

PENERAPAN *CONVOLUTIONAL NEURAL NETWORK (CNN)* DALAM DETEKSI PENYAKIT PADA TANAMAN TERONG

Sigit Dwianto*¹, Farhan Naufal Mubarak², Dzaki Satriatama³, Tinuk Agustin⁴

¹²³⁴STMIK Amikom Surakarta

¹²³⁴Sukoharjo Indonesia

Email: ¹sigit.10403@mhs.amikomsolo.ac.id,

²farhan.10397@mhs.amikomsolo.ac.id, ³dzaki.10394@mhs.amikomsolo.ac.id,

⁴agustin.amikom@gmail.com

Abstract

This research evaluates the performance of three optimization algorithms, namely Adam, SGD, and RMSProp, in classifying disease-infected leaves and healthy leaves using Convolutional Neural Networks (CNN). This study highlights the challenges farmers face due to various diseases that affect the growth of eggplant plants, which can lead to crop failure. By utilizing transfer learning using the Inception-V3 architecture, this research aims to improve disease identification in eggplant plants, so as to increase production. The results show that the Adam optimizer provides the best accuracy and loss, with training and validation accuracy close to 1 after 10 epochs. RMSProp also shows good performance with accuracy close to 0.95, while SGD improves accuracy more slowly. This study concludes that CNN is effective in distinguishing diseased and healthy leaves, and recommends further exploration of other optimization algorithms and expansion of the data set.

Keywords : Convolutional Neural Networks (CNN), Optimizer Adam, RMSProp Stochastic Gradient Descent (SGD)

Abstraksi

Penelitian ini mengevaluasi kinerja tiga algoritma optimasi, yaitu Adam, SGD, dan RMSProp, dalam mengklasifikasikan daun terinfeksi penyakit dan daun sehat menggunakan Convolutional Neural Networks (CNN). Studi ini menyoroti tantangan yang dihadapi petani akibat berbagai penyakit yang mempengaruhi pertumbuhan tanaman terong, yang dapat menyebabkan kegagalan panen. Dengan memanfaatkan transfer learning menggunakan arsitektur Inception-V3, penelitian ini bertujuan untuk meningkatkan identifikasi penyakit pada tanaman terong, sehingga dapat meningkatkan produksi. Hasil menunjukkan bahwa optimizer Adam memberikan akurasi dan loss terbaik, dengan akurasi pelatihan dan validasi mendekati 1 setelah 10 epoch. RMSProp juga menunjukkan kinerja yang baik dengan akurasi mendekati 0,95, sementara SGD meningkatkan akurasi lebih lambat. Penelitian ini menyimpulkan bahwa CNN efektif dalam membedakan daun sakit dan sehat, dan merekomendasikan eksplorasi lebih lanjut terhadap algoritma optimasi lainnya serta perluasan kumpulan data.

Kata Kunci : Convolutional Neural Networks (CNN), Optimizer Adam, RMSProp Stochastic Gradient Descent (SGD)

1. PENDAHULUAN

Tanaman terong tidak serta merta tumbuh dan berkembang begitu saja, Berdasarkan pengamatan dilapangan pada musim ini banyak masyarakat/petani mengalami kerusakan tanaman terong sampai tanaman terong mati dan menyebabkan gagal panen. Fakta menunjukkan bahwa tanaman terong memiliki berbagai macam gangguan untuk kelangsungan hidup dan berkembangnya [1]

Pengaruh media tanam terhadap pertumbuhan tanaman terong dengan sistem hidroponik. Produksi terong di Indonesia pada tahun 2020,2021 berturut-turut adalah sebesar 551.552 ton dan 676.339 ton. Jumlah tersebut cenderung meningkat namun produksinya masih tergolong rendah [2]. Insiden dan identifikasi penyakit layu pada tanaman terong. Penyakit layu fusarium menunjukkan tanda dan gejala yang khas, Gejalanya ditandai dengan tanaman menjadi layu, mulai dari daun bagian bawah dan anak tulang daun menguning [3]

Sistem pendukung keputusan diagnosa penyakit pada tumbuhan terong merupakan salah satu alternatif yang dapat diberikan untuk memberikan bantuan dalam mengidentifikasi penyakit yang ada pada tumbuhan terong, diharapkan untuk mempermudah proses diagnosa penyakit pada tumbuhan terong [4]. Namun, dengan kemajuan teknologi, berbagai metode deteksi berbasis otomatis telah berkembang.

Model *Convolutional Neural Network (CNN)* adalah salah satu metode yang sangat bermanfaat. *CNN* yang dapat mengklasifikasikan gambar dengan akurasi tinggi merupakan salah satu teknik yang saat ini sedang dikembangkan untuk kategorisasi penyakit tanaman [5]. Model *Convolutional Neural Network (CNN)* adalah Jaringan saraf tiruan yang dimodelkan setelah korteks visual hewan dan sangat efektif dalam mengenali pola rumit dalam data visual [6]. Selain itu, strukturnya yang dalam dan hierarkis, *Convolutional Neural Network (CNN)* dapat mempelajari fitur dari level rendah hingga level tinggi dan memerlukan lebih sedikit parameter, sehingga menurunkan kemungkinan *overfitting* [7].

Proses *transfer learning* antara *Convolutional Neural Network (CNN)* disebut sebagai "*fine-tuning*", di mana lapisan fitur ditransfer dari sumber *CNN* yang hanya dimodifikasi untuk menggunakan data target [8]. *Adam*, *SGD*, dan *RMSprop* adalah beberapa pengoptimal yang digunakan di *CNN* untuk klasifikasi gambar [9][10] Pada penelitian ini menggunakan pengujian optimizer yang berbeda *Adam*, *SGD*, dan *RMSProp* dalam menentukan algoritma terbaik untuk mengklasifikasikan daun sehat dan daun yang terinfeksi penyakit. Diharapkan bahwa studi ini akan membantu mengurangi penyakit terong bagi petani terong, peneliti, dan masyarakat umum.

2. TINJAUAN PUSTAKA

Penelitian Andi Nurdin dkk [11] Dalam penelitian ini, pendekatan Convolutional Neural Network (CNN) dengan transfer learning Inception-V3 digunakan untuk menyelidiki penyakit daun tanaman tomat. Hasil klasifikasi menggunakan optimizer Adam, SGD, dan RMS Prop menunjukkan bahwa optimizer Adam menghasilkan hasil terbaik, seperti yang ditunjukkan oleh akurasi tertinggi dengan total 93,8% dan kinerja model yang stabil.

Penelitian Doni Anggara dkk [12] melakukan penelitian terhadap ekspresi wajah dengan dengan metode Convolutional Neural Network (CNN) menggunakan perbandingan performa optimizer Adam, SGD, dan RMSProp. Mendapat hasil penelitian eksperimental, model yang menggunakan optimizer Adam memiliki accuracy sebesar 68.61%, model dengan SGD memiliki accuracy 57.68%, dan model dengan RMSprop memiliki accuracy 54.83%.

Sebuah penelitian yang dilakukan Khrisnaldi Wijaya dkk [13] melakukan penelitian klasifikasi kepemilikan tanda tangan menggunakan Convolutional Neural Network berdasarkan optimizer yang digunakan. Dengan *optimizer Adam, SGD, dan RMSprop* dapat mengklasifikasi tanda tangan dengan cukup baik dan akurat. *Optimizer* dengan akurasi tertinggi didapatkan oleh *optimizer SGD* dibandingkan *optimizer Adam* dan *RMSprop*. Hal ini dibuktikan pada pengujian dataset yang dilakukan didapatkan hasil akurasi tertinggi pada *optimizer SGD* dengan nilai *precision* sebesar 90%, *recall* 83,3%, *f1-score* 80,7%, dan *accuracy* 83,3%.

Penelitian Eka Aenun Nisa Munfaati dkk [14] Memisahkan antara buah dan sayuran yang segar dengan busuk dapat dilakukan dengan menggunakan teknologi deep learning. Salah satu teknologi deep learning adalah Convolutional Neural Network (CNN). Dalam penelitian ini, klasifikasi dengan CNN memperoleh akurasi pelatihan sebesar 90,42%, akurasi validasi mencapai 94,21%, dan akurasi pengujian mencapai 80,83%. Akurasi ini diperoleh dengan menggunakan optimizer SGD, 0,01 learning rate, 16 batch size, dan 20 epochs.

Sebuah penelitian yang dilakukan Mukti Setiono dkk [15] menunjukkan pengujian model Convolutional Neural Network (CNN) untuk klasifikasi penyakit antraknosa pada citra cabai rawit menunjukkan variasi kinerja berdasarkan jenis optimizer yang digunakan. Pada pengujian pertama, optimizer Adam menunjukkan hasil terbaik dengan mencapai akurasi sebesar 93.25% dan nilai loss sebesar 6.75%. Optimizer kedua yang diuji adalah RMSprop, yang mencapai akurasi 92% dengan nilai loss 8%. Pengujian terakhir menggunakan optimizer SGD menghasilkan akurasi sebesar 91.50% dan nilai loss 8.50%.

Penelitian Yuzril Nur Maulana dkk [16] melakukan klasifikasi penyakit tanaman kentang dengan metode Convolutional Neural Network (CNN). Menggunakan DenseNet201 untuk perbandingan optimizer seperti Adam, SGD, dan RMSprop memberikan variasi pendekatan optimasi dan membantu menemukan parameter yang optimal untuk meningkatkan performa model. Adam mencapai akurasi rata-rata 97%

dengan precision, recall, dan F1-score masing-masing mencapai 98%, menunjukkan efektivitasnya dalam mengoptimalkan model. SGD, meskipun sedikit lebih rendah dengan akurasi 83% dan metrik lain sekitar 82%, tetap memberikan hasil yang baik dengan pendekatan optimasi yang sederhana. RMSprop menunjukkan akurasi 94% dengan metrik lain sekitar 94%.

R. Dhamayanti dkk [17] melakukan penelitian klasifikasi kualitas sayur kol dengan learning rate sebesar 0.004, 30 epoch dan tiga optimizer yang digunakan yaitu SGD, Adam dan RMSProp. Pada penelitian ini hasil akurasi terbesar yaitu pada optimizer Adam sebesar 80% untuk data test dan 73% untuk data train.


Agung Sutikno dkk [18] Dalam penelitian model CNN mampu mengidentifikasi pola visual yang membedakan antara dua situasi dengan tingkat akurasi yang sangat tinggi menggunakan dataset yang mencakup berbagai penyakit dan masalah kesehatan yang memengaruhi tanaman sawi pak choy. Menurut hasil pengujian, teknik optimizer Adam menghasilkan kinerja terbaik, dengan nilai loss 0,240 dan tingkat akurasi 0,8912 atau 89,12%.

Penelitian yang dilakukan Nur Ibrahim dkk [19] melakukan klasifikasi tingkat kematangan pucuk daun teh menggunakan metode Convolutional Neural Network (CNN). Pada pengujian arsitektur ResNet50 menggunakan Optimizer Adam, SGD dan RMSprop. Optimizer SGD memperoleh nilai akurasi tertinggi yaitu 93% dan precision 94% dibandingkan dengan nilai akurasi pada Optimizer lain, Sedangkan pada pengujian arsitektur VGGNet19 menggunakan Optimizer Adam, SGD dan RMSprop. Optimizer Adam dan RMSprop memperoleh nilai akurasi tertinggi yaitu 97% dan precision 97% dibandingkan dengan nilai akurasi pada Optimizer SGD.

Penelitian Afis Julianto dkk [20] melakukan klasifikasi untuk penyakit tanaman padi menggunakan metode Convolutional Neural Network berdasarkan optimizer yang digunakan. Penelitian ini menggunakan CNN arsitektur MobileNet-V2 sebagai model pelatihan. Berdasarkan percobaan yang sudah dilakukan, penentuan *hyperparameter* sangat berpengaruh terhadap performa model. *Hyperparameter* dengan jumlah *epoch* 100, *batch size* 32, *learning rate* 0,001 dan *optimizer* RMSProp memberikan hasil yang paling optimal dengan nilai *accuracy* 97,56%, *precision* 97,64%, *recall* 97,57% dan *f1-score* 97,57% pada data *testing* yang digunakan.

3. METODE PENELITIAN

Pada penelitian ini ada beberapa tahapan penyelesaian dalam melakukan deteksi penyakit daun pada tanaman terong seperti yang ditampilkan pada gambar 1.



Gambar 1. Alur Penelitian

Terdapat beberapa tahapan dalam melakukan Identifikasi yang memanfaatkan model pembelajaran transfer metode *Convolutional Neural Network (CNN)* melibatkan beberapa langkah. Pengumpulan data merupakan langkah pertama, diikuti oleh *preprocessing data*, yang meliputi perubahan ukuran gambar dan pemisahan *dataset* menjadi data pelatihan, validasi, dan pengujian. Selanjutnya, pembelajaran *transfer Inception-V3* digunakan untuk menguji model arsitektur *Convolutional Neural Network (CNN)*. Prosedur klasifikasi dengan pembelajaran transfer menggunakan arsitektur *Inception-V3* merupakan langkah berikutnya. Model CNN yang optimal untuk mengenali penyakit daun terong akan diidentifikasi dengan mengevaluasi hasil klasifikasi menggunakan tabel perbandingan *accuracy* validasi dan *lost* validasi berdasarkan metode optimasi

3.1. Pengumpulan Data

Dalam penelitian ini, data gambar daun terong dari situs web Kaggle digunakan untuk mengidentifikasi penyakit daun terong. Data yang digunakan dibagi menjadi 2 kelas yaitu *Healthy Leaf* dan *Wilt Disease*. Dengan setiap kelas memiliki jumlah 200 data.

3.2. Preprocessing Data

Proses mengubah data asli supaya dapat digunakan pada model klasifikasi dikenal sebagai persiapan data, atau *preprocessing data*. Dalam penelitian ini, *preprocessing data* mencakup meningkatkan akurasi proses klasifikasi dengan meningkatkan ukuran gambar menjadi 255 x 255 piksel. Untuk memasukkan data ke dalam model klasifikasi, kumpulan data dibagi menjadi dua bagian. Untuk melatih model klasifikasi, 80% dari

pembagian ini dikhususkan untuk data *training*., dan 20% lagi digunakan untuk data *validation*, yang merupakan data yang digunakan untuk memvalidasi model klasifikasi untuk mencegah *overfitting*.

3.3. Transfer Learning

Teknik di mana model yang sudah dilatih pada dataset besar digunakan kembali pada *dataset* baru yang lebih kecil, dengan melakukan modifikasi atau *fine-tuning* pada lapisan terakhir. Arsitektur yang digunakan mungkin telah dikembangkan sebagai pelengkap dari model pralatih, dengan beberapa lapisan atas dilatih kembali pada dataset baru, sedangkan lapisan-lapisan dasar dipertahankan. Dalam hal *Transfer Learning*, model ini dapat dibuat menggunakan fitur *feature extractor* dari model yang sudah terlatih (misalnya *VGG*, *ResNet*), kemudian ditambahkan lapisan klasifikasi yang lebih spesifik.

3.4. Pelatihan Model

Algoritma *optimizer* bertujuan untuk meminimalkan error, memperoleh bobot yang optimal, serta meningkatkan akurasi model sebaik mungkin. Pada penelitian ini, digunakan tiga jenis *optimizer*: *Adam*, *SGD*, dan *RMSprop*.

1. *Adam (Adaptive Moment Estimation)*

Salah satu *optimizer* yang paling banyak diterapkan yakni Adam Untuk meningkatkan efisiensi pelatihan, Adam menghitung gradien adaptif dan momentum gradien secara bersamaan, menggabungkan keunggulan *RMSprop* dan momentum. Dengan menggunakan estimasi rata-rata dan variansi gradien, *optimizer* ini secara dinamis menyesuaikan laju pembelajaran dan memberikan pembaruan parameter yang sesuai. Pada penelitian menggunakan parameter *learning_rate* = 0.0001, momentum=0.7.

2. *SGD (Stochastic Gradient Descent)*

Metode optimasi utama untuk model *deep learning* adalah *Stochastic Gradient Descent (SGD)*. Algoritme ini memperbarui bobot model dengan bergerak berlawanan arah gradien fungsi kerugian pada setiap batch data pelatihan. Meskipun mudah digunakan dan mudah diakses, SGD biasanya memiliki kecepatan konvergensi yang lebih lambat daripada metode optimasi lainnya. Pada penelitian menggunakan parameter *learning_rate*=0.0001, momentum=0.7.

3. *RMSprop*

Metode optimasi *RMSprop* menggunakan perubahan gradien dari iterasi sebelumnya untuk menyesuaikan laju pembelajaran untuk setiap parameter. Teknik ini membantu mengatasi masalah laju pembelajaran SGD karena menyesuaikan laju pembelajaran untuk setiap parameter secara khusus. *RMSprop* melatih *deep neural networks* dan mempercepat proses konvergensi pelatihan. Pada penelitian menggunakan parameter *learning_rate*=0.0001, momentum=0.7.

4. HASIL DAN PEMBAHASAN

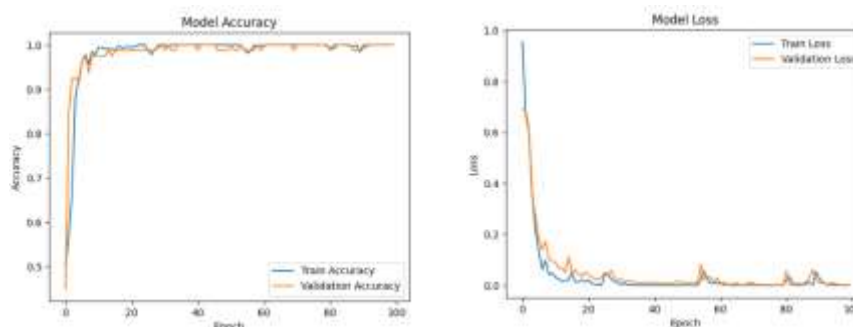
Pada penelitian ini bertujuan untuk menganalisis kinerja tiga algoritma optimasi dalam menentukan algoritma terbaik untuk mengklasifikasikan daun sehat dan daun yang terinfeksi penyakit. Berikut hasil pengujian yang dilakukan pada penelitian ini dapat dilihat pada tabel 1. Perbandingan akurasi validasi dan lost validasi loss berdasarkan metode optimasi.

Tabel 1. Perbandingan accuracy validasi dan lost validasi berdasarkan metode optimasi.

Optimizer	Accuracy		Loss	
	Training	Validasi	Training	Validasi
Adam	0.9970	0.9750	0.0114	0.0679
SGD	0.9489	0.9500	0.1384	0.1491
RMSProp	0.9842	0.9625	0.0788	0.1368

4.1. Hasil Klasifikasi dengan Optimizer Adam

Berikut hasil klasifikasi *optimizer Adam* pada data Accuracy dan Loss memberikan kinerja yang baik, seperti yang terlihat pada gambar 2 dibawah ini.




Gambar 2. Grafik Accuracy dan Loss dengan Optimizer Adam

Grafik Accuracy ini menunjukkan peningkatan tajam pada *accuracy* pelatihan dan validasi pada awal pelatihan, di mana *accuracy* mencapai nilai mendekati 1 setelah sekitar 10 *epoch*. Setelah itu, baik *accuracy* pelatihan maupun validasi tetap stabil dan sangat dekat satu sama lain. Hal ini menunjukkan bahwa model berhasil mempelajari pola dari data pelatihan dengan baik dan dapat menggeneralisasi dengan baik pada data validasi tanpa mengalami *overfitting*.

Pada grafik *loss* menunjukkan penurunan tajam pada *loss* pelatihan dan validasi pada awal pelatihan, di mana *loss* mencapai nilai mendekati 0 setelah sekitar 10 *epoch*. Setelah itu, baik *loss* pelatihan maupun validasi tetap rendah dan sangat dekat satu sama lain. Hal ini menunjukkan bahwa model berhasil meminimalkan kesalahan pada data pelatihan dan dapat menggeneralisasi dengan baik pada data validasi.

4.2. Hasil Klasifikasi dengan *Optimizer SGD*

Berikut hasil klasifikasi *optimizer SGD* pada data *Accuracy* dan *Loss* memberikan kinerja yang baik, seperti yang terlihat pada gambar 3 dibawah ini.




Gambar 3. Grafik *Accuracy* dan *Loss* dengan *Optimizer SGD*

Pada awal pelatihan *accuracy* pelatihan dan pengujian mulai dari titik yang lebih rendah (sekitar 0.4) dan secara bertahap meningkat seiring bertambahnya *epoch*. *Accuracy* pelatihan menunjukkan peningkatan yang stabil, menandakan bahwa model belajar dari data dengan baik. *Accuracy* pengujian awalnya menunjukkan fluktuasi, yang umum terjadi karena model mencoba menyesuaikan diri dengan data baru yang belum pernah dilihat sebelumnya. Namun, seiring waktu, *accuracy* pengujian mulai stabil dan mendekati *accuracy* pelatihan, mencapai nilai yang mendekati maksimum (sekitar 1.0).

Loss pelatihan dan pengujian dimulai dari nilai yang lebih tinggi (sekitar 0.7) dan secara bertahap menurun seiring bertambahnya *epoch*. *Loss* pelatihan menurun dengan bagus, menunjukkan bahwa model mampu meminimalkan kesalahan pada data pelatihan. Garis *loss* pengujian mengikuti tren serupa dengan beberapa fluktuasi awal, tetapi akhirnya menurun dan stabil mendekati nilai *loss* pelatihan, menandakan bahwa model juga mampu meminimalkan kesalahan pada data pengujian.

4.3. Hasil Klasifikasi dengan *Optimizer RMSProp*

Berikut hasil klasifikasi *optimizer RMSProp* pada data *Accuracy* dan *Loss* memberikan kinerja yang baik, seperti yang terlihat pada gambar 4 dibawah ini.



Gambar 4. Grafik *Accuracy* dan *Loss* dengan *Optimizer RMS Prop*

Hasil klasifikasi *optimizer* RMS Prop pada data pelatihan dan validasi memberikan kinerja yang baik, seperti yang terlihat pada gambar 4, grafik ini menunjukkan bahwa *accuracy* pelatihan cepat meningkat dan stabil mendekati nilai 1.0 setelah sekitar 10 *epoch*. *Accuracy* pengujian juga meningkat dengan cepat dan stabil pada nilai sekitar 0.95, dengan beberapa fluktuasi. Ini menunjukkan bahwa model berhasil belajar dengan baik dari data pelatihan dan dapat menggeneralisasi dengan baik pada data pengujian.

Grafik *loss* ini menunjukkan bahwa *loss* pelatihan menurun dengan cepat dan stabil pada sekitar 0.05 setelah sekitar 10 *epoch*. *Loss* pengujian juga menurun dengan cepat dan stabil pada sekitar 0.1, dengan beberapa fluktuasi. Ini menunjukkan bahwa model mampu meminimalkan kesalahan pada data pelatihan dan dapat menggeneralisasi dengan baik pada data pengujian.

5. KESIMPULAN

Berdasarkan penelitian ini, *optimizer* Adam menampilkan akurasi dan *loss* terbaik, meskipun pendekatan optimasi RMSprop dalam deteksi penyakit terong menggunakan *Convolutional Neural Networks (CNN)* menunjukkan kinerja yang baik.

- Adam menghasilkan akurasi dan *loss* terbaik dalam deteksi penyakit terong menggunakan *Convolutional Neural Networks (CNN)*. Setelah 10 *epoch*, akurasi pelatihan dan validasi Adam konsisten mendekati nilai 1.
- RMSprop mencapai akurasi yang mendekati 0,95, meskipun tidak sebaik Adam. RMSprop masih menunjukkan kinerja yang cukup baik dalam optimasi CNN.
- Meskipun SGD digunakan secara luas, optimasi dengan SGD lebih lambat dalam meningkatkan akurasi dibandingkan dengan Adam dan RMSprop.
- Hasil utama penelitian menunjukkan bahwa CNN efektif dalam membedakan daun tanaman terong yang sehat dan yang terinfeksi penyakit. Hal ini membuka peluang untuk intervensi cepat bagi petani dalam menangani masalah penyakit tanaman.

Penelitian selanjutnya disarankan untuk mengeksplorasi algoritma *optimizer* lain yang belum diuji, seperti AdaGrad, Adadelta, atau kombinasi berbagai *optimizer*. Perluasan kumpulan data untuk mencakup lebih banyak kondisi dan penyakit tanaman yang bervariasi sangat disarankan untuk meningkatkan kemampuan generalisasi model.

DAFTAR PUSTAKA

- [1] E. Famati Saro Ndruru *et al.*, “Sistem Pakar Mendiagnosis Hama Dan Penyakit Tanaman Terong Berbasis Web,” *INFORMATION SYSTEM DEVELOPMENT [ISD]*, vol. 5, no. 2, pp. 47–51, Jul. 2020.
- [2] A. Al Fandi, R. Muchtar, and D. Notarianto, “Pengaruh Media Tanam terhadap Pertumbuhan Tanaman Terong (*Solanum melongena* L.) Dengan Sistem Hidroponik,” 2020. doi: 10.52643/jir.v11i2.1108.
- [3] H. Hamidson *et al.*, “Insidensi dan Identifikasi Penyakit Layu pada Terong (*Solanum melongena* L.) di Desa Tanjung Pering, Kabupaten Ogan Ilir, Provinsi Sumatera Selatan,” vol. 10, no. 1, pp. 963–973, Oct. 2022.
- [4] M. R. Hardianto and R. N. Sukmana, “Sistem Pendukung Keputusan Diagnosa Penyakit Pada Tumbuhan Terong Ungu Menggunakan Metode Teorema Bayes,” *Digital Transformation Technology*, vol. 3, no. 2, pp. 505–514, Oct. 2023, doi: 10.47709/digitech.v3i2.2882.
- [5] I. E. Handayani and D. Avianto, “Klasifikasi Penyakit Antraknosa pada Cabai Merah Teropong ‘Inko Hot’ Dengan Metode Convolutional Neural Network,” *SINTECH*, vol. 6, 2023, doi: <https://doi.org/10.31598>.
- [6] O. A. Montesinos López, A. Montesinos López, and J. Crossa, “Convolutional Neural Networks in Multivariate Statistical Machine Learning Methods for Genomic Prediction,” pp. 533–577, 2022, doi: <https://doi.org/10.1007/978-3-030-89010-0>.
- [7] M. M. Taye, “Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions,” vol. 11, no. 3, Mar. 2023, doi: 10.3390/computation11030052.
- [8] J. Gupta, S. Pathak, and G. Kumar, “Deep Learning (CNN) and Transfer Learning: A Review,” *Journal of Physics: Conference Series, Institute of Physics*, 2022, doi: 10.1088/1742-6596/2273/1/012029.
- [9] E. Rasywir, Y. Pratama, and F. Fachruddin, “Eksperimen Pengujian Optimizer dan Fungsi Aktivasi Pada Code Clone Detection dengan Pemanfaatan Deep Neural Network (DNN),” *Building of Informatics, Technology and Science (BITS)*, vol. 4, no. 2, pp. 405–412, Sep. 2022, doi: 10.47065/bits.v4i2.1776.
- [10] K. Wijaya and E. P. Widiyanto, “Klasifikasi Kepemilikan Tanda Tangan Menggunakan Convolutional Neural Network dengan Arsitektur AlexNet,” *MDP Student Conference*, vol. 2, no. 1, pp. 133–143, Apr. 2023, doi: 10.35957/mdp-sc.v2i1.4328.

- [11] A. Nurdin, D. Satria, Y. Kartika, A. Rezha, and E. Najaf, "KLASIFIKASI PENYAKIT DAUN TOMAT DENGAN METODE CONVOLUTIONAL NEURAL NETWORK MENGGUNAKAN ARSITEKTUR INCEPTION-V3," *JURNAL ILMIAH INFORMATIKA*, vol. 12, Sep. 2024, doi: <https://doi.org/10.33884/jif.v12i02.9162>.
- [12] D. Anggara, N. Suarna, and Y. Arie Wijaya, "ANALISA PERBANDINGAN PERFORMA OPTIMIZER ADAM, SGD, DAN RMSPROP PADA MODEL H5," *Jurnal Ilmiah NERO*, vol. 8, no. 1, pp. 53–64, 2023, doi: <https://doi.org/10.21107/nero.v8i1.19226>.
- [13] K. Wijaya and E. P. Widiyanto, "KLASIFIKASI KEPEMILIKAN TANDA TANGAN MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK DENGAN ARSITEKTUR ALEXNET," vol. 2, no. 1, pp. 133–143, 2023, doi: <https://doi.org/10.35957/mdp-sc.v2i1.4328>.
- [14] E. Aenun, N. Munfaati, and A. Witanti, "Klasifikasi Buah dan Sayuran Segar atau Busuk Menggunakan Convolutional Neural Network," *Jurnal Informatika Sunan Kalijaga*, vol. 9, no. 1, pp. 27–38, Jan. 2024, doi: <https://doi.org/10.14421/jiska.2024.9.1.27-38>.
- [15] M. Setiono and Supatman, "Klasifikasi Penyakit Antraknosa Citra Cabai Rawit Dengan Metode Convolutional Neural Network (CNN)," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 11, no. 2, pp. 308–320, Jun. 2024, doi: <https://doi.org/10.35957/jatisi.v11i2.8039>.
- [16] Y. N. Maulana, C. Rozikin, and A. Voutama, "Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Penyakit Tanaman Kentang Dengan Arsitektur Densenet," *Jurnal Lentera*, vol. 23, no. 3, Sep. 2024, doi: <https://doi.org/10.29138/lentera.v23i3.1455>.
- [17] R. Dhamayanti, M. F. Rohmah, and S. Zahara, "PENGUNAAN DEEP LEARNING DENGAN METODE CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI KUALITAS SAYUR KOL BERDASARKAN CITRA FISIK," *Jurnal Ilmiah Teknologi Informasi dan Sains*, vol. 1, no. 1, pp. 8–15, Jun. 2021, doi: <https://doi.org/10.36815/submit>.
- [18] A. Sutikno, S. D. Pohan, and A. Aljabar, "KLASIFIKASI PENYAKIT PADA SAWI PAKCOY DENGAN MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)," *Jurnal TIKTA Fakultas Ilmu Komputer Universitas Almuslim*, vol. 9, no. 2, pp. 137–145, Aug. 2024, doi: <https://doi.org/10.51179/tika.v9i2.2665>.
- [19] N. IBRAHIM *et al.*, "Klasifikasi Tingkat Kematangan Pucuk Daun Teh menggunakan Metode Convolutional Neural Network," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 10, no. 1, p. 162, Jan. 2022, doi: <https://doi.org/10.26760/elkomika.v10i1.162>.
- [20] A. Julianto, A. Sunyoto, and F. W. Wibowo, "OPTIMASI HYPERPARAMETER CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI PENYAKIT TANAMAN PADI," *TEKNIMEDIA*, vol. 3, no. 2, pp. 98–105, Dec. 2022, doi: <https://doi.org/10.46764/teknimedia.v3i2.77>.