

Penerapan Metode Transfer Learning untuk Klasifikasi Penyakit Tanaman Kembang Kol dengan Arsitektur Inception V3

Randy Marsevin*, Tri Hasanah Bimastari Aviani, A. Taqwa Martadinata, Budi Santoso

Universitas Bina Insan Lubuklinggau

Abstrak: Indonesia sebagai negara agraris menghadapi tantangan dalam produksi pertanian, khususnya akibat serangan hama dan penyakit yang menurunkan kualitas hasil panen kembang kol (*Brassica oleracea* var. *botrytis* L). Penelitian ini mengembangkan model klasifikasi penyakit tanaman kembang kol menggunakan metode *transfer learning* berbasis arsitektur Inception V3. Dataset terdiri dari empat kelas: Bacterial Spot Rot, Black Rot, Downy Mildew, dan No Disease, diperoleh dari Kaggle. Proses pengembangan mengikuti tahapan CRISP-DM, mulai dari pra-pemrosesan data, pelatihan model, hingga evaluasi. Model dilatih dengan memanfaatkan bobot awal dari ImageNet, diikuti dengan penyesuaian beberapa lapisan klasifikasi dan penggunaan teknik *fine-tuning* serta augmentasi data. Evaluasi performa dilakukan dengan metrik akurasi, precision, recall, dan F1-score. Hasil akhir menunjukkan akurasi validasi sebesar 93,75% dan akurasi pengujian mencapai 99%, dengan nilai precision dan recall yang seimbang (93,75%). Model terbukti efektif dalam mengklasifikasi penyakit tanaman dan memiliki potensi untuk diterapkan pada sistem deteksi otomatis berbasis citra guna mendukung pertanian presisi secara real-time.

Kata Kunci: Deep Learning, Transfer Learning, Inception V3, Klasifikasi Penyakit, Kembang Kol

DOI:

<https://doi.org/10.47134/ijat.v2i4.5167>

*Correspondence: Randy Marsevin

Email: rmarsevin@gmail.com

Received: 11-09-2025

Accepted: 20-09-2025

Published: 27-10-2025



Copyright: © 2025 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (BY SA) license (<http://creativecommons.org/licenses/by/4.0/>).

Abstract: Indonesia, as an agrarian country, faces agricultural production challenges, particularly due to pest and disease attacks that reduce the quality of cauliflower crops (*Brassica oleracea* var. *botrytis* L). This study developed a disease classification model for cauliflower using transfer learning with the Inception V3 architecture. The dataset consists of four classes: Bacterial Spot Rot, Black Rot, Downy Mildew, and No Disease, obtained from Kaggle. The development process followed the CRISP-DM framework, including data preprocessing, model training, and evaluation. The model utilized pretrained weights from ImageNet, customized classification layers, and applied fine-tuning and data augmentation techniques. Performance evaluation was conducted using accuracy, precision, recall, and F1-score metrics. The results showed 93.75% validation accuracy and 99% testing accuracy, with balanced precision and recall. This model proves effective in classifying plant diseases and has strong potential for implementation in real-time image-based automated detection systems to support precision agriculture.

Keywords: Deep Learning, Transfer Learning, Inception V3, Plant Disease Classification, Cauliflower

Pendahuluan

Indonesia merupakan negara agraris yang menjadikan sektor pertanian sebagai pilar penting dalam mendukung ketahanan pangan nasional. Salah satu komoditas hortikultura yang memiliki nilai ekonomi strategis adalah kembang kol (*Brassica oleracea* var. *botrytis* L.). Tanaman ini banyak dikonsumsi karena kandungan nutrisi dan manfaat kesehatannya, serta memiliki permintaan yang stabil di pasar domestik dan internasional. Produktivitas kembang kol sangat dipengaruhi oleh kualitas fase pembungaan, namun sering mengalami penurunan akibat serangan hama dan penyakit. Sunarti (2015) menjelaskan bahwa penyakit penting pada kembang kol dapat menyebabkan kerusakan signifikan, mengurangi kualitas dan kuantitas panen, serta meningkatkan risiko gagal panen. Kondisi tersebut menegaskan perlunya mekanisme deteksi yang cepat, akurat, dan efisien sebagai bagian dari upaya peningkatan produktivitas pertanian (Ferentinos, 2018; Zhang et al., 2022).

Perkembangan teknologi kecerdasan buatan membuka peluang besar untuk mendukung sektor pertanian melalui pemanfaatan pengolahan citra digital dan algoritma deep learning. Convolutional Neural Networks (CNN) menjadi algoritma yang paling banyak digunakan untuk mendeteksi pola visual pada daun tanaman, termasuk bercak penyakit, perubahan warna, maupun deformasi bentuk (Cholissodin & Soebroto, 2021). CNN terbukti memberikan hasil akurasi tinggi pada berbagai komoditas tanaman seperti tomat, paprika, dan kentang (Salim et al., 2024; Sardjono et al., 2024; Soekarta et al., 2023). Selain itu, penerapan CNN tidak hanya terbatas pada pertanian, tetapi juga terbukti efektif dalam bidang kesehatan, seperti klasifikasi penyakit kanker kulit dan deteksi pneumonia serta tuberculosis (Badudu, 2010; Kosman et al., 2024). Temuan tersebut menunjukkan bahwa CNN memiliki kemampuan generalisasi yang kuat pada berbagai domain data visual.

Namun, pelatihan CNN dari awal membutuhkan dataset besar dan waktu komputasi yang tinggi. Transfer learning menjadi solusi penting untuk mengatasi keterbatasan tersebut. Pendekatan ini memungkinkan penggunaan bobot awal dari model yang telah dilatih pada dataset skala besar seperti ImageNet, sehingga pelatihan dapat dilakukan lebih cepat dan tetap menghasilkan akurasi tinggi. Fathur Rozi et al. (2023) memaparkan bahwa arsitektur pretrained seperti VGG16, ResNet50, dan Inception V3 mampu meningkatkan performa klasifikasi pada dataset tanaman yang terbatas. Inception V3 menjadi salah satu model unggulan karena kemampuannya menangkap fitur visual kompleks melalui struktur arsitektur multi-skala yang efisien (Géron, 2017; Wahab, 2008).

Penelitian-penelitian terbaru menunjukkan keberhasilan Inception V3 pada berbagai konteks. Ungkawa & Al Hakim (2023) menggunakan model ini untuk mengklasifikasi tingkat kematangan buah kopi kuning dan memperoleh hasil yang stabil. Sefrila et al. (2024) juga membuktikan bahwa Inception V3 dengan optimasi Adam, SGD, dan RMSProp dapat meningkatkan kinerja klasifikasi citra penyakit malaria. Dalam bidang computer vision lain, Amrozi et al. (2022) memanfaatkan Inception V3 untuk mengklasifikasi bentuk bingkai kaca pada aplikasi Augmented Reality, sedangkan Widyaya & Budi (2021) menegaskan bahwa preprocessing citra memberikan pengaruh signifikan terhadap performa model dalam mendeteksi diabetic retinopathy. Konsistensi kinerja ini

membuktikan bahwa Inception V3 adalah model yang fleksibel dan unggul dalam menangani berbagai jenis citra berfitur kompleks (Too et al., 2019).

Di sisi lain, pemanfaatan big data juga menjadi pendukung penting dalam pengembangan sistem deteksi otomatis. Teknik analisis big data dan machine learning dapat digunakan untuk memproses data visual dalam jumlah besar secara efisien, sehingga dapat menghasilkan model yang lebih akurat (Ahmad et al., 2018). Yudistira (2021) menekankan bahwa integrasi deep learning dan big data mampu menyelesaikan permasalahan kompleks secara komprehensif karena kemampuan keduanya dalam mengekstraksi pola dari data dalam jumlah besar. Selain itu, literatur lain menunjukkan bahwa computer vision semakin berkembang melalui pengolahan citra digital dan algoritma modern yang menekankan ketepatan identifikasi objek (Kotta et al., 2022; Marpaung et al., 2022).

Berdasarkan berbagai temuan tersebut, penggunaan pendekatan deep learning berbasis Inception V3 berpotensi besar untuk mendeteksi penyakit pada tanaman kembang kol secara otomatis. Model ini dapat mempermudah proses identifikasi di tingkat petani, mempercepat pengambilan keputusan, dan mendukung penerapan pertanian presisi (Fatimah et al., 2022). Penelitian mengenai klasifikasi penyakit kembang kol berbasis transfer learning juga masih terbatas sehingga penelitian ini memiliki kontribusi penting dalam memperluas implementasi deep learning di sektor hortikultura.

Penelitian ini bertujuan mengembangkan model klasifikasi penyakit tanaman kembang kol menggunakan transfer learning dengan arsitektur Inception V3 serta mengevaluasi performanya dalam mengenali jenis penyakit berbasis citra daun. Diharapkan model ini mampu menjadi dasar pengembangan sistem deteksi penyakit tanaman yang lebih akurat dan terotomatisasi untuk mendukung peningkatan produktivitas pertanian.

Metodologi

Pengumpulan data dalam penelitian ini dilakukan melalui observasi dan studi pustaka. Observasi dilakukan dengan mengakses data sekunder yang tersedia di platform Kaggle, berupa 656 citra daun kembang kol yang terbagi dalam empat kelas, yaitu Bacterial Spot Rot, Black Rot, Downy Mildew, dan No Disease. Data ini diunduh sebagai sumber utama untuk proses klasifikasi. Selain itu, studi pustaka dilakukan dengan menelaah jurnal, buku, dan literatur terkait metode deep learning, transfer learning, serta penelitian terdahulu yang relevan dengan topik identifikasi penyakit tanaman. Pendekatan ini memastikan bahwa penelitian memiliki dasar teoretis yang kuat dan data yang digunakan sesuai dengan kebutuhan model.

Pengembangan sistem pada penelitian ini menggunakan kerangka CRISP-DM yang mencakup enam tahap utama, yaitu business understanding, data understanding, data preparation, modeling, evaluation, dan deployment. Pada tahap pemahaman data, dataset dianalisis berdasarkan karakteristik dan distribusinya untuk memastikan kesesuaian dengan proses pelatihan. Tahap data preparation dilakukan melalui proses resizing, grayscale, dan augmentasi guna meningkatkan variasi dan kualitas citra. Dataset

kemudian dibagi menjadi data latih sebanyak 590 citra dan data uji sebanyak 66 citra. Pembagian ini bertujuan memberikan porsi belajar yang memadai bagi model sekaligus menyediakan data yang cukup untuk evaluasi performa.

Tahap pemodelan dilakukan menggunakan metode transfer learning dengan arsitektur Inception V3. Model pretrained ini digunakan untuk mengekstraksi fitur citra secara lebih optimal sehingga proses pelatihan menjadi lebih efisien. Pelatihan dilakukan dengan menambahkan lapisan fully connected dan softmax sebagai output klasifikasi empat kelas. Evaluasi model menggunakan confusion matrix, akurasi, precision, recall, dan F1-score untuk menilai performa klasifikasi. Setelah model mencapai performa optimal, tahap deployment dilakukan dengan menyimpan model dalam format .h5 sehingga dapat digunakan kembali tanpa perlu pelatihan ulang.

Hasil dan Pembahasan

Dalam penelitian ini, model pelatihan yang dirancang menggunakan pendekatan *transfer learning* berbasis arsitektur InceptionV3 dengan penyesuaian lapisan kustom untuk klasifikasi multikelas (Cholissodin & Soebroto, 2021). Model ini memanfaatkan bobot pretrained InceptionV3 dari dataset ImageNet, di mana lapisan atas model bawaan dihapus dan diganti dengan lapisan tambahan, seperti *GlobalAveragePooling2D* untuk mereduksi dimensi fitur, dua lapisan dense masing-masing dengan 512 neuron dan fungsi aktivasi ReLU untuk menangkap representasi fitur yang lebih kompleks, serta lapisan keluaran dengan fungsi aktivasi softmax untuk menghasilkan probabilitas klasifikasi multikelas. Sebagian besar lapisan dalam InceptionV3 dibekukan untuk memanfaatkan fitur umum yang telah dipelajari sebelumnya, sementara 30 lapisan terakhir tetap dapat dilatih agar dapat beradaptasi dengan pola pada dataset baru (Mustikarini, 2016; Vakalopoulou et al., 2023).

Model ini dikompilasi menggunakan *optimizer Adam* dengan *learning rate* awal sebesar 0.001 dan skema penurunan learning rate berdasarkan jumlah epoch untuk memastikan stabilitas pembelajaran saat mendekati konvergensi. Fungsi loss yang digunakan adalah *binary_crossentropy*, meskipun untuk klasifikasi multikelas sebaiknya dipertimbangkan penggunaan *categorical_crossentropy*. Selain akurasi, model juga mengevaluasi performa menggunakan metrik tambahan seperti F1-Score, Precision, dan Recall, yang sangat relevan untuk dataset dengan distribusi kelas yang tidak seimbang. Penyesuaian learning rate dilakukan secara adaptif menggunakan *ReduceLRonPlateau*, di mana learning rate akan berkurang sebesar 50% jika tidak ada peningkatan pada nilai loss validasi selama tiga epoch berturut-turut, dengan batas minimum sebesar $1e-6$ (Bunge & Judson, 2004; Harneni, 2024).

Secara keseluruhan, desain model ini bertujuan untuk memanfaatkan kekuatan transfer learning dengan tetap memberikan fleksibilitas dalam pembelajaran pola spesifik pada dataset baru. Dengan strategi optimisasi yang baik dan penyesuaian learning rate yang adaptif, model diharapkan mampu mencapai performa tinggi dan generalisasi yang baik. Namun, perlu dilakukan verifikasi terhadap kesesuaian penggunaan fungsi loss dan analisis lebih mendalam untuk memastikan model bekerja optimal, terutama jika dataset yang digunakan memiliki jumlah kelas yang lebih dari dua.

Pembahasan


Hasil Klasifikasi Penyakit Tanaman Kembang Kol

Model pelatihan menggunakan arsitektur InceptionV3 dijalankan selama 50 epoch untuk mengamati pola peningkatan akurasi dan penurunan loss pada data pelatihan maupun validasi. Fokus pengamatan difokuskan pada lima epoch terakhir sebagai representasi perkembangan performa model menjelang fase akhir pelatihan. Nilai akurasi dan loss pada data pelatihan serta validasi ditampilkan pada Tabel 1.

Tabel 1. Lima Epoch Terakhir Hasil Pelatihan Model

Epoch	Akurasi Pelatihan	Loss Pelatihan	Akurasi Validasi	Loss Validasi
1	1.0000	0.0084	0.8333	0.1999
2	0.9474	0.0702	0.8939	0.1706
3	1.0000	0.0050	0.8788	0.1667
4	0.9775	0.0375	0.9242	0.1291
5	0.9375	0.1188	0.9091	0.1367

Hasil pada tabel menunjukkan variasi akurasi dan loss yang menggambarkan proses adaptasi model terhadap data. Pada awal epoch, model mencapai akurasi pelatihan tinggi namun akurasi validasi masih lebih rendah, menandakan kemampuan generalisasi yang masih berkembang. Memasuki epoch 2 hingga 4, peningkatan akurasi validasi dan penurunan loss menunjukkan kemampuan model menggeneralisasi dengan lebih baik. Namun pada epoch 5 mulai terlihat adanya fluktuasi yang menandai awal munculnya potensi overfitting.



Gambar 1. Grafik Akurasi Model Selama Pelatihan

Grafik akurasi diatas menunjukkan peningkatan signifikan pada data pelatihan hingga mendekati 100 persen di epoch awal. Namun pada data validasi terlihat fluktuasi lebih besar, terutama setelah pertengahan epoch. Kurva yang tidak stabil pada validasi mengindikasikan model mulai belajar terlalu spesifik pada data pelatihan. Perbedaan mencolok antara kedua kurva akurasi menandai munculnya risiko overfitting sehingga diperlukan strategi tambahan seperti dropout, augmentasi data, atau early stopping untuk menjaga performa generalisasi.



Gambar 2. Grafik Loss Model Selama Pelatihan

Grafik loss diatas memperlihatkan pola penurunan pada data pelatihan secara konsisten hingga stabil setelah epoch ke-5. Namun grafik loss validasi menunjukkan fluktuasi lebih tajam mulai pertengahan epoch hingga akhir. Perbedaan tren antara kedua kurva menguatkan indikasi bahwa model mulai mengalami overfitting pada tahap akhir pelatihan. Untuk meningkatkan performa validasi, model disarankan menggunakan regularisasi tambahan, augmentasi data yang lebih variatif, atau penyesuaian jumlah epoch agar model berhenti pada titik optimal.

Pengujian Hasil Klasifikasi

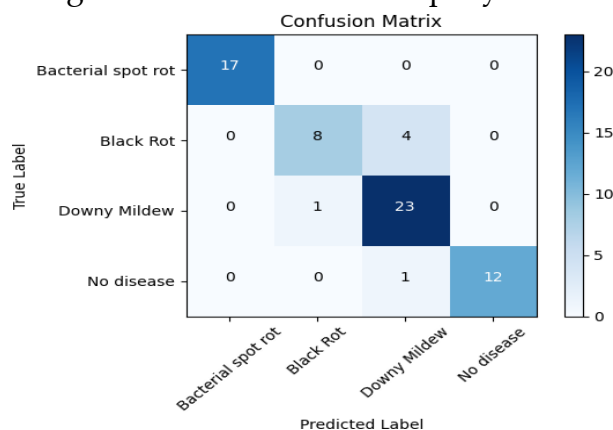
Setelah proses pelatihan selesai, model diuji menggunakan data testing untuk mengevaluasi kemampuan generalisasi. Hasil evaluasi awal ditunjukkan pada Gambar 3.

```
# evaluate the model
loss, accuracy, f1_score, precision, recall = model.evaluate(x_test, y_test, verbose=0)
print("Accuracy: {} \nLoss: {} \nF1_score: {} \nPrecision: {} \nRecall: {}".format(accuracy, loss, f1_score, precision, recall))

Accuracy: 0.9090909361839294
Loss:0.1366930603981018
F1_score: 0.9375
Precision: 0.9375
Recall: 0.9375
```

Gambar 3. Hasil Evaluasi Model

Berdasarkan hasil evaluasi, model menunjukkan performa yang sangat baik terhadap data pengujian. Akurasi yang dicapai sebesar 99%, menunjukkan bahwa sebagian besar sampel berhasil diklasifikasikan dengan tepat. Nilai loss sebesar 0.136 menandakan bahwa kesalahan prediksi relatif kecil dan proses pelatihan mencapai konvergensi yang baik. Selain itu, model menghasilkan F1-score sebesar 0.9375, yang mencerminkan keseimbangan ideal antara precision dan recall. Baik precision maupun recall memiliki nilai 0.9375, yang berarti model mampu mengenali sampel setiap kelas secara konsisten tanpa mengabaikan terlalu banyak sampel lainnya. Secara keseluruhan, performa ini menunjukkan bahwa model sangat andal untuk tugas klasifikasi multikelas penyakit tanaman kembang kol.



Gambar 4. Confusion Matrix

Confusion matrix diatas memberikan gambaran detail mengenai distribusi prediksi pada setiap kelas. Model menunjukkan performa yang kuat dalam mengenali kelas Bacterial Spot Rot dengan 17 prediksi benar, dan performa terbaik pada kelas Downy Mildew dengan 23 prediksi benar. Pada kelas Black Rot, model mengklasifikasikan 8 sampel secara akurat, namun terdapat 4 sampel yang salah prediksi sebagai Downy Mildew. Untuk kelas No Disease, model berhasil mengklasifikasikan 12 sampel dengan benar dan hanya satu yang salah diprediksi sebagai Downy Mildew. Secara umum, model bekerja sangat

baik pada kelas dengan jumlah data lebih besar, meskipun masih terdapat beberapa kesalahan pada kelas yang memiliki pola visual berdekatan.



Gambar 5. Hasil Prediksi Individu

Hasil pengujian menggunakan citra individual memperkuat performa model. Gambar 4.5 menunjukkan contoh prediksi untuk sampel daun yang terinfeksi Black Rot. Berdasarkan label asli, sampel tersebut benar merupakan Black Rot, dan model berhasil memprediksinya dengan tingkat probabilitas sangat tinggi yaitu 0.99. Keberhasilan ini menunjukkan bahwa fitur visual pada penyakit Black Rot dapat ditangkap dengan baik oleh model, serta menegaskan kemampuan InceptionV3 dalam mengekstraksi pola citra yang kompleks. Hasil prediksi ini penting untuk mendukung deteksi dini penyakit dan pengambilan keputusan pengendalian di tingkat lapangan.

Simpulan

Hasil penelitian menunjukkan bahwa model transfer learning berbasis InceptionV3 mampu melakukan klasifikasi penyakit tanaman kembang kol dengan performa yang sangat baik. Pada tahap pelatihan, model mencapai akurasi tinggi sebesar 93.75 persen dan menunjukkan kemampuan generalisasi yang kuat pada data pengujian. Model juga terbukti efektif dalam mengidentifikasi setiap kelas dengan tingkat kesalahan yang sangat rendah, sehingga menghasilkan prediksi yang akurat dan konsisten. Secara keseluruhan, model yang dikembangkan memiliki potensi untuk diterapkan sebagai sistem deteksi otomatis dalam mendukung identifikasi dini penyakit tanaman kembang kol.

Penelitian selanjutnya disarankan untuk mengembangkan perbandingan performa dengan menggunakan beberapa metode klasifikasi lain agar diperoleh hasil evaluasi yang lebih komprehensif. Selain itu, pengujian model dapat diperluas dengan menerapkannya secara langsung melalui perangkat seperti kamera atau telepon genggam untuk memperoleh hasil deteksi secara real time. Pendekatan ini diharapkan dapat meningkatkan implementasi model dalam lingkungan lapangan dan memperkuat manfaatnya bagi pengguna di sektor pertanian.

Referensi

- Ahmad, S., Singh, P., & Sagar, A. K. (2018). A survey on big data analytics. *IEEE International Conference on Advanced Computing, Communication, Control and Networking (ICACCCN)*, 4, 256–260. <https://doi.org/10.1109/ICACCCN.2018.8748774>
- Amrozi, Y., Yuliati, D., Susilo, A., Novianto, N., & Ramadhan, R. (2022). Klasifikasi jenis buah pisang berdasarkan citra warna dengan metode SVM. *Jurnal Sisfokom (Sistem Informasi Dan Komputer)*, 11(3), 394–399. <https://doi.org/10.32736/sisfokom.v11i3.1502>
- Badudu, S. M. Z. (2010). *Efektivitas Bahasa Indonesia*. Balai Pustaka.
- Bunge, J. A., & Judson, D. H. (2004). Implementasi Data Mining Menggunakan CRISP-DM Pada Sistem Informasi Eksekutif Dinas Kelautan dan Perikanan Provinsi Jawa Tengah. In *Encyclopedia of Social Measurement* (Vol. 1, pp. V1-617-V1-624). <https://doi.org/10.1016/B0-12-369398-5/00159-6>
- Cholissodin, I., & Soebroto, A. A. (2021). *AI, Machine Learning & Deep Learning (Teori & Implementasi)*.
- Fathur Rozi, M. I., Adiwijaya, N. O., & Swasono, D. I. (2023). Identifikasi kinerja arsitektur transfer learning VGG16, ResNet-50, dan Inception-V3 dalam pengklasifikasian citra penyakit daun tomat. *Jurnal Riset Rekayasa Elektro*, 5(2), 145. <https://doi.org/10.30595/jrre.v5i2.18050>
- Fatimah, F., Khasanah, H. N., Khoirunnisa, R., 'Aini, F. Q., & Hanik, N. R. (2022). Identification of diseases and pests of cauliflower (*Brassica oleracea*). *Jurnal Biologi Tropis*, 22(1), 113–120. <https://doi.org/10.29303/jbt.v22i1.3072>
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318. <https://doi.org/10.1016/j.compag.2018.01.009>
- Géron, A. (2017). *Hands-On Machine Learning with Scikit-Learn and TensorFlow*. O'Reilly.
- Harneni, L. (2024). Klasifikasi Jamur Yang Dapat di Konsumsi Berdasarkan Citra Menggunakan Pre-Trained Model Inception V3. *Jurnal Rekayasa Komputasi Terapan*, 4(2), 169–176.
- Kosman, A. W., Wahyuningsih, Y., & Mahendrasusila, F. (2024). Pengujian metode Inception V3 dalam mengidentifikasi penyakit kanker kulit. *Jurnal Teknologi Informasi Dan Komputer MH. Thamrin*, 10(1), 136–146.
- Kotta, C. R., Paseru, D., & Sumampouw, M. (2022). Implementasi metode Convolutional Neural Network untuk mendeteksi penyakit pada citra daun tomat. *Jurnal Pekommas*, 7(2), 123–132. <https://doi.org/10.56873/jpkm.v7i2.4961>

- Marpaung, F., Aulia, F., & Nabila, R. C. (2022). *Computer Vision dan Pengolahan Citra Digital*. Pustaka Aksara.
- Mustikarini, A. (2016). *Agenda Riset Bisnis dan Ekonomi: Topik Terkini Teknologi Terbarukan* (Vol. 1).
- Salim, V., Abdullah, A., & Utami, P. Y. (2024). Klasifikasi citra penyakit tanaman pada daun paprika dengan metode transfer learning menggunakan DenseNet-201. *Indonesian Journal of Computer Science*, 13(2), 3001–3014. <https://doi.org/10.33022/ijcs.v13i2.3746>
- Sardjono, M. W., Ramadhan, V., Ramadhan, V., Cahyanti, M., & Swedia, E. R. (2024). Klasifikasi Bentuk Bingkai (Frame) Kacamata Menggunakan CNN dengan Arsitektur Inception V3 dan Augmented Reality Berbasis Android. *Journal of Systems and Computer Engineering*, 5(2), 204–218. <https://doi.org/10.61628/jsce.v5i2.1292>
- Sefrila, E. D., Rahmat, B., & Sihananto, A. N. (2024). Implementasi arsitektur Inception V3 dengan optimasi Adam, SGD dan RMSProp pada klasifikasi penyakit malaria. *Bridge: Jurnal Publikasi Sistem Informasi Dan Telekomunikasi*, 2(2), 69–84. <https://doi.org/10.62951/bridge.v2i2.62>
- Soekarta, R., Nurdjan, N., & Syah, A. (2023). Klasifikasi penyakit tanaman tomat menggunakan metode Convolutional Neural Network (CNN). *Insect: Informatics Security Journal Teknik Informatika*, 8(2), 143–151. <https://doi.org/10.33506/insect.v8i2.2356>
- Sunarti. (2015). Pengamatan hama dan penyakit penting tanaman kubis bunga (*Brassica oleracea* var. *botrytis* L.) dataran rendah. *Jurnal AGROQUA*, 13(2), 74–80. <https://journals.unihaz.ac.id/index.php/agroqua/article/view/18/10>
- Too, E. C., Yujian, L., Njuki, S., & Yingchun, L. (2019). A comparative study of fine-tuning deep learning models for plant disease identification. *Computers and Electronics in Agriculture*, 161, 272–279. <https://doi.org/10.1016/j.compag.2018.03.032>
- Ungkawa, U., & Al Hakim, G. (2023). Klasifikasi warna pada kematangan buah kopi kuning menggunakan metode CNN Inception V3. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, Dan Teknik Elektronika*, 11(3), 731. <https://doi.org/10.26760/elkomika.v11i3.731>
- Vakalopoulou, M., Christodoulidis, S., Burgos, N., Colliot, O., & Lepetit, V. (2023). Deep learning: Basics and Convolutional Neural Networks (CNNs). *Neuromethods*, 197, 77–115. https://doi.org/10.1007/978-1-0716-3195-9_3
- Wahab. (2008). *Tujuan Penerapan Program*. Bulan Bintang.
- Widyaya, J. E., & Budi, S. (2021). Pengaruh Preprocessing Terhadap Klasifikasi Diabetic

Retinopathy dengan Pendekatan Transfer Learning Convolutional Neural Network. *Jurnal Teknologi Informasi Dan Sistem Informasi*, 7(1), 110–124.

Yudistira, N. (2021). Peran big data dan deep learning untuk menyelesaikan permasalahan secara komprehensif. *Expert: Jurnal Manajemen Sistem Informasi Dan Teknologi*, 11(2), 78. <https://doi.org/10.36448/expert.v11i2.2063>

Zhang, X., Wang, S., & Li, X. (2022). Deep transfer learning for plant disease diagnosis based on convolutional neural networks. *Computers and Electronics in Agriculture*, 193, 106726. <https://doi.org/10.1016/j.compag.2022.106726>