

PENERAPAN DEEP LEARNING UNTUK DETEKSI DINI PENYAKIT TANAMAN CENGKEH BERBASIS CITRA DIGITAL PADA WILAYAH PERKEBUNAN TRADISIONAL DI MALUKU

Janeman Sumah, Jimmy Purwata Mangasi Sirait, Roberth Ricky Y. Manaha, Ulan Ningsih Etwior

Fak. Ilmu Komputer, Teknik Informatika, Universitas Kristen Indonesia Maluku

Jl. OT Pattimaipauw, Tanah Lapang Kecil Ambon - 97115, Maluku, Indonesia

yanno28@gmail.com

ABSTRAK

Penelitian ini bertujuan menerapkan metode deep learning untuk deteksi dini penyakit tanaman cengkeh di perkebunan tradisional Maluku. Permasalahan yang diangkat adalah rendahnya efektivitas deteksi penyakit pada tanaman cengkeh, yang dapat mengancam produktivitas. Dengan menggunakan dataset citra daun cengkeh, model dilatih untuk mengklasifikasikan kondisi tanaman sehat dan yang terkena penyakit. Metode yang digunakan menunjukkan penurunan konsisten pada training loss dan validation loss, menandakan proses pembelajaran yang efektif. Hasil penelitian menunjukkan akurasi validasi di atas 95%, dengan kurva stabil tanpa fluktuasi tajam. Evaluasi menggunakan confusion matrix menunjukkan kinerja seimbang dalam membedakan kedua kelas, dengan recall Class 0 mencapai 0,95 dan precision Class 1 juga di angka 0,95. Kedua kelas memperoleh nilai F1-score setara (0,93) dan akurasi keseluruhan 0,93. Kesimpulan menunjukkan bahwa model deep learning ini efektif dalam mendeteksi kondisi sehat dan penyakit pada tanaman cengkeh, serta dapat mendukung sistem deteksi dini di sektor pertanian. Untuk peningkatan performa, disarankan penyesuaian jumlah epoch dan penerapan strategi data augmentasi.

Kata kunci : Deep learning, Penyakit tanaman cengkeh, Citra digital

1. PENDAHULUAN

Tanaman cengkeh (*Syzygium Aromaticum*) merupakan salah satu komoditas perkebunan yang memiliki nilai ekonomi tinggi dan peran penting dalam sejarah agrikultur Indonesia [1]. Wilayah Maluku, secara historis dikenal sebagai "Kepulauan Rempah", memiliki potensi besar dalam pengembangan tanaman cengkeh secara tradisional maupun modern. Namun demikian, tantangan utama yang dihadapi oleh petani cengkeh adalah serangan penyakit yang dapat menurunkan kualitas dan kuantitas produksi secara signifikan [2].

Penyakit yang sering menyerang tanaman cengkeh antara lain penyakit bercak daun (*leaf spot*), karat daun (*leaf rust*), dan serangan jamur patogen seperti *Phytophthora sp.* dan *Cylindrocladium sp.* yang menginfeksi bagian daun dan batang [3]. Identifikasi penyakit secara dini merupakan langkah krusial dalam upaya pencegahan, namun di daerah perkebunan tradisional seperti Maluku, deteksi penyakit masih dilakukan secara manual dan sangat bergantung pada pengalaman petani [4].

Keterbatasan sumber daya manusia, minimnya pelatihan teknis, serta tantangan geografis menjadikan proses pemantauan penyakit di lapangan menjadi tidak efisien. Oleh karena itu, dibutuhkan solusi berbasis teknologi yang dapat membantu petani mengenali gejala penyakit secara otomatis, cepat, dan akurat [5].

Dalam penelitian ini, tujuan yang ingin dicapai adalah mengembangkan sistem deteksi penyakit tanaman cengkeh berbasis teknologi Deep Learning, khususnya menggunakan Convolutional Neural Network (CNN). Metode ini telah terbukti sangat

efektif dalam mengidentifikasi pola visual kompleks, termasuk gejala penyakit pada tanaman dari citra daun [6].

Rencana penyelesaian masalah mencakup pelatihan model CNN menggunakan dataset citra daun dari lapangan, sehingga dapat menghasilkan model AI dengan akurasi tinggi untuk klasifikasi penyakit daun cengkeh. Hasil dari penelitian ini diharapkan tidak hanya berupa model yang efektif tetapi juga publikasi ilmiah sebagai kontribusi akademik. Dengan demikian, penelitian ini tidak hanya memiliki nilai akademik, tetapi juga nilai praktis dalam memberdayakan petani lokal dan meningkatkan ketahanan sektor pertanian di wilayah Maluku.

Lebih lanjut, penelitian ini juga sejalan dengan visi transformasi digital sektor pertanian yang dicanangkan oleh pemerintah, khususnya dalam mendukung program *smart village* dan *smart farming* di daerah-daerah terpencil [7].

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Berbagai studi sebelumnya telah mengimplementasikan metode Deep Learning, khususnya Convolutional Neural Network, untuk mengidentifikasi penyakit pada daun tanaman dengan tingkat akurasi yang tinggi [8]. Misalnya, penelitian tentang deteksi penyakit pada daun kentang menggunakan CNN telah berhasil mencegah keterlambatan dan penurunan hasil produksi [9]. Paliwang et al. juga menunjukkan efektivitas CNN dalam klasifikasi penyakit tanaman apel dari citra daun, mencapai akurasi 97,1% [10][11]. Demikian

pula, sistem identifikasi otomatis berbasis CNN telah dikembangkan untuk diagnosis dini penyakit tanaman padi, yang sangat penting untuk mencegah kerugian dan meningkatkan kualitas produk pertanian [12]. Pendekatan serupa juga telah diterapkan pada identifikasi penyakit daun tomat dengan model DenseNet121 berbasis transfer learning, meskipun dengan cakupan kelas penyakit yang lebih terbatas [13]. Studi lain turut mengeksplorasi penggunaan CNN dalam mengidentifikasi penyakit pada daun tembakau, di mana model mampu mendeteksi berbagai kondisi seperti busuk daun dan mosaik tembakau dengan memanfaatkan kapabilitas ekstraksi fitur otomatisnya [14].

Penelitian oleh Ferentinos menunjukkan bahwa CNN mampu mencapai akurasi lebih dari 99% dalam klasifikasi berbagai jenis penyakit tanaman berbasis citra daun. Pendekatan ini tidak hanya meningkatkan efisiensi dalam deteksi penyakit, tetapi juga memungkinkan integrasi dengan sistem berbasis aplikasi untuk mendukung petani di lapangan [15].

2.2. Penyakit Tanaman Cengkeh

Identifikasi dini penyakit tanaman krusial untuk menjaga produktivitas perkebunan, terutama pada tanaman cengkeh yang memiliki nilai ekonomis tinggi di wilayah Maluku [16]. Deteksi penyakit melalui citra digital, yang memanfaatkan kecerdasan buatan, menjadi solusi potensial untuk mengidentifikasi dan mengklasifikasikan penyakit tanaman secara akurat berdasarkan fitur visualnya [17].

Dengan demikian, implementasi sistem deteksi dini berbasis citra digital ini dapat membantu petani dalam mengambil tindakan preventif yang tepat waktu, mengurangi kerugian ekonomi, dan meningkatkan kualitas serta kuantitas panen cengkeh [18]. Pemanfaatan teknologi ini juga dapat mengatasi kendala geografis dan aksesibilitas pakar di wilayah perkebunan tradisional seperti Maluku, di mana identifikasi manual seringkali terkendala oleh kurangnya tenaga ahli dan waktu respons yang lambat [19]. Fokus akan diberikan pada pengembangan algoritma deep learning yang robust dan efisien untuk klasifikasi penyakit, dengan penekanan pada data citra yang representatif dari varietas cengkeh lokal dan kondisi lingkungan spesifik Maluku. Selain itu, studi ini akan mengeksplorasi metode akuisisi citra yang optimal di lapangan, termasuk pertimbangan pencahayaan dan resolusi kamera, untuk memastikan kualitas data input yang memadai bagi model pembelajaran mendalam. Penelitian ini bertujuan untuk mengatasi tantangan tersebut dengan merumuskan strategi peningkatan kapasitas petani melalui inovasi teknologi berbasis deep learning, khususnya untuk deteksi dini penyakit tanaman cengkeh, guna mengakselerasi pembangunan pertanian di wilayah perkebunan tradisional Maluku[20]. Studi ini akan mengeksplorasi kelayakan dan efektivitas implementasi sistem berbasis citra digital untuk deteksi penyakit cengkeh, dengan

mempertimbangkan karakteristik unik perkebunan tradisional di Maluku [21].

2.3. Deep Learning

Deep learning, khususnya melalui implementasi jaringan saraf tiruan yang mendalam, telah merevolusi bidang visi komputer dan memberikan kemajuan signifikan dalam deteksi penyakit tanaman otomatis [22][23]. Model-model ini, terutama Convolutional Neural Networks, mampu mengekstraksi fitur kompleks dari citra digital, memungkinkan identifikasi penyakit secara akurat dan efisien, bahkan dalam kondisi latar belakang yang rumit[24]. Kinerja optimal model deep learning ini sangat bergantung pada ketersediaan dataset citra yang besar dan anotasi yang akurat, mencerminkan keragaman manifestasi penyakit di lapangan [25]. Oleh karena itu, pengumpulan dan kurasi dataset yang representatif menjadi langkah krusial dalam pengembangan sistem deteksi penyakit tanaman berbasis deep learning yang andal dan dapat digeneralisasi [26]. Pengembangan algoritma yang kuat untuk pra-pemrosesan citra, segmentasi area daun yang sakit, dan ekstraksi fitur berbasis matriks ko-kejadian tingkat abu-abu juga vital untuk meningkatkan akurasi identifikasi [27].

2.4. Convolutional Neural Network (CNN)

Convolutional Neural Networks merupakan arsitektur deep learning yang secara inheren dirancang untuk memproses data bergambar, mampu secara otomatis mempelajari representasi hierarkis fitur dari citra, mulai dari tepi dan sudut hingga pola yang lebih kompleks [28]. Kemampuan ini memungkinkan CNN untuk mengidentifikasi dan mengklasifikasikan objek dalam citra dengan tingkat akurasi yang tinggi, menjadikannya pilihan utama dalam aplikasi visi komputer seperti deteksi penyakit tanaman [29]. Model ini menunjukkan kapabilitas yang luar biasa dalam memproses citra dua dimensi, termasuk identifikasi objek dan pengenalan pola visual yang kompleks [30]. Arsitektur CNN secara fundamental terdiri dari lapisan konvolusional, lapisan pooling (seringkali max-pooling), dan lapisan klasifikasi, yang secara kolektif mentransformasikan volume masukan tiga dimensi menjadi volume keluaran aktivasi sel saraf [31].

Dalam konteks deteksi penyakit tanaman cengkeh, arsitektur CNN menawarkan keuntungan signifikan karena mampu secara adaptif mempelajari fitur-fitur visual spesifik penyakit, seperti perubahan warna daun, lesi, atau deformasi bentuk, langsung dari citra mentah tanpa perlu segmentasi manual yang rumit [32][33]. Keunggulan ini sangat relevan untuk aplikasi pertanian cerdas, di mana CNN terbukti efektif dalam ekstraksi fitur dan analisis data visual untuk pengambilan keputusan yang lebih baik [34].

2.5. Transfer Learning

Transfer learning merupakan teknik yang memungkinkan pemanfaatan model deep learning

yang telah dilatih pada dataset yang sangat besar untuk tugas-tugas baru dengan dataset yang lebih kecil, secara signifikan mengurangi kebutuhan akan data berlabel dan waktu pelatihan. Metode ini sangat bermanfaat dalam domain visi komputer, khususnya untuk klasifikasi citra, di mana model yang telah dilatih pada tugas-tugas generik seperti pengenalan objek dapat diadaptasi untuk tugas-tugas spesifik seperti deteksi penyakit tanaman [35][36].

Pemanfaatan transfer learning ini memungkinkan pengembangan model deteksi penyakit yang akurat meskipun dengan ketersediaan data citra penyakit cengkeh yang relatif terbatas, mengatasi salah satu tantangan utama dalam implementasi deep learning pada bidang pertanian.

2.6. Citra Digital

Pemanfaatan citra digital dalam diagnosis penyakit tanaman secara signifikan mengurangi kebutuhan akan identifikasi manual yang memakan waktu dan rentan terhadap kesalahan manusia, terutama dalam skala perkebunan tradisional [37]. Sistem berbasis citra digital memungkinkan identifikasi dini dan akurat terhadap gejala penyakit pada tanaman cengkeh, memberikan solusi yang efisien dan skalabel untuk pemantauan kesehatan tanaman di area geografis yang luas [38]. Pendekatan ini sangat relevan untuk pertanian di Maluku, yang dikenal dengan perkebunan cengkeh tradisionalnya, karena memungkinkan deteksi penyakit yang cepat dan akurat, mendukung intervensi dini untuk meminimalkan kerugian hasil panen [39].

Dalam konteks deteksi penyakit tanaman, resolusi yang optimal memastikan identifikasi gejala mikroskopis yang tidak terlihat secara kasat mata, seperti perubahan warna atau tekstur daun, yang krusial untuk diagnosis dini. Oleh karena itu, pengolahan citra digital merupakan tahapan fundamental yang memungkinkan sistem berbasis AI untuk menganalisis dan menginterpretasi informasi visual secara efektif, mengubah data mentah menjadi wawasan yang dapat ditindaklanjuti untuk pengelolaan penyakit tanaman [40]. Pemanfaatan teknologi ini memungkinkan identifikasi dini penyakit melalui pemrosesan gambar dan pengenalan pola, secara signifikan mengurangi ketergantungan pada identifikasi manual [17].

2.7. Pengolahan Citra

Pengolahan citra merupakan serangkaian teknik yang diterapkan untuk memanipulasi dan menganalisis citra digital guna mengekstraksi informasi yang relevan atau untuk meningkatkan kualitas visualnya [41]. Ini melibatkan berbagai operasi, mulai dari preprocessing untuk memperbaiki kualitas citra hingga segmentasi untuk memisahkan objek dari latar belakang, serta ekstraksi fitur untuk mengidentifikasi karakteristik penting [42] [43].

Selanjutnya, metode ini dapat dikombinasikan dengan teknik pembelajaran mendalam untuk secara

otomatis mengidentifikasi dan mengklasifikasikan pola-pola penyakit yang kompleks pada skala besar. Teknik ekstraksi fitur merupakan tahapan esensial dalam pemrosesan citra yang bertujuan untuk mendapatkan representasi data yang lebih ringkas dan informatif, di mana beberapa penelitian telah mengeksplorasi penggunaan metode deteksi objek berbasis *deep learning* untuk meningkatkan kualitas ekstraksi citra [44].

3. METODE PENELITIAN

Untuk menjawab permasalahan rendahnya deteksi dini terhadap penyakit daun tanaman cengkeh di wilayah perkebunan tradisional Maluku, penelitian ini menerapkan pendekatan berbasis Deep Learning, khususnya menggunakan algoritma Convolutional Neural Network (CNN). CNN terbukti efektif dalam melakukan klasifikasi dan segmentasi citra, termasuk pada bidang pertanian dan deteksi penyakit tanaman [35][16]. Pendekatan yang digunakan: 1. Pendekatan Kuantitatif-eksperimental melalui proses pelatihan dan pengujian model deep learning menggunakan dataset citra daun tanaman cengkeh. Eksperimen dilakukan untuk mengukur akurasi model dalam mengenali berbagai jenis penyakit berdasarkan fitur visual dari gambar daun. 2. Pendekatan Teknologi Artificial Intelligence (AI) digunakan untuk membangun sistem klasifikasi otomatis yang mampu menganalisis citra digital secara efisien. CNN dipilih karena kemampuannya dalam mengenali pola-pola kompleks dalam data visual [17].

Penelitian ini berfokus pada pengembangan model yang spesifik terhadap data lokal, agar lebih adaptif dengan karakteristik lingkungan dan jenis penyakit di wilayah Maluku.

Langkah pertama dimulai dari proses pengumpulan dataset citra daun secara langsung dari perkebunan tradisional di wilayah Maluku. Citra daun dikumpulkan dalam kondisi sehat maupun yang menunjukkan gejala penyakit, kemudian divalidasi dan dilabeli dengan bantuan ahli tanaman atau penyuluh pertanian setempat untuk memastikan akurasi klasifikasi.

Tahapan selanjutnya adalah preprocessing citra, termasuk teknik augmentasi seperti rotasi, zoom, dan pencahayaan, yang bertujuan memperkaya variasi data dan mencegah *overfitting* pada saat pelatihan model [18].

Data yang telah diproses kemudian digunakan untuk melatih model Convolutional Neural Network (CNN) menggunakan arsitektur ResNet50.

$$y = \mathcal{F}(x, \{W_i\}) + x$$


Keterangan:

- x = input dari block
- $\mathcal{F}(x, \{W_i\})$ = fungsi residual (hasil dari beberapa layer konvolusi, batchnorm, ReLU)
- $+x$ = shortcut connection (identity mapping)
- y = output dari residual block

- Kemudian diteruskan ke fungsi aktivasi ReLU: $z = \text{ReLU}(y)$

Pelatihan dilakukan menggunakan teknik validasi silang dan pengujian parameter untuk memperoleh performa optimal, yang dievaluasi dengan metrik seperti akurasi dan F1-score. Arsitektur ini dipilih karena kemampuannya dalam mengenali fitur visual kompleks pada daun yang terinfeksi penyakit [19].

Tahap akhir adalah evaluasi dan validasi, menguji performa model pada data uji dan lapangan, serta memastikan sistem dapat mengidentifikasi penyakit secara akurat di kondisi nyata dengan validasi dari penyuluh dan petani. Alur *flowchart* proses deteksi penyakit tanaman cengkeh berbasis *deep learning* ditunjukkan pada Gambar 1.



Gambar 1. Alur penelitian deteksi penyakit tanaman cengkeh berbasis deep learning

4. HASIL DAN PEMBAHASAN

Proses Alat penelitian yang digunakan adalah laptop Asus dengan spesifikasi hardware Intel®Core™ i5-3317 CPU @1.70GHz, GPU NVIDIA GeForce GT 635M, RAM 16 GB. Sedangkan Software yang digunakan dalam penelitian ini adalah sistem operasi Windows 11 Home Single Edition 64 bit, Adobe Photoshop CS5 untuk proses editing, Bahasa pemrograman python dan library tensorflow.keras untuk mendukung proses pengolahan citra.

Data citra daun cengkeh dibagi ke dalam tiga folder utama, yaitu train, test dan valid, dengan

preprocessing dan augmentasi data yang dilakukan melalui ImageDataGenerator. Augmentasi mencakup rotasi, pergeseran horizontal dan vertikal, *shear*, *zoom*, serta *flipping*, sehingga model lebih adaptif terhadap variasi data. Proses augmentasi dataset terlihat pada gambar 2.



Gambar 2. Pendefinisian imagedatagenerator dengan augmentasi dataset gambar

ImageDataGenerator dari pustaka Keras untuk melakukan proses *preprocessing* sekaligus augmentasi data gambar. Tahap preprocessing dilakukan dengan menormalisasi nilai piksel setiap citra melalui parameter `rescale=1./255`,

sehingga nilai piksel berada pada rentang 0–1. Normalisasi ini bertujuan untuk mempercepat proses komputasi serta membantu model dalam mencapai konvergensi lebih stabil.

Selain itu, proses augmentasi diterapkan pada data latih guna meningkatkan variasi citra dan memperkaya distribusi dataset. Bentuk augmentasi yang digunakan antara lain rotasi hingga 40 derajat, pergeseran posisi horizontal dan vertikal sebesar 20%, transformasi geser (*shear*) sebesar 20%, pembesaran (*zoom*) hingga 20%, serta pembalikan horizontal (*horizontal flip*). Proses ini dilengkapi dengan `fill_mode='nearest'` untuk mengisi piksel kosong akibat transformasi. Teknik augmentasi semacam ini bertujuan mengurangi risiko *overfitting* dengan cara menghasilkan variasi data baru yang menyerupai kondisi nyata.

Berbeda dengan data latih, pada data validasi hanya diterapkan proses normalisasi tanpa augmentasi. Hal ini dilakukan untuk menjaga konsistensi data validasi agar tetap merepresentasikan kondisi asli, sehingga evaluasi kinerja model tidak terdistorsi oleh transformasi tambahan.

Data gambar dimuat menggunakan fungsi `flow_from_directory`, yang secara otomatis membaca dataset dari struktur folder. Parameter `target_size=(224, 224)` digunakan untuk menyeragamkan ukuran citra sesuai kebutuhan arsitektur model yang digunakan. Sementara itu, `batch_size=32` ditetapkan untuk menentukan jumlah sampel dalam setiap iterasi, dan `class_mode='categorical'` digunakan karena klasifikasi yang dilakukan melibatkan lebih dari dua kelas.

Melalui pendekatan ini, pipeline data dapat berjalan secara efisien, di mana setiap batch data yang telah diproses dan diaugmentasi dapat langsung digunakan pada tahap pelatihan dan validasi model.

Pada implementasi ini, bagian klasifikasi teratas (*fully connected layers*) dari ResNet50 dihapus (`include_top=False`) sehingga hanya digunakan sebagai *feature extractor*. Parameter `input_shape=(224, 224, 3)` ditetapkan agar citra masukan berukuran 224×224 piksel dengan tiga kanal warna (RGB). Untuk menjaga keutuhan bobot awal hasil pelatihan pada ImageNet, lapisan-lapisan pada ResNet50 dibekukan (`trainable=False`), sehingga tidak ikut diperbarui dalam proses *training*. Dengan demikian, proses pelatihan difokuskan pada lapisan tambahan yang ditambahkan di atas *base model*.

Di atas *base model* ditambahkan beberapa lapisan klasifikasi. Pertama, (GAP) digunakan untuk mereduksi *Global Average Pooling* dimensi keluaran tanpa kehilangan informasi penting. Selanjutnya, ditambahkan *Dense layer* dengan 512 neuron dan fungsi aktivasi ReLU untuk menangkap representasi non-linear, diikuti oleh *Dropout layer* dengan tingkat dropout 0.5 untuk mengurangi risiko *overfitting*.

Terakhir, lapisan *Dense output* dengan dua neuron dan aktivasi *Softmax* digunakan untuk melakukan klasifikasi terhadap dua kelas target.

Model kemudian dikompilasi menggunakan optimizer Adam, dengan fungsi *loss categorical_crossentropy* dan metrik evaluasi berupa akurasi. Proses pelatihan dilakukan menggunakan data dari `train_generator` selama 10 epoch, dengan validasi paralel menggunakan `validation_generator`.


Kurva hasil pelatihan menunjukkan bahwa model mampu belajar secara efektif dari data latih sekaligus mempertahankan kemampuan generalisasi pada data validasi. Pada awal pelatihan, akurasi data latih berada pada kisaran 0,78 dan kemudian meningkat tajam hingga mendekati 0,98 pada epoch ke-10, yang mengindikasikan bahwa model secara bertahap mampu mengenali pola dalam data secara konsisten tanpa mengalami penurunan performa. Sementara itu, akurasi validasi dimulai dari sekitar 0,80 dan terus meningkat stabil hingga mencapai lebih dari 0,95 pada epoch ke-10, menunjukkan bahwa model tidak hanya menghafal data latih, tetapi juga dapat menggeneralisasi pola pada data baru. Perbedaan akurasi antara data latih dan validasi relatif kecil, dengan tren yang paralel dan kesenjangan yang stabil. Hal ini menandakan bahwa model memiliki kemampuan generalisasi yang baik serta risiko *overfitting* yang rendah, sehingga dapat dikatakan cukup andal dalam menyelesaikan tugas klasifikasi pada dataset yang digunakan seperti pada gambar 3.



Gambar 3. Training dan validation accuracy

Sementara itu pada gambar 4, grafik nilai `validation_loss` dan `loss` pelatihan sebesar `train_loss` yang ditampilkan menunjukkan tren penurunan nilai `loss` baik pada data latih maupun validasi, yang menandakan model mampu belajar secara efektif. Pada awal pelatihan, nilai *training loss* masih cukup tinggi sekitar 0,58, namun terus menurun signifikan hingga mencapai sekitar 0,04 pada epoch ke-10. Hal ini menunjukkan bahwa model berhasil meminimalkan kesalahan prediksi pada data latih secara stabil. Sementara itu, *validation loss* juga mengalami penurunan dari sekitar 0,52 pada epoch pertama menjadi sekitar 0,12 pada epoch ke-10. Meskipun penurunannya tidak sedrastis data latih, tren


ini tetap mencerminkan kemampuan model dalam mengenali pola pada data yang belum pernah dilihat sebelumnya. Perbandingan antara kedua kurva memperlihatkan adanya kesenjangan (gap) setelah epoch ke-4, di mana *training loss* lebih cepat menurun dibanding *validation loss*. Walaupun demikian, gap tersebut tidak terlalu lebar sehingga model masih menunjukkan kemampuan generalisasi yang baik, meski terdapat indikasi awal terjadinya *overfitting* ringan pada akhir pelatihan



Gambar 4. Training dan validation loss

Penerapan augmentasi data terbukti membantu mengurangi potensi *overfitting*, karena model diberikan variasi data yang lebih luas meskipun berasal dari dataset terbatas. Nilai akurasi yang cukup tinggi pada data validasi membuktikan bahwa model dapat mengenali pola visual pada daun cengkeh dengan baik.

Namun demikian, perbedaan antara akurasi pelatihan dan akurasi validasi perlu diperhatikan. Jika gap terlalu besar, hal ini menunjukkan adanya potensi *overfitting*. Untuk meningkatkan performa, jumlah epoch dapat ditambah, atau lapisan tertentu dari ResNet50 dapat di-*unfreeze* untuk dilakukan *fine-tuning*, sehingga model dapat menyesuaikan bobot lebih spesifik terhadap karakteristik dataset daun cengkeh.



Gambar 5. Confusion matrix (validation set)

Berdasarkan hasil pelatihan *Confusion Matrix* ini memperlihatkan bahwa model memiliki kinerja yang seimbang dalam membedakan kedua kelas. Dengan tingkat prediksi benar yang tinggi di kedua kelas, model cukup andal dan konsisten, meskipun perlu perhatian pada pengurangan kesalahan klasifikasi untuk Kelas 0 agar performa semakin optimal seperti terlihat pada gambar 5.

Tabel 1. Classification report

Class	Precision	Recall	F1-Score	Support
Class 0	0.91	0.95	0.93	200
Class 1	0.95	0.91	0.93	200
Accuracy			0.93	400
Macro Avg	0.93	0.93	0.93	400
Weighted Avg	0.93	0.93	0.93	400

Interpretasi *classification report* tabel 1:

- Class 0 memiliki performa *recall* lebih tinggi (0.95), artinya model lebih baik dalam menangkap semua sampel positif pada kelas ini.
- Class 1 memiliki *precision* lebih tinggi (0.95), artinya prediksi untuk kelas ini lebih tepat dan minim kesalahan klasifikasi.
- Nilai F1-Score setara di kedua kelas (0.93), menunjukkan keseimbangan *precision* dan *recall*.
- Akurasi keseluruhan mencapai 0.93, yang merepresentasikan kinerja model yang konsisten.

5. KESIMPULAN DAN SARAN

Model terbukti belajar dengan baik, ditunjukkan oleh penurunan konsisten pada training loss dan validation loss serta akurasi validasi yang stabil di atas 95%. *Confusion Matrix* mengonfirmasi kinerja seimbang dalam membedakan kedua kelas, sementara *classification report* menunjukkan recall tinggi pada Class 0 dan precision tinggi pada Class 1 dengan F1-score setara (0.93). Secara keseluruhan, model memiliki generalisasi yang baik, stabil, dan andal.

Untuk meningkatkan performa lebih lanjut dan mencegah *overfitting*, disarankan melakukan penyesuaian jumlah epoch, menambah regularisasi, atau memperluas data augmentasi. Evaluasi tambahan menggunakan precision, recall, F1-score, dan confusion matrix tetap diperlukan untuk memastikan keseimbangan performa terutama pada dataset yang tidak seimbang.

DAFTAR PUSTAKA

- [1] G. m Tumanduk, B. A. N. Pinaria, and C. L. Salaki, "Serangan hama penggerek batang cengkeh *Hexamithodera semivelutina* Hell. di Desa Kumelembuai Kabupaten Minahasa Selatan," *Cocos*, vol. 8, no. 5, pp. 1–12, 2017.
- [2] B. F. Supriyanto, N. D. Murtadho, N. A. Murthisari, and T. A. Atmojo, "Transformasi Digital Pertanian dan Edukasi Kesehatan Melalui Marketplace Berbasis Website," vol. 4, no. 1, pp.

- 539–546, 2025.
- [3] F. Mursyid, M. Arfal Albarzah, I. Irnawati, W. Ceria Juliana, M. Rifki Adiyatma, and F. M. Hamundu, “Aplikasi Deteksi Penyakit Tanaman Cabai Menggunakan Teknologi Machine Learning dan Flask,” *J. Pustaka Data (Pusat Akses Kaji. Database, Anal. Teknol. dan Arsit. Komputer)*, vol. 5, no. 1, pp. 176–182, 2025, doi: 10.55382/jurnalpustakadata.v5i1.1026.
 - [4] D. Mailuhu, J. Patty, G. N. C. Tuhumury, V. Kewilaa, and R. Sarfan, “Kerusakan Tanaman Cengkeh (*Zyzygium aromaticum*) Akibat Serangan Penyakit Di Kecamatan Saparua,” *Agrol. J. Ilmu Budid. Tanam.*, vol. 13, pp. 175–183, 2024, doi: 10.30598/agrologia.v13i2.15591.
 - [5] R. Sigitta, R. Saputra, and F. Fathulloh, “Deteksi Penyakit Tomat melalui Citra Daun menggunakan Metode Convolutional Neural Network,” *AVITEC*, vol. 5, p. 43, 2023, doi: 10.28989/avitec.v5i1.1404.
 - [6] I. Nesta Suandana, A. Asriyanik, and W. Apriandari, “Pemanfaatan Cnn (Convolution Neural Network) Dan Mobilenet V2 Dalam Klasifikasi Rempah-Rempah Lokal Di Indonesia,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 5, pp. 10109–10116, 2024, doi: 10.36040/jati.v8i5.10873.
 - [7] A. B. Santoso, “Upaya Mempertahankan Eksistensi Cengkeh di Provinsi Maluku Melalui Rehabilitasi dan Peningkatan Produktivitas,” *J. Penelit. dan Pengemb. Pertan.*, vol. 37, no. 1, p. 26, 2018, doi: 10.21082/jp3.v37n1.2018.p26-32.
 - [8] A. N. M. Ramadhani, G. W. Saraswati, R. T. Agung, and H. A. Santoso, “Performance Comparison of Convolutional Neural Network and MobileNetV2 for Chili Diseases Classification,” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 7, no. 4, pp. 940–946, 2023, doi: 10.29207/resti.v7i4.5028.
 - [9] A. M. Lesmana, R. P. Fadhillah, and C. Rozikin, “Identifikasi Penyakit pada Citra Daun Kentang Menggunakan Convolutional Neural Network (CNN),” *J. Sains dan Inform.*, vol. 8, no. 1, pp. 21–30, 2022, doi: 10.34128/jsi.v8i1.377.
 - [10] N. Istiqomah and M. Murinto, “Klasifikasi Penyakit Tanaman Padi Berbasis Citra Daun Menggunakan Convolutional Neural Network (CNN),” *JSTIE (Jurnal Sarj. Tek. Inform.)*, vol. 12, no. 1, p. 18, 2024, doi: 10.12928/jstie.v12i1.27314.
 - [11] S. Yuliany, A. Aradea, and A. N. Rachman, “Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN),” *J. Buana Inform.*, vol. 13, no. 1, pp. 54–65, 2022, doi: 10.24002/jbi.v13i1.5022.
 - [12] M. Khoiruddin, A. Junaidi, and W. A. Saputra, “Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network,” *J. Dinda Data Sci. Inf. Technol. Data Anal.*, vol. 2, no. 1, pp. 37–45, 2022, doi: 10.20895/dinda.v2i1.341.
 - [13] R. Soekarta, N. Nurdjan, and A. Syah, “Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (CNN),” *Insect (Informatics Secur. J. Tek. Inform.)*, vol. 8, no. 2, pp. 143–151, 2023, doi: 10.33506/insect.v8i2.2356.
 - [14] A. Achmadi, B. A. Umam, and A. Anwari, “Identifikasi Penyakit Daun Tembakau Berbasis Pengolahan Citra dengan Metode Convolutional Neural Network (CNN) Dan Metode Transfer Learning,” *J. SISKOM-KB (Sistem Komput. dan Kecerdasan Buatan)*, vol. 8, no. 1, pp. 10–16, 2024, doi: 10.47970/siskom-kb.v8i1.654.
 - [15] K. Ferentinos, “Deep learning models for plant disease detection and diagnosis,” *Comput. Electron. Agric.*, vol. 145, pp. 311–318, 2018, doi: 10.1016/j.compag.2018.01.009.
 - [16] R. Sharma *et al.*, “Plant Disease Diagnosis and Image Classification Using Deep Learning,” *Comput. Mater. Contin.*, vol. 71, pp. 2125–2140, 2021, doi: 10.32604/cmc.2022.020017.
 - [17] S. Agustiani, Y. T. Arifin, A. Junaidi, S. K. Wildah, and A. Mustopa, “Klasifikasi Penyakit Daun Padi menggunakan Random Forest dan Color Histogram,” *J. Komputasi*, vol. 10, no. 1, pp. 65–74, 2022, doi: 10.23960/komputasi.v10i1.2961.
 - [18] M. Naveenkumar and S. Nandagopal, “Adaptive hybrid segmentation combined with meta heuristic optimization in transfer learning for plant leaf disease classification,” *Sci. Rep.*, vol. 15, no. 1, 2025, doi: 10.1038/s41598-025-93225-9.
 - [19] H. Orchi, M. Sadik, and M. Khaldoun, “On Using Artificial Intelligence and the Internet of Things for Crop Disease Detection: A Contemporary Survey,” *Agriculture*, vol. 12, p. 9, 2021, doi: 10.3390/agriculture12010009.
 - [20] S. P. Luanmasa, J. A. Leatemia, and C. Uruilal, “Intensitas Kerusakan Tanaman Cengkeh (*Syzygium aromaticum* L.) Akibat Serangan Hama dan Penyakit di Negeri Hitu Lama, Kecamatan Leihitu Kabupaten Maluku Tengah,” *J. Agrosilvopasture-Tech*, vol. 2, no. 2, pp. 412–420, 2023, doi: 10.30598/j.agrosilvopasture-tech.2023.2.2.412.
 - [21] K. Sulandjari and D. Suparwata, “Inovasi Dalam Pertanian Berkelanjutan di Kabupaten Sukabumi: Dari Pertanian Vertikal hingga Bioinformatika Pertanian Mewujudkan Sumber Pangan yang Lebih Berkelanjutan,” *J. Multidisiplin West Sci.*, vol. 2, pp. 780–789, 2023, doi: 10.58812/jmws.v2i09.667.
 - [22] T. Saikawa, Q. Cap, S. Kagiwada, H. Uga, and H. Iyatomi, “AOP: An Anti-overfitting Pretreatment for Practical Image-based Plant Diagnosis,” 2019, doi: 10.48550/arXiv.1911.10727.
 - [23] M. M. Kabir, A. Q. Ohi, and M. F. Mridha, “A

- Multi-Plant Disease Diagnosis Method Using Convolutional Neural Network,” pp. 99–111, 2021, doi: 10.1007/978-981-33-6424-0_7.
- [24] J. Zheng *et al.*, “FPGA-Based Low-Power High-Performance CNN Accelerator Integrating DIST for Rice Leaf Disease Classification,” *Electronics*, vol. 14, p. 1704, 2025, doi: 10.3390/electronics14091704.
- [25] A. Khaldi and E. M. Kalmoun, “Automated Disease Diagnosis in Pumpkin Plants Using Advanced CNN Models,” 2024, [Online]. Available: <http://arxiv.org/abs/2410.00062>
- [26] J. Zudikhina and A. Smirnov, “Convolutional neural network’s choice for integration into a disease detection on plants leaves application,” in *AIP Conference Proceedings*, 2020, p. 80036. doi: 10.1063/5.0032961.
- [27] D. Haba, “Data Augmentation with Python: Enhance deep learning accuracy with data augmentation methods for image, text, audio, and tabular data,” *Data Augment. with Python Enhanc. Deep Learn. accuracy with data Augment. methods image, text, audio, tabular data*, 2023.
- [28] R. Yadav, Y. Rana, and S. Nagpal, “Plant Leaf Disease Detection and Classification Using Particle Swarm Optimization,” 2019, pp. 294–306. doi: 10.1007/978-3-030-19945-6_21.
- [29] G. Y. Christiawan, R. A. Putra, A. Sulaiman, E. Poerbaningtyas, and S. W. Putri Listio, “Penerapan Metode Convolutional Neural Network (CNN) Dalam Mengklasifikasikan Penyakit Daun Tanaman Padi,” *J-Intech*, vol. 11, no. 2, pp. 294–306, 2023, doi: 10.32664/j-intech.v11i2.1006.
- [30] S. Sriyati, A. Setyanto, and E. E. Luthfi, “Literature Review: Pengenalan Wajah Menggunakan Algoritma Convolutional Neural Network,” *J. Teknol. Inf. dan Komun.*, vol. 8, no. 2, 2020, doi: 10.30646/tikomsin.v8i2.463.
- [31] D. Setiawan, A. Dwi, K. Stefani, and J. Felisa, “Implementasi Convolutional Neural Network untuk Facial Recognition,” *Media Inform.*, vol. 20, pp. 66–79, 2021, doi: 10.37595/mediainfo.v20i2.68.
- [32] R. Yamashita, M. Nishio, R. Do, and K. Togashi, “Convolutional neural networks: an overview and application in radiology,” *Insights Imaging*, vol. 9, 2018, doi: 10.1007/s13244-018-0639-9.
- [33] J. Nichols, H. Chan, and M. Baker, “Machine learning: applications of artificial intelligence to imaging and diagnosis,” *Biophys. Rev.*, vol. 11, 2018, doi: 10.1007/s12551-018-0449-9.
- [34] M. El Sakka, M. Ivanovici, L. Chaari, and J. Mothe, “A Review of CNN Applications in Smart Agriculture Using Multimodal Data,” *Sensors*, vol. 25, p. 472, 2025, doi: 10.3390/s25020472.
- [35] D. Nugraheni, A. Nugroho, D. Dewi, and B. Noranita, “Deca Convolutional Layer Neural Network (DCL-NN) Method for Categorizing Concrete Cracks in Heritage Building,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, 2023, doi: 10.14569/IJACSA.2023.0140180.
- [36] A. Voulodimos, N. Doulamis, A. Doulamis, and E. Protopapadakis, “Deep Learning for Computer Vision: A Brief Review,” *Comput. Intell. Neurosci.*, vol. 2018, pp. 1–13, 2018, doi: 10.1155/2018/7068349.
- [37] T. Aboneh, A. Rorissa, R. Srinivasagan, and A. Gemechu, “Computer Vision Framework for Wheat Disease Identification and Classification Using Jetson GPU Infrastructure,” *Technologies*, vol. 9, no. 3, 2021, doi: 10.3390/technologies9030047.
- [38] C. Subbarayudu and M. Kubendiran, “An automated hybrid deep learning framework for paddy leaf disease identification and classification,” *Sci. Rep.*, vol. 15, p. 26873, 2025, doi: 10.1038/s41598-025-08071-6.
- [39] G. Kulkarni, “Cloud Storage Architecture,” 2012.
- [40] B. Nugroho and E. Puspaningrum, “Kinerja Metode CNN untuk Klasifikasi Pneumonia dengan Variasi Ukuran Citra Input,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 8, p. 533, 2021, doi: 10.25126/jtiik.2021834515.
- [41] M. Muslih and E. H. Rachmawanto, “Convolutional Neural Network (Cnn) Untuk Klasifikasi Citra Penyakit Diabetes Retinopathy,” *Skanika*, vol. 5, no. 2, pp. 167–176, 2022, doi: 10.36080/skanika.v5i2.2945.
- [42] M. Nugroho, N. Sanjaya, A. Tubagus, M. R. Syarif, and C. Rozikin, “Foreground Extraction pada Citra Daun Melon dengan Bantuan Deep Neural Network,” *J. Inform. Polinema*, vol. 7, pp. 17–22, 2021, doi: 10.33795/jip.v7i3.550.
- [43] G. Riantama, I. Piarsa, and G. Sasmita, “Pengaruh Segmentasi Terhadap Hasil Rotasi Citra Menggunakan Metode Minimum Area Rectangle,” *J. Ilm. Merpati (Menara Penelit. Akad. Teknol. Informasi)*, p. 95, 2019, doi: 10.24843/JIM.2019.v07.i02.p01.
- [44] M. D. Nasution, A.-K. Al-Khowarizmi, and H. Maulana, “Optimization of Faster R-CNN to Detect SNI Masks at Mandatory Mask Doors,” *J. Informatics Telecommun. Eng.*, vol. 6, no. 2, pp. 602–611, 2023, doi: 10.31289/jite.v6i2.8128.