum frutescens* L) menjadi salah satu penyebab utama penurunan produktivitas panen. Kendala utama implementasi sistem deteksi otomatis berbasis deep learning adalah penurunan akurasi pada pengujian kross-domain, di mana citra tangkapan kamera smartphone di lapangan memiliki noise latar belakang yang kompleks dibanding dataset laboratorium. Penelitian ini bertujuan mengusulkan arsitektur SE-MobileNetV2 dengan mengintegrasikan modul Squeeze-and-Excitation (SE) untuk meningkatkan ketahanan klasifikasi kross-domain sekaligus mempertahankan efisiensi memori untuk perangkat seluler. Pengujian dilakukan pada 675 citra uji kross-domain (200 citra benchmark Kaggle dan 75 foto smartphone) yang terbagi dalam lima kelas kondisi daun. Hasil eksperimen menunjukkan bahwa SE-MobileNetV2 berhasil meraih akurasi total tertinggi sebesar 91,27%, presisi weighted average 92,09%, recall 91,27%, dan F1-score 91,41%. Capaian ini mengungguli MobileNetV2 Standar (akurasi 90,55%) serta jauh melampaui model VGG16 (akurasi 84,00%). Integrasi mekanisme channel attention terbukti efektif menekan gangguan latar belakang tanah dan bayangan, sehingga meningkatkan presisi kelas Spot hingga 84,75% dan Whitefly hingga 100,00%. Dari aspek efisiensi komputasi, SE-MobileNetV2 hanya membutuhkan memori sebesar ~14,8 MB, jauh lebih ringkas dibandingkan VGG16 (~528 MB). Dengan demikian, SE-MobileNetV2 terbukti mencapai keseimbangan optimal antara ketahanan akurasi lapangan dan efisiensi ukuran berkas, menjadikannya model yang sangat ideal untuk diimplementasikan secara luring (offline) pada perangkat smartphone petani.

Kata Kunci: *Capsicum frutescens* L; Convolutional Neural Network; Citra Smartphone; Klasifikasi Penyakit Cabai Rawit; MobileNetV2; Squeeze-and-Excitation Attention.

Abstract

Diseases affecting bird's eye chili (*Capsicum frutescens* L) leaves are a primary cause of reduced harvest productivity. A major challenge in implementing deep learning-based automated detection systems is the drop in accuracy during cross-domain testing, where smartphone images captured in the field contain complex background noise compared to laboratory datasets. This study proposes an SE-MobileNetV2 architecture that integrates a Squeeze-and-Excitation (SE) module to enhance cross-domain classification robustness while maintaining memory efficiency for mobile devices. Testing was conducted on 675 cross-domain images (200 from a Kaggle benchmark dataset and 75 smartphone photos) categorized into five leaf condition classes. Experimental results demonstrate that SE-MobileNetV2 achieved the highest overall accuracy at 91.27%, with a weighted average precision of 92.09%, recall of 91.27%, and F1-score of 91.41%. These results outperform the standard MobileNetV2 (90.55% accuracy) and significantly surpass the VGG16 model (84.00% accuracy). Integrating the channel attention mechanism proved effective in mitigating background interference from soil and shadows, thereby boosting precision for the "Spot" class to 84.75% and the "Whitefly" class to 100.00%. Regarding computational efficiency, SE-MobileNetV2 requires only ~14.8 MB of memory, making it far more compact than VGG16 (~528 MB). Thus, SE-MobileNetV2 achieves an optimal balance between robust field accuracy and file size efficiency, making it an ideal model for offline implementation on farmers' smartphones.

Keyword: *Capsicum frutescens* L; Cayenne Pepper Disease Classification; Convolutional Neural Network; MobileNetV2; Smartphone Images; Squeeze-and-Excitation Attention.

1. Pendahuluan

Cabai rawit (*Capsicum frutescens* L.) merupakan salah satu komoditas hortikultura strategis di Indonesia yang memiliki nilai ekonomi tinggi dan tingkat konsumsi masyarakat yang besar. Febriansyah *et al.*, (2024) menyatakan bahwa cabai rawit memiliki peran penting dalam sektor pertanian karena permintaan pasar yang terus meningkat. Namun, upaya peningkatan produksi cabai rawit secara konsisten dihadapkan pada ancaman serangan berbagai jenis penyakit tanaman, khususnya yang menyerang organ daun, seperti leaf curl (daun keriting), leaf spot (bercak daun), serangan whitefly (kutu putih), dan yellowish (daun menguning). Tasmi, (2023) serta Algiffari *et al.*, (2026) menegaskan bahwa penyakit daun pada tanaman cabai dapat menurunkan kualitas tanaman dan berpotensi mengurangi hasil panen secara signifikan. Penyakit yang tidak teridentifikasi dan tidak tertangani secara dini dapat menyebabkan penurunan kualitas hasil panen hingga risiko gagal panen. Oleh karena itu, sistem identifikasi penyakit yang cepat, akurat, dan mudah diakses oleh petani di lapangan sangat dibutuhkan untuk mendukung tindakan pencegahan secara tepat waktu.

Dalam beberapa tahun terakhir, teknologi computer vision berbasis deep learning, khususnya Convolutional Neural Network (CNN), telah menunjukkan peningkatan performa yang baik dalam otomatisasi klasifikasi citra penyakit tanaman. Fitrony *et al.*, (2025) menunjukkan bahwa CNN mampu memberikan hasil yang baik dalam klasifikasi penyakit tanaman melalui pendekatan transfer learning. Penelitian lain oleh Simanjutak *et al.*, (2025) juga membuktikan bahwa CNN dapat digunakan untuk mengidentifikasi jenis penyakit pada tanaman cabai rawit dengan tingkat akurasi yang cukup baik. Banyak penelitian terdahulu mengimplementasikan arsitektur CNN berparameter besar seperti VGG16 atau ResNet untuk memperoleh akurasi klasifikasi yang tinggi. Shah *et al.*, (2023) menjelaskan bahwa arsitektur besar sering kali memberikan performa yang kuat pada tugas deteksi penyakit tanaman, tetapi membutuhkan sumber daya komputasi yang besar.


Walaupun arsitektur tersebut sangat tangguh, kompleksitas komputasinya membutuhkan memori dan daya komputasi (computational power) yang sangat besar. Hal ini menjadi kendala utama ketika model akan diimplementasikan pada perangkat bergerak atau edge devices milik petani yang memiliki keterbatasan sumber daya (resource-constrained devices). Ristanti (2024) menegaskan bahwa perbandingan antara VGG16 dan MobileNetV2 menunjukkan adanya kompromi antara akurasi dan efisiensi komputasi. Untuk mengatasi masalah efisiensi, arsitektur ringan seperti MobileNetV2 dirancang khusus agar dapat berjalan secara efisien pada perangkat seluler dengan jumlah parameter yang jauh lebih sedikit. Sandler *et al.*, (2018) memperkenalkan MobileNetV2 sebagai arsitektur yang menggunakan inverted residuals dan linear bottlenecks untuk mencapai efisiensi tinggi. Penelitian Xu *et al.*, (2025) menunjukkan bahwa pengembangan MobileNetV2 yang sangat ringan dapat tetap menghasilkan akurasi tinggi pada klasifikasi penyakit tanaman, dengan dukungan mekanisme aktivasi dan perhatian. Selain itu, Gulzar (2023) dan Bahadur *et al.*, (2022) juga menunjukkan bahwa MobileNetV2 cukup efektif untuk klasifikasi citra berbasis deep transfer learning.

Namun, efisiensi komputasi pada MobileNetV2 sering kali berdampak pada penurunan kemampuan model dalam mengekstraksi fitur-fitur spasial yang halus ketika dihadapkan pada citra daun dengan noise atau latar belakang yang rumit. Penelitian Mashuri *et al.*, (2024) menunjukkan bahwa arsitektur VGG16 mampu menghasilkan akurasi tinggi pada klasifikasi penyakit daun cabai, tetapi model tersebut memiliki jumlah parameter yang besar. Di sisi lain, penelitian Hassan *et al.*, (2026) menunjukkan bahwa MobileNetV2 masih dapat digunakan secara efektif untuk klasifikasi penyakit tanaman, meskipun tetap memerlukan peningkatan pada kemampuan fokus fitur. Penelitian Ma *et al.*, (2023) juga mengindikasikan bahwa penambahan mekanisme perhatian pada MobileNetV2 dapat meningkatkan performa klasifikasi citra. Untuk mengatasi research gap tersebut, penelitian ini mengusulkan integrasi mekanisme Squeeze-and-Excitation (SE) Attention ke dalam arsitektur MobileNetV2. Hu *et al.*, (2018) menjelaskan bahwa SE-Attention bekerja dengan cara merekapitulasi hubungan antar-saluran fitur secara adaptif (feature channel re-weighting), sehingga model dapat lebih terfokus menyoroti area lesi penyakit pada daun cabai rawit dan

mengabaikan informasi latar belakang yang tidak relevan tanpa menambah beban parameter secara signifikan. Sejalan dengan itu, Askale *et al.*, (2026) menunjukkan bahwa arsitektur MobileNetV2 yang dipadukan dengan mekanisme attention dan squeeze-and-excitation mampu meningkatkan efisiensi sekaligus akurasi dalam deteksi penyakit daun.

2. Metode Penelitian


Alur penelitian ini mencakup serangkaian tahapan yang tersusun secara sistematis, dimulai dari pengumpulan data citra, prapemrosesan untuk meningkatkan kualitas input, perancangan arsitektur model, hingga proses pelatihan (*training*). Setelah itu, dilakukan evaluasi kinerja model pada skema *cross-domain* serta analisis efisiensi untuk mengetahui kemampuan model dalam menghasilkan klasifikasi yang akurat dan ringan digunakan.



Gambar 1. Alur Penelitian

2.1 Pengumpulan dan Pembagian Dataset

Penelitian ini menggunakan dua sumber data utama untuk memenuhi kebutuhan pelatihan model dan evaluasi ketahanan (*robustness*) lintas domain dengan dataset benchmark dari situs (Kaggle) yang digunakan sebagai data utama untuk proses pelatihan (*training*) dan validasi (*validation*). Dataset ini terdiri dari citra daun cabai rawit yang terbagi ke dalam 5 kategori penyakit: leaf curl, leaf spot, whitefly, yellowish, dan healthy (daun sehat) Ristanti *et al.*, (2024). Berikut adalah representasi sampel citra untuk 5 kategori penyakit tanaman cabai rawit dapat dilihat pada gambar 2.



Gambar 2. (a) Leaf Curl; (b) Healthy; (c) Leaf Spot; (d) Leaf Whitefly; (e) Yellowish

Penelitian ini juga menggunakan dataset yang di ambil menggunakan kamera smartphone secara khusus sebagai data pengujian (*test set*) tambahan dalam skema *cross-domain* testing. Sebanyak 75 citra nyata diambil secara langsung di lahan pertanian menggunakan kamera smartphone (15 citra per kategori penyakit). Citra ini memiliki variasi pencahayaan alami, latar belakang tanah/tanaman lain yang kompleks, serta sudut pengambilan gambar yang tidak seragam Aulia & Husna (2025). Total data uji (*test set*) yang digunakan pada tahap evaluasi akhir berjumlah

675 citra, yang merupakan gabungan dari 200 citra benchmark Kaggle (40 citra per kelas) dan 75 citra smartphone (15 citra per kelas). Rincian distribusi dataset disajikan pada Tabel 1.

Tabel 1. Distribusi Dataset Penyakit Daun Cabai Rawit

Penyakit	Data Training	Data Validasi	Data Test	Data Smartphone	Total Data
Leaf Curl	40	40	40	15	135
Leaf Spot	40	40	40	15	135
Whitefly	40	40	40	15	135
Yellowish	40	40	40	15	135
Healthy	40	40	40	15	135
Total	200	200	200	75	675

2.2 Augmentasi Data

Sebelum dimasukkan ke dalam model, seluruh citra melalui tahap prapemrosesan (preprocessing) sebagai berikut: Ubah Ukuran (Resizing): Dimensi citra diubah menjadi 224 x 224 piksel sesuai dengan ukuran input standar arsitektur MobileNetV2 dan VGG16. Normalisasi: Nilai intensitas piksel citra yang bernilai 0 hingga 255 dinormalisasi ke rentang [0, 1] atau [-1, 1] untuk mempercepat konvergensi proses gradient descent. Untuk mencegah terjadinya overfitting pada data latih, teknik augmentasi data diterapkan secara on-the-fly selama proses pelatihan. Augmentasi yang digunakan meliputi rotasi acak (random rotation hingga 20°), pergeseran horizontal dan vertikal (width/height shift sebesar 0,2), pembesaran/pengecilan (zoom range 0,2), serta pembalikan horizontal (horizontal flip) Zulfa *et al.*, (2023).

2.3 Perancangan Arsitektur SE-MobileNetV2

Model yang diusulkan dibangun dengan menggabungkan arsitektur dasar MobileNetV2 sebagai backbone ekstraksi fitur dan modul Squeeze-and-Excitation (SE) Attention. Backbone MobileNetV2 menggunakan Inverted Residual Block dengan Linear Bottleneck dan Depthwise Separable Convolution untuk mereduksi jumlah parameter dan beban komputasi secara drastis dibandingkan konvolusi standar. Modul SE-Attention ditempatkan setelah blok bottleneck ekstraksi fitur. Modul ini bekerja melalui dua tahapan matematis utama yaitu Squeeze serta (Kompresi Spasial) dengan fitur spasial dikompresi menjadi vektor respon saluran menggunakan Global Average Pooling (GAP), dirumuskan sebagai Shahi *et al.*, (2022).

$$z_c = F_{\{sq\}(u_c)} = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_{c(i,j)} \quad (1)$$

Di mana $H \times W$ adalah dimensi spasial fitur dan u_c adalah peta fitur saluran ke- c . Excitation (Penyesuaian Saluran) dengan mempelajari ketergantungan non-linear antar-saluran menggunakan dua lapisan Fully Connected (FC) dengan fungsi aktivasi ReLU dan Sigmoid Askale *et al.*, (2026).


$$s = F_{\{ex\}(z,W)} = \sigma(W_2 \cdot \delta(W_1 z)) \quad (2)$$

Di mana δ merepresentasikan aktivasi ReLU, σ adalah aktivasi Sigmoid, serta W_1 dan W_2 adalah bobot lapisan FC dengan rasio reduksi tertentu. Scaling: Peta fitur awal dikalikan kembali dengan bobot aktivasi s_c yang telah dipelajari ($x_c = s_c \cdot u_c$) Mekanisme ini memungkinkan model untuk secara adaptif memperkuat fitur lesi penyakit dan menekan fitur latar belakang yang tidak relevan Ma *et al.*, (2022). Setelah modul SE-Attention, ditambahkan lapisan Global Average Pooling, lapisan Dropout (sebesar 0,3) untuk mencegah overfitting, serta lapisan Dense akhir dengan fungsi aktivasi Softmax untuk menghasilkan probabilitas klasifikasi pada 5 kelas penyakit.

3. Hasil dan Pembahasan

3.1 Hasil

Pada bab ini dipaparkan hasil eksperimen pengujian tiga model Deep Learning, yaitu SE-MobileNetV2 (model yang diusulkan), MobileNetV2 Standar (baseline), dan VGG16 (model pembandingan berparameter besar). Seluruh model dievaluasi menggunakan dataset uji cross-domain (cross-domain test set) sebanyak 675 citra daun cabai rawit (*Capsicum frutescens* L.), yang terdiri dari 200 citra benchmark Kaggle dan 75 citra hasil tangkapan kamera smartphone di lapangan. Proses pelatihan seluruh model selama 20 epoch menunjukkan pola konvergensi yang cepat tanpa terindikasi overfitting ekstrem pada data validasi benchmark, dengan nilai loss meluruh di bawah 0,05. Perbandingan dinamika akurasi pelatihan dan validasi dari ketiga model yaitu SE-MobileNetV2, MobileNetV2 Standar, dan VGG16 ditunjukkan pada Gambar 3.




Gambar 3. Grafik Perbandingan Akurasi Pelatihan dan Validasi: (a) SE-MobileNetV2, (b) MobileNetV2 Standar, dan (c) VGG16

Pada tahap pengujian kross-domain menggunakan 675 citra gabungan (benchmark Kaggle dan 75 foto nyata kamera smartphone), arsitektur SE-MobileNetV2 berhasil mencatatkan kinerja tertinggi dengan akurasi total sebesar 91,27% (251 dari 675 citra berhasil diprediksi secara tepat). Capaian ini melampaui kinerja MobileNetV2 Standar yang memperoleh akurasi 90,55% serta jauh mengungguli model VGG16 yang hanya mencapai 84,00%. Secara keseluruhan, SE-MobileNetV2 juga mendominasi pada metrik rata-rata terbobot (weighted average) dengan nilai presisi sebesar 92,09%, recall 91,27%, dan F1-score 91,41%. sebagaimana dirangkum pada Tabel 2.

Tabel 2. Perbandingan Kinerja Model

Arsitektur Model	Akurasi Total	Presisi (<i>Weighted</i>)	Recall (<i>Weighted</i>)	F1-Score (<i>Weighted</i>)	Total Salah Prediksi
VGG16	84,00%	85,59%	84,00%	84,09%	44 Citra
MobileNetV2 Standar	90,55%	90,18%	90,55%	90,62%	26 Citra
SE-MobileNetV2 (Usulan)	91,27%	92,09%	91,27%	91,41%	24 Citra

Analisis performa per kelas menunjukkan bahwa integrasi modul Squeeze-and-Excitation (SE) memberikan kontribusi besar pada peningkatan daya pembeda fitur infeksi penyakit. Kelas Whitefly pada SE-MobileNetV2 meraih nilai presisi sempurna sebesar 100,00% (F1-score 94,23%), sementara kelas Yellowish mencapai F1-score tertinggi sebesar 94,44%. Peningkatan cukup baik juga terlihat pada kelas Spot, di mana presisi meningkat dari 79,69% pada MobileNetV2 Standar menjadi 84,75% pada SE-MobileNetV2. Hal ini membuktikan bahwa mekanisme pemfilteran saluran melalui Global Average Pooling dan pembobotan non-linear pada modul SE secara efektif mampu meredam noise latar belakang seperti tanah dan pantulan cahaya matahari pada foto smartphone sehingga fokus ekstraksi fitur tetap tertuju pada lesi spesifik daun cabai. Visualisasi detail sebaran prediksi dan misklasifikasi dari ketiga model disajikan pada Gambar 4.



Gambar 4. Perbandingan Confusion Matrix pada Data Uji Kross-Domain: (a) SE-MobileNetV2, (b) MobileNetV2 Standar, dan (c) VGG16.

Penurunan performa yang cukup tajam pada VGG16 (44 kesalahan prediksi) memberikan gambaran berharga terkait keterbatasan model berparameter besar dalam skenario pengujian lapangan. VGG16 mengalami degradasi recall yang cukup parah pada kelas Yellowish (74,55%) dan Whitefly (78,18%) akibat kecenderungan overfitting terhadap karakteristik visual dataset laboratorium. Tanpa adanya mekanisme attention, lapisan konvolusi standar VGG16 gagal memisahkan karakteristik lesi penyakit dari gangguan latar belakang nyata, sehingga menghasilkan banyak kesalahan prediksi ke kelas Healthy maupun Spot.

3.2 Pembahasan

Hasil uji menunjukkan bahwa SE-MobileNetV2 bekerja lebih baik dibanding MobileNetV2 standar dan VGG16 dalam klasifikasi penyakit daun cabai rawit. Temuan ini sejalan dengan Sandler et al. (2018) yang menjelaskan bahwa MobileNetV2 memang dirancang ringan dan hemat daya komputasi. Namun, pada penelitian ini, keunggulan tersebut belum cukup jika berdiri sendiri. Ketika modul Squeeze-and-Excitation ditambahkan, model menjadi lebih peka terhadap fitur penyakit yang relevan dan lebih tahan terhadap gangguan latar pada citra lapangan. Hal ini selaras dengan Hu et al. (2018) yang menjelaskan bahwa mekanisme SE dapat memberi bobot lebih besar pada saluran fitur yang benar-benar dibutuhkan.

Performa per kelas juga memperlihatkan pola yang layak dicermati. Presisi pada kelas Spot dan Whitefly meningkat, yang berarti model lebih mampu membedakan gejala penyakit dari latar yang tidak seragam. Ini cukup masuk akal karena foto dari smartphone biasanya memuat bayangan, tanah, atau daun lain yang ikut tertangkap kamera. Dalam kondisi seperti itu, model tanpa perhatian sering membaca fitur yang keliru. Hasil ini sejalan dengan Shahi et al. (2022), Xu et al. (2025), dan Ma et al. (2022), yang menunjukkan bahwa penambahan attention pada MobileNetV2 dapat memperbaiki hasil klasifikasi citra pertanian.

Jika dibandingkan dengan VGG16, SE-MobileNetV2 juga lebih layak untuk penerapan lapangan. VGG16 memang kuat dalam ekstraksi fitur, tetapi ukuran modelnya jauh lebih besar dan beban komputasinya lebih berat. Mashuri et al. (2024) dan Ristanti (2024) juga memperlihatkan bahwa model besar sering memberi hasil baik di atas kertas, tetapi kurang praktis untuk perangkat dengan sumber daya kecil. Dalam penelitian ini, ukuran berkas SE-MobileNetV2 yang jauh lebih kecil membuat model ini lebih realistis dipakai pada smartphone petani.

4. Kesimpulan dan Saran

Berdasarkan hasil pengujian, integrasi modul Squeeze-and-Excitation (SE) pada arsitektur MobileNetV2 menunjukkan peningkatan kinerja dalam klasifikasi penyakit daun cabai rawit (*Capsicum frutescens* L.) pada skenario evaluasi cross-domain. Model SE-MobileNetV2 memperoleh akurasi total sebesar 91,27%, dengan presisi 92,09%, recall 91,27%, dan F1-score 91,41% pada 675 citra uji gabungan. Pada pengujian terpisah, model ini mencapai akurasi 93,50% pada data uji Kaggle dan 73,33% pada citra smartphone. Nilai performance drop pada domain smartphone sebesar 20,17% lebih rendah dibandingkan MobileNetV2 standar dan VGG16, sehingga menunjukkan bahwa penambahan modul SE mampu meningkatkan stabilitas model terhadap perbedaan domain citra. Selain itu, model ini juga menghasilkan ukuran berkas yang jauh lebih kecil dibandingkan VGG16, sehingga lebih efisien untuk implementasi pada perangkat dengan sumber daya terbatas. Meskipun demikian, penelitian ini masih memiliki keterbatasan, terutama pada jumlah citra smartphone yang terbatas, variasi kondisi lapangan yang belum luas, serta belum dilakukannya pengujian langsung pada perangkat seluler. Oleh karena itu, penelitian selanjutnya disarankan untuk memperluas dataset dengan kondisi lingkungan yang lebih beragam, membandingkan dengan arsitektur attention lain seperti CBAM atau ECA-Net, serta melakukan on-device testing untuk menilai kinerja nyata pada perangkat mobile.

5. Daftar Pustaka

Algiffari, M. A., Abdillah, A., Amirah, A., & Tamsir, N. (2026). Klasifikasi penyakit pada daun tanaman cabai menggunakan metode convolutional neural network. *Dipaneegara Komputer Teknologi Informatika*, 17(2), 130–141. <https://doi.org/10.36774/dipakomti.v17i2.2194>

- Askale, G. T., Yibel, A. B., Taye, B. M., & Wubneh, G. D. (2026). An attention-enhanced MobileNetV2 with squeeze-and-excitation architecture for efficient potato leaf disease detection and classification. *Scientific Reports*.
- Aulia, R., & Husna, W. (2025). Klasifikasi jenis buah mangga menggunakan convolutional neural network (CNN) berbasis citra digital. *JITSI: Jurnal Ilmiah Teknologi Sistem Informasi*, 6(4), 417–421. <https://doi.org/10.62527/jitsi.6.4.473>
- Febriansyah, F., Haris, A., & Gani, M. S. (2024). Pola tanam tanaman cabai rawit (*Capsicum frutescens*) dengan kacang panjang (*Vigna sinensis* L.) terhadap populasi dan intensitas serangan hama. *AGrotekMAS Jurnal Indonesia: Jurnal Ilmu Pertanian*, 5(1), 91–99.
- Fitrony, F. A., & Utami, E. (2025). Development rice plant disease classification using CNN with transfer learning. *JURTEKSI (Jurnal Teknologi dan Sistem Informasi*, 11(4), 677–684.
- Gulzar, Y. (2023). Fruit image classification model based on MobileNetV2 with deep transfer learning technique. *Sustainability*, 15(3), 1906. <https://doi.org/10.3390/su15031906>
- Hu, J., Shen, L., & Sun, G. (2018). Squeeze-and-excitation networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 7132–7141).
- Ma, R., Wang, J., Zhao, W., Guo, H., Dai, D., Yun, Y., ... & Ma, D. (2022). Identification of maize seed varieties using MobileNetV2 with improved attention mechanism CBAM. *Agriculture*, 13(1), 11. <https://doi.org/10.3390/agriculture13010011>
- Mashuri, A. S., Sunyoto, A., & Kusnawi, K. (2024). Klasifikasi penyakit pada daun cabai menggunakan arsitektur VGG16. *Journal of Electrical Engineering and Computer (JEECOM)*, 6(2), 305–313. <https://doi.org/10.33650/jeeecom.v6i2.9116>
- Ristanti, E. P. (2024). Analisis dan perbandingan arsitektur VGG16 dan MobileNetV2 untuk klasifikasi dan identifikasi penyakit daun pada tanaman cabai menggunakan CNN. *Sci. J. Ilm. Sains dan Teknologi*, 2(9), 216–226.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. In *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 4510–4520). IEEE. <https://doi.org/10.1109/CVPR.2018.00474>
- Shah, S. R., Qadri, S., Bibi, H., Shah, S. M. W., Sharif, M. I., & Marinello, F. (2023). Comparing Inception V3, VGG 16, VGG 19, CNN, and ResNet 50: A case study on early detection of a rice disease. *Agronomy*, 13(6), 1633. <https://doi.org/10.3390/agronomy13061633>
- Shahi, T. B., Sitaula, C., Neupane, A., & Guo, W. (2022). Fruit classification using attention-based MobileNetV2 for industrial applications. *PLOS ONE*, 17(2), e0264586. <https://doi.org/10.1371/journal.pone.0264586>
- Simanjutak, T. J., Saputra, K., Syahputra, H., Al Idrus, S. I., & Febrian, D. (2025). Identifikasi jenis penyakit pada tanaman cabai rawit menggunakan algoritma convolutional neural network (CNN) di Desa Bintang Kecamatan Sidikalang. *JATI (Jurnal Mahasiswa Teknik Informatika*, 9(1), 584–591.
- Tasmi, T. (2023). *Klasifikasi penyakit daun tanaman cabai menggunakan metode convolutional neural network* [Doctoral dissertation, Universitas Indo Global Mandiri].

- Xu, Y., Li, D., Li, C., Yuan, Z., & Dai, Z. (2025). LiSA-MobileNetV2: An extremely lightweight deep learning model with Swish activation and attention mechanism for accurate rice disease classification. *Frontiers in Plant Science*, 16, 1619365. <https://doi.org/10.3389/fpls.2025.1619365>
- Zulfa, A. N., Jasril, M. I., Yanto, F., & Sanjaya, S. (2023). Optimasi convolutional neural network NASNetLarge menggunakan augmentasi data untuk klasifikasi citra penyakit daun padi. *MIB: Jurnal Media Informatika Budidarma*, 7(2), 696–706. <https://doi.org/10.30865/mib.v7i2.6056>