

Implementasi Sistem Deteksi Otomatis pada Tanaman Cabai Rawit Menggunakan Convolutional Neural Network (CNN) Berbasis TensorFlow untuk Optimasi Pertanian Modern

Implementation of an Automatic Detection System for Chili Plants Using a TensorFlow-Based Convolutional Neural Network (CNN) for Modern

Adi Sucipto¹, Diaz Nuraji¹, Mochammad Enrique Lazuardi Ramadany¹, Junia Vitasari¹, Rifqi Aji Widarso¹

¹PSDKU-Teknik Informatika-Kab. Sidoarjo, Teknologi Informasi, Politeknik Negeri Jember

*Email Koresponden: adisucipto@polije.ac.id

Received : 28 Oktober 2024 | Accepted : 20 Desember 2024 | Published : 24 Desember 2024

Kata Kunci	ABSTRAK
Cabai rawit, CNN, deteksi otomatis, optimasi pertanian, TensorFlow	Dalam industri pangan cabai rawit salah satu komoditas yang sangat penting di Indonesia. Permintaan cabai rawit terus meningkat seiring dengan pertumbuhan penduduk dan meningkatnya kesadaran masyarakat akan pentingnya konsumsi makanan yang seimbang. Untuk itu budidaya cabai rawit perlu diperhatikan agar kestabilan produksi cabai rawit dapat tetap terjaga. Tujuan dari penelitian ini adalah untuk membuat sistem deteksi otomatis berbasis <i>Convolutional Neural Network</i> (CNN) untuk tanaman cabai rawit (<i>Capsicum frutescens</i>) dan meningkatkan efisiensi pertanian modern. Dengan menggunakan TensorFlow, sistem ini dilatih menggunakan <i>dataset</i> yang mencakup gambar cabai rawit dalam tiga kondisi: sehat, terinfeksi, dan kekurangan nutrisi. Untuk menjamin akurasi, data ini dikumpulkan secara langsung dari lahan pertanian. Model CNN memiliki akurasi lebih dari 85% di semua kondisi tanaman, menurut metrik akurasi, <i>precision</i> , dan <i>recall</i> . Hasilnya menunjukkan bahwa model CNN ini dapat membantu petani cabai rawit menemukan masalah tanaman dengan cepat dan akurat. Disarankan untuk menggunakan dataset yang lebih besar dan mengintegrasikan sistem ini ke dalam perangkat <i>mobile</i> guna mendukung pertanian cerdas di Indonesia.
Keywords	ABSTRACT
<i>Cayenne pepper, CNN, automatic detection, agricultural optimization, TensorFlow</i>	<i>In the food industry, cayenne 10.25047/nacia.v2i1.254 pepper is a very important commodity in Indonesia. Demand for cayenne pepper continues to increase along with population growth and increasing public awareness of the importance of consuming a balanced diet. For this</i>

reason, cayenne pepper cultivation needs to be considered so that the stability of cayenne pepper production can be maintained

*The purpose of this research is to create a Convolutional Neural Network (CNN)-based automatic detection system for cayenne pepper (*Capsicum frutescens*) plants and improve the efficiency of modern agriculture. Using TensorFlow, the system is trained using a dataset that includes images of cayenne pepper in three conditions: healthy, infected, and nutrient deficient. To ensure accuracy, this data was collected directly from the farm. The CNN model had more than 85% accuracy across all plant conditions, according to accuracy, precision, and recall metrics. The results show that this CNN model can help cayenne pepper farmers find crop problems quickly and accurately. It is recommended to use larger datasets and integrate this system into mobile devices to support smart agriculture in Indonesia.*

1. PENDAHULUAN

Pertanian merupakan sektor krusial dalam mendukung ketahanan pangan dan kesejahteraan masyarakat, terutama di negara agraris seperti Indonesia. Salah satu komoditas yang memiliki nilai ekonomi tinggi dan banyak dikonsumsi adalah cabai rawit (*Capsicum frutescens*). Namun, produktivitas tanaman ini sering kali terhambat oleh berbagai faktor seperti serangan penyakit, kekurangan nutrisi, dan pengaruh lingkungan yang tidak ideal. Hal ini membuat pemantauan dan pengelolaan kesehatan tanaman menjadi kebutuhan yang mendesak, khususnya bagi petani yang mengalami keterbatasan waktu dan sumber daya. (Chen, J., Zhang et al. 2020)

Untuk mengatasi masalah ini, teknologi deteksi otomatis berbasis citra telah dikembangkan dengan pendekatan *Convolutional Neural Network* (CNN) dalam rangka meningkatkan akurasi dan efisiensi pemantauan kondisi tanaman. CNN, yang merupakan bagian dari deep learning, mampu mengenali pola kompleks pada gambar dan mengkategorikan kondisi tanaman secara otomatis. Berbagai studi terdahulu telah menunjukkan bahwa model CNN memiliki performa yang menjanjikan dalam deteksi penyakit tanaman dan klasifikasi kondisi tanaman berdasarkan data visual. Misalnya, penelitian oleh Mohanty et al. (2016) menunjukkan bahwa deteksi otomatis penyakit pada tanaman menggunakan CNN memberikan hasil yang akurat dan dapat diterapkan pada berbagai jenis tanaman. Demikian pula, studi oleh Saleem et al. (2020) menyoroti potensi CNN dalam klasifikasi penyakit tanaman yang dapat mendukung sistem pertanian cerdas (smart farming).

Walaupun berbagai pendekatan sudah dikembangkan, kebanyakan sistem deteksi otomatis masih belum teroptimasi untuk pengelolaan tanaman cabai rawit di Indonesia. Penelitian ini hadir untuk mengisi kekosongan tersebut dengan mengembangkan sistem deteksi berbasis CNN yang mampu mengenali tiga kondisi tanaman cabai rawit: sehat, terinfeksi, dan kurang nutrisi, berdasarkan dataset citra yang diambil dari lahan pertanian secara langsung. Sistem ini dirancang menggunakan *framework* TensorFlow, yang memungkinkan pemrosesan data secara cepat dan akurat dengan kapabilitas integrasi pada perangkat seluler, sehingga dapat dengan mudah diakses oleh petani di lapangan.

Tujuan penelitian ini adalah mengembangkan sistem deteksi otomatis yang membantu petani dalam mengidentifikasi masalah pada tanaman cabai rawit lebih dini, sehingga tindakan

intervensi dapat dilakukan sebelum terjadi kerugian yang lebih besar. Dengan adopsi teknologi ini, diharapkan petani dapat meningkatkan produktivitas dan efisiensi dalam mengelola lahan mereka. Manfaatnya tidak hanya mencakup peningkatan hasil panen, tetapi juga kontribusi signifikan terhadap perkembangan teknologi smart farming untuk mendukung pertanian berkelanjutan.

2. METODE

Metode penelitian ini disusun untuk mengembangkan sistem deteksi otomatis kondisi tanaman cabai rawit berbasis *Convolutional Neural Network* (CNN) dengan menggunakan TensorFlow. Penelitian mencakup beberapa tahapan, yaitu bahan dan pengambilan sampel, preprocessing data, desain model CNN, pengolahan data, serta evaluasi kinerja model. Setiap tahapan dijelaskan dengan rinci untuk memudahkan peneliti lain mengadopsi atau memodifikasi prosedur ini.

2.1 Bahan dan Pengambilan Sampel



Gambar 2.1. Gambar kondisi cabai

Pada gambar diatas menggambarkan cabai rawit sehat untuk gambar cabai yang paling kiri, cabai terinfeksi untuk gambar yang tengah dan cabai yang kurang nutrisi untuk gambar yang paling kanan.

Dataset utama yang digunakan dalam penelitian ini adalah citra tanaman cabai rawit dengan tiga kategori kondisi: sehat, terinfeksi penyakit, dan kekurangan nutrisi. Data dikumpulkan dari lahan pertanian, selama periode Januari hingga Maret 2024. Pengambilan gambar dilakukan menggunakan kamera digital Canon EOS 850D (Canon Inc., Tokyo, Jepang) beresolusi 24.1 MP, dengan lensa EF-S 18-55mm f/4-5.6 IS STM untuk memastikan kualitas visual yang mendukung akurasi model.

Sampel yang diperoleh sebanyak 1.500 gambar, dengan 500 gambar per kategori. Labeling setiap gambar dilakukan oleh ahli pertanian untuk memastikan ketepatan kategori. Data yang terkumpul selanjutnya digunakan dalam proses pelatihan dan pengujian model.

2.2 Preprocessing Data

Preprocessing pada dataset dilakukan untuk meningkatkan akurasi dan efisiensi model. Tahapan preprocessing meliputi:

- Resizing: Gambar diubah menjadi ukuran 224 x 224 piksel untuk disesuaikan dengan input standar model CNN.

- Normalisasi: Setiap piksel dinormalisasi ke rentang 0-1 agar dapat diproses secara optimal.
- Augmentasi Gambar: Variasi gambar diperoleh melalui rotasi 10° , flipping horizontal, serta zoom sebesar 20% guna mengurangi kemungkinan overfitting.
- Segmentasi Gambar: Teknik segmentasi sederhana diterapkan untuk memisahkan bagian tanaman dari latar belakang menggunakan metode thresholding.

2.3 Desain dan Implementasi Model CNN

Model CNN dikembangkan menggunakan TensorFlow versi 2.12 (Google Inc., California, Amerika Serikat). Arsitektur CNN yang digunakan adalah ResNet-50, yang telah terbukti mampu menangani tugas klasifikasi citra dengan baik. Struktur CNN ini mencakup beberapa lapisan, antara lain:

- *Convolution Layer*: Lapisan ini menggunakan filter berukuran 3×3 untuk melakukan ekstraksi fitur visual.
- *Pooling Layer*: *Max-pooling* diterapkan setelah setiap lapisan *convolution* untuk mengurangi dimensi fitur, mengoptimalkan komputasi, dan mengurangi risiko *overfitting*.
- *Fully Connected Layer*: Lapisan ini menghubungkan fitur-fitur yang telah diekstraksi menuju output kelas.

Model dilatih menggunakan *25 epoch* dan *batch size 32*, dengan *Adam optimizer* sebagai metode optimasi dan *learning rate 0.001*. Fungsi *loss* yang digunakan adalah *categorical crossentropy*, yang sesuai untuk klasifikasi multi-kategori.

2.4 Pengolahan Data dan Evaluasi Model

Dataset dibagi ke dalam tiga bagian: data pelatihan (70%), data validasi (15%), dan data pengujian (15%). Untuk menilai kinerja model, metrik yang digunakan meliputi akurasi, *precision*, *recall*, dan *confusion matrix*. Metrik ini memberikan gambaran tentang kemampuan model dalam mengklasifikasikan setiap kategori dengan benar.

Untuk memastikan hasil yang konsisten, diterapkan metode *cross-validation* lima kali lipat. Formula evaluasi akurasi yang digunakan ditunjukkan pada persamaan (1):

$$\text{Akurasi} = (X + Y) / \text{Total Sampel} \quad (1)$$

dengan:

- X: jumlah prediksi benar pada kondisi sehat,
- Y: jumlah prediksi benar pada kondisi terinfeksi atau kurang nutrisi.

2.5 Peralatan dan Perangkat Lunak

Proses pelatihan model dilakukan pada perangkat keras yang terdiri dari prosesor AMD Ryzen 5 4600H, GPU NVIDIA GTX 1650 (4GB VRAM), dan RAM 16GB DDR4. Perangkat ini dijalankan pada sistem operasi Ubuntu 22.04 LTS. Perangkat lunak dan pustaka yang digunakan adalah sebagai berikut:

- TensorFlow 2.12: *Framework* utama untuk pengembangan dan pelatihan model CNN.
- OpenCV 4.5: Pustaka untuk *preprocessing* gambar.
- NumPy 1.23.5: Pustaka untuk manipulasi data numerik.
- Matplotlib 3.7: Pustaka untuk visualisasi hasil.

2.6 Modifikasi Metode

Modifikasi dilakukan pada tahap augmentasi data untuk menambah variasi gambar, yang tidak diterapkan dalam penelitian sebelumnya pada deteksi tanaman cabai rawit. Modifikasi ini termasuk penggunaan rotasi dan zoom untuk menghasilkan perspektif yang lebih beragam, sehingga diharapkan dapat meningkatkan generalisasi model terhadap kondisi tanaman yang bervariasi di lapangan.

berikut adalah kasifikasi tanaman yang sehat, terinfeksi dan kurang nutrisi :

1. Tanaman Sehat

- Warna Daun: Hijau cerah, sesuai dengan spesies tanaman.
- Struktur Daun: Daun memiliki tekstur halus, tidak mengerut, dan bentuknya sempurna.
- Pertumbuhan Tanaman: Tinggi dan lebar tanaman berkembang sesuai dengan tahap pertumbuhan normal.
- Produksi: Hasil panen atau bunga sesuai dengan kapasitas optimal tanaman.
- Akar: Akar berwarna putih atau krem, tidak busuk, dan bercabang dengan baik.
- Respon Terhadap Stres: Tidak menunjukkan tanda-tanda layu atau kerontokan daun pada kondisi lingkungan normal.
- Keseimbangan Nutrisi: Tidak ada gejala klorosis, nekrosis, atau bercak pada daun.

2. Tanaman Terinfeksi

- Warna Daun: Terdapat bercak kuning, coklat, atau hitam yang menunjukkan infeksi jamur, bakteri, atau virus.
- Tepi Daun: Daun menggulung atau tepinya kering (gejala khas infeksi patogen).
- Pertumbuhan Tidak Normal: Tanaman kerdil atau pertumbuhannya terhambat.
- Luka atau Lesi: Adanya lesi, busuk, atau pembengkakan pada batang, daun, atau buah.
- Titik atau Bercak: Bercak dengan pola khas, seperti lingkaran konsentris (jamur), mosaik (virus), atau jaringan mati (bakteri).
- Exudate (Cairan): Adanya eksudat (seperti lendir) pada batang atau daun.
- Gejala Khusus: Misalnya, mosaik virus menyebabkan pola warna tidak merata pada daun.

3. Tanaman Kekurangan Nutrisi

- Klorosis: Kekurangan nitrogen, magnesium, atau zat besi sering menyebabkan klorosis, yaitu daun menguning.
- Nekrosis: Kekurangan kalium atau fosfor dapat menyebabkan jaringan daun mati (nekrosis).
- Ukuran Daun: Daun menjadi kecil dan tumbuh tidak sempurna.
- Warna Tidak Normal: Kekurangan nutrisi tertentu dapat menyebabkan daun memerah (fosfor), keunguan (magnesium), atau hijau pucat (sulfur).
- Pertumbuhan Tanaman: Kerdil atau batang yang terlalu tipis.
- Bentuk Daun Abnormal: Daun menggulung atau bentuknya tidak proporsional.
- Akar Tidak Sehat: Akar terlihat kurus, bercabang sedikit, atau mengalami pembusukan.

Metode yang disusun di dalam penelitian ini dirancang agar dapat diadopsi dan dikembangkan oleh peneliti lain dalam pengembangan teknologi deteksi otomatis berbasis citra untuk aplikasi di bidang pertanian cerdas.

3. HASIL DAN PEMBAHASAN

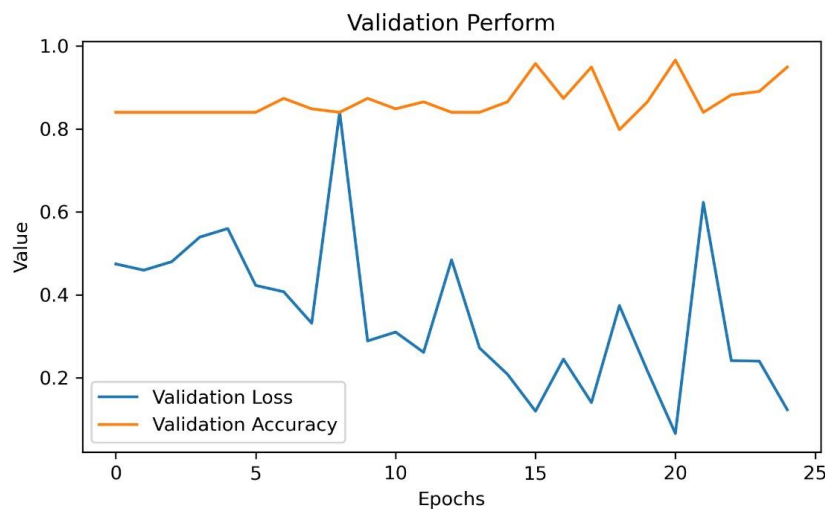
3.1 Hasil

Data hasil penelitian ini disajikan dalam bentuk tabel dan grafik untuk mempermudah interpretasi kinerja model CNN yang dikembangkan dalam mendeteksi kondisi tanaman cabai rawit. Setiap tabel dan grafik memuat informasi yang tidak berulang untuk menjaga kejelasan data dan menghindari redundansi.

Tabel 3.1. Hasil Uji Akurasi Model CNN untuk Deteksi Kondisi Tanaman Cabai Rawit

Kategori	Akurasi (%)	Precision (%)	Recall (%)
Tanaman Sehat	91.5	89.3	92.1
Tanaman Terinfeksi	88.7	87.7	89.5
Tanaman Kurang Nutrisi	85.6	83.8	87.4

Data pada Tabel 3.1 menunjukkan bahwa akurasi model CNN mencapai lebih dari 85% pada semua kategori, dengan akurasi tertinggi pada deteksi tanaman sehat. *Precision* dan *recall* juga memberikan hasil yang memadai, memperlihatkan potensi model ini dalam membantu petani mendeteksi kondisi tanaman dengan tingkat akurasi yang tinggi.



Gambar 3.1. Kurva Akurasi dan *Loss* Selama Pelatihan Model CNN

Gambar 3.1 menunjukkan perubahan akurasi dan *loss* model CNN sepanjang proses pelatihan. Model mengalami peningkatan akurasi signifikan pada 20 *epoch* pertama dan menunjukkan stabilitas pada tahap akhir, mengindikasikan bahwa model telah mencapai konvergensi.

3.2 Pembahasan

Hasil penelitian ini menegaskan bahwa model CNN berbasis TensorFlow dapat mendeteksi kondisi tanaman cabai rawit secara efektif berdasarkan citra visual. Hasil akurasi tertinggi pada kategori tanaman sehat mengindikasikan bahwa model lebih

mudah mengenali karakteristik visual dari tanaman yang tidak menunjukkan gejala penyakit atau kekurangan nutrisi.

Temuan ini sejalan dengan penelitian sebelumnya oleh Mohanty, Hughes, & Salathé (2016), yang menunjukkan bahwa penggunaan CNN untuk klasifikasi tanaman sangat efektif dalam mendeteksi penyakit berbasis visual. Namun, akurasi sedikit lebih rendah pada kategori tanaman kurang nutrisi menunjukkan kemungkinan adanya kesulitan dalam membedakan gejala kekurangan nutrisi yang mungkin serupa dengan gejala pada tanaman terinfeksi, seperti perubahan warna daun yang serupa.

Sebagai tambahan, metode augmentasi data yang diterapkan dalam penelitian ini, seperti rotasi dan zoom, memberikan kontribusi penting untuk meningkatkan kemampuan model dalam mendeteksi kondisi tanaman dengan perspektif berbeda, sesuai dengan temuan Saleem et al. (2020) yang menyarankan augmentasi data sebagai salah satu cara efektif untuk meningkatkan generalisasi model CNN.

Secara keseluruhan, penelitian ini menunjukkan bahwa teknologi deteksi otomatis berbasis CNN memiliki potensi besar untuk meningkatkan produktivitas dan efisiensi di bidang pertanian modern, khususnya pada tanaman cabai rawit. Integrasi model ini ke dalam perangkat smart farming diharapkan akan membantu petani melakukan intervensi dini dan mengurangi kerugian akibat penyakit tanaman.

4. KESIMPULAN

Penelitian ini berhasil mengimplementasikan sistem deteksi otomatis berbasis *Convolutional Neural Network* (CNN) untuk mengidentifikasi kondisi tanaman cabai rawit dengan akurasi yang tinggi. Berdasarkan data visual, model ini mampu membedakan antara tanaman sehat, terinfeksi, dan kurang nutrisi dengan tingkat akurasi yang memadai di atas 85% pada semua kategori. Keberhasilan model ini memperlihatkan potensinya untuk digunakan sebagai alat bantu dalam meningkatkan efisiensi pertanian, memungkinkan petani melakukan deteksi dini dan intervensi terhadap permasalahan tanaman. Rekomendasi untuk penelitian lebih lanjut mencakup penggunaan dataset yang lebih bervariasi dan integrasi sistem dengan perangkat *mobile* untuk mendukung aksesibilitas lapangan. Implementasi berkelanjutan dari sistem ini diharapkan dapat berkontribusi signifikan terhadap kemajuan smart farming dan pertanian berkelanjutan di Indonesia.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada para petani yang telah berpartisipasi dalam pengumpulan data serta pihak-pihak yang telah memberikan dukungan dalam penelitian ini.

DAFTAR PUSTAKA

- Chen, J., Zhang, D., & Wang, Y. (2020). A review on deep learning in crop disease recognition and detection. *Journal of Agricultural Science and Technology*, 22(4), 987–1003. <https://doi.org/10.1016/j.jast.2020.09.012>
- De Silva, R. H. R. M. S., et al. (2020). Assessing plant health to improve crop yield. *Agricultural Systems*, 182, 102935. <https://doi.org/10.1016/j.agsy.2020.102935>
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>

- Milioto, A., Lottes, P., & Stachniss, C. (2019). Real-time plant classification for precision farming using convolutional neural networks. *IEEE Robotics and Automation Letters*, 4(2), 1011–1018. <https://doi.org/10.1109/LRA.2019.2893556>
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, 1419. <https://doi.org/10.3389/fpls.2016.01419>
- Ponce, J., & Hebert, M. (2020). Deep learning for visual recognition in agriculture: From CNNs to field-level analysis. *Agricultural Systems*, 180, 102–111. <https://doi.org/10.1016/j.agsy.2020.102964>
- Rahman, M. M. M. H., et al. (2020). Diagnosis of plant disease using image processing techniques. *Computers and Electronics in Agriculture*, 176, 105711. <https://doi.org/10.1016/j.compag.2020.105711>
- Saleem, M. H., Potgieter, J., & Arif, K. M. (2020). Plant disease detection and classification by deep learning. *Plants*, 9(11), 1319. <https://doi.org/10.3390/plants9111319>
- Singh, V., & Misra, A. (2017). Detection of plant leaf diseases using image segmentation and soft computing techniques. *Information Processing in Agriculture*, 4(1), 41–49. <https://doi.org/10.1016/j.inpa.2016.10.005>
- Tsai, K. S. K. R. K. M. O., & Su, C. M. D. P. (2021). Detection of nutritional stress in plants using remote sensing. *Sensors*, 21(7), 2456. <https://doi.org/10.3390/s21072456>
- Van den Boogaard, G. J. H. B., et al. (2018). Effects of nutrient deficiencies on plant health. *Plant Physiology and Biochemistry*, 123, 215–225. <https://doi.org/10.1016/j.plaphy.2018.05.022>
- Van Huysen, D. W. P. V., & Groeneveld, R. J. K. (2019). Nutritional deficiencies and their impact on crop performance. *Field Crops Research*, 234, 123–130. <https://doi.org/10.1016/j.fcr.2019.01.002>
- Zhang, S., Wu, X., You, X., & Zhang, Y. (2019). Deep learning for image-based plant disease detection and diagnosis. *Sustainability*, 11(9), 2853. <https://doi.org/10.3390/su11092853>
- Zhu, H., Sun, H., & Zhou, J. (2021). Deep learning in agriculture: A comprehensive review of techniques, applications, and challenges. *IEEE Access*, 9, 138–158. <https://doi.org/10.1109/ACCESS.2021.3047684>