

## OPTIMALISASI CONVOLUTIONAL NEURAL NETWORK KONTRA VGG16 KLASIFIKASI CITRA DAUN SAWI

Rio Febriyan<sup>✉</sup>, Ade Irma Purnamasari, Denni Pratama, Puji Pramudya Marta,  
Yudhistira Arie Wijaya

Program Studi Teknik Informatika, STMIK IKMI Cirebon, Jawa Barat, Indonesia  
Email: [rioFebriyan455@gmail.com](mailto:rioFebriyan455@gmail.com)

### ABSTRACT

Manual detection of pests on mustard greens (*Caisim*) is a major constraint in reducing harvest productivity, as manual methods are inefficient, time-consuming, and require specialized expertise. Furthermore, Deep Learning models often suffer from overfitting when applied to limited agricultural datasets. This study aimed to develop and compare the effectiveness of a Convolutional Neural Network (CNN) from scratch model versus the VGG16 Transfer Learning architecture for automatic classification of healthy and pest-affected mustard leaf images. A dataset of 1,000 images was used for training and testing across four experimental scenarios (A to D), with Percobaan C being the optimized CNN from scratch model (using data augmentation) and Percobaan D using VGG16. The results showed that the VGG16 Transfer Learning model achieved the highest test accuracy of 95.0% (F1-Score: 0.95), while the optimized CNN from scratch model achieved 92.0% (F1-Score: 0.92). Therefore, Transfer Learning VGG16 is the most effective and optimal approach, demonstrating superior performance and efficiency by achieving high accuracy without complex data augmentation.

**Keyword:** Convolutional Neural Network, VGG16, Image Classification, Mustard Greens, Transfer Learning.

### ABSTRAK

Deteksi hama pada tanaman sawi hijau (*Caisim*) secara manual merupakan kendala utama yang menurunkan produktivitas panen, karena metode manual terbukti tidak efisien, memakan waktu, dan membutuhkan keahlian khusus. Selain itu, model Deep Learning sering rentan mengalami overfitting saat diterapkan pada kumpulan data pertanian yang terbatas. Penelitian ini bertujuan untuk mengembangkan dan membandingkan efektivitas model Convolutional Neural Network (CNN) from scratch versus arsitektur Transfer Learning VGG16 untuk klasifikasi otomatis citra daun sawi sehat dan terkena hama. Sebanyak 1.000 citra digunakan untuk pelatihan dan pengujian melalui empat skenario eksperimental (A hingga D), di mana Percobaan C adalah model CNN from scratch yang dioptimasi (data augmentation) dan Percobaan D menggunakan VGG16. Hasil penelitian menunjukkan bahwa model Transfer Learning VGG16 mencapai akurasi uji tertinggi sebesar 95,0% (F1-Score: 0,95), sementara model CNN from scratch teroptimasi mencapai 92,0% (F1-Score: 0,92). Oleh karena itu, Transfer Learning VGG16 merupakan pendekatan yang paling efektif dan optimal, menunjukkan kinerja superior dan efisiensi karena mencapai akurasi tinggi tanpa memerlukan data augmentation yang kompleks.

**Kata Kunci:** Convolutional Neural Network, VGG16, Klasifikasi Citra, Daun Sawi, Transfer Learning.

### PENDAHULUAN

Tanaman sawi hijau (*Caisim*) merupakan komoditas pertanian penting, namun kerentanannya terhadap serangan hama menjadi kendala serius dalam upaya peningkatan produktivitas. Deteksi dini hama penting untuk mitigasi, namun identifikasi secara manual tidak efisien, memakan waktu, dan sangat tergantung pada pengalaman pengamat. Urgensi penelitian ini terletak pada pengembangan sistem otomatis berbasis visi komputer yang dapat memberikan klasifikasi status kesehatan daun sawi secara cepat dan akurat (Ali et al., 2023).

Dalam konteks kecerdasan buatan, model Convolutional Neural Network (CNN) telah terbukti efektif dalam klasifikasi citra (Bahri et al., 2024;

Kurniadi, 2020). Namun, tantangan utama dalam domain pertanian dengan dataset terbatas adalah *overfitting*. Oleh karena itu, penelitian ini merasionalkan perbandingan antara model yang dibangun dari nol (*from scratch*) dengan model Transfer Learning VGG16 yang menggunakan bobot terlatih (*pre-trained*) dari dataset besar (ImageNet) (Lyu et al., 2025).

Tujuan penelitian ini adalah untuk (1) Mengembangkan model klasifikasi otomatis CNN yang akurat, (2) Menganalisis dan mengoptimalkan model CNN *from scratch* melalui teknik *data augmentation* untuk mengatasi *overfitting*, dan (3) Menyajikan data komparatif kuantitatif antara model CNN *from scratch* teroptimasi dan VGG16 untuk

menentukan arsitektur yang paling efektif dalam klasifikasi citra daun sawi (Ramadan et al., 2024).

## TINJAUAN PUSTAKA DAN PENGEMBANGAN HIPOTESIS

Berikut adalah tinjauan pustaka yang berkaitan dengan penelitian ini:

1. Pengolahan citra digital telah menjadi instrumen fundamental dalam deteksi dan identifikasi penyakit serta hama tanaman secara otomatis, memberikan solusi yang lebih efisien dibandingkan metode inspeksi visual tradisional. Teknologi ini memanfaatkan perangkat visi industri untuk memotret tanaman guna memeriksa keberadaan penyakit atau hama. Deteksi yang tepat terhadap hama dan penyakit merupakan aspek esensial untuk meningkatkan produksi pertanian secara berkelanjutan (Pertanian 4.0). Dalam dunia nyata, mendeteksi hama menjadi tantangan karena perbedaan dalam bentuk, ukuran, tekstur, warna, latar belakang, dan pencahayaan (Sakka et al., 2024).
2. Preprocessing citra, yang mencakup operasi resizing dan normalisasi, merupakan langkah fundamental untuk mempersiapkan citra tanaman untuk pelatihan model deep learning. Normalisasi nilai piksel menstandarisasi rentang intensitas di semua citra, memastikan input yang konsisten. Resizing citra menstandarisasi dimensi spasial agar sesuai dengan persyaratan arsitektur deep learning yang memerlukan dimensi input tetap. Preprocessing harus dirancang untuk mempertahankan konsistensi data sambil melestarikan fitur utama dari citra tanaman (Chen et al., 2022).
3. *Deep learning* telah merevolusi cara sistem komputer mengklasifikasikan citra digital, khususnya melalui pemanfaatan arsitektur *Convolutional Neural Network* (CNN). CNN mampu mengekstrak fitur spasial secara hierarkis dari data gambar, menjadikannya lebih unggul dibandingkan jaringan saraf tradisional (Xiong et al., 2024).
4. *Transfer learning* merupakan pendekatan yang memungkinkan model CNN memanfaatkan pengetahuan yang telah diperoleh dari pelatihan pada dataset besar (*ImageNet*) untuk diterapkan pada dataset yang lebih kecil, seperti dalam penelitian pertanian (Xie et al., 2024).

Tinjauan literatur menunjukkan adanya kesenjangan penelitian (*research gap*) yang jelas. Literatur terbagi antara mayoritas yang menggunakan *Transfer Learning* (seperti VGG16) sebagai solusi

*default* untuk menghindari *overfitting*, dan adanya bukti bahwa model *From Scratch* yang dioptimalkan juga dapat lebih unggul. Kesenjangan ini memberikan dasar untuk melakukan perbandingan yang adil antara model *from scratch* yang dioptimalkan (Percobaan C) dan *Transfer Learning* VGG16 (Percobaan D).

## Pengembangan Hipotesis

Berdasarkan tinjauan pustaka dan kesenjangan penelitian, penelitian ini bertujuan untuk menguji hipotesis: Model *Transfer Learning* VGG16 akan menghasilkan kinerja klasifikasi citra daun sawi yang lebih efektif dan optimal dibandingkan dengan model CNN *from scratch* yang telah dioptimasi.

## METODE PENELITIAN

Penelitian ini mengadopsi metodologi kuantitatif dengan desain eksperimental yang bertujuan untuk membandingkan efektivitas klasifikasi citra daun sawi antara model CNN *from scratch* teroptimasi dan model *Transfer Learning* VGG16. Seluruh eksperimen dikembangkan menggunakan bahasa pemrograman Python dengan kerangka kerja TensorFlow/Keras dan dijalankan pada lingkungan Google Colaboratory yang memanfaatkan GPU untuk akselerasi komputasi.

Objek utama penelitian ini adalah dataset citra hama sawi yang bersumber dari repositori publik Kaggle. Dataset ini terdiri dari total 1.000 citra dan diklasifikasikan menjadi dua kategori biner: "Sawi Ada Hama" dan "Sawi Tanpa Hama", dengan distribusi yang seimbang sempurna (500 citra per kelas). Sebelum dimasukkan ke dalam model, seluruh citra menjalani proses pra-pemrosesan data yang ketat. Langkah pertama adalah resizing citra dari resolusi asli 512x512 piksel menjadi 128x128 piksel untuk memastikan dimensi *input* yang seragam dan sesuai dengan persyaratan jaringan saraf konvolusional. Selanjutnya, proses normalisasi dilakukan dengan menskalakan nilai piksel ke rentang.

Eksperimen penelitian ini dibagi menjadi empat skenario sistematis, dirancang untuk menguji hipotesis dan mengidentifikasi optimalisasi yang diperlukan, seperti yang diringkas pada Tabel 1. Skenario Percobaan C dan Percobaan D mewakili perbandingan final:

1. Model CNN *From Scratch* (Percobaan C): Arsitektur kustom dikembangkan dengan tiga blok konvolusi (masing-masing diikuti oleh *Max Pooling* dan *Batch Normalization*) dan diakhiri dengan lapisan *Flatten* dan *Fully Connected* (klasifikasi *dense*). Model ini dilatih dengan *hyperparameter* Adam Optimizer (LR 0.001) dan Batch Size 32. Untuk mengatasi *overfitting* yang

teridentifikasi di Percobaan B, *Data Augmentation* ekstensif (meliputi rotasi 20 derajat, pergeseran lebar/tinggi 20%, dan *horizontal flip*) diterapkan wajib pada Percobaan C.

- Model *Transfer Learning* VGG16 (Percobaan D): Arsitektur VGG16 *pre-trained* dari ImageNet digunakan, dengan strategi *Feature Extraction*. Bobot pada lapisan konvolusional VGG16 dibekukan (*base\_model.trainable = False*). Di atas lapisan fitur VGG16, ditambahkan *classifier head* kustom yang terdiri dari lapisan *Flatten*, *Dropout*, dan lapisan *Dense* klasifikasi akhir (dengan fungsi aktivasi *Softmax*). Model ini dilatih dengan *hyperparameter* yang sama (Adam, LR 0.001, BS 32) untuk perbandingan yang adil.

ini memvalidasi perlunya model *deep learning* yang kuat untuk mengekstraksi fitur tekstural yang tidak kasat mata secara langsung, seperti yang diilustrasikan pada Gambar 1.



Gambar 1. Sampel Visual Citra dari Dataset

Tabel 1. Pembagian Dataset

Skenario	Rasio (Train/Val/Test)	Tujuan Metodologis
Percobaan A	40%/30%/30%	Diagnosis <i>Underfitting</i>
Percobaan B	80%/10%/10%	Diagnosis <i>Overfitting</i>
Percobaan C	90%/5%/5%	Optimalisasi <i>From Scratch</i>
Percobaan D	80%/10%/10%	Perbandingan VGG16

Untuk menganalisis kinerja setiap model, penelitian ini menggunakan metrik evaluasi klasifikasi yang komprehensif, meliputi Akurasi Uji (*Test Accuracy*), F1-Score, Precision, dan Recall. Selain itu, analisis Confusion Matrix digunakan untuk memvisualisasikan kinerja model secara detail, mengidentifikasi jumlah *True Positives*, *True Negatives*, *False Positives*, dan *False Negatives*, yang krusial untuk mengevaluasi keseimbangan model. Hasil kinerja dari model CNN *from scratch* teroptimasi (Percobaan C) dibandingkan secara langsung dengan hasil VGG16 (*Transfer Learning*) (Percobaan D) untuk menentukan efektivitas optimal dan memvalidasi hipotesis penelitian.

## HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil dari empat skenario eksperimental, dimulai dari diagnostik hingga perbandingan final, diikuti oleh pembahasan mendalam mengenai temuan tersebut.

Hasil *Exploratory Data Analysis* (EDA) menunjukkan bahwa citra daun sawi memiliki karakteristik yang menantang; meskipun citra memiliki resolusi tinggi, profil warna RGB antara kelas "Sawi Ada Hama" dan "Sawi Tanpa Hama" sangat mirip. Hal

Eksperimen diagnostik awal (Percobaan A dan B) menunjukkan hasil yang kurang memuaskan, dengan Percobaan A mengalami *underfitting* parah (akurasi uji 47%) dan Percobaan B mengalami *overfitting* drastis (akurasi uji 73%), yang menggarisbawahi ketidakmampuan model CNN *from scratch* awal untuk bergeneralisasi dengan data terbatas.

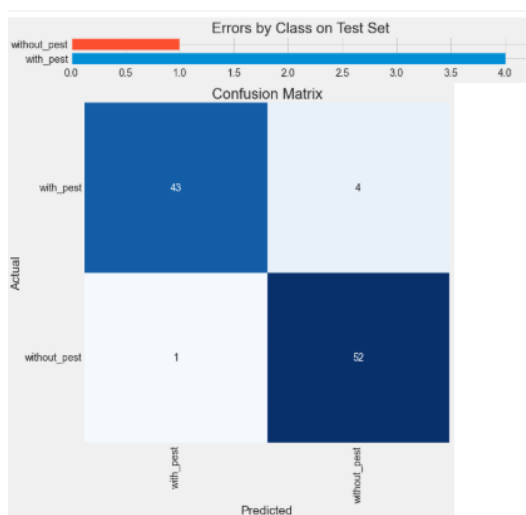
Optimalisasi pada Percobaan C (CNN *from scratch* dengan *Data Augmentation* dan *Early Stopping*) berhasil mengatasi *overfitting*, menghasilkan model yang konvergen secara stabil dan mencapai Akurasi Uji 92.0% dengan F1-Score yang seimbang (0.92). Kinerja superior dicapai oleh Percobaan D yang mengimplementasikan *Transfer Learning* VGG16, menghasilkan Akurasi Uji Final 95.0% dan F1-Score Macro Avg 0.95. Perbandingan akhir kinerja model terbaik diringkas pada Tabel 2.

Tabel 2. Perbandingan Kinerja Model C & D

Model Eksperimen	Akurasi Uji Final	F1-Score (Macro Avg)	Keterangan Tambahan
Percobaan C (CNN <i>from scratch</i> + <i>Augmentation</i> )	92.0%	0.92	Dioptimalkan dengan <i>Data Augmentation</i>
Percobaan D (VGG16 <i>Transfer Learning</i> )	95.0%	0.95	Akurasi tertinggi, tanpa <i>Data Augmentation</i>

Analisis Confusion Matrix VGG16 (Percobaan D), yang disajikan pada Gambar 2, menunjukkan kinerja klasifikasi yang sangat bersih. Dari 100 data uji, hanya 5 yang salah klasifikasi (*False Positive* dan *False Negative*), menunjukkan tingkat *True Positive* yang

sangat tinggi dan mengonfirmasi bahwa model ini memiliki keseimbangan yang kuat antara *Precision* dan *Recall*.



Gambar 2. Confusion Matrix Model VGG16

Hasil komparatif menunjukkan keunggulan yang signifikan dari pendekatan Transfer Learning VGG16 atas model CNN from scratch yang telah dioptimasi. Meskipun model from scratch (Percobaan C) mencapai akurasi yang baik (92.0%), kinerja tersebut sangat bergantung pada implementasi wajib Data Augmentation yang ekstensif dan mekanisme regularisasi ketat. Hal ini menegaskan bahwa untuk dataset berukuran 1.000 citra, model yang dibangun dari awal berjuang untuk mempelajari fitur yang dapat digeneralisasi tanpa intervensi data buatan.

Sebaliknya, VGG16 (Percobaan D) mencapai akurasi 95.0% dengan efisiensi data yang jauh lebih tinggi. Keberhasilan ini dapat diatribusikan pada bobot *pre-trained* VGG16 yang telah mempelajari representasi fitur visual yang matang dari ImageNet. Ketika bobot fitur VGG16 dibekukan (strategi *Feature Extraction*), model secara efektif bertindak sebagai ekstraktor fitur yang sangat andal, yang kemudian diterjemahkan oleh lapisan klasifikasi kustom. Hasilnya menunjukkan bahwa fitur yang diekstrak oleh VGG16 memiliki kemampuan generalisasi yang jauh lebih superior dibandingkan dengan fitur yang dipelajari secara eksklusif dari dataset daun sawi yang terbatas. Dengan kata lain, *Transfer Learning* VGG16 terbukti merupakan solusi yang paling optimal, memberikan kinerja tertinggi dengan risiko *overfitting* yang minimal dan efisiensi komputasi yang unggul, sekaligus secara empiris memvalidasi hipotesis penelitian.

## KESIMPULAN

Kesimpulan dari penelitian yang membandingkan efektivitas klasifikasi citra daun sawi menggunakan dua arsitektur *deep learning* adalah bahwa model *Transfer Learning* VGG16 terbukti menjadi pendekatan yang paling efektif dan optimal. Secara kuantitatif, model VGG16 mencapai akurasi pengujian tertinggi sebesar 95,0%, melampaui kinerja model CNN *from scratch* yang telah dioptimasi yang mencapai 92,0%. Keunggulan VGG16 tidak hanya terletak pada akurasinya, tetapi yang lebih krusial, pada efisiensi, karena model mencapai hasil superiornya tanpa memerlukan implementasi *Data Augmentation* yang kompleks, menjadikannya solusi yang lebih kuat, stabil, dan data-efficient untuk pengembangan sistem deteksi hama sawi otomatis. Penelitian ini merekomendasikan penggunaan arsitektur *Transfer Learning* sebagai *baseline* implementasi untuk mengatasi keterbatasan data dalam klasifikasi citra pertanian.

## DAFTAR PUSTAKA

- Ali, F., Qayyum, H., & Iqbal, M. (2023). Faster-PestNet: A Lightweight Deep Learning Framework for Crop Pest Detection and Classification. *IEEE Access*, 11, 104016–104027. <https://doi.org/10.1109/access.2023.3317506>
- Bahri, S., Sunyoto, A., & Kurniawan, M. P. (2024). Klasifikasi Hama Pada Daun Sawi Menggunakan Convolutional Neural Network (CNN) dengan Algoritma Xception dan Optimasi Adam. *Journal of Electrical Engineering and Computer (JEECOM)*, 6(2), 359-370.
- Chen, Y., Chen, Y., Chen, Y., Huang, Y., Wong, H., Yan, J., & Wang, J. (2022). Deep learning-based brain computed tomography image classification with hyperparameter optimization through transfer learning for stroke. *Diagnostics*, 12(4), 807. <https://doi.org/10.3390/diagnostics12040807>
- El Sakka, M., Mothe, J., & Ivanovici, M. (2024). Images and CNN applications in smart agriculture. *European Journal of Remote Sensing*, 57(1), 2352386. <https://doi.org/10.1080/22797254.2024.2352386>
- Kurniadi, A. (2020). Implementasi Convolutional Neural Network Untuk Klasifikasi Varietas Pada Citra Daun Sawi Menggunakan Keras. *DoubleClick: Journal of Computer and Information Technology*, 4(1), 25-33.
- Lyu, Y., Lu, F., Wang, X., Wang, Y., Wang, Z., Zhu, Y., & Dong, M. (2025). A cnn-transformer hybrid framework for multi-label predator-prey detection in agricultural fields. *Sensors*, 25(15), 4719. <https://doi.org/10.3390/s25154719>

- Ramadan, S., Sakib, T., Farid, F., Islam, M., Abdullah, J., Bhuiyan, M., & Karim, H. (2024). Improving wheat leaf disease classification: evaluating augmentation strategies and cnn-based models with limited dataset. *IEEE Access*, *12*, 69853–69874.  
<https://doi.org/10.1109/access.2024.3397570>
- Xie, S., Liao, H., & Zhang, L. (2024). A deep cnn-based detection method for multi-scale fine-grained objects in remote sensing images. *IEEE Access*.  
<https://doi.org/10.1109/access.2024.3356716>
- Xiong, P., Zhang, C., He, L., Zhan, X., & Han, Y. (2024). Deep learning-based rice pest detection research. *Plos One*, *19*(11), e0313387.  
<https://doi.org/10.1371/journal.pone.0313387>