

Pengembangan Deteksi Hama Daun Sawi Berbasis Web dengan Model NASNetMobile

Swelandiah Endah Pratiwi¹⁾, Paranita Asnur^{2*)}, Iqbal Nur Kholish³⁾, Dody Pernadi⁴⁾

¹⁾ Teknik Komputer, Universitas Gunadarma

²⁾ Agroteknologi, Universitas Gunadarma

³⁾ Informatika, Universitas Gunadarma

⁴⁾ Sistem Informasi, Universitas Gunadarma

¹⁾ swelandiah@staff.gunadarma.ac.id, ²⁾ paranita@staff.gunadarma.ac.id, ³⁾ iqbalnurkholish24@gmail.com,

⁴⁾ dody_ernadi@staff.gunadarma.ac.id

ABSTRACT

Green mustard (Brassica rapa var. parachinensis) is an important horticultural commodity in Indonesia with high economic value, but its production has declined due to leaf pest attacks such as armyworms, Plutella larvae, and aphids. Manual pest detection, which is time-consuming and error-prone, poses a major challenge for effective early control. This research aims to develop a web-based pest detection system for mustard green leaves using the NASNetMobile deep learning model and sequential architecture to provide a practical, accurate, and easily accessible solution for farmers. NASNetMobile is designed to deliver high classification accuracy while remaining lightweight and efficient, making it suitable for mobile devices and low-resource environments. The research method includes collecting 1000 annotated leaf images from the Kaggle dataset, preprocessing with augmentation and normalization, training CNN models, evaluating performance, and implementing a Flask-based web prototype. The best model achieved 94% validation accuracy with a training time of just 14 seconds, and testing on 50 new images yielded 96% detection accuracy (100% on pest-infected and 92% on pest-free leaves). While this system offers fast, accessible, and highly accurate detection to support precision agriculture, challenges remain in generalizing results to real-world conditions, indicating the need for further development with more diverse datasets and field testing to ensure broader reliability.

Keywords: classification, convolutional neural network, data augmentation, image segmentation, precision agriculture

I. PENDAHULUAN

Sawi hijau (*Brassica rapa* var. *parachinensis*) merupakan salah satu komoditas hortikultura penting di Asia, terutama di Indonesia, yang memiliki nilai ekonomi tinggi. Tanaman ini populer di kalangan masyarakat karena kandungan gizinya yang tinggi, mudah dibudidayakan, dan memiliki permintaan pasar yang relatif stabil sepanjang tahun (Yama & Kartiko, 2020). Kondisi agroklimat Indonesia yang mendukung, seperti suhu udara yang sesuai, ketersediaan lahan subur, serta dukungan sosial-ekonomi petani lokal, menjadikan sawi hijau sebagai salah satu tanaman unggulan dalam sektor pertanian (Santoso & Widyawati, 2020). Namun demikian, produksi sawi hijau nasional mengalami penurunan dari 727.467ton pada tahun 2021 menjadi 706.305ton pada tahun 2022. Salah satu penyebab utama penurunan tersebut adalah serangan hama yang merusak daun, seperti ulat grayak (*Spodoptera litura*), ulat (*Plutella xylostella*), dan kutu daun (Aphididae) (Fattah & Ilyas, 2016). Kondisi ini menunjukkan perlunya upaya yang sistematis dan terintegrasi dalam pengendalian hama, terutama melalui deteksi dini untuk mencegah penyebaran dan kerusakan lebih lanjut.

Deteksi hama secara manual yang dilakukan dengan pemeriksaan visual satu per satu memerlukan waktu dan tenaga yang tidak sedikit, serta rentan terhadap kesalahan identifikasi, terutama bagi petani yang tidak memiliki pelatihan teknis memadai (Fattah & Ilyas, 2016). Keterlambatan mendeteksi dan mengendalikan serangan hama tidak hanya

menurunkan hasil panen tetapi juga mendorong penggunaan pestisida secara berlebihan, yang berdampak negatif pada lingkungan dan kesehatan manusia. Hal ini menunjukkan perlunya sistem deteksi otomatis yang efisien, akurat, dan mudah diakses oleh petani untuk mendukung produktivitas dan keberlanjutan budidaya sawi hijau.

Penelitian ini secara khusus bertujuan untuk mengembangkan sistem deteksi hama pada daun sawi hijau berbasis website dengan memanfaatkan metode *deep learning*, menggunakan arsitektur NASNetMobile yang ringan namun akurat, serta model Sequential yang fleksibel untuk membangun arsitektur jaringan. Sistem ini diharapkan menghasilkan prototipe aplikasi yang praktis, mudah digunakan oleh petani, mendukung deteksi hama secara cepat dan akurat, serta menjadi bagian dari transformasi digital dalam praktik pertanian presisi yang berkelanjutan.

II. TINJAUAN PUSTAKA

2.1 *Convolutional Neural Network* (CNN)

Teknologi *Convolutional Neural Network* (CNN) telah banyak digunakan dalam mendeteksi penyakit dan hama tanaman secara otomatis melalui analisis citra. CNN mampu mengenali pola visual kompleks pada gambar daun tanaman dengan akurasi tinggi (Y.-H. Wang & Su, 2022). Berbagai arsitektur CNN seperti ResNet, Inception, dan Faster R-CNN telah berhasil digunakan untuk klasifikasi penyakit tanaman dengan tingkat akurasi di atas 95% (Kamble et al., 2024; Suárez et al., 2021). Pendekatan hybrid dengan penggabungan CNN dan algoritma seperti *Support Vector Machine* (SVM) juga terbukti dapat meningkatkan akurasi klasifikasi (Annesa et al., 2020).

2.2 NASNetMobile

NASNetMobile adalah arsitektur CNN ringan yang dirancang untuk mengoptimalkan akurasi klasifikasi sambil mempertahankan efisiensi komputasi. Model ini sangat sesuai untuk diterapkan pada perangkat dengan sumber daya terbatas seperti smartphone atau perangkat IoT (Yang et al., 2020). NASNetMobile menunjukkan performa klasifikasi gambar lebih baik dibandingkan model ringan lainnya seperti MobileNet dan ShuffleNet (Yang et al., 2020; Song et al., 2023). Keunggulan utamanya adalah kemampuannya menyeimbangkan kualitas prediksi dengan kecepatan proses, mendukung penerapan pada aplikasi praktis di lapangan.

2.3 *Internet of Things* (IoT)

Integrasi teknologi *Internet of Things* (IoT) dalam sistem monitoring pertanian juga menjadi pendekatan yang semakin relevan. IoT memungkinkan pengiriman notifikasi real-time kepada petani mengenai keberadaan hama, sehingga meningkatkan respons dan pengambilan keputusan di lapangan (Thomas et al., 2023). Sistem berbasis IoT dapat mempermudah monitoring kondisi tanaman tanpa pengamatan langsung yang melelahkan, mendukung efisiensi tenaga kerja dan pengelolaan lahan secara modern.

2.4 Augmentasi Data


Selain arsitektur model, teknik augmentasi data sangat penting dalam pengembangan sistem berbasis citra. Augmentasi seperti rotasi, flipping, dan penyesuaian kontras dapat memperluas variasi data latih, membantu model menggeneralisasi lebih baik dan menghindari overfitting (Debats et al., 2016; D. Zhang, 2022; H. Zhang et al., 2024; J. Wang et al., 2025). Penggunaan citra dari UAV dan hyperspectral imaging juga menambah dimensi analisis, memungkinkan identifikasi hama dengan detail spektral yang lebih mendalam.

2.5 Gap Penelitian

Meskipun pendekatan CNN, arsitektur ringan seperti NASNetMobile, IoT, dan teknik augmentasi data telah berkembang pesat dalam penelitian klasifikasi citra tanaman, hingga kini belum ada aplikasi berbasis website yang dirancang khusus untuk mendeteksi hama pada daun sawi hijau. Celah ini menunjukkan perlunya pengembangan sistem praktis yang mudah diakses petani, mendukung deteksi cepat dan akurat sebagai bagian dari upaya transformasi digital dalam pertanian presisi.

III. METODE PENELITIAN

Penelitian ini menggunakan pendekatan berbasis algoritma *Convolutional Neural Network* (CNN) untuk mendeteksi hama pada daun sawi hijau (*Brassica rapa* var. parachinensis). Tahapan penelitian meliputi pengumpulan data, preprocessing data, pengembangan model CNN, evaluasi model, dan implementasi model dalam bentuk prototipe berbasis web. Gambar 1 berikut adalah penjelasan rinci dari setiap tahapan penelitian.




Gambar 1. Tahapan Penelitian Identifikasi Serangan Hama pada Daun Sawi

Dataset yang digunakan dalam penelitian ini diambil dari situs Kaggle dengan nama Caisim, yang berisi 1000 gambar daun sawi hijau terbagi dalam dua kelas, yaitu Sawi Tanpa Hama dan Sawi Terserang Hama. Dataset ini berisi gambar daun sawi hijau yang telah diberi anotasi, termasuk kategori daun sehat dan yang terinfeksi hama. Untuk meningkatkan kualitas data, dilakukan *preprocessing* melalui beberapa langkah, seperti augmentasi data (rotasi, flipping, dan penyesuaian kontras) guna memperkaya variasi gambar, normalisasi agar skala intensitas piksel berada dalam rentang 0-1, serta perubahan ukuran gambar menjadi 224x224 piksel agar sesuai dengan format input model CNN. Langkah-langkah ini bertujuan untuk meningkatkan akurasi model dalam mengenali pola kerusakan daun akibat hama.

Pengembangan model CNN dilakukan dengan dua arsitektur, yaitu NASNetMobile (Gambar 2) dan sequential CNN. NASNetMobile dipilih karena efisiensinya dalam menangani perangkat dengan sumber daya terbatas, sementara arsitektur sequential dirancang untuk mengeksplorasi performa model secara lebih fleksibel. Model ini dilatih dengan dataset yang dibagi menjadi 70% untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian. Selama pelatihan, optimizer Adam dengan learning rate 0,001 dan fungsi loss categorical cross-entropy digunakan untuk mengoptimalkan kinerja model. Setelah pelatihan, model diintegrasikan ke dalam prototipe berbasis web menggunakan *Framework*

Flask, memungkinkan pengguna mengunggah gambar daun sawi hijau dan mendapatkan hasil prediksi. Prototipe ini diuji dengan gambar uji baru untuk menilai akurasi serta kemudahan penggunaannya dalam praktik pertanian.



Gambar 2. Arsitektur NASNetMobile

Penelitian ini mengembangkan dan menguji tiga arsitektur CNN berbeda untuk mendeteksi hama pada daun sawi hijau. Arsitektur 1 mengombinasikan NASNetMobile sebagai *feature extractor* dengan model Sequential yang fleksibel untuk penambahan lapisan tambahan. Arsitektur ini dirancang agar memiliki akurasi tinggi sekaligus efisiensi komputasi yang mendukung penggunaan pada perangkat dengan sumber daya terbatas seperti *smartphone* atau IoT. Arsitektur 2 berfungsi sebagai *baseline* dengan desain yang lebih sederhana, memiliki kedalaman layer lebih dangkal dan jumlah filter lebih sedikit, sehingga dapat digunakan sebagai pembandingan untuk mengukur manfaat penambahan kompleksitas model. Arsitektur 3 dirancang dengan kompleksitas menengah, lebih dalam dibanding Arsitektur 2 namun lebih ringan dari Arsitektur 1, untuk mengeksplorasi keseimbangan antara akurasi dan efisiensi waktu pelatihan.



Pengujian ketiga arsitektur ini dilakukan untuk menemukan desain model yang paling sesuai dengan karakteristik data gambar daun sawi hijau serta kebutuhan penerapan praktis di lapangan.


IV. HASIL DAN PEMBAHASAN

4.1 Pembagian Data

Dataset penelitian terdiri dari gambar daun sawi hijau yang telah dianotasi sebagai “ada hama” dan “tanpa hama”. Data ini dibagi menjadi tiga subset untuk pelatihan, validasi, dan pengujian. Proporsi pembagian adalah 70% untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian.


Tabel 1 Hasil Pembagian Data

No	Training	Validation	Test
1.			
2.			
3.			
4.			
5.			
6.			
7.			

No	Training	Validation	Test
8.			
9.			
10.			

Tabel 1 menunjukkan sampel hasil pembagian data, di mana data pelatihan mendominasi proporsi karena berperan penting dalam membangun model yang kuat. Sementara itu, data validasi dan pengujian masing-masing digunakan untuk mengevaluasi performa model selama proses pelatihan maupun setelahnya.

Proses pelatihan model dilakukan menggunakan arsitektur *Convolutional Neural Network* (CNN) yang menggabungkan model NASNetMobile dan model Sequential. Data yang telah melalui tahap *preprocessing* digunakan untuk melatih model dengan membagi dataset menjadi dua bagian, yaitu data latih dan data validasi. Selama proses pelatihan, digunakan 900 data latih sebagai input, yang kemudian dibagi secara acak menjadi 90% untuk data latih dan 10% untuk data validasi. Grafik hasil pelatihan dari salah satu arsitektur yang dilatih ditampilkan pada Gambar 3 berikut ini.



Gambar 3 Grafik Pelatihan Arsitektur 1

Gambar 3 menunjukkan grafik *training progress* dari arsitektur model NASNetMobile dan Sequential. Grafik ini terbagi menjadi dua komponen utama, yaitu training loss dan validation loss, serta training accuracy dan validation accuracy. Grafik Loss menunjukkan bahwa nilai training loss dan validation loss mengalami fluktuasi dengan tren penurunan yang tidak signifikan di setiap epoch. Nilai validation loss terkecil tercatat pada epoch ke-6 dengan nilai sebesar 0,0585. Penurunan ini menunjukkan bahwa model mampu mempelajari pola dalam dataset tanpa mengalami overfitting atau underfitting yang signifikan. Grafik Accuracy menunjukkan bahwa nilai *training accuracy* dan *validation accuracy* mengalami peningkatan dan penurunan dengan tren yang positif. Peningkatan ini mengindikasikan bahwa model berhasil memahami pola dari data selama proses pelatihan. Nilai *validation accuracy* tertinggi tercatat pada epoch ke-6 dengan nilai 1,00. Namun, model memilih hasil pada akhir epoch ke-10 dengan nilai validation accuracy sebesar 94%, dan menghasilkan validation loss sebesar 0,1160 dengan waktu pelatihan selama 14 detik. Berdasarkan Gambar 3 mendukung bukti bahwa model CNN yang dilatih efektif dalam mendeteksi hama pada daun sawi. Model ini mampu membedakan ciri-ciri visual kerusakan akibat hama dengan presisi tinggi, sehingga dapat digunakan sebagai alat bantu praktis bagi petani untuk mendeteksi serangan hama secara cepat dan akurat melalui aplikasi berbasis web.

4.2 Perbandingan Model

Tabel berikut menunjukkan hasil perbandingan dari tiga arsitektur CNN yang diuji selama proses pelatihan:

Tabel 2 Hasil Pelatihan 3 Arsitektur

Arsitektur	Pembelajaran (Detik)	Validation Loss	Validation Accuracy (%)
1	14	0,1160	94%
2	14	0,6914	72%
3	12	0,3267	85%

Berdasarkan hasil yang ditunjukkan dalam tabel perbandingan model CNN yang diuji, dapat dilakukan analisis terhadap masing-masing arsitektur yang diuji selama proses pelatihan. Arsitektur 1, yang menggabungkan model NASNetMobile dengan model Sequential, menunjukkan hasil yang paling efektif dengan validation accuracy tertinggi sebesar 94% dan validation loss terkecil sebesar 0,1160. Hal ini menunjukkan bahwa kombinasi arsitektur ini mampu mempelajari karakteristik pola pada dataset dengan sangat efektif dan memiliki kemampuan generalisasi yang baik tanpa mengalami overfitting yang signifikan. Waktu yang dibutuhkan untuk melatih model ini adalah 14 detik, yang menunjukkan efisiensi dalam memahami data tanpa mengorbankan performa.

Di sisi lain, Arsitektur 2 menunjukkan hasil yang paling rendah dibandingkan dengan arsitektur lainnya, dengan validation accuracy sebesar 72% dan validation loss sebesar 0,6914. Nilai ini menunjukkan bahwa arsitektur ini memiliki kesulitan dalam memahami karakteristik data, yang mungkin disebabkan oleh pemilihan kombinasi model yang tidak optimal atau kompleksitas model yang kurang cocok dengan karakteristik dataset yang digunakan. Meski memakan waktu yang sama dengan Arsitektur 1 selama 14 detik, performa arsitektur ini tetap menunjukkan hasil yang jauh lebih rendah.

Sementara itu, Arsitektur 3 mampu menunjukkan hasil yang cukup baik dengan validation accuracy sebesar 85% dan validation loss sebesar 0,3267 dalam waktu pelatihan selama 12 detik. Meskipun waktu pelatihan yang dibutuhkan lebih cepat dibandingkan kedua arsitektur lainnya, performanya masih berada di bawah Arsitektur 1. Ini menunjukkan bahwa

meskipun model ini lebih cepat dilatih, akurasi masih dapat ditingkatkan melalui optimasi tambahan.

Berdasarkan analisis ini, dapat disimpulkan bahwa Arsitektur 1 adalah yang paling efektif, dengan akurasi tertinggi dan validation loss terkecil, menunjukkan kombinasi model NASNetMobile dan Sequential memiliki potensi yang optimal untuk digunakan dalam aplikasi berbasis machine learning, khususnya dalam mendeteksi serangan hama pada tanaman. Di sisi lain, Arsitektur 2 memiliki performa yang paling rendah dan memerlukan evaluasi lebih lanjut untuk memahami penyebabnya, sedangkan Arsitektur 3 menunjukkan waktu pelatihan yang lebih cepat dengan performa yang masih dapat ditingkatkan. Hasil ini memberikan wawasan penting dalam mengembangkan model deteksi yang lebih efektif dan efisien.

Berdasarkan hasil ini, arsitektur 1 dengan kombinasi model NASNetMobile dan Sequential adalah yang paling efektif, dengan validation accuracy tertinggi sebesar 94% dan validation loss terkecil sebesar 0,1160. Model ini menunjukkan hasil yang optimal untuk digunakan dalam aplikasi deteksi berbasis machine learning.

4.3 Uji Coba Model

Hasil pengujian dilakukan menggunakan model arsitektur A yang telah dilatih dengan 100 data uji. Model ini menghasilkan nilai akurasi sebesar 93%. Tabel 3 memperlihatkan hasil pengujian dari tiga arsitektur yang telah dilatih sebelumnya, yaitu arsitektur CNN 1, CNN 2, dan CNN 3.


Tabel 3 Nilai Akurasi Pengujian 3 Arsitektur

Arsitektur/CNN	Akurasi Pengujian (%)	Keterangan
1	93%	Akurasi tertinggi
2	62%	
3	88%	

Hasil pengujian tersebut, CNN 1 menunjukkan performa yang paling optimal dibandingkan dengan CNN 2 dan CNN 3. Hal ini dikarenakan CNN 1 memiliki arsitektur yang lebih efektif dalam mempelajari fitur dan karakteristik dari data yang digunakan selama proses pelatihan. Arsitektur CNN 1 diduga memiliki lapisan-lapisan seperti lapisan konvolusi, pooling, dan lapisan fully connected yang dirancang dengan baik sehingga mampu menangkap pola-pola penting dalam citra daun sawi, baik yang memiliki hama maupun tanpa hama. Selain itu, CNN 1 memiliki jumlah parameter dan kedalaman arsitektur yang tepat untuk menangani kompleksitas data uji tanpa mengalami masalah seperti overfitting atau underfitting. Faktor lain yang membuat CNN 1 paling optimal adalah kemampuannya dalam menggeneralisasi informasi dari data latih ke data uji dengan baik, yang ditunjukkan melalui akurasi yang tinggi sebesar 93%.

4.4 Evaluasi Confusion Matrix

Evaluasi lebih lanjut pada 50 gambar uji dari dataset sawi-Test dilakukan untuk Arsitektur 1. Hasil confusion matrix ditampilkan pada Gambar 4.




Gambar 4. *Confussion Matrix* Arsitektur 1

Hasil ini menunjukkan bahwa model CNN 1 memiliki keseimbangan yang baik antara kompleksitas model dan jumlah data yang tersedia. Dengan keseimbangan tersebut, CNN 1 tidak hanya menghafal data latih tetapi juga mampu melakukan prediksi dengan benar pada data yang belum pernah dilihat sebelumnya. Di sisi lain, CNN 2 memiliki akurasi yang lebih rendah, yaitu sebesar 62%. Hal ini mungkin disebabkan oleh arsitektur yang digunakan kurang kompleks atau tidak mampu menangkap informasi penting dari citra daun sawi. Sedangkan CNN 3, meskipun memiliki akurasi yang lebih baik (88%), diduga mengalami keterbatasan dalam jumlah parameter atau desain arsitektur dibandingkan dengan CNN 1. Oleh karena itu, berdasarkan hasil pengujian menandakan sistem memiliki kemampuan sangat baik dalam mendeteksi daun yang ada hama (tidak ada yang terlewat), meski terdapat sedikit *false positive* pada kategori tanpa hama. Arsitektur ini cocok dengan karakteristik dan kompleksitas dataset yang digunakan untuk mempelajari perbedaan antara daun sawi dengan dan tanpa hama.

4.5 Pengujian Kinerja

Pengujian kinerja dilakukan menggunakan aplikasi berbasis website yang dirancang khusus untuk menguji data baru, dengan melibatkan 50 gambar daun sawi hijau yang diperoleh dari website Kaggle dengan nama sawi-Test. Model yang digunakan dalam pengujian ini adalah NASNetMobile yang dipadukan dengan model sequential yang telah dilatih sebelumnya. Proses pengujian dilakukan untuk mengevaluasi kemampuan sistem dalam mendeteksi dua kondisi pada daun sawi, yaitu "ada hama" dan "tanpa hama". Alur pengujian dapat dilihat pada Gambar 5.

Tahapan pengujian dilakukan melalui dua langkah utama, yaitu pengguna dapat mengunggah gambar melalui tombol Choose File dan kemudian menekan tombol Submit. Selanjutnya, aplikasi akan memberikan hasil deteksi berupa "Ada Hama" atau "Tanpa Hama" berdasarkan analisis model. Gambar yang diuji berjumlah 50, yang terdiri dari 25 gambar daun sawi dengan kondisi ada hama dan 25 gambar daun sawi tanpa hama. Tampilan hasil pengujian dapat dilihat pada Gambar 5.



Gambar 5. Tampilan *Prototype* Hasil Pengujian

Hasil pengujian menunjukkan sistem berhasil mendeteksi seluruh gambar daun sawi yang terjangkit hama dengan akurasi 100%, sementara pada kategori tanpa hama tercapai akurasi 92%, sehingga total akurasi mencapai 96%. Hal ini menunjukkan kemampuan model dalam membedakan daun yang sehat dan terinfeksi secara andal. Penggunaan NASNetMobile yang dikombinasikan dengan arsitektur Sequential terbukti efektif, didukung oleh antarmuka berbasis web yang memudahkan akses dan mendukung praktik pertanian modern melalui pemantauan cepat dan akurat.

Namun, penelitian ini memiliki keterbatasan pada jumlah sampel uji yang relatif kecil, sehingga belum mencakup variasi kondisi lingkungan nyata yang lebih kompleks. Terdapat juga kesalahan pada kategori tanpa hama yang perlu diminimalkan. Selain itu, penggunaan aplikasi berbasis web memerlukan koneksi internet dan perangkat yang memadai. Oleh karena itu, diperlukan penelitian lanjutan dengan dataset lebih bervariasi dan pengujian pada kondisi lapangan untuk meningkatkan keandalan dan efektivitas sistem dalam mendukung pengelolaan hama secara berkelanjutan.

V. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Penelitian ini berhasil mengembangkan sistem deteksi hama pada daun sawi hijau berbasis website dengan menggunakan model NASNetMobile yang dikombinasikan dengan arsitektur Sequential. Model terbaik menunjukkan akurasi pengujian sebesar 96%, dengan akurasi 100% pada gambar yang terjangkit hama dan 92% pada gambar tanpa hama. Keunggulan utama sistem ini terletak pada kemampuannya mengenali pola citra secara efektif dengan waktu pelatihan yang singkat serta kemudahan akses melalui antarmuka web. Implikasi praktis dari pengembangan sistem ini adalah kemampuannya untuk mendukung pengambilan keputusan yang lebih cepat dan tepat dalam pengendalian hama, serta potensi untuk diintegrasikan dengan perangkat *Internet of Things* (IoT) atau sistem rekomendasi pengendalian hama berbasis data, sehingga mendukung praktik pertanian presisi dan keberlanjutan produksi.

5.2 Saran

Meskipun sistem menunjukkan performa yang baik pada pengujian terbatas, diperlukan penelitian lanjutan dengan jumlah sampel yang lebih besar dan lebih bervariasi, serta pengujian pada kondisi lapangan yang lebih kompleks untuk meningkatkan kemampuan

generalisasi model. Selain itu, pengembangan lebih lanjut perlu mempertimbangkan integrasi dengan perangkat IoT dan sistem rekomendasi pengendalian hama secara otomatis, sehingga sistem ini dapat memberikan manfaat yang lebih luas dan mendukung transformasi digital dalam sektor pertanian secara menyeluruh.

DAFTAR PUSTAKA

- Annesa, O. D., Kartiko, C., & Prasetiadi, A. (2020). Identifikasi Spesies Reptil Menggunakan *Convolutional Neural Network* (CNN). *Jurnal Resti (Rekayasa Sistem Dan Teknologi Informasi)*, 1(1), 19–25.
- Debats, S., Luo, D., Estes, L., Fuchs, T. J., & Caylor, K. K. (2016). A Generalized Computer Vision Approach to Mapping Crop Fields in Heterogeneous Agricultural Landscapes. *Remote Sensing of Environment*, 179, 210–221. <https://doi.org/10.1016/j.rse.2016.03.010>
- Fattah, A., & Ilyas, A. (2016). Siklus Hidup Ulat Grayak (*Spodoptera litura*, F) dan Tingkat Serangan pada Beberapa Varietas Unggul Kedelai di Sulawesi Selatan. *Prosiding Seminar Nasional Inovasi Teknologi Pertanian*, 0411, 834–842. http://kalsel.litbang.pertanian.go.id/ind/images/pdf/Semnas2016/103_abdul_fattah.pdf
- Kamble, D. R., Gdale, S. K., Pawar, D. N., Shedage, G. D., & Mahajan, M. (2024). Leaf Disease Detection System. *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, 12(Maret), 160–164. <https://doi.org/https://doi.org/10.22214/ijraset.2024.58699>
- Liu, J., & Wang, X. (2021). Plant diseases and pests detection based on deep learning: a review. *Plant Methods*, 17(1), 22. <https://doi.org/10.1186/s13007-021-00722-9>
- Santoso, A., & Widyawati, N. (2020). Pengaruh Umur Bibit terhadap Pertumbuhan dan Hasil Pakcoy (*Brassica rapa* ssp. *chinensis*) pada Hidroponik NFT. *Vegetalika*, 9(3), 464. <https://doi.org/10.22146/veg.52570>
- Song, J. S., Kim, D. S., Kim, H. S., Jung, E. J., Hwang, H. J., & Park, J. (2023). Comparison of *Convolutional Neural Network* (CNN) Models for Lettuce Leaf Width and Length Prediction. *Journal of Bio-Environment Control*, 32(4), 434–441. <https://doi.org/10.12791/ksbec.2023.32.4.434>
- Suárez, A., Molina, R. S., Ramponi, G., Petrino, R., Bollati, L., & Sequeiros, D. (2021). Pest detection and classification to reduce pesticide use in fruit crops based on deep neural networks and image processing. *2021 XIX Workshop on Information Processing and Control (RPIC)*, 1–6. <https://doi.org/10.1109/RPIC53795.2021.9648485>
- Thomas, J. C. S., Manikandarajan, S., & Subha, T. K. (2023). AI based pest detection and alert system for farmers using IoT. *E3S Web Conf.*, 387. <https://doi.org/10.1051/e3sconf/202338705003>
- Wang, J., Chen, C., Huang, S., Wang, H., Zhao, Y., Wang, J., Yao, Z., Sun, C., & Liu, T. (2025). Monitoring of Agricultural Progress in Rice-Wheat Rotation Area Based on UAV RGB Images. *Frontiers in Plant Science*, 15. <https://doi.org/10.3389/fpls.2024.1502863>
- Wang, Y.-H., & Su, W.-H. (2022). Convolutional Neural Networks in Computer Vision for Grain Crop Phenotyping: A Review. In *Agronomy* (Vol. 12, Issue 11). <https://doi.org/10.3390/agronomy12112659>
- Yama, D. I., & Kartiko, H. (2020). Pertumbuhan dan Kandungan Klorofil Pakcoy (*Brassica rapa* L) Pada Beberapa Konsentrasi AB Mix Dengan Sistem Wick. *Jurnal Teknologi*, 12(1), 21–30.

- Yang, G., He, Y., Yang, Y., & Xu, B. (2020). Fine-Grained Image Classification for Crop Disease Based on Attention Mechanism. *Frontiers in Plant Science*, 11(December), 1–15. <https://doi.org/10.3389/fpls.2020.600854>
- Zhang, D. (2022). Auto machine learning-based modelling and prediction of excavation-induced tunnel displacement. *Journal of Rock Mechanics and Geotechnical Engineering*, 14(4), 1100–1114. <https://doi.org/10.1016/j.jrmge.2022.03.005>
- Zhang, H., Feng, S., Wu, D., Zhao, K., Liu, X., Zhou, Y., Wang, S., Deng, H., & Zheng, S. (2024). Hyperspectral Image Classification on Large-Scale Agricultural Crops: The Heilongjiang Benchmark Dataset, Validation Procedure, and Baseline Results. *Remote Sensing*, 16(3), 478. <https://doi.org/10.3390/rs16030478>