



Klasifikasi Penyakit Tanaman Cabai Menggunakan Googlenet Pada Citra Daun

Classification Of Chili Plant Diseases Using Googlenet on Leaf Images

Jaffar Siddik Harahap & Arnes Sembiring*

Teknik Informatika, Fakultas Teknik, Universitas Medan Area, Indonesia

*Corresponding Email: jafarharahap13@gmail.com

Abstrak

Cabai merah (*Capsicum annum L.*) merupakan komoditas hortikultura yang memiliki nilai ekonomi tinggi, namun produksinya sering terhambat oleh serangan penyakit tanaman. Untuk mendeteksi penyakit pada daun cabai secara otomatis, penelitian ini menggunakan pendekatan deep learning dengan arsitektur GoogLeNet dan teknik transfer learning. Penelitian ini bertujuan untuk mengklasifikasikan lima jenis penyakit daun cabai, yaitu Healthy, Leaf Curl, Leaf Spot, Whitefly, dan Yellowish, menggunakan model yang diinisialisasi dengan bobot pretrained dari ImageNet. Tiga jenis optimizer (Adam, RMSprop, dan SGD) diuji untuk mengevaluasi pengaruhnya terhadap akurasi klasifikasi. Hasil menunjukkan bahwa Adam memberikan performa terbaik dengan akurasi validasi sebesar 98.80%, diikuti oleh RMSprop (98.40%) dan SGD (94.00%). Confusion matrix menunjukkan bahwa kesalahan klasifikasi terutama terjadi pada kelas Leaf Curl, yang sering tertukar dengan Yellowish, akibat kemiripan visual. Meskipun hasil klasifikasi sangat baik, keterbatasan seperti ukuran dataset yang kecil (500 gambar) dan kebutuhan untuk teknik augmentasi lebih lanjut untuk mengatasi kesalahan prediksi tetap menjadi tantangan. Penelitian ini memberikan kontribusi pada pengembangan sistem klasifikasi penyakit tanaman berbasis visi komputer yang efisien dan akurat.

Kata Kunci: Penyakit Daun Cabai; GoogLeNet; Transfer Learning; Optimizer; Deep Learning; Klasifikasi; Computer Vision.

Abstract

*Red chili pepper (*Capsicum annum L.*) is a horticultural commodity that has high economic value, but its production is often hampered by plant disease attacks. To automatically detect diseases in chili leaves, this study uses a deep learning approach with GoogLeNet architecture and transfer learning techniques. This study aims to classify five types of chili leaf diseases, namely Healthy, Leaf Curl, Leaf Spot, Whitefly, and Yellowish, using a model initialized with pretrained weights from ImageNet. Three types of optimizers (Adam, RMSprop, and SGD) were tested to evaluate their effect on classification accuracy. The results showed that Adam performed best with a validation accuracy of 98.80%, followed by RMSprop (98.40%) and SGD (94.00%). The confusion matrix shows that misclassification occurs mainly in the Leaf Curl class, which is often confused with Yellowish, due to visual similarities. Although the classification results were excellent, limitations such as the small size of the dataset (500 images) and the need for further augmentation techniques to address prediction errors remained challenges. This research contributes to the development of an efficient and accurate computer vision-based plant disease classification system.*

Keywords: Chili Leaf Disease; GoogLeNet; Transfer Learning; Optimizer; Deep Learning; Classification; Computer Vision.

PENDAHULUAN

Indonesia dikenal sebagai negara agraris, di mana sebagian besar penduduknya menggantungkan mata pencaharian pada sektor pertanian. Keunggulan ini didukung oleh kondisi geografis dan iklim yang menguntungkan, terutama tanah yang subur serta luasnya lahan potensial yang tersebar di berbagai wilayah [1]. Sektor pertanian memiliki kontribusi penting dalam perekonomian nasional, baik dari sisi penyediaan bahan pangan maupun penyerapan tenaga kerja. Salah satu komoditas hortikultura yang memiliki nilai ekonomi tinggi dan menjadi kebutuhan sehari-hari masyarakat Indonesia adalah cabai merah (*Capsicum annum L.*) [2], [3].

Cabai merah bukan hanya digunakan sebagai bahan dasar pembuatan sambal dan saus, tetapi juga merupakan elemen penting dalam berbagai jenis masakan Nusantara. Meskipun penggunaannya relatif sedikit dalam jumlah, tingkat konsumsinya sangat tinggi karena hampir setiap rumah tangga menggunakannya setiap hari [4]. Oleh karena itu, fluktuasi produksi dan harga cabai dapat berdampak langsung terhadap stabilitas ekonomi rumah tangga dan pasar secara luas.

Namun demikian, produksi cabai merah di Indonesia masih menghadapi berbagai tantangan, salah satunya adalah gangguan penyakit tanaman. Serangan penyakit pada daun cabai dapat menurunkan kualitas dan kuantitas hasil panen secara signifikan [5]–[7]. Penyakit seperti leaf curl, leaf spot, serangan whitefly, hingga perubahan warna daun (yellowish) merupakan jenis-jenis gangguan yang umum ditemukan dan dapat menyebabkan kerugian besar bagi petani. Jika tidak ditangani secara dini dan tepat, serangan tersebut dapat menyebabkan gagal panen serta berdampak negatif pada keberlangsungan pendapatan petani [8].

Dalam menghadapi tantangan tersebut, berbagai pendekatan telah dikembangkan untuk mempermudah proses diagnosis penyakit tanaman, salah satunya melalui pemanfaatan teknologi informasi dan kecerdasan buatan. Seiring dengan perkembangan teknologi digital, sistem komputer saat ini telah mampu melakukan pemantauan kondisi tanaman secara otomatis dengan bantuan kamera dan algoritma pemrosesan citra [9]–[11]. Teknik ini dikenal sebagai computer vision, yang mengintegrasikan metode image processing dengan kecerdasan buatan untuk mengenali pola-pola visual yang tidak mudah diamati oleh mata manusia.



Salah satu pendekatan yang terbukti efektif dalam bidang ini adalah deep learning, khususnya dengan menggunakan arsitektur Convolutional Neural Network (CNN). Deep learning merupakan cabang dari pembelajaran mesin (machine learning) yang memanfaatkan jaringan saraf tiruan berlapis-lapis untuk mengekstrak fitur-fitur kompleks dari data, baik dalam bentuk teks, suara, maupun gambar [12], [13]. CNN, sebagai salah satu arsitektur deep learning paling populer untuk pengolahan citra, memiliki keunggulan dalam mengenali pola spasial dan struktural dalam gambar melalui proses konvolusi yang dilakukan oleh filter-filter pembelajaran [14].

Proses klasifikasi dalam konteks ini merujuk pada upaya membedakan gambar daun cabai berdasarkan jenis penyakit yang menyeranginya. Proses ini mencakup dua tahap utama, yaitu training dan testing. Pada tahap training, model belajar dari sekumpulan data yang telah dilabeli, sementara pada tahap testing, model diuji dengan data baru yang belum pernah dilihat sebelumnya untuk mengukur akurasi prediksinya [15].

Dalam upaya meningkatkan akurasi model klasifikasi, salah satu teknik yang banyak digunakan adalah transfer learning. Transfer learning memungkinkan penggunaan model yang telah dilatih pada dataset besar (seperti ImageNet) untuk diaplikasikan pada dataset baru yang berukuran lebih kecil atau bersifat khusus. Teknik ini menghemat waktu pelatihan dan sumber daya komputasi karena model tidak perlu dilatih dari awal. Dalam konteks CNN, lapisan awal dari model pretrained seperti GoogLeNet dapat digunakan kembali, sementara lapisan akhir disesuaikan dengan klasifikasi target yang spesifik, seperti klasifikasi penyakit daun cabai [16].

Beberapa penelitian terdahulu telah menerapkan metode deep learning dalam deteksi penyakit tanaman. Contohnya, penelitian oleh Brahimi et al. (2017) menggunakan AlexNet dan VGG16 untuk klasifikasi penyakit daun tomat dan menunjukkan hasil akurasi tinggi pada data laboratorium. Sementara itu, Mohanty et al. (2016) menggunakan transfer learning pada dataset PlantVillage untuk mengklasifikasikan berbagai penyakit tanaman dan melaporkan performa akurasi di atas 95%. Namun demikian, sebagian besar penelitian tersebut fokus pada tanaman lain dan kurang mengeksplorasi penerapan GoogLeNet dalam klasifikasi penyakit daun cabai secara spesifik. Selain itu, banyak studi sebelumnya belum membandingkan efektivitas

penggunaan berbagai optimizer dalam pelatihan model transfer learning, padahal pilihan optimizer dapat mempengaruhi kecepatan konvergensi dan kualitas generalisasi model.

Dalam konteks cabai merah, penelitian tentang klasifikasi penyakit daun masih tergolong terbatas. Beberapa studi yang ada masih menggunakan teknik konvensional berbasis gejala visual manual atau pencocokan citra sederhana tanpa memanfaatkan kekuatan representasi fitur dari jaringan saraf tiruan. Hal ini membuka ruang bagi pengembangan pendekatan yang lebih modern dan akurat.

Untuk mengisi gap tersebut, penelitian ini mengusulkan penggunaan arsitektur GoogLeNet dalam pendekatan transfer learning untuk klasifikasi penyakit daun cabai. GoogLeNet, yang dikenal dengan Inception Module-nya, memiliki keunggulan dalam memproses fitur dari berbagai skala dalam satu tahap konvolusi, yang menjadikannya efisien dan akurat dalam klasifikasi visual. Selain itu, penelitian ini juga akan mengeksplorasi pengaruh penggunaan tiga jenis optimizer yaitu Adam, RMSprop, dan SGD dalam meningkatkan performa klasifikasi. Perbandingan ini penting untuk mengidentifikasi konfigurasi pelatihan terbaik yang mampu memberikan hasil prediksi paling optimal.

Jenis penyakit yang diklasifikasikan dalam penelitian ini mencakup lima kategori utama, yaitu: Healthy, Leaf Curl, Leaf Spot, Whitefly, dan Yellowish, yang merupakan jenis penyakit daun paling umum ditemukan pada budidaya cabai merah di Indonesia. Setiap kategori memiliki ciri visual yang khas dan dapat dideteksi dengan bantuan sistem visi komputer berbasis CNN.

Dataset yang digunakan dalam penelitian ini merupakan kumpulan citra daun cabai yang telah dilabeli sesuai dengan kondisi kesehatan atau jenis penyakitnya. Dataset akan dibagi menjadi data pelatihan dan pengujian, serta dilakukan augmentasi untuk meningkatkan generalisasi model. Model GoogLeNet akan diinisialisasi dengan bobot pretrained dari ImageNet dan diadaptasi dengan lapisan klasifikasi baru sesuai jumlah kelas pada dataset. Selanjutnya, model akan dilatih menggunakan kombinasi parameter yang disesuaikan untuk masing-masing optimizer.

Dengan pendekatan ini, penelitian diharapkan dapat memberikan kontribusi nyata dalam pengembangan sistem klasifikasi penyakit tanaman berbasis visi komputer yang cepat, efisien, dan akurat, khususnya pada tanaman cabai yang memiliki nilai strategis bagi petani dan pasar Indonesia.



Penelitian ini bertujuan menguji efektivitas GoogLeNet dalam klasifikasi penyakit daun cabai menggunakan pendekatan transfer learning dan membandingkan performa tiga optimizer.

METODE PENELITIAN

Deep Learning

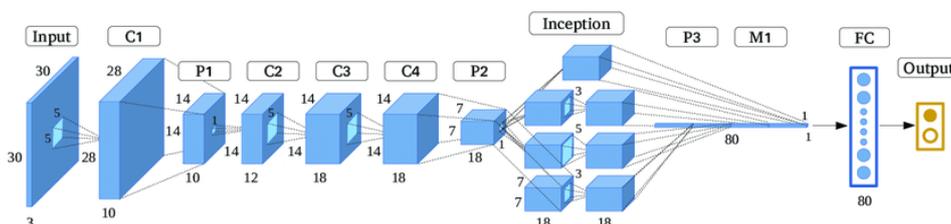
Deep learning adalah bagian dari kecerdasan buatan dan pengajaran mesin di mana jaringan saraf tiruan dan algoritmanya terinspirasi oleh otak manusia dan belajar dari sejumlah besar data. *Algoritma deep learning* menggunakan jaringan saraf tiruan berlapis-lapis untuk memberikan akurasi yang tinggi dalam deteksi objek dan pengenalan suara, dan arsitekturnya sangat fleksibel karena dapat belajar dari data mentah dan meningkatkan prediktifnya ketika lebih banyak data ditambahkan. [14].

Classification

Klasifikasi adalah proses menemukan kumpulan model dan fungsi yang menjelaskan dan membedakan data dari kelas tertentu, dengan tujuan menggunakan model dalam menentukan kelas objek yang kelasnya tidak diketahui. Ada dua proses dalam klasifikasi yaitu proses pembelajaran/pelatihan. Model ini menggunakan data pelatihan. Proses pengujian digunakan menggunakan model yang diperoleh dari proses pelatihan [15].

Klasifikasi adalah proses menempatkan objek ke dalam kelas-kelas yang berbeda untuk membuatnya lebih mudah diidentifikasi dan berusaha menggeneralisasikan struktur yang sudah diketahui untuk diterapkan pada data baru. [19].

Google Net



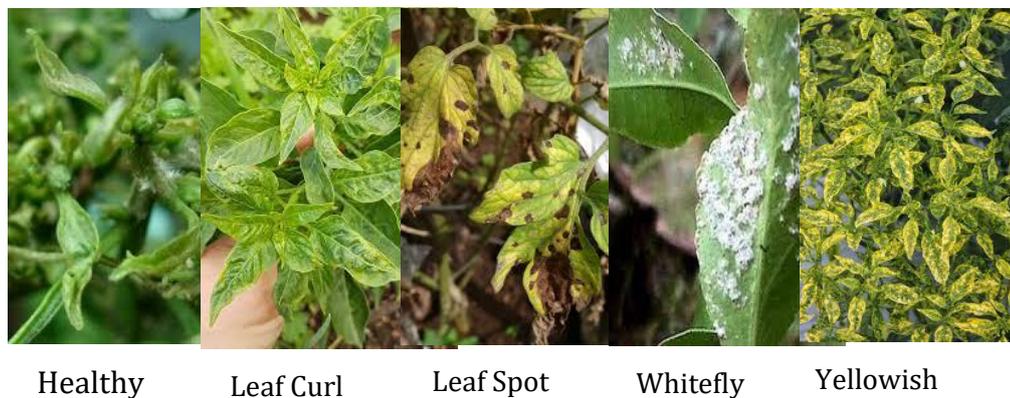
Gambar 1. Arsitektur Googlenet

Sejak 2014, *Google* telah memperkenalkan *GoogLeNet*, yang muncul di peringkat pertama dalam kompetisi *ILSVRC* dan dinobatkan sebagai arsitektur kinerja terbaik.

Seperti yang ditunjukkan pada gambar 1, modul awal *Googlenet* terdiri dari beberapa *convolution* kecil yang digunakan untuk mereduksi [20].

Dataset

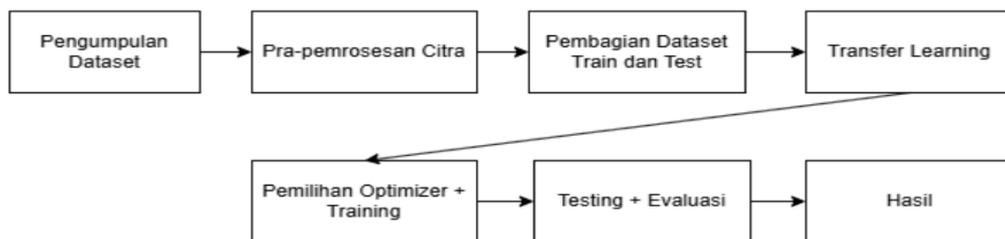
Dalam penelitian ini, dataset sebanyak 500 gambar dalam format jpg digunakan dari platform *Kaggle*. Dataset ini dibagi menjadi lima kelas gambar yaitu *healthy*, *leaf curl*, *leaf spot*, *whitefly*, dan *yellowish*. Data latih adalah sekumpulan data gambar yang digunakan untuk melatih pola gambar sehingga sistem dapat mempelajarinya. Data gambar digunakan untuk menguji kinerja model yang digunakan. Dapat dilihat pada Tabel 2.



Gambar 2. Contoh citra pada dataset

Alur Penelitian

Dalam klasifikasi jenis penyakit pada tanaman cabai ada beberapa tahapan dalam bentuk diagram alur guna mempermudah dalam penyusunan penelitian ini. dapat dilihat pada gambar 3 sebagai berikut:



Gambar 3. Alur Penelitian

Sebelum melakukan proses klasifikasi dengan menggunakan arsitektur *Googlenet*, gambar tersebut akan masuk ke tahap pra-pemrosesan terlebih dahulu. Melakukan *preprocessing* pada citra, seperti *resize*, *augmentasi*, dan normalisasi. Setelah itu dataset dibagi menjadi dua bagian yaitu train dan test. Selanjutnya melakukan *transfer learning* untuk memanfaatkan fitur yang sudah dipelajari dari dataset besar. Dataset dilatih

menggunakan tiga *optimizer*. Adapun ketiga *optimizer* tersebut adalah *Adam*, *SGD*, dan *RMSprop*. Setelah model selesai dilatih, dilakukan evaluasi menggunakan *accuracy*, *precision*, *recall*, *F1-score*, serta visualisasi *confusion matrix*. Selanjutnya menampilkan hasil akhir dari klasifikasi yang telah dilakukan, seperti akurasi model, *loss function*, dan visualisasi prediksi.

Parameter Performansi

Salah satu tolak ukur untuk mengukur kualitas sistem adalah parameter performansi. Parameter-parameter berikut diukur dalam penelitian ini adalah *loss*, *accuracy*, *precision*, *recall*, dan *F1-Score* (persamaan 1 – 4).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots 1$$

$$Presisi = \frac{TP}{TP+FP} \dots\dots\dots 2$$

$$Recall = \frac{TP}{FN+TP} \dots\dots\dots 3$$

$$F1-Score = 2 \times \frac{Presisi * Recall}{Presisi + Recall} \dots\dots\dots 4.$$

HASIL DAN PEMBAHASAN

Optimizer

Pengujian ini bertujuan untuk mengevaluasi pengaruh tiga jenis optimizer yaitu Adam, Stochastic Gradient Descent (SGD), dan RMSprop terhadap performa klasifikasi penyakit daun cabai menggunakan arsitektur GoogLeNet. Untuk menjaga validitas perbandingan, seluruh pengujian dilakukan dengan parameter yang konsisten: learning rate ditetapkan sebesar 0.001, batch size sebanyak 32, dan ukuran input citra adalah 224 × 224 piksel. Dengan parameter yang seragam ini, perbedaan performa yang diamati dapat lebih dikaitkan secara langsung dengan efektivitas masing-masing optimizer.

Tabel 1. Hasil Pengujian Optimizer



<i>Optimizer</i>	<i>Train Accuracy (%)</i>	<i>Train Loss</i>	<i>Val Accuracy (%)</i>	<i>Val Loss</i>
<i>Adam</i>	98.40	0.0329	98.80	0.0295
<i>SGD</i>	90.80	0.3128	94.00	0.2416
<i>RMSprop</i>	98.20	0.0360	98.40	0.0324

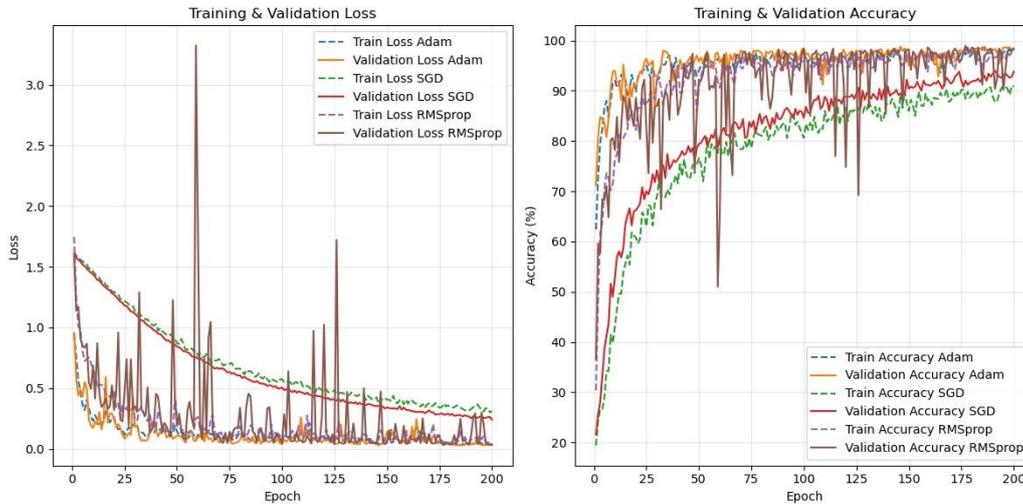
Dari hasil pada Tabel 1, dapat diamati bahwa optimizer Adam menghasilkan performa terbaik, baik pada data pelatihan (train accuracy sebesar 98.40% dan train loss sebesar 0.0329) maupun data validasi (val accuracy sebesar 98.80% dan val loss sebesar 0.0295). Adam menunjukkan keunggulan yang konsisten dalam hal akurasi dan stabilitas pelatihan, yang menjadikannya pilihan optimal untuk arsitektur GoogLeNet pada dataset klasifikasi penyakit daun cabai ini.

Keunggulan Adam dapat dijelaskan melalui mekanisme dasarnya yang menggabungkan kelebihan dari dua optimizer lain, yaitu Momentum (seperti pada SGD dengan momentum) dan Adagrad. Adam secara adaptif menyesuaikan learning rate untuk setiap parameter berdasarkan estimasi momen pertama (rata-rata gradien) dan momen kedua (rata-rata kuadrat gradien). Pendekatan ini sangat sesuai dengan karakteristik arsitektur GoogLeNet yang kompleks, di mana banyak lapisan convolusi dan non-linearitas memerlukan stabilisasi dalam proses pelatihan. Selain itu, penggunaan learning rate sebesar 0.001 pada Adam merupakan nilai yang ideal karena tidak terlalu besar sehingga tidak menyebabkan divergensi, namun cukup kecil untuk memungkinkan konvergensi bertahap yang stabil.

Sebaliknya, optimizer SGD menghasilkan akurasi pelatihan yang jauh lebih rendah (90.80%) dan akurasi validasi 94.00%, dengan nilai loss yang juga relatif tinggi. Kinerja ini mengindikasikan bahwa SGD memerlukan lebih banyak waktu dan epoch untuk mencapai konvergensi optimal. SGD tidak memiliki mekanisme adaptif seperti Adam, sehingga seluruh parameter diperbarui dengan kecepatan yang sama. Hal ini menyulitkan pada jaringan dalam seperti GoogLeNet yang memerlukan penyesuaian parameter yang kompleks.

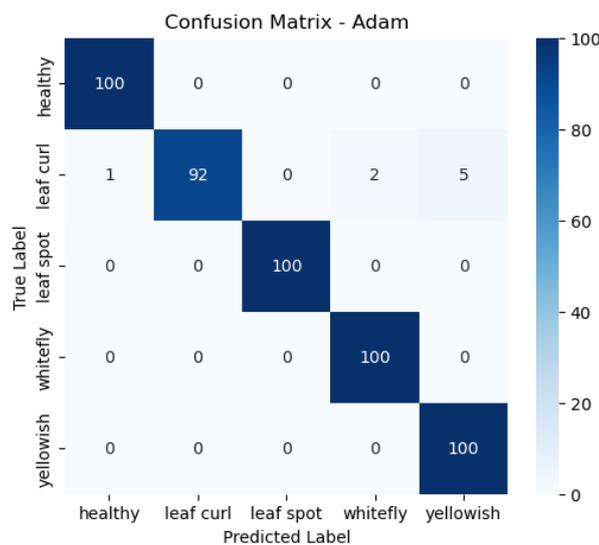
Sementara itu, RMSprop mencatat hasil yang cukup kompetitif dengan Adam. RMSprop memiliki kemampuan untuk menyesuaikan learning rate secara dinamis berdasarkan rata-rata kuadrat gradien sebelumnya. Meskipun RMSprop bekerja cukup baik dalam mengurangi nilai loss, ia masih sedikit tertinggal dari Adam dalam hal stabilitas dan akurasi, yang terlihat dari nilai val accuracy sebesar 98.40% dan val loss

sebesar 0.0324. RMSprop cenderung lebih sensitif terhadap batch size dan learning rate, sehingga bisa saja performanya meningkat dengan konfigurasi yang berbeda.



Gambar 4. Grafik Perbandingan tiga optimizer

Gambar 4 menampilkan visualisasi perbandingan tiga optimizer dari segi akurasi dan *loss* selama proses pelatihan dan validasi. Terlihat bahwa Adam menghasilkan kurva konvergensi yang paling cepat dan stabil, dengan fluktuasi *loss* yang sangat minim setelah beberapa *epoch* pertama. SGD menunjukkan kurva yang lebih datar dan fluktuatif, menandakan proses pelatihan yang lebih lambat. RMSprop berada di antara keduanya, mendekati performa Adam namun dengan variasi fluktuasi yang sedikit lebih besar.



Gambar 5. Confusion Matrix best Optimizer

Gambar 5 memperlihatkan confusion matrix dari hasil klasifikasi menggunakan Adam sebagai optimizer terbaik. Secara umum, model menunjukkan performa klasifikasi

yang sangat baik pada semua kelas penyakit daun cabai. Namun, terdapat beberapa kesalahan klasifikasi yang perlu menjadi perhatian, terutama pada kelas Leaf Curl, di mana terdapat enam kesalahan prediksi.

Analisis terhadap confusion matrix menunjukkan bahwa sebagian besar kesalahan prediksi pada kelas Leaf Curl terjadi karena tertukar dengan kelas Yellowish. Hal ini kemungkinan besar disebabkan oleh kemiripan visual antara gejala leaf curl dan perubahan warna daun akibat yellowish, yang keduanya sering muncul dalam bentuk perubahan warna pada permukaan daun. Daun yang melengkung (leaf curl) dapat menunjukkan bagian ujung daun yang menguning atau terlihat memudar, sehingga menyulitkan model dalam membedakan dua kelas ini tanpa fitur kontekstual tambahan seperti struktur tulang daun atau distribusi warna yang lebih detail.

Kesalahan klasifikasi ini menunjukkan bahwa meskipun model memiliki akurasi tinggi secara keseluruhan, masih terdapat overlap semantik dan visual antar kelas yang menyulitkan proses klasifikasi. Kemungkinan solusi untuk meningkatkan akurasi adalah dengan menambahkan teknik augmentasi khusus untuk meningkatkan keragaman data visual dalam kelas Leaf Curl dan Yellowish, atau mempertimbangkan integrasi teknik segmentasi daun sebagai tahap praproses untuk memperjelas pola penyakit.

Meskipun hasil penelitian ini menunjukkan performa tinggi dalam klasifikasi penyakit daun cabai, terdapat beberapa keterbatasan yang perlu disampaikan. Pertama, ukuran dataset yang digunakan relatif kecil, yaitu hanya mencakup sekitar 500 gambar yang tersebar dalam lima kelas. Dataset yang kecil cenderung membatasi kemampuan generalisasi model, terutama jika variasi citra dalam setiap kelas tidak cukup mewakili kondisi nyata di lapangan.

Kedua, seluruh citra dalam dataset diambil dalam kondisi pencahayaan dan latar belakang yang relatif seragam. Hal ini menyulitkan model untuk diimplementasikan dalam kondisi lingkungan nyata, di mana gambar daun dapat memiliki latar belakang kompleks, pencahayaan tidak stabil, dan posisi objek yang bervariasi.

Ketiga, penelitian ini hanya fokus pada satu jenis tanaman, yaitu cabai merah (*Capsicum annum* L.), dan lima jenis gejala penyakit. Padahal, dalam praktik pertanian, petani sering menghadapi berbagai jenis penyakit yang menyerang tanaman lain, seperti tomat, terong, atau sayuran daun lainnya. Oleh karena itu, perluasan cakupan penelitian



ke jenis tanaman dan gejala penyakit lain menjadi langkah penting untuk validasi lebih lanjut.

Terakhir, meskipun GoogLeNet dan optimizer Adam memberikan hasil yang sangat baik dalam skenario ini, eksperimen lebih lanjut perlu dilakukan dengan variasi model CNN lainnya, seperti EfficientNet atau DenseNet, serta eksplorasi penggunaan teknik ensemble learning yang menggabungkan output dari beberapa model untuk meningkatkan akurasi dan stabilitas.

SIMPULAN

Penelitian ini berhasil menunjukkan bahwa penggunaan GoogLeNet dengan pendekatan transfer learning dan optimisasi menggunakan Adam sebagai optimizer memberikan performa klasifikasi terbaik dalam deteksi penyakit daun cabai. Dari hasil pengujian, Adam menunjukkan akurasi pelatihan dan validasi yang sangat tinggi, yakni 98.40% dan 98.80%, dengan nilai loss yang sangat rendah. Keunggulan Adam terletak pada kemampuannya untuk menyesuaikan learning rate secara dinamis, yang membuatnya sangat cocok untuk jaringan saraf dalam seperti GoogLeNet yang memiliki banyak lapisan konvolusi dan kompleksitas. Sementara itu, meskipun RMSprop memberikan hasil yang kompetitif, SGD menunjukkan hasil yang jauh lebih rendah, terutama pada data validasi, yang mengindikasikan bahwa optimizer ini kurang efektif pada model yang kompleks dan membutuhkan waktu konvergensi lebih lama.

Namun, meskipun hasil penelitian menunjukkan akurasi yang tinggi, terdapat beberapa keterbatasan yang perlu diperhatikan. Salah satunya adalah ukuran dataset yang relatif kecil, hanya mencakup sekitar 500 gambar, yang membatasi kemampuan model untuk menggeneralisasi dengan baik pada kondisi dunia nyata. Selain itu, kesalahan klasifikasi pada kelas Leaf Curl dan Yellowish mengindikasikan adanya kemiripan visual antara dua penyakit tersebut yang perlu ditangani dengan augmentasi data lebih lanjut atau penggunaan teknik segmentasi citra. Penelitian ini membuka jalan untuk perluasan penelitian ke jenis tanaman lain dan meningkatkan cakupan dataset, serta eksperimen lanjutan dengan model CNN lainnya seperti EfficientNet dan DenseNet untuk mengatasi masalah yang ada dan meningkatkan akurasi klasifikasi secara keseluruhan.



DAFTAR PUSTAKA

- [1] N. E. Mustamu, B. A. Dalimunthe, S. Hartati, and Y. Saragih, "Aplikasi Pemberian Abu Sekam Padi dan Pupuk Organik Cair (POC) Terhadap Produksi Tanaman Cabai Merah (Capsicum annum L.)," *J. Mhs. Agroteknologi*, vol. 4, pp. 56–63, 2023.
- [2] V. F. Alviana and A. D. Susila, "Optimasi dosis pemupukan pada budidaya cabai (Capsicum annum L.) menggunakan irigasi tetes dan mulsa polyethylene," *J. Agron. Indones. (Indonesian J. Agron.)*, vol. 37, no. 1, pp. 28–33, 2009.
- [3] , H., , G., A. I. Amri, and A. Diansyah, "Respons Pertumbuhan dan Produksi Tanaman Cabai Keriting (Capsicum annum L.) terhadap Aplikasi Pupuk Kompos dan Pupuk Anorganik di Polibag," *Jurnal Hortikultura Indonesia*, vol. 8, no. 3. pp. 203–208, 2017. doi: 10.29244/jhi.8.3.203-208.
- [4] F. Zikra, K. Usman, and R. Patmasari, "Deteksi Penyakit Cabai Berdasarkan Citra Daun Menggunakan Metode Gray Level Co-Occurence Matrix Dan Support Vector Machine," *Semin. Nas. Has. Penelit. dan Pengabd. Masy.*, pp. 105–113, 2021.
- [5] A. I. Amri and A. Diansyah, "Respons Pertumbuhan dan Produksi Tanaman Cabai Keriting (Capsicum annum L.) terhadap Aplikasi Pupuk Kompos dan Pupuk Anorganik di Polibag," *J. Hortik. Indones.*, vol. 8, no. 3, pp. 203–208, 2017, doi: 10.29244/jhi.8.3.203-208.
- [6] B. C. Subambhi, S. Mardiana, & Faoeza, and H. Saragih, "Jurnal Ilmiah Pertanian (JIPERTA) Analisis Location Quotient (LQ) Tanaman Cabai Besar (Capsicum annum L.) di Provinsi Sumatera Utara Location Quotient (LQ) Analysis of Large Chili Plant (Capsicum annum L.) in North Sumatera," *J. Ilm. Pertan.*, vol. 2, no. 2, pp. 169–179, 2019, [Online]. Available: <http://jurnalmahasiswa.uma.ac.id/index.php/jiperta>
- [7] Saparso and Haryanto, "Pertumbuhan dan hasil cabai merah pada berbagai metode irigasi dan pemberian pupuk kandang di wilayah pesisir pantai," *Pros. Semin. Nas. Fak. Pertan. UNS*, vol. 2, no. 1, pp. 247–257, 2018, [Online]. Available: <http://jurnal.fp.uns.ac.id/index.php/semnas/article/view/1135/807>
- [8] R. S. Pirngadi, J. P. Utami, A. F. Siregar, Salsabila, A. Habib, and J. R. Manik, "Analisis Faktor Yang Mempengaruhi Pendapatan Usahatani Cabai Merah Di Kecamatan Beringin," *J. Pertan. Agros*, vol. 25, no. 1, pp. 486–492, 2023.
- [9] J. -, M. Husna, and A. R. Lubis, "OpenCV Using on a Single Board Computer for Incorrect Facemask-Wearing Detection and Capturing," *J. Informatics Telecommun. Eng.*, vol. 5, no. 2, pp. 315–323, 2022, doi: 10.31289/jite.v5i2.6118.
- [10] N. Mamuriyah and J. Sumantri, "Penerapan Metode Convolution Neural Network (CNN) Pada Aplikasi Automatic Lip Reading," *J. Informatics Telecommun. Eng.*, vol. 6, no. 1, pp. 276–287, 2022, doi: 10.31289/jite.v6i1.7523.
- [11] A. Bin Rashid and M. A. K. Kausik, "AI revolutionizing industries worldwide: A comprehensive overview of its diverse applications," *Hybrid Adv.*, vol. 7, no. undefined, p. 100277, 2024, doi: 10.1016/j.hybadv.2024.100277.
- [12] S. H. Abdullah, R. Magdalena, and R. Y. N. Fu'adah, "Klasifikasi Diabetic Retinopathy Berbasis Pengolahan Citra Fundus Dan Deep Learning," *J. Electr. Syst. Control Eng.*, vol. 5, no. 2, pp. 84–90, 2022, doi: 10.31289/jesce.v5i2.5659.
- [13] W. R. PERDANI, R. MAGDALENA, and N. K. CAECAR PRATIWI, *Deep Learning untuk Klasifikasi Glaukoma dengan menggunakan Arsitektur EfficientNet*, vol. 10, no. 2. ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika, 2022. doi: 10.26760/elkomika.v10i2.322.
- [14] R. Rosalina and A. Wijaya, "Pendeteksian Penyakit pada Daun Cabai dengan Menggunakan Metode Deep Learning," *J. Tek. Inform. dan Sist. Inf.*, vol. 6, no. 3, pp. 452–461, 2020, doi: 10.28932/jutisi.v6i3.2857.
- [15] Q. N. Azizah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network AlexNet," *sudo J. Tek. Inform.*, vol. 2, no. 1, pp. 28–33, 2023, doi: 10.56211/sudo.v2i1.227.
- [16] M. Kevin Santosa, M. Hanindia Prami Swari, and A. Nugroho Sihananto, "Implementasi Arsitektur Alexnet Dan Resnet34 Pada Klasifikasi Citra Penyakit Daun Kentang Menggunakan Transfer Learning," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 5, pp. 3293–3301, 2024, doi: 10.36040/jati.v7i5.7337.
- [17] M. Brahim, K. Boukhalfa, and A. Moussaoui, "Deep learning for tomato diseases: classification and symptoms visualization," *Appl. Artif. Intell.*, vol. 31, no. 4, pp. 299–315, 2017.
- [18] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using deep learning for image-based plant disease detection," *Front. Plant Sci.*, vol. 7, p. 215232, 2016.



- [19] G. Taufik, S. Suharjanti, U. Khultsum, and I. Ispandi, "Perangkingan Siswa Terbaik Untuk Penerimaan Beasiswa Menggunakan Model Fuzzy Tahani," *J. Infortech*, vol. 5, no. 2, pp. 97–105, 2023.
- [20] A. Faizin, M. Lutfi, and others, "Perbandingan arsitektur lenet dan googlenet dalam klasifikasi diabetic retinopathy pada citra retina fundus," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 6, no. 1, pp. 342–347, 2022.

