



Klasifikasi Penyakit Daun Cabai Dengan Metode CNN Untuk Deteksi Awal.

Anda Putra ^{a,*}, Willy Prihartono ^b

^a Sekolah Tinggi Manajemen Informatika dan Komputer (STMIK) IKMI Cirebon; Jl. Perjuangan No.10B, Karyamulya, Kec Kesambi, Kota Cirebon, Jawa Barat 45135; Telp (0231) 490480

INFORMASI ARTIKEL

Riwayat artikel:
Diterima : 8 Mei 2025
Diterbitkan : 24 Juni 2025

Kata kunci:
Convolutional Neural Network;
Image Processing;
Disease Classification;
Agriculture Technology

ABSTRAK

Penelitian ini mengembangkan model klasifikasi penyakit daun cabai menggunakan metode *Convolutional Neural Network (CNN)* untuk mendukung deteksi dini dalam sektor pertanian. Dataset terdiri dari 222 citra daun cabai yang terbagi dalam dua kategori, yaitu daun sehat dan daun keriting. Proses data melibatkan augmentasi seperti rotasi, flipping, dan zoom untuk meningkatkan variasi dan kualitas dataset. Model *CNN* dirancang dengan kombinasi lapisan konvolusi, pooling, dan *fully connected*, dilatih menggunakan optimizer Adam dengan fungsi loss binary crossentropy. Hasil pelatihan menunjukkan akurasi 91% pada data validasi. Implementasi berbasis Flask memungkinkan prediksi real-time melalui antarmuka web yang mudah digunakan. Evaluasi kinerja dilakukan dengan metrik akurasi, presisi, recall, dan *confusion matrix* untuk memastikan model dapat membedakan daun sehat dan keriting dengan tingkat kesalahan minimal. Hasil penelitian ini menunjukkan bahwa pendekatan berbasis deep learning dapat menjadi solusi praktis bagi petani dalam mendeteksi penyakit daun cabai, sehingga dapat meningkatkan produktivitas dan efisiensi pengelolaan tanaman. Penelitian ini diharapkan dapat dikembangkan lebih lanjut untuk mencakup dataset yang lebih besar dan integrasi dengan perangkat IoT untuk pemantauan otomatis tanaman

1. Pendahuluan

Pertanian merupakan sektor vital dalam perekonomian, khususnya di negara agraris seperti Indonesia. Salah satu tantangan utama dalam sektor ini adalah deteksi dini penyakit tanaman, yang sering kali menyebabkan penurunan hasil panen secara signifikan. Kemajuan teknologi telah membawa solusi inovatif melalui penerapan metode berbasis kecerdasan buatan (Artificial Intelligence/AI), khususnya Convolutional Neural Network (CNN). CNN telah terbukti efektif dalam menganalisis citra digital untuk identifikasi penyakit tanaman, sebagaimana yang telah diterapkan pada berbagai jenis tanaman seperti padi (Hawari et al., 2022), cabai (Rahayu et al., 2023) dan teh (Febriady Marpaung, Nurul Khairina, Rizki Muliono³, Muhathir, 2024)

Pada tanaman cabai, penyakit seperti keriting dan bercak daun menjadi masalah utama yang berdampak pada kualitas dan kuantitas hasil panen. (Usamah Putra Firdaus¹, Yovi Litanianda², 2024) menunjukkan bahwa CNN mampu mengidentifikasi penyakit tersebut dengan akurasi tinggi. Selain itu, metode optimasi pada CNN seperti yang disampaikan oleh

(Tilasefana & Putra, 2023)) semakin meningkatkan efisiensi dan akurasi sistem deteksi. Penelitian ini bertujuan untuk mengimplementasikan CNN dalam mendeteksi penyakit daun cabai melalui pengolahan citra digital, dengan harapan memberikan solusi praktis dan efisien bagi petani dalam mengelola kesehatan tanaman cabai mereka.

1.1. Landasan teori

Convolutional Neural Network (CNN) adalah salah satu arsitektur deep learning yang dirancang untuk analisis data berbentuk grid, seperti citra digital. Model ini telah digunakan secara luas untuk klasifikasi dan deteksi penyakit tanaman. (Anggraeni et al., 2022) menunjukkan bahwa CNN dapat mengklasifikasikan penyakit cabai dengan akurasi tinggi, sedangkan (Usamah Putra Firdaus¹, Yovi Litanianda², 2024) mengonfirmasi keunggulan CNN dalam mendeteksi penyakit daun cabai.

1. Optimasi CNN Upaya untuk meningkatkan performa CNN mencakup penggunaan arsitektur ringan seperti

*Penulis korespondensi.

E-mail: arifaffandi11@gmail.com

MobileNet dan metode optimasi lainnya. (Febriady Marpaung, Nurul Khairina, Rizki Muliono³, Muhathir, 2024)membahas implementasi MobileNet pada klasifikasi daun teh, sementara (Gugus Azhari et al., 2023)menyoroti aplikasinya untuk penyakit daun cabai. Selain itu, (Tilasefana & Putra, 2023)menjelaskan teknik optimasi yang dapat diterapkan untuk meningkatkan efisiensi deteksi penyakit tanaman.

2. Penerapan CNN pada Tanaman Cabai (Usamah Putra Firdaus^{*1}, Yovi Litanianda² 1, 2024)serta (Gugus Azhari et al., 2023) memaparkan bahwa implementasi CNN untuk deteksi penyakit daun cabai menunjukkan hasil yang menjanjikan, terutama untuk penyakit keriting dan bercak daun. Penelitian ini diperkuat oleh (Rahayu et al., 2023),yang mengidentifikasi penyakit daun cabai dengan akurasi tinggi menggunakan dataset lokal.
3. Distribusi Dataset Keberhasilan model CNN sangat bergantung pada kualitas dan distribusi dataset yang digunakan. (Dzaky, 2021)menekankan pentingnya distribusi dataset yang seimbang untuk meningkatkan performa model, sementara (Azizah, 2023)mengkaji efektivitas penggunaan dataset dalam klasifikasi penyakit tanaman.
4. Komparasi Metode dan Arsitektur Berbagai arsitektur CNN seperti AlexNet, MobileNet, dan YOLO telah diterapkan untuk deteksi penyakit tanaman.(Bukhari, 2024) membandingkan AlexNet dan SqueezeNet, sedangkan penelitian (Laksono, 2024)"Deteksi Penyakit Tanaman dengan Convolution Neural Network: Kombinasi Arsitektur VGG16 dan ResNet34 untuk Klasifikasi Daun" menunjukkan bahwa kombinasi VGG16 dan ResNet34 memberikan akurasi tinggi dalam mengklasifikasikan penyakit tanaman. Selain itu, penelitian (Ardiansyah & Nugroho, 2023)"Klasifikasi Penyakit Daun Kopi dengan Arsitektur MobileNetV2" mendemonstrasikan efektivitas MobileNetV2 dalam mendeteksi penyakit daun kopi dengan efisiensi komputasi yang baik. Studi-studi ini menunjukkan bahwa pemilihan arsitektur sangat bergantung pada kebutuhan spesifik dan karakteristik dataset.

2. Metodologi

2.1 Metode pengumpulan data dan sampel


Data daun cabai yang digunakan untuk membuat model klasifikasi dikumpulkan secara langsung di lapangan. Pengumpulan data dimulai dengan pengambilan gambar daun cabai sehat dan keriting dari tanaman yang ada di Desa Sayana, Kecamatan Jalaksana, Kabupaten Kuningan. Gambar diambil dari berbagai sudut pandang dan pencahayaan untuk memastikan keberagaman data yang representatif. Setiap daun difokuskan secara manual untuk memastikan kualitas gambar yang jelas, dengan latar belakang alami. Pencahayaan alami digunakan untuk menghasilkan citra yang realistis, mencerminkan kondisi sebenarnya di lapangan. Kamera smartphone Xiaomi Redmi Note 12 digunakan dalam proses ini, menghasilkan resolusi gambar yang memadai untuk kebutuhan model Convolutional Neural Network (CNN).

Gambar yang diambil dikelompokkan ke dalam dua kategori utama, yaitu daun sehat dan daun keriting. Langkah ini

dilakukan secara hati-hati untuk menjaga keakuratan dalam pelabelan data. Dengan teknik pengumpulan data ini, diharapkan model yang dikembangkan mampu mendeteksi dan mengklasifikasikan daun cabai dengan akurasi tinggi berdasarkan ciri-ciri visualnya.

2.2 Metode analisis

Pada Penelitian ini menggunakan metode Convolutional Neural Network (CNN). CNN merupakan evolusi dari Multilayer Perceptron (MLP) yang dirancang khusus untuk mengolah data dua dimensi, seperti gambar. CNN menggunakan algoritma deep learning untuk mengidentifikasi objek dalam



gambar(Tilasefana & Putra, 2023). Gambar 3.3 menunjukkan langkah-langkah yang perlu dilakukan dalam studi ini, yaitu: Convolution, Pooling, Flattening, dan Full Connection(Amartama et al., 2024).

Gambar 3.3 Metode Convolutional Neural Network (CNN)

1. Convolution


Lapisan konvolusi bertugas untuk mengekstraksi fitur dari gambar masukan. Operasi konvolusi dilakukan dengan memindahkan filter ke seluruh gambar untuk menghasilkan peta fitur (*feature map*). Rumus dasar pada lapisan ini adalah:

$$M^p_j = f\left(\sum_{i \in M_j} M^p_{ij} * k^p + N^p\right)$$

Dimana p mewakili lapisan ke-p, k ij menunjukkan kernel konvolusional, Nj menunjukkan bias, dan Mj menunjukkan satu set peta masukan. Berbagai parameter arsitektur, seperti bias dan bobot kernel, adalah biasanya dilatih menggunakan pendekatan pembelajaran tanpa pengawasan.

2. Pooling

Pooling Layer merupakan suatu layer yang digunakan secara berturut turut dalam suatu arsitektur CNN dengan progresif. Tujuan digunakannya pooling layer ini yaitu mengambil *max pooling* atau nilai rata-rata dari bagian-bagian dari citra. Gambar 3.4 (Tilasefana & Putra, 2023)menunjukkan proses dari pooling layer



Gambar 3.4 Pooling

3. Flattening

Setelah *pooling*, peta fitur diratakan menjadi vektor satu dimensi melalui proses *flattening*. Vektor ini menjadi input bagi lapisan *fully connected*. Proses ini penting untuk

menghubungkan hasil ekstraksi fitur dengan tahap klasifikasi (Harahap et al., 2022)

4. Fully Connection

Fully connection layer digunakan untuk mengubah dimensi data sehingga data dapat diklasifikasikan secara linear. Untuk mendapatkan hasil dari lapisan ini, tidak diperlukan operasi konvolusi; sebaliknya, komputasi perkalian matriks diikuti dengan bias offset memungkinkan setiap neuron memiliki koneksi penuh ke semua aktivasi dalam lapisan sebelumnya. Akibatnya, lapisan ini disebut sebagai lapisan yang penuh terhubung (Amartama et al., 2024)


3. Hasil dan pembahasan

3.1 Pembahasan Data

Penelitian ini menghasilkan model dengan akurasi tinggi, yaitu 91% pada data pelatihan dan validasi, yang menunjukkan keberhasilan penerapan CNN dalam mendeteksi penyakit pada daun cabai secara akurat. Pada tahap preprocessing, dilakukan normalisasi nilai piksel ke rentang 0-1, pengubahan ukuran gambar menjadi 150x150 piksel, serta augmentasi data seperti rotasi dan flipping untuk meningkatkan variasi dalam dataset. Langkah ini bertujuan agar model memiliki data pelatihan yang lebih representatif.

Arsitektur model CNN dirancang mencakup lapisan convolutional untuk ekstraksi fitur utama, pooling untuk mengurangi dimensi data, serta dropout untuk mencegah overfitting. Selama pelatihan, penurunan nilai loss yang konsisten menunjukkan bahwa model semakin efektif dalam meminimalkan kesalahan prediksi. Penurunan ini dicapai melalui pengaturan parameter pelatihan yang optimal, seperti fungsi loss *binary_crossentropy* dan optimizer Adam. Meskipun demikian, fluktuasi kecil pada nilai loss kadang terjadi pada beberapa epoch akibat kompleksitas data atau variasi yang diperkenalkan melalui augmentasi.

Evaluasi model menggunakan metrik akurasi, precision, recall, dan F1-score menunjukkan kinerja yang optimal. Model ini kemudian diimplementasikan dengan menyimpan hasil pelatihan dan mengintegrasikannya ke dalam aplikasi berbasis web. Hasil analisis menunjukkan kemampuan model dalam memberikan prediksi yang akurat, sehingga metode ini terbukti efektif untuk tugas klasifikasi penyakit daun cabai.



Gambar 2. Hasil model

3.2 Pengolahan Data

Proses pengolahan data dilakukan melalui dua tahap utama. Tahap pertama adalah membagi dataset ke dalam kelompok data pelatihan, pengujian, dan validasi. Pembagian ini dilakukan dengan proporsi 80% untuk pelatihan, 10% untuk pengujian, dan 10% untuk validasi. Dari total 222 gambar, sebanyak 180 gambar digunakan untuk pelatihan, 22 gambar

untuk pengujian, dan 22 gambar untuk validasi. Pembagian ini diterapkan pada kedua kelas utama, yaitu daun sehat dan daun keriting, sebagaimana ditampilkan pada Tabel 4.2 berikut:

Tabel 2. umlah Pemisahan Data Train, Test, dan Validasi

o	N	Kelas	Tra n (80%)	Tes t (10%)	Valid si (10%)
1		Daun Sehat	89	11	11
2		Daun Keriting	91	11	11
To tal			180	22	22

tahap kedua adalah augmentasi data untuk meningkatkan variasi pada dataset pelatihan, sehingga model dapat lebih baik dalam mengenali pola daun cabai. Teknik augmentasi data ini dilakukan menggunakan pustaka *ImageDataGenerator* dengan menerapkan berbagai transformasi, seperti rotasi, pergeseran, zoom, dan flipping. Parameter yang digunakan dalam proses augmentasi ditampilkan pada Tabel 4.3.

Tabel 3. Parameter Augmentasi Data

Image Data Generator	train_data gen	test_data gen
Rescale	1./255	1./255
Rotation Range	40	-
Shear Range	0.2	-
Zoom Range	0.2	-
Horizontal Flip	True	-
Width Shift Range	0.2	-
Height Shift Range	0.2	-

3.3 Pemodelan

Setelah proses pengolahan data selesai, dataset diintegrasikan ke dalam model atau arsitektur CNN yang telah dirancang.

Model CNN terdiri atas lapisan konvolusi pertama yang memanfaatkan fungsi aktivasi ReLU serta MaxPooling untuk mengekstraksi fitur utama dari gambar. Hasil keluaran dari lapisan pertama ini menjadi input untuk lapisan konvolusi kedua, dan proses ini terus berlanjut hingga seluruh lapisan selesai diproses. Pada lapisan akhir, data diratakan menggunakan metode Flatten, lalu diteruskan ke lapisan fully connected untuk menghasilkan output akhir. Untuk mencegah overfitting selama pelatihan, diterapkan metode Dropout. Model CNN yang digunakan ditampilkan pada tabel berikut:

Tabel 4. Pemodelan

Layer (type)	Output Shape	Param #
conv2d_1 (Conv2D)	(None, 148, 148, 32)	896
max_pooling2d_1 (MaxPooling2D)	(None, 74, 74, 32)	0
conv2d_2 (Conv2D)	(None, 72, 72, 64)	18,496
max_pooling2d_2 (MaxPooling2D)	(None, 36, 36, 64)	0
conv2d_3 (Conv2D)	(None, 34, 34, 128)	73,856
max_pooling2d_3 (MaxPooling2D)	(None, 17, 17, 128)	0
flatten (Flatten)	(None, 36992)	0
dense_1 (Dense)	(None, 128)	4,735,104
dropout (Dropout)	(None, 128)	0
dense_2 (Dense)	(None, 1)	129

Total Parameter:

- Parameter total: 4,828,481
- Parameter yang dapat dilatih (*trainable params*): 4,828,481
- Parameter yang tidak dapat dilatih (*non-trainable params*): 0


Model dilatih selama 10 epoch, menghasilkan akurasi terbaik sebesar 91% pada data pengujian. Hasil ini menunjukkan kemampuan model yang sangat baik dalam mengenali dan mengklasifikasikan citra daun cabai berdasarkan kategorinya.

3.4 Evaluasi

Proses evaluasi kinerja model bertujuan untuk memastikan bahwa model yang telah dikembangkan mampu memberikan performa yang baik pada data baru yang belum pernah dilatih sebelumnya. Salah satu metode yang digunakan untuk mengevaluasi model adalah *confusion matrix*.

Confusion matrix memberikan gambaran tentang seberapa baik model mampu mengklasifikasikan data ke dalam kategori yang benar. Selain itu, matriks ini juga mengungkapkan kesalahan prediksi yang dilakukan oleh model.

3.5 Interpretasi dari Confusion matrix



Gambar 3. confusion matrik

Berdasarkan *confusion matrix* yang telah disusun, model ini menunjukkan adanya beberapa kesalahan dalam mengklasifikasikan gambar daun sehat dan keriting. Walaupun terdapat kesalahan dalam prediksi, matriks ini memberikan gambaran yang cukup jelas mengenai performa model. Informasi ini dapat digunakan sebagai acuan untuk langkah-langkah perbaikan selanjutnya.

Untuk mengevaluasi kinerja model secara lebih mendalam, beberapa metrik tambahan dapat digunakan, seperti:

- **Akurasi:** Mengukur seberapa baik model mengklasifikasikan data secara keseluruhan. Akurasi dihitung dengan formula: $\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN}$. Di mana TP adalah *true positive*, TN adalah *true negative*, FP adalah *false positive*, dan FN adalah *false negative*.
- **Presisi:** Mengukur proporsi prediksi positif yang benar.
- **Recall:** Mengukur kemampuan model dalam mendeteksi semua kasus positif.
- **F1-score:** Harmonik rata-rata antara presisi dan recall, memberikan keseimbangan antara keduanya.

Setelah menghitung metrik tersebut, dapat disimpulkan bahwa meskipun model memiliki ruang untuk perbaikan, hasil klasifikasinya cukup baik untuk mengidentifikasi daun sehat dan keriting. Dengan optimalisasi lebih lanjut, model ini diharapkan dapat mencapai performa yang lebih tinggi.

3.6 Implementasi



Gambar 4 Implementasi

Setelah model berhasil di-deploy menggunakan *framework* Flask, implementasi ini memberikan kontribusi signifikan terhadap kinerja sistem berbasis web. Dengan memanfaatkan model yang telah dilatih, aplikasi berbasis Flask mampu menyediakan prediksi atau hasil klasifikasi secara cepat dan akurat untuk kategori daun sehat dan daun keriting. Pengguna dapat dengan mudah mengakses fungsi ini melalui antarmuka web yang dirancang sederhana dan responsif.

Integrasi model ke dalam aplikasi Flask menghadirkan kemudahan akses bagi pengguna, menciptakan solusi yang terintegrasi, dan memungkinkan klasifikasi daun dilakukan langsung melalui sistem berbasis web. Dengan dukungan model terlatih, aplikasi mampu memberikan hasil prediksi yang relevan, sehingga dapat dimanfaatkan sebagai referensi dalam menentukan kondisi daun cabai.

Penggunaan Flask sebagai *framework* pengembangan memberikan fleksibilitas dalam pengolahan data dan memastikan efisiensi sistem. Respons aplikasi yang cepat dengan prediksi yang dapat diperoleh dalam waktu singkat membuat sistem ini praktis dan efektif untuk kebutuhan klasifikasi berbasis citra.

Secara keseluruhan, *deploy* model menggunakan Flask tidak hanya meningkatkan performa sistem tetapi juga meningkatkan pengalaman pengguna dalam mengakses informasi berkualitas dan akurat terkait klasifikasi daun cabai. Sistem ini memiliki potensi menjadi alat bantu yang bermanfaat dalam pengambilan keputusan, terutama dalam penerapan teknologi di bidang pertanian.

4. Kesimpulan

Model Convolutional Neural Network (CNN) yang dikembangkan dalam penelitian ini menunjukkan efektivitas yang tinggi dalam mengklasifikasikan penyakit daun cabai, khususnya dalam membedakan antara daun sehat dan daun yang terkena penyakit keriting. Dengan akurasi yang mencapai 91%, model ini membuktikan bahwa pendekatan berbasis deep learning sangat potensial untuk diterapkan dalam sektor pertanian, khususnya dalam deteksi dini penyakit tanaman. Salah satu faktor yang turut menunjang keberhasilan ini adalah penerapan teknik augmentasi data, yang memberikan variasi tambahan pada dataset dan memungkinkan model untuk mengenali pola dengan lebih baik. Augmentasi seperti rotasi, flipping, dan zoom telah berhasil memperluas cakupan data pelatihan, sehingga meningkatkan kemampuan generalisasi model terhadap data baru yang belum pernah ditemui sebelumnya. Selain dari sisi teknis pemodelan, penelitian ini juga memberikan kontribusi nyata melalui implementasi berbasis web menggunakan *framework* Flask. Pendekatan ini memungkinkan pengguna, khususnya para petani,

untuk melakukan prediksi secara langsung dan real-time melalui antarmuka yang sederhana dan mudah diakses. Dengan demikian, teknologi ini tidak hanya memberikan hasil yang akurat dalam mendeteksi penyakit, tetapi juga menawarkan solusi praktis yang dapat diadopsi secara luas di lapangan. Hasil dari penelitian ini diharapkan dapat menjadi langkah awal menuju pengembangan sistem monitoring pertanian yang lebih cerdas dan terintegrasi, yang pada akhirnya mampu meningkatkan produktivitas, efisiensi, serta ketahanan pangan secara berkelanjutan.

Daftar pustaka

- Amartama, S. N., Hidayah, A. N., Sari, P. K., & Ramadhani, R. A. (2024). Implementasi Convolutional Neural Network (CNN) dalam Pengenalan Pola Penulisan Tangan. *Seminar Nasional Teknologi & Sains*, 3(1), 133–138. <https://doi.org/10.29407/stains.v3i1.4155>
- Anggraeni, D. S., Widayana, A., Rahayu, P. D., & Rozikin, C. (2022). Metode Algoritma Convolutional Neural Network pada Klasifikasi Penyakit Tanaman Cabai. *STRING (Satuan Tulisan Riset Dan Inovasi Teknologi)*, 7(1), 73. <https://doi.org/10.30998/string.v7i1.13304>
- Ardiansyah, A. S., & Nugroho, A. (2023). Klasifikasi Penyakit Daun Kopi Dengan Arsitektur MobileNetV2. *Jurnal Ilmu Komputer Dan Bisnis*, 14(1), 66–73. <https://doi.org/10.47927/jikb.v14i1.622>
- Azizah, Q. N. (2023). Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network AlexNet. *Sudo Jurnal Teknik Informatika*, 2(1), 28–33. <https://doi.org/10.56211/sudo.v2i1.227>
- Bukhari, S. A. (2024). Implementasi Metode Convolutional Neural Network (Cnn) Untuk Diagnosa Penyakit Tanaman Cabai Pada Citra Daun. *Jurnal Multidisiplin Saintek*, 3(0), 1–11.
- Dzaky, A. T. R. (2021). Deteksi Penyakit Tanaman Cabai Menggunakan Metode Convolutional Neural Network. *E-Proceeding of Engineering*, 8(2), 3039–3055. <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/14701/14478>
- Febriady Marpaung, Nurul Khairina, Rizki Muliono3, Muhathir, S. (2024). Penerapan Arsitektur Mobilenetv2 Pada Klasifikasi Penyakit Daun Teh. *INOTEK*, 8, 215–225.
- Gugus Azhari, M., Ajid Husain, M., & Lutfi, M. (2023). Transfer Learning Convolutional Neural Network Dengan Arsitektur Efficientnet Untuk Identifikasi Penyakit Daun Cabai. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(5), 3662–3666. <https://doi.org/10.36040/jati.v7i5.7791>
- Harahap, F. A. A., Sinaga, R. M., Arifin, K., & S, K. (2022). Implementasi Algoritma Convolutional Neural Network Untuk Mendeteksi Penyakit Ginjal Implementation of Convolutional Neural Network for Detecting Kidney Disease. *Teknologi Informasi, Komputer Dan Aplikasinya (JTika)*, 4(2), 212–219. <http://jtika.if.unram.ac.id/index.php/JTika/>
- Hawari, F. H., Fadillah, F., Alviandi, M. R., & Arifin, T. (2022). Klasifikasi Penyakit Tanaman Padi Menggunakan Algoritma Cnn (Convolutional Neural Network). *Jurnal Responsif: Riset Sains Dan Informatika*, 4(2), 184–189. <https://doi.org/10.51977/jti.v4i2.856>

- Laksono, F. B. (2024). Deteksi penyakit tanaman dengan convolution neural network: Kombinasi arsitektur VGG16 dan ResNet34 untuk klasifikasi daun. *Jurnal Komputer Dan Teknologi Informasi*, 2(2), 72–79. <https://doi.org/10.26714/jkti.v2i2.13932>
- Rahayu, S., Wulanningrum, R., & Wahyuniar, L. S. (2023). Identifikasi Penyakit Pada Daun Cabai Rawit (*Capsicum Frutescens*) Di Desa Krenceng Kecamatan Kepung Kabupaten Kediri. *Agustus*, 7, 2549–7952.
- Tilasefana, R. A., & Putra, R. E. (2023). Penerapan Metode Deep Learning Menggunakan Algoritma CNN Dengan Arsitektur VGG NET Untuk Pengenalan Cuaca. *Journal of Informatics and Computer Science (JINACS)*, 05(1), 48–57.
- Usamah Putra Firdaus*1, Yovi Litanianda2 1, 2Universitas. (2024). Deteksi Penyakit Tanaman Cabai Menggunakan Metode Convolutional Neural Network. *E-Proceeding of Engineering*, 8(2), 3039–3055. <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/14701/14478>