

**ANALISIS TEKNIK *AUGMENTASI* TERHADAP KINERJA CNN
DALAM KLASIFIKASI KONDISI DAUN MELON**

SKRIPSI

Oleh:
ALHUBUL AUSTAD RAMADAN
NIM. 220605110003



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

HALAMAN PERSETUJUAN

ANALISIS TEKNIK *AUGMENTASI* TERHADAP KINERJA CNN DALAM KLASIFIKASI KONDISI DAUN MELON

SKRIPSI

Oleh:

ALHUBUL AUSTAD RAMADAN

NIM. 220605110003

Telah Diperiksa dan Disetujui untuk Diuji:

Tanggal: 12 Juni 2026

Pembimbing I,



Shoffin Nahwa Utama, M.T
NIP. 19860703 202012 1 003

Pembimbing II,



Khadijah Fahmi Hayati Holle, M.Kom
NIP. 19900626 202203 2 002

Mengetahui,

Ketua Program Studi Teknik Informatika

Fakultas Sains dan Teknologi

Universitas Islam Negeri Maulana Malik Ibrahim Malang



Supriyono, M.Kom

NIP. 19841010 201903 1 012

HALAMAN PENGESAHAN

ANALISIS TEKNIK *AUGMENTASI* TERHADAP KINERJA CNN DALAM KLASIFIKASI KONDISI DAUN MELON

SKRIPSI

Oleh:

ALHUBUL AUSTAD RAMADAN
NIM. 220605110003

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 23 Juni 2026

Susunan Dewan Penguji

Ketua Penguji : Johan Ericka Wahyu Prakasa, M.Kom
NIP. 19831213 201903 1 004


Anggota Penguji I : Nur Fitriyah Ayu Tunjung Sari, M.Cs
NIP. 19911226 202012 2 001

Anggota Penguji II : Shoffin Nahwa Utama, M.T
NIP. 19860703 202012 1 003

Anggota Penguji III : Khadijah Fahmi Hayati Holle, M.Kom
NIP. 19900626 202203 2 002

()
()
()
()

Mengetahui dan Mengesahkan,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Alhubul Austad Ramadan
NIM : 220605110003
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Analisis Teknik Augmentasi Terhadap Kinerja
CNN Dalam Klasifikasi Kondisi Daun Melon

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 23 Juni 2026

Yang membuat pernyataan,



Alhubul Austad Ramadan

NIM.220605110003

**ANALISIS TEKNIK *AUGMENTASI* TERHADAP KINERJA CNN DALAM
KLASIFIKASI KONDISI DAUN MELON**

SKRIPSI

Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)

Oleh:
ALHUBUL AUSTAD RAMADAN
NIM. 220605110003

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

MOTTO

... *“Suro diro joyoningrat, lebur dening pangastuti” ...*

... *“Kegigihan dan kerja keras akan selalu menemukan jalan untuk menundukkan segala rintangan besar.” ...*

HALAMAN PERSEMBAHAN

Alhamdulillah rabbil 'alamin, puji syukur senantiasa penulis panjatkan ke hadirat Allah *Subhānahu wa Ta'ālā* atas segala limpahan rahmat, hidayah, serta karunia-Nya sehingga penyusunan skripsi ini dapat diselesaikan dengan baik. Shalawat seiring salam semoga terus tumpahruai kepada junjungan besar Nabi *Muhammad Ṣallallāhu 'Alaihi Wasallam* yang telah membimbing umat manusia menuju cahaya kebenaran dan peradaban addinul Islam yang mulia. Melalui lembar persembahan ini, penulis bermaksud menyampaikan rasa terima kasih dan penghormatan yang setinggi-tingginya kepada berbagai pihak yang telah menjadi pilar kekuatan selama menempuh pendidikan di jenjang perguruan tinggi.

Karya tulis ini secara khusus penulis persembahkan sebagai wujud bakti, rasa hormat, dan cinta kasih yang mendalam kepada:

1. Mama Tercinta, yang tidak pernah lelah merapalkan doa terbaik di setiap sepertiga malam bagi keselamatan, kesehatan, dan kelancaran studi penulis. Kasih sayang yang tulus, kehangatan, serta rida Mama adalah sumber energi utama yang membuat penulis selalu mampu bangkit di kala lelah dan melangkah dengan keyakinan penuh hingga mencapai tahap akhir ini.
2. Ayah Tercinta, atas segala pengorbanan yang tak terhitung jumlahnya, bimbingan, serta teladan kerja keras yang luar biasa. Dukungan moral dan kepercayaan besar yang Ayah berikan menjadi fondasi kekuatan bagi penulis dalam menghadapi setiap tantangan dan rintangan selama menempuh masa perkuliahan.

3. Seseorang yang Amat Istimewa, yang senantiasa hadir sebagai sistem pendukung terbaik, pemberi ketenangan di tengah badai revisi, serta tempat bertukar cerita yang paling teduh. Terima kasih atas kesabaran, pengertian yang luar biasa, serta dukungan moral yang tulus tanpa henti dari awal masa perkuliahan hingga draf skripsi ini benar-benar rampung. Kehadiranmu membuat seluruh perjalanan dan pendewasaan diri ini terasa jauh lebih bermakna.
4. Laily dan Uqie teman seperjuangan yang sangat istimewa, yang tidak hanya kebersamaian penulis dalam urusan akademik, tetapi juga menjadi saksi sekaligus rekan dalam proses pendewasaan diri dan bertumbuh bersama. Terima kasih atas setiap diskusi, motivasi di saat-saat kritis, serta kebersamaan yang selalu menjadi penyemangat di tengah penatnya menempuh revisi.

Pada akhirnya, sebuah apresiasi yang paling jujur dan mendalam penulis tujukan untuk diri sendiri. Terima kasih karena telah memilih untuk terus bertahan, berjuang, dan menolak untuk menyerah di setiap fase yang penuh tekanan, kelelahan fisik, dan keraguan. Terima kasih atas segala kerja keras, keteguhan hati, serta malam-malam panjang yang telah dilalui di depan layar demi menyelesaikan tanggung jawab ini hingga tuntas ke garis akhir.

Penulis menyadari sepenuhnya bahwa keberhasilan menyelesaikan skripsi ini adalah hasil dari dukungan kolektif dan kebaikan hati banyak orang yang tidak akan mampu terbalas dengan sepadan. Oleh karena itu, penulis hanya dapat memanjatkan doa tulus agar seluruh bantuan, waktu, dan energi yang telah

dicurahkan oleh semua pihak bernilai ibadah serta mendapatkan ganjaran kebaikan yang berlipat ganda dari Allah Subhānahu wa Ta‘ālā. Semoga langkah kita semua ke depannya senantiasa diberkahi, dan karya sederhana ini diharapkan mampu memberikan manfaat yang nyata bagi perkembangan keilmuan, khususnya di bidang teknik informatika.

KATA PENGANTAR

Alhamdulillah rabbil ‘alamin, puji syukur senantiasa penulis panjatkan ke hadirat Allah *Subhānahu wa Ta‘ālā* atas segala limpahan rahmat, hidayah, serta kasih sayang-Nya yang telah memberikan kemudahan dan kelancaran bagi penulis untuk merampungkan karya ilmiah yang berjudul “ANALISIS TEKNIK AUGMENTASI TERHADAP KINERJA CNN DALAM KLASIFIKASI KONDISI DAUN MELON”. Shalawat seiring salam semoga terus tercurahkan kepada junjungan besar Nabi Muhammad *Ṣallallāhu ‘Alaihi Wasallam*, teladan utama umat manusia yang syafaatnya selalu kita harapkan di hari akhir nanti, *Aamiin*.

Penulis menyadari sepenuhnya bahwa perjalanan panjang menyelesaikan skripsi ini tidak akan pernah terwujud tanpa adanya bimbingan, ketulusan, serta dukungan kolektif dari berbagai pihak. Oleh karena itu, dengan segala kerendahan hati, penulis ingin memberikan rasa terima kasih dan penghormatan yang setinggi-tingginya kepada:

1. Prof. Dr. Hj. Ilfi Nurdiana, M.Si., CAHRM., CRMP selaku Rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang, atas kesempatan dan fasilitas yang diberikan selama penulis menempuh pendidikan.
2. Dr. Agus Mulyono, M.Kes. selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang, atas segala dukungan dan kebijakan selama masa studi penulis.

3. Johan Ericka Wahyu Prakasa, M.Kom, selaku Ketua Penguji, yang telah meluangkan waktu dan memberikan arahan serta evaluasi yang sangat berharga demi kesempurnaan skripsi ini.
4. Nur Fitriyah Ayu Tunjung Sari, M.Cs. selaku Anggota Penguji I, atas ketelitian, masukan ilmiah, dan kritik konstruktif yang sangat bermanfaat bagi penelitian ini.
5. Shoffin Nahwa Utama, M.T selaku Anggota Penguji II sekaligus Dosen Pembimbing I, yang telah melimpahkan kesabaran, waktu, serta bimbingan teoretis yang mendalam dari awal hingga akhir.
6. Khadijah Fahmi Hayati Holle, M.Kom, selaku Anggota Penguji III sekaligus Dosen Pembimbing II, atas segala kebaikan, bimbingan teknis, dan saran akademis yang krusial dalam menyempurnakan skripsi ini.
7. Segenap Dosen, Staf Administrasi, dan Laboran, yang telah membekali penulis dengan ilmu pengetahuan serta memberikan bantuan layanan administratif selama masa perkuliahan.
8. Kedua orang tua serta saudara-saudara tercinta, pilar kekuatan utama yang tiada henti melangitkan doa, memberikan pengorbanan, dan motivasi agar penulis dapat menuntaskan studi dengan lancar.
9. Teman-teman sejawat dan sahabat seperjuangan angkatan 2022, rekan bertumbuh yang luar biasa, yang selalu menjadi teman diskusi yang kritis dan saling menguatkan dalam suka maupun duka.

Terakhir, sebuah apresiasi yang paling jujur penulis tujukan untuk diri sendiri. Terima kasih karena telah memilih untuk terus bertahan, berjuang, dan

menolak untuk menyerah di setiap fase yang melelahkan. Terima kasih atas segala kerja keras, keteguhan hati, serta malam-malam panjang yang telah dilalui di depan layar demi menyelesaikan tanggung jawab ini hingga ke garis akhir. Semoga karya tulis ini dapat membawa keberkahan dan manfaat bagi perkembangan keilmuan ke depannya.

Malang, 23 Juni 2026

Penulis

DAFTAR ISI

HALAMAN PENGESAHAN	Error! Bookmark not defined.
PERNYATAAN KEASLIAN TULISAN	Error! Bookmark not defined.
MOTTO	iii
HALAMAN PERSEMBAHAN.....	iv
KATA PENGANTAR.....	vii
DAFTAR ISI.....	x
DAFTAR GAMBAR	xiii
DAFTAR TABEL	xiv
ABSTRAK	viii
ABSTRACT	ix
مستخلص البحث.....	x
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	6
1.3 Batasan Masalah	7
1.4 Tujuan Penelitian	7
1.5 Manfaat Penelitian	8
BAB II STUDI PUSTAKA	9
2.1 Penelitian Terkait	9
2.2 Landasan Teori.....	12
2.2.1 Tanaman Melon (<i>Cucumis melo L.</i>)	12
2.2.2 Penyakit Embun Tepung (<i>Podosphaera xanthii</i>)	14
2.2.3 Penyakit Embun Bulu (<i>Pseudoperonospora cubensis</i>).....	15
2.2.4 <i>Preprocessing Citra</i>	16
2.2.5 <i>Deep Learning</i>	18
2.2.6 <i>Convolutional Neural Network (CNN)</i>	20
2.2.7 Data Augmentation.....	22
BAB III METODOLOGI PENELITIAN	26
3.1 Design Sistem	26
3.2 Pengumpulan Dataset	28
3.3 Pelabelan Data	29
3.4 Pembagian Dataset.....	31

3.4.1	Proporsi Pembagian Dataset	31
3.4.2	Metode Pembagian: Stratified Random Split.....	32
3.4.3	Justifikasi Ilmiah Rasio 70:30.....	32
3.4.4	Penghindaran Data Leakage.....	33
3.5	Preprocessing Citra.....	33
3.5.1	Resizing Citra.....	33
3.5.2	Normalisasi Nilai Piksel.....	34
3.6	Data Augmentation	35
3.6.1	Teknik Augmentasi yang Digunakan	36
3.6.2	Konfigurasi Augmentasi per Skenario	38
3.6.3	Justifikasi Brightness Adjustment Tidak Digunakan	39
3.7	Perancangan dan Implementasi Skenario Convolutional Neural Network .	40
3.7.1	Arsitektur CNN	40
3.7.2	Fungsi Aktivasi ReLU.....	41
3.7.3	Lapisan Max-Pooling	41
3.7.4	Flatten dan Fully Connected Layer	42
3.8	Proses Pelatihan (Training Data)	42
3.8.1	Eksperimen Pencarian Augmentasi Terbaik.....	43
3.8.2	Pelatihan Model CNN Final.....	44
3.9	Evaluasi Skenario (Testing Data)	45
BAB IV HASIL DAN PEMBAHASAN.....		49
4.1	Hasil Uji Coba dan Evaluasi.....	49
4.1.1	Hasil Pengujian Skenario Rotation Only	49
4.1.2	Hasil Pengujian Skenario Zoom Only.....	58
4.1.3	Hasil Pengujian Skenario Flip Only.....	62
4.1.4	Hasil Model Final Classification.....	63
4.2	Analisis Pengaruh Data Augmentation	70
4.2.1	Analisis Pengaruh Rotation.....	70
4.2.2	Analisis Pengaruh Zoom	72
4.2.3	Analisis Pengaruh Flip	74
4.2.4	Pemilihan Konfigurasi Augmentasi Terbaik	75
4.3	Integrasi Sains dan Islam	76
BAB V KESIMPULAN DAN SARAN		82
5.1	Kesimpulan	82

5.2	Saran	84
-----	-------------	----

DAFTAR PUSTAKA

DAFTAR GAMBAR

Gambar 3.1 Tahapan Prosedur Penelitian	26
Gambar 3.2 Dokumentasi proses observasi dan validasi pelabelan data	31
Gambar 4.1 Confusion Matrix Test Skenario 45°	50
Gambar 4.2 Per-Class Metrics Test Skenario 45°	51
Gambar 4.3 Final Test Metrics Skenario 45	52
Gambar 4.4 Training History (Accuracy & Loss) Skenario 225°	53
Gambar 4.5 Confusion Matrix Test Skenario 225°	54
Gambar 4.6 Per-Class Metrics dan Final Test Metrics Skenario 225°	54
Gambar 4.7 Training History Skenario 90°	55
Gambar 4.8 Confusion Matrix Test Skenario 90°	56
Gambar 4.9 Confusion Matrix Test Zoom 0%	59
Gambar 4.10 Grafik Akurasi, Loss, Confusion Matrix, dan Per-Class Metrics Skenario Zoom Only	60
Gambar 4.11 Grafik Akurasi, Loss, Confusion Matrix, dan Per-Class Metrics Skenario Flip Only	63
Gambar 4.12 Validation Accuracy dan Validation Loss A vs B	65
Gambar 4.13 Confusion Matrix Skenario A dan B	66
Gambar 4.14 F1-Score Per Kelas Skenario A vs B	68
Gambar 4.15 Perbandingan Metrik Keseluruhan A vs B	69

DAFTAR TABEL

Tabel 2.1 Penelitian Terdahulu.....	11
Tabel 3.1 Spesifikasi Arsitektur CNN.....	41
Tabel 4.1 Perbandingan Metrik Evaluasi Skenario Rotation Only pada Data Uji	49
Tabel 4.2 Perbandingan Metrik Evaluasi Skenario Zoom Only pada Data Uji	58
Tabel 4.3 Perubahan Konfigurasi pada Skenario 3	62
Tabel 4.4 Hasil Evaluasi Model Final Two-Stage Classification pada Data Uji...	64
Tabel 4.5 Hasil Skenario Rotation	70

ABSTRAK

Ramadan, Alhubul Austad. 2026. **Analisis Teknik Augmentasi terhadap Kinerja CNN dalam Klasifikasi Kondisi Daun Melon.** Skripsi. Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Shoffin Nahwa Utama, M.T. (II) Khadijah Fahmi Hayati Holle, M.Kom.

Kata Kunci: Data Augmentation, Convolutional Neural Network, Klasifikasi Citra, Kondisi Daun Melon, Klasifikasi Dua Tahap.

Identifikasi penyakit pada daun melon umumnya masih dilakukan secara visual oleh petani sehingga berpotensi menimbulkan kesalahan identifikasi, terutama pada gejala awal penyakit. Pemanfaatan Convolutional Neural Network (CNN) dapat membantu proses klasifikasi secara otomatis, namun performa model sangat dipengaruhi oleh ketersediaan dan variasi data pelatihan. Penelitian ini bertujuan untuk menganalisis pengaruh teknik data augmentation terhadap kinerja CNN dalam klasifikasi penyakit daun melon. Dataset yang digunakan berjumlah 600 citra yang terdiri atas tiga kelas, yaitu daun sehat, embun tepung, dan embun bulu. Eksperimen dilakukan dengan menguji beberapa variasi augmentasi berupa rotation range, zoom range, dan horizontal flip untuk memperoleh konfigurasi augmentasi yang paling sesuai. Evaluasi model dilakukan menggunakan metrik accuracy, precision, recall, dan F1-score. Hasil penelitian menunjukkan bahwa variasi augmentasi memberikan pengaruh yang berbeda terhadap performa CNN. Pada pengujian rotation range, akurasi tertinggi diperoleh pada sudut rotasi 45° sebesar 77,78%, sedangkan akurasi terendah diperoleh pada rotasi 90° sebesar 33,33%. Pada pengujian zoom range, akurasi tertinggi diperoleh pada rentang zoom 40% sebesar 75,56%, sementara tanpa zoom hanya mencapai 33,33%. Hasil tersebut menunjukkan bahwa augmentasi yang sesuai mampu meningkatkan kemampuan generalisasi model, sedangkan transformasi yang terlalu ekstrem dapat menurunkan performa klasifikasi karena mengubah karakteristik visual penting pada daun melon. Dengan demikian, pemilihan konfigurasi data augmentation yang tepat terbukti berpengaruh terhadap peningkatan kinerja CNN dalam klasifikasi penyakit daun melon.

ABSTRACT

Ramadan, Alhubul Austad. 2026. **Analysis of Data Augmentation Techniques on CNN Performance for Melon Leaf Disease Classification.** Undergraduate Thesis. Department of Informatics Engineering, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University of Malang. Supervisors: (I) Shoffin Nahwa Utama, M.T. (II) Khadijah Fahmi Hayati Holle, M.Kom.

Key words: Data Augmentation, Convolutional Neural Network, Image Classification, Melon Leaf Disease, Two-Stage Classification.

The identification of melon leaf diseases is commonly performed through visual observation by farmers, which may lead to misclassification, particularly during the early stages of disease development. The application of Convolutional Neural Networks (CNNs) offers an automated approach for image classification; however, their performance is highly dependent on the availability and diversity of training data. This study aims to analyze the effect of data augmentation techniques on CNN performance for melon leaf disease classification. The dataset consisted of 600 images belonging to three classes: healthy leaves, powdery mildew, and downy mildew. Experiments were conducted by evaluating several augmentation configurations, including rotation range, zoom range, and horizontal flipping, to determine the most effective augmentation strategy. Model performance was assessed using accuracy, precision, recall, and F1-score metrics. The results demonstrated that different augmentation techniques had varying impacts on CNN performance. In the rotation range experiment, the highest accuracy of 77.78% was achieved at a rotation angle of 45°, while the lowest accuracy of 33.33% was obtained at 90°. In the zoom range experiment, the highest accuracy of 75.56% was achieved with a zoom range of 40%, whereas the model without zoom augmentation achieved only 33.33%. These findings indicate that appropriate augmentation techniques can improve the model's generalization capability, while excessive transformations may degrade classification performance by altering important visual characteristics of melon leaves. Therefore, the selection of suitable data augmentation configurations plays a significant role in enhancing CNN performance for melon leaf disease classification.

مستخلص البحث

رمضان، الحبول أستاذ. الحبول أستاذ.. تحليل تقنيات زيادة البيانات على أداء الشبكات العصبية الالتفافية مالانغ ، ٢٠٢٦. تحليل تقنيات زيادة البيانات على أداء الشبكات العصبية الالتفافية الشبكة العصبية الالتفافية في تصنيف حالات أوراق الشمام. رسالة جامعية. قسم هندسة المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك . إبراهيم الإسلامية الحكومية مالانغ ، المشرفان (1) شوفين نھوا أوتاما، ماجستير هندسة. (2) خديجة ف. ه. هولّي . ماجستير حاسوب

الكلمات المفتاحية: زيادة البيانات، الشبكات العصبية الالتفافية، تصنيف الصور، حالات أوراق الشمام، التصنيف ثنائي المراحل.

عادةً ما يتم التعرف على أمراض أوراق الشمام بصرياً من قبل المزارعين، وهي عملية عرضة للتشخيص الخاطئ، لا سيما في المراحل المبكرة من المرض. ورغم أن الشبكات العصبية التلافيفية يمكن أن تسهل عملية التصنيف الآلي، إلا أن أداء النموذج يعتمد بشكل كبير على توفر بيانات التدريب وتنوعها. تهدف هذه الدراسة إلى تحليل تأثير تقنيات تعزيز البيانات (زيادة البيانات) على أداء الشبكات العصبية التلافيفية في تصنيف أمراض أوراق الشمام. تتكون مجموعة البيانات من ٦٠٠ صورة موزعة على ثلاث فئات أوراق سليمة، وبياض دقيق، وبياض زغبي. وشملت التجارب اختبار معاملات تعزيز مختلفة - وتحديدًا نطاق التدوير، ونطاق (accuracy) التكبير/التصغير، والقلب الأفقي - لتحديد الإعداد الأمثل. وقد تم تقييم النموذج باستخدام المقاييس التالية: الدقة وتشير النتائج إلى أن خيارات التعزيز المختلفة (F1 (F1-score) ومقياس (recall) والاستدعاء (precision) والإحكام تؤثر بشكل كبير على أداء الشبكة العصبية التلافيفية؛ ففيما يتعلق بنطاق التدوير، تم تحقيق أعلى دقة (77.78%) عند تدوير بزوايا ٤٥ درجة، بينما لوحظت أقل دقة (33.33%) عند زاوية ٩٠ درجة. أما بالنسبة لنطاق التكبير/التصغير، فقد تم الوصول إلى أقصى دقة (75.56%) عند نطاق 40%، في حين أن عدم استخدام التكبير أدى إلى دقة بلغت 33.33% فقط. وتُظهر هذه النتائج ؛ وفي المقابل، يمكن للتحويلات المفرطة أن تضعف أداء (generalization) أن التعزيز المناسب يعزز قدرة النموذج على التعميم التصنيف من خلال تغيير الخصائص البصرية الجوهرية لأوراق الشمام. ومن ثم، فإن اختيار إعداد مناسب لتعزيز البيانات يحسن أداء... الشبكات العصبية التلافيفية في تصنيف أمراض أوراق الشمام

BAB I

PENDAHULUAN

1.1 Latar Belakang

Melon (*Cucumis melo L.*) merupakan komoditas hortikultura strategis yang memberikan kontribusi penting bagi pendapatan petani dan nilai tambah subsektor pertanian nasional sehingga memerlukan pengelolaan budidaya yang intensif. Data sekunder menunjukkan bahwa produksi melon nasional mengalami fluktuasi pada periode 2018–2021 dengan angka produksi tercatat pada level puluhan ribu ton, yang mengindikasikan kebutuhan pengelolaan yang lebih terarah untuk menjaga kesinambungan produksi. Tekanan dari serangan penyakit tanaman, seperti infeksi oleh patogen jamur dan virus, berdampak negatif terhadap kuantitas serta mutu hasil panen sehingga memperbesar risiko kerugian ekonomi bagi petani komersial dan skala rumah tangga. Oleh karena itu, praktik budidaya melon menuntut kontrol terpadu terhadap faktor lingkungan meliputi pengelolaan air, suhu, kelembapan, pencahayaan, nutrisi, dan pH media serta strategi manajemen penyakit yang tepat waktu sebagai upaya mitigasi kerugian produksi. Konsekuensinya, pengembangan metode deteksi dini berbasis teknologi menjadi langkah strategis untuk meningkatkan ketepatan intervensi agronomis dan mempertahankan mutu buah di tingkat produksi.

Penyakit daun yang disebabkan oleh *Podosphaera xanthii* (embun tepung) dan *Pseudoperonospora cubensis* (embun bulu) merupakan kendala utama pada budidaya melon karena keduanya menyerang organ fotosintetik sehingga mengurangi kapasitas tanaman untuk menghasilkan energi biologis. Penelitian

mutakhir menunjukkan bahwa infeksi *Pseudoperonospora cubensis* berdampak signifikan terhadap fungsi fotosintesis dan dapat menyebabkan penurunan hasil panen yang substansial pada anggota keluarga *Cucurbitaceae* (Mirzwa-Mróz et al., 2024). Studi eksperimental juga melaporkan bahwa serangan embun tepung secara langsung mengganggu parameter fotosintetik dan struktur mikro daun sehingga menurunkan efisiensi penangkapan cahaya dan kualitas jaringan daun (Tian et al., 2024). Bukti empiris dari kajian agronomi memperlihatkan bahwa kegagalan dalam pengendalian penyakit foliar dapat berujung pada kehilangan hasil yang besar, termasuk penurunan bobot buah dan kadar padatan terlarut total yang memengaruhi mutu komersial produk (Keinath, 2022). Kondisi-kondisi agronomis ini menegaskan urgensi pengembangan metode deteksi dini yang sensitif dan andal untuk memitigasi kerugian produksi pada budidaya melon.

Diagnosis penyakit tanaman di lapang umumnya masih bergantung pada inspeksi visual manual yang dilakukan oleh petani atau teknisi lapangan sehingga bersifat subjektif dan rentan kesalahan. Kajian komparatif menyatakan bahwa metode tradisional tersebut memerlukan keterampilan khusus, memakan waktu, dan kerap tidak sensitif terhadap gejala pada fase awal infeksi sehingga mengurangi efektivitas manajemen penyakit (Demilie, 2024). Analisis metodologis lebih lanjut menunjukkan bahwa ketergantungan pada pengamatan manusia menyebabkan keterlambatan dalam pengambilan keputusan agronomis dan meningkatkan risiko penerapan tindakan pengendalian yang tidak tepat atau terlambat (Xia et al., 2022). Dampak operasional dari keterbatasan ini mencakup peningkatan biaya pemantauan, intensitas tenaga kerja yang tinggi, dan ketidakmampuan untuk

melakukan monitoring skala besar secara kontinu pada lahan yang luas. Oleh karena itu, Oleh karena itu, diperlukan pendekatan berbasis pengolahan citra digital yang mampu membantu proses identifikasi penyakit daun secara lebih konsisten dan objektif dibandingkan pengamatan visual manual.

Convolutional Neural Network (CNN) merupakan metode *deep learning* yang efektif dalam klasifikasi penyakit tanaman berbasis citra karena kemampuannya melakukan ekstraksi fitur visual secara otomatis dari gambar daun. Berbagai penelitian menunjukkan bahwa CNN mampu mencapai tingkat akurasi yang tinggi pada tugas identifikasi penyakit tanaman, meskipun tetap memerlukan desain dataset dan strategi pelatihan yang tepat untuk menjaga kemampuan generalisasi pada kondisi lapang yang beragam (Khan et al., 2023; Mahmood ur Rehman et al., 2024). Dalam praktiknya, performa skenario CNN sangat dipengaruhi oleh kualitas dan jumlah dataset yang digunakan dalam proses pelatihan. Dataset yang terbatas seringkali menyebabkan skenario mengalami *overfitting* sehingga performanya menurun ketika diuji pada data baru. Oleh karena itu, strategi pengolahan data yang tepat diperlukan agar skenario tetap mampu mempelajari pola penyakit daun secara optimal meskipun menggunakan dataset dengan jumlah yang relatif terbatas.

Salah satu pendekatan yang banyak digunakan untuk mengatasi keterbatasan dataset pada pelatihan skenario *deep learning* adalah teknik *data augmentation*. Data augmentation merupakan proses penambahan variasi pada dataset dengan memodifikasi citra asli melalui transformasi tertentu seperti rotasi, pembalikan, perubahan skala, maupun penyesuaian tingkat kecerahan. Teknik ini

memungkinkan skenario memperoleh variasi data pelatihan yang lebih beragam tanpa harus melakukan pengumpulan data tambahan secara langsung. Penelitian sebelumnya menunjukkan bahwa penerapan *data augmentation* dapat membantu meningkatkan kemampuan generalisasi skenario CNN serta mengurangi risiko *overfitting* pada dataset dengan jumlah terbatas (Mahmood ur Rehman et al., 2024). Oleh karena itu, pemanfaatan teknik data augmentation menjadi strategi penting dalam pengembangan skenario klasifikasi penyakit tanaman berbasis citra.

Dataset pada penelitian ini dikumpulkan secara mandiri melalui proses akuisisi citra daun melon menggunakan kamera pada lingkungan budidaya. Strategi ini dipilih untuk memastikan kesesuaian kondisi visual dengan konteks agroekosistem lokal serta mengurangi bias domain yang sering muncul pada penggunaan dataset publik yang diambil dalam kondisi laboratorium terkontrol. Literatur menunjukkan bahwa penggunaan dataset lokal dengan variasi pencahayaan, sudut pengambilan, serta kondisi latar belakang yang beragam dapat meningkatkan validitas eksternal skenario pada kondisi lapang nyata (Mahmood ur Rehman et al., 2024). Dataset dalam penelitian ini diklasifikasikan ke dalam tiga kelas target, yaitu daun sehat, embun tepung (*Podosphaera xanthii*), dan embun bulu (*Pseudoperonospora cubensis*), dengan prosedur anotasi terstandarisasi untuk menjaga konsistensi label antar sampel.

Dalam perspektif Islam, manusia diberi amanah sebagai khalifah untuk menjaga keberlanjutan bumi dan mengelola sumber daya alam secara bertanggung jawab. Allah SWT berfirman dalam QS. Al-An‘am ayat 141:

وَهُوَ الَّذِي أَنشَأَ جَنَّاتٍ مَّعْرُوسَاتٍ وَعَظِيرَ مَعْرُوسَاتٍ وَالنَّخْلَ وَالزَّرْعَ مُخْتَلِفًا أَكْثَرَهُ ۖ وَالزَّيْتُونَ وَالرُّمَّانَ مُشَاشًا وَعَظِيرَ مَشَاشٍ ۚ كُلُوا مِنْ ثَمَرِهِ ۖ إِذَا أَثْمَرَ وَآتُوا حَقَّهُ ۖ يَوْمَ حَصَادِهِ ۖ وَلَا تُسْرِفُوا ۚ إِنَّهُ لَا يُحِبُّ الْمُسْرِفِينَ (141)

“Dialah yang menumbuhkan tanaman-tanaman yang merambat dan yang tidak merambat, pohon kurma, tanaman yang beraneka ragam rasanya, serta zaitun dan delima yang serupa (bentuk dan warnanya) dan tidak serupa (rasanya). Makanlah buahnya apabila ia berbuah dan berikanlah haknya (zakatnya) pada waktu memetik hasilnya. Akan tetapi, janganlah berlebih-lebihan. Sesungguhnya Allah tidak menyukai orang-orang yang berlebih-lebihan.” (QS. Al-An’am [6]:141).

Penafsiran kontemporer menegaskan bahwa ayat ini merupakan landasan teologis bagi etika pemanfaatan hasil pertanian secara proporsional dan berkelanjutan (Rahmawati, 2021). Kajian eco-theology Islam juga menghubungkan tanggung jawab ekologis manusia dengan prinsip pencegahan kerusakan (dar’ul mafasid) dan larangan pemborosan (israf) dalam praktik pertanian modern (Hidayat, 2020). Dalam konteks ini, Dalam konteks ini, pemanfaatan metode klasifikasi citra berbasis kecerdasan buatan dapat menjadi salah satu pendekatan untuk membantu analisis kondisi kesehatan daun tanaman secara lebih sistematis.

Meskipun berbagai penelitian telah mengevaluasi CNN untuk klasifikasi penyakit tanaman, sebagian besar studi masih terfokus pada penggunaan dataset publik seperti PlantVillage dan belum banyak yang menguji performa skenario pada dataset lokal dengan kondisi agroekosistem tropis yang beragam. Selain itu, kajian mengenai pengaruh teknik *data augmentation* terhadap performa skenario CNN pada dataset penyakit daun melon yang terbatas masih relatif terbatas dalam literatur terkini. Kesenjangan ini menunjukkan perlunya penelitian yang tidak hanya mengevaluasi kinerja skenario CNN, tetapi juga menganalisis bagaimana

penerapan berbagai teknik augmentasi dapat mempengaruhi performa klasifikasi pada dataset yang berasal dari kondisi budidaya nyata.

Penelitian mengenai aplikasi CNN dalam deteksi penyakit tanaman memang telah menunjukkan pertumbuhan publikasi yang pesat, tetapi penelitian spesifik yang berfokus pada penyakit daun melon dengan dataset lokal masih sangat terbatas. Kajian *bibliometrik* terkini mengidentifikasi bahwa sebagian besar penelitian CNN untuk klasifikasi penyakit tanaman masih terkonsentrasi pada domain dataset publik dan belum banyak divalidasi pada kondisi lapang dengan karakteristik agroekosistem tropis seperti di Indonesia (Miller et al., 2025). Penelitian lanjutan juga menunjukkan bahwa kekurangan representasi data lokal dapat menurunkan performa skenario dan menyebabkan degradasi akurasi ketika skenario digunakan pada lingkungan nyata yang memiliki variasi kondisi pencahayaan, latar belakang, serta morfologi daun yang berbeda (El Sakka et al., 2025). Oleh karena itu, penelitian ini bertujuan untuk menganalisis pengaruh teknik data augmentation terhadap kinerja skenario Convolutional Neural Network dalam klasifikasi kondisi daun melon menggunakan dataset citra yang diperoleh dari lingkungan budidaya.

1.2 Rumusan Masalah

Bagaimana pengaruh variasi teknik data augmentation terhadap performa skenario Convolutional Neural Network (CNN) dalam klasifikasi tiga kondisi daun melon yaitu daun sehat, embun tepung (*Podosphaera xanthii*), dan embun bulu (*Pseudoperonospora cubensis*)?

1.3 Batasan Masalah

Agar penelitian ini lebih terarah dan sesuai dengan ruang lingkup kajian, batasan masalah ditetapkan sebagai berikut.

1. Kelas citra yang digunakan dibatasi pada tiga kategori, yaitu daun melon sehat, daun terdampak embun tepung (*Podosphaera xanthii*), dan daun terdampak embun bulu (*Pseudoperonospora cubensis*).
2. Dataset citra diperoleh melalui proses pengambilan gambar secara mandiri pada lingkungan budidaya melon menggunakan *handphone*, kemudian dilakukan proses labeling dan anotasi secara terstandarisasi untuk memastikan konsistensi data pada setiap kelas.
3. Penelitian ini menerapkan beberapa teknik data augmentation, seperti *rotation*, *flip*, *zoom*, dan *brightness adjustment*, yang digunakan untuk meningkatkan variasi data pelatihan dan mengurangi risiko *overfitting* pada skenario CNN.
4. Evaluasi performa skenario dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*, serta dibatasi pada analisis pengaruh penerapan teknik data augmentation terhadap kinerja skenario CNN, tanpa membahas implementasi sistem IoT, optimasi perangkat keras, maupun integrasi sistem deteksi pada lingkungan budidaya secara langsung.

1.4 Tujuan Penelitian

Penelitian ini bertujuan untuk menganalisis pengaruh variasi teknik data augmentation terhadap performa skenario Convolutional Neural Network (CNN) dalam klasifikasi tiga kondisi daun melon yaitu daun sehat, embun tepung

(*Podosphaera xanthii*), dan embun bulu (*Pseudoperonospora cubensis*) pada dataset citra yang terbatas.

1.5 Manfaat Penelitian

Sesuai Hasil penelitian ini diharapkan dapat memberikan manfaat sebagai berikut.

1. Bagi peneliti, penelitian ini menjadi sarana untuk meningkatkan pemahaman dan kemampuan dalam penerapan metode Convolutional Neural Network (CNN) serta analisis pengaruh data augmentation pada klasifikasi citra penyakit tanaman.
2. Bagi petani dan praktisi pertanian, hasil penelitian ini diharapkan dapat menjadi referensi dalam pengembangan sistem klasifikasi penyakit daun melon berbasis citra digital untuk membantu proses identifikasi kondisi daun secara lebih cepat dan konsisten.
3. Bagi akademisi dan peneliti selanjutnya, penelitian ini dapat menjadi referensi dalam pengembangan skenario CNN dan penerapan teknik data augmentation pada klasifikasi penyakit tanaman menggunakan dataset terbatas.
4. Bagi masyarakat luas, penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan pemanfaatan teknologi kecerdasan buatan berbasis pengolahan citra pada bidang pertanian.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terkait

Penelitian oleh Sholikhin dan Alexandro. (2022) mengembangkan sistem klasifikasi penyakit pada daun melon menggunakan metode *Convolutional Neural Network* (CNN) berbasis pengolahan citra digital. Dataset yang digunakan dalam penelitian tersebut terdiri dari 5000 citra daun melon yang dibagi ke dalam lima kelas, yaitu daun melon sehat, daun melon embun bulu, daun melon embun tepung, daun melon virus gemini, dan bukan daun melon. Proses pengambilan citra dilakukan secara langsung di perkebunan melon di Kecamatan Sugio menggunakan kamera smartphone dan kamera digital. Skenario CNN yang dikembangkan mampu melakukan klasifikasi penyakit daun melon dengan tingkat akurasi sebesar 89% pada aplikasi komputer dan 90% pada aplikasi berbasis smartphone. Hasil penelitian tersebut menunjukkan bahwa metode CNN memiliki kemampuan yang baik dalam mengenali pola visual penyakit daun melon serta dapat dimanfaatkan sebagai sistem klasifikasi penyakit tanaman berbasis citra digital.

Penelitian lain yang relevan dilakukan oleh Sholikhin (2022) yang juga mengkaji penerapan metode *Convolutional Neural Network* untuk klasifikasi penyakit pada citra daun melon. Penelitian tersebut memanfaatkan dataset citra daun melon yang diperoleh dari proses pengambilan gambar di lapangan dengan distribusi data yang seimbang pada setiap kelas penyakit. Dalam penelitian tersebut dilakukan tahapan preprocessing, proses pelatihan skenario CNN, serta pengujian sistem klasifikasi menggunakan data uji untuk mengevaluasi performa skenario.

Hasil pengujian menunjukkan bahwa skenario CNN mampu mengidentifikasi beberapa jenis penyakit daun melon dengan tingkat akurasi yang cukup tinggi, sehingga pendekatan berbasis *deep learning* dinilai efektif dalam membantu proses identifikasi penyakit tanaman secara otomatis melalui citra daun.

Penelitian mengenai klasifikasi penyakit tanaman menggunakan metode *Convolutional Neural Network* juga dilakukan oleh Mohanty et al. (2016) yang memanfaatkan dataset PlantVillage untuk mendeteksi berbagai penyakit pada tanaman menggunakan citra daun. Penelitian tersebut menggunakan lebih dari 50.000 citra daun tanaman yang mencakup berbagai jenis tanaman dan kondisi penyakit. Skenario CNN yang dikembangkan dalam penelitian tersebut mampu mencapai tingkat akurasi klasifikasi hingga lebih dari 99% pada proses pengujian. Hasil penelitian ini menunjukkan bahwa metode CNN memiliki kemampuan yang sangat baik dalam mengekstraksi fitur visual pada citra daun sehingga mampu membedakan kondisi tanaman sehat dan tanaman yang terinfeksi penyakit dengan tingkat ketepatan yang tinggi.

Berdasarkan beberapa penelitian terdahulu tersebut dapat diketahui bahwa pendekatan *deep learning*, khususnya menggunakan metode *Convolutional Neural Network* (CNN), telah banyak digunakan dalam penelitian klasifikasi penyakit tanaman berbasis citra daun dan terbukti mampu menghasilkan performa klasifikasi yang cukup baik. Namun demikian, sebagian besar penelitian sebelumnya menggunakan dataset dengan jumlah yang relatif besar untuk memperoleh performa skenario yang optimal. Dalam praktik di lapangan, proses pengumpulan dataset citra tanaman sering kali memiliki keterbatasan jumlah data karena

dipengaruhi oleh kondisi lingkungan, ketersediaan tanaman yang terinfeksi penyakit tertentu, serta proses anotasi data yang memerlukan validasi dari praktisi atau pakar pertanian. Oleh karena itu, diperlukan pendekatan yang dapat meningkatkan performa skenario CNN meskipun menggunakan dataset dengan jumlah yang lebih terbatas. Salah satu pendekatan yang dapat digunakan adalah teknik *data augmentation*, yaitu proses menghasilkan variasi citra baru dari dataset yang ada melalui transformasi tertentu seperti *rotasi*, *flipping*, *zoom*, dan perubahan tingkat pencahayaan. Dengan demikian, penelitian ini difokuskan pada analisis pengaruh penerapan teknik *data augmentation* terhadap kinerja skenario *Convolutional Neural Network* dalam klasifikasi kondisi daun melon.

Tabel 2.1 Penelitian Terdahulu

Judul Penelitian	Hasil Penelitian	Persamaan	Perbedaan
Klasifikasi Penyakit pada Citra Daun Melon Menggunakan Convolutional Neural Network	Skenario CNN mampu mengklasifikasikan kondisi daun melon dengan akurasi sekitar 89–90% berdasarkan citra yang diambil dari lapangan.	Sama-sama menggunakan CNN untuk kondisi penyakit daun melon.	Penelitian ini fokus pada klasifikasi, sedangkan penelitian yang dilakukan menganalisis pengaruh data augmentation pada dataset terbatas.
Klasifikasi Penyakit pada Citra Daun Melon Menggunakan Deep Learning	Skenario CNN dapat mengidentifikasi kondisi daun melon dan penyakitnya dengan akurasi yang cukup baik melalui proses pelatihan skenario.	Sama-sama menggunakan <i>deep learning</i> berbasis CNN untuk klasifikasi citra daun.	Tidak membahas peningkatan performa skenario, sedangkan penelitian ini menambahkan analisis data augmentation.
Using Deep Learning for Image-Based Plant Disease Detection	CNN mencapai akurasi lebih dari 99% menggunakan dataset besar (PlantVillage) dengan berbagai jenis tanaman.	Sama-sama menggunakan CNN untuk klasifikasi penyakit tanaman.	Menggunakan dataset besar, sedangkan penelitian ini menggunakan dataset terbatas dengan augmentasi.
Deep Learning for Plant Disease Detection Using Convolutional Neural Networks	CNN mampu mengekstraksi fitur citra daun secara otomatis dan menghasilkan akurasi klasifikasi yang tinggi.	Sama-sama menggunakan CNN dalam deteksi penyakit tanaman berbasis citra.	Fokus pada performa umum CNN, sedangkan penelitian ini menganalisis pengaruh augmentasi terhadap performa skenario.

Judul Penelitian	Hasil Penelitian	Persamaan	Perbedaan
Image-Based Plant Disease Detection Using <i>Deep Learning</i> Techniques	Deep learning meningkatkan akurasi klasifikasi penyakit tanaman melalui pengolahan citra daun dan preprocessing data.	Sama-sama menggunakan deep learning dan citra daun untuk deteksi penyakit.	Bersifat umum, sedangkan penelitian ini fokus pada daun melon dan analisis data <i>augmentation</i> .
Analisis Teknik Augmentasi terhadap Kinerja CNN dalam Klasifikasi Kondisi Daun Melon	Penelitian ini menganalisis pengaruh teknik data augmentation berupa rotation, zoom, dan flip terhadap kinerja CNN dalam klasifikasi kondisi daun melon yang terdiri atas tiga kelas, yaitu sehat, embun tepung, dan embun bulu.	Sama-sama menggunakan metode Convolutional Neural Network (CNN) untuk melakukan klasifikasi citra daun tanaman serta memanfaatkan teknik data augmentation untuk meningkatkan performa model.	Penelitian ini berfokus pada analisis pengaruh setiap variabel augmentasi secara terpisah menggunakan pendekatan One Variable At a Time (OVAT) pada dataset lokal daun melon, serta mengevaluasi implementasi konfigurasi augmentasi terbaik pada model CNN final dengan klasifikasi tiga kelas.

2.2 Landasan Teori

Landasan teori dalam penelitian ini memuat konsep-konsep ilmiah yang menjadi dasar dalam pengembangan sistem klasifikasi penyakit daun melon berbasis *Convolutional Neural Network* (CNN). Kajian teori meliputi aspek biologis tanaman dan penyakit daun, prinsip pengolahan citra digital, konsep dan arsitektur CNN dengan memaksimalkan augmentasi, serta parameter evaluasi kinerja mode.

2.2.1 Tanaman Melon (*Cucumis melo L.*)

Melon (*Cucumis melo L.*) merupakan tanaman hortikultura dari famili Cucurbitaceae yang dibudidayakan secara luas di daerah tropis dan subtropis karena memiliki nilai ekonomi tinggi serta permintaan pasar yang stabil. Tanaman ini termasuk tipe semusim dengan sistem perakaran dangkal, batang merambat, serta

daun tunggal berbentuk menjari dengan permukaan relatif lebar dan berwarna hijau. Secara morfologis, daun melon berperan sebagai organ fotosintesis utama yang menentukan akumulasi biomassa dan kualitas buah yang dihasilkan. Struktur permukaan daun yang luas menjadikan daun sebagai bagian tanaman yang paling sering terpapar langsung oleh lingkungan, sehingga rentan terhadap serangan patogen penyebab penyakit.

Secara fisiologis, produktivitas tanaman melon sangat dipengaruhi oleh efisiensi proses fotosintesis yang berlangsung pada jaringan daun. Gangguan pada jaringan daun akibat infeksi patogen dapat menurunkan laju fotosintesis, mempercepat kerusakan jaringan, serta berdampak pada penurunan kualitas dan kuantitas hasil panen (Tian et al., 2024). Selain itu, kondisi lingkungan seperti kelembapan dan suhu juga berperan penting dalam memicu perkembangan penyakit daun, khususnya pada tanaman dari famili Cucurbitaceae yang cenderung sensitif terhadap perubahan kondisi mikroklimat (Mirzwa-Mróz et al., 2024).

Dari aspek morfologi, daun melon memiliki karakteristik permukaan yang memungkinkan terjadinya interaksi langsung dengan patogen, terutama pada kondisi kelembapan tinggi. Keberadaan stomata serta struktur jaringan daun yang relatif tipis meningkatkan potensi penetrasi patogen ke dalam jaringan tanaman. Hal ini menyebabkan tanaman melon menjadi rentan terhadap penyakit foliar yang dapat berkembang dengan cepat jika tidak ditangani secara tepat (Keinath, 2022). Oleh karena itu, identifikasi kondisi kesehatan daun menjadi langkah penting dalam menjaga produktivitas tanaman.

Berdasarkan karakteristik morfologi dan fisiologinya, daun melon merupakan objek yang relevan untuk penelitian klasifikasi penyakit berbasis citra. Gejala infeksi pada daun umumnya ditunjukkan melalui perubahan visual seperti warna, tekstur, dan pola bercak yang dapat diamati secara langsung. Karakteristik visual tersebut memungkinkan pemanfaatan teknik pengolahan citra digital dan metode Convolutional Neural Network untuk mengidentifikasi kondisi kesehatan daun secara otomatis. Oleh karena itu, pemilihan tanaman melon sebagai objek penelitian memiliki dasar ilmiah yang kuat dalam pengembangan sistem klasifikasi penyakit berbasis citra.

2.2.2 Penyakit Embun Tepung (*Podosphaera xanthii*)

Embun Embun tepung (*Podosphaera xanthii*) merupakan salah satu penyakit utama pada tanaman melon yang disebabkan oleh jamur patogen dari kelompok Ascomycetes. Penyakit ini umumnya menyerang bagian daun, batang, dan permukaan tanaman lainnya, terutama pada kondisi lingkungan dengan kelembapan relatif tinggi dan sirkulasi udara yang kurang baik. Infeksi embun tepung dapat terjadi pada berbagai fase pertumbuhan tanaman dan berpotensi berkembang dengan cepat apabila tidak dilakukan pengendalian secara tepat.

Secara visual, gejala embun tepung ditandai dengan munculnya lapisan putih seperti tepung pada permukaan daun. Lapisan tersebut merupakan kumpulan miselium dan spora jamur yang berkembang di jaringan permukaan daun. Gejala ini umumnya mulai terlihat beberapa hari setelah infeksi dan akan semakin meluas seiring dengan perkembangan patogen (Kuzuya et al., 2006). Seiring dengan perkembangan penyakit, permukaan daun dapat mengalami perubahan warna

menjadi kekuningan hingga kecoklatan dan diikuti dengan kerusakan jaringan daun.

Dari sisi fisiologis, infeksi embun tepung dapat menghambat proses fotosintesis karena menutupi permukaan daun serta merusak struktur jaringan yang berperan dalam penyerapan cahaya. Kondisi ini menyebabkan penurunan pertumbuhan tanaman dan berdampak pada kualitas serta kuantitas hasil panen. Penelitian menunjukkan bahwa serangan embun tepung dapat menyebabkan kerugian signifikan pada produksi tanaman melon jika tidak ditangani secara optimal (Daryono & Qurrohman, 2009).

Karakteristik visual berupa lapisan putih yang kontras dengan warna hijau daun menjadikan penyakit embun tepung relatif mudah dikenali melalui citra digital. Pola visual tersebut dapat dimanfaatkan sebagai fitur dalam proses klasifikasi menggunakan metode Convolutional Neural Network, sehingga memungkinkan identifikasi penyakit dilakukan secara otomatis berdasarkan citra daun.

2.2.3 Penyakit Embun Bulu (*Pseudoperonospora cubensis*)

Embun bulu (*Pseudoperonospora cubensis*) merupakan penyakit pada tanaman melon yang disebabkan oleh patogen dari kelompok oomycetes. Penyakit ini berkembang pada kondisi lingkungan dengan kelembapan tinggi, suhu relatif rendah, serta adanya air bebas pada permukaan daun. Infeksi embun bulu umumnya terjadi pada daun dan dapat menyebar dengan cepat melalui spora yang terbawa oleh angin maupun percikan air.

Gejala awal embun bulu ditandai dengan munculnya bercak berwarna kuning pucat atau klorotik pada permukaan atas daun. Seiring perkembangan infeksi, bercak tersebut akan berubah menjadi coklat hingga kehitaman dengan pola yang tidak beraturan. Pada bagian bawah daun, sering ditemukan lapisan berwarna abu-abu hingga keunguan yang merupakan struktur sporulasi patogen (Wallace et al., 2014). Perubahan visual ini menunjukkan adanya kerusakan jaringan daun yang cukup signifikan.

Secara fisiologis, infeksi embun bulu dapat mengganggu proses fotosintesis karena menyebabkan kerusakan jaringan daun serta menurunkan luas daun yang aktif. Penyakit ini juga dapat mempercepat proses gugurnya daun dan berdampak langsung terhadap penurunan produktivitas tanaman melon. Oleh karena itu, deteksi dini terhadap penyakit ini sangat penting untuk mencegah penyebaran yang lebih luas dan kerugian hasil panen (Ariyan, 2025).

Dari perspektif pengolahan citra, embun bulu memiliki karakteristik visual berupa perubahan warna dari hijau menjadi kuning hingga coklat dengan pola bercak yang tidak beraturan. Variasi warna dan tekstur tersebut dapat dimanfaatkan sebagai fitur dalam proses klasifikasi citra menggunakan metode Convolutional Neural Network, sehingga skenario dapat membedakan kondisi daun berdasarkan pola visual yang terbentuk.

2.2.4 Preprocessing Citra

Preprocessing citra merupakan tahapan awal dalam pengolahan data citra yang bertujuan untuk meningkatkan kualitas data sebelum digunakan dalam proses pelatihan skenario *Convolutional Neural Network* (CNN). Tahapan ini berperan

penting dalam memastikan bahwa data yang digunakan memiliki format yang konsisten serta meminimalkan gangguan yang dapat memengaruhi kinerja skenario. Dalam konteks klasifikasi citra daun tanaman, *preprocessing* menjadi langkah krusial karena citra yang diperoleh dari lingkungan nyata umumnya memiliki variasi dalam ukuran, pencahayaan, dan kondisi latar belakang (Shorten & Khoshgoftaar, 2019; Khan et al., 2023).

Salah satu tahapan utama dalam *preprocessing* adalah proses resizing, yaitu penyesuaian ukuran citra menjadi dimensi yang seragam. Proses ini diperlukan karena skenario CNN membutuhkan input dengan ukuran yang konsisten agar proses pelatihan dapat berjalan optimal. Selain itu, penggunaan ukuran citra yang lebih kecil juga dapat mengurangi kompleksitas komputasi tanpa menghilangkan informasi penting dari citra (Khan et al., 2023). Oleh karena itu, pemilihan ukuran citra yang tepat menjadi faktor penting dalam menjaga keseimbangan antara efisiensi dan kualitas informasi visual.

Tahapan berikutnya adalah normalisasi citra, yang bertujuan untuk menyamakan skala nilai piksel sehingga berada dalam rentang tertentu, umumnya antara 0 hingga 1. Normalisasi membantu mempercepat proses konvergensi selama pelatihan skenario serta meningkatkan stabilitas pembelajaran. Dengan distribusi nilai piksel yang lebih terkontrol, skenario CNN dapat mempelajari pola fitur dengan lebih efektif dan mengurangi risiko terjadinya bias terhadap nilai intensitas tertentu (Goodfellow et al., 2021).

Selain itu, *preprocessing* juga dapat mencakup proses pembersihan data (*data cleaning*), seperti menghapus citra yang memiliki kualitas buruk, kabur, atau tidak

relevan dengan objek penelitian. Kualitas dataset sangat berpengaruh terhadap performa skenario, sehingga keberadaan data yang tidak *representatif* dapat menurunkan kemampuan skenario dalam melakukan generalisasi. Penelitian menunjukkan bahwa kualitas data memiliki peran yang sama pentingnya dengan arsitektur skenario dalam menentukan keberhasilan sistem klasifikasi berbasis *deep learning* (Mahmood et al., 2022).

Berdasarkan tahapan-tahapan tersebut, *preprocessing* citra dalam penelitian ini mencakup proses penyeragaman ukuran citra (*resizing*) dan normalisasi nilai piksel sebagai langkah utama sebelum data digunakan dalam proses pelatihan skenario CNN. Tahapan ini bertujuan untuk menghasilkan dataset yang lebih terstruktur dan siap digunakan dalam proses pembelajaran skenario, sehingga dapat meningkatkan performa klasifikasi pada data citra daun melon.

2.2.5 Deep Learning

Deep Learning merupakan salah satu cabang dari *Machine Learning* yang menggunakan jaringan saraf tiruan (*artificial neural networks*) dengan banyak lapisan (*deep neural networks*) untuk mempelajari representasi data secara otomatis. Metode ini dirancang untuk mengekstraksi fitur dari data dalam jumlah besar tanpa memerlukan proses rekayasa fitur secara manual. Dalam beberapa tahun terakhir, *Deep Learning* telah menunjukkan performa yang sangat baik dalam berbagai bidang, khususnya pada pengolahan citra, pengenalan pola, dan klasifikasi objek (LeCun et al., 2015; Goodfellow et al., 2021).

Keunggulan utama *Deep Learning* dibandingkan metode tradisional terletak pada kemampuannya dalam melakukan ekstraksi fitur secara otomatis dari data

mentah. Pada metode konvensional, proses ekstraksi fitur biasanya dilakukan secara manual berdasarkan karakteristik tertentu seperti warna, tekstur, atau bentuk. Namun, pendekatan tersebut memiliki keterbatasan dalam menangani variasi data yang kompleks. *Deep Learning* mampu mengatasi keterbatasan tersebut dengan mempelajari fitur secara hierarkis, mulai dari fitur sederhana hingga fitur yang lebih kompleks, sehingga menghasilkan representasi data yang lebih akurat (Mahmood et al., 2022).

Dalam konteks pengolahan citra, *Deep Learning* menjadi pendekatan yang sangat efektif karena mampu mengenali pola visual yang sulit didefinisikan secara *eksplisit*. Hal ini sangat relevan dalam klasifikasi penyakit tanaman berbasis citra daun, di mana perbedaan antara kondisi sehat dan terinfeksi sering kali ditunjukkan melalui variasi warna, tekstur, dan pola bercak yang kompleks. Oleh karena itu, penggunaan *Deep Learning* memungkinkan skenario untuk mempelajari karakteristik visual tersebut secara langsung dari data citra yang digunakan.

Salah satu arsitektur *Deep Learning* yang paling banyak digunakan dalam pengolahan citra adalah *Convolutional Neural Network* (CNN). Arsitektur ini dirancang khusus untuk menangani data berbentuk citra dengan memanfaatkan operasi konvolusi dalam proses ekstraksi fitur. Dalam penelitian ini, metode CNN digunakan sebagai pendekatan utama dalam melakukan klasifikasi penyakit daun melon karena kemampuannya dalam mengidentifikasi pola visual secara efektif dan efisien.

2.2.6 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu arsitektur *Deep Learning* yang dirancang khusus untuk pengolahan data berbentuk citra. CNN memiliki kemampuan untuk mengekstraksi fitur secara otomatis melalui operasi konvolusi, sehingga sangat efektif dalam mengenali pola visual seperti warna, tekstur, dan bentuk objek dalam citra. Arsitektur ini telah banyak digunakan dalam berbagai penelitian klasifikasi citra karena mampu menghasilkan performa yang tinggi dibandingkan metode konvensional (LeCun et al., 2015; Khan et al., 2023).

Secara umum, CNN terdiri dari beberapa lapisan utama yang bekerja secara berurutan dalam proses ekstraksi dan klasifikasi fitur. Lapisan pertama adalah *convolutional layer*, yang berfungsi untuk mengekstraksi fitur dari citra input menggunakan filter atau kernel tertentu. Proses konvolusi ini menghasilkan *feature map* yang merepresentasikan pola-pola penting dalam citra, seperti tepi, tekstur, dan bentuk sederhana. Semakin dalam lapisan CNN, fitur yang diekstraksi akan semakin kompleks dan abstrak.

Lapisan berikutnya adalah *activation function*, yang umumnya menggunakan fungsi *Rectified Linear Unit* (ReLU). Fungsi aktivasi ini bertujuan untuk memperkenalkan sifat non-linear ke dalam skenario, sehingga CNN mampu mempelajari hubungan yang lebih kompleks dalam data. Tanpa fungsi aktivasi, skenario hanya akan bekerja secara linear dan tidak mampu menangkap pola yang kompleks dalam citra (Goodfellow et al., 2021).

Selanjutnya, terdapat pooling layer yang berfungsi untuk mengurangi dimensi *feature map* sekaligus mempertahankan informasi penting. Proses ini membantu

mengurangi kompleksitas komputasi serta mencegah terjadinya *overfitting*. Salah satu metode yang umum digunakan adalah *max pooling*, yang mengambil nilai maksimum dari setiap area tertentu pada *feature map* sebagai representasi fitur.

Setelah melalui beberapa lapisan konvolusi dan pooling, data akan masuk ke tahap *fully connected layer*. Pada tahap ini, fitur yang telah diekstraksi akan diubah menjadi vektor satu dimensi dan digunakan untuk proses klasifikasi. Lapisan ini berfungsi sebagai penghubung antara proses ekstraksi fitur dan output akhir berupa prediksi kelas. Pada penelitian ini, output yang dihasilkan berupa tiga kelas, yaitu daun sehat, embun tepung, dan embun bulu.

Dalam proses pelatihan, CNN menggunakan algoritma *backpropagation* untuk memperbarui bobot pada setiap lapisan berdasarkan nilai kesalahan (*loss*) yang dihasilkan. Proses ini dilakukan secara iteratif hingga skenario mencapai performa yang optimal. Selain itu, penggunaan fungsi *loss* dan *optimizer* juga berperan penting dalam menentukan kecepatan dan stabilitas proses pelatihan skenario.

Dalam konteks penelitian ini, CNN digunakan sebagai metode utama untuk melakukan klasifikasi citra daun melon berdasarkan karakteristik visual yang terdapat pada masing-masing kelas. Kemampuan CNN dalam mengekstraksi fitur secara otomatis memungkinkan skenario untuk mengenali perbedaan antara daun sehat, embun tepung, dan embun bulu tanpa memerlukan proses rekayasa fitur secara manual. Oleh karena itu, CNN menjadi pendekatan yang tepat untuk digunakan dalam penelitian klasifikasi penyakit tanaman berbasis citra.

2.2.7 Data Augmentation

Data augmentation merupakan teknik dalam pengolahan data yang digunakan untuk meningkatkan jumlah dan variasi dataset dengan cara melakukan transformasi terhadap data yang sudah ada tanpa mengubah label aslinya. Teknik ini banyak digunakan dalam *Deep Learning*, khususnya pada pengolahan citra, untuk mengatasi keterbatasan jumlah data serta meningkatkan kemampuan generalisasi skenario. Dalam kasus dataset yang terbatas, seperti pada penelitian ini, *data augmentation* menjadi langkah penting untuk mencegah skenario mengalami *overfitting* dan meningkatkan performa klasifikasi (Shorten & Khoshgoftaar, 2019; Mahmood et al., 2022).

Pada proses pelatihan skenario *Convolutional Neural Network* (CNN), jumlah dan keberagaman data sangat berpengaruh terhadap kemampuan skenario dalam mengenali pola. Dataset yang terbatas cenderung membuat skenario hanya menghafal data latih (*memorization*) tanpa mampu mengenali pola baru pada data uji. Kondisi ini menyebabkan skenario memiliki performa yang tinggi pada data latih namun rendah pada data pengujian. Oleh karena itu, *data augmentation* digunakan untuk mensimulasikan variasi kondisi nyata yang mungkin terjadi pada proses akuisisi citra, seperti perbedaan sudut pengambilan, pencahayaan, maupun skala objek (Khan et al., 2023).

Secara umum, *data augmentation* bekerja dengan menerapkan berbagai transformasi geometris maupun fotometrik terhadap citra. Transformasi geometris meliputi perubahan posisi atau orientasi objek dalam citra, sedangkan transformasi fotometrik berkaitan dengan perubahan intensitas atau kualitas pencahayaan.

Dengan menerapkan transformasi ini, skenario CNN dapat belajar dari berbagai variasi representasi data tanpa perlu mengumpulkan data baru secara langsung di lapangan.

Dalam penelitian ini, teknik *data augmentation* yang digunakan meliputi *rotation*, *flip*, *zoom*, dan *brightness adjustment*. Transformasi *rotation* dilakukan dengan memutar citra dalam rentang sudut tertentu untuk mensimulasikan variasi posisi daun saat pengambilan gambar. Teknik *flip* digunakan untuk membalik citra secara horizontal maupun vertikal, sehingga skenario dapat mengenali objek dari berbagai orientasi. Selanjutnya, *zoom* diterapkan untuk mensimulasikan variasi jarak pengambilan gambar terhadap objek daun, baik dalam bentuk perbesaran (*zoom in*) maupun pengecilan (*zoom out*). Sementara itu, penyesuaian *brightness* digunakan untuk merepresentasikan variasi kondisi pencahayaan yang sering terjadi pada lingkungan nyata, seperti perubahan intensitas cahaya di greenhouse.

Penerapan teknik *data augmentation* tidak hanya bertujuan untuk menambah jumlah data, tetapi juga untuk meningkatkan ketahanan skenario terhadap variasi kondisi lingkungan. Dengan adanya variasi data yang lebih beragam, skenario CNN diharapkan mampu mengenali pola penyakit daun secara lebih robust dan tidak bergantung pada kondisi spesifik tertentu dari data latih. Penelitian menunjukkan bahwa penerapan *data augmentation* secara tepat dapat meningkatkan performa klasifikasi secara signifikan, terutama pada dataset dengan jumlah terbatas (Shorten & Khoshgoftaar, 2019).

Namun demikian, penggunaan *data augmentation* juga perlu dilakukan secara terkontrol agar tidak mengubah karakteristik utama dari objek yang

diklasifikasikan. Transformasi yang terlalu ekstrem berpotensi menghasilkan data yang tidak realistis dan justru dapat menurunkan performa skenario. Oleh karena itu, pemilihan jenis dan parameter augmentasi harus disesuaikan dengan karakteristik data serta tujuan penelitian.


Dalam konteks penelitian ini, *data augmentation* digunakan sebagai variabel utama yang dianalisis pengaruhnya terhadap kinerja skenario CNN dalam klasifikasi penyakit daun melon. Penerapan teknik augmentasi dilakukan pada data latih untuk menghasilkan variasi dataset yang lebih kaya, kemudian dibandingkan dengan skenario tanpa augmentasi. Dengan pendekatan ini, penelitian tidak hanya berfokus pada penggunaan CNN, tetapi juga pada analisis efektivitas teknik data augmentation dalam meningkatkan performa skenario pada dataset citra daun melon yang terbatas.

BAB III

METODOLOGI PENELITIAN

3.1 Design Sistem

Penelitian ini dirancang sebagai studi eksperimental yang bertujuan untuk menganalisis secara sistematis pengaruh variasi teknik data augmentation terhadap kinerja model Convolutional Neural Network (CNN) dalam tugas klasifikasi kondisi daun melon. Objek klasifikasi yang digunakan mencakup tiga kondisi, yaitu daun sehat, daun terinfeksi embun tepung (*Podosphaera xanthii*), dan daun terinfeksi embun bulu (*Pseudoperonospora cubensis*). Keseluruhan desain eksperimen dibangun dengan memastikan bahwa seluruh variabel kontrol, seperti arsitektur CNN, ukuran citra, jumlah epoch, batch size, dan parameter pelatihan lainnya dijaga secara konsisten pada setiap eksperimen. Dengan demikian, perbedaan performa model yang diperoleh dapat dikaitkan secara spesifik dengan perbedaan konfigurasi data augmentation yang diterapkan.



Gambar 3.1 Tahapan Prosedur Penelitian

Desain sistem pada penelitian ini terdiri atas delapan tahapan yang dilaksanakan secara berurutan dan saling berkaitan. Tahapan tersebut meliputi: (1) pengumpulan dataset citra daun melon beserta validasi label oleh praktisi lapangan;

(2) pelabelan dataset ke dalam tiga kelas target, yaitu sehat, embun tepung, dan embun bulu; (3) pembagian dataset menjadi training set dan testing set menggunakan metode stratified random split dengan rasio 70:30; (4) preprocessing citra berupa resizing dan normalisasi yang diterapkan pada training set dan testing set, sedangkan proses augmentasi hanya diterapkan pada training set; (5) eksperimen data augmentation secara terpisah pada setiap variabel, yaitu rotation, zoom, dan flip, untuk memperoleh konfigurasi augmentasi terbaik; (6) pemilihan konfigurasi augmentasi terbaik berdasarkan nilai accuracy dan F1-score tertinggi; (7) perancangan dan pelatihan model CNN final menggunakan konfigurasi augmentasi terbaik yang diperoleh dari tahap eksperimen; serta (8) evaluasi model menggunakan metrik accuracy, precision, recall, F1-score, dan confusion matrix.

Urutan tahapan tersebut disusun berdasarkan pertimbangan metodologis untuk meminimalkan potensi terjadinya data leakage. Oleh karena itu, pembagian dataset dilakukan sebelum tahap preprocessing dan augmentasi. Seluruh teknik augmentasi hanya diterapkan pada training set, sedangkan testing set dipertahankan dalam kondisi asli agar mampu merepresentasikan data yang belum pernah dilihat model sebelumnya. Pendekatan eksperimen per variabel (One Variable At A Time/OVAT) digunakan untuk memungkinkan analisis yang lebih terkontrol terhadap pengaruh masing-masing teknik augmentasi terhadap performa CNN.

Pada tahap eksperimen, setiap teknik augmentasi diuji secara terpisah dengan tetap mempertahankan parameter pelatihan lainnya dalam kondisi yang sama. Setelah konfigurasi terbaik dari masing-masing teknik diperoleh, konfigurasi tersebut diterapkan pada model CNN final sebagai bentuk implementasi hasil

analisis. Penelitian ini tidak bertujuan untuk mencari kombinasi augmentasi global terbaik, melainkan untuk menganalisis pengaruh individual setiap teknik augmentasi terhadap kinerja CNN dalam klasifikasi kondisi daun melon.

3.2 Pengumpulan Dataset

Pengumpulan dataset merupakan tahap awal yang menjadi fondasi dari seluruh proses penelitian. Tujuan utama dari tahap ini adalah memperoleh citra daun melon yang representatif terhadap kondisi agronomis nyata di lapangan, sehingga model CNN yang dikembangkan memiliki relevansi praktis dan tidak hanya optimal pada kondisi data yang terkontrol.

Dataset yang digunakan dalam penelitian ini diperoleh secara mandiri melalui akuisisi citra langsung di lingkungan budidaya melon. Pendekatan pengambilan data primer secara lapangan ini dipilih atas pertimbangan bahwa dataset yang diperoleh dari kondisi nyata di lapangan lebih mampu merepresentasikan variasi visual yang sesungguhnya terjadi pada tanaman melon, termasuk variasi pencahayaan, sudut pandang pengambilan gambar, kondisi cuaca, serta tingkat keparahan gejala penyakit yang bervariasi antarindividu tanaman.

Proses akuisisi citra dilakukan menggunakan kamera pada perangkat telepon genggam (smartphone). Variasi kondisi pengambilan gambar, seperti perbedaan intensitas cahaya, sudut kamera, serta jarak terhadap objek, secara disengaja tidak dibatasi secara ketat. Hal ini bertujuan untuk menghasilkan dataset yang memiliki keragaman visual yang memadai, sehingga model CNN mampu belajar mengenali pola yang bersifat lebih umum.

Dataset yang berhasil dikumpulkan terdiri dari tiga kelas utama, yaitu: (1) daun sehat, sebagai representasi kondisi tanaman melon yang tidak terinfeksi penyakit; (2) daun terinfeksi embun tepung (*Podosphaera xanthii*); dan (3) daun terinfeksi embun bulu (*Pseudoperonospora cubensis*). Total dataset yang digunakan dalam penelitian ini berjumlah 600 citra dengan distribusi yang seimbang, yakni masing-masing kelas terdiri dari 200 citra. Keseimbangan distribusi antarkelas ini merupakan upaya yang disengaja untuk menghindari bias model terhadap kelas dengan jumlah sampel yang lebih dominan selama proses pelatihan.

Untuk menjamin kualitas dataset, setiap citra yang dikumpulkan melalui proses seleksi awal yang meliputi pengeliminasian gambar yang tidak layak pakai, seperti gambar yang buram, tidak fokus, memiliki resolusi terlalu rendah, atau tidak menampilkan bagian daun secara memadai. Aspek validitas label juga menjadi perhatian utama. Proses validasi kondisi setiap citra dilakukan dengan melibatkan seorang praktisi pertanian berpengalaman, yaitu Pak Dimun, seorang petani melon berpengalaman dari Desa Kepuhrejo, Kecamatan Takeran, Kabupaten Magetan.

3.3 Pelabelan Data

Pelabelan data merupakan tahapan yang menentukan kualitas supervisi dalam proses pembelajaran model CNN. Tanpa label yang akurat dan konsisten, model tidak dapat mempelajari hubungan antara pola visual pada citra dengan kelas kondisi kesehatan daun yang sebenarnya. Oleh karena itu, tahap ini dilaksanakan dengan prosedur yang sistematis dan melibatkan validasi dari praktisi lapangan yang berkompeten.

Dalam penelitian ini, setiap citra yang berhasil dikumpulkan diberikan label yang merepresentasikan kondisi kesehatan daun melon yang ditampilkan. Terdapat tiga label kelas yang digunakan, yaitu: kelas 0 untuk daun sehat, kelas 1 untuk daun terinfeksi embun tepung (*Podosphaera xanthii*), dan kelas 2 untuk daun terinfeksi embun bulu (*Pseudoperonospora cubensis*). Penentuan label untuk setiap citra dilakukan berdasarkan dua sumber acuan: kajian literatur ilmiah sebagaimana dipaparkan pada Bab II, dan observasi lapangan langsung bersama Pak Dimun.

Daun sehat diidentifikasi berdasarkan ciri warna hijau yang merata di seluruh permukaan daun, tanpa adanya perubahan warna, bintik, bercak, atau kelainan tekstur yang abnormal. Daun yang terinfeksi embun tepung diidentifikasi berdasarkan kemunculan lapisan tepung putih keabu-abuan pada permukaan daun, terutama pada sisi atas (adaksial). Daun yang terinfeksi embun bulu diidentifikasi berdasarkan kemunculan bercak-bercak kekuningan hingga coklat pada permukaan atas daun, disertai dengan pertumbuhan miselium berwarna putih keabu-abuan hingga keunguan pada sisi bawah daun (abaksial).

Konsistensi label dijaga melalui dua mekanisme utama. Pertama, setiap citra yang meragukan atau tidak menunjukkan karakteristik visual yang jelas dari salah satu kelas dieliminasi dari dataset. Kedua, seluruh hasil pelabelan awal divalidasi kembali oleh Pak Dimun secara langsung di lapangan. Proses pelabelan yang terstruktur dan divalidasi oleh praktisi berpengalaman ini diharapkan menghasilkan dataset dengan tingkat reliabilitas label yang tinggi.



Gambar 3. 2 Dokumentasi proses observasi dan validasi pelabelan data

Dengan adanya proses pelabelan yang terstruktur dan tervalidasi, dataset yang digunakan dalam penelitian ini diharapkan memiliki tingkat keandalan yang tinggi, sehingga mampu mendukung proses pembelajaran skenario CNN dalam mengklasifikasikan kondisi kesehatan daun melon secara optimal.

3.4 Pembagian Dataset

Pembagian dataset merupakan tahapan yang secara metodologis harus dilaksanakan sebelum proses *preprocessing* citra maupun data augmentation. Urutan ini merupakan persyaratan metodologis yang bersifat wajib untuk mencegah terjadinya data leakage, yaitu kondisi di mana informasi yang berasal dari *testing set*, baik secara langsung maupun implisit, turut memengaruhi transformasi yang diterapkan pada data latih.

3.4.1 Proporsi Pembagian Dataset

Dataset total yang digunakan dalam penelitian ini berjumlah 600 citra dengan distribusi yang seimbang antarkelas. Tiga kelas yang ada, yaitu daun sehat, daun terinfeksi embun tepung, dan daun terinfeksi embun bulu, masing-masing diwakili

oleh 200 citra. Seluruh dataset dibagi menjadi dua subset yang terpisah secara mutlak menggunakan rasio 70:30, sehingga diperoleh:

- a. *Training Set*: 420 citra (70% dari total 600 citra), terdiri dari 140 citra per kelas.
- b. *Testing Set*: 180 citra (30% dari total 600 citra), terdiri dari 60 citra per kelas.

3.4.2 Metode Pembagian: Stratified Random Split

Pembagian dataset dilakukan menggunakan metode stratified random split, yaitu teknik pembagian data yang mempertahankan proporsi distribusi kelas pada setiap subset yang dihasilkan. Penggunaan stratified split menjadi sangat penting dalam konteks dataset yang mencakup lebih dari satu kelas, karena pembagian data secara acak murni berpotensi menghasilkan subset yang tidak proporsional, sehingga dapat menghasilkan evaluasi yang bias.

3.4.3 Justifikasi Ilmiah Rasio 70:30

Pemilihan rasio 70:30 dalam penelitian ini didasarkan pada beberapa pertimbangan ilmiah. Dari sisi *training set*, proporsi 70% (420 citra) memberikan volume data yang cukup bagi model CNN untuk mempelajari pola visual yang beragam dari ketiga kelas. Dari sisi *testing set*, proporsi 30% (180 citra, atau 60 citra per kelas) memberikan ukuran sampel yang cukup besar untuk menghasilkan estimasi metrik evaluasi yang stabil secara statistik. Dengan demikian, rasio 70:30 dipilih sebagai titik keseimbangan antara kebutuhan data pelatihan yang memadai dan representativitas data evaluasi yang cukup.

3.4.4 Penghindaran Data Leakage

Proses pembagian dataset dilakukan sebelum tahap *preprocessing* citra dan data augmentation. Urutan ini sangat krusial untuk menghindari terjadinya data leakage. Dengan memisahkan *testing set* terlebih dahulu, setiap operasi *preprocessing* dan augmentation hanya diterapkan pada *training set*, memastikan bahwa *testing set* tetap merepresentasikan data yang truly unseen selama proses pelatihan model CNN.

3.5 Preprocessing Citra

Preprocessing citra merupakan tahapan pengolahan awal yang bertujuan untuk menyiapkan citra agar memenuhi persyaratan teknis yang dibutuhkan oleh model CNN. Tahap ini dilaksanakan setelah pembagian dataset diselesaikan dan mencakup dua proses utama, yaitu *resizing* dan normalisasi nilai piksel, yang diterapkan pada seluruh data, baik *training set* maupun *testing set*. Sementara itu, proses data augmentation hanya diterapkan secara eksklusif pada training set dan tidak diterapkan pada *testing set* guna mencegah terjadinya data leakage.

3.5.1 Resizing Citra

Resizing merupakan proses pengubahan dimensi spasial citra menjadi ukuran yang seragam. Dalam penelitian ini, seluruh citra pada *training set* maupun *testing set* diubah ukurannya menjadi 224×224 piksel. Pemilihan dimensi ini didasarkan pada pertimbangan keseimbangan antara kebutuhan komputasi dan kemampuan mempertahankan detail visual yang relevan. Ukuran 224×224 piksel merupakan ukuran standar yang banyak digunakan pada penelitian CNN berbasis klasifikasi

citra dan terbukti mampu mempertahankan informasi tekstur dan warna yang memadai untuk membedakan karakteristik visual antarkelas kondisi daun. Proses *resizing* dilakukan menggunakan metode *bilinear interpolation*.

3.5.2 Normalisasi Nilai Piksel

Normalisasi nilai piksel merupakan proses transformasi numerik yang mengubah rentang nilai piksel dari rentang aslinya $[0, 255]$ menjadi rentang $[0, 1]$ dengan cara membagi setiap nilai piksel dengan 255. Proses ini diterapkan pada seluruh data, baik training set maupun testing set, sebelum dimasukkan ke dalam model CNN. Normalisasi dilakukan karena model CNN bekerja lebih efisien ketika nilai input berada dalam rentang yang kecil dan seragam. Nilai piksel yang besar dapat menyebabkan gradien yang besar selama proses backpropagation, yang berpotensi menyebabkan ketidakstabilan dalam proses optimasi bobot jaringan. Selain itu, normalisasi membantu mempercepat konvergensi proses pelatihan.

Perlu ditegaskan bahwa proses data augmentation hanya diterapkan pada *training set* dan secara metodologis tidak diperkenankan untuk diterapkan pada *testing set*. Penerapan augmentasi pada *testing set* akan mengakibatkan terjadinya *data leakage*, yaitu kondisi di mana distribusi data uji tidak lagi merepresentasikan kondisi nyata yang akan dihadapi model saat digunakan pada data yang benar-benar baru. Fungsi utama *testing set* adalah mengevaluasi kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya (*unseen data*), sehingga data uji harus mencerminkan distribusi data yang sesungguhnya tanpa modifikasi tambahan apapun. Apabila transformasi augmentasi diterapkan pada testing set, maka nilai metrik evaluasi yang diperoleh tidak dapat dianggap sebagai ukuran

performa yang valid, karena model sedang dievaluasi pada data yang telah dimodifikasi secara artifisial dan tidak merepresentasikan skenario penggunaan nyata (Shorten & Khoshgoftaar, 2019). Dengan demikian, pembatasan augmentasi hanya pada *training set* merupakan persyaratan metodologis yang fundamental dalam desain eksperimen machine learning yang bertujuan untuk menghasilkan estimasi performa model yang objektif dan dapat dipercaya.

3.6 Data Augmentation

Data augmentation merupakan variabel utama yang menjadi fokus analisis dalam penelitian ini. Secara umum, data augmentation didefinisikan sebagai serangkaian teknik transformasi yang diterapkan pada citra dalam dataset untuk menciptakan variasi citra baru secara artifisial tanpa mengubah label kelas dari citra tersebut. Tujuan utama augmentasi adalah meningkatkan keragaman data latih agar model CNN dapat mempelajari fitur yang lebih robust serta memiliki kemampuan generalisasi yang lebih baik terhadap data baru. Teknik ini menjadi sangat relevan karena dataset yang digunakan dalam penelitian ini memiliki jumlah citra yang terbatas, sehingga berpotensi menimbulkan *overfitting* apabila model hanya dilatih pada data asli. Dengan demikian, augmentasi hanya diterapkan pada data latih dan tidak digunakan pada data uji agar evaluasi model tetap mencerminkan kemampuan generalisasi yang sesungguhnya.

Pendekatan eksperimen augmentasi dalam penelitian ini dilakukan per variabel, yaitu dengan menguji setiap teknik augmentasi secara independen terlebih dahulu sebelum menentukan konfigurasi terbaik yang akan digunakan pada model final. Pendekatan ini memungkinkan identifikasi kontribusi spesifik dari setiap

teknik augmentasi terhadap performa model, sekaligus menghindari interaksi antarteknik yang dapat menyamarkan pengaruh masing-masing variabel.

3.6.1 Teknik Augmentasi yang Digunakan

Dalam penelitian ini, teknik data augmentation yang diuji terdiri dari tiga jenis transformasi geometris, yaitu *rotation*, *zoom*, dan *flip*. Setiap teknik dipilih berdasarkan relevansinya terhadap variasi kondisi visual yang secara wajar dapat terjadi selama pengambilan citra daun melon di lapangan, sekaligus mempertimbangkan kemampuannya dalam memperkaya keragaman data latih tanpa mengubah karakteristik diagnostik objek yang diklasifikasikan.

Tabel 3.1 Jumlah Data Sebelum dan Sesudah Augmentasi

Tahap Dataset	Jumlah Citra
Dataset awal	600
Training set (70%)	420
Testing set (30%)	180
Training efektif setelah augmentasi	840

Perlu dicatat bahwa *brightness adjustment* secara eksplisit tidak digunakan dalam penelitian ini. Keputusan tersebut didasarkan pada pertimbangan bahwa perubahan intensitas kecerahan secara artifisial berpotensi mengubah karakteristik warna alami daun, yang merupakan salah satu fitur diskriminatif utama dalam membedakan kondisi daun sehat, embun tepung, dan embun bulu. Temuan dari kajian empiris terdahulu menunjukkan bahwa *brightness augmentation* tidak selalu memberikan peningkatan kinerja pada CNN dan dalam kondisi tertentu justru dapat menurunkan performa model, terutama pada tugas klasifikasi yang bergantung pada informasi warna (Kandel et al., 2022). Oleh karena itu, augmentasi yang digunakan

dalam penelitian ini dibatasi pada transformasi geometris yang tidak mengubah informasi fotometrik citra.

a. *Rotation*

Rotation merupakan transformasi geometris yang memutar citra pada bidang dua dimensi dengan sudut tertentu terhadap pusat citra. Transformasi ini mensimulasikan variasi orientasi pengambilan gambar yang secara natural terjadi ketika kamera tidak selalu dipegang dalam posisi yang sepenuhnya horizontal. Rotasi membantu model agar tidak bergantung pada orientasi spasial tertentu dalam mengenali pola visual kondisi daun, sehingga model menjadi lebih invariant terhadap perubahan sudut pengambilan gambar. Dalam eksperimen per variabel, beberapa rentang rotasi diuji secara terpisah untuk menentukan nilai yang memberikan peningkatan performa terbaik tanpa merusak karakteristik visual citra.

b. *Flip*

Flip merupakan transformasi geometris yang membalik citra secara simetris, baik pada sumbu vertikal maupun horizontal. Transformasi ini relevan diterapkan pada citra daun karena gejala visual penyakit daun tidak memiliki orientasi spasial yang bersifat kiri atau kanan secara biologis. Penerapan flip memperkaya variasi spasial data latih dan membantu model mempelajari pola penyakit secara lebih fleksibel. Dalam eksperimen per variabel, jenis flip yang diuji meliputi *horizontal flip* dan *vertical flip* secara terpisah.

c. *Zoom*

Zoom merupakan transformasi geometris yang memperbesar atau memperkecil bagian tertentu dari citra dalam rentang persentase tertentu dari

ukuran asli. Transformasi ini mensimulasikan variasi jarak antara kamera dan objek daun saat pengambilan gambar di lapangan. *Zoom in* membuat tekstur dan detail gejala penyakit terlihat lebih besar, sedangkan *zoom out* menyajikan konteks daun yang lebih luas dalam satu frame. Dalam eksperimen per variabel, beberapa nilai rentang *zoom* diuji secara terpisah untuk menentukan konfigurasi yang optimal.

3.6.2 Konfigurasi Augmentasi per Skenario

Penelitian ini menggunakan desain eksperimen augmentasi per variabel, di mana setiap teknik augmentasi diuji secara *independen* dengan beberapa konfigurasi nilai parameter yang berbeda. Tujuan dari pendekatan ini adalah mengidentifikasi nilai terbaik dari masing-masing teknik sebelum dikombinasikan pada model final, sehingga pengaruh setiap variabel dapat dianalisis secara lebih terkontrol dan objektif.

Eksperimen augmentasi per variabel dilakukan sebagai berikut. Untuk rotation, beberapa rentang sudut yang diuji meliputi nilai 0° , 45° , 90° , 135° , 180° , 225° , 270° dan 315° . Untuk flip, jenis transformasi yang diuji secara terpisah adalah horizontal flip dan vertical flip. Untuk zoom, beberapa rentang yang diuji meliputi 0%, 10%, 20%, 30%, 40% dan 50%.

Setiap konfigurasi dijalankan dengan melatih model CNN menggunakan parameter pelatihan yang identik. Perbandingan performa antarskenario augmentasi digunakan sebagai dasar untuk menentukan teknik dan parameter augmentasi terbaik yang akan digunakan pada tahap pelatihan model final.

3.6.3 Justifikasi Brightness Adjustment Tidak Digunakan

Berbeda dengan beberapa penelitian sebelumnya yang menggunakan *brightness adjustment* sebagai salah satu teknik augmentasi, penelitian ini secara eksplisit tidak menggunakan transformasi fotometrik tersebut. Keputusan ini didasarkan pada pertimbangan ilmiah yang berkaitan dengan karakteristik visual objek yang diklasifikasikan serta temuan dari kajian literatur terkini.

Kajian empiris menunjukkan bahwa *brightness augmentation* tidak selalu memberikan peningkatan kinerja pada CNN, khususnya pada tugas klasifikasi citra. Dalam studi Kandel dkk. (2022), *brightness augmentation* pada beberapa skala justru tidak menghasilkan performa yang lebih baik dibandingkan tanpa augmentasi, dan pada kondisi ekstrem bahkan dapat menurunkan performa model. Studi tersebut juga menunjukkan bahwa *geometric augmentation* memberikan hasil yang lebih baik dibandingkan *brightness augmentation*.

Pada konteks penelitian ini, karakteristik visual daun melon sangat bergantung pada pola warna, tekstur, dan kontras gejala penyakit. Pada kelas embun tepung, ciri utama berupa lapisan putih keabu-abuan yang kontras dengan permukaan daun hijau sangat sensitif terhadap perubahan intensitas cahaya. Perubahan *brightness* secara global dapat mengubah distribusi intensitas piksel dan berpotensi mengaburkan kontras khas tersebut. Demikian pula pada kelas embun bulu, perubahan warna daun menjadi kekuningan hingga kecoklatan merupakan fitur visual penting yang dapat terganggu apabila *brightness* diterapkan secara berlebihan.

Berdasarkan pertimbangan tersebut, *brightness adjustment* tidak dimasukkan ke dalam eksperimen augmentasi maupun model final. Pendekatan ini konsisten dengan prinsip bahwa pemilihan teknik augmentasi harus disesuaikan dengan domain *knowledge* objek yang diklasifikasikan, sehingga augmentasi yang diterapkan benar-benar mensimulasikan variasi yang realistis tanpa menghilangkan fitur diskriminatif yang dibutuhkan model.

3.7 Perancangan dan Implementasi Skenario Convolutional Neural Network

Dalam penelitian ini, proses ekstraksi fitur dari citra daun melon dilakukan secara otomatis oleh model CNN melalui proses pembelajaran end-to-end. Hal ini berarti bahwa fitur-fitur yang digunakan untuk membedakan antarkelas penyakit daun melon dipelajari secara mandiri oleh jaringan saraf tiruan dari data latih yang tersedia, tanpa adanya intervensi manual dalam menentukan jenis atau karakteristik fitur yang harus diekstraksi.

3.7.1 Arsitektur CNN

Arsitektur CNN yang digunakan dalam penelitian ini terdiri dari dua blok konvolusi yang bekerja secara hierarkis. Pada lapisan konvolusi pertama (Conv2D dengan 32 filter), filter yang dipelajari umumnya akan mendeteksi fitur-fitur visual dasar seperti tepi (edges), garis, dan gradien warna. Pada lapisan konvolusi kedua (Conv2D dengan 64 filter), proses konvolusi menghasilkan fitur yang lebih kompleks dan lebih abstrak, seperti pola tekstur, bentuk bintik, atau pola warna yang lebih kompleks.

Tabel 3.2 Spesifikasi Arsitektur CNN

Komponen	Konfigurasi
Input image size	224 × 224 piksel (RGB)
Conv Layer 1	32 filter, kernel 3×3, aktivasi ReLU
MaxPooling 1	2×2
Conv Layer 2	64 filter, kernel 3×3, aktivasi ReLU
MaxPooling 2	2×2
Flatten	Mengubah <i>feature map</i> ke vektor 1D
Dense Layer	128 neuron, aktivasi ReLU
Dropout	Rate 0,5

3.7.2 Fungsi Aktivasi ReLU

Setelah setiap operasi konvolusi, hasil yang diperoleh dilewatkan melalui fungsi aktivasi non-linear Rectified Linear Unit (ReLU). Fungsi ReLU mendefinisikan transformasi $f(x) = \max(0, x)$, yang berarti nilai negatif diubah menjadi nol sedangkan nilai positif dipertahankan. Penerapan fungsi aktivasi non-linear ini sangat penting karena tanpanya, serangkaian lapisan konvolusi hanya akan menghasilkan transformasi linear dari input, yang secara fundamental membatasi kemampuan representasi jaringan (Goodfellow et al., 2021).

3.7.3 Lapisan Max-Pooling

Setelah setiap blok konvolusi-aktivasi, lapisan max-pooling dengan ukuran jendela 2×2 diterapkan untuk melakukan reduksi dimensi spasial *feature map*. Operasi pooling ini melayani dua tujuan utama. Pertama, pooling mengurangi dimensi spasial *feature map* sehingga secara signifikan mengurangi jumlah parameter dan komputasi yang diperlukan pada lapisan-lapisan berikutnya, yang membantu mencegah *overfitting* pada dataset yang terbatas. Kedua, pooling memberikan sifat translational invariance yang parsial kepada representasi fitur,

yang sangat relevan untuk klasifikasi penyakit daun karena gejala visual dapat muncul di lokasi manapun pada permukaan daun.

3.7.4 Flatten dan Fully Connected Layer

Setelah melalui dua blok konvolusi-pooling, representasi fitur yang tersimpan dalam *feature map* diratakan (flatten) menjadi sebuah vektor satu dimensi. Vektor fitur ini kemudian dimasukkan ke dalam lapisan fully connected (Dense layer) yang terdiri dari 128 neuron dengan fungsi aktivasi ReLU. Lapisan Dropout dengan rate 0,5 ditempatkan setelah lapisan Dense untuk mencegah *overfitting*. Akhirnya, lapisan output disesuaikan dengan kebutuhan masing-masing stage klasifikasi, sebagaimana dijelaskan pada subbab 3.8.

3.8 Proses Pelatihan (Training Data)

Proses pelatihan dalam penelitian ini dilakukan dalam dua fase yang saling berkaitan. Fase pertama adalah eksperimen pencarian augmentasi terbaik, yang bertujuan untuk mengidentifikasi teknik dan parameter augmentasi yang memberikan peningkatan performa terbaik secara terkontrol. Fase kedua adalah pelatihan model CNN final menggunakan konfigurasi augmentasi terbaik yang diperoleh dari fase pertama. Kedua fase tersebut menggunakan arsitektur CNN yang identik serta parameter pelatihan yang konsisten agar hasil antarfase dapat dibandingkan secara adil.

Tabel 3.3 Paramater Pelatihan CNN

Parameter	Nilai
<i>Optimizer</i>	<i>Adam (Adaptive Moment Estimation)</i>
<i>Learning Rate</i>	0,001
<i>Batch Size</i>	16
<i>Epoch Maksimum</i>	30
<i>Dropout Rate</i>	0,5

Parameter	Nilai
<i>Fungsi Loss</i>	<i>Binary Crossentropy (Stage 1) / Categorical Crossentropy (Stage 2)</i>
<i>Early Stopping Monitor</i>	<i>val_f1_score</i>
<i>Early Stopping Patience</i>	<i>10 epoch</i>
<i>Restore Best Weights</i>	<i>True</i>

3.8.1 Eksperimen Pencarian Augmentasi Terbaik

Eksperimen pencarian augmentasi terbaik dilakukan sebelum pelatihan model final. Pada tahap ini, setiap teknik augmentasi yang telah ditetapkan pada subbab 3.6 diuji secara independen dengan beberapa konfigurasi nilai parameter yang berbeda. Desain eksperimen yang digunakan adalah one-variable-at-a-time (OVAT), yaitu hanya satu variabel augmentasi yang berubah pada setiap skenario pengujian, sementara komponen lainnya dijaga konsisten. Pendekatan ini dipilih karena memungkinkan identifikasi pengaruh spesifik dari masing-masing teknik augmentasi terhadap performa model secara terisolasi, tanpa terpengaruh oleh interaksi antarteknik yang dapat mempersulit interpretasi hasil.

Setiap skenario eksperimen augmentasi diuji dalam dua kondisi yang berjalan secara paralel. Kondisi A merupakan kondisi tanpa augmentasi sebagai baseline internal, sehingga model hanya dilatih menggunakan training set yang telah melalui preprocessing resizing dan normalisasi tanpa penerapan augmentasi apapun. Kondisi B merupakan kondisi dengan augmentasi, di mana model dilatih menggunakan training set yang telah diperkaya dengan satu teknik augmentasi sesuai konfigurasi skenario yang bersangkutan. Perbandingan antara Kondisi A dan Kondisi B pada setiap skenario digunakan untuk mengukur kontribusi bersih dari teknik augmentasi yang diuji terhadap kemampuan generalisasi model.

Hasil evaluasi dari setiap skenario eksperimen dibandingkan berdasarkan metrik accuracy dan macro F1-score pada testing set. Konfigurasi augmentasi yang memberikan peningkatan performa terbaik dibandingkan kondisi baseline dipilih sebagai konfigurasi yang akan digunakan pada tahap pelatihan model final. Apabila tidak ada teknik augmentasi yang memberikan peningkatan yang signifikan, maka konfigurasi yang menghasilkan penurunan performa paling minimal yang dipertimbangkan untuk digunakan pada model final.

3.8.2 Pelatihan Model CNN Final

Pelatihan model CNN final dilaksanakan setelah konfigurasi augmentasi terbaik diperoleh dari tahap eksperimen pada subbab 3.8.1. Model final dilatih menggunakan *training set* yang telah melalui *preprocessing resizing* dan normalisasi, serta diperkaya dengan teknik augmentasi terbaik hasil eksperimen. *Testing set* tidak dikenai augmentasi apapun dan digunakan secara eksklusif pada tahap evaluasi akhir untuk mengukur kemampuan generalisasi model terhadap data yang belum pernah dilihat selama pelatihan.

Arsitektur CNN yang digunakan pada model final identik dengan arsitektur yang telah dideskripsikan pada subbab 3.7. Proses pelatihan dilakukan dengan mengoptimalkan bobot jaringan menggunakan algoritma Adam optimizer dengan nilai learning rate yang telah ditentukan. Fungsi loss yang digunakan adalah *Categorical Crossentropy*, yang secara matematis sesuai untuk tugas klasifikasi multikelas sebagaimana yang diterapkan dalam penelitian ini. Pelatihan dilaksanakan selama sejumlah epoch yang telah ditetapkan dengan ukuran batch yang konsisten pada setiap iterasi.

Selama proses pelatihan, performa model dipantau pada setiap epoch menggunakan metrik *accuracy* dan *loss* untuk mendeteksi indikasi *overfitting* secara dini. Apabila performa pada data validasi menunjukkan tren yang memburuk sementara performa pada data latih terus meningkat, mekanisme *early stopping* dapat dipertimbangkan untuk menghentikan pelatihan sebelum jumlah epoch maksimum tercapai. Bobot model terbaik yang diperoleh selama proses pelatihan disimpan dan digunakan pada tahap evaluasi akhir.

Setelah pelatihan selesai, model dievaluasi pada *testing set* menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*, serta divisualisasikan melalui *confusion matrix* untuk menganalisis pola kesalahan klasifikasi pada masing-masing kelas. Hasil evaluasi ini menjadi dasar pembahasan mengenai efektivitas konfigurasi augmentasi terbaik dalam meningkatkan performa model CNN pada tugas klasifikasi kondisi daun melon.

3.9 Evaluasi Skenario (Testing Data)

Evaluasi model merupakan tahapan yang bertujuan untuk mengukur sejauh mana model CNN yang telah dilatih mampu melakukan klasifikasi kondisi daun melon secara akurat dan andal. Evaluasi dilakukan pada *testing set* yang tidak digunakan selama proses pelatihan, sehingga hasil yang diperoleh mencerminkan kemampuan generalisasi model terhadap data yang benar-benar baru. Dalam penelitian ini, evaluasi model menggunakan lima metrik, yaitu *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Penggunaan kombinasi metrik tersebut didasarkan pada pertimbangan bahwa tidak ada satu metrik tunggal yang mampu memberikan gambaran performa model secara menyeluruh, terutama pada konteks

klasifikasi multikelas dengan distribusi data yang perlu dievaluasi secara cermat pada setiap kelasnya.

Metrik pertama yang digunakan adalah *accuracy*, yang didefinisikan sebagai proporsi jumlah prediksi yang benar terhadap keseluruhan jumlah data uji. *Accuracy* memberikan gambaran umum mengenai tingkat kebenaran prediksi model secara keseluruhan dan merupakan metrik yang paling intuitif untuk mengukur performa klasifikasi.

Metrik berikutnya adalah *precision*, yang mengukur tingkat ketepatan prediksi *positif* model, yaitu seberapa besar proporsi prediksi suatu kelas yang benar-benar sesuai dengan kelas tersebut. *Precision* menjadi relevan dalam penelitian ini karena kesalahan prediksi yang menghasilkan positif palsu (*false positive*) pada kelas penyakit tertentu dapat menyebabkan tindakan penanganan yang tidak tepat sasaran di lapangan.

Berbeda dengan *precision* yang berfokus pada ketepatan prediksi positif, *recall* mengukur kemampuan model dalam mendeteksi seluruh sampel yang sesungguhnya termasuk dalam suatu kelas. *Recall* didefinisikan sebagai proporsi data positif yang berhasil diidentifikasi dengan benar oleh model dari keseluruhan data yang sesungguhnya bersifat positif. Dalam penelitian ini, *recall* yang rendah pada kelas penyakit mengindikasikan bahwa model gagal mendeteksi sebagian kasus daun yang sakit, yang dalam penerapan nyata dapat berakibat pada tidak teridentifikasinya penyakit secara dini.

Mengingat adanya kemungkinan *trade-off* antara *precision* dan *recall*, penelitian ini juga menggunakan *F1-score* sebagai metrik yang menyeimbangkan

kedua nilai tersebut dalam satu ukuran tunggal. *F1-score* didefinisikan sebagai rata-rata harmonik dari *precision* dan *recall*, sehingga nilai *F1-score* yang tinggi hanya dapat dicapai apabila baik *precision* maupun *recall* sama-sama bernilai tinggi secara bersamaan.

Dalam penelitian ini, *F1-score* digunakan sebagai metrik utama dalam pemilihan konfigurasi augmentasi terbaik pada tahap eksperimen, karena kemampuannya dalam mencerminkan keseimbangan antara ketepatan dan kelengkapan prediksi model secara komprehensif. Nilai *macro F1-score* yang tinggi mengindikasikan bahwa model mampu melakukan klasifikasi dengan baik secara merata pada ketiga kelas kondisi daun melon.

Selain keempat metrik numerik di atas, evaluasi model juga dilengkapi dengan *confusion matrix* sebagai alat *visualisasi* yang menyajikan distribusi hasil prediksi model secara menyeluruh. *Confusion matrix* merupakan tabel berukuran $n \times n$, di mana n adalah jumlah kelas, yang memuat jumlah prediksi benar dan salah dari model untuk setiap kombinasi kelas aktual dan kelas yang diprediksi. Dalam penelitian ini, *confusion matrix* berukuran 3×3 dengan baris merepresentasikan kelas *aktual* dan kolom merepresentasikan kelas yang diprediksi oleh model, mencakup ketiga kelas yaitu sehat, embun tepung, dan embun bulu. Melalui *confusion matrix*, dapat diidentifikasi secara spesifik kelas mana yang paling sering mengalami kesalahan klasifikasi serta ke kelas mana kesalahan tersebut paling banyak terjadi. Informasi ini memberikan wawasan yang lebih mendalam dibandingkan metrik *agregat* semata, sehingga memungkinkan analisis yang lebih

terarah mengenai kelemahan model dalam membedakan karakteristik visual antarkelas kondisi daun melon.

BAB IV

HASIL DAN PEMBAHASAN

4.1 Hasil Uji Coba dan Evaluasi

Bagian ini menyajikan hasil uji coba dan evaluasi model klasifikasi kondisi daun melon berbasis Convolutional Neural Network (CNN). Pengujian dilakukan melalui dua tahap utama, yaitu eksplorasi teknik augmentasi data secara individual (rotation, zoom, dan flip) untuk menentukan konfigurasi terbaik, dilanjutkan dengan evaluasi model akhir menggunakan pendekatan *two-stage classification*. Metrik evaluasi yang digunakan meliputi *accuracy*, *precision*, *recall*, dan *F1-score* yang dihitung pada data uji (test set).


4.1.1 Hasil Pengujian Skenario Rotation Only

Pengujian pada skenario augmentasi rotasi dilakukan dengan menerapkan delapan variasi sudut rotasi secara terpisah terhadap data latih, yaitu 0°, 45°, 90°, 135°, 180°, 225°, 270°, dan 315°. Tujuan pengujian ini adalah untuk menganalisis sejauh mana variasi sudut rotasi memengaruhi kemampuan generalisasi model CNN dalam mengklasifikasikan kondisi daun melon. Hasil akurasi keseluruhan delapan skenario dirangkum pada Tabel 4.1.

Tabel 4.1 Perbandingan Metrik Evaluasi Skenario Rotation Only pada Data Uji

Skenario Rotasi	Accuracy	Precision (Macro)	Recall (Macro)	F1-Score (Macro)
Rotasi 0°	0.6778	0.6808	0.6778	0.6645
Rotasi 45°	0.7778	0.7902	0.7778	0.7782
Rotasi 90°	0.3333	0.1111	0.3333	0.1667
Rotasi 135°	0.7444	0.7484	0.7444	0.7436
Rotasi 180°	0.7333	0.7423	0.7333	0.7331
Rotasi 225°	0.7722	0.7703	0.7722	0.7703
Rotasi 270°	0.7452	0.7783	0.7778	0.7452
Rotasi 315°	0.6444	0.6766	0.6444	0.6428

Berdasarkan Tabel 4.5, terlihat bahwa penerapan augmentasi rotasi menghasilkan rentang performa yang cukup lebar, yakni dari 33,33% hingga 77,78%. Hal ini mengindikasikan bahwa sudut rotasi yang dipilih berpengaruh signifikan terhadap kemampuan model dalam mempelajari representasi visual daun melon. Dua skenario dengan performa tertinggi adalah rotasi 45° (77,78%) dan rotasi 225° (77,22%), sementara dua skenario dengan performa terendah adalah rotasi 90° (33,33%) dan rotasi 0° atau tanpa rotasi berarti (67,78%). Pembahasan berikut difokuskan pada keempat skenario tersebut.



Gambar 4.1 Confusion Matrix Test Skenario 45°


Berdasarkan Gambar 4.1, confusion matrix pada data uji skenario rotasi 45° memperlihatkan bahwa kelas embun_bulu berhasil diklasifikasikan dengan tingkat kebenaran paling tinggi di antara ketiga kelas, dengan nilai presisi yang mencapai sekitar 0,92. Kelas embun_tepung dan sehat menunjukkan tingkat kesalahan klasifikasi yang lebih besar, khususnya pada kesalahan prediksi antara kedua kelas tersebut. Pola kesalahan ini mengindikasikan bahwa model mengalami kesulitan dalam membedakan tekstur permukaan daun yang terinfeksi embun_tepung dengan

daun dalam kondisi sehat, yang secara visual memang memiliki kemiripan pada tahap awal infeksi.



Gambar 4.2 Per-Class Metrics Test Skenario 45°


Berdasarkan Gambar 4.2, grafik metrik per kelas menunjukkan bahwa kelas embun_bulu memiliki keseimbangan antara presisi, recall, dan F1-score yang paling baik di antara ketiga kelas. Sementara itu, kelas embun_tepung memiliki nilai presisi yang lebih rendah tetapi recall yang relatif tinggi, yang berarti model cenderung memprediksi suatu sampel sebagai embun_tepung meskipun sebenarnya bukan. Ketidakseimbangan ini kemungkinan disebabkan oleh kemiripan pola tekstur antara embun_tepung dan sehat yang tidak cukup terdiversifikasi oleh augmentasi rotasi tunggal.



Gambar 4.3 Final Test Metrics Skenario 45


Berdasarkan Gambar 4.3, nilai akurasi, presisi, recall, dan F1-score pada data uji skenario 45° secara keseluruhan berada pada kisaran yang seragam, yakni sekitar 0,77–0,78. Konsistensi antar metrik ini menunjukkan bahwa model tidak mengalami bias prediksi yang ekstrem ke salah satu kelas, melainkan memiliki kapasitas generalisasi yang relatif seimbang.

Secara teknis, keunggulan rotasi 45° dapat dijelaskan melalui karakteristik visual daun melon itu sendiri. Daun melon memiliki pola venasi (leaf venation) dan distribusi spora penyakit yang tidak berorientasi pada satu sumbu tertentu. Rotasi 45° menghasilkan variasi posisi yang cukup signifikan dari orientasi aslinya sehingga model CNN dipaksa untuk mempelajari fitur-fitur yang lebih bersifat posisi-invarian (position-invariant). Augmentasi ini secara efektif memperluas distribusi data latih ke arah diagonal yang jarang muncul pada pengambilan gambar natural, sehingga meningkatkan kemampuan model dalam mengenali pola penyakit dari berbagai sudut pandang tanpa mengubah struktur morfologis daun secara berlebihan.



Gambar 4.4 Training History (Accuracy & Loss) Skenario 225°

Berdasarkan Gambar 4.4, grafik training history skenario rotasi 225° memperlihatkan kurva akurasi pelatihan yang meningkat secara konsisten dari sekitar 0,33 pada epoch awal hingga mendekati 0,65 pada epoch terakhir. Kurva validasi mengikuti tren yang serupa meskipun dengan fluktuasi yang lebih besar, terutama pada epoch ke-10 hingga ke-13 di mana terdapat lonjakan akurasi validasi yang mendekati akurasi pelatihan. Pola ini menandakan bahwa model mampu belajar dengan baik dan tidak menunjukkan gejala overfitting yang parah, meskipun selisih antara akurasi pelatihan dan validasi pada beberapa epoch mengindikasikan adanya ketidakstabilan generalisasi ringan. Pada grafik loss, penurunan tajam terjadi sejak epoch pertama dan kedua, kemudian melandai dengan stabil, yang merupakan tanda bahwa proses optimisasi berjalan normal dan model berhasil menemukan lembah konvergensi yang wajar.




Gambar 4.5 Confusion Matrix Test Skenario 225°

Berdasarkan Gambar 4.5, confusion matrix pada data uji skenario 225° menunjukkan bahwa kelas embun_bulu kembali menjadi kelas dengan klasifikasi paling akurat (53 benar dari total sampelnya), diikuti kelas sehat (45 benar), sementara embun_tepung memiliki tingkat kesalahan tertinggi dengan 11 sampel salah diklasifikasikan sebagai sehat. Pola kesalahan antara embun_tepung dan sehat ini konsisten dengan yang ditemukan pada skenario 45°, memperkuat indikasi bahwa karakteristik visual kedua kelas ini memang membutuhkan teknik augmentasi yang lebih beragam untuk dapat dibedakan secara optimal oleh model.




Gambar 4.6 Per-Class Metrics dan Final Test Metrics Skenario 225°

Berdasarkan Gambar 4.6, metrik per kelas pada skenario 225° menunjukkan profil yang serupa dengan skenario 45° , dengan recall kelas embun_bulu yang tinggi dan presisi kelas embun_tepung yang lebih rendah. Nilai akurasi akhir sebesar 77,22% hanya berbeda 0,56 poin persentase dari skenario 45° , yang secara statistik dapat dianggap setara. Hal ini secara teknis dapat dipahami karena rotasi 225° setara dengan rotasi 45° yang kemudian dilanjutkan dengan rotasi 180° , sehingga menghasilkan variasi orientasi diagonal yang serupa namun dengan arah berlawanan. Kedua sudut ini sama-sama menghasilkan pergeseran orientasi diagonal yang bermakna bagi model tanpa memperkenalkan distorsi geometris yang merusak ciri morfologis daun melon.



Gambar 4.7 Training History Skenario 90°

Berdasarkan Gambar 4.7, grafik *training history* skenario rotasi 90° memperlihatkan anomali yang sangat jelas: akurasi pelatihan maupun validasi sama sekali tidak meningkat secara bermakna sepanjang tujuh epoch pelatihan, keduanya stagnan di kisaran 0,318–0,334. Secara bersamaan, kurva *loss* justru meningkat dari epoch pertama ke epoch ketujuh, bukan menurun. Pola ini merupakan indikasi kuat terjadinya *underfitting* parah di mana model gagal total dalam mempelajari pola dari data latih yang telah diaugmentasi dengan rotasi 90° .



Gambar 4.8 Confusion Matrix Test Skenario 90°

Berdasarkan Gambar 4.8, *confusion matrix* pada data uji mengonfirmasi kegagalan model secara eksplisit: seluruh 180 sampel uji (60 per kelas) diprediksi sebagai kelas *embun_bulu* tanpa terkecuali. Tidak ada satu pun sampel dari kelas *embun_tepung* maupun *sehat* yang berhasil diklasifikasikan dengan benar. Pola serupa juga tampak pada confusion matrix validasi. Kondisi ini dikenal sebagai *class collapse*, yaitu kondisi di mana model hanya memprediksi satu kelas dominan untuk semua input, yang ekuivalen dengan performa acak pada masalah tiga kelas (33,33%).

Secara keseluruhan, hasil pengujian delapan skenario augmentasi rotasi menunjukkan bahwa teknik ini memiliki pengaruh yang sangat bervariasi dan sangat bergantung pada kesesuaian sudut rotasi dengan karakteristik visual objek yang diklasifikasikan. Dari delapan skenario yang diuji, enam skenario (45°, 135°, 180°, 225°, 270°, dan 315°) menghasilkan akurasi di atas 64%, sedangkan satu skenario (90°) mengalami kegagalan total dengan class collapse.

Pola umum yang dapat diidentifikasi adalah bahwa sudut-sudut rotasi diagonal (45° , 135° , 225° , 315°) cenderung menghasilkan performa yang lebih baik dibandingkan rotasi ortogonal (90°) maupun kondisi tanpa rotasi (0°). Hal ini konsisten dengan sifat visual daun melon yang memiliki fitur morfologis — seperti venasi daun, batas tepi, dan distribusi bercak penyakit — yang tidak berorientasi secara vertikal maupun horizontal secara ketat. Rotasi diagonal memperkenalkan variasi yang cukup signifikan untuk meningkatkan keragaman data latih tanpa mengubah konteks visual daun secara berlebihan, sehingga mendorong model untuk mempelajari representasi fitur yang lebih bersifat rotasi-invarian.

Sebaliknya, rotasi 90° menunjukkan bahwa tidak semua augmentasi rotasi bersifat menguntungkan. Perubahan orientasi yang terlalu ekstrem dapat merusak koherensi distribusi fitur pada lapisan konvolusi awal CNN, yang pada akhirnya mengakibatkan kegagalan proses pembelajaran secara keseluruhan. Temuan ini menegaskan bahwa pemilihan rentang sudut rotasi dalam augmentasi data bukan merupakan keputusan yang trivial, melainkan harus mempertimbangkan karakteristik geometris dan orientasi natural dari objek dalam dataset.

Dengan demikian, augmentasi rotasi pada sudut-sudut diagonal — khususnya 45° dan 225° — terbukti menjadi konfigurasi yang paling efektif untuk meningkatkan performa CNN dalam tugas klasifikasi kondisi daun melon pada penelitian ini.

4.1.2 Hasil Pengujian Skenario Zoom Only


Pengujian pada skenario augmentasi zoom dilakukan dengan menerapkan enam variasi intensitas zoom secara terpisah terhadap data latih, yaitu 0%, 10%, 20%, 30%, 40%, dan 50%. Augmentasi zoom mensimulasikan variasi jarak pengambilan gambar dengan cara memperbesar atau memperkecil area pandang pada citra secara acak dalam rentang intensitas yang ditentukan. Tujuan pengujian ini adalah untuk menganalisis sejauh mana intensitas zoom memengaruhi kemampuan generalisasi model CNN dalam mengklasifikasikan kondisi daun melon. Hasil lengkap keenam skenario disajikan pada Tabel 4.2.

Tabel 4.2 Perbandingan Metrik Evaluasi Skenario Zoom Only pada Data Uji

Skenario Zoom	<i>Accuracy</i>	<i>Precision (Macro)</i>	<i>Recall (Macro)</i>	<i>F1-Score (Macro)</i>
0%	0.3333	0.1111	0.3333	0.1667
10%	0.7056	0.7254	0.7056	0.7073
20%	0.7261	0.7202	0.7335	0.7178
30%	0.7006	0.7091	0.6974	0.6930
40%	0.7556	0.7532	0.7556	0.7519
50%	0.7000	0.7622	0.7000	0.7039

Berdasarkan Tabel 4.6, terdapat perbedaan performa yang sangat mencolok antara skenario *zoom* 0% dan seluruh skenario yang menerapkan zoom aktif. Skenario zoom 0% menghasilkan akurasi sebesar 0,3333 yang mengindikasikan kegagalan total model, sedangkan skenario-skenario dengan zoom aktif semuanya menghasilkan akurasi di atas 0,70. Di antara skenario zoom aktif, terdapat tren peningkatan performa dari 10% hingga puncaknya pada 40%, diikuti penurunan pada 50%. Konfigurasi terbaik adalah zoom 40% dengan akurasi 0,7556 dan F1-score 0,7519, sementara konfigurasi terburuk adalah zoom 0% yang mengalami

class collapse. Pembahasan berikut difokuskan pada analisis kedua konfigurasi ekstrem tersebut serta fenomena penurunan performa pada zoom 50%.




Gambar 4.9 Confusion Matrix Test Zoom 0%

Berdasarkan Gambar 4.9, *confusion matrix* pada data uji skenario *zoom 0%* memperlihatkan kondisi *class collapse* yang serupa dengan yang ditemukan pada skenario rotasi 90° : seluruh 180 sampel uji tanpa terkecuali diprediksi sebagai kelas sehat, baik sampel yang berasal dari kelas *embun_bulu*, *embun_tepung*, maupun sehat itu sendiri. Tidak ada satu pun sampel dari kelas *embun_bulu* dan *embun_tepung* yang berhasil diklasifikasikan dengan benar. Akibatnya, nilai *recall* hanya berasal dari prediksi kelas sehat yang kebetulan tepat, sementara presisi secara keseluruhan sangat rendah (0,1111).

Kegagalan ini memiliki penjelasan teknis yang berbeda dari skenario rotasi 90° . Pada *zoom 0%*, augmentasi zoom tidak benar-benar diterapkan — gambar diproses dalam ukuran aslinya tanpa variasi skala apapun. Dalam konteks implementasi augmentasi berbasis *Keras/TensorFlow*, nilai *zoom* range sebesar 0 secara efektif menonaktifkan lapisan augmentasi *zoom*, sehingga tidak ada

keragaman skala yang diperkenalkan ke dalam data latih. Model yang dilatih dalam kondisi ini menjadi sangat sensitif terhadap skala tampilan objek dan tidak memiliki kapasitas untuk mengenali pola penyakit yang muncul pada skala yang berbeda. Lebih lanjut, tanpa variasi zoom, model cenderung mengeksploitasi bias distribusi kelas pada data latih dan mempelajari fitur-fitur yang berkorelasi dengan kelas mayoritas atau kelas yang paling mudah dipisahkan secara statistik, yang dalam kasus ini menyebabkan model kolaps ke prediksi kelas sehat. Fenomena ini menunjukkan bahwa augmentasi *zoom* bukan sekadar pelengkap, melainkan memiliki peran fundamental dalam membantu model mempelajari representasi fitur yang bersifat *skala-invariant* (scale-invariant).



Gambar 4.10 Grafik Akurasi, Loss, Confusion Matrix, dan Per-Class Metrics Skenario Zoom Only

Berdasarkan Gambar 4.10, *confusion matrix* pada data uji skenario *zoom* 40% memperlihatkan distribusi prediksi yang jauh lebih seimbang dibandingkan skenario *zoom* 0%. Kelas *embun_bulu* diklasifikasikan dengan tingkat kebenaran tertinggi, di mana 55 dari 60 sampel berhasil diprediksi dengan tepat dan hanya 5 sampel salah diklasifikasikan sebagai *embun_tepung*. Kelas *sehat* juga menunjukkan performa yang baik dengan 43 dari 60 sampel terklasifikasi benar,

dengan kesalahan utama berupa 9 sampel yang salah diprediksi sebagai *embun_bulu* dan 8 sampel sebagai *embun_tepung*. Kelas *embun_tepung* menjadi kelas dengan tingkat kesalahan tertinggi: dari 60 sampel, hanya 38 yang diprediksi benar, sementara 19 sampel salah diklasifikasikan sebagai sehat dan 3 sampel sebagai *embun_bulu*.

Pola kesalahan pada kelas *embun_tepung* yang cenderung salah diprediksi sebagai sehat ini konsisten dengan temuan pada skenario rotasi dan mencerminkan tantangan *inheren* pada dataset. Gejala awal *infeksi embun tepung (powdery mildew)* pada daun melon sering kali hanya menampilkan bercak putih halus yang secara visual dapat menyerupai permukaan daun sehat dalam kondisi pencahayaan tertentu. Augmentasi *zoom 40%* membantu model menangkap detail tekstur ini pada berbagai skala, namun tidak sepenuhnya mengeliminasi *ambiguitas* visual tersebut.

Secara teknis, keunggulan *zoom 40%* dapat dijelaskan melalui konsep *receptive field* dalam arsitektur CNN. Dengan intensitas *zoom* hingga 40%, model diekspos pada gambar daun yang diperbesar (*zoom-in*) maupun diperkecil (*zoom-out*) secara acak dalam rentang tersebut selama pelatihan. Kondisi *zoom-in* memaksa model untuk mempelajari fitur-fitur tekstural lokal dari penyakit — seperti detail *spora*, bercak, dan perubahan warna — pada resolusi yang lebih tinggi, sehingga *filter-filter* konvolusi pada lapisan awal memperoleh supervisi yang lebih kaya untuk mendeteksi pola mikro. Sebaliknya, kondisi *zoom-out* memberikan konteks global yang lebih luas, membantu model memahami distribusi spasial gejala penyakit pada keseluruhan permukaan daun. Keseimbangan antara

kedua perspektif ini pada intensitas 40% tampaknya merupakan rentang optimal yang sesuai dengan skala natural variasi pengambilan gambar daun melon di lapangan.

4.1.3 Hasil Pengujian Skenario Flip Only

Pengujian skenario flip only membandingkan dua jenis augmentasi cermin, yaitu horizontal flip dan vertical flip. Kedua skenario dijalankan secara terpisah tanpa augmentasi tambahan lainnya. Hasil evaluasi pada data uji disajikan pada Tabel 4.3 berikut.


Tabel 4.3 Perubahan Konfigurasi pada Skenario 3

Skenario Flip	<i>Accuracy</i>	<i>Precision (Macro)</i>	<i>Recall (Macro)</i>	<i>F1-Score (Macro)</i>
Horizontal Flip	0.7516	0.7520	0.7592	0.7471
Vertical Flip	0.7771	0.7792	0.7814	0.7674

Hasil pengujian menunjukkan bahwa kedua jenis flip memberikan performa yang relatif tinggi dibandingkan skenario rotation dan zoom. Horizontal flip memperoleh *accuracy* 0.7516, *precision* macro 0.7520, *recall* macro 0.7592, dan *F1-score* macro 0.7471. Sementara itu, vertical flip menghasilkan performa yang lebih baik di seluruh metrik, dengan *accuracy* 0.7771, *precision* macro 0.7792, *recall* macro 0.7814, dan *F1-score* macro 0.7674. Vertical flip ditetapkan sebagai konfigurasi terbaik pada skenario flip only.

Keunggulan vertical flip atas horizontal flip dapat dijelaskan dari perspektif sifat visual data. Pada citra daun melon, penyakit seperti embun bulu dan embun tepung umumnya memiliki pola distribusi yang tidak simetris secara vertikal, sehingga pembalikan vertikal menghasilkan variasi yang lebih bermakna secara semantik bagi model. Horizontal flip, meskipun juga memberikan augmentasi yang

berguna, menghasilkan variasi yang lebih terbatas karena struktur visual daun cenderung simetris secara horizontal. Secara keseluruhan, skenario flip only memberikan performa terbaik dibandingkan rotation only dan zoom only, yang mengindikasikan bahwa variasi orientasi cermin lebih efektif dalam meningkatkan generalisasi model pada dataset ini.



Gambar 4.11 Grafik Akurasi, Loss, Confusion Matrix, dan Per-Class Metrics Skenario Flip Only

4.1.4 Hasil Model Final Classification


Setelah seluruh eksperimen *OVAT* pada variabel rotasi, *zoom*, dan *flip* diselesaikan, tahap akhir penelitian ini melibatkan konstruksi model final yang mengintegrasikan konfigurasi augmentasi terbaik dari setiap variabel yang telah

diuji secara individual. Tahap ini berfungsi sebagai validasi empiris untuk mengonfirmasi apakah kombinasi konfigurasi augmentasi optimal yang diperoleh melalui pendekatan OVAT benar-benar menghasilkan peningkatan performa yang terukur dan konsisten dibandingkan model tanpa augmentasi. Dua skenario dibandingkan secara langsung: Skenario A sebagai *baseline* tanpa augmentasi, dan Skenario B yang menerapkan kombinasi augmentasi terbaik berupa rotasi 45°, zoom 40%, dan vertical flip. Hasil perbandingan lengkap keduanya disajikan pada Tabel 4.4.

Tabel 4.4 Hasil Evaluasi Model Final Two-Stage Classification pada Data Uji

Metrik	Skenario A (Tanpa Augmentasi)	Skenario B (Dengan Augmentasi)	Peningkatan
Accuracy	0,7667	0,7889	+0,0222
Precision	0,7840	0,8043	+0,0203
Recall	0,7667	0,7889	+0,0222
F1-Score	0,7675	0,7924	+0,0249

Berdasarkan Tabel 4.4, Skenario B secara konsisten mengungguli Skenario A pada seluruh metrik evaluasi. Peningkatan *F1-score* sebesar 0,0249 merupakan peningkatan yang paling signifikan di antara keempat metrik, mengindikasikan bahwa augmentasi tidak hanya meningkatkan akurasi secara keseluruhan, tetapi juga memperbaiki keseimbangan antara presisi dan recall secara proporsional. Pembahasan berikut menganalisis pengaruh augmentasi terhadap stabilitas pelatihan, *generalisasi*, dan distribusi prediksi per kelas secara lebih mendalam.



Gambar 4. 12 Validation Accuracy dan Validation Loss A vs B


Berdasarkan Gambar 4.12, grafik *validation accuracy* menunjukkan perbedaan karakteristik pelatihan yang mencolok antara kedua skenario. Skenario A (biru) memperlihatkan lonjakan akurasi validasi yang sangat tinggi pada *epoch* ke-1 hingga ke-2, mencapai sekitar 0,78, namun kemudian mengalami *fluktuasi ekstrem* yang tidak stabil sepanjang *epoch* ke-3 hingga ke-12, dengan *amplitudo osilasi* yang dapat mencapai selisih hingga 0,15 poin dalam satu *epoch* ke *epoch* berikutnya. Setelah *epoch* ke-12, akurasi validasi Skenario A relatif melandai dan *stagnan* di kisaran 0,65–0,72.

Skenario B (oranye) menampilkan pola yang berbeda secara fundamental: akurasi validasi memulai dari titik yang lebih rendah pada *epoch* awal (sekitar 0,35), namun meningkat secara lebih *gradual* dan bertahap, dengan *amplitudo fluktuasi* yang jauh lebih kecil. Mulai *epoch* ke-15, Skenario B menunjukkan tren peningkatan yang konsisten dan akhirnya melampaui Skenario A, mencapai akurasi validasi sekitar 0,73 pada akhir pelatihan.

Pola ini secara teknis mencerminkan perbedaan mendasar dalam dinamika *generalisasi* kedua model. Pada Skenario A, lonjakan awal yang tinggi namun tidak stabil mengindikasikan bahwa model dengan cepat menghafal pola-pola dominan dalam data latih yang tidak diaugmentasi, namun *representasi* yang dihasilkan

terlalu spesifik dan sensitif terhadap variasi kecil pada data validasi — suatu gejala klasik *overfitting* terhadap distribusi pelatihan. Sebaliknya, pada Skenario B, augmentasi secara efektif bertindak sebagai regularizer implisit: dengan memperkenalkan variasi *transformasi* geometris secara terus-menerus pada setiap *epoch*, model dipaksa untuk tidak mengandalkan fitur-fitur posisi atau skala yang spesifik, melainkan membangun *representasi* yang lebih abstrak dan umum. Proses ini membutuhkan lebih banyak *epoch* untuk *konvergen*, namun menghasilkan kurva validasi yang lebih stabil dan model yang lebih *robust*.

Pada grafik *validation loss*, pola yang sama dapat diamati: kurva Skenario A menunjukkan lonjakan *loss* yang dramatis pada beberapa *epoch* (terutama *epoch* ke-9 hingga ke-11, dengan *loss* mencapai 1,6), sedangkan Skenario B mempertahankan *loss* validasi yang lebih rendah dan lebih konsisten dalam rentang 0,6–0,9 sepanjang pelatihan. Lonjakan *loss* pada Skenario A merupakan indikasi bahwa model sesekali membuat prediksi dengan kepercayaan tinggi namun salah (*high-confidence errors*), yang merupakan konsekuensi langsung dari overfitting terhadap distribusi data latih yang tidak beragam.




Gambar 4.13 Confusion Matrix Skenario A dan B

Berdasarkan Gambar 4.13, perbandingan *confusion matrix* antara Skenario A dan Skenario B mengungkapkan perubahan distribusi kesalahan yang bermakna secara kualitatif, tidak hanya secara kuantitatif.

Pada Skenario A, kelas *embun_tepung* memiliki performa klasifikasi terbaik dengan 52 dari 60 sampel terprediksi benar. Kelas *embun_bulu* menghasilkan 45 prediksi benar dengan 11 sampel salah diklasifikasikan sebagai *embun_tepung* pola kesalahan yang konsisten dengan kemiripan visual antara tahap awal infeksi embun bulu dengan gejala embun tepung. Kelas sehat memiliki performa paling lemah pada Skenario A, dengan hanya 41 prediksi benar dan 15 sampel yang salah diklasifikasikan sebagai *embun_tepung*, mengindikasikan bahwa model tanpa augmentasi kesulitan memisahkan daun sehat dari daun yang terinfeksi embun tepung ringan.

Pada Skenario B, profil prediksi mengalami redistribusi yang signifikan. Kelas *embun_tepung* mempertahankan tingkat klasifikasi yang tinggi (47 benar), sementara kelas *embun_bulu* meningkat menjadi 47 benar — naik dari 45 pada Skenario A. Yang paling menonjol, kelas sehat meningkat menjadi 48 prediksi benar dari sebelumnya 41, suatu peningkatan substansial sebesar 17% untuk kelas yang sebelumnya paling bermasalah. Namun, perlu dicatat bahwa pada Skenario B, kelas *embun_tepung* kini memiliki 13 sampel yang salah diprediksi sebagai sehat — lebih tinggi dibanding Skenario A yang hanya 5. Pertukaran kesalahan ini mengindikasikan bahwa augmentasi berhasil meningkatkan kemampuan model dalam mengenali daun sehat, namun pada saat yang sama sedikit menurunkan kemampuan *diskriminasi* antara *embun_tepung* dengan sehat, kemungkinan karena

variasi geometris yang diperkenalkan augmentasi *zoom* dan rotasi membuat batas keputusan (*decision boundary*) antara kedua kelas ini menjadi lebih lunak.




Gambar 4.14 F1-Score Per Kelas Skenario A vs B

Berdasarkan Gambar 4.14, grafik *F1-score* per kelas memperlihatkan bahwa peningkatan performa akibat augmentasi tidak terdistribusi secara merata di antara ketiga kelas. Kelas *embun_bulu* mengalami peningkatan *F1-score* yang paling signifikan, dari sekitar 0,80 pada Skenario A menjadi sekitar 0,87 pada Skenario B. Peningkatan ini secara teknis dapat dikaitkan dengan efek kombinasi augmentasi rotasi 45° dan *vertical flip* yang sangat relevan untuk kelas ini: gejala embun bulu (*downy mildew*) pada daun melon umumnya muncul sebagai lesi berbentuk *angular* yang mengikuti batas-batas *venasi* daun, sehingga variasi *orientasi* yang diperkenalkan oleh rotasi dan *flip* membantu model mempelajari pola *geometris* lesi ini dari berbagai sudut pandang.

Kelas *embun_tepung* juga mengalami peningkatan *F1-score* yang moderat, dari sekitar 0,76 menjadi 0,77. Peningkatan yang lebih kecil pada kelas ini konsisten dengan temuan pada *confusion matrix* bahwa augmentasi menyebabkan sedikit

peningkatan kesalahan klasifikasi antara *embun_tepung* dan sehat, sehingga efek positif augmentasi pada kelas ini tidak sebesar pada kelas *embun_bulu*.

Kelas sehat merupakan satu-satunya kelas yang menunjukkan penurunan *F1-score marginal* pada Skenario B, dari sekitar 0,75 menjadi sedikit di bawahnya. Penurunan ini, meskipun kecil, konsisten dengan meningkatnya kesalahan pada *confusion matrix* di mana 13 sampel *embun_tepung* diprediksi sebagai sehat. Fenomena ini menunjukkan bahwa augmentasi *zoom*, yang memperkenalkan variasi skala visual pada ciri-ciri *tekstural* halus, secara tidak langsung mempersulit model dalam membedakan tekstur permukaan daun yang terinfeksi embun tepung ringan dengan daun sehat pada skala tertentu.



Gambar 4.15 Perbandingan Metrik Keseluruhan A vs B

Berdasarkan Gambar 4.15, grafik perbandingan metrik keseluruhan pada data uji mengonfirmasi bahwa Skenario B secara konsisten mengungguli Skenario A pada seluruh metrik *agregat*. Selisih antara kedua skenario paling terlihat pada presisi (sekitar 0,02 poin), yang menandakan bahwa model dengan augmentasi lebih jarang membuat prediksi positif yang salah. Nilai akurasi, recall, dan F1 yang

seragam meningkat juga mengonfirmasi bahwa peningkatan performa bersifat *holistik* dan tidak hanya disebabkan oleh bias prediksi ke kelas tertentu.

4.2 Analisis Pengaruh Data Augmentation

Bagian ini menyajikan analisis pengaruh setiap teknik data augmentation terhadap performa model CNN dalam mengklasifikasikan kondisi daun melon. Eksperimen dilakukan menggunakan pendekatan *one-variable-at-a-time (OVAT)*, di mana setiap teknik augmentasi diuji secara independen dengan memvariasikan nilai parameternya, sementara seluruh komponen pelatihan lainnya dijaga konsisten. Metrik utama yang digunakan dalam analisis ini adalah accuracy pada testing set. Analisis mencakup tiga teknik augmentasi, yaitu *rotation*, *zoom*, dan *flip*, yang masing-masing dibahas secara terpisah sebelum disintesis pada bagian akhir untuk menentukan konfigurasi augmentasi terbaik yang akan diterapkan pada model CNN final.

4.2.1 Analisis Pengaruh Rotation

Eksperimen rotation dilakukan dengan menguji delapan nilai sudut rotasi yang berbeda, yaitu 0°, 45°, 90°, 135°, 180°, 225°, 270°, dan 315°. Hasil eksperimen menunjukkan bahwa pengaruh rotation terhadap performa model sangat bergantung pada nilai sudut yang diterapkan, dan tidak semua nilai sudut memberikan dampak yang positif. Ringkasan hasil eksperimen disajikan pada Tabel 4.5 berikut.

Tabel 4.5 Hasil Skenario Rotation

Sudut Rotasi	Accuracy
0°	67,78%
45°	77,78%
90°	33,33%

Sudut Rotasi	Accuracy
135°	74,44%
180°	73,33%
225°	77,22%
270°	74,52%
315°	64,44%

Tanpa augmentasi rotasi (0°), model mencapai *accuracy* sebesar 67,78%. Nilai ini menjadi *baseline* yang digunakan sebagai acuan untuk mengukur kontribusi bersih dari setiap konfigurasi rotation yang diuji. Dari delapan nilai sudut yang dievaluasi, rotasi 45° menghasilkan performa tertinggi dengan *accuracy* 77,78%, diikuti oleh rotasi 225° sebesar 77,22% dan rotasi 135° sebesar 74,44%. Sementara itu, rotasi 315° menghasilkan *accuracy* 64,44% yang berada di bawah baseline, dan rotasi 90° menghasilkan penurunan performa yang paling drastis dengan *accuracy* hanya 33,33%.

Pola hasil tersebut dapat dijelaskan melalui mekanisme kerja CNN dalam mengekstraksi fitur spasial. Rotasi pada sudut moderat seperti 45° memperkenalkan variasi orientasi yang cukup untuk memperkaya keragaman data latih, sehingga model terekspos pada pola tekstur daun dari sudut pandang yang lebih beragam tanpa mengubah bentuk keseluruhan objek secara berlebihan. Hal ini membantu model menjadi lebih *invariant* terhadap orientasi dan meningkatkan kemampuan generalisasinya terhadap data uji. Sebaliknya, rotasi 90° menghasilkan penurunan performa yang sangat signifikan hingga 33,33%, yang mendekati tingkat acak pada klasifikasi tiga kelas. Hal ini dapat terjadi karena rotasi tepat 90° mengubah orientasi daun secara ortogonal sehingga fitur spasial yang dipelajari model dari data latih tidak lagi sesuai dengan pola yang diekstraksi pada data uji, terutama apabila arsitektur CNN tidak memiliki mekanisme *rotation invariance* yang cukup

kuat untuk sudut-sudut yang bersifat tepat ortogonal. Selain itu, citra daun melon yang diambil di lapangan cenderung memiliki orientasi yang lebih variatif pada rentang sudut miring dibandingkan sudut tegak lurus, sehingga variasi 90° menghasilkan distribusi data latih yang justru tidak representatif terhadap kondisi nyata.

Rotasi 225° yang menghasilkan *accuracy* 77,22% menunjukkan bahwa variasi sudut pada rentang 180° – 270° juga mampu memberikan manfaat yang cukup signifikan. Namun, rotasi 315° yang menghasilkan penurunan di bawah baseline mengindikasikan bahwa tidak semua sudut dalam rentang tersebut bersifat menguntungkan. Hal ini menegaskan bahwa pemilihan nilai sudut rotasi harus didasarkan pada eksperimen empiris dan disesuaikan dengan karakteristik visual dataset yang digunakan, bukan sekadar asumsi bahwa semakin besar variasi rotasi akan selalu menghasilkan performa yang lebih baik.

4.2.2 Analisis Pengaruh Zoom

Eksperimen zoom dilakukan dengan menguji enam nilai rentang zoom yang berbeda, yaitu 0%, 10%, 20%, 30%, 40%, dan 50%. Hasil eksperimen menunjukkan bahwa zoom memberikan pola pengaruh yang berbeda dibandingkan rotation, dengan tren yang lebih kompleks dan tidak linear. Ringkasan hasil eksperimen disajikan pada Tabel 4.6 berikut.

Tabel 4.6 Hasil Skenario Zoom

Rentang Zoom	Accuracy
0%	33,33%
10%	70,56%
20%	72,61%
30%	70,06%
40%	75,56%

Hasil yang paling mencolok adalah kondisi tanpa augmentasi zoom (0%) yang menghasilkan *accuracy* hanya 33,33%, suatu nilai yang setara dengan tingkat prediksi acak pada klasifikasi tiga kelas. Perlu dicatat bahwa nilai *baseline* ini berbeda dengan nilai *baseline* pada eksperimen *rotation* (67,78%), yang mengindikasikan adanya variasi kondisi pelatihan antar eksperimen yang perlu dipertimbangkan dalam *interpretasi* hasil. Begitu zoom diterapkan pada rentang 10%, *accuracy* meningkat drastis menjadi 70,56%, yang menunjukkan bahwa augmentasi zoom bahkan pada nilai terkecil sekalipun memberikan manfaat substansial bagi kemampuan model dalam mempelajari fitur kondisi daun.

Peningkatan bertahap terlihat dari 10% menuju 20% (72,61%), kemudian terjadi penurunan moderat pada 30% (70,06%), sebelum mencapai nilai tertinggi pada 40% sebesar 75,56%. Nilai 50% kemudian kembali menurun ke 70,00%. Pola naik-turun yang tidak sepenuhnya monoton ini mencerminkan dinamika trade-off yang inheren dalam penerapan zoom augmentation. Pada rentang zoom yang terlalu kecil, variasi skala yang dihasilkan belum cukup signifikan untuk memberikan keragaman yang bermakna bagi proses pelatihan. Sebaliknya, pada rentang yang terlalu besar seperti 50%, proses crop yang agresif berpotensi membuang bagian penting dari citra daun, termasuk area dengan gejala penyakit yang menjadi fitur diskriminatif utama bagi model CNN. Kondisi ini mengakibatkan model kehilangan informasi visual yang dibutuhkan untuk membedakan karakteristik antar kelas secara efektif.

Rentang *zoom* 40% menghasilkan performa terbaik karena berada pada titik keseimbangan antara keragaman variasi skala yang diperkenalkan dan kelengkapan

informasi visual yang dipertahankan dalam citra. Pada rentang ini, model terekspos pada variasi jarak pengambilan gambar yang cukup luas sehingga mampu mengenali gejala visual kondisi daun pada berbagai tingkat perbesaran, tanpa kehilangan konteks spasial yang diperlukan untuk klasifikasi yang tepat.

4.2.3 Analisis Pengaruh Flip

Eksperimen flip dilakukan dengan membandingkan dua jenis transformasi cermin, yaitu *horizontal flip* dan *vertical flip*, yang masing-masing diuji secara terpisah. Berbeda dengan *rotation* dan *zoom* yang memiliki rentang parameter yang lebih luas, eksperimen *flip* bersifat dikotomis sehingga analisis difokuskan pada perbandingan langsung antara kedua jenis transformasi tersebut. Ringkasan hasil eksperimen disajikan pada Tabel 4.7 berikut.

Kedua jenis *flip* memberikan hasil yang relatif berdekatan, namun *vertical flip* menghasilkan performa yang lebih tinggi dengan *accuracy* 77,71% dibandingkan *horizontal flip* sebesar 75,16%. Perbedaan sebesar 2,55 poin persentase ini secara konsisten menunjukkan bahwa *vertical flip* lebih sesuai dengan karakteristik dataset citra daun melon yang digunakan dalam penelitian ini.

Perbedaan performa antara kedua jenis *flip* tersebut dapat dijelaskan melalui karakteristik visual kondisi daun melon yang diklasifikasikan. *Horizontal flip* membalik citra secara lateral dari kiri ke kanan, yang menghasilkan variasi yang secara biologis wajar karena gejala penyakit daun seperti koloni *spora* embun tepung maupun miselium embun bulu tidak memiliki preferensi kemunculan pada sisi kiri atau kanan daun. Namun, *vertical flip* membalik citra dari atas ke bawah, yang secara efektif mensimulasikan variasi orientasi pengambilan gambar dari

sudut yang berlawanan. Dalam kondisi pengambilan gambar di lapangan, variasi orientasi atas-bawah dapat terjadi ketika kamera diarahkan dari posisi yang berbeda terhadap permukaan daun, sehingga *vertical flip* menghasilkan variasi yang lebih relevan dan informatif bagi model dalam mempelajari pola distribusi gejala penyakit pada permukaan daun. Selain itu, pada citra daun melon, distribusi tekstur dan pola warna secara vertikal cenderung lebih bervariasi dibandingkan secara horizontal, sehingga *vertical flip* memberikan keragaman fitur yang lebih bernilai bagi proses pembelajaran CNN.

4.2.4 Pemilihan Konfigurasi Augmentasi Terbaik

Berdasarkan hasil analisis dari ketiga teknik augmentasi yang telah diuji, konfigurasi augmentasi terbaik yang dipilih untuk diterapkan pada pelatihan model CNN final adalah *rotation 45°*, *zoom 40%*, dan *vertical flip*. Pemilihan ini didasarkan pada nilai *accuracy* tertinggi yang secara konsisten dicapai oleh masing-masing konfigurasi dalam eksperimen per *variabel*, yaitu 77,78% untuk *rotation 45°*, 75,56% untuk *zoom 40%*, dan 77,71% untuk *vertical flip*.

Ketiga konfigurasi terpilih tersebut memiliki kesamaan karakteristik yang secara teknis menjelaskan mengapa masing-masing memberikan manfaat terbesar bagi performa model. *Rotation 45°* memperkenalkan variasi orientasi pada sudut miring yang secara *empiris* paling sesuai dengan keragaman orientasi pengambilan gambar di lapangan, tanpa menghasilkan *distorsi ortogonal* yang terbukti merusak performa model seperti yang ditunjukkan oleh *rotasi 90°*. *Zoom 40%* berada pada titik optimal yang menyeimbangkan keragaman variasi skala dengan kelengkapan informasi visual, sehingga model dapat mempelajari karakteristik gejala penyakit

pada berbagai tingkat perbesaran tanpa kehilangan area diagnostik yang krusial. *Vertical flip* terbukti lebih efektif dibandingkan *horizontal flip* dalam menghasilkan variasi yang relevan dengan karakteristik pengambilan gambar daun melon di lapangan, sehingga variasi yang dihasilkan lebih informatif bagi proses pembelajaran CNN.

Secara keseluruhan, hasil eksperimen ini menegaskan bahwa augmentasi tidak bersifat *universal* dan tidak selalu memberikan peningkatan performa. Terbukti bahwa rotation 90° justru menurunkan *accuracy* secara drastis, sementara konfigurasi *zoom* yang terlalu besar maupun terlalu kecil juga memberikan hasil yang kurang optimal. Hal ini menekankan pentingnya pemilihan teknik dan parameter augmentasi yang disesuaikan secara *empiris* dengan karakteristik spesifik dataset yang digunakan, dalam hal ini citra daun melon dengan variasi visual yang khas dari kondisi *agroekosistem* tropis. Konfigurasi terpilih kemudian diterapkan secara terpadu pada tahap pelatihan model CNN final sebagai *implementasi* hasil analisis augmentasi dalam penelitian ini.

4.3 Integrasi Sains dan Islam

Penelitian ini berfokus pada analisis pengaruh teknik data augmentation terhadap kinerja Convolutional Neural Network (CNN) dalam klasifikasi kondisi daun melon berbasis citra digital. Pengembangan teknologi kecerdasan buatan dalam bidang pertanian pada penelitian ini bertujuan untuk membantu proses deteksi dini penyakit tanaman secara lebih cepat, konsisten, dan efisien. Dengan adanya sistem klasifikasi otomatis, petani dapat melakukan penanganan penyakit lebih awal sehingga potensi kerusakan tanaman dan penurunan hasil panen dapat

diminimalkan. Pemanfaatan teknologi tersebut selaras dengan ajaran Islam yang menekankan pentingnya menjaga keberlanjutan sumber daya alam dan memanfaatkan ilmu pengetahuan untuk kemaslahatan manusia.

Dalam perspektif Islam, manusia memiliki tanggung jawab sebagai khalifah di bumi untuk menjaga keseimbangan alam dan mengelola hasil pertanian secara bijak. Prinsip tersebut sejalan dengan penelitian ini yang berupaya mendukung keberlanjutan produksi melon melalui teknologi deteksi penyakit berbasis kecerdasan buatan. Allah SWT berfirman dalam Surah Al-An'am ayat 141:

وَهُوَ الَّذِي أَنشَأَ جَنَّاتٍ مَّعْرُوشَاتٍ وَغَيْرَ مَعْرُوشَاتٍ وَالنَّخْلَ وَالزَّرْعَ مُخْتَلِفًا أَكُلُهُ ۖ وَالزَّيْتُونَ وَالرُّمَّانَ مُتَشَابِهًا وَغَيْرَ مُتَشَابِهٍ ۚ كُلُوا مِنْ ثَمَرِهِ إِذَا أَثْمَرَ وَآتُوا حَقَّهُ ۖ وَلَا تَسْرِفُوا ۚ إِنَّهُ لَا يُحِبُّ الْمُسْرِفِينَ (141)

“Dialah yang menumbuhkan tanaman-tanaman yang merambat dan yang tidak merambat, pohon kurma, tanaman yang beraneka ragam rasanya, serta zaitun dan delima yang serupa (bentuk dan warnanya) dan tidak serupa (rasanya). Makanlah buahnya apabila ia berbuah dan berikanlah haknya (zakatnya) pada waktu memetik hasilnya. Akan tetapi, janganlah berlebih-lebihan. Sesungguhnya Allah tidak menyukai orang-orang yang berlebih-lebihan.” (QS. Al-An'am [6]:141).

Dalam Tafsir Ibnu Katsir, dijelaskan bahwa Allah SWT menciptakan berbagai tanaman dan hasil bumi sebagai bentuk kekuasaan serta nikmat yang diberikan kepada manusia. Pada Surah Al-An'am ayat 141, Ibnu Katsir menafsirkan larangan “janganlah berlebih-lebihan” sebagai peringatan agar manusia tidak melampaui batas dalam memanfaatkan hasil pertanian dan nikmat yang diberikan Allah SWT. Ibnu Katsir menukil beberapa pendapat ulama, di antaranya kisah seseorang yang menghabiskan seluruh hasil panennya karena berlebihan dalam penggunaannya, sehingga turun ayat sebagai peringatan agar manusia bersikap seimbang dan tidak melampaui batas. Selain itu, Ibnu Katsir juga menjelaskan bahwa segala bentuk

tindakan yang melebihi ketentuan Allah termasuk dalam perilaku israf (berlebih-lebihan), karena sikap tersebut dapat menimbulkan kerusakan dan menghilangkan keberkahan. Oleh karena itu, manusia memiliki tanggung jawab untuk mengelola hasil bumi secara bijak, menjaga keseimbangan, dan tidak melakukan tindakan yang merusak.

Dalam konteks penelitian ini, penerapan teknologi Convolutional Neural Network (CNN) untuk klasifikasi kondisi daun melon dapat dipandang sebagai bentuk ikhtiar dalam menjaga kualitas hasil pertanian serta meminimalkan kerusakan tanaman akibat serangan penyakit. Melalui proses identifikasi penyakit berbasis citra, petani dapat mengetahui kondisi tanaman secara lebih cepat dan akurat sehingga penanganan dapat dilakukan sedini mungkin. Dengan adanya deteksi dini tersebut, risiko gagal panen dapat dikurangi dan penggunaan pestisida dapat dilakukan secara lebih tepat sasaran. Pemanfaatan teknologi kecerdasan buatan dalam bidang pertanian ini tidak hanya memberikan manfaat secara teknis, tetapi juga mencerminkan tanggung jawab manusia dalam menjaga amanah terhadap sumber daya alam yang telah diberikan Allah SWT.

Hal tersebut sejalan dengan firman Allah SWT dalam Surah Al-An'am ayat 141 yang menjelaskan bahwa manusia diperintahkan untuk memanfaatkan hasil bumi dengan baik dan tidak berlebihan dalam penggunaannya. Dalam Tafsir Ibnu Katsir dijelaskan bahwa larangan berlebih-lebihan (israf) mencakup segala bentuk tindakan yang melampaui batas sehingga dapat menimbulkan kerusakan dan menghilangkan keberkahan. Manusia diperintahkan untuk menjaga keseimbangan dalam memanfaatkan nikmat yang diberikan Allah SWT serta mengelola hasil bumi

secara bijaksana. Oleh karena itu, penggunaan teknologi dalam penelitian ini dapat dipahami sebagai upaya untuk membantu pengelolaan pertanian secara lebih efektif, efisien, dan tidak berlebihan dalam penggunaan sumber daya maupun bahan kimia pertanian.

Selain itu, penelitian ini juga berkaitan dengan konsep Maqashid Syariah, khususnya pada aspek hifz al-mal (menjaga harta) dan hifz al-bi'ah (menjaga lingkungan). Pada aspek hifz al-mal, sistem klasifikasi penyakit daun melon dapat membantu petani mengurangi kerugian ekonomi akibat keterlambatan penanganan penyakit tanaman. Hasil penelitian menunjukkan bahwa Skenario 3 dengan augmentasi menghasilkan performa terbaik dengan *accuracy* sebesar 72,78% dan macro F1-score sebesar 72,71%, sehingga skenario mampu melakukan klasifikasi penyakit daun melon dengan lebih baik dibandingkan skenario lainnya. Dengan kemampuan identifikasi yang lebih akurat, proses pengendalian penyakit dapat dilakukan lebih cepat sehingga kualitas dan kuantitas hasil panen tetap terjaga. Hal ini sejalan dengan tujuan syariat Islam yang menekankan pentingnya menjaga harta dan menghindari kerugian.

Pada aspek hifz al-bi'ah, penelitian ini mendukung upaya pelestarian lingkungan melalui penggunaan teknologi yang membantu pengelolaan pertanian secara lebih terarah. Sistem klasifikasi berbasis citra memungkinkan identifikasi penyakit dilakukan secara lebih spesifik sehingga penggunaan pestisida dapat disesuaikan dengan kondisi tanaman yang terinfeksi. Dengan demikian, risiko penggunaan bahan kimia secara berlebihan yang dapat mencemari tanah dan lingkungan dapat diminimalkan. Pendekatan tersebut selaras dengan ajaran Islam

yang menekankan pentingnya menjaga keseimbangan alam dan menghindari kerusakan di muka bumi.

Hasil penelitian ini juga menunjukkan bahwa pemanfaatan ilmu pengetahuan dan teknologi perlu dilakukan secara bijaksana dan sesuai kebutuhan. Berdasarkan hasil eksperimen, tidak semua teknik augmentasi memberikan dampak positif terhadap performa skenario. Pada Skenario 1 dan Skenario 2, penerapan augmentasi dengan intensitas yang lebih agresif justru menurunkan performa klasifikasi dibandingkan skenario tanpa augmentasi. Sebaliknya, pada Skenario 3 augmentasi yang disesuaikan dengan karakteristik visual daun melon mampu meningkatkan performa skenario secara signifikan. Kondisi tersebut menunjukkan bahwa penggunaan teknologi memerlukan keseimbangan dan ketepatan penerapan agar menghasilkan manfaat yang optimal. Prinsip ini sejalan dengan nilai Islam yang melarang sikap berlebih-lebihan (*israf*) dalam melakukan suatu tindakan.

Dengan demikian, penelitian ini tidak hanya berkontribusi pada pengembangan teknologi klasifikasi penyakit tanaman berbasis Convolutional Neural Network, tetapi juga menunjukkan bahwa pemanfaatan kecerdasan buatan dapat selaras dengan nilai-nilai Islam dan prinsip Maqashid Syariah. Melalui penggunaan teknologi secara bertanggung jawab dan proporsional, penelitian ini diharapkan dapat membantu petani dalam menjaga kualitas hasil pertanian, mendukung keberlanjutan lingkungan, serta menjadi bentuk ikhtiar manusia dalam menjaga keseimbangan alam sesuai ajaran Islam.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan seluruh rangkaian eksperimen dan analisis yang telah dilakukan, penelitian ini berhasil mencapai tujuan utama, yaitu menganalisis pengaruh teknik data augmentation terhadap kinerja model CNN dalam klasifikasi kondisi daun melon yang terdiri atas tiga kelas, yaitu sehat, embun tepung, dan embun bulu. Hasil penelitian menunjukkan bahwa penerapan konfigurasi augmentasi terbaik mampu meningkatkan performa model CNN dibandingkan model *baseline*. *Accuracy* meningkat dari 76,67% menjadi 78,89%, *precision* meningkat dari 78,40% menjadi 80,43%, *recall* meningkat dari 76,67% menjadi 78,89%, dan *F1-score* meningkat dari 76,75% menjadi 79,24%. Peningkatan tersebut menunjukkan bahwa augmentasi yang dirancang sesuai dengan karakteristik dataset mampu meningkatkan kemampuan generalisasi model dalam mengenali variasi visual kondisi daun melon.

Pada pengujian variasi *rotation*, konfigurasi terbaik diperoleh pada sudut rotasi 45° dengan *accuracy* sebesar 77,78%, sedangkan performa terendah diperoleh pada rotasi 90° dengan *accuracy* sebesar 33,33%. Hasil ini menunjukkan bahwa rotasi moderat mampu meningkatkan keragaman orientasi data tanpa mengubah karakteristik visual utama daun secara signifikan. Sebaliknya, rotasi *ortogonal* pada sudut 90° menyebabkan perubahan distribusi spasial fitur yang terlalu ekstrem sehingga pola visual penyakit yang telah dipelajari model menjadi

lebih sulit dikenali. Temuan ini menunjukkan bahwa tidak semua nilai rotasi memberikan dampak positif terhadap performa CNN.

Pada pengujian variasi *zoom*, konfigurasi terbaik diperoleh pada nilai *zoom* 40% dengan *accuracy* sebesar 75,56%, sedangkan performa terendah diperoleh pada kondisi tanpa *zoom* (0%) dengan *accuracy* sebesar 33,33%. Hasil tersebut menunjukkan bahwa augmentasi *zoom* mampu membantu model mempelajari variasi ukuran objek yang dapat terjadi akibat perbedaan jarak pengambilan gambar di lapangan. Namun, ketika nilai *zoom* ditingkatkan hingga 50%, performa model mengalami penurunan menjadi 70,00%. Kondisi ini mengindikasikan bahwa pembesaran yang terlalu besar dapat menghilangkan sebagian area diagnostik penting pada daun sehingga informasi visual yang digunakan model untuk melakukan klasifikasi menjadi berkurang.

Pada pengujian variasi *flip*, konfigurasi terbaik diperoleh pada *vertical flip* dengan *accuracy* sebesar 77,71%, sedangkan *horizontal flip* menghasilkan *accuracy* sebesar 75,16%. Hasil ini menunjukkan bahwa transformasi *flip* mampu menambah variasi spasial data latih tanpa mengubah karakteristik visual utama penyakit. *Vertical flip* memberikan performa yang lebih baik karena menghasilkan variasi orientasi yang lebih sesuai dengan karakteristik dataset yang digunakan, sehingga model mampu mempelajari pola visual penyakit secara lebih efektif.

Secara keseluruhan, penelitian ini menunjukkan bahwa pengaruh data augmentation terhadap performa CNN sangat dipengaruhi oleh jenis dan konfigurasi transformasi yang digunakan. Augmentasi yang sesuai dengan karakteristik visual dataset mampu meningkatkan kemampuan generalisasi model,

sedangkan augmentasi yang terlalu ekstrem justru dapat menurunkan performa klasifikasi. Berdasarkan hasil eksperimen, konfigurasi *rotation* 45°, *zoom* 40%, dan *vertical flip* dipilih sebagai konfigurasi augmentasi terbaik dan berhasil meningkatkan performa model CNN final dibandingkan model *baseline*. Temuan ini menunjukkan bahwa pemilihan strategi augmentasi yang tepat memiliki peran penting dalam meningkatkan kinerja CNN pada klasifikasi kondisi daun melon..

5.2 Saran

Berdasarkan hasil yang diperoleh dari proses klasifikasi citra kondisi daun melon menggunakan skenario Convolutional Neural Network, peneliti menyadari bahwa masih terdapat ruang untuk pengembangan di masa mendatang. Oleh karena itu, beberapa saran yang dapat dipertimbangkan dalam penelitian selanjutnya antara lain:

1. Penelitian ini menggunakan dataset citra daun melon yang dikumpulkan secara mandiri dari lingkungan greenhouse dengan tiga kelas, yaitu daun sehat, embun tepung, dan embun bulu. Untuk memperluas cakupan penelitian serta menguji kemampuan generalisasi skenario, disarankan agar penelitian selanjutnya menggunakan dataset yang lebih beragam, baik dari jumlah citra, variasi tingkat keparahan penyakit, maupun kondisi pencahayaan dan latar belakang yang berbeda. Dengan demikian, skenario CNN dapat diuji pada kondisi yang lebih mendekati variasi nyata di lapangan.
2. Arsitektur CNN yang digunakan dalam penelitian ini masih tergolong sederhana atau lightweight CNN, dengan parameter pelatihan yang relatif tetap selama tiga skenario pengujian. Mengacu pada hasil penelitian bahwa

perubahan strategi pelatihan dan penyederhanaan augmentasi dapat memengaruhi performa skenario, maka pada penelitian berikutnya disarankan untuk mengeksplorasi arsitektur yang lebih kompleks, melakukan modifikasi lanjutan pada konfigurasi jaringan, atau membandingkannya dengan pendekatan transfer *learning* agar dapat diketahui apakah performa klasifikasi dapat ditingkatkan lebih jauh.

3. Penelitian ini menunjukkan bahwa augmentasi tidak selalu meningkatkan performa skenario secara otomatis, karena pada beberapa skenario augmentasi yang terlalu agresif justru menurunkan hasil klasifikasi, sedangkan augmentasi yang lebih ringan pada Skenario 3 memberikan performa terbaik. Berdasarkan temuan tersebut, penelitian selanjutnya disarankan untuk menguji variasi augmentasi yang lebih terkontrol dan menyesuaikannya dengan karakteristik visual kondisi daun melon, khususnya pada aspek warna, tekstur, dan bercak daun yang menjadi ciri utama klasifikasi. Selain itu, penelitian lanjutan dapat dikembangkan menjadi sistem deteksi dini kondisi daun melon yang lebih praktis, misalnya dalam bentuk aplikasi berbasis web atau mobile untuk membantu petani melakukan identifikasi secara cepat di lapangan.

DAFTAR PUSTAKA

- Alzubaidi, L., Zhang, J., Humaidi, A. J., et al. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8, 53. <https://doi.org/10.1186/s40537-021-00444-8>
- Bhardwaj, R., et al. (2023). Deep learning-based plant disease detection: A review. *Artificial Intelligence in Agriculture*, 8, 45–60.
- Ferentinos, K. P. (2018). Deep learning skenarios for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318. <https://doi.org/10.1016/j.compag.2018.01.009>
- Food and Agriculture Organization of the United Nations. (2024). FAOSTAT statistical database. <https://www.fao.org/faostat>
- Ghorbani, M., et al. (2024). Recent advances in deep learning for plant disease detection: A comprehensive review. *Agronomy*, 14, 1021. <https://doi.org/10.3390/agronomy14051021>
- Goodfellow, I., Bengio, Y., & Courville, A. (2021). *Deep learning*. MIT Press.
- Howard, A., Sandler, M., Chu, G., et al. (2019). Searching for MobileNetV3. *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 1314–1324. <https://doi.org/10.1109/ICCV.2019.00140>
- Khan, A., Sohail, A., Zahoor, U., & Qureshi, A. S. (2023). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 56, 545–579.
- Keinath, A. P., & Rennberger, G. (2022). Powdery mildew on watermelon. *Clemson Cooperative Extension*. <https://lgpress.clemson.edu/publication/powdery-mildew-on-watermelon/>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8), 2674. <https://doi.org/10.3390/s18082674>
- Mahmood ur Rehman, M., Liu, J., & Nijabat, A. (2024). Leveraging convolutional neural networks for disease detection in vegetables: A comprehensive review. *Agronomy*, 14, 2231. <https://doi.org/10.3390/agronomy14102231>
- Mahmood, Z., et al. (2022). Deep learning for plant disease detection: A review. *Computers and Electronics in Agriculture*, 199, 107142.
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image based plant disease detection. *Frontiers in Plant Science*, 7, 1419. <https://doi.org/10.3389/fpls.2016.01419>

- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(60).
- Sladojevic, S., Arsenovic, M., Anderla, A., et al. (2016). *Deep neural networks based recognition of plant diseases by leaf image classification*. *Computational Intelligence and Neuroscience*, 2016, 3289801. <https://doi.org/10.1155/2016/3289801>
- Tian, M., Yu, R., Yang, W., et al. (2024). Effect of powdery mildew on the photosynthetic parameters and leaf microstructure of melon. *Agriculture*, 14(6), 886. <https://doi.org/10.3390/agriculture14060886>
- Too, E. C., Yujian, L., Njuki, S., & Yingchun, L. (2019). A comparative study of fine-tuning deep learning skenarios for plant disease identification. *Computers and Electronics in Agriculture*, 161, 272–279. <https://doi.org/10.1016/j.compag.2018.03.032>
- Xia, F., Xie, X., Wang, Z., et al. (2022). A novel computational framework for precision diagnosis and subtype discovery of plant with lesion. *Frontiers in Plant Science*, 12, 789630. <https://doi.org/10.3389/fpls.2021.789630>
- Zhang, S., Zhang, S., Zhang, C., Wang, X., & Shi, Y. (2019). Cucumber leaf disease identification using deep CNN. *Computers and Electronics in Agriculture*, 162, 422–430. <https://doi.org/10.1016/j.compag.2019.04.012>
- Ibnu Kasir, Isma'il bin Umar. (1999). *Tafsir Ibnu Kasir Juz 8: Al-An'am 111 s.d. Al-A'raf 87*. Bandung: Sinar Baru Algensindo.
- Kandel, I., Castelli, M., & Manzoni, L. (2022). *Brightness as an augmentation technique for image classification*. *Emerging Science Journal*, 6(4), 881–892. <https://doi.org/10.28991/ESJ-2022-06-04-015>