

## KLASIFIKASI PENYAKIT PADA DAUN TOMAT MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN)

Jadianan Parhusip<sup>1)</sup>, Ferdy Afriza Maulana<sup>2)</sup>, Rizqullah Falah Mahendra<sup>3)</sup>, Athay Setya Dwi Putri<sup>4)</sup>

<sup>1)</sup> “Teknik Informatika” Universitas Palangka Raya

<sup>2)</sup> “Teknik Informatika” Universitas Palangka Raya

<sup>3)</sup> “Teknik Informatika” Universitas Palangka Raya

<sup>4)</sup> “Teknik Informatika” Universitas Palangka Raya

Email : parhusip.jadianan@it.upr.ac.id<sup>1)</sup>, ferdyafriza.m@mhs.eng.upr.ac.id<sup>2)</sup>, rizqulahfalahmahendra@mhs.eng.upr.ac.id<sup>3)</sup>, athaysetyadwiputri@mhs.eng.upr.ac.id<sup>4)</sup>

### Abstract

Tomato leaf diseases significantly affect crop productivity, and manual inspection often leads to misclassification due to the visual similarity of symptoms. Previous studies across various plant species, such as rice, banana, potato, and several horticultural plants, demonstrate that Convolutional Neural Networks (CNN) consistently achieve high accuracy in leaf-based disease classification, strengthening their role in early disease detection. This study aims to develop an accurate tomato leaf disease classification system using a CNN model trained on the Kaggle tomato leaf dataset consisting of four classes: Leaf Blight, Bacterial Spot, Leaf Scab, and Healthy. The methodology includes literature review, dataset acquisition, preprocessing, augmentation, CNN architecture design, model training, and evaluation. The model achieved 0.98 training accuracy with a loss of 0.07, while validation accuracy peaked at 0.94. Tests on single and multiple images show high-confidence predictions with only minor misclassifications in visually similar cases. These results highlight CNN's reliability for supporting early tomato disease detection within smart agriculture applications.

**Keywords :** Convolutional Neural Network, Tomato Leaf Disease, Image Classification, Deep Learning, Smart Agriculture

### Abstrak

Penyakit pada daun tomat dapat menurunkan produktivitas tanaman, sedangkan identifikasi manual sering menimbulkan kesalahan akibat kemiripan gejala antarpenyakit. Berbagai penelitian pada berbagai komoditas seperti padi, pisang, kentang, herbal, hingga tanaman hias menunjukkan bahwa *Convolutional Neural Network (CNN)* mampu memberikan akurasi tinggi dalam klasifikasi penyakit berbasis citra daun, sehingga menjadi pendekatan yang relevan dan dapat diandalkan untuk deteksi dini penyakit tanaman. Penelitian ini bertujuan mengembangkan sistem klasifikasi penyakit daun tomat berbasis *CNN* menggunakan *dataset Kaggle* yang terdiri dari empat kelas, yaitu Hawar Daun, Infeksi Bakteri, Kudis Daun, dan Sehat. Metode penelitian meliputi studi literatur, pengumpulan *dataset*, *preprocessing*, *augmentasi*, perancangan arsitektur *CNN*, pelatihan model, serta evaluasi performa. Model dilatih selama 40 *epoch* dengan ukuran *batch* 16 dan menunjukkan peningkatan akurasi secara konsisten hingga mencapai 0,98 dengan *loss* 0,07, sementara akurasi validasi terbaik mencapai 0,94. Pengujian pada citra tunggal maupun sembilan citra menunjukkan bahwa model mampu menghasilkan prediksi dengan tingkat *confidence* tinggi, meskipun masih terjadi kesalahan minor pada kelas dengan kemiripan tekstur dan warna. Secara keseluruhan, sistem ini efektif dalam mengklasifikasikan penyakit daun tomat dan berpotensi mendukung implementasi deteksi dini pada konsep *smart agriculture*.

**Kata kunci :** Convolutional Neural Network, Penyakit Daun Tomat, Klasifikasi Citra, Deep Learning, Smart Agriculture

## 1. Pendahuluan

Perkembangan teknologi digital telah menghadirkan peluang besar dalam meningkatkan efisiensi sektor pertanian, terutama dalam proses identifikasi penyakit tanaman berbasis citra daun. Selama ini, petani umumnya masih mengandalkan pengamatan visual yang bersifat subjektif, sangat bergantung pada pengalaman, serta rentan terhadap kesalahan identifikasi. Kondisi tersebut dapat menunda penanganan dini dan berdampak pada menurunnya produktivitas tanaman. Oleh karena itu, pemanfaatan *computer vision* dan *deep learning* menjadi solusi yang semakin banyak diteliti untuk meningkatkan akurasi identifikasi penyakit tanaman (Setiawan et al., 2023).

Di antara berbagai pendekatan, *Convolutional Neural Network (CNN)* menjadi metode yang paling dominan digunakan karena kemampuannya dalam mengekstraksi fitur visual secara otomatis dan mendalam. *CNN* efektif mengenali pola penting seperti tekstur, warna, dan bentuk gejala penyakit yang sering kali sulit dibedakan melalui pengamatan manusia (Hasan et al., 2021). Berbagai penelitian telah membuktikan keunggulan *CNN* pada tanaman apel, anggur, gandarusa, padi, kubis, hingga tomat.

Penelitian oleh Husen et al. (2022) menunjukkan bahwa *CNN* mampu mencapai akurasi hingga 99,66% dalam mendeteksi hama pada daun apel, menegaskan efektivitas metode ini pada *dataset* yang kompleks. Temuan serupa juga terlihat pada penelitian identifikasi kualitas daun gambir menggunakan arsitektur *miniVGGNet* yang mencatat akurasi mencapai 99,87% (Winanda et al., 2021). Selain itu, klasifikasi penyakit pada daun pisang melalui *transfer learning VGG19* juga menunjukkan performa akurasi kuat sebesar 92% (Pratama et al., 2024).

Pada studi lainnya, Kasim et al. (2023) mengimplementasikan *CNN* untuk mengklasifikasikan tanaman herbal dan memperoleh akurasi 92,74%, menegaskan kemampuan *CNN* dalam mengenali variasi morfologi daun yang sangat beragam. Pada tanaman pangan, *CNN* melalui proses *cross-validation* juga berhasil mengidentifikasi penyakit daun kubis dengan akurasi mencapai 100% (Sembung et al., 2022). Sementara itu, penelitian pada daun kentang menunjukkan akurasi validasi hingga 99% dalam membedakan penyakit *early blight* dan *late blight* (Lesmana et al., 2022). Bahkan pada tanaman padi yang memiliki gejala penyakit sangat mirip, *CNN* mampu mencapai akurasi hingga 98% (Khoiruddin et al., 2022).

Enam penelitian tambahan yang lebih mutakhir juga memperkuat dominasi *CNN* dalam klasifikasi citra daun. Rijal et al. (2024) menunjukkan bahwa *CNN* mampu mengidentifikasi penyakit daun padi dengan akurasi pelatihan 99,05% pada *epoch* ke-50, menjadikannya solusi yang relevan untuk komoditas pangan utama. Imanulloh et al. (2023) mengembangkan arsitektur *CNN* ringan yang berhasil mengklasifikasikan 38 kelas penyakit tanaman dengan akurasi 97% dan terbukti unggul dibanding model populer seperti *InceptionV3* dan *MobileNetV2*. Panjaitan et al. (2024) membuktikan efektivitas *CNN* dalam klasifikasi daun tomat dengan akurasi pelatihan mencapai 94,06% pada *dataset* besar.

Selain itu, Suswati (2024) mengimplementasikan *CNN* untuk mengenali tujuh jenis tanaman hias dan berhasil memperoleh akurasi 100% pada data uji. Setiyono et al. (2023) menggunakan *CNN* berbasis *EfficientNetV2* untuk mengidentifikasi tanaman herbal Indonesia dan memperoleh akurasi rata-rata 98%. Sementara itu, Ramadhani et al. (2022) yang menerapkan *VGG-16* pada klasifikasi 23 kelas citra daun memperoleh akurasi 92,6%, menunjukkan bahwa model *CNN* yang lebih kompleks tetap efektif untuk berbagai variasi vegetasi.

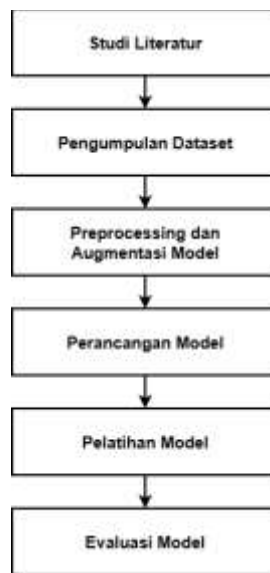
Konsistensi akurasi tinggi dari berbagai penelitian tersebut menunjukkan bahwa *CNN* memiliki kemampuan yang sangat baik dalam menangani tantangan utama pada identifikasi visual, seperti kemiripan gejala antarpenyakit, variasi pencahayaan, perbedaan sudut pengambilan gambar, serta *noise* pada citra. Hal ini menjadikan *CNN* sebagai pendekatan yang sangat potensial untuk terus dikembangkan dalam mendukung sistem deteksi dini penyakit tanaman di berbagai komoditas.

Berdasarkan berbagai temuan tersebut, dapat disimpulkan bahwa pengembangan sistem

klasifikasi penyakit daun berbasis *CNN* merupakan langkah strategis untuk mendukung implementasi *smart agriculture*. Sistem ini tidak hanya meningkatkan akurasi identifikasi, tetapi juga mempercepat pengambilan keputusan bagi petani sehingga potensi kerugian dapat diminimalkan. Oleh karena itu, penelitian lanjutan sangat diperlukan untuk mengoptimalkan performa model, memperluas variasi *dataset*, serta meningkatkan kemampuan generalisasi pada kondisi lapangan yang lebih dinamis.

## 2. Metode Penelitian

Tahapan penelitian dalam pengembangan sistem klasifikasi penyakit daun tomat berbasis *Convolutional Neural Network (CNN)* dilakukan melalui beberapa tahap, yaitu studi literatur, pengumpulan *dataset*, *preprocessing*, perancangan model *CNN*, pelatihan model, serta evaluasi model.



**Gambar 1.** Tahapan Penelitian

### a. Studi Literatur

Tahap ini dilakukan untuk mempelajari karakteristik penyakit daun tomat, konsep dasar pengolahan citra, serta penerapan *Convolutional Neural Network (CNN)* dalam klasifikasi gambar. Informasi teoritis yang diperoleh menjadi dasar dalam penentuan arsitektur model, parameter pelatihan, serta teknik evaluasi yang nantinya terlihat pada bagian hasil, khususnya pada perubahan nilai akurasi dan *loss* selama proses pelatihan.

### b. Pengumpulan Dataset

*Dataset* berasal dari platform *Kaggle*, yang berisi 400 citra daun tomat dengan empat kategori: hawar daun, infeksi bakteri, kudis daun, dan sehat. *Dataset* ini digunakan pada seluruh proses pelatihan dan pengujian, serta menjadi acuan dalam membaca perkembangan performa model pada bagian pembahasan.

### c. *Preprocessing* dan *Augmentasi*

Tahapan *preprocessing* mencakup penyeragaman ukuran citra, normalisasi piksel, serta *augmentasi* seperti *random flip* dan *random rotation*. Teknik *augmentasi* ini diterapkan untuk memperluas variasi data yang berperan dalam stabilitas pelatihan. Pembagian *dataset* dilakukan dalam proporsi data latih, validasi, dan uji, yang kemudian memengaruhi pola peningkatan akurasi dan penurunan *loss* yang tampak pada bagian hasil.

d. Perancangan Model

Arsitektur *CNN* dirancang secara *sequential* dengan kombinasi lapisan konvolusi, *batch normalization*, dan *max pooling* untuk mengekstraksi fitur citra secara bertahap. Setelah itu, lapisan *flatten* dan *fully connected* digunakan sebelum menghasilkan keluaran empat kelas melalui *softmax*. Pemilihan arsitektur ini didasarkan pada studi literatur dan bertujuan menghasilkan pola pembelajaran yang kemudian dapat diamati pada grafik performa pelatihan yang ditampilkan dalam pembahasan.

e. Pelatihan Model

Pelatihan dilakukan selama 40 *epoch* dengan ukuran *batch* 16. Pada setiap *epoch*, nilai akurasi dan *loss* pada data latih dan validasi dihitung. Hasil pencatatan nilai tersebut terlihat jelas pada bagian pembahasan, yang menunjukkan bagaimana model mengalami peningkatan performa sejalan dengan bertambahnya *epoch*.

f. Pengujian

Pengujian kuantitatif dilakukan dengan melihat akurasi dan *loss* pada data uji, yang hasilnya mendukung pola performa selama pelatihan sebagaimana digambarkan pada pembahasan.

Pengujian kualitatif dilakukan dengan menguji citra tunggal serta beberapa citra uji lainnya. Hasil visual dari pengujian ini dapat dilihat pada bagian pembahasan, yang menunjukkan kesesuaian antara label aktual, prediksi model, dan nilai *confidence* yang dihasilkan.

### 3. Hasil dan Pembahasan

#### 3.1 Hasil Pelatihan Model

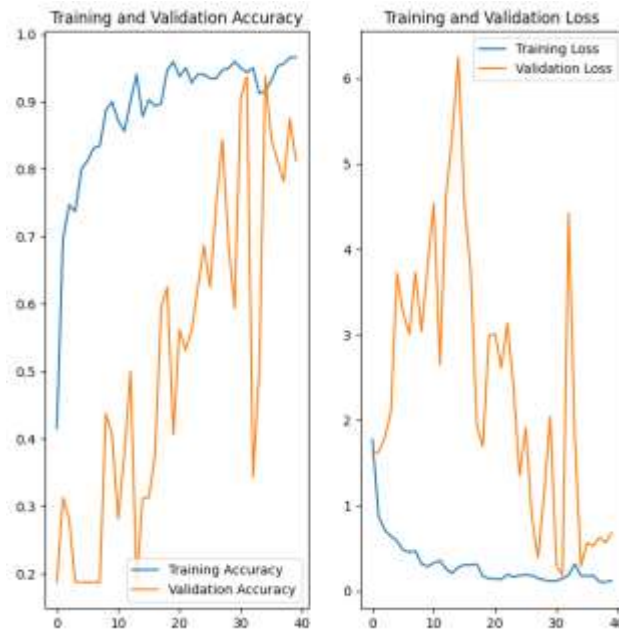
Hasil pelatihan menunjukkan bahwa akurasi model meningkat secara bertahap sepanjang 40 *epoch*, sementara nilai *loss* pada data latih terus menurun. Akurasi *validation* turut mengalami peningkatan meskipun terdapat sedikit fluktuasi pada beberapa *epoch*. Secara keseluruhan, pola tersebut menunjukkan bahwa model mampu mempelajari fitur daun tomat dengan baik tanpa indikasi *overfitting* yang berarti. Rangkuman perkembangan akurasi dan *loss* selama proses pelatihan ditunjukkan pada Tabel 1.

**Tabel 1.** Hasil Pelatihan Model

| Epoch | Accuracy | Loss   | Val_Accuracy | Val_Loss |
|-------|----------|--------|--------------|----------|
| 1     | 0.3824   | 2.0822 | 0.1875       | 1.6103   |
| 5     | 0.7737   | 0.6379 | 0.1875       | 3.7221   |
| 10    | 0.9125   | 0.2525 | 0.4062       | 3.8118   |
| 20    | 0.9689   | 0.1188 | 0.4062       | 2.9892   |
| 30    | 0.9561   | 0.1233 | 0.5938       | 2.0418   |
| 40    | 0.9815   | 0.0774 | 0.8125       | 0.6785   |

Akurasi model mengalami peningkatan signifikan selama pelatihan, di mana akurasi *training* naik dari 0,38 pada *epoch* 1 hingga mencapai 0,98 pada *epoch* 40. Akurasi *validation* juga menunjukkan tren peningkatan dan mencapai nilai terbaik 0,94 pada *epoch* 32. Sejalan dengan itu, nilai *loss* turut menurun secara konsisten; *training loss* turun dari 1,70 menjadi 0,07, sedangkan *validation loss* mencapai nilai terendah 0,18 pada *epoch* 32. Hasil *training*


dan *validation* dapat dilihat pada Gambar 2.



**Gambar 2.** Grafik Training dan Validation

### 3.2 Pengujian Model

Pada pengujian citra tunggal, model diberikan satu citra daun dari *test set* untuk dievaluasi. Citra tersebut memiliki pola bercak dan perubahan warna yang menjadi ciri khas penyakit tertentu sesuai label aktualnya. Hasil prediksi menunjukkan bahwa model mampu mengklasifikasikan citra tersebut dengan benar dan menghasilkan label yang sesuai dengan kelas aktual. Nilai *confidence* yang tinggi pada prediksi ini menegaskan bahwa model dapat mengenali pola visual utama pada daun, seperti tekstur kerusakan dan distribusi bercak, sehingga mampu melakukan identifikasi penyakit dengan akurat pada satu citra uji. Hasil pengujian citra tunggal dapat dilihat pada Gambar 3.

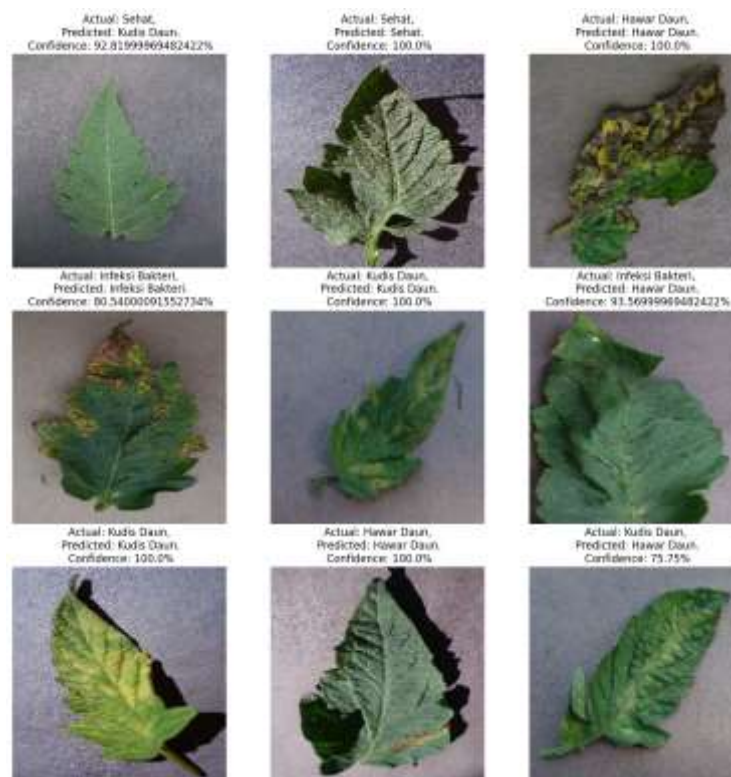


**Gambar 3.** Hasil Pengujian Citra Tunggal



Pengujian lanjutan dilakukan dengan menguji sembilan citra daun sekaligus dari *test set* untuk menilai konsistensi performa model pada berbagai kondisi visual. Hasil pengujian menunjukkan bahwa sebagian besar citra berhasil diprediksi dengan benar dan memiliki tingkat *confidence* yang tinggi, bahkan beberapa mencapai 100%, terutama pada kelas “Sehat”, “Kudis Daun”, dan “Hawar Daun”. Pada beberapa citra lain, misalnya yang berlabel “Infeksi Bakteri”, model tetap mampu menghasilkan prediksi yang sesuai dengan tingkat *confidence* di atas 80%, menunjukkan pemahaman fitur yang stabil.

Meskipun terdapat satu-dua kasus prediksi yang tidak sesuai, seperti citra berlabel “Kudis Daun” yang diprediksi sebagai “Hawar Daun” dengan *confidence* 75,75%, perbedaan ini dapat terjadi karena kemiripan visual antar jenis penyakit, terutama pada pola bercak dan perubahan warna daun. Secara keseluruhan, hasil pengujian pada sembilan citra ini menggambarkan bahwa model mampu mengenali pola penyakit secara konsisten dan tetap memberikan prediksi yang kuat pada sebagian besar sampel uji. Hasil pengujian sembilan citra dapat dilihat pada Gambar 4.



Gambar 4. Hasil Pengujian Sembilan Citra

#### 4. Kesimpulan

Penelitian ini berhasil mengembangkan sistem klasifikasi penyakit daun tomat berbasis *Convolutional Neural Network (CNN)* yang mampu mengenali empat kelas penyakit, yaitu Hawar Daun, Infeksi Bakteri, Kudis Daun, dan Sehat. Berdasarkan proses pelatihan selama 40 *epoch*, model menunjukkan performa yang sangat baik dengan akurasi *training* mencapai 0,98 dan akurasi *validasi* terbaik sebesar 0,94, menandakan bahwa model mampu mempelajari fitur visual daun secara efektif tanpa mengalami *overfitting* yang signifikan.

Hasil pengujian menggunakan citra tunggal maupun sembilan citra uji memperlihatkan bahwa model mampu memberikan prediksi dengan tingkat *confidence* tinggi serta konsisten pada sebagian besar sampel. Kesalahan klasifikasi yang muncul umumnya disebabkan oleh

kemiripan tekstur dan pola warna antar jenis penyakit, namun tidak memengaruhi performa keseluruhan model secara signifikan. Dengan demikian, dapat disimpulkan bahwa metode *CNN* layak dan efektif digunakan dalam sistem deteksi dini penyakit daun tomat serta mendukung pengembangan solusi berbasis *smart agriculture*.

Saran untuk penelitian selanjutnya meliputi penggunaan *dataset* yang lebih beragam untuk meningkatkan generalisasi model, penerapan teknik *augmentasi* lanjutan untuk memperkaya variasi citra, serta eksplorasi arsitektur *CNN* yang lebih kompleks atau metode *transfer learning* guna memperoleh performa klasifikasi yang lebih optimal.

### Daftar Pustaka

- Hasan, M. A., Riyanto, Y., & Riana, D. (2021). Klasifikasi penyakit citra daun anggur menggunakan model CNN-VGG16. *Jurnal Teknologi dan Sistem Komputer*, 9(4), 218–223.
- Henry, G., Panjaitan, A., & Simatupang, F. (2024). Pemodelan Klasifikasi Penyakit Daun Tanaman Tomat dengan Convolutional Neural Network Algorithm. *KLIK: Kajian Ilmiah Informatika dan Komputer*, 4(5), 2667-2667.
- Husen, D., Kusriani, K., & Kusnawi, K. (2022). Deteksi Hama Pada Daun Apel Menggunakan Algoritma Convolutional Neural Network. *Jurnal Media Informatika Budidarma*, 6(4), 2103–2110.
- Imanulloh, S. B., Muslikh, A. R., & Setiadi, D. R. I. M. (2023). Plant diseases classification based leaves image using convolutional neural network. *Journal of Computing Theories and Applications*, 1(1), 1-10.
- Irfansyah, D., Mustikasari, M., & Suroso, A. (2021). Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi. *Jurnal Informatika: Jurnal Pengembangan IT*, 6(2), 87–92.
- Kasim, N., Fadilah, M. B., Al Hidayat, W., & Saputra, R. A. (2024). Klasifikasi Jenis Tanaman Herbal Berdasarkan Citra Menggunakan Metode Convolution Neural Network (CNN). *vol*, 19, 64–78.
- Khoiruddin, M., Junaidi, A., & Saputra, W. A. (2022). Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network. *Journal of Dinda: Data Science, Information Technology, and Data Analytics*, 2(1), 37–45.
- Lesmana, A. M., Fadhillah, R. P., & Rozikin, C. (2022). Identifikasi Penyakit pada Citra Daun Kentang Menggunakan Convolutional Neural Network (CNN). *Jurnal Sains dan Informatika*, 8(1), 21–30.
- Pratama, M. D., Gustriansyah, R., & Purnamasari, E. (2024). Klasifikasi Penyakit Daun Pisang menggunakan Convolutional Neural Network (CNN). *Jurnal Teknologi Terpadu*, 10(1), 1–6.
- Ramadhani, I. R., Nilogiri, A., & A'yun, Q. (2022). Klasifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network. *Jurnal Smart Teknologi*, 3(3), 249-260.
- Rijal, M., Yani, A. M., & Rahman, A. (2024). Deteksi Citra Daun untuk Klasifikasi Penyakit Padi menggunakan Pendekatan Deep Learning dengan Model CNN. *Jurnal Teknologi Terpadu*, 10(1), 56-62.
- Sembung, J., Latumakulita, L. A., & Komalig, H. A. H. (2022). Sistem Identifikasi Penyakit pada Tanaman Kubis menggunakan Metode Convolutional Neural Network (CNN). *Indonesian Journal of Intelligence Data Science*, 1(2), 13–25.
- Setiawan, M. J., Nugroho, B., & Sari, A. P. (2023). Klasifikasi Penyakit Daun Tanaman Menggunakan Algoritma CNN dan Random Forest: Classification Leaf Diseases. *Teknologi: Jurnal Ilmiah Sistem Informasi*, 13(2), 12–18.
- Setiyono, B., Arif, M. R. A., Aini, Q. Q., Soegianto, T. H., Ohanna, J., Gunawan, R. A. F., & Rizkia, A. P. (2023). Identifikasi Tanaman Obat Indonesia Melalui Citra Daun

Menggunakan Metode Convolutional Neural Network (CNN). *J. Teknol. Inf. dan Ilmu Komput.*

Suswati, B. (2024). Implementasi Convolutional Neural Network pada Klasifikasi Citra Daun Tanaman Hias. *Decode: Jurnal Pendidikan Teknologi Informasi*, 4(2), 554-565.

Winanda, T., Yuhandri, Y., & Hendrick, H. (2021). Klasifikasi Kualitas Mutu Daun Gambir Ladang Rakyat Menggunakan Metode Convolutional Neural Network. *Jurnal Sistim Informasi dan Teknologi*, 102–107.