

Implementasi Deep Learning pada Deteksi Penyakit Daun Kentang dengan Arsitektur InceptionResNetV2

Elly Firasari^{1*}, F. Lia Dwi Cahyanti³
Universitas Nusa Mandiri^{1,2}
elly.efa@nusamandiri^{1*}, flia.fdc@nusamandiri.ac.id²

Diterima (17-04-2025)	Direvisi (22-04-2025)	Disetujui (28-04-2025)
--------------------------	--------------------------	---------------------------

Abstrak - Kentang (*Solanum tuberosum*) merupakan salah satu komoditas pangan penting di Indonesia. Namun, produktivitasnya kerap terganggu oleh penyakit daun seperti *Early Blight*, *Late Blight*, dan infeksi virus. Identifikasi penyakit secara manual oleh petani masih memiliki keterbatasan dari segi waktu, tenaga, dan akurasi. Tujuan dari penelitian ini untuk pengembangan sistem klasifikasi otomatis penyakit daun kentang dengan menggunakan metode deep learning, khususnya melalui arsitektur *InceptionResNetV2*. Dataset yang digunakan bersumber dari Kaggle dan terdiri dari 3.251 citra yang terbagi dalam tiga kelas: *Healthy* (816), *Early Blight* (1.303), dan *Late Blight* (1.132). Data diproses melalui tahapan praproses berupa *resize*, normalisasi piksel, dan augmentasi data. Pelatihan dilakukan dengan menggunakan ukuran input 299x299 piksel, batch size 20, dan jumlah epoch sebanyak 20. Hasil pelatihan model mencapai akurasi testing sebesar 94,20% dan akurasi validasi 95,30%. Evaluasi model menggunakan confusion matrix menunjukkan kinerja yang baik pada kelas *Early Blight* dan *Healthy*, namun model masih mengalami kesulitan dalam membedakan antara *Late Blight* dan daun *Healthy*. Secara keseluruhan, model *InceptionResNetV2* terbukti efektif dalam mengklasifikasikan penyakit daun kentang dan dapat menjadi solusi pendukung dalam sistem pertanian berbasis teknologi.

Kata Kunci : Kentang, Penyakit Daun, Deep Learning, InceptionResNetV2, Klasifikasi Citra.

Abstract - *Potato (Solanum tuberosum) is one of the main food commodities in Indonesia. However, its productivity is often threatened by leaf diseases such as Early Blight, Late Blight, and viral infections. Manual disease identification by farmers still has limitations in terms of time, effort, and accuracy. This study aims to develop an automated classification system for potato leaf diseases using deep learning, specifically the InceptionResNetV2 architecture. The dataset used was obtained from Kaggle and consists of 3,251 images divided into three classes: Healthy (816), Early Blight (1,303), and Late Blight (1,132). The images were preprocessed through resizing, pixel normalization, and data augmentation. The model was trained with an input size of 299x299 pixels, a batch size of 20, and over 20 epochs. The training results show that the model achieved a training accuracy of 94.20% and a validation accuracy of 95.30%. Evaluation using a confusion matrix demonstrated strong performance in classifying Early Blight and Healthy leaves, although the model showed some difficulty distinguishing between Late Blight and Healthy leaves. Overall, the InceptionResNetV2 model proved effective in classifying potato leaf diseases and has the potential to support technology-based agricultural decision-making.*

Keywords: Potato, Leaf Disease, Deep Learning, InceptionResNetV2, Image Classification.

I. PENDAHULUAN

Kentang (*Solanum tuberosum*) merupakan salah satu komoditas pangan utama di Indonesia dan dunia (Nurpauziah & Riani, 2024). Namun, produktivitasnya sering terancam oleh berbagai penyakit daun seperti *late blight*, *early blight*, dan infeksi virus, yang dapat menyebabkan kerugian hasil panen secara signifikan jika tidak terdeteksi dan ditangani secara dini. berbagai penyakit dapat terjadi pada daun kentang sehingga menyulitkan petani dalam mengidentifikasi penyakit yang menyerang tanaman kentang

(Teresia Ompusunggu, 2022). Penyakit bercak kering daun kentang disebut juga penyakit hawar daun. Tempat yang dingin dan lembap menjadi salah satu faktor berkembangnya penyakit hawar daun (Fitriana & Hakim, 2019) Penyakit busuk daun biasanya muncul pada tahap pertumbuhan tanaman antara minggu ke-5 dan ke-6. Gejala awalnya berupa bercak basah yang muncul di pinggir daun, yang terkadang juga dapat terlihat di bagian tengah. Seiring waktu, bintik-bintik tersebut akan membesar, dan warna daun akan berubah menjadi coklat atau abu-abu. Sedangkan gejala

penyakit bercak kering (early blight) ditandai dengan bercak kering berupa lingkaran coklat pada bagian bawah daun (Fuadi & Suharso, 2022). Metode identifikasi penyakit secara manual oleh petani atau ahli agronomi seringkali memerlukan waktu, tenaga, dan bergantung pada keahlian individu, sehingga rentan terhadap kesalahan diagnosis.

Perkembangan teknologi kecerdasan buatan, khususnya deep learning, telah membuka peluang besar dalam bidang klasifikasi citra, termasuk dalam identifikasi penyakit tanaman (Riyanto et al., 2025). Model deep learning seperti Convolutional Neural Networks (CNN) telah terbukti efektif dalam melakukan klasifikasi citra penyakit tanaman karena kemampuannya dalam mengekstraksi fitur visual secara otomatis dan mendalam (Nurdin et al., 2024) (Lu et al., 2021).

Salah satu arsitektur CNN lanjutan yang menunjukkan performa tinggi dalam pengenalan objek adalah InceptionResNetV2, yang menggabungkan kekuatan modul Inception dalam menangani multi-skala fitur dengan keunggulan residual connections yang mempercepat proses konvergensi dan mencegah degradasi akurasi pada jaringan yang sangat dalam (Dash et al., 2023)

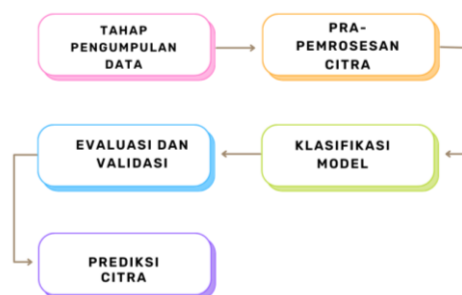
Beberapa penelitian yang membahas mengenai klasifikasi penyakit daun kentang antara lain penelitian Identifikasi Penyakit Daun Kentang Berdasarkan Ciri Teksstur dan Warna Menggunakan Metode K-Nearest Neighbor dalam penelitian (Amatullah et al., 2021) melakukan proses resize, ekstraksi fitur, pembagian dataset (pelatihan, pengujian) serta perhitungan akurasi dan prediksi menggunakan K-Nearest neighbour menghasilkan akurasi sebesar 80%. Klasifikasi Penyakit Daun Kentang Menggunakan Pendekatan Deep Learning (Sholihati et al., 2020) menggunakan 5.100 data dari Google yang terbagi dalam 5 kelas yang diolah menggunakan model VGG16 dan VGG19 sehingga mendapatkan akurasi sebesar 91,0% dan 90%. Implementasi Deteksi Objek Penyakit Daun Kentang Menggunakan Metode Convolutional Neural Network (Nauval & Lestari, 2022). Penelitian ini mengklasifikasikan tiga kelas, yaitu daun sehat, penyakit busuk daun, dan penyakit busuk daun, menggunakan arsitektur Convolutional Neural Network (CNN). Hasil penelitian menunjukkan performa yang baik, di mana pada epoch ke-10 dengan batch size 20, akurasi pelatihan mencapai 95% dan akurasi validasi mencapai 94%.

Beberapa penelitian menunjukkan bahwa CNN memiliki tingkat akurasi yang lebih tinggi dalam mengolah data gambar. (Firasari & Cahyanti, 2023). Penelitian ini bertujuan untuk

mengembangkan dan menguji sistem klasifikasi penyakit pada daun kentang menggunakan arsitektur InceptionResNetV2. Model ini diharapkan dapat mengklasifikasikan kondisi daun kentang ke dalam berbagai kategori berdasarkan gejala visual yang terlihat, sehingga dapat membantu mempercepat dan meningkatkan akurasi dalam pengambilan keputusan untuk manajemen pertanian.

II. METODOLOGI PENELITIAN

Bagian ini menjelaskan langkah-langkah yang dilakukan dalam pelaksanaan penelitian, mulai dari pengumpulan data hingga evaluasi model. Setiap tahapan dirancang secara sistematis untuk mencapai tujuan penelitian, yaitu mengklasifikasikan kondisi daun kentang menggunakan pendekatan deep learning. Metodologi yang digunakan mencakup proses pra-proses data, pembangunan arsitektur model, pelatihan, serta pengujian dan evaluasi kinerja model.




Sumber: Penelitian (2025)

Gambar 1. Metode Penelitian

1. Pengumpulan Dataset

Data diperoleh dari data publik yang tersedia di Kaggle (https://www.kaggle.com/datasets/rizwan12345_6789/potato-disease-leaf-datasetpld).

Kumpulan data tersebut terdiri dari dua kategori: Sehat 816, citra, Early Blight 1303 Citra, Late Blight 1132 Citra yang dibagi menjadi data training, data testing dan data validasi. Gambar dibawah ini merupakan dataset daun tanaman kentang yang terbagi menjadi 3 kelas yaitu Early Blight, Healthy, and Late Blight.



Sumber: Penelitian (2025)

Gambar 2. (a) Early Blight, (b) Healthy, (c) Late Blight

2. Pemrosesan Data

Pada tahap praproses, gambar akan melewati beberapa tahapan pengolahan awal sebelum memasuki proses ekstraksi fitur. Langkah-langkah praproses ini mencakup penyesuaian ukuran (resize), pemisahan objek penting melalui segmentasi, serta normalisasi untuk menyamakan skala nilai piksel:

a. Resize

Seluruh citra dalam dataset diubah ukurannya menjadi **299 x 299 piksel**. Ukuran ini merupakan ukuran input standar dari model InceptionResNetV2. Proses resize memastikan bahwa setiap gambar memiliki dimensi konsisten sehingga dapat diproses dalam batch oleh model

b. Normalisasi piksel

Nilai piksel citra awalnya berada dalam rentang 0–255 (uint8). Untuk mempercepat konvergensi pelatihan dan meningkatkan stabilitas numerik, dilakukan normalisasi ke dalam rentang **[0, 1]** dengan membagi setiap piksel dengan 255. Beberapa implementasi InceptionResNetV2 menggunakan rentang normalisasi [-1, 1] dengan transformasi $(x / 127.5) - 1$, namun dalam penelitian ini digunakan pendekatan [0, 1] untuk kesederhanaan dan konsistensi dengan augmentasi Keras.

c. Augmentasi data


Digunakan untuk meningkatkan kemampuan generalisasi model, dengan menerapkan berbagai teknik seperti rotasi, pembalikan horizontal maupun vertikal, dan perbesaran (zooming)

3. Convolutional Neural Network

CNN tersusun atas sejumlah neuron yang masing-masing memiliki bobot (weight), bias, serta fungsi aktivasi. Pada lapisan konvolusi, neuron-neuron ini dirancang dalam pola tertentu untuk membentuk filter yang memiliki ukuran panjang dan lebar dalam satuan piksel. Setiap neuron menerima input dari neuron pada lapisan sebelumnya dan melakukan operasi seperti perkalian terhadap input tersebut. (Delfana et al., 2020). Arsitektur CNN dapat dilihat pada Gambar 2.1.

Metode CNN (Convolutional Neural Network) digunakan untuk mengklasifikasikan gambar dengan cara memproses gambar yang diinput dan kemudian mengategorikannya, contohnya pada gambar manusia, yang mungkin mencakup fitur-fitur seperti wajah, mata, hidung, mulut, tangan, dan lainnya. Gambar tersebut akan dikonversi menjadi array yang merepresentasikan nilai tiap piksel, dengan dimensi yang meliputi tinggi, lebar, serta kedalaman atau channel. Biasanya, citra RGB memiliki tiga channel yang mewakili

warna Red, Green, dan Blue, sementara gambar grayscale hanya memiliki satu channel. Namun, jumlah channel ini bisa lebih dari tiga, bahkan mencapai ratusan, yang mewakili berbagai warna lainnya dalam arsitektur RGB.




Sumber: Penelitian (2025)

Gambar 3. Arsitektur CNN

4. Arsitektur Model InceptionResNetV2

Inception-ResNet-V2 merupakan varian dari model Inception V3, yang memiliki kedalaman lebih besar dibandingkan dengan Inception V3 sebelumnya. Pada blok konvolusi Inception-ResNet-V2, jaringan yang digunakan serupa, namun blok residual yang berulang telah dipadatkan. Blok residual pertama kali berhasil diperkenalkan melalui arsitektur ResNet, yang menjadi pemenang dalam kompetisi LSVRC 2015 (*ImageNet Large Scale Visual Recognition Challenge*). Keunggulan utamanya adalah kemampuannya dalam mengatasi permasalahan Vanishing Gradient yang disebabkan oleh kedalaman jaringan konvolusi yang sangat dalam. Oleh karena itu, koneksi residual diperlukan untuk melatih arsitektur yang sangat dalam. Inception-ResNet-V2 adalah arsitektur CNN yang dibangun berdasarkan keluarga arsitektur Inception, namun mengintegrasikan koneksi residual untuk menggantikan tahap rangkaian filter pada arsitektur Inception. (Nugraha et al., 2022). Inception-ResNet-V2 memanfaatkan semua keuntungan dari pendekatan residual, sambil tetap menjaga efisiensi komputasinya. Skema dari Inception-ResNet-V2 dapat dilihat pada Gambar 2.



Sumber : Penelitian 2025

Gambar 4. Blok Pada Model InceptionResNetV2

Dalam proses pelatihan, model yang digunakan mengadopsi arsitektur Inception ResNet V2, yang memiliki beberapa susunan blok, antara lain Stem block, blok Inception-A, Inception-B, dan Inception-C, serta blok reduksi

seperti Inception-A Reduction dan Inception-B Reduction, hingga mencapai lapisan akhir yaitu softmax. Pelatihan diawali saat citra dimasukkan ke dalam Stem block, yang mencakup lapisan-lapisan seperti konvolusi, penggabungan filter (concatenation), serta max pooling. Setelah itu, citra secara bertahap diproses melalui sejumlah blok lanjutan, yakni Inception ResNet-A, Reduction-A, Inception ResNet-B, Reduction-B, hingga Reduction-C. Setelah ekstraksi fitur selesai, fitur-fitur yang diperoleh akan digabungkan dalam lapisan fully connected, dan akhirnya, hasilnya diteruskan ke lapisan softmax untuk menentukan bobot pada setiap kelas

5. Evaluasi

Evaluasi adalah proses pengukuran kinerja model menggunakan data validasi yang tidak disertakan dalam data pelatihan. Metrik evaluasi yang digunakan adalah akurasi. Metrik akurasi menilai seberapa baik model dapat memprediksi data dengan benar.

6. Prediksi

Pengujian prediksi dilakukan menggunakan data uji guna menilai sejauh mana model mampu memprediksi data yang belum pernah dilihat sebelumnya. Data uji ini terdiri dari sampel yang tidak digunakan selama proses pelatihan maupun validasi, sehingga dapat memberikan gambaran yang objektif mengenai performa model terhadap data baru. Hasil dari pengujian ini biasanya disajikan dalam bentuk confusion matrix, yang menggambarkan secara rinci tingkat keberhasilan model dalam mengklasifikasikan masing-masing kategori.

III. HASIL DAN PEMBAHASAN

Epoch merupakan proses pelatihan pada neural network di mana di mana seluruh data dalam dataset digunakan sekali untuk melatih model dari awal hingga akhir. (Rozaqi et al., 2021). Dalam pelatihan data menggunakan model neural network, penggunaan hanya satu epoch dapat membuat proses pelatihan menjadi terlalu berat, terutama jika jumlah data sangat besar. Oleh karena itu, data dibagi menjadi beberapa bagian kecil yang disebut batch (batch size) untuk mempermudah dan mempercepat proses pelatihan. Dalam penelitian ini digunakan batch size sebanyak 20, dan penentuan jumlah epoch disesuaikan oleh peneliti berdasarkan jumlah batch size serta jumlah sampel yang digunakan. Proses klasifikasi ini dilakukan menggunakan total 3.251 data yang telah dibagi ke dalam data training, testing, dan validasi, dengan rincian salah satunya adalah 816 citra daun dalam kondisi sehat, Early Blight 1303 Citra,

Late Blight 1132 Citra. Langkah berikutnya adalah melatih model menggunakan citra daun kentang yang telah dibagi sebelumnya, melalui proses fit model. Hasil dari proses ini ditampilkan pada Tabel 1, yang menunjukkan bahwa dari epoch ke-1 hingga epoch ke-10, terjadi peningkatan akurasi baik pada data pelatihan (train) maupun data pengujian (test).

Tabel 1. Hasil Dari Fit Model

Epoch	Data Training		Data Validasi	
	accuracy	loss	accuracy	loss
1	0.7176	0.6672	0.8365	0.3764
2	0.8863	0.2818	0.9087	0.2379
3	0.9243	0.1940	0.9255	0.1945
4	0.9334	0.1832	0.9303	0.1755
5	0.9550	0.1268	0.9183	0.1821
6	0.9420	0.1598	0.9399	0.1522
7	0.9570	0.1179	0.9327	0.1890
8	0.9518	0.1240	0.8822	0.2818
9	0.9518	0.1427	0.8870	0.2819
10	0.9593	0.1159	0.9087	0.2111
11	0.9608	0.1016	0.9135	0.2158
12	0.9643	0.1055	0.9111	0.2416
13	0.9502	0.1222	0.9447	0.1720
14	0.9676	0.0938	0.8990	0.2585
15	0.9641	0.1115	0.9183	0.1770
16	0.9675	0.0815	0.9591	0.1341
17	0.9806	0.0576	0.9231	0.1674
18	0.9772	0.0592	0.9255	0.1817
19	0.9781	0.0598	0.9423	0.1941
20	0.9802	0.0561	0.9567	0.1699

Berdasarkan Tabel 4, pada epoch pertama model menunjukkan akurasi sebesar 0,7176 dengan nilai loss sebesar 0,6672. Pada epoch kedua, akurasi meningkat menjadi 0,8863 dengan loss sebesar 0,2818. Selanjutnya, pada epoch ketiga akurasi mencapai 0,9243 dengan loss sebesar 0,1940, dan terus mengalami peningkatan hingga pada epoch ke-20 akurasi mencapai 0,9802 dengan nilai loss 0,0561. Sementara itu, untuk data pengujian (testing), pada epoch pertama diperoleh akurasi sebesar 0,8365 dengan loss 0,3764. Pada epoch kedua, akurasi meningkat menjadi 0,9087 dengan loss sebesar 0,2379. Kemudian pada epoch ketiga, akurasi mencapai 0,9255 dengan loss sebesar 0,1945, dan terus meningkat hingga pada epoch ke-20 tercapai akurasi sebesar 0,9567 dengan nilai loss 0,1699.

Tabel 2. Cofussion Matrix

	Early_Blight	Healty	Late_Blight
Early Bright	154	5	3
Healty	0	99	3
Late Blaght	0	81	133

Sumber: Penelitian (2025)

Berdasarkan confusion matrix yang ditampilkan, model klasifikasi penyakit daun kentang diuji terhadap tiga kelas, yaitu Early Blight, Healthy, dan Late Blight. Berikut interpretasi dari hasil pengujian:

- Kelas Early Blight**
Sebanyak 154 citra daun yang sebenarnya merupakan *Early Blight* berhasil diklasifikasikan dengan benar. Namun, terdapat 5 citra yang keliru diklasifikasikan sebagai *Healthy*, dan 3 citra yang salah diklasifikasikan sebagai *Late Blight*. Hal ini menunjukkan bahwa model cukup mampu mengenali *Early Blight* dengan baik, meskipun masih terdapat sejumlah kecil kesalahan klasifikasi.
- Kelas Healthy**
Model berhasil mengklasifikasikan 99 citra daun sehat dengan benar. Namun, masih terdapat 3 citra daun sehat yang keliru diprediksi sebagai *Late Blight*. Tidak ada citra daun sehat yang diklasifikasikan sebagai *Early Blight*, yang menunjukkan performa cukup tinggi pada kelas ini.
- Kelas Late Blight**
Sebanyak 133 citra daun yang sebenarnya terkena *Late Blight* berhasil diklasifikasikan dengan benar. Namun, model mengalami kesulitan dalam membedakan *Late Blight* dari daun sehat, terbukti dengan 81 citra *Late Blight* yang salah diklasifikasikan sebagai *Healthy*. Hal ini menjadi indikator bahwa fitur pembeda antara *Late Blight* dan *Healthy* belum sepenuhnya optimal dikenali oleh model.

Secara umum, model menunjukkan kinerja yang cukup baik pada kelas *Early Blight* dan *Healthy*, namun performanya masih perlu ditingkatkan pada kelas *Late Blight*, khususnya dalam membedakan dengan daun yang sehat.



Sumber : Penelitian 2025

Gambar 5. Hasil Prediksi Model

Gambar tersebut menunjukkan enam citra daun kentang yang diklasifikasikan sebagai *Late Blight* oleh model InceptionResNetV2. Setiap gambar dilengkapi dengan label "Actual Class: *Late Blight*" dan nilai confidence, yang menunjukkan tingkat keyakinan model terhadap prediksinya. Berdasarkan hasil tersebut, model berhasil mengklasifikasikan seluruh citra dengan benar ke dalam kelas *Late Blight*, dengan tingkat kepercayaan yang sangat tinggi, yaitu di atas 97%. Hal ini menandakan bahwa model mampu mengenali fitur visual khas dari penyakit *Late Blight*, seperti bercak coklat kehitaman di area tepi atau tengah daun, secara konsisten. Tingginya nilai confidence juga menjadi indikator bahwa model bekerja dengan stabil dan akurat dalam mendeteksi penyakit ini, mendukung kesimpulan bahwa InceptionResNetV2 merupakan arsitektur yang efektif dalam klasifikasi citra daun kentang berdasarkan gejala penyakit.

IV. KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa implementasi model dan proses pengujian terhadap data citra daun kentang menunjukkan performa yang baik. Dataset dibagi dengan proporsi 80% untuk pelatihan dan 20% untuk pengujian, sementara ukuran citra diubah menjadi 299 x 299 piksel. Pada epoch ke-10 dengan batch size sebesar 20, model dilatih menggunakan total 816 citra daun sehat, 1.303 citra *Early Blight*, dan 1.132 citra *Late Blight*, yang telah dibagi ke dalam data training, testing, dan validasi. Hasil pelatihan ini menghasilkan akurasi sebesar 94,20% untuk data pelatihan dan 95,30% untuk data validasi.

V. REFERENSI

- Amatullah, L., Ein, I., & Santoni, M. M. (2021). Identifikasi Penyakit Daun Kentang Berdasarkan Fitur Tekstur dan Warna Dengan Menggunakan Metode K-Nearest Neighbor. *Seminar Nasional Mahasiswa Ilmu Komputer Dan Aplikasinya (SENAMIKA), April*, 783–791.
- Dash, S., Sethy, P. K., & Behera, S. K. (2023). Cervical Transformation Zone Segmentation and Classification based on Improved Inception-ResNet-V2 Using Colposcopy Images. *Cancer Informatics*, 22. <https://doi.org/10.1177/11769351231161477>
- Firasari, E., & Cahyanti, F. L. D. (2023). Classification of Potato Leaf Diseases Using Convolutional Neural Network. *Jurnal Techno Nusa Mandiri*, 20(2), 89–94. <https://doi.org/10.33480/techno.v20i2.465>

- 5
- Fitriana, A., & Hakim, L. (2019). EFEKTIVITAS CENDAWAN ENDOFIT ASAL AKAR TANAMAN KENTANG dalam MEDIA KOMPOS KULIT KOPI untuk MENEKAN PERKEMBANGAN PENYAKIT HAAR DAUN KENTANG (Phytophthora infestans) Endophytic Fungus effectiveness Origin Root Crops Potatoes in Compost Media Skin Diseases Co. *Jurnal Agrista*, 23(1), 9–10.
- Fuadi, A., & Suharso, A. (2022). Perbandingan Arsitektur Mobilenet Dan Nasnetmobile Untuk Klasifikasi Penyakit Pada Citra Daun Kentang. *JIPi (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 7(3), 701–710. <https://doi.org/10.29100/jipi.v7i3.3026>
- Lu, J., Tan, L., & Jiang, H. (2021). Review on convolutional neural network (CNN) applied to plant leaf disease classification. *Agriculture (Switzerland)*, 11(8), 1–18. <https://doi.org/10.3390/agriculture11080707>
- Nauval, K. I., & Lestari, S. (2022). Implementasi Deteksi Objek Penyakit Daun Kentang dengan Metode Convolutional Neural Network. *Jurnal Aplikasi Teknologi Informasi Dan Manajemen (JATIM)*, 3(2), 136–149. <https://doi.org/10.31102/jatim.v3i2.1576>
- Nugraha, P., Komarudin, A., & Ramadhan, E. (2022). Deteksi Objek Dan Jenis Burung Menggunakan Convolutional Neural Network Dengan Arsitektur Inception Resnet-V2. *INFOTECH Journal*, 8, 47–55. <https://doi.org/10.31949/infotech.v8i2.2889>
- Nurdin, A., Satria, D., Kartika, Y., Rezha, A., & Najaf, E. (2024). *Klasifikasi Penyakit Daun Tomat Dengan Metode Convolutional Neural Network Menggunakan Arsitektur Inception-V3*. 1, 1–6.
- Nurpauziah, I., & Riani, S. (2024). Identifikasi Budidaya Tanaman Kentang (Solanum Tuberosum L.) Varietas Granola Dengan Sistem Aeroponik. *Jurnal Biosains Medika*, 2(1), 15–21.
- Riyanto, V., Nurdianti, S., Marimin, Syukur, M., & Neyman, S. N. (2025). Journal of Agricultural Science and Technology A. *Deep Learning Approaches for Plant Disease Diagnosis Systems: A Review and Future Research Agendas*, 9(1), 1–17.
- Rozaqi, A. J., Sunyoto, A., & Arief, M. rudyanto. (2021). Deteksi Penyakit Pada Daun Kentang Menggunakan Pengolahan Citra dengan Metode Convolutional Neural Network. *Creative Information Technology Journal*, 8(1), 22. <https://doi.org/10.24076/citec.2021v8i1.263>
- Sholihati, R. A., Sulistijono, I. A., Risnumawan, A., & Kusumawati, E. (2020). Potato Leaf Disease Classification Using Deep Learning Approach. *IES 2020 - International Electronics Symposium: The Role of Autonomous and Intelligent Systems for Human Life and Comfort*, 392–397. <https://doi.org/10.1109/IES50839.2020.9231784>
- Teresia Ompusunggu, P. (2022). Klasifikasi Penyakit Tanaman Pada Daun Kentang Dengan Metode Convolutional Neural Network Arsitektur Mobilenet. *Jurnal Syntax Fusion*, 2(09), 740–751. <https://doi.org/10.54543/fusion.v2i09.217>