

IMPLEMENTASI TRANSFER LEARNING UNTUK KLASIFIKASI PENYAKIT PADA DAUN CABAI MENGUNAKAN CNN

Rahmat Arief Setyadi ¹, Sayuti Rahman ², Dionixon Manurung ³, Maridiatul Hasanah ⁴,
Asmah Indrawati⁵

1,2,3,4) Teknik Informatika, Fakultas Teknik, Universitas Medan Area, Indonesia

5) Agroteknologi, Fakultas Pertanian, Universitas Medan Area

Article Info

Article history:

Received: 09 Juli 2024

Revised: 15 Juli 2024

Accepted: 06 Agustus 2024

ABSTRACT

Abstrak

Penelitian ini bertujuan untuk mengklasifikasikan penyakit pada daun cabai merah menggunakan metode *Convolutional Neural Network (CNN)* dengan pendekatan transfer learning, khususnya arsitektur ResNet101. Indonesia, sebagai negara agraris, memiliki banyak petani yang mengandalkan tanaman cabai merah sebagai salah satu komoditas utama. Namun, penyakit daun cabai sering kali menurunkan kualitas dan kuantitas hasil panen. Dalam upaya meningkatkan deteksi dini penyakit, penelitian ini memanfaatkan teknologi deep learning untuk menganalisis citra daun cabai. Dataset yang digunakan terdiri dari citra penyakit daun cabai merah yang telah diaugmentasi, dengan total 2128 gambar yang dibagi menjadi data training sebanyak 1702 citra dan data validasi sebanyak 426 citra. Penelitian ini membandingkan kinerja berbagai arsitektur CNN, termasuk AlexNet, GoogleNet, VGGNet16, dan ResNet50, serta lapisan-lapisan pada arsitektur ResNet. Hasil penelitian menunjukkan bahwa augmentasi dataset meningkatkan akurasi validasi dari 89.72% menjadi 97.18%. ResNet101 mencapai akurasi validasi tertinggi sebesar 98.12%, menunjukkan efektivitas transfer learning dalam tugas klasifikasi penyakit daun cabai. Penelitian ini menunjukkan bahwa penggunaan metode CNN dengan transfer learning, khususnya arsitektur ResNet101, sangat efektif untuk mendeteksi dan mengklasifikasikan penyakit pada daun cabai merah. Peningkatan kinerja model melalui augmentasi dataset dan pemilihan arsitektur yang tepat dapat membantu meningkatkan kualitas dan kuantitas hasil panen, serta mendukung pertanian cerdas di Indonesia.

Kata Kunci: CNN, Transfer Learning, Sistem Pertanian Cerdas, Visi Komputer.

Abstract

This study aims to classify diseases on chili pepper leaves using the Convolutional Neural Network (CNN) method with a transfer learning approach, specifically the ResNet101 architecture. Indonesia, as an agrarian country, has many farmers relying on chili peppers as one of their main commodities. However, leaf diseases often reduce the quality and quantity of the harvest. In an effort to improve early disease detection, this research leverages deep learning technology to analyze images of chili leaves. The dataset used consists of augmented images of chili leaf diseases, totaling 2128 images, divided into 1702 training images and 426 validation images. This study compares the performance of various CNN architectures, including AlexNet, GoogleNet, VGGNet16, and ResNet50, as well as layers within the ResNet architecture. The results show that dataset augmentation increases validation accuracy from 89.72% to 97.18%. ResNet101 achieved the highest validation accuracy of 98.12%, demonstrating the effectiveness of transfer learning in the task of chili leaf disease Classification. This research demonstrates that using the CNN method with transfer learning, particularly the ResNet101 architecture, is highly effective for detecting and classifying diseases on chili pepper

leaves. Improving model performance through dataset augmentation and the appropriate selection of architecture can help enhance the quality and quantity of the harvest, supporting smart agriculture in Indonesia.

Keywords: CNN, Transfer Learning, Smart Agriculture Systems, Computer Vision.

Djtechno: Jurnal Teknologi Informasi oleh Universitas Dharmawangsa Artikel ini bersifat open access yang didistribusikan di bawah syarat dan ketentuan dengan Lisensi Internasional Creative Commons Attribution NonCommercial ShareAlike 4.0 ([CC-BY-NC-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/)).



Corresponding Author:

E-mail : sayutirahman@staff.uma.ac.id

1. PENDAHULUAN

Indonesia dikenal sebagai negara agraris dengan mayoritas penduduknya bekerja di sektor pertanian. Keadaan ini didukung oleh keberadaan lahan kosong yang luas dan kondisi tanah yang subur, ideal untuk pertumbuhan berbagai tanaman. Salah satu tanaman hortikultura yang memiliki permintaan tinggi dari berbagai kalangan adalah cabai merah (Ilham et al., 2023).

Cabai merah (*Capsicum annum L.*) merupakan salah satu sayuran penting di Indonesia, baik sebagai komoditas domestik maupun ekspor. Cabai merah umumnya digunakan sebagai bahan bumbu masakan dan bahan bumbu pedas. Tanaman cabai ini dapat tumbuh dalam berbagai kondisi, tetapi sering kali diserang oleh berbagai jenis penyakit yang dapat menurunkan kualitas dan kuantitas hasil panen. Penyakit yang sering menyerang tanaman cabai, terutama yang menyerang daun, disebabkan oleh faktor hama dan lingkungan yang dapat merusak kesehatan daun cabai (Astuti et al., 2021).

Penyakit pada tanaman sangat mempengaruhi hasil panen. Jika tidak segera ditangani, penyakit ini dapat merusak tanaman, menyebabkan gagal panen, dan berdampak negatif pada perekonomian petani (Pirngadi et al., 2023). Dalam penelitian ini, jenis daun cabai yang diteliti meliputi embun tepung, daun sehat, kompleks murda (tungau, thrips), bercak daun (*Cercospora*), dan kurang nutrisi. Tujuannya adalah untuk mengklasifikasikan penyakit pada daun cabai dengan visi komputer (S Rahman et al., 2020) yaitu menggunakan metode *Convolutional Neural Network (CNN)* dengan arsitektur *ResNet50*, yang memiliki kemampuan mengolah informasi citra secara otomatis dan akurat.

Perkembangan teknologi saat ini memungkinkan pemantauan tanaman secara otomatis menggunakan sistem komputer. Pemrosesan gambar memungkinkan

komputer menganalisis dan mengidentifikasi penyakit yang direkam oleh kamera. Metode deep learning, khususnya *CNN*, telah terbukti efektif dalam mendeteksi penyakit tanaman secara otomatis dan akurat (Dzaky & Al Maki, 2021).

Deep learning telah menjadi bagian penting dari pengembangan *machine learning*, dengan aplikasi yang mencakup prediksi peluang, pengenalan objek, dan diagnosis penyakit menggunakan sistem pemrosesan citra. *CNN* adalah salah satu algoritma deep learning yang dirancang untuk mengolah data dua dimensi seperti gambar (Karno et al., 2022). *CNN* memiliki kemampuan untuk menerima input berupa citra dan mempelajari aspek-aspek di dalamnya, melakukan ekstraksi fitur secara otomatis, dan kemudian melakukan klasifikasi berdasarkan fitur-fitur yang diperoleh (Anggraeni et al., 2022). Salah satu arsitektur *CNN* yang populer adalah *Residual Network (ResNet)*, yang mampu mengatasi masalah gradien yang menghilang akibat banyaknya lapisan (Ridhovan & Suharso, 2022).


Fine tuning merupakan proses penyesuaian parameter atau bobot dengan dataset baru atau yang sudah ada, bertujuan untuk mencapai akurasi yang lebih baik (Poojary et al., 2021). Pemilihan metode *CNN* dengan arsitektur *ResNet50* dalam penelitian ini didasarkan pada efektivitas metode ini dalam memanfaatkan sumber daya yang tidak terlalu berat dan menghasilkan akurasi maksimal berdasarkan penelitian sebelumnya.

Penelitian terkait klasifikasi penyakit daun cabai telah dilakukan sebelumnya. Misalnya, menggunakan *CNN* dengan arsitektur AlexNet dan SqueezeNet, menunjukkan bahwa AlexNet memiliki akurasi 90% lebih baik dibandingkan SqueezeNet yang memiliki akurasi 85% (Danendra et al., 2023). Sementara itu, penggunaan machine learning pada daun singkong dan cabai menunjukkan akurasi training 87.50% dan testing 82.50% (Chavez, 2023). ResNet pada daun gandum menunjukkan akurasi lebih dari 95%, dengan skenario terbaik mencapai 98% akurasi (Ridhovan & Suharso, 2022).

Berdasarkan latar belakang dan penelitian terkait yang telah dijelaskan, penelitian ini bertujuan untuk mencoba transfer learning menggunakan metode *CNN* yang sudah ada, khususnya arsitektur *ResNet101*, dalam mengklasifikasikan penyakit pada daun cabai merah. Penelitian ini diberi judul "Implementasi Transfer Learning untuk Klasifikasi Penyakit pada Daun Cabai Menggunakan *CNN*."

2. METODE PENELITIAN

Sistem pertanian cerdas, khususnya dalam budidaya cabai, memerlukan pendeteksian penyakit daun cabai secara cepat dan tepat. Untuk mencapai hal ini, diperlukan kamera yang mampu mengenali penyakit tersebut. Kamera ini harus dilengkapi dengan sistem visi komputer yang memanfaatkan *Convolutional Neural Network (CNN)*. Agar *CNN* yang diterapkan pada sistem pertanian cerdas ini optimal, diperlukan penelitian yang mendalam. Tahapan penelitian ini dapat dilihat pada Gambar 1 berikut:



Gambar 1. Tahapan Penelitian

Gambar 1 menunjukkan proses metodelis yang digunakan dalam penelitian untuk mengembangkan sistem deteksi penyakit daun cabai dalam budidaya cabai. Proses ini dimulai dengan pengumpulan dataset citra daun cabai, yang kemudian dibagi menjadi dua bagian: satu bagian tanpa augmentasi dan bagian lain dengan augmentasi data. Augmentasi data sangat penting untuk meningkatkan kemampuan model dalam mengenali berbagai kondisi penyakit dengan lebih efektif. Selanjutnya, kedua jenis data ini digunakan untuk melatih model *Convolutional Neural Network (CNN)*. Fokus utama adalah pada penggunaan data yang diaugmentasi untuk mengoptimalkan akurasi pengenalan pola penyakit oleh sistem. Penggunaan arsitektur *CNN* lanjutan seperti ResNet 101 juga dijelaskan, yang diketahui dapat meningkatkan hasil latihan dengan menangani masalah yang lebih kompleks dan variatif. Tahapan ini tidak hanya melibatkan pelatihan model tetapi juga validasi dan pengujian untuk memastikan

bahwa sistem yang dikembangkan dapat beroperasi dengan baik dalam kondisi nyata. Proses penelitian ini bertujuan untuk menghasilkan sistem pertanian cerdas yang dapat dengan cepat dan tepat mendeteksi penyakit pada daun cabai, sehingga membantu para petani dalam mengelola budidaya cabai mereka dengan lebih efisien.

2.1 Dataset

Dataset yang digunakan dalam penelitian ini berupa kumpulan citra penyakit pada daun cabai merah bersumber dari mendeley data yang terdiri dari 5 kelas penyakit (Aishwarya & Reddy, 2024). Dataset terbagi menjadi 2 jenis dataset yaitu diaugmentasi (augmented) dan tidak di augmentasi. Dataset memiliki 531 citra sebelum diaugmentasi, setelah di augmentasi dataset berjumlah 2128 gambar. Berikut Dataset yang telah diaugmentasi dapat dilihat pada Tabel 1 Berikut:

Tabel 1. Dataset Augmentasi


Kelas	Gambar	Training	Validation	Total
Embun Tepung		486	122	608
Daun Sehat		221	55	276
kompleks murda (tungau, thrips)		342	86	428
Bercak Daun (Cercospora)		326	82	408
Kurang Nutrisi		327	81	408
Total		1702	426	2128

Tabel 1 memberikan informasi tentang distribusi dataset augmentasi yang digunakan dalam penelitian ini untuk mengidentifikasi penyakit pada daun cabai merah. Dataset ini terdiri dari lima kelas penyakit yang berbeda: Embun Tepung, Daun Sehat, Kompleks Murda (tungau, thrips), Bercak Daun (*Cercospora*), dan Kurang Nutrisi. Setiap kelas berisi sejumlah gambar yang telah dibagi menjadi subset untuk pelatihan (training) dan validasi (validation). Total gambar dalam dataset setelah augmentasi berjumlah 2128, yang mencakup 1702 gambar untuk pelatihan dan 426 gambar untuk validasi.

Augmentasi dilakukan untuk meningkatkan jumlah dan keragaman gambar dalam dataset, yang bertujuan untuk meningkatkan kinerja model pembelajaran mesin dalam mengklasifikasikan penyakit. Proses augmentasi ini mencakup teknik-teknik seperti rotasi, skala, dan transformasi lainnya yang dapat membantu model mengenali pola yang lebih umum dan bervariasi dalam gambar. Dengan demikian, distribusi dataset yang seimbang dan terstruktur ini memastikan bahwa model yang dilatih memiliki generalisasi yang baik terhadap data baru yang belum pernah dilihat sebelumnya.

2.2 Convolutional Neural Network (CNN)

CNN yang sering disebut *convolutional networks (ConvNets)* merupakan arsitektur jaringan syaraf tiruan yang sedang populer. *CNN* adalah *multi-layer perceptron* yang merupakan *Deep neural networks* yang digunakan sebagai metode untuk klasifikasi data citra digital. Jaringan konvolusi pada *CNN* berguna untuk mengekstraksi fitur pada Citra digital. Fitur yang kuat akan dikenali dan diklasifikasi sesuai target output yang diberikan. Contoh Arsitektur *CNN* ditampilkan pada Gambar 2 (Sayuti Rahman et al., 2021).



Gambar 2. Arsitektur CNN

Arsitektur *CNN* memiliki dua bagian utama yaitu *Feature Learning* dan *Clasification* seperti terlihat pada Gambar 2. *Feature Learning* terdiri dari lapisan konvolusi, fungsi aktivasi *Rectified Linear Unit (ReLU)*, dan *Pooling*. Arsitektur *CNN* umumnya menumpuk lapisan-lapisan ini pada *Feature Learning* untuk ekstraksi fitur lebih baik. Bagian klasifikasi terdiri dari *Flatten*, *Fully Connected* dan *Softmax*. Pada Gambar 1 dapat dilihat sebuah gambar daun cabai sebagai data input. Data input diproses untuk dikenali apakah sehat atau tidak sehat berdasarkan penyakit yang ada.

3. HASIL DAN PEMBAHASAN

Untuk mendapatkan akurasi model *CNN* yang telah dilatih (*pretrained*) dengan hasil tingkat akurasi yang tinggi. Maka dilakukan perbandingan akurasi dari berbagai arsitektur *Convolutional Neural Network (CNN)*. Perbandingan ini dilakukan dengan menguji performa masing-masing model pada dataset yang sama, namun menggunakan dua teknik dataset yang berbeda yang pertama adalah dataset yang tanpa diaugmentasi, dan yang kedua adalah dataset yang telah diaugmentasi. Setiap model dilatih selama 30 epoch untuk memastikan stabilitas dan konsistensi hasil pelatihan.

Tahapan awal penelitian dimulai dengan percobaan menggunakan dataset tanpa augmentasi. Setiap model dilatih sebanyak 30 *epoch*. Setelah itu, dilakukan percobaan serupa dengan dataset yang telah di-augmented, juga dengan 30 *epoch* pelatihan. Tahap berikutnya adalah melatih dan membandingkan setiap lapisan pada ResNet.

3.1 Pengaruh Augmentasi Dataset

Pada penelitian ini menggunakan 2 jenis dataset citra cabai yang pertama tidak di augmented dan yang kedua dataset diaugmented. Penelitian ini dilakukan untuk melihat pengaruh augmentasi terhadap kekurangan dataset. Augmentasi ini dilakukan dengan menggandakan dengan mencerminkan verikal, cerminkan horinzontal dan rotasi 90. Berikut perbandingan akurasi Resnet101 pada dataset dengan dan tidak aumentasi seperti disajikan pada Tabel 2.

Tabel 2. Perbandingan Akurasi Resnet101 pada dataset berbeda

No	Dataset	Akurasi Latih	Akurasi Validasi
1	Tanpa Augmentasi	98.35%	89.72%
2	Dengan Augmentasi	97.83%	97.18%

Pada eksperimen menggunakan arsitektur ResNet101, terdapat dua kondisi yang dibandingkan. Pertama, tanpa melakukan augmentasi dataset, model mencapai akurasi latih sebesar 98.35% dan akurasi validasi sebesar 89.72%. Kedua, dengan melakukan augmentasi dataset, model mencapai akurasi latih sebesar 97.83% dan akurasi validasi sebesar 97.18%. Hal ini menunjukkan bahwa augmentasi dataset dapat meningkatkan kinerja model pada data validasi secara signifikan.

3.2 Hasil Pelatihan Existing CNN

Hasil pelatihan arsitektur *Convolutional Neural Network* (CNN) digunakan untuk mengevaluasi kinerja model dalam klasifikasi citra daun. Proses pelatihan ini melibatkan beberapa parameter penting seperti jumlah epoch, ukuran batch, dan tingkat pembelajaran (*learning rate*). Tabel di bawah ini menampilkan metrik kinerja utama yang diperoleh, termasuk akurasi pelatihan dan akurasi validasi:

No	Metode	Akurasi Latih	Akurasi Validasi
1	AlexNet (Krizhevsky et al., 2012)	93.89%	95.78%
2	GoogleNet (Szegedy et al., 2015)	95.12%	96.95%
3	VGGNet16 (Simonyan &	95.95%	96.95%

	Zisserman, 2014)		
4	<i>ResNet50</i> (He et al., 2016)	98.47%	97.42%

Tabel berikut menunjukkan akurasi latih dan akurasi validasi dari beberapa metode jaringan saraf konvolusi yang digunakan dalam eksperimen. AlexNet memiliki akurasi latih sebesar 93.89% dan akurasi validasi sebesar 95.78%. GoogleNet menunjukkan akurasi latih sebesar 95.12% dan akurasi validasi sebesar 96.95%. VGGNet16 mencapai akurasi latih sebesar 95.95% dan akurasi validasi sebesar 96.95%. *ResNet50* memiliki akurasi tertinggi dengan akurasi latih sebesar 98.47% dan akurasi validasi sebesar 97.42%.


3.3 Perbandingan ResNet

Perbandingan kinerja berbagai lapisan pada arsitektur ResNet yang digunakan dalam penelitian ini bertujuan untuk mengevaluasi performa setiap lapisan ResNet dalam model klasifikasi yang dikembangkan. Hasil perbandingan ditampilkan dalam bentuk tabel di bawah ini:

No.	Metode	Akurasi Pelatihan	Akurasi Validasi
1	ResNet18	96.42%	95.78%
2	ResNet34	97.36%	97.18%
3	<i>ResNet50</i>	97.83%	97.18%
4	ResNet101	97.65%	98.12%
5	ResNet152	98.41%	97.18%

Tabel menyajikan perbandingan akurasi pelatihan dan validasi dari berbagai metode ResNet yang digunakan dalam penelitian. Metode ResNet18 menghasilkan akurasi pelatihan sebesar 96.42% dan akurasi validasi sebesar 95.78%. ResNet34 menunjukkan peningkatan dengan akurasi pelatihan 97.36% dan akurasi validasi

97.18%, Metode *ResNet50* memiliki akurasi pelatihan sebesar 97.83% dan akurasi validasi 97.18%, *ResNet101* mencapai akurasi pelatihan 97.65% dan akurasi validasi tertinggi di antara metode lainnya, yaitu 98.12%. Terakhir, metode *ResNet152* menghasilkan akurasi pelatihan tertinggi sebesar 98.41%, namun akurasi validasinya masih 97.18%. Berikut Perbandingan Akurasi Seperti Terlihat Pada Gambar 3.



Gambar 3. Perbandingan Akurasi Training dan Validasi pada ResNet

Gambar 3 merupakan dua diagram batang yang terpisah, yang pertama menunjukkan Akurasi Pelatihan dan yang kedua menunjukkan Akurasi Validasi untuk berbagai model ResNet. Akurasi Pelatihan dalam diagram pertama (warna oranye), dapat dilihat bahwa *ResNet152* memiliki akurasi pelatihan tertinggi sebesar 98.41%, diikuti oleh *ResNet50* dengan 97.83%. Model-model ini menunjukkan kinerja yang sangat baik dalam fase pelatihan, dengan semua model mencapai akurasi di atas 96%. Sedangkan akurasi validasi dalam diagram kedua (warna merah), *ResNet101* menonjol dengan akurasi validasi tertinggi sebesar 98.12%, yang menunjukkan keunggulannya dalam menggeneralisasi data yang tidak terlihat dibandingkan model

lainnya. Model-model lainnya, kecuali ResNet18, semua mencatatkan akurasi validasi yang sama sebesar 97.18%.

4. SIMPULAN

Penelitian ini bertujuan untuk mengklasifikasikan penyakit pada daun cabai merah menggunakan metode *Convolutional Neural Network (CNN)* dengan pendekatan transfer learning, khususnya menggunakan arsitektur ResNet101. Berdasarkan hasil yang diperoleh, augmentasi dataset terbukti meningkatkan kinerja model *CNN* dalam klasifikasi penyakit daun cabai. Akurasi validasi meningkat dari 89.72% pada dataset tanpa augmentasi menjadi 97.18% pada dataset yang diaugmentasi, menunjukkan bahwa augmentasi dataset dapat membantu mengatasi keterbatasan data dan meningkatkan generalisasi model. Beberapa arsitektur *CNN* yang diuji, termasuk AlexNet, GoogleNet, VGGNet16, dan *ResNet50*, menunjukkan performa yang bervariasi. *ResNet50* mencapai akurasi latih tertinggi sebesar 98.47% dan akurasi validasi sebesar 97.42%, menegaskan efektivitas arsitektur ini dalam klasifikasi citra daun cabai.

Perbandingan berbagai lapisan pada arsitektur ResNet menunjukkan bahwa ResNet101 mencapai akurasi validasi tertinggi sebesar 98.12%, meskipun ResNet152 memiliki akurasi pelatihan tertinggi. Hal ini menunjukkan bahwa ResNet101 menawarkan keseimbangan optimal antara kompleksitas model dan kemampuan generalisasi. Penerapan transfer learning dengan arsitektur ResNet101 dalam penelitian ini menunjukkan bahwa model pretrained pada dataset besar dapat diadaptasi dengan baik untuk tugas spesifik seperti klasifikasi penyakit daun cabai. Transfer learning memungkinkan pengurangan waktu dan sumber daya yang diperlukan untuk pelatihan model baru dari awal. Secara keseluruhan, penelitian ini menunjukkan bahwa penggunaan metode *CNN* dengan transfer learning, khususnya arsitektur ResNet101, sangat efektif untuk mendeteksi dan mengklasifikasikan penyakit pada daun cabai merah. Peningkatan kinerja model melalui augmentasi dataset dan pemilihan arsitektur yang tepat dapat membantu meningkatkan kualitas dan kuantitas hasil panen, serta mendukung pertanian cerdas di Indonesia.

UCAPAN TERIMA KASIH (Optional)

Kami mengucapkan terima kasih yang sebesar-besarnya kepada Universitas Medan Area dan Program Studi Teknik Informatika yang telah memberikan

dukungan penuh dalam pelaksanaan penelitian ini. Dukungan yang diberikan berupa fasilitas dan sarana penelitian sangat membantu kelancaran dan keberhasilan penelitian ini.

PUSTAKA

- Aishwarya, M. P., & Reddy, A. P. (2024). Dataset of chilli and onion plant leaf images for *Classification and detection*. *Data in Brief*, 54, 110524.
- Anggraeni, D. S., Widayana, A., Rahayu, P. D., & Rozikin, C. (2022). Metode Algoritma Convolutional Neural Network pada Klasifikasi Penyakit Tanaman Cabai. *Satuan Tulisan Riset Dan Inovasi Teknologi*, 7(1), 73–78.
- Astuti, F. S., Wanto, H. S., & Koesriwulandari, K. (2021). Elastisitas Permintaan Cabai Merah (*Capsicum annum* L.) DI KOTA SURABAYA. *Jurnal Ilmiah Sosio Agribis*, 21(1).
- Chavez, K. (2023). Implementasi Sistem Pendeteksi Penyakit Pada Daun Singkong Dan Daun Cabai Berbasis Machine Learning. *JURNAL QUANCOM: QUANTUM COMPUTER JURNAL*, 1(2), 1–5.
- Danendra, F. A., Anggraeny, F. T., & Maulana, H. (2023). Klasifikasi Citra Penyakit Daun Cabai Rawit Dengan Menggunakan CNN Arsitektur AlexNet dan SqueezeNet. *Syntax: Jurnal Informatika*, 12(01), 50–61.
- Dzaky, A. T. R., & Al Maki, W. F. (2021). Deteksi Penyakit Tanaman Cabai Menggunakan Metode Convolutional Neural Network. *EProceedings of Engineering*, 8(2).
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Ilham, N., Mustamu, N. E., Dalimunthe, B. A., & Saragih, S. H. Y. (2023). Aplikasi Pemberian Abu Sekam Padi dan Pupuk Organik Cair (POC) Terhadap Produksi Tanaman Cabai Merah (*Capsicum annum* L.). *JURNAL MAHASISWA AGROTEKNOLOGI (JMATEK)*, 4(2), 56–63.
- Karno, A. S. B., Hastomo, W., Wardhana, I. S. K., Sutarno, S., & Arif, D. (2022). Identification of 29 Types of Plant Diseases using Deep Learning EfficientNetB3. *Insearch: Information System Research Journal*, 2(02), 35–45.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet *Classification with deep convolutional neural networks*. *Advances in Neural Information Processing Systems*, 1097–1105.
- Pirngadi, R. S., Utami, J. P., Siregar, A. F., Salsabila, S., Habib, A., & Manik, J. R. (2023). Analisis Faktor Yang Mempengaruhi Pendapatan Usahatani Cabai Merah Di Kecamatan Beringin. *Welcome*, 25(1), 486–492.
- Poojary, R., Raina, R., & Mondal, A. K. (2021). Effect of data-augmentation on fine-tuned CNN model performance. *IAES International Journal of Artificial Intelligence*, 10(1), 84.
- Rahman, S., Ramli, M., Arnia, F., Muharar, R., Luthfi, M., & Sundari, S. (2020). Analysis and Comparison of Hough Transform Algorithms and Feature Detection to Find Available Parking Spaces. *Journal of Physics: Conference Series*, 1566(1), 012092. <https://doi.org/10.1088/1742-6596/1566/1/012092>
- Rahman, Sayuti, Ramli, M., Arnia, F., Muharar, R., Zen, M., & Ikhwan, M. (2021). *Convolutional Neural Networks Untuk Visi Komputer Jaringan Saraf Konvolusional untuk Visi Komputer (Arsitektur Baru, Transfer Learning, Fine Tuning, dan Pruning)*. Deepublish.
- Ridhovan, A., & Suharso, A. (2022). Penerapan Metode Residual Network (RESNET) Dalam Klasifikasi Penyakit Pada Daun Gandum. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 7(1), 58–65.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *ArXiv Preprint ArXiv:1409.1556*.
- Szegedy, C., Wei Liu, Yangqing Jia, Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1–9. <https://doi.org/10.1109/CVPR.2015.7298594>