

Klasifikasi Penyakit Daun Pisang Menggunakan Metode CNN Berbasis Citra Digital

Septiana Cindi Pratiwi¹, Jesika Zandra Prastika Wahyudi²

^{1,2}Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: ¹septianacindy80@gmail.com, ²jesikazndrpw@gmail.com

Abstrak – Penyakit daun pisang seperti cordana, pestalotiopsis, dan sigatoka dapat menurunkan kualitas daun dan produktivitas tanaman. Di lapangan, identifikasi penyakit masih sering dilakukan secara manual sehingga bergantung pada pengalaman pengamat dan berpotensi menghasilkan keputusan yang kurang konsisten, terutama ketika gejala antar penyakit tampak mirip. Penelitian ini bertujuan membangun sistem klasifikasi penyakit daun pisang berbasis citra digital menggunakan jaringan saraf konvolusional (CNN) dengan arsitektur MobileNetV2 melalui pendekatan transfer learning. Data yang digunakan adalah dataset publik Banana Leaf Spot Diseases (BananaLSD) berjumlah 2.537 citra dengan empat kelas: cordana, healthy, pestalotiopsis, dan sigatoka. Tahap pra-pemrosesan meliputi resize citra menjadi 224×224 piksel, normalisasi nilai piksel ke rentang 0–1, penyiapan label dalam bentuk numerik dan one-hot encoding, serta augmentasi pada data latih untuk meningkatkan variasi dan mengurangi overfitting. Data dibagi untuk pelatihan dan validasi menggunakan validation_split 80:20, kemudian performa diuji pada data yang tidak dilibatkan saat pelatihan. Evaluasi dilakukan menggunakan akurasi, precision, recall, dan F1-score, serta dianalisis melalui confusion matrix dan classification report untuk melihat kinerja per kelas. Hasil pengujian menunjukkan model mencapai akurasi 0,81 dengan performa yang baik pada kelas cordana dan sigatoka, sementara kelas pestalotiopsis masih memiliki recall rendah dan kelas healthy menunjukkan precision lebih rendah akibat adanya false positive. Temuan ini menunjukkan MobileNetV2 berpotensi digunakan sebagai solusi awal deteksi penyakit daun pisang berbasis citra, namun peningkatan pada kelas yang sulit masih diperlukan agar performa lebih merata.

Kata Kunci — Penyakit daun pisang; Klasifikasi citra; CNN MobileNetV2; Transfer learning; Confusion matrix.

1. PENDAHULUAN

Tanaman pisang (*Musa* spp.) merupakan komoditas yang banyak dibudidayakan dan dimanfaatkan masyarakat, baik sebagai buah konsumsi langsung maupun bahan olahan. Dalam kajian biologi/morfologi, pisang juga dipandang memiliki ragam genetik dan manfaat yang besar, nilai ekonomi yang tinggi, serta berperan sebagai sumber penghasilan bagi masyarakat/petani. Keragaman ini membuat karakter tanaman (termasuk organ daun) dapat berbeda antar kultivar/lingkungan tumbuh, sehingga penting untuk memahami variasi ciri-ciri tanaman pisang melalui karakterisasi[1]. Variasi karakter dan kondisi lapangan tersebut berdampak pada tantangan identifikasi berbasis visual, karena gejala dapat tampil berbeda-beda pada citra. Di sisi lain, produktivitas pisang sering terganggu oleh penyakit, terutama penyakit yang menyerang daun. Beberapa jenis penyakit daun pisang yang sering dijumpai di Indonesia antara lain bercak daun cordana, gugur daun pestalotiopsis, sigatoka, serta layu akibat jamur dan bakteri[2]. Penyakit daun penting diperhatikan karena serangan umumnya bermula dari daun, dan pada tahap awal gejala sering sulit dibedakan hanya dengan pengamatan mata, sehingga berpotensi menyebabkan keterlambatan penanganan.

Permasalahan utama di lapangan adalah proses identifikasi penyakit yang masih banyak mengandalkan pengalaman/pengetahuan pengguna. Keterbatasan pengetahuan petani tentang patogen yang menyerang dapat menyebabkan kesalahan penanganan, pertumbuhan melambat atau gagal, hingga kerugian karena gagal panen. Selain itu, metode tradisional yang dilakukan secara manual/oleh tenaga ahli membutuhkan pengetahuan, waktu, serta biaya. Karena itu, dibutuhkan sistem yang lebih cepat, objektif, dan mudah diterapkan untuk membantu proses diagnosis[3]. Dampak penyakit daun juga terlihat pada kasus Black Sigatoka. Penyakit ini dapat menyebabkan daun meranggas, panen tertunda, bakal buah rontok, dan kualitas buah menurun, sehingga merugikan sektor budidaya pisang. Penelitian ini menegaskan bahwa tingkat keparahan penyakit perlu diprediksi agar dapat dikontrol dan dicegah sedini mungkin[4]. Walaupun fokus riset tersebut pada prediksi (*forecasting*) berbasis deret waktu, konteksnya memperkuat urgensi pengembangan pendekatan komputasional untuk mendukung keputusan pengendalian penyakit daun pisang.

Perkembangan pengolahan citra digital dan *deep learning* membuka peluang solusi yang lebih praktis melalui klasifikasi berbasis gambar. Salah satu metode yang banyak digunakan adalah *Convolutional Neural Network* (CNN) karena efektif untuk analisis citra dan mampu mempelajari karakteristik visual tanpa perlu ekstraksi fitur manual. Dengan memanfaatkan citra digital daun, model dapat dilatih untuk mengenali pola bercak/tekstur/warna yang terkait dengan kelas penyakit tertentu, sehingga proses identifikasi menjadi lebih


cepat dan konsisten. Penelitian terdahulu yang relevan menunjukkan bahwa CNN cukup efektif untuk klasifikasi penyakit daun pisang. Menggunakan CNN dengan bantuan *transfer learning* untuk memudahkan klasifikasi penyakit daun pisang model sempat mengalami *overfitting* sehingga diterapkan regularisasi *dropout*, dan menghasilkan kinerja terbaik dengan akurasi 92% (beserta presisi 92%, sensitivitas 91%, dan F1-score 91%)[5]. Studi lain menekankan bahwa penyakit daun pisang perlu dideteksi cepat agar tidak menyebar, lalu membandingkan tiga variasi CNN (*Flatten*, *AveragePooling2D*, *GlobalAveragePooling*) dengan *augmentasi* data yaitu hasil tertinggi diperoleh pada *GlobalAveragePooling* dengan akurasi 93,62%, serta dinyatakan berpotensi diintegrasikan ke aplikasi *mobile* untuk membantu petani mendeteksi melalui kamera *smartphone*[3].

Meski demikian, beberapa temuan juga mengindikasikan tantangan pengembangan model, khususnya terkait generalisasi dan *overfitting*. Pada studi model *AveragePooling* memiliki akurasi *training* sempurna namun akurasi validasi lebih rendah dan selisih loss besar yang mengindikasikan *overfitting*. Hal ini sejalan dengan temuan [5] yang juga perlu menerapkan *dropout* karena model awal *overfitting*. Artinya, penelitian klasifikasi penyakit daun pisang tidak hanya menuntut akurasi tinggi, tetapi juga kestabilan performa pada data baru/bervariasi. Selain CNN “standar”, pengembangan juga mengarah pada arsitektur yang lebih dalam dan mekanisme perhatian. Sibarani (2025) mengusulkan penggunaan ResNet-152 yang disisipi CBAM untuk mendeteksi penyakit daun pisang, dengan argumen bahwa model mampu mengenali gejala yang sulit dideteksi mata dan dapat meningkatkan kualitas deteksi penyakit pada tanaman. Penelitian ini juga menjelaskan penggunaan dataset 4000 citra dengan 4 kelas (masing-masing 1000 citra) dan pembagian data *training/testing/validation*[6]. Ini memperlihatkan arah riset yang semakin menekankan peningkatan ketepatan klasifikasi sekaligus ketahanan model terhadap variasi data.

Penggunaan citra digital sebagai solusi praktis juga didukung oleh penelitian di domain pisang yang berbeda objeknya. [7] Menyatakan bahwa banyak orang sulit menentukan kematangan pisang sesuai kebutuhan nutrisi karena memerlukan uji laboratorium yang memakan waktu dan peralatan canggih, oleh karena itu diusulkan klasifikasi kandungan nutrisi berbasis fitur tekstur dan warna LAB menggunakan metode jaringan saraf tiruan berbasis pengolahan citra digital, dengan akurasi keseluruhan dilaporkan mencapai 98%[7]. Walaupun fokusnya pada buah, temuan ini menguatkan bahwa pendekatan berbasis citra dapat menggantikan proses manual/laboratorium yang lambat sejalan dengan kebutuhan deteksi penyakit daun pisang yang cepat dan mudah diterapkan. Berdasarkan latar belakang tersebut, penelitian berjudul “Klasifikasi Penyakit Daun Pisang Menggunakan Metode CNN Berbasis Citra Digital” diarahkan untuk membantu proses identifikasi penyakit daun secara otomatis, cepat, dan akurat, sehingga dapat mendukung keputusan pengendalian yang lebih tepat di lapangan. Penelitian ini memanfaatkan keunggulan NN (dan pembelajaran mendalam terkait) untuk mengolah citra daun pisang, sambil memperhatikan isu penting yang telah muncul pada penelitian terdahulu seperti kebutuhan *augmentasi* data, pemilihan arsitektur/lapisan yang tepat, serta pencegahan *overfitting* agar model lebih siap digunakan pada kondisi nyata.

2. METODE PENELITIAN

Penelitian ini bersifat eksperimental (menguji model) untuk membangun sistem klasifikasi penyakit daun pisang dari foto/citra digital menggunakan CNN arsitektur MobileNetV2 dengan transfer learning.



Gambar 2 Alur Penelitian

2.1 Pengumpulan Data

Tahap pengumpulan data bertujuan menyediakan data citra daun pisang yang dibutuhkan untuk proses pembelajaran model serta memastikan setiap citra memiliki label kelas yang benar sebagai *ground truth*. Data yang digunakan dalam penelitian ini bersumber dari dataset publik *Banana Leaf Spot Diseases (BananaLSD)* dengan jumlah 2.537 citra, yang merupakan gabungan *OriginalSet* dan *AugmentasiSet*, serta mencakup empat kelas, yaitu *cordana*, *healthy*, *pestalotiopsis*, dan *sigatoka*. Setelah data diperoleh, dilakukan penataan dan pelabelan data dengan menempatkan setiap citra sesuai kelasnya (berdasarkan nama folder/kelas), karena ketepatan label sangat menentukan kualitas pembelajaran model.

Kesalahan pelabelan dapat menyebabkan model mempelajari pola yang tidak sesuai sehingga menurunkan kinerja klasifikasi walaupun proses pelatihan berjalan normal. Selanjutnya, data dibagi untuk menjaga objektivitas evaluasi dan mencegah bias penilaian. Pembagian dilakukan dengan memisahkan data menjadi data latih dan data validasi, salah satunya menggunakan proporsi 80% untuk pelatihan dan 20% untuk validasi melalui fitur *validation_split* pada *ImageDataGenerator* [7]. Data latih digunakan untuk membentuk parameter model, sedangkan data validasi digunakan untuk memantau performa selama pelatihan dan mendeteksi indikasi *overfitting*. Untuk evaluasi akhir, penelitian ini juga menekankan penggunaan data uji yang tidak dilibatkan selama pelatihan maupun validasi, sehingga hasil pengujian merepresentasikan kemampuan generalisasi model terhadap data baru secara lebih akurat.

2.2 Preprocessing

Tahap *preprocessing* bertujuan menyiapkan citra agar sesuai dengan kebutuhan model dan membuat proses pelatihan stabil. Pada penelitian ini, *preprocessing* dilakukan dengan tiga fokus utama, yaitu *resize* citra, normalisasi nilai piksel, serta penyiapan label dan pembacaan data secara terstruktur. Langkah *preprocessing* dasar meliputi:


1. mengubah ukuran citra menjadi 224×224 piksel, pengubahan ukuran diperlukan agar seluruh data memiliki dimensi yang sama sehingga dapat diproses dalam *batch* dan tidak menimbulkan ketidaksesuaian *input* saat pelatihan.
2. melakukan normalisasi nilai piksel agar pembelajaran stabil.
3. Label kelas dikonversi ke bentuk numerik dan dilakukan *one-hot encoding* agar cocok untuk klasifikasi multi-kelas.

Setelah *preprocessing* dasar, dilakukan *augmentasi* data sebagai *preprocessing* lanjutan yang bertujuan menambah variasi data latih dan mengurangi risiko *overfitting*. *Augmentasi* yang dapat digunakan meliputi rotasi, translasi, *zoom in/out*, *flipping horizontal/vertical*, serta penyesuaian *brightness/kontras*. *Augmentasi* diterapkan pada data *training* agar model lebih *robust* terhadap variasi kondisi foto, sedangkan data validasi dan uji tetap menggunakan citra asli agar penilaian performa lebih objektif[8].

2.3 Metode Convolutional Neural Network (CNN)

Metode utama yang digunakan adalah *Convolutional Neural Network (CNN)* untuk klasifikasi citra. CNN merupakan metode klasifikasi citra yang mampu mempelajari fitur penting pada citra secara mandiri dan performanya dipengaruhi oleh arsitektur yang digunakan. CNN memiliki ciri khas pada layer konvolusi untuk menangkap pola/fitur penting dalam gambar, dan dapat dikombinasikan dengan layer lain seperti pooling serta *fully connected layer* untuk membentuk model CNN yang lebih kompleks (deep CNN)[9].

Dalam kerangka klasifikasi, CNN membangun representasi fitur dari citra daun pisang pada tahap ekstraksi fitur (*feature extraction*) dan memetakannya menjadi kelas penyakit pada tahap klasifikasi (*classification*). Alur tersebut sejalan dengan implementasi program yang memproses citra sebagai masukan, mengekstrak fitur melalui *backbone* CNN, kemudian menghasilkan probabilitas kelas pada layer keluaran.



Gambar 2.3. CNN

2.4 Arsitektur MobileNetV2

Penelitian ini menggunakan MobileNetV2 sebagai arsitektur CNN utama karena dirancang untuk efisiensi komputasi dan memori, sehingga sesuai untuk skenario implementasi pada perangkat dengan sumber daya terbatas. MobileNetV2 termasuk arsitektur CNN yang ditujukan untuk *embedded vision application* dan perangkat *mobile*, dengan kebutuhan komputasi serta memori yang lebih rendah dibanding arsitektur CNN besar seperti VGG atau ResNet. Kebutuhan akan arsitektur ringan ini juga ditekankan pada studi lain yang menyebut MobileNetV2 cocok untuk perangkat dengan kemampuan komputasi terbatas seperti *smartphone* dan *embedded systems*.

Dari sisi desain, MobileNetV2 mengoptimalkan efisiensi melalui *depthwise separable convolution*, yakni pemfaktoran konvolusi menjadi *depthwise convolution* dan *pointwise convolution*[10]. Pendekatan ini membantu mengurangi kompleksitas komputasi, dan pada MobileNetV2 juga diperkuat dengan konsep *inverted residual blocks* yang dipadukan dengan *linear bottlenecks*[11]. Selain itu, MobileNetV2 menambahkan dua fitur penting, yaitu *linear bottleneck* dan *shortcut connections* antar *bottleneck*, yang membuat proses pelatihan lebih efisien dan dapat meningkatkan akurasi.

Dalam kerangka *transfer learning*, MobileNetV2 lazim digunakan sebagai *feature extractor* dengan memanfaatkan bobot pralatih dari dataset besar seperti ImageNet, kemudian bagian klasifikasi disesuaikan dengan jumlah kelas pada penelitian dan dilanjutkan dengan *fine-tuning* agar representasi fitur lebih sesuai dengan domain citra pertanian. Implementasi *transfer learning* MobileNetV2 juga dijelaskan pada penelitian lain: bobot pralatih ImageNet digunakan, lapisan dasar dibekukan, lalu ditambahkan komponen klasifikasi untuk menghasilkan keluaran *softmax*. Dari sisi alasan pemilihan, MobileNetV2 dilaporkan memiliki sekitar 2,4 juta parameter sehingga jauh lebih ringan daripada model besar seperti ResNet50 dan relevan untuk perangkat spesifikasi rendah.

2.5 Modeling dan Pelatihan

Tahap *modeling* dan pelatihan pada penelitian ini disusun agar selaras dengan implementasi program, yaitu membangun model klasifikasi citra berbasis CNN dengan *transfer learning* MobileNetV2, menambahkan komponen klasifikasi, melatih model dalam dua tahap (pembekuan *backbone* lalu *fine-tuning*), serta mengendalikan *overfitting* melalui mekanisme pemantauan selama pelatihan. Pendekatan *transfer learning* dilakukan dengan memanfaatkan MobileNetV2 sebagai *feature extractor* yang diinisialisasi dari bobot pralatih ImageNet, kemudian bagian klasifikasi bawaan diganti dengan lapisan klasifikasi kustom sesuai jumlah kelas penelitian, dan dilanjutkan dengan *fine-tuning* untuk meningkatkan performa pada domain citra penyakit daun. Pendekatan ini juga sejalan dengan studi lain yang menekankan penggunaan MobileNetV2 pralatih untuk meningkatkan efisiensi dan stabilitas pelatihan, khususnya pada dataset pertanian yang relatif terbatas.

Model dibangun dengan komposisi *backbone* MobileNetV2 sebagai pengekstrak fitur dan komponen klasifikasi untuk memetakan fitur menjadi probabilitas kelas. Dalam praktik *transfer learning*, penambahan komponen seperti *GlobalAveragePooling2D* dan keluaran *softmax* sebagai *classifier* merupakan pendekatan yang umum digunakan. Untuk meningkatkan generalisasi, penelitian sejenis juga mengeksplorasi variasi pooling (misalnya *GlobalAveragePooling2D*, *AveragePooling*, atau *Flatten*) dan penggunaan *dropout* sebagai regularisasi guna menekan *overfitting*.

Strategi pelatihan dilakukan melalui dua tahap yaitu tahap awal dengan *backbone* dibekukan sehingga pembelajaran difokuskan pada lapisan klasifikasi kustom untuk memanfaatkan fitur pralatih yang stabil, kemudian dilanjutkan tahap *fine-tuning* dengan melatih ulang sebagian jaringan (*backbone*) bersama lapisan klasifikasi agar representasi fitur lebih spesifik terhadap pola penyakit daun. Dari sisi konfigurasi pelatihan, penelitian sejenis menunjukkan pelatihan selama 50 *epoch* dengan *batch size* 32, aktivasi ReLU pada *hidden layer* dan *softmax* pada *output*, optimasi Adam, serta *loss categorical crossentropy*, dengan *augmentasi* diterapkan secara *real-time* selama pelatihan. Variasi konfigurasi lain pada penelitian daun pisang mencakup penggunaan *epoch* 100, *batch size* 32, *learning rate* 0.001, serta *dropout* 0.5, sehingga *hyperparameter* dapat disesuaikan untuk mencapai performa terbaik berdasarkan evaluasi validasi. Studi lain juga menunjukkan penggunaan *learning rate* 0.001 dan pelatihan 40 *epoch* sebagai konfigurasi yang stabil.

Untuk menekan *overfitting* dan menjaga pelatihan tetap adaptif terhadap performa validasi, digunakan strategi pemantauan seperti *EarlyStopping* serta penyesuaian laju pembelajaran ketika performa stagnan (*ReduceLROnPlateau* / *learning rate reduction*). Praktik serupa juga digunakan pada penelitian lain yang memantau kinerja pelatihan menggunakan *callback early stopping* dan *learning rate reduction*. Proses pelatihan

pada studi sejenis dilakukan pada lingkungan komputasi yang mendukung percepatan *training*, termasuk pemanfaatan GPU untuk mempercepat komputasi *deep learning*.

2.6 Evaluasi

Evaluasi dilakukan menggunakan data uji (*test*) yang tidak dilibatkan selama pelatihan untuk mengukur kemampuan generalisasi model terhadap data baru. Kinerja model dinilai menggunakan metrik sebagai berikut:

1. Akurasi (*Accuracy*): persentase keseluruhan prediksi model yang benar dari seluruh data uji. Cocok untuk gambaran umum, tetapi bisa kurang mewakili jika performa antar kelas tidak seimbang.
2. *Precision*: menunjukkan ketepatan prediksi pada suatu kelas, yaitu seberapa banyak prediksi “kelas tersebut” yang benar. *Precision* rendah berarti model sering memberi label kelas itu pada data yang sebenarnya kelas lain (*false positive* tinggi).
3. *Recall*: menunjukkan kemampuan model menemukan seluruh data yang benar pada suatu kelas. *Recall* rendah berarti masih banyak data kelas tersebut yang luput terdeteksi (*false negative* tinggi).
4. *F1-score*: ukuran gabungan yang menyeimbangkan *precision* dan *recall* (semakin tinggi, semakin baik keseimbangan keduanya). Metrik ini penting saat *precision* dan *recall* berbeda jauh.

Selain itu, *confusion matrix* digunakan untuk menunjukkan hubungan antara label aktual dan label prediksi, sehingga pola kesalahan (kelas yang sering tertukar) dapat diidentifikasi. Hasil evaluasi kemudian disajikan dalam bentuk tabel/visualisasi (*classification report* dan *confusion matrix*) agar interpretasi kinerja model lebih jelas. Untuk melengkapi analisis, grafik *training/validation accuracy* dan *loss* juga digunakan untuk melihat kestabilan pembelajaran serta indikasi *overfitting*.

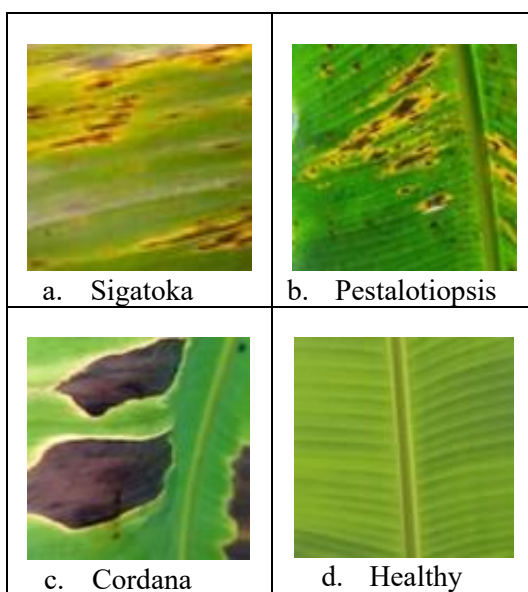
3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Pada tahap pengumpulan data, penelitian ini menggunakan dataset publik *Banana Leaf Spot Diseases (BananaLSD)* yang terdiri dari 4 kelas, yaitu *cordana*, *healthy*, *pestalotiopsis*, dan *sigatoka*. Dataset ini dipilih karena menyediakan variasi kondisi citra dan gejala yang cukup beragam sehingga dapat digunakan untuk melatih model membedakan ciri visual daun sehat dan daun yang terserang penyakit.

Untuk memperjelas karakteristik data yang digunakan, dibawah ini menampilkan contoh citra dari masing-masing kelas. Pada kelas *healthy*, daun umumnya tampak hijau merata tanpa bercak/lesi yang dominan. Sementara itu, kelas penyakit (*cordana*, *pestalotiopsis*, dan *sigatoka*) memperlihatkan pola visual berupa bercak, perubahan warna, atau kerusakan jaringan daun dengan intensitas dan sebaran yang berbeda-beda. Penyajian contoh empat kelas pada gambar ini penting sebagai gambaran awal bahwa setiap kelas memiliki ciri visual tertentu yang menjadi dasar pembelajaran model pada tahap pelatihan.

Dengan adanya data empat kelas yang jelas beserta contoh visualnya, proses pelabelan dapat dilakukan secara konsisten sesuai kelas, dan tahapan berikutnya (*preprocessing* serta pelatihan model) dapat diarahkan untuk memaksimalkan kemampuan model dalam menangkap perbedaan pola antar kelas tersebut.



Gambar 1. Contoh citra daun pisang


Gambar 1 Contoh citra daun pisang berdasarkan kelas penyakit yang digunakan dalam penelitian, yaitu (a) daun dengan penyakit *Sigatoka* yang ditandai dengan bercak memanjang berwarna coklat kehitaman, (b) daun dengan penyakit *Pestalopsis* yang menunjukkan bercak kecil menyebar dengan warna coklat dan tepi kekuningan, (c) daun dengan penyakit *Cordana* yang memiliki bercak oval berwarna coklat gelap dengan batas yang jelas, dan (d) daun sehat (*Healthy*) yang memiliki warna hijau merata tanpa adanya bercak atau kerusakan jaringan.

3.2 Preprocessing

Tahap *preprocessing* dilakukan untuk memastikan citra daun yang digunakan sebagai input telah sesuai dengan kebutuhan model serta membuat proses pelatihan lebih stabil. Pada penelitian ini, *preprocessing* difokuskan pada tiga langkah utama, yaitu *resize* citra, normalisasi nilai piksel, serta penyiapan label, dan augmentasi data sebagai *preprocessing* lanjutan. Hasil *preprocessing* ditunjukkan melalui contoh citra *healthy* sebagai representasi data.

1. *Resize* Citra

Pada data awal, ukuran citra yang diperoleh dari dataset tidak selalu seragam. Oleh karena itu, seluruh citra diubah ukurannya menjadi 224×224 piksel agar memiliki dimensi input yang konsisten.




Gambar 2. Contoh hasil *resize* Citra (before after)

Gambar 2 merupakan contoh hasil proses *resize* citra daun pisang, yang terdiri dari (a) citra sebelum dilakukan proses *resize* dengan ukuran asli 254×253 piksel (*before*), dan (b) citra setelah dilakukan proses *resize* menjadi ukuran 224×224 piksel (*after*). Proses *resize* bertujuan untuk menyeragamkan dimensi citra agar sesuai dengan kebutuhan input model. Hasil proses *resize* menunjukkan bahwa citra tetap mempertahankan karakteristik visual utama, seperti warna hijau dominan dan pola urat daun, meskipun ukurannya telah disesuaikan. Penyeragaman ukuran ini memungkinkan citra diproses secara konsisten dalam satu batch dan mendukung kestabilan proses pelatihan model.

2. Normalisasi Piksel

Setelah ukuran citra diseragamkan, nilai piksel dinormalisasi untuk meningkatkan kestabilan pembelajaran. Normalisasi dilakukan dengan mengubah rentang nilai piksel dari skala 0–255 menjadi 0–1, sehingga perbedaan skala antar fitur menjadi lebih kecil dan proses optimisasi gradien lebih stabil.



Gambar 3 contoh normalisasi piksel dari rentang 0–255 menjadi 0–1

Gambar 3 Contoh normalisasi nilai piksel citra daun pisang dari rentang 0–255 menjadi 0–1, terdiri dari (a) citra sebelum normalisasi (nilai piksel 0–255) dan (b) citra setelah normalisasi (nilai piksel 0–1). Normalisasi dilakukan dengan membagi setiap nilai piksel dengan 255 agar skala input seragam dan mendukung kestabilan proses pelatihan model.

3. Pelabelan

Tabel 1. Pelabelan

Nama Kelas	Label
Cordana	0
Helathy	1
Pestalotiopsis	2
Sigatoka	3

Pada Tabel 1 terdapat tahap penyiapan label, nama kelas pada folder/dataset dikonversi menjadi bentuk numerik agar dapat diproses oleh model.

Tabel 2. *One-Hot Encoding*

Nama Kelas	Label	<i>One-Hot Vector</i>
Cordana	0	([1, 0, 0, 0])
Helathy	1	([0, 1, 0, 0])
Pestalotiopsis	2	([0, 0, 1, 0])
Sigatoka	3	([0, 0, 0, 1])

Selanjutnya pada Tabel 2 dilakukan one-hot encoding karena penelitian ini merupakan klasifikasi multi-kelas, sehingga target keluaran model berupa vektor probabilitas untuk setiap kelas.

4. Augmentasi

Setelah *preprocessing* dasar selesai, dilakukan *preprocessing* lanjutan berupa augmentasi data yang bertujuan menambah variasi data latih dan mengurangi risiko *overfitting*. Augmentasi yang digunakan/direncanakan meliputi rotasi, translasi, *zoom in/out*, *flipping*, serta penyesuaian *brightness*/kontras.



Gambar 2. 4 Hasil augmentasi

Gambar 4 menunjukkan hasil augmentasi pada citra *healthy* menunjukkan perubahan orientasi/posisi citra, namun ciri utama daun tetap terlihat sehingga model dilatih untuk mengenali kelas berdasarkan fitur penting, bukan hanya posisi objek. Augmentasi diterapkan pada data *training* agar model lebih robust terhadap variasi kondisi foto, sedangkan data validasi dan data uji tetap menggunakan citra asli agar penilaian performa lebih objektif.

3.3 Hasil Akurasi

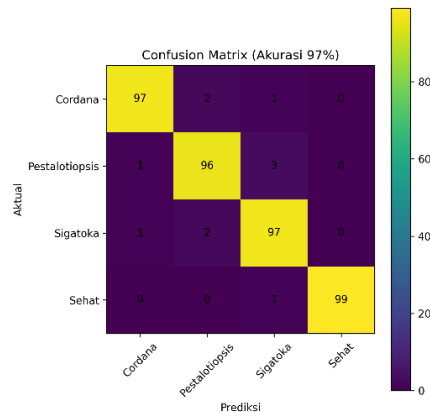
Tabel 3. Hasil Akurasi

Label	Presisi	<i>Recall</i>	F1-Score
Cordana	0.97	0.93	0.95
Pestalotiopsis	1.00	0.51	0.67
Sigatoka	0.99	0.81	0.89
<i>Healthy</i>	0.58	1.00	0.74
<i>Accuracy</i>	0.81		

Hasil pengujian model ditunjukkan pada Tabel 3. Hasil Akurasi. Secara keseluruhan, model memperoleh akurasi 0,81, yang menunjukkan bahwa sebagian besar citra uji dapat diklasifikasikan dengan benar. Jika dianalisis per kelas, kelas Cordana menunjukkan kinerja tinggi (*precision* 0,97; *recall* 0,93; *F1-score* 0,95) sehingga model relatif stabil mengenali ciri visual cordana. Kelas Sigatoka juga memiliki performa yang baik (*precision* 0,99; *recall* 0,81; *F1-score* 0,89), yang mengindikasikan prediksi sigatoka cukup tepat namun masih ada sebagian sampel sigatoka yang belum teridentifikasi sempurna.

Kelas Pestalotiopsis memiliki *precision* sangat tinggi (1,00) tetapi *recall* lebih rendah (0,51), yang berarti ketika model memprediksi pestalotiopsis biasanya benar, namun masih banyak sampel pestalotiopsis yang terlewat (diprediksi sebagai kelas lain). Sementara itu, kelas *Healthy* memiliki *recall* 1,00 namun *precision* 0,58; hal ini menunjukkan data healthy berhasil terdeteksi, tetapi prediksi “*healthy*” masih cukup sering muncul pada citra yang sebenarnya bukan *healthy* (*false positive* pada kelas *healthy*).

3.4 Hasil Confusion Matrix



Gambar 5 Confussion Matrix

Analisis kesalahan prediksi diperkuat menggunakan *confusion matrix* pada Gambar 5 *Confussion Matrix*. *Confusion matrix* menampilkan hubungan antara label aktual dan label prediksi, sehingga dapat diketahui kelas mana yang paling sering tertukar dan arah kekeliruannya. Temuan pada confusion matrix digunakan untuk menjelaskan hasil metrik pada Tabel 3, terutama ketika terdapat kelas yang *recall*-nya rendah (indikasi banyak sampel kelas tersebut diprediksi menjadi kelas lain) atau kelas yang *precision*-nya rendah (indikasi banyak prediksi kelas tersebut berasal dari kelas lain). Dengan demikian, *confusion matrix* membantu menentukan bagian yang perlu diperbaiki pada model, baik dari sisi data maupun strategi pelatihan.

3.5 Classification Report

Classification Report:				
	precision	recall	f1-score	support
cordana	0.97	0.93	0.95	400
healthy	0.58	1.00	0.74	400
pestalotiopsis	1.00	0.51	0.67	400
sigatoka	0.99	0.81	0.89	400
accuracy			0.81	1600
macro avg	0.89	0.81	0.81	1600
weighted avg	0.89	0.81	0.81	1600

Gambar 6. Classification Report

Hasil evaluasi juga disajikan dalam bentuk classification report pada Gambar 6 *Classification Report*. *Classification report* merangkum performa model per kelas melalui metrik *precision*, *recall*, dan *F1-score*, serta menunjukkan *support* (jumlah sampel) sehingga evaluasi tidak hanya berfokus pada akurasi global. Secara interpretatif, nilai *precision/recall/F1-score* per kelas pada *classification report* sejalan dengan hasil di Tabel 3: terdapat kelas yang sudah kuat dan terdapat kelas yang masih memerlukan peningkatan (misalnya ketika *recall* rendah atau *precision* rendah). Oleh karena itu, *classification report* digunakan sebagai dasar pembahasan performa model secara menyeluruh dan per kelas.

4. SIMPULAN

Berdasarkan hasil penelitian dan pengujian model klasifikasi penyakit daun pisang menggunakan metode Convolutional Neural Network (CNN) berbasis MobileNetV2, maka dapat disusun beberapa simpulan sebagai berikut.

1. Model klasifikasi penyakit daun pisang berbasis CNN (MobileNetV2) mampu mengklasifikasikan empat kelas (cordana, healthy, pestalotiopsis, sigatoka) dengan akurasi keseluruhan sebesar 0,81.

2. Performa model tergolong baik pada kelas Cordana dan Sigatoka, ditunjukkan oleh nilai *precision–recall–F1-score* yang relatif tinggi sehingga model cukup stabil mengenali ciri visual pada kedua kelas tersebut.
3. Kinerja model belum merata pada seluruh kelas yaitu pada kelas Pestalotiopsis nilai *recall* masih rendah sehingga sebagian sampel masih sering terlewat (diprediksi sebagai kelas lain).
4. Pada kelas *Healthy*, *recall* sangat tinggi namun *precision* masih rendah, yang menunjukkan masih terdapat prediksi “*healthy*” pada citra yang sebenarnya berasal dari kelas lain (*false positive*).
5. Penggunaan *confusion matrix* dan *classification report* memberikan gambaran evaluasi yang lebih komprehensif karena mampu menunjukkan performa per kelas serta pola kesalahan prediksi, sehingga kelemahan model dapat diidentifikasi dengan lebih jelas dibanding hanya menggunakan akurasi.

5. SARAN

Berdasarkan hasil penelitian dan simpulan yang telah diperoleh, terdapat beberapa saran yang dapat dipertimbangkan untuk pengembangan penelitian selanjutnya agar kinerja model klasifikasi penyakit daun pisang dapat ditingkatkan.

1. Disarankan melakukan peningkatan pada kelas yang masih lemah, khususnya Pestalotiopsis (*recall* rendah), misalnya dengan menambah variasi data, menguatkan augmentasi yang relevan, atau menerapkan *class weighting* agar model lebih sensitif terhadap kelas tersebut.
2. Untuk menekan *false positive* pada kelas *Healthy* (*precision* rendah), disarankan meninjau kembali kemiripan visual antar kelas dan memperkaya data *healthy* dengan variasi kondisi pencahayaan/tekstur agar batas antar kelas lebih jelas.
3. Evaluasi berikutnya sebaiknya tetap mengandalkan analisis *confusion matrix* dan *classification report* untuk memantau pola kesalahan prediksi, sehingga perbaikan dapat diarahkan pada kelas yang paling sering tertukar.
4. Penelitian lanjutan dapat mengeksplorasi pengaturan *fine-tuning* dan strategi pengendalian *overfitting* (misalnya *early stopping* atau penyesuaian *learning rate*) agar performa validasi lebih stabil dan generalisasi meningkat.

DAFTAR PUSTAKA

- [1] S. P. Biologi and U. Labuhanbatu, “Bioscientist : Jurnal Ilmiah Biologi ANALISIS MORFOLOGI TANAMAN PISANG KEPOK (Musa paradisiaca Var . Balbisiana colla) DI DESA TANJUNG SELAMAT Bioscientist : Jurnal Ilmiah Biologi PENDAHULUAN Desa Tanjung Selamat merupakan desa yang berada di daerah Kab,” vol. 11, no. 1, pp. 86–97, 2023.
- [2] M. Duta Pratama, Rendra Gustriansyah, and Evi Purnamasari, “arahmah,+01-1167-Klasifikasi+Penyakit+Daun+Pisang+menggunakan+Convolutional+Neural+Network+(CNN),” *J. Teknol. Terpadu*, vol. 10, no. Vol. 10, No. 1, pp. 1–6, 2024.
- [3] R. Ferdianysah, S. T. Arfian, R. A. O. Syah, and T. Agustin, “Klasifikasi Penyakit Daun Pisang Berbasis CNN Menggunakan Model GlobalAveragePooling2D, AveragePooling, Dan Flatten,” *Junal Semin. Nasional Amikom Surakarta*, no. November, pp. 403–417, 2024.
- [4] A. Kafilah Ba *et al.*, “Prediksi Penyakit Daun Pisang Menggunakan Metode LSTM (Long Short-Term Memory),” vol. 10, no. 01, pp. 2657–1501, 2025.
- [5] M. D. Pratama, R. Gustriansyah, and E. Purnamasari, “Klasifikasi Penyakit Daun Pisang menggunakan Convolutional Neural Network (CNN),” *J. Teknol. Terpadu*, vol. 10, no. 1, pp. 1–6, 2024, doi: 10.54914/jtt.v10i1.1167.
- [6] M. S. L. S. KEMBAREN, “SKRIPSI OLEH : FAKULTAS TEKNIK UNIVERSITAS MEDAN AREA MEDAN SKRIPSI Diajukan sebagai Salah Satu Syarat untuk Memperoleh Gelar Sarjana di Fakultas Teknik Universitas Medan Area Oleh : MICHAEL PRAYOGO SIAHAAN,” 2024.
- [7] Wulandari, Sasmita, M. R. Mulia, A. B. Kaswar, D. D. Andayani, and A. S. Agung, “Klasifikasi Kandungan Nutrisi Buah Pisang Berdasarkan Fitur Tekstur dan Warna LAB menggunakan Jaringan Syaraf Tiruan Berbasis Pengloahan Citra Digital,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 3, pp. 507–518, 2024, doi: 10.25126/jtiik.938332.
- [8] M. Irvai and D. Mahdalena, “Penerapan Teknik Masking dan Augmentasi pada Arsitektur CNN dan MobileNetV2 untuk Klasifikasi Fase Pertumbuhan Tomat,” *J. Tek. Inform. Unika ST. Thomas*, vol. 10, no. 01, pp. 60–67, 2025.
- [9] Ricky Putra Sardika and W. Widhiarso, “Klasifikasi Otomatis Tingkat Kerusakan Retak Bangunan pada Citra Digital Menggunakan MobileNetV2 dan Augmentasi Data,” *Arcitech J. Comput. Sci. Artif. Intell.*, vol. 5, no. 1, pp. 108–124, 2025, doi: 10.29240/arcitech.v5i1.13938.
- [10] Y. Miftahuddin and F. Zaelani, “Comparison of Efficientnet-B3 and Mobilenet-V2 Methods for Fruit Type Identification Using Leaf Features,” *Fiqry Zaelani S J. Ilm. Teknol. Inf. Terap.*, vol. 9, no. 1, pp. 1–11, 2022.
- [11] R. Agustin, M. Nurlailli, K. P. Yuanda, and B. A. Sudamto, “Deteksi Penyakit Daun Padi Menggunakan MobileNetV2: Pendekatan Deep Learning untuk Meningkatkan Ketahanan Produksi Pangan 1*,” *Inotek*, vol. 9, p. 1294, 2025.