

**PENGUNAAN METODE *CONVOLUTIONAL NEURAL NETWORK* UNTUK
MENGKLASIFIKASI PENYAKIT PADA TANAMAN JAGUNG
BERDASARKAN CITRA DAUN**

SKRIPSI

Oleh :
MOHAMAD ABDUL ROZZAQ
NIM. 220605110018



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

**PENGUNAAN METODE *CONVOLUTIONAL NEURAL NETWORK*
UNTUK MENGLASIFIKASI PENYAKIT PADA TANAMAN
JAGUNG BERDASARKAN CITRA DAUN**

SKRIPSI

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

Oleh:
MOHAMAD ABDUL ROZZAQ
NIM. 220605110018

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

HALAMAN PERSETUJUAN


PENGUNAAN METODE *CONVOLUTIONAL NEURAL NETWORK* UNTUK MENGLASIFIKASI PENYAKIT PADA TANAMAN JAGUNG BERDASARKAN CITRA DAUN

SKRIPSI

Oleh :
MOHAMAD ABDUL ROZZAQ
NIM. 220605110018

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 22 Juni 2026

Pembimbing I,



Dr. M. Amin Hariyadi, M.T
NIP. 19670018 200501 1 001

Pembimbing II,



Fajar Rohman Hariri, M.Kom
NIP. 19890515 201801 1 001

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



Supriyono, M.Kom
NIP. 19771020 200912 1 001

HALAMAN PENGESAHAN

PENGUNAAN METODE *CONVOLUTIONAL NEURAL NETWORK* UNTUK MENGLASIFIKASI PENYAKIT PADA TANAMAN JAGUNG BERDASARKAN CITRA DAUN

SKRIPSI

Oleh :
MOHAMAD ABDUL ROZZAQ
NIM. 220605110018

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 28 Juni 2026

Susunan Dewan Penguji

Ketua Penguji : Dr. Zainal Abidin, M.Kom
NIP. 19760613 200501 1 004

Anggota Penguji I : Ajib Hanani, M.T
NIP. 19840731 202321 1 013

Anggota Penguji II : Dr. M. Amin Hariyadi, M.T
NIP. 19670118 200501 1 001

Anggota Penguji III : Fajar Rohman Hariri, M.Kom
NIP. 19890515 201801 1 001

()
()
()
()

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 : Mohamad Abdul Rozzaq

NIM : 220605110018

Fakultas / Prodi : Sains dan Teknologi / Teknik Informatika

Judul Skripsi : Penggunaan Metode *Convolutional Neural Network* Untuk Mengklasifikasi Penyakit Pada Tanaman Jagung Berdasarkan Citra Daun

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, 29 Juni 2026
Yang membuat pernyataan,



Mohamad Abdul Rozzaq
NIM.220605110018

MOTTO

”Tidak apa – apa jalanmu pelan, yang penting kamu sudah berani melangkah”

HALAMAN PERSEMBAHAN

Dengan penuh rasa syukur, penulis mempersembahkan karya ini kepada:

Abah, Ibuk, dan Kakak

Atas doa, kasih sayang, dan dukungan semangat.

Dosen

Atas ilmu dan bimbingannya selama masa studi.

Diri Sendiri

Yang sudah berjuang dan bertahan sampai pada titik ini.

KATA PENGANTAR

Puji syukur penulis panjatkan kehadiran Allah SWT atas segala rahma dan karunia-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul "Penggunaan Metode *Convolutional Neural Network* Untuk Mengklasifikasi Penyakit Pada Tanaman Jagung Berdasarkan Citra Daun"

Penyusunan skripsi ini tidak terlepas dari bimbingan, dukungan, serta doa dari berbagai pihak. Oleh karena itu, penulis menyampaikan terima kasih kepada:

1. Prof. Dr. Hj. Ilfi Nurdiana, S.Ag., M.Si, selaku Rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Dr. Agus Mulyono, M.Kes, selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Supriyono, M.Kom selaku Ketua Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang
4. Nia Faricha, S.Si selaku Staff Administrasi Program Studi Teknik Universitas Islam Negeri Maulana Malik Ibrahim Malang atas arahan penyusunan skripsi.
5. Dr. M. Amin Hariyadi, M.T selaku Dosen Pembimbing I dan Fajar Rohman Hariri, M.Kom selaku Dosen Pembimbing II atas bimbingan, arahan, dan ilmunya dalam penyusunan skripsi.
6. Dr. Zainal Abidin, M.Kom selaku Dosen Penguji I dan Ajib Hanani, M.T selaku Dosen Penguji II atas bimbingan, arahan, dan ilmunya dalam penyusunan skripsi.
7. Dr. Cahyo Crysdian, M.Cs selaku Dosen Wali atas arahan dan bimbingannya selama masa studi.

8. Segenap dosen dan staf akademik Program Studi Teknik Informatika atas ilmu yang diberikan selama masa studi.
9. Kedua orang tua dan kakak penulis yang telah memberikan dorongan, doa, semangat untuk menyelesaikan skripsi.
10. Orang-orang terdekat yang menjadi sumber semangat, dorongan, sarana berdiskusi, tempat curhat, dan tempat mengeluh penulis.
11. Saudara Teknik Informatika khususnya INFINITY '22 yang telah kebersamai selama masa akademik serta senantiasa saling mendukung.
12. Teman-teman Ma'had Al-Ghazali yang telah kebersamai penulis dan menjadi bagian dari cerita perjalanan di UIN Maulana Malik Ibrahim Malang.
13. Diri sendiri yang selalu mengeluh tapi kuat bertahan sampai dengan menulis bagian ini, terima kasih atas usahanya dan kerja kerasnya. Kamu hebat.

Besar harapan penulis agar skripsi ini dapat memberikan manfaat serta wawasan bagi pembaca.

Malang, 29 Juni 2026

Penulis

DAFTAR ISI

HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR.....	viii
DAFTAR ISIIts.....	x
DAFTAR GAMBAR.....	xii
DAFTAR TABEL	xiii
ABSTRAK	xiv
ABSTRACT	xv
مستخلص البحث.....	xvi
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Pernyataan Masalah	5
1.3 Batasan Masalah	6
1.4 Tujuan Penelitian	6
1.5 Manfaat Penelitian	6
BAB II STUDI PUSTAKA	7
2.1 Penelitian Terkait	7
2.2 Penyakit Daun Jagung.....	17
2.2.1 Hawar Daun.....	17
2.2.2 Karat Daun	18
2.2.3 Bercak Daun.....	19
2.3 <i>Convolutional Neural Network (CNN)</i>	19
BAB III DESAIN DAN IMPLEMENTASI	22
3.1 Desain Penelitian	22
3.2 Pengumpulan Data	23
3.3 Desain Sistem.....	24
3.3.1 <i>Input Citra</i>	25
3.3.2 <i>Pre-Processing Citra</i>	25
3.4 Implementasi Metode.....	30
3.4.1 <i>Convolutional Layer</i>	31
3.4.2 <i>Pooling Layer</i>	33
3.4.3 <i>Flatten Layer</i>	34
3.4.4 <i>Fully Connected Layer</i>	35
3.4.5 <i>Softmax</i>	35
3.4.6 <i>Categorical Cross-entropy</i>	36
3.4.7 <i>Backpropragation</i> dan Perhitungan Gradien.....	37
3.4.8 <i>Skenario Pengujian</i>	38
3.4.9 <i>K-Fold Cross Validation</i>	39
3.5 Evaluasi.....	40

BAB IV HASIL DAN PEMBAHASAN	43
4.1 Hasil Uji Coba.....	43
4.1.1 Skenario Uji A1.....	43
4.1.2 Skenario Uji A2.....	44
4.1.3 Skenario Uji A3.....	46
4.1.4 Skenario Uji A4.....	47
4.1.5 Skenario Uji B1	48
4.1.6 Skenario Uji B2	49
4.1.7 Skenario Uji B3	50
4.1.8 Skenario Uji B4	52
4.2 Analisis Hasil	53
4.3 Integrasi Sains dan Islam	60
BAB V KESIMPULAN DAN SARAN	64
5.1 Kesimpulan	64
5.2 Saran	65
DAFTAR PUSTAKA	

DAFTAR GAMBAR

Gambar 2.1 Penyakit Hawar Daun	17
Gambar 2.2 Penyakit Karat Daun	18
Gambar 2.3 Penyakit Bercak Daun	19
Gambar 2.4 Arsitektur <i>Convolutional Neural Network</i>	20
Gambar 3.1 Desain Alur Penelitian	23
Gambar 3.2 Desain Sistem	25
Gambar 3.3 <i>Rotate</i>	27
Gambar 3.4 <i>Vertical Flip</i>	27
Gambar 3.5 <i>Horizontal Flip</i>	28
Gambar 3.6 <i>Gaussian Blur</i>	28
Gambar 3.7 <i>Brightness</i>	29
Gambar 3.8 <i>Random Shadow</i>	29
Gambar 3.9 Bentuk Arsitektur CNN	30
Gambar 3.10 Penerapan Proses <i>Max Pooling</i>	34
Gambar 3.11 Proses <i>Flatten</i>	34
Gambar 3.12 Metode <i>K-Fold Cross Validation</i>	40
Gambar 4.1 Tabel <i>Confusion Matrix</i> Skenario A1	44
Gambar 4.2 Tabel <i>Confusion Matrix</i> Skenario A2	45
Gambar 4.3 Tabel <i>Confusion Matrix</i> Skenario A3	47
Gambar 4.4 Tabel <i>Confusion Matrix</i> Skenario A4	48
Gambar 4.5 Tabel <i>Confusion Matrix</i> Skenario B1	49
Gambar 4.6 Tabel <i>Confusion Matrix</i> Skenario B2	50
Gambar 4.7 Tabel <i>Confusion Matrix</i> Skenario B3	52
Gambar 4.8 Tabel <i>Confusion Matrix</i> Skenario B4	53

DAFTAR TABEL

Tabel 2.1 Penelitian Terkait	13
Tabel 3.1 Contoh Jenis Kategori Daun	24
Tabel 3.2 Skenario Pengujian	38
Tabel 4.1 Hasil Klasifikasi CNN Skenario A1	44
Tabel 4.2 Hasil Klasifikasi CNN Skenario A2	45
Tabel 4.3 Hasil Klasifikasi CNN Skenario A3	46
Tabel 4.4 Hasil Klasifikasi CNN Skenario A4	48
Tabel 4.5 Hasil Klasifikasi CNN Skenario B1.....	49
Tabel 4.6 Hasil Klasifikasi CNN Skenario B2.....	50
Tabel 4.7 Hasil Klasifikasi CNN Skenario B3.....	51
Tabel 4.8 Hasil Klasifikasi CNN Skenario B4.....	53

ABSTRAK

Rozzaq, Mohamad Abdul. 2026. **Penggunaan Metode *Convolutional Neural Network* Untuk Mengklasifikasi Penyakit Pada Tanaman Jagung Berdasarkan Citra Daun.** Skripsi. Jurusan Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. M. Amin Hariyadi, MT (II) Fajar Rohman Hariri, M.Kom.

Kata kunci: *Convolutional Neural Network, Klasifikasi Citra, Penyakit Daun Jagung*

Tanaman jagung merupakan salah satu komoditas pangan penting di Indonesia yang rentan terhadap berbagai jenis penyakit daun, seperti bercak daun, hawar daun, karat daun. Identifikasi penyakit daun jagung umumnya masih dilakukan secara manual melalui pengamatan visual, sehingga memerlukan waktu, bergantung pada keahlian pengamat, dan berpotensi menghasilkan kesalahan diagnosis. Penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit daun jagung menggunakan metode *Convolutional Neural Network* (CNN) serta mengevaluasi pengaruh jumlah *epoch*, *zoom range*, dan jumlah *fold* pada *K-Fold Cross Validation* terhadap kinerja model. Dataset terdiri atas 4.600 citra daun jagung yang terbagi dalam empat kelas yakni kelas Bercak Daun, Hawar Daun, Karat Daun, dan Daun Sehat. Data pelatihan divalidasi menggunakan *K-Fold Cross Validation* dengan nilai *k* sebanyak 5 dan 10, serta diterapkan data *augmentation* untuk meningkatkan variasi data. Pengujian dilakukan dalam delapan skenario yang menggunakan kombinasi skenario meliputi jumlah *epoch*, *zoom range*, dan jumlah *fold cross validation*. Skenario terbaik diperoleh pada kombinasi *epoch* 20, *zoom range* 0,3, dan *5-fold cross validation* dengan hasil prediksi paling minimal dibanding skenario lainnya serta *F1-Score* masing-masing kelas sebesar 94,95%, 94,85%, 97,54%, dan 92,31%. Hasil penelitian menunjukkan bahwa metode CNN efektif dalam mengklasifikasikan penyakit daun jagung, serta bahwa kombinasi parameter *epoch* 20, *zoom range* 0,3, dan *5-fold cross validation* memberikan performa terbaik dibandingkan skenario pengujian lainnya.

ABSTRACT

Rozzaq, Mohamad Abdul. 2026. **The Use of the *Convolutional Neural Network* Method to Classify Diseases in Corn Plants Based on Leaf Images.** Thesis. Department of Computer Engineering, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University, Malang. Advisors: (I) Dr. M. Amin Hariyadi, MT (II) Fajar Rohman Hariri, M.Kom.

Key words: Convolutional Neural Network, Corn Leaf Disease, Image Classification

Corn is one of Indonesia's key food crops and is susceptible to various types of leaf diseases, such as leaf spot, leaf blight, and leaf rust. The identification of corn leaf diseases is generally still done manually through visual observation, which is time-consuming, dependent on the observer's expertise, and prone to misdiagnosis. This study aims to develop a corn leaf disease classification model using the Convolutional Neural Network (CNN) method and to evaluate the impact of the number of epochs, zoom range, and the number of folds in K-Fold Cross Validation on the model's performance. The dataset consists of 4,600 corn leaf images divided into four classes: Leaf Spot, Leaf Blight, Leaf Rust, and Healthy Leaf. The training data was validated using K-fold cross-validation with k values of 5 and 10, and data augmentation was applied to increase data variability. Testing was conducted across eight scenarios using various combinations of the number of epochs, zoom range, and the number of cross-validation folds. The best scenario was achieved with a combination of 20 epochs, a zoom range of 0.3, and 5-fold cross-validation, yielding the lowest prediction error compared to other scenarios and F1-Scores for each class of 94.95%, 94.85%, 97.54%, and 92.31%, respectively. The results of the study show that the CNN method is effective in classifying corn leaf diseases, and that a combination of 20 epochs, a zoom range of 0.3, and 5-fold cross-validation yields the best performance compared to other testing scenarios.

مستخلص البحث

روزاق، محمد عبدول. 2026. استخدام طريقة الشبكة العصبية التلافيفية لتصنيف أمراض نبات الذرة استناداً إلى صور الأوراق. أطروحة البكالوريوس. قسم هندسة المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية فاجار روهمان هاري، ماجستير في (II) د. م. أمين هارياي، ماجستير في الهندسة (I): الحكومية، مالانج. المشرفان. علوم الحاسوب.

الكلمات المفتاحية : أمراض أوراق الذرة، الصور الشبكة العصبية التلافيفية، تصنيف

تعد نباتات الذرة إحدى السلع الغذائية المهمة في إندونيسيا، وهي معرضة لأنواع مختلفة من أمراض الأوراق، مثل البقع الورقية، والذبول الورقي، والصدأ الورقي. ولا يزال تحديد أمراض أوراق الذرة يتم بشكل عام يدوياً من خلال الملاحظة البصرية، مما يستغرق وقتاً طويلاً، ويعتمد على خبرة المراقب، وقد يؤدي إلى أخطاء في التشخيص. يهدف هذا البحث إلى تطوير نموذج لتصنيف أمراض أوراق الذرة باستخدام طريقة الشبكة العصبية التلافيفية (CNN)، وتقييم تأثير عدد الدورات (*epoch*)، ونطاق التكبير (*zoom range*)، وعدد الطيات (*fold*) في عملية التحقق المتقاطع *K-Fold* على أداء النموذج. تتكون مجموعة البيانات من 4,600 صورة لأوراق الذرة مقسمة إلى أربع فئات، وهي: البقع الورقية، والذبول الورقي، والصدأ الورقي، والأوراق السليمة. تم التحقق من صحة بيانات التدريب باستخدام «التحقق المتقاطع *K-Fold* بقيم k تبلغ 5 و 10، كما تم تطبيق تقنية زيادة البيانات (*data augmentation*) لزيادة تنوع البيانات. أُجري الاختبار في ثمانية سيناريوهات تستخدم مزيجاً من العوامل تشمل عدد الدورات ونطاق التكبير وعدد طيات التحقق المتقاطع. تم الحصول على أفضل سيناريو من خلال الجمع بين *epoch 20* ونطاق تكبير 0,3 و *fold cross* -5 و *validation*، حيث حقق أقل معدل خطأ في التنبؤ مقارنة بالسيناريوهات الأخرى، وبلغت قيمة *F1-Score* لكل فئة على التوالي 94,95% و 94,85% و 97,54% و 92,31%. أظهرت نتائج البحث أن طريقة CNN فعالة في تصنيف أمراض أوراق الذرة، وأن الجمع بين المعلمات *epoch 20* ونطاق التكبير 0,3 والتحقق المتقاطع خماسي الطيات يوفر أفضل أداء مقارنةً بسيناريوهات الاختبار الأخرى.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Sebagai salah satu bahan pangan esensial di tingkat global dan nasional, jagung menduduki posisi strategis. Tingkat konsumsinya berada di peringkat ketiga terbanyak, persis di bawah beras serta gandum. Tidak hanya diandalkan untuk pakan hewan ternak, komoditas ini juga bertransformasi menjadi aneka olahan konsumsi, mulai dari camilan, tepung-tepungan, hingga minyak nabati rendah kolesterol (Sarah & Guntoro, 2023). luktiasi harga maupun volume panen kerap terjadi akibat pergerakan suplai dan kebutuhan pasar. Berdasarkan data Badan Pusat Statistik (BPS) estimasi hasil panen jagung pipil kering dengan kadar air 14% di tahun 2023 mencapai 14,46 juta tonAngka ini menyusut sekitar 12,50% atau 2,07 juta ton dari capaian tahun sebelumnya yang menyentuh 16,53 juta ton (Statistik, 2023). Besarnya permintaan lokal memacu Indonesia agar mampu menstabilkan rasio antara ketersediaan dan konsumsi jagung nasional. Langkah strategis guna mencapai stabilitas ini mencakup optimalisasi sumber daya untuk menggenjot hasil panen lokal, serta opsi impor jika stok dalam negeri masih defisit (Iswantoro & Handayani, 2022). Akan tetapi, demi menjamin kesinambungan pasokan dan permintaan secara mandiri, dibutuhkan strategi terpadu untuk mendongkrak mutu serta kuantitas panen dalam jangka panjang.

Ancaman patogen dan hama sering kali menjadi kendala berat bagi kaum tani, mengingat inspeksi visual secara menyeluruh di area tanam sangat sulit

dilakukan sejak fase awal. Situasi tersebut berdampak pada merosotnya angka panen nasional, memicu kegagalan panen, dan berujung pada kerugian finansial yang signifikan bagi para petani. Oleh sebab itu, riset ini digagas untuk merespons kendala tersebut melalui pemanfaatan kumpulan dataset gambar daun jagung yang merepresentasikan aneka stadium penyakit, dari tahap kemunculan awal hingga kondisi infeksi berat. Karena tanda-tanda infeksi berkembang secara bertahap seiring berjalannya waktu, identifikasi serta mitigasi sejak dini menjadi sangat krusial guna menekan potensi kerugian skala besar.

Indikasi abnormalitas pada tanaman jagung umumnya tampak jelas pada area daun. Biasanya, jenis infeksi ini hanya mampu dikenali secara akurat oleh pembudidaya berpengalaman. Namun, keterbatasan pengetahuan pembudidaya awam dalam mengenali jenis infeksi kerap menjadi hambatan. Hal ini menyebabkan proses pelacakan tanaman sakit berjalan lambat, sehingga upaya penanggulangan menjadi tidak efisien dan terlambat (Azizah, 2023). Walaupun langkah preventif terhadap hama terus digalakkan hingga saat ini, fluktuasi kondisi lingkungan seperti perubahan cuaca, kelembapan, dan temperatur turut memicu percepatan perkembangbiakan penyakit tersebut. Adapun metode konvensional yang mengandalkan pengamatan mata telanjang untuk mengidentifikasi bercak, hawar, maupun karat daun dinilai tidak efisien. Prosedur manual ini lazimnya mewajibkan kehadiran pakar fitopatologi yang notabene memakan biaya operasional tinggi (Widianto *et al.*, 2023).

Eksplorasi terkait pengelompokan penyakit jagung telah banyak dikerjakan, utamanya melalui implementasi algoritma *Convolutional Neural Network (CNN)*

beserta ragam metode lain yang memiliki strategi tersendiri dalam mendongkrak ketepatan diagnosis. Contohnya, riset dari Akhyari *et al.*, (2021), membuktikan bahwa CNN sangat mumpuni untuk melacak penyakit pada tanaman jagung. Melalui penerapan arsitektur transfer learning VGG-16 terhadap 3.846 sampel citra daun, uji coba mereka berhasil mencetak tingkat akurasi mencapai 98%. Capaian ini menegaskan kehebatan CNN dalam meng*feature extraction* visual guna mengenali penyakit. Walau demikian, studi ini masih memiliki celah, yakni absennya tahapan *hyperparameter tuning* serta kurangnya penjabaran terkait risiko bias pada dataset yang dipakai.

Penelitian lain oleh Yoggyanto *et al.*, (2024), juga membuktikan kemampuan metode CNN dalam mengenali atau mendeteksi penyakit pada tanaman jagung. Dengan melakukan data training sejumlah 10 kali, model ciptaannya sanggup meraih akurasi training 91,5% serta akurasi validasi di angka 91% pada dataset citra daun sebanyak 4.188 citra. Namun dalam penelitian ini tidak dilakukannya pra-proses data dan augmentasi data yang kemungkinan dapat menyebabkan overfitting, selain itu pengulangan pelatihan juga dilakukan sekali sebanyak 10 kali dan tidak menguji menggunakan parameter yang berbeda.

Pendekatan lain dilakukan oleh Satria Yudha *et al.*, (2025) yang memanfaatkan platform Teachable Machine berskema CNN untuk memisahkan kategori cabai bugar dan tidak sehat. Diatur dengan learning rate 0,001, batch size 16, serta 50 kali perulangan pelatihan, model ini memperlihatkan performa solid: menembus ketepatan 83% pada sampel sehat dan 100% untuk sampel sakit. Evaluasi *Confusion Matrix* mereka juga mengonfirmasi minimnya tingkat

kesalahan prediksi. Kelemahan teknis dari penelitian ini terletak pada minimnya rincian arsitektur bawaan *Teachable Machine*, serta ditiadakannya prosedur *preprocessing* yang memang menjadi limitasi utama platform tersebut. Tambahan pula, muncul indikasi terjadinya *overfitting* yang ditandai oleh lonjakan kecil pada nilai loss saat tahap pengujian, kendati para peneliti tersebut mengklaim tidak mendapati masalah itu.

Dalam Al-Qur'an, konsep pengelompokan dan pembagian suatu kelompok untuk menemukan yang terbaik tersirat dalam firman Allah SWT di bawah ini pada *Surah An-Nur ayat 45*.

وَاللَّهُ خَلَقَ كُلَّ دَابَّةٍ مِّن مَّاءٍ فَمِنْهُمْ مَّن يَمْشِي عَلَى بَطْنِهِ ۖ وَمِنْهُمْ مَّن يَمْشِي عَلَى رِجْلَيْنِ وَمِنْهُمْ مَّن يَمْشِي عَلَى أَرْبَعٍ يَخْلُقُ اللَّهُ مَا يَشَاءُ إِنَّ اللَّهَ عَلَى كُلِّ شَيْءٍ قَدِيرٌ

“Dan Allah telah menciptakan semua jenis hewan dari air, maka sebagian ada yang berjalan di atas perutnya, sebagian berjalan dengan dua kaki, dan sebagian berjalan dengan empat kaki. Allah menciptakan apa yang Dia kehendaki. Sungguh, Allah Mahakuasa atas segala sesuatu.” (Q.S An-Nur:45)

Berdasarkan penjelasan dalam Tafsir Ibnu Katsir mengenai ayat ini, Allah SWT mendemonstrasikan keagungan-Nya melalui penciptaan aneka ragam makhluk hidup. Walaupun bersumber dari elemen yang sama yakni air, setiap makhluk diciptakan dengan variasi wujud, rupa, pigmen, hingga metode pergerakan yang berlainan. Terdapat golongan hewan melata yang merayap menggunakan perutnya layaknya ular, ada pula entitas bipedal yang bertumpu pada dua kaki semacam unggas dan manusia, hingga kelompok hewan ternak yang melangkah memakai empat kaki. Bentuk pluralitas ini secara eksplisit menegaskan kemahakuasaan Sang Pencipta dalam membentuk wujud apa pun yang dikehendaki-Nya, lengkap dengan sifat atau ciri khas masing-masing. Bila

dikaitkan dengan ranah studi identifikasi penyakit, prosedur pengelompokan dieksekusi dengan cara memisahkan objek melalui pengamatan fitur visual, misalnya variasi corak warna, kekasaran permukaan, hingga bentuk lesi atau bercak di area daun. Mirip dengan prinsip pemisahan jenis makhluk berdasarkan anatomi dan gerakanya seperti yang tersurat pada *QS. An-Nur ayat 45*, sistem klasifikasi komputasi juga beroperasi dengan mendeteksi perbedaan atribut pada setiap kategori data. Dengan demikian, riset pengkategorian ini pada hakikatnya merupakan ikhtiar manusia dalam mendayagunakan sains untuk mengidentifikasi sekaligus memilah objek-objek alamiah, selaras dengan keteraturan dan keragaman sifat yang telah Allah rancang.

Berpijak pada landasan tersebut, studi ini mengajukan implementasi algoritma Convolutional Neural Network (CNN) guna mendeteksi dan memilah jenis infeksi pada tanaman jagung dengan mengandalkan data gambar atau citra. Penelitian akan berfokus pada tingkat akurasi dan performa model CNN untuk mengevaluasi seberapa akurat dan baik dalam mengenali pola-pola penyakit pada daun tanaman jagung. CNN dipilih dikarenakan kemampuannya yang bisa secara otomatis mempelajari pola-pola mulai dari tepi, tekstur, dan warna dari data citra.

1.2 Pernyataan Masalah

Mengevaluasi performa Metode *Convolutional Neural Network* dalam mengklasifikasi penyakit pada tanaman jagung berbasis citra daun.

1.3 Batasan Masalah

Batasan Untuk memperoleh hasil yang optimal, penelitian ini menetapkan batasan-batasan berikut ini.

1. Data yang digunakan pada penelitian ini merupakan data yang di peroleh dari situs resmi *Kaggle* yaitu "*Corn Leaf Dataset*" dan "*Corn or Maize Leaf Disease Dataset*" yang tersedia secara *public*. Berisi gambar penyakit daun jagung dengan format gambar JPG.
2. Kategori penyakit daun jagung yang diklasifikasi berjumlah 4 kategori yakni, kelas bercak daun, hawar daun, karat daun, dan daun sehat.

1.4 Tujuan Penelitian

Penelitian ini bertujuan untuk mengevaluasi performa pada Metode *Convolutional Neural Network* berbasis citra daun jagung.

1.5 Manfaat Penelitian

Penelitian yang dilakukan diharapkan memberikan kontribusi nyata dalam beberapa bidang yaitu:

1. Dalam bidang pertanian, mampu mengenali gejala-gejala penyakit yang terjadi di lapangan sedari awal untuk mencegah penyakit menyebar yang akan menimbulkan kerugian pada masyarakat bermata pencaharian sebagai petani.
2. Bidang riset, mampu mengembangkan temuan obat pencegahan penyakit daun jagung untuk disosialisasikan kepada masyarakat khususnya yang bermata pencaharian sebagai petani.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terkait

Klasifikasi merupakan teknik untuk merumuskan suatu model analitik dengan cara mempelajari pola tersembunyi dari suatu himpunan data. Mekanismenya bertumpu pada pengategorian objek ke dalam kelompok-kelompok tertentu berbasis pada atribut atau fitur yang dimilikinya. Dalam praktiknya, data yang telah dilengkapi anotasi difungsikan sebagai *training data* untuk mematangkan algoritma pengelompokan tersebut. Output dari fase pelatihan ini adalah sebuah model cerdas yang kompeten dalam menerjemahkan pola data lama, sehingga bisa mengategorikan data-data baru secara akurat (Akram *et al.*, 2024). Menurut evolusi algoritma deep learning menunjukkan tren kemajuan yang sangat pesat. Di antara sekian banyak varian, *Convolutional Neural Network (CNN)* menjadi salah satu model yang mencatat perkembangan paling menonjol. Berbagai studi mutakhir membuktikan bahwa kemampuan *feature extraction* bawaan CNN sangat handal untuk keperluan identifikasi citra, pengenalan objek dalam berbagai resolusi, hingga tugas segmentasi semantik. Menurut kajian tersebut, CNN lahir sebagai bentuk modernisasi dari arsitektur *Multilayer Perceptron (MLP)* yang dimodifikasi secara khusus guna menangani pemrosesan data spasial dua dimensi, utamanya gambar.

Penelitian yang dilakukan Gumelar *et al.*, (2025), algoritma CNN dimanfaatkan untuk merancang dan membangun suatu sistem aplikasi berbasis

Android yang ditujukan untuk melacak penyakit pada daun jagung secara otonom. Para ahli ini mengadopsi arsitektur *MobileNetV2* sebagai tulang punggung sistemnya. Sumber data didapatkan dari platform *Kaggle*, yang kemudian diperbanyak melalui proses augmentasi hingga mencapai total 5.000 sampel untuk masing-masing dari lima kelas yang ada. Proporsi pembagian datanya adalah 80% untuk tahap *training*, 10% untuk *validation*, dan sisanya 10% untuk *testing*. Pemeriksaan performa membuktikan bahwa model mampu mencetak *F1-Score* di atas 94% untuk semua kategori. *F1-Score* tertinggi diraih oleh kategori hawar daun dengan angka 97,49%, disusul secara berurutan oleh daun sehat 96,55%, karat daun 96,52%, bulai daun 96,41%, dan bercak daun 94,06%. Tingkat akurasi globalnya menyentuh level 96,20%, dengan nilai *recall* serta *precision* yang secara konsisten melampaui 94% pada tiap kelas. Ini mengindikasikan bahwa model tersebut sangat mumpuni dalam memisahkan tipe penyakit dan daun normal, menjadikannya dapat diandalkan sebagai alat diagnosis otomatis dengan reliabilitas tinggi.

Penelitian lain oleh Yusuf *et al.*, (2024), yang menyoroiti pengategorian penyakit tanaman jagung mengandalkan algoritma CNN. Berbasis dataset dari *Kaggle*, penelitian ini melibatkan 200 sampel daun terinfeksi dan 141 daun normal. Tim peneliti menyandingkan dua pendekatan: penggunaan model *pre-trained* VGG-16 dengan model arsitektur CNN dasar. Rasio data dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian. Hasil akhir memperlihatkan VGG-16 berhasil meraih *precision* 97,10%, sedangkan CNN dasar mencatatkan akurasi 94,20%. Dalam laporannya, para kreator menyimpulkan bahwa superioritas VGG-16

bersumber pada sinergi antara kedalaman layernya, penerapan dropout, dan teknik augmentasi yang mendorong performa sekaligus menekan tingkat loss.

Dalam penelitian Pratama & Pristyanto, (2023), menggelar studi komparatif dengan menguji keandalan tiga arsitektur CNN yaitu MobileNet, AlexNet, dan LeNet dalam rangka mengidentifikasi gangguan pada daun jagung. Menggunakan 4.000 sampel gambar dari Kaggle yang terklasifikasi dalam empat kelas, eksperimen dilakukan menggunakan porsi 80:20 untuk data latih dan uji. Hasil evaluasi perbandingan 3 arsitektur menunjukkan pada nilai dari akurasi, presisi, dan *g-mean*, arsitektur *MobileNet* menunjukkan hasil tertinggi dibanding *LeNet* dan *AlexNet*. Peneliti mengungkapkan terdapat kekurangan dalam penelitiannya seperti, input gambar yang terlalu kecil, jumlah data yang dirasa kurang, dan susunan arsitektur pada *MobileNet* yang lebih kompleks dari dua arsitektur lainnya. Hal ini menyebabkan penelitian yang dilakukan tidak seimbang untuk dilakukan perbandingan dengan akurasi pada *MobileNet* mencapai 83,37%; presisi rata-rata 83,37%; dan *g-mean* sebesar 82,98%. Berbanding jauh dengan dua arsitektur lainnya yang rata rata akurasinya berada di angka 76% sampai 80%.

Studi oleh Alwan *et al.*, (2024), turut mengeksplorasi penggunaan CNN, tetapi dengan mengintegrasikannya ke dalam ekosistem YOLOv8 untuk tujuan inspeksi penyakit jagung berbasis 900 citra yang terbagi merata menjadi 300 gambar untuk tiga kelas berbeda dari Kaggle. Pemanfaatan YOLOv8 ini didesain khusus agar sanggup melakukan deteksi visual secara *real-time*. Dari serangkaian pengujian, sistem ini mencatatkan akurasi operasional sebesar 93%. Menurut penjelasan penulis, keberhasilan akurasi ini tidak lepas dari intervensi berbagai

variabel, seperti kejelasan resolusi video, integritas dataset, dan ragam sudut pengambilan gambar. Selain itu, dijelaskan bahwa semakin baik kualitas video dan semakin beragam juga pengambilan gambar maka semakin tinggi juga nilai akurasi yang dapat diperoleh.

Dalam penelitian Bhagawanta & Budy Santoso, (2025), pengembangan model AI berbasis CNN ditujukan untuk meninjau status kesehatan daun kapas. Bermodalkan 3.601 citra dari Kaggle, mereka memecah proporsi data menjadi 80% untuk *training* dan 20% untuk uji kelayakan. Riset ini memaparkan performa yang memuaskan; sistem sanggup mengenali setiap klasifikasi secara tepat dengan persentase akurasi pelatihan menembus 97% dan akurasi validasi 90% hanya dalam 20 *epoch*. Fakta ini menjadi bukti bahwa arsitektur yang dirancang memiliki daya klasifikasi yang presisi untuk inspeksi patologi daun kapas.

Selanjutnya Wahyuningrum *et al.*, (2025), penelitian mengenai klasifikasi penyakit daun jagung menggunakan *EfficientNet85* dengan dataset yang mencapai 60.000 dari repositori *Mendeley data* yang tersedia namun, peneliti hanya memilih sekitar 3.852 citra yang terbagi ke dalam 4 kategori yang spesifik menunjukkan citra daun jagung yang terinfeksi penyakit. Dengan menggunakan arsitektur *EfficientNet85* dan menggunakan 6 kombinasi yang berbeda yaitu learning rate (0,001; 0,0001; 0,00001) dan batch size (16 dan 32) serta peneliti mengukur kinerja model menggunakan metrik evaluasi yang berbeda seperti *accuracy*, *sensitivity*, *specificity*, dan *precision*. Uji coba penelitian memperoleh hasil akurasi terbaik pada skenario ke-5 dengan *learning rate* 0,0001 dan *batch size* 32 yaitu nilai *accuracy* 96,27%; nilai *precision* 90,90%; nilai *specificity* 97,55% namun, nilai

sensitivity terbaik justru terjadi pada skenario ke-4 yaitu mencapai 89,32%. Jadi dapat disimpulkan jika, penentuan nilai *learning rate* 0,0001 dan *batch size* = 32 merupakan kombinasi yang mendapatkan hasil yang bagus pada *training* model.

Penelitian oleh Lesmana *et al.*, (2022), penelitian ini menerapkan algoritma *deep learning*, yaitu *Convolutional Neural Network* (CNN), untuk melakukan identifikasi penyakit pada citra daun kentang. Dataset yang digunakan berasal dari situs *Kaggle* dengan total 5.400 citra yang dikelompokkan ke dalam tiga kelas, yaitu daun sehat, *early blight*, dan *late blight*. Arsitektur model yang diterapkan berupa CNN sederhana yang terdiri atas tiga *convolutional layer*, tiga *max pooling layer*, dan satu *dense layer* tanpa penambahan arsitektur maupun teknik optimasi lainnya. Berdasarkan hasil pengujian, model memperoleh akurasi tertinggi sebesar 93% pada data pelatihan (*training*) dan 99% pada data validasi (*validation*). Hasil tersebut menunjukkan bahwa metode CNN mampu mengidentifikasi penyakit pada citra daun kentang dengan tingkat akurasi yang sangat baik.

Penelitian lain oleh Rosadi & Lutfi, (2021), mengimplementasikan metode *Convolutional Neural Network pre-trained model* untuk mendeteksi jenis penyakit pada daun jagung. Penelitian ini menerapkan metode *transfer learning* dalam proses *training* datasetnya yang berjumlah 3.847 yang terbagi dalam 4 kategori jenis daun. Data dibagi menjadi dua tahapan, *testing* berjumlah 770 data keseluruhan dan *training* berjumlah 1.923, hasil menunjukkan penggunaan Pre Trained model menghasilkan akurasi training sebesar 84% dengan eror 0.45 dan akurasi validasi sebesar 88% eror sebesar 0.54.

Penelitian oleh Sarasati *et al.*, (2022), penelitian tersebut mengusulkan penerapan metode *deep learning* dengan arsitektur *EfficientNetB0* untuk mendeteksi penyakit pada tanaman jagung melalui proses klasifikasi citra pelepah daun, baik yang terinfeksi penyakit maupun yang berada dalam kondisi sehat. Data yang digunakan berasal dari *kaggle* berjumlah 4.188 yang terbagi dalam 4 kategori jenis daun. Data dibagi menjadi 3 tahapan, *train*, *test*, dan *validation* dengan pembagian 60%, 20%, dan 20%. Berdasarkan hasil pengujian, arsitektur *EfficientNetB0* yang diterapkan pada dataset penelitian mampu menghasilkan performa yang baik dengan akurasi tertinggi sebesar 96%. Selain itu, model memperoleh nilai *loss* sebesar 0,12, *validation loss* sebesar 0,13, dan *validation accuracy* sebesar 95%. Hasil tersebut menunjukkan bahwa metode yang diusulkan mampu mengklasifikasikan setiap kelas secara tepat, dengan tingkat akurasi pada masing-masing kelas melebihi 90%.

Selanjutnya penelitian oleh Anugrah & Rachmat (2025), penelitian ini mengembangkan model klasifikasi otomatis berbasis *Convolutional Neural Network* (CNN) dengan pendekatan *transfer learning* melalui evaluasi tiga varian arsitektur *MobileNetV4*, yaitu Small, Medium, dan Large, serta membandingkan performa dua optimizer, yaitu Adam dan SGD. Dataset yang digunakan terdiri atas 4.000 citra daun jagung yang diperoleh dari Kaggle dan berasal dari lahan pertanian di Kabupaten Sampang. Seluruh data dikelompokkan ke dalam empat kelas, kemudian dibagi menjadi data pelatihan sebesar 80%, data validasi sebesar 10%, dan data pengujian sebesar 10%. Berdasarkan hasil eksperimen, model dengan performa terbaik diperoleh dari arsitektur *MobileNetV4* varian Medium yang

menggunakan optimizer Adam, *learning rate* sebesar 0,01, *epoch* sebanyak 50, dan *batch size* 32. Hasil tersebut menunjukkan bahwa varian MobileNetV4 Medium mampu memberikan keseimbangan yang optimal antara efisiensi komputasi dan kinerja klasifikasi, sehingga berpotensi untuk diterapkan pada sistem bergerak (*mobile system*) dalam mendukung pertanian presisi.

Penelitian-penelitian terdahulu yang menjadi acuan dalam penelitian mengenai penerapan *Convolutional Neural Network* (CNN) untuk klasifikasi penyakit daun jagung berbasis citra dirangkum dalam tabel 2.1.

Tabel 2.1 Penelitian Terkait

No	Nama Peneliti	Judul Penelitian	Metode	Hasil Penelitian	Perbedaan Penelitian
1	(Gumelar et al., 2025)	<i>Implementasi of CNN for Corn Leaf Disease Identification</i>	Metode CNN berbasis arsitektur <i>MobileNetV2</i>	Akurasi rata-rata 96,2%. <i>F1-Score</i> rata-rata per kelas di atas 94%, diikuti nilai presisi dan <i>recall</i> berada di atas angka 94%.	Berbeda dengan penelitian ini yang menggunakan model CNN untuk <i>feature extraction</i> dari awal sampai tahap klasifikasi, penelitian (Gumelar et al., menggunakan arsitektur <i>MobileNetV2</i> sebagai tahap ekstraksi awal saja.
2	(Yusuf et al., 2024)	<i>Klasifikasi Penyakit Tanaman Jagung Dengan Kecerdasan Buatan Berbasis CNN</i>	Model CNN Sederhana dengan Optimizer Adam dan Arsitektur <i>VGG16</i> .	Model CNN sederhana pada akurasi pelatihan 89,51% dan akurasi validasi sebesar 94,20%. Model <i>VGG16</i> pada akurasi pelatihan 93% dan akurasi	Penelitian oleh Yusuf et al. menggunakan arsitektur model yaitu <i>VGG16</i> dan menggunakan optimizer adam berbeda dengan penelitian ini yang hanya berfokus untuk mengukur akurasi dan performa metode CNN-nya.

No	Nama Peneliti	Judul Penelitian	Metode	Hasil Penelitian	Perbedaan Penelitian
				validasi 97,10%.	
3	(A. Y. Pratama & Pristyanto, 2023)	<i>Classification of Corn Plant Diseases Using Various Convolutional Neural Network</i>	Menggunakan variasi arsitektur pada metode CNN yaitu, <i>AlexNet</i> , <i>LeNet</i> , <i>MobileNet</i>	Hasil menunjukkan arsitektur <i>MobileNet</i> melampaui dua arsitektur lainnya dengan akurasi mencapai 83,37%; nilai presisi 0,8337 dan <i>g-mean</i> 0,8298.	Penelitian yang dilakukan tidak melakukan perbandingan kombinasi arsitektur untuk mengklasifikasi jenis penyakit pada daun jagung, penelitian ini mengukur tingkat akurasi dan performa dari metode CNN.
4	(Alwan et al., 2024)	<i>Implementasi YOLOv8 Untuk Deteksi Penyakit Daun Jagung Menggunakan Algoritma Convolutional Neural Network (CNN)</i>	Algoritma <i>Convolutional Neural Network</i> (CNN) dengan <i>framework YOLOv8</i>	Algoritma CNN dengan <i>framework YOLOv8</i> telah berhasil mendapatkan nilai akurasi dari pengujian model sebesar 93%.	Pada penelitian Alwan et al. menggunakan bantuan website untuk melabeli objek kemudian hasil labelnya, dilatih dengan kerangka kerja <i>YOLOv8</i> . Berbeda dengan penelitian ini yang lebih fokus untuk mengukur performa CNN.
5	(Bhagawanta & Budy Santoso, 2025)	<i>Deteksi Penyakit Daun Kapas Dengan Deep Learning Berbasis Convolutional Neural Network (CNN)</i>	Menggunakan Algoritma CNN	Hasil akurasi pelatihan mencapai 97% dan akurasi validasi mencapai 90% dalam 20 <i>epochs</i> .	Berbeda dengan penelitian ini yang menggunakan ReLU pada setiap lapisan konvolusi, varian konfigurasi pada arsitektur model dan menggunakan penanganan kesalahan untuk mencegah model salah prediksi.

No	Nama Peneliti	Judul Penelitian	Metode	Hasil Penelitian	Perbedaan Penelitian
6	(Wahyu ningrum <i>et al.</i> , 2025)	<i>Klasifikasi Penyakit Daun Jagung Menggunakan Model Deep Learning EfficientNetB5</i>	Model <i>Deep Learning</i> dengan <i>EfficientNetB5</i>	Dengan learning rate 0,0001 dan <i>batch size</i> 32 mendapatkan kinerja terbaik dengan nilai akurasi 96,27%; presisi 90,90%; spesifitas 97,55%; dan sensitivitas 88,13%.	Dengan menggunakan arsitektur <i>EfficientNet85</i> dan juga tuning hyperparameter, penelitian ini tidak dilakukan tuning hyperparameter dan hanya dilakukan perbaruan bobot dan bias secara menerus untuk mengatasi kesalahan prediksi.
7	(Mulya Lesmana <i>et al.</i> , 2022)	<i>Identifikasi Penyakit pada Citra Daun Kentang Menggunakan Convolutional Neural Network (CNN)</i>	Model CNN <i>custom</i>	Akurasi tertinggi pada data training mencapai 93% dan akurasi tertinggi data validation mencapai 99%.	Meskipun terdapat kesamaan yaitu mengimplementasikan metode CNN, namun perbedaan terdapat pada penggunaan variasi arsitektur model dan penggunaan fungsi aktivasi. Pada penelitian yang dilakukan menggunakan fungsi aktivasi <i>ReLU</i> dan <i>softmax</i> .
8	(Rosadi & Lutfi, 2021)	<i>Identifikasi Jenis Penyakit Daun Jagung Menggunakan Deep Learning Pre-Trained Model</i>	CNN <i>pre-trained model</i>	Akurasi data <i>training</i> 0.85% dengan <i>error rate</i> 0.45% dan data validasi 0.88% dengan <i>error rate</i> 0.54%	Pada penelitian Rosadi & Lutfi menggunakan metode CNN <i>pre-trained model</i> di mana model sudah dilatih menggunakan data lain. Berbeda dengan penelitian ini menggunakan model metode yang dilatih sepenuhnya dari awal menggunakan

No	Nama Peneliti	Judul Penelitian	Metode	Hasil Penelitian	Perbedaan Penelitian
					<i>dataset</i> yang akan digunakan.
9	(Sarasati <i>et al.</i> , 2022)	<i>Pemanfaatan Metode Deep Learning untuk Klasifikasi Penyakit pada Tanaman Jagung</i>	<i>Deep Learning Efficient NetB0</i>	Metode yang digunakan menghasilkan akurasi <i>training</i> sebesar 96% dengan <i>loss training</i> 0,12 dan akurasi <i>validasi</i> 95% dengan <i>loss</i> 0,13	Pada penelitian ini menggunakan arsitektur standar atau <i>fully trained</i> CNN yang dilatih sepenuhnya dari awal menggunakan <i>dataset</i> yang akan digunakan. Berbeda dengan penelitian oleh Sarasati yang menggunakan metode yang sudah dilatih sebelumnya menggunakan data yang serupa atau <i>pre-trained model</i> .
10	(Anugrah & Rachmat, 2025)	<i>Klasifikasi Penyakit Daun Tanaman Jagung Menggunakan Pendekatan Transfer Learning Arsitektur MobileNet V4</i>	CNN berbasis <i>transfer learning</i> menggunakan <i>MobileNetV4</i>	Akurasi <i>validasi</i> sebesar 95,25% dan <i>F1-Score</i> 92% dengan penggunaan <i>hyperparameter learning rate</i> 0.01, <i>epoch</i> 50 dan <i>batch size</i> 32.	Pada penelitian Anugrah & Rachmat menggunakan metode CNN berbasis <i>transfer learning</i> yang mana metode ini adalah <i>pre-trained model</i> . Pada penelitian ini menggunakan model CNN yang dilatih sepenuhnya dari awal atau arsitektur CNN standar.

Berdasarkan tabel 2.1, dapat disimpulkan bahwa pendekatan *deep learning* menggunakan metode CNN mampu mengklasifikasikan secara baik dan akurat dalam mengenali pola-pola atau bercak-bercak pada daun berpenyakit berbasis data citra. Metode CNN menunjukkan kinerja yang optimal. Maka dari itu, penelitian

berfokus pada penggunaan metode CNN dalam mengklasifikasi penyakit pada tanaman jagung berbasis citra daun.

2.2 Penyakit Daun Jagung

Jagung merupakan salah satu komoditas pangan utama di dunia, termasuk di Indonesia. Tanaman ini dapat tumbuh secara optimal pada daerah yang memiliki curah hujan sedang, dengan mempertimbangkan pola curah hujan pada periode-periode sebelumnya. Pada setiap tahap pertumbuhan, mulai dari bernih hingga fase menghasilkan benih, tanaman jagung rentan terhadap berbagai penyakit yang dapat memengaruhi jumlah dan kualitas hasil panen. Dengan demikian, penyakit menjadi salah satu faktor utama yang membatasi produksi serta kualitas benih jagung.

2.2.1 Hawar Daun



Gambar 2.1 Penyakit Hawar Daun

Hawar daun jagung merupakan salah satu penyakit yang disebabkan oleh infeksi jamur *Helminthosporium turcicum* pada fase aseksual. Penyakit ini umumnya berkembang secara sporadis pada daerah yang memiliki tingkat kelembapan tinggi. Pertumbuhan patogen berlangsung secara optimal pada suhu udara berkisar antara 18–27 °C dengan kondisi lingkungan yang lembap atau berembun. Apabila serangan penyakit terjadi sebelum tanaman jagung memasuki

fase pembungaan, terutama pada musim kemarau, kehilangan hasil panen dapat mencapai sekitar 50%. Sebaliknya, jika infeksi baru terjadi sekitar enam minggu setelah munculnya bulu jagung (*silking*), dampak terhadap penurunan hasil panen cenderung lebih rendah.

2.2.2 Karat Daun



Gambar 2.2 Penyakit Karat Daun

Penyakit karat daun pada tanaman jagung disebabkan oleh infeksi cendawan *Puccinia polysora* dan *Puccinia sorghi*. Penyakit ini merupakan salah satu faktor utama yang menyebabkan penurunan produktivitas jagung di Indonesia. Infeksi cendawan mengganggu proses fotosintesis karena merusak jaringan daun, sehingga pertumbuhan tanaman menjadi terhambat dan hasil panen dapat menurun. Gejala awal penyakit ditandai dengan munculnya lesi berukuran kecil pada permukaan daun yang kemudian berkembang menjadi bercak berbentuk bulat hingga memanjang. Seiring perkembangan penyakit, terbentuk pustula pada permukaan daun bagian atas maupun bawah yang berwarna coklat kemerahan. Pada tahap infeksi yang lebih lanjut, warna pustula berubah menjadi coklat kehitaman sebagai tanda semakin berkembangnya penyakit.

2.2.3 Bercak Daun




Gambar 2.3 Penyakit Bercak Daun

Penyakit bercak daun abu-abu pada tanaman jagung disebabkan oleh infeksi jamur *Cercospora zeae-maydis*. Penyakit ini termasuk salah satu penyakit penting yang sering menyerang tanaman jagung pada setiap musim tanam dan berpotensi menurunkan hasil produksi. Gejala awal ditandai dengan munculnya bercak-bercak kecil berwarna cokelat muda hingga cokelat yang dikelilingi oleh tepi berwarna kekuningan pada daun bagian bawah. Seiring perkembangan infeksi, bercak tersebut akan membesar dan membentuk lesi berwarna abu-abu dengan bentuk memanjang mengikuti arah tulang daun.

2.3 *Convolutional Neural Network (CNN)*

Salah satu metode yang termasuk dalam kategori *deep learning* adalah *Convolutional Neural Network (CNN)*. Metode ini banyak dimanfaatkan dalam bidang pengenalan citra karena mampu menghasilkan tingkat akurasi yang sebanding dengan kemampuan manusia pada dataset tertentu. Selain itu, CNN memiliki kemampuan untuk mempelajari representasi fitur secara otomatis sehingga mampu menghasilkan performa klasifikasi yang lebih baik (Paraijun *et al.*, 2022). Dibandingkan dengan metode *Multi Layer Perceptron (MLP)*, CNN

umumnya memberikan hasil yang lebih optimal pada tugas klasifikasi citra. Hal tersebut disebabkan oleh arsitektur CNN yang memiliki lapisan neuron lebih dalam dan dirancang untuk mempertahankan informasi spasial, seperti pola, bentuk, dan hubungan antar piksel pada citra. Sebaliknya, MLP memperlakukan setiap piksel sebagai fitur yang berdiri sendiri tanpa mempertimbangkan hubungan spasialnya, sehingga performanya pada klasifikasi citra cenderung lebih rendah (I. P. Putra *et al.*, 2022). CNN menjadi salah satu metode *deep learning* yang paling banyak digunakan karena mampu melakukan *feature extraction* secara otomatis tanpa memerlukan perancangan fitur secara manual. Kemampuan tersebut memungkinkan model mempelajari karakteristik objek sesuai dengan tugas yang diberikan, sehingga dapat mengenali objek baru dengan tingkat akurasi yang tinggi melalui proses pelatihan jaringan yang telah dibangun (Fithratul Zalmi *et al.*, 2025).



Gambar 2.4 Arsitektur Convolutional Neural Network

Pada gambar di atas, menunjukkan algoritma CNN terdiri dari 2 bagian yaitu, *feature learning* dan *classification*. Pada bagian *feature learning*, *input* gambar melewati lapisan-lapisan *convolution* dan *pooling* untuk meng*feature extraction*-fitur penting dari data *input*. *Convolution* berfungsi untuk mempelajari pola-pola sederhana seperti bentuk, tepi, warna, tekstur dengan memanfaatkan *filter*

atau *kernel* yang digeser pada seluruh area citra untuk melakukan proses konvolusi. Hasil dari proses ini berupa *feature map* yang menggambarkan pola visual pada citra. *Pooling* digunakan untuk melakukan *downsampling* atau mereduksi ukuran spasial dari *feature map* yang telah dihasilkan pada *convolution* yang akan digunakan sebagai input untuk menghasilkan representasi fitur sehingga CNN dapat mengenali objek (Sheila *et al.*, 2023). Setelah melewati proses *pooling*, dimensi *feature map* berkurang, tetapi informasi penting yang terkandung pada data masukan tetap pertahankan.


Selanjutnya tahap *classification*, pada bagian ini berfungsi untuk mengklasifikasikan tiap data yang telah melewati proses *convolution* dan *pooling* dengan cara menghubungkan semua neuron yang telah diekstraksi. Terdapat 3 lapisan pada tahap ini, yang pertama *flatten* yang berguna untuk meratakan vektor multidimensi menjadi satu dimensi. Kemudian lapisan *fully connected*, lapisan ini yang berfungsi untuk menggabungkan seluruh informasi yang diperoleh dari lapisan-lapisan sebelumnya. Kemudian yang terakhir adalah fungsi aktivasi *softmax* yang berfungsi untuk memutuskan kelas akhir klasifikasi dengan mengubah hasil akhir menjadi nilai probabilitas (O'Shea & Nash, 2022).

BAB III

DESAIN DAN IMPLEMENTASI

3.1 Desain Penelitian

Alur penelitian ini dikonstruksikan ke dalam beberapa fase terstruktur dan sistematis guna menjamin agar seluruh tahapan berjalan selaras dengan target yang ingin dicapai. Langkah awal diinisiasi dengan melakukan penelusuran studi literatur serta kajian teori dari berbagai publikasi terdahulu. Setelah itu, dilakukan pengumpulan data yang segera diikuti dengan proses seleksi sampel. Tahapan berikutnya beralih pada *preprocessing* data, sebelum akhirnya masuk ke bagian perancangan sistem yang berfungsi mendesain arsitektur proses yang hendak diaplikasikan. Prosedur selanjutnya melibatkan implementasi algoritma melalui aktivitas *training* sekaligus *testing* terhadap dataset untuk menakar kompetensi sistem. Guna menguji reliabilitas performa tersebut, serangkaian skenario pengujian yang variatif diterapkan. Fase akhir dari rangkaian ini adalah melakukan pembedahan dan analisis hasil untuk meninjau seberapa baik kemampuan algoritma dalam mengekstraksi informasi citra visual berdasarkan skenario yang diujikan, yang kemudian ditutup dengan penarikan kesimpulan dari seluruh capaian yang didapatkan. Representasi visual dari bagan kerangka kerja ini dapat dicermati secara detail pada Gambar 3.1.



Gambar 3.1 Desain Alur Penelitian

3.2 Pengumpulan Data


Pemenuhan kebutuhan dataset bersumber dari platform repositori publik yang diakses secara terbuka, yakni Kaggle. Himpunan data utama yang diekstraksi bertajuk “*Corn Leaf Disease*”, yang mana sampel visualnya diabadikan secara langsung dari area perkebunan jagung di wilayah Desa Polagan, di bawah pengelolaan Dinas Pertanian Kabupaten Sampang. Koleksi awal ini memuat 4.000 gambar yang didistribusikan secara proporsional ke dalam empat kelompok klasifikasi daun. Rinciannya mencakup 1.000 sampel untuk masing-masing kategori, yaitu hawar daun, karat daun, bercak daun, serta kondisi daun sehat. Guna memperkaya variasi sampel dan mengatasi ketidakseimbangan, dilakukan integrasi tambahan sebanyak 600 citra khusus untuk kategori karat daun yang ditarik dari repositori “*Corn or Maize Leaf Disease Dataset*”. Penambahan ekstra ini mendongkrak total sampel pada kelompok karat daun menjadi 1.600 gambar. Sebagai representasi visual, perwakilan gambar dari keempat klasifikasi daun tersebut diilustrasikan secara lebih rinci pada Tabel 3.1.

Tabel 3.1 Contoh Jenis Kategori Daun

No	Kategori	Gambar	Jumlah Data
1	Karat Daun		1.600 data (Seribu enam ratus)
2	Bercak Daun		1.000 data (Seribu)
3	Hawar Daun		1.000 data (Seribu)
4	Daun Sehat		1.000 data (Seribu)

3.3 Desain Sistem

Tahap desain sistem ini disusun guna memaparkan tahapan operasional dalam mengategorikan visual infeksi pada daun jagung melalui adopsi algoritma *Convolutional Neural Network (CNN)*. Adapun visualisasi dari skema usulan tersebut direpresentasikan secara rinci pada Gambar 3.2.



Gambar 3.2 Desain Sistem

3.3.1 Input Citra

Dalam tahapan ini, kumpulan gambar anomali pada helaian daun jagung yang telah diakuisisi sebelumnya akan dioperasikan sebagai data masukan utama bagi arsitektur pengklasifikasi. Koleksi data tersebut mencakup keseluruhan 4.600 sampel visual yang didistribusikan secara spesifik ke dalam empat kategori, yaitu kondisi hawar daun, karat daun, bercak daun, serta daun normal.

3.3.2 Pre-Processing Citra

CNN melibatkan beberapa proses *preprocessing* yaitu *cropping* hingga *rescaling* data. Hal ini bertujuan untuk meminimalkan risiko data *overfitting* atau model terlalu menghafal pola-pola yang terdapat pada karakteristik data dan memastikan data yang diolah tersebut memperoleh hasil yang konsisten.

3.3.2.1 Cropping

Cropping merupakan proses menghilangkan sebagian area terluar yang tidak termasuk ke dalam tujuan penelitian. Hal ini bertujuan untuk membuat data citra yang diteliti menjadi lebih fokus dan tajam (Peryanto *et al.*, 2020). Tahap ini dilakukan dengan menghilangkan sebagian area di tepi gambar untuk menghapus

elemen yang tidak relevan, meningkatkan kualitas pemingkakan dan menyesuaikan rasio aspek citra.

3.3.2.2 *Rescale*

Tahapan *rescale* bertindak sebagai prosedur standarisasi intensitas piksel citra, yakni dengan mengonversi skala awal 0–255 ke dalam interval 0–1. Langkah fungsional ini diaplikasikan guna memangkas durasi pencapaian konvergensi pada fase komputasi pelatihan algoritma. Di samping itu, penyesuaian ini berfungsi mengamankan format data input agar selaras dengan skala referensi, sehingga proses eksekusinya dapat berjalan jauh lebih optimal dan efisien. Formulasi matematis dari teknik penyesuaian skala ini dijabarkan secara rinci pada persamaan *rescale* 3.1.

$$R_s = \frac{\text{nilai_pixel}}{255} \quad (3.1)$$

Keterangan :

nilai_pixel = nilai pixel dari citra, berkisar antara 0-255

R_s = nilai hasil *rescale*, berkisar antara 0-1

3.3.2.3 *Augmentasi Citra*

Teknik untuk mengatasi ketidakseimbangan jumlah data antar kelas dengan cara menambah variasi dataset. Selain untuk menambah jumlah data, hal ini juga bertujuan agar model menjadi lebih *robust* (tahan terhadap variasi gambar nyata di lapangan) dan mampu menganalisa objek dalam kondisi apapun.

1. *Rotate*

Proses *rotate* dilakukan dengan memutar citra pada sudut tertentu, misalnya 90°, 180°, atau 270° untuk menghasilkan variasi orientasi dari data


latih. Teknik ini membantu model CNN agar lebih *robust* terhadap perbedaan posisi pada objek citra, sehingga tidak hanya mengenali pola dalam orientasi tunggal, tetapi juga mampu melakukan klasifikasi secara akurat. Pada penelitian ini akan digunakan sudut 270° sebagai variasi orientasi. Contoh dari *rotate* dapat dilihat pada gambar 3.3.



Gambar 3.3 *Rotate*

2. *Vertical Flip*

Proses *Vertical flip* dilakukan dengan membalik citra secara vertikal (atas menjadi bawah dan sebaliknya). Tujuannya adalah untuk menambah keragaman data latih serta melatih model CNN agar tidak hanya bergantung pada arah vertikal objek, sehingga meningkatkan kemampuan generalisasi dalam klasifikasi. Contoh gambar *vertical flip* dapat dilihat pada gambar 3.4.




Gambar 3.4 *Vertical Flip*

3. *Horizontal Flip*

Proses *horizontal flip* dilakukan dengan membalik citra secara *horizontal* (kiri menjadi kanan dan sebaliknya). Teknik ini memberikan variasi tambahan


pada dataset sehingga model CNN dapat mengenali objek meskipun posisinya terbalik secara lateral. Gambar *horizontal* terdapat pada gambar 3.5.



Gambar 3.5 *Horizontal Flip*

4. *Gaussian Blur*

Gaussian blur adalah teknik yang digunakan untuk membuat citra menjadi lebih halus dengan mengurangi gangguan atau *noise*. Teknik ini bekerja dengan cara mengaburkan citra menggunakan pola tertentu sehingga detail-detail kecil yang tidak penting dapat dikurangi, sementara bentuk utama objek tetap terlihat. Semakin besar nilai pengaburan yang digunakan, semakin halus tampilan citra yang dihasilkan (Gayatri Devi et al., 2023). *Gaussian blur* sering digunakan sebagai langkah awal sebelum citra diproses lebih lanjut agar hasil analisis menjadi lebih stabil dan akurat.



Gambar 3.6 *Gaussian Blur*

5. *Brightness*

Brightness dilakukan untuk memodifikasi tingkat kecerahan piksel pada citra dengan mensimulasikan variasi kondisi pencahayaan dengan menambah


atau mengurangi nilai intensitas piksel secara global maupun lokal (Wang & Song, 2025). Tujuannya adalah untuk meningkatkan kemampuan generalisasi model agar lebih *robust* terhadap perubahan.



Gambar 3.7 *Brightness*

6. *Random Shadow*


Random shadow pada teknik augmentasi data digunakan untuk menambahkan bayangan secara acak pada data citra. Teknik ini dilakukan bertujuan untuk mensimulasikan keberadaan bayangan secara acak pada data yang menirukan kondisi nyata di mana objek sering tertutup oleh bayangan yang disebabkan oleh cahaya matahari, benda lain, atau arah lampu yang berbeda. Dengan adanya bayangan buatan, model dilatih agar tetap dapat mengenali objek meskipun sebagian citra terlihat lebih gelap.



Gambar 3.8 *Random Shadow*

3.4 Implementasi Metode

Pendekatan komputasi yang dioperasikan dalam studi ini guna memetakan jenis anomali pada daun jagung bertumpu pada algoritma Convolutional Neural Network (CNN). Skema jaringan yang digunakan merupakan hasil penyesuaian dari kerangka dasar yang sebelumnya telah dieksplorasi oleh Wirabowo & Susilawati, (2025). Adapun representasi visual dari rancangan struktur arsitektur yang diaplikasikan dalam eksperimen ini dapat ditinjau pada Gambar 3.9.



Gambar 3.9 Bentuk Arsitektur CNN

Terdapat dua tahap yaitu *feature extraction* dan klasifikasi. Tahap *feature extraction* berfokus pada pengenalan karakteristik visual penting dari citra penyakit daun jagung, sedangkan tahap klasifikasi bertujuan untuk mengelompokkan kelas sesuai dengan kelas sebenarnya berdasarkan pola sederhana yang di dapat dari proses pelatihan data.

Proses dimulai dengan memasukkan citra berukuran 224 x 224 piksel melewati kernel *convolutional layer* untuk mengenali fitur-fitur utama yang terdapat di dalam citra seperti, pola tepi, bentuk, warna, dan objek-objek lainnya.

Kemudian tahap ekstraksi di *convolutional layer*, data citra akan diarahkan menuju *max pooling layer* guna menyusutkan resolusi spasial sekaligus mereduksi beban komputasi, dengan tetap menjaga informasi esensial dari gambar tersebut. Berikutnya, representasi data yang dihasilkan dari fase pemampatan ini diumpankan ke dalam *fully connected layer* sebagai tahapan penentu untuk memilah dan mengategorikan jenis infeksi pada daun jagung berdasarkan kelas-kelas yang telah ditargetkan.

3.4.1 *Convolutional Layer*

Sebagai komponen fundamental, *convolutional layer* mengemban tugas krusial untuk menyeleksi dan mengenali karakteristik penting dari data masukan. Secara struktural, tingkatan ini dibangun oleh serangkaian neuron yang terkonfigurasi menjadi sebuah filter berukuran spesifik, di mana skalanya dipetakan melalui representasi panjang serta tinggi berbasis piksel. Lapisan ini adalah lapisan terpenting untuk *feature extraction* melalui operasi konvolusi. *Convolutional layer* melakukan proses *feature extraction* dengan mengaplikasikan beberapa *kernel* pada citra masukan. *Kernel* tersebut berupa matriks kecil yang bergerak secara berurutan di setiap bagian citra. Pada setiap pergeseran, dilakukan operasi konvolusi dengan mengalikan nilai-nilai pada *kernel* dengan piksel citra yang saling bersesuaian, kemudian menjumlahkan hasilnya untuk menghasilkan fitur baru. Hasilnya berupa *feature map* yang menyoroti bagian penting gambar seperti, tepi, tekstur, pola, bentuk, warna dan lain sebagainya. Berikut persamaan dari *convolutional layer* 3.2 (Bhat *et al.*, 2023).

$$C_{i,j} = \sum_{k=1}^m \sum_{l=1}^m W_{(k,l)} X_{(i+k),j+l-1} \quad (3.2)$$

Keterangan:

X = input citra

$W_{k,l}$ = bobot filter (kernel)

$C_{i,j}$ = output atau nilai feature map pada posisi (i,j)

m = ukuran filter (lebar dan tinggi kernel)

(k, l) = indeks posisi di dalam kernel

Setelah melewati operasi konvolusi, selanjutnya fungsi aktivasi *Rectified Linear Unit* (ReLU) diterapkan untuk memberikan kemampuan non-linearitas dalam data, artinya fungsi ini bekerja dengan menghilangkan semua nilai negatif dalam *feature map* menjadi nol dan mempertahankan nilai positif. Jadi jika Fungsi aktivasi ReLU dapat dilihat pada persamaan 3.3 (Adhinata *et al.*, 2021).

$$f(x) = \max(0, x) \quad (3.3)$$

Keterangan:

$f(x)$ = fungsi aktivasi ReLU

x = input

Penambahan fungsi aktivasi menghasilkan *feature map* yang didominasi oleh nilai-nilai positif, sehingga fitur-fitur yang penting dapat ditonjolkan dan diteruskan ke lapisan berikutnya untuk diproses lebih lanjut. Jadi intinya jika nilai input yang dihasilkan dari *convolutional layer* lebih besar dari nol, maka hasilnya akan tetap nilai tersebut. Namun jika nilai input lebih kecil dari nol, hasilnya akan diubah menjadi 0. Secara sederhana, *convolutional layer* menghasilkan nilai positif dan negatif yaitu kombinasi dari deteksi tepi, pola, dan tekstur. *ReLU* tugasnya hanya meneruskan bagian yang positif (aktif) dan membuang yang negatif.

3.4.2 Pooling Layer

Layer ini bertindak sebagai bagian yang memegang peran dalam *downsampling* gambar ataupun mengecilkan volume data. Mekanisme ini diaplikasikan dengan target memangkas dimensi dari *feature map*. Melalui langkah ini, akumulasi jumlah parameter beserta beban kerja komputasi dapat diminimalisir, yang berujung pada peningkatan kecepatan durasi training sistem sekaligus menekan probabilitas terjadinya *overfitting*. Menariknya, walau cakupan spasial dari peta fitur tersebut mengalami penyusutan, informasi taktis atau atribut visual yang paling signifikan akan tetap dipertahankan dengan baik. Dalam arsitektur CNN, *pooling layer* ditempatkan secara berurutan setelah *convolutional layer* sehingga secara bertahap mengurangi volume *feature map* sebelum diteruskan ke lapisan berikutnya. (Cahya Pratiwi, 2023).

Dalam penelitian ini, *pooling layer* yang digunakan untuk mengklasifikasikan penyakit pada daun jagung adalah *Max Pooling Layer*. *Max Pooling* dipilih karena kemampuannya untuk membuat model menjadi lebih *robust* dan bisa mempercepat proses komputasi dengan memilih nilai terbesar dari suatu area kecil. Prinsip kerja *pooling layer* adalah menerapkan filter dengan ukuran dan nilai *stride* tertentu yang bergerak melintasi seluruh *feature map*. Pada penelitian ini digunakan *Max Pooling* berukuran 2×2 dengan *stride* 2, di mana setiap jendela filter akan mengambil nilai maksimum dari area 2×2 piksel sebagai hasil keluaran. Perhitungan *max pooling* pada persamaan 3.4 (Adhinata *et al.*, 2021).

$$P_{(a,b)} = \max\{X(a + h, b + w)\} \quad (3.4)$$

Keterangan:

$P_{(a,b)}$ = output pooling di posisi (a,b)

$X_{(a+h,b+w)}$ = nilai piksel *input* dalam area *pooling*
 h dan w = indeks yang menentukan area lokal dalam *pooling window*

Setelah operasi *max pooling* dilakukan, dimensi *feature map* akan berkurang, tetapi informasi atau fitur-fitur penting pada citra tetap dipertahankan.


Contoh *visual* dari *Max Pooling* pada gambar 3.7.



Gambar 3.10 Penerapan Proses Max Pooling

3.4.3 Flatten Layer

Feature map yang diperoleh dari tahap *feature extraction* masih berbentuk array multidimensi. Oleh karena itu, dilakukan proses *flatten* untuk mengubahnya menjadi vektor satu dimensi sebelum diproses pada lapisan berikutnya. Proses ini diperlukan agar hasil keluaran dari lapisan *convolution* dan *pooling* dapat diteruskan ke *fully connected layer* untuk proses klasifikasi. Hal ini dikarenakan, karakteristik dari *fully connected layer* itu sendiri yang tidak memahami struktur spasial (posisi piksel) dan hanya bisa mengolah vektor 1D seperti pada jaringan saraf biasa seperti MLP. Contoh dari proses *flatten* pada gambar 3.8.



Gambar 3.11 Proses Flatten

3.4.4 Fully Connected Layer

Layer ini bertindak sebagai tahapan krusial yang berfungsi mengolah kembali seluruh karakteristik visual yang telah dihimpun dari tingkatan terdahulu. Lapisan ini menerima semua informasi dari *convolutional layer* dan *pooling layer*, lalu menggabungkannya untuk melakukan klasifikasi akhir. Namun, sebelum masuk ke *fully connected*, hasil dari *convolution* dan *pooling* yang berbentuk *feature map* 3D harus diratakan menjadi satu vektor 1D, kemudian menghitung bobot dan bias karena setiap neuron mencoba menggabungkan fitur-fitur penting dari citra untuk mengenali pola. Berikut persamaan *fully connected layer* operasinya pada 3.5 (Wulandari *et al.*, 2024).

$$Z_r = \sum_{c=1}^J X_c W_{cr} + b_r \quad (3.5)$$

Keterangan:

Z_r = output pada *neuron* ke- r

J = jumlah *neuron* input

X_c = input pada *neuron* ke- c

W_{cr} = bobot penghubung antara *neuron* input dan output

b_r = bias pada *neuron* output ke- r

Setelah *proses* tersebut, nilai hasil perkalian bobot dan penambahan bias ini akan dihitung menggunakan fungsi aktivasi ReLU seperti pada persamaan 3.3, di mana setiap *output* yang bernilai negatif akan diubah menjadi 0 dengan tujuan untuk mempertahankan nilai positif.

3.4.5 Softmax

Tahap *terakhir* pada bagian *fully connected layer*, fungsi aktivasi untuk memutuskan kelas akhir klasifikasi dengan mengubah hasil akhir menjadi nilai

probabilitas. Contoh terdapat tiga output probabilitas [0.05, 0.10, 0.85] yang masing-masing kelasnya dari kiri ke kanan *healthy*, *blight*, *common rust*. Maka model akan memprediksi kelas *common rust* karena nilainya paling tinggi. Operasi yang digunakan dapat dilihat pada Persamaan 3.6 (Satoto *et al.*, 2023).

$$f(Z_r) = \frac{e^{Z_r}}{\sum_{m=1}^M e^{Z_m}} \quad (3.6)$$

Keterangan:

Z_r = skor (*logit*) untuk kelas ke- r

M = jumlah total kelas

e^{Z_r} = eksponensial dari skor kelas ke- r . (Eksponensial artinya menaikkan nilai $e \approx 2.71828$ pangkat skor tersebut.)

$\sum_{m=1}^M e^{Z_m}$ = jumlah dari semua nilai eksponensial skor untuk seluruh kelas

3.4.6 Categorical Cross-entropy

Categorical cross-entropy adalah sebuah fungsi untuk menghitung seberapa baik prediksi model sesuai dengan kelas sebenarnya. Kelas yang benar biasanya dilabeli dengan angka “1” dan kelas prediksi dilabeli dengan angka “0”. *Categorical crossentropy* bekerja dengan memberikan penalti pada kelas prediksi berdasarkan seberapa yakin model terhadap kelas yang benar. Nilai *cross-entropy* akan semakin kecil apabila model memberikan probabilitas yang tinggi terhadap kelas yang benar. Sebaliknya, jika probabilitas yang diberikan pada kelas yang benar rendah, maka nilai *cross-entropy* akan semakin besar. Persamaan *loss* pada persamaan 3.7 (Batool *et al.*, 2025).

$$CE = -\log \left(\frac{e^{Z_r}}{\sum_{m=1}^M e^{Z_m}} \right) \quad (3.7)$$

Nilai CE menunjukkan seberapa jauh prediksi dari target sebenarnya. Semakin besar nilai probabilitas prediksi terhadap kelas sebenarnya, nilai log menjadi kecil, maka model semakin yakin terhadap kelas sebenarnya.

3.4.7 Backpropagation dan Perhitungan Gradien

Backpropagation merujuk pada suatu proses “mundur ke belakang” yang bertujuan untuk memperbarui parameter model bobot yang sebelumnya telah dihitung oleh fungsi *loss* untuk memperkecil kesalahan model dalam memprediksi kelas. Gradien di sini berfungsi untuk mengoptimalkan fungsi *loss* dengan memperbarui parameter jaringan. Barulah setelah gradien dihitung, nilai tersebut digunakan dalam algoritma *Gradient Descent* atau turunannya seperti *Adam*, *SGD*, *RMSProp* dan lain lain atau biasa dikenal sebagai optimasi untuk memperbarui bobot dalam jaringan.

Dalam penelitian ini digunakan metode optimasi *RMSProp* untuk menstabilkan pembaruan bobot dengan menyesuaikan *learning rate* di setiap parameter. *RMSProp* adalah algoritma optimasi yang merupakan varian dari algoritma *gradient descent* yang *adaptive learning rate* atau dapat menyesuaikan *learning rate* berdasarkan *moving average* dari kuadrat gradien. Berikut ini rumus persamaan 3.8 untuk menghitung *moving average* (rata-rata kuadrat gradien) dari kuadrat gradien (Gautam *et al.*, 2025).

$$E[g^2] = \rho \cdot E[g^2]_{t-1} + (1 - \rho) \cdot g_t^2 \quad (3.8)$$

Keterangan:

$E[g^2]_t$ = *moving average* dari kuadrat gradien pada langkah ke-t

ρ = *decay rate* (faktor peluruhan)

$E[g^2]_{t-1}$ = nilai rata-rata kuadrat gradien dari langkah sebelumnya.

g_t = gradien pada langkah ke-t

$(1 - \rho)$ = faktor bobot untuk gradien baru

Kemudian setelah menghitung *moving average* untuk mengetahui seberapa besar gradiennya, pembaruan bobot pada persamaan 3.9 (Askale *et al.*, 2025).

$$W_{t+1} = W_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} \cdot g_t \quad (3.9)$$

Keterangan:

η = *learning rate*

g_t = gradien loss terhadap bobot saat ini

$E[g^2]_t$ = rata-rata kuadrat gradien

ϵ = nilai kecil agar tidak dibagi nol

RMSProp menyesuaikan *learning rate* untuk setiap parameter berdasarkan nilai gradien (*moving average*) dari fungsi *loss*, sehingga pembaruan bobot menjadi lebih stabil dan adaptif terhadap perubahan nilai gradien selama proses pelatihan.

3.4.8 Skenario Pengujian

Untuk mengukur kinerja dan performa model CNN dalam klasifikasi penyakit pada daun tanaman jagung berbasis citra, dilakukan skema uji coba dengan variasi *zoom range*, jumlah *epoch*, dan jumlah *fold*. Berikut ini skenario pengujian yang diterapkan disajikan pada Tabel 3.2.


Tabel 3.2 Skenario Uji Coba

Kode	<i>Epoch</i>	<i>Fold</i>	<i>Zoom Range</i>
A1	20	5	0.3
A2	20	5	0.5
A3	20	10	0.3
A4	20	10	0.5
B1	50	5	0.3
B2	50	5	0.5
B3	50	10	0.3
B4	50	10	0.5

Tahapan uji coba *zoom range* dan *epoch* dilakukan untuk mengetahui seberapa mampu model dapat mempelajari pola-pola bercak yang terdapat pada data citra daun jagung dengan tujuan mendapatkan tingkat akurasi dan performa yang lebih baik. Pengaturan *zoom range* dilakukan untuk memperbesar dan memperkecil objek gambar agar model lebih bervariasi dalam memprediksi kategori penyakit citra. Sedangkan *epoch* bertujuan untuk mengulang-ulang pelatihan model supaya lebih konsisten dalam mempelajari data citra. Sedangkan jumlah *fold* digunakan agar model lebih banyak mempelajari pola pada data citra.

3.4.9 K-Fold Cross Validation

Guna menguji kapabilitas generalisasi sistem secara maksimal sekaligus mencegah terjadinya bias atau kecenderungan model pada kategori data tertentu, studi ini mengadopsi pendekatan *k-fold* cross validation sebagai metode validasinya. Dalam penerapannya, himpunan data yang ada dipisahkan menjadi beberapa sub-bagian dengan porsi yang sama besar. Tiap bagian tersebut difungsikan secara bergilir sebagai *testing data*, sedangkan segmen sisanya dialokasikan sebagai *training data*. Siklus ini dieksekusi secara berulang sebanyak *k* kali, demi memastikan seluruh pecahan data mendapatkan kesempatan yang setara untuk berperan sebagai data pengujian. Selanjutnya, nilai performa yang diperoleh dari masing-masing iterasi dihitung rata-ratanya sehingga menghasilkan evaluasi yang lebih konsisten dan representatif terhadap kemampuan model (Resti *et al.*, 2022). Penggambaran metode *K-Fold* pada disajikan dalam gambar 3.12.



Gambar 3.12 Metode *K-Fold Cross Validation*

3.5 Evaluasi

Evaluasi terhadap hasil pengujian dilaksanakan guna menakar tingkat ketepatan serta efektivitas kinerja algoritma dalam mengelompokkan jenis infeksi pada daun jagung. Pendekatan penilaian ini dapat direalisasikan salah satunya melalui pemanfaatan confusion matrix. Confusion matrix bertindak sebagai instrumen evaluasi yang merepresentasikan kapabilitas arsitektur cerdas dalam memetakan data ke dalam kategori yang benar. Di samping itu, mekanisme ini juga mampu menyajikan rincian mengenai variasi sekaligus kuantitas kekeliruan estimasi yang dibuat oleh sistem (A. Putra & Prihartono, 2025). Terdapat empat parameter fundamental di dalam matriks ini yang dioperasikan sebagai landasan utama untuk mengalkulasi nilai akurasi, meliputi:

1. *True Positive* (TP), yaitu jumlah data yang termasuk dalam kelas positif dan berhasil diprediksi sebagai kelas positif.
2. *True Negative* (TN), yaitu jumlah data yang termasuk dalam kelas negatif dan berhasil diprediksi sebagai kelas negatif.

3. *False Positive* (FP), yaitu jumlah data yang sebenarnya berada pada kelas negatif, tetapi diprediksi sebagai kelas positif.
4. *False Negative* (FN), yaitu jumlah data yang sebenarnya berada pada kelas positif, tetapi diprediksi sebagai kelas negatif.

Berdasarkan keempat nilai tersebut, metrik evaluasi dapat dihitung seperti tingkat *accuracy* yang menunjukkan tingkat data yang diklasifikasikan dengan benar dari semua data pada Persamaan 3.10 (A. Y. Pratama & Pristyanto, 2023).

$$accuracy = \frac{TP + TN}{TP + FN + TN + FP} \times 100\% \quad (3.10)$$

Precision merupakan metrik evaluasi yang digunakan untuk mengukur tingkat ketepatan model dalam memprediksi kelas positif. Nilai *precision* menunjukkan proporsi data yang diprediksi sebagai positif dan benar-benar termasuk ke dalam kelas positif. Precision pada persamaan 3.11 (Anugrah & Rachmat, 2025).

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (3.11)$$

Recall merupakan metrik evaluasi yang mengukur kemampuan model dalam mengenali seluruh data yang benar-benar termasuk kelas positif. Nilai *recall* menunjukkan proporsi kasus positif yang berhasil diidentifikasi dengan benar dibandingkan dengan total seluruh kasus positif yang sebenarnya, seperti ditunjukkan pada persamaan 3.12 (Wahyuningrum *et al.*, 2021)

$$recall = \frac{TP}{TP + FN} \times 100\% \quad (3.12)$$

Kemudian *F1-Score*, adalah hasil dari rata-rata perhitungan metrik *recall* dan *precision*. Nilai *f1-score* dapat diperoleh menggunakan rumus Persamaan 3.13 (Ubaidillah *et al.*, 2022).

$$f1 - score = 2 \times \frac{Recall \times Precision}{Recall + Precision} \times 100\% \quad (3.13)$$

BAB IV

HASIL DAN PEMBAHASAN

4.1 Hasil Uji Coba

Proses evaluasi terhadap performa model CNN dalam memetakan jenis penyakit daun tanaman jagung dilakukan dengan menerapkan delapan skema pengujian yang berbeda. Masing-masing skenario menerapkan kombinasi parameter, meliputi nilai *zoom range*, jumlah *fold* pada *cross validation*, dan jumlah *epoch*. Hasil yang diperoleh dievaluasi menggunakan metrik evaluasi yang terdiri atas *precision*, *recall*, dan *f1-score*, tabel *confusion matrix*, dan disajikan tabel yang menampilkan tingkat akurasi klasifikasi pada setiap kategori penyakit.

4.1.1 Skenario Uji A1

Pengujian pada skenario ini dilakukan menggunakan kombinasi parameter jumlah *epoch* 20, *k-fold cross validation* sebanyak 5 *fold*, dan *zoom range* sebesar 0.3. Dataset dibagi menjadi 10% untuk pengujian dan 90% sisanya yang terbagi menjadi 18% data pada setiap *fold*-nya digunakan untuk pelatihan.


Pada skenario ini, model mampu mengklasifikasikan sebagian besar data citra pada setiap kelas dengan benar. Seperti pada kelas Hawar Daun yang memperoleh nilai *f1-score* sebesar 97.54% dengan *recall* mencapai 99%. Hasil ini menunjukkan model hampir selalu berhasil mendeteksi citra hawar daun yang sebenarnya. Tingginya nilai *recall* menunjukkan sangat sedikit hawar daun yang terlewatkan selama proses klasifikasi. Performa model yang tinggi dipengaruhi oleh penggunaan tiga *convolutional layer* memungkinkan model melakukan *feature*

extraction secara bertingkat, mulai dari karakteristik sederhana seperti tepi dan tekstur kemudian berkembang hingga mengenali fitur yang lebih kompleks. Selain itu, penggunaan optimizer RMSProp membantu proses pembelajaran menjadi lebih stabil dan cepat dalam menemukan nilai bobot yang optimal. Hasil klasifikasi pada skenario A1 tertuang pada tabel 4.1.

Tabel 4.1 Hasil Klasifikasi CNN Skenario A1

Kategori	Prediksi Benar	Prediksi Salah	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Bercak daun	94	6	95.92%	94%	94.95%
Daun Sehat	92	8	97.87%	92%	94.85%
Hawar Daun	99	1	96.12%	99%	97.54%
Karat Daun	150	10	90.91%	93.75%	92.31%

Untuk lebih jelasnya informasi mengenai hasil pengujian pada data *testing*, disajikan secara visual melalui tabel *confusion matrix* dalam gambar 4.1.



Gambar 4.1 Tabel *Confusion Matrix* Skenario A1

4.1.2 Skenario Uji A2


Pengujian skenario ini, digunakan kombinasi parameter jumlah *epoch* 20, *k-fold cross validation* sebanyak 5 *fold*, dan *zoom range* sebesar 0.3. Dataset dibagi menjadi 10% untuk pengujian dan 90% sisanya yang terbagi menjadi 18% data pada setiap *fold*-nya digunakan untuk pelatihan.

Hasil klasifikasi pada skenario ini terlihat penurunan yang cukup signifikan dibanding skenario A1, yang dapat dilihat dari jumlah kesalahan prediksi yang bertambah pada kelas Daun Sehat dan kelas Karat Daun. Hal ini bisa terjadi yang kemungkinan dipengaruhi penggunaan parameter *zoom range* 0.5. Model kehilangan kemampuannya dalam mengenali pola data citra karena citra yang terlalu diperbesar visualnya. Sehingga menyebabkan pola yang dipelajari, salah dikenali sesuai dengan kelas sebenarnya. Hasil klasifikasi pada skenario A2 dirangkum pada tabel 4.2.

Tabel 4.2 Hasil Klasifikasi CNN Skenario A2

Kategori	Prediksi Benar	Prediksi Salah	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Bercak Daun	93	7	90.29%	93%	91.63%
Daun Sehat	59	41	93.65%	59%	72.39%
Hawar Daun	96	4	82.76%	96%	88.89%
Karat Daun	132	28	74.16%	82.50%	78.11%

Untuk lebih jelasnya informasi mengenai hasil pengujian pada data *testing*, disajikan secara visual melalui tabel *confusion matrix* dalam gambar 4.2.



Gambar 4.2 Tabel *Confusion Matrix* Skenario A2

4.1.3 Skenario Uji A3


Pada skenario ini dilakukan pengujian dengan kombinasi parameter jumlah *epoch* 20, *k-fold cross validation* sebanyak 10 *fold*, dan *zoom range* sebesar 0.3. Dataset dibagi menjadi 10% untuk pengujian dan 90% sisanya yang terbagi menjadi 18% data pada setiap *fold*-nya digunakan untuk pelatihan.

Hasil klasifikasi skenario A3 menunjukkan hasil prediksi model yang stabil dan seimbang, meskipun masih terdapat kesalahan prediksi tidak sesuai dengan kelas sebenarnya. Penggunaan *k-fold cross validation* sebanyak 10 *fold* dapat memberikan ”tambahan waktu” belajar bagi model dalam mempelajari karakteristik pada dataset di setiap kelasnya secara detail. Parameter *zoom range* sebesar 0.3 juga dinilai cukup untuk membantu model dalam mengidentifikasi fitur-fitur dasar seperti tepi dan tekstur pada citra daun secara keseluruhan. Hasil klasifikasi skenario A3 ditampilkan pada 4.3.

Tabel 4.3 Hasil Klasifikasi CNN Skenario A3

Kategori	Prediksi Benar	Prediksi Salah	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Bercak Daun	100	-	90.91%	100%	95.24%
Daun Sehat	87	13	97.75%	87%	92.06%
Hawar Daun	89	11	100%	89%	94.18%
Karat Daun	148	12	86.05%	92.50%	89.16%

Untuk lebih jelasnya informasi mengenai hasil pengujian pada data *testing*, disajikan secara visual pada gambar 4.3 dalam tabel *confusion matrix*.



Gambar 4.3 Tabel *Confusion Matrix* Skenario A3

4.1.4 Skenario Uji A4

Pengujian pada skenario A4 menggunakan kombinasi parameter *epoch* 20, *k-fold cross validation* sebanyak 10 *fold*, dan *zoom range* sebesar 0.5. Dataset dibagi menjadi 10% untuk pengujian dan 90% sisanya yang terbagi menjadi 18% data pada setiap *fold*-nya digunakan untuk pelatihan.


Pada hasil klasifikasi yang diperoleh skenario ini dengan *zoom range* sebesar 0.5 dan 10 *fold* yang digunakan, model menunjukkan metrik evaluasi yang cukup stabil terlihat dari nilai *precision*, *recall*, dan *f1-score* pada tiap kelasnya. Hasil pengujian menggunakan *zoom range* 0.5 tetap menunjukkan kinerja model yang optimal, terutama pada kelas hawar daun yang memperoleh *f1-score* tertinggi sebesar 96.52%. Temuan tersebut mengindikasikan bahwa karakteristik visual hawar daun tetap dapat dikenali meskipun citra mengalami perubahan ukuran yang cukup besar. Namun terlihat adanya penurunan *recall* seperti yg ditunjukkan pada kelas daun sehat dan karat daun. Kedua kelas ini juga terlihat bertambah jumlah kesalahan klasifikasinya. Kondisi ini mengindikasikan bahwa variasi *zoom* yang terlalu besar dapat mengubah tampilan tekstur dan pola visual sehingga sebagian

fitur khas menjadi kurang jelas, akibatnya model lebih sulit membedakan antara kelas daun sehat dan daun berpenyakit. Hasil klasifikasi skenario A4 pada tabel 4.4.

Tabel 4.4 Hasil Klasifikasi CNN Skenario A4

Kategori	Prediksi Benar	Prediksi Salah	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Bercak Daun	93	7	91.18%	93%	92.08%
Daun Sehat	83	17	97.65%	83%	89.73%
Hawar Daun	97	3	96.04%	97%	96.52%
Karat Daun	146	14	84.88%	91.25%	87.95%

Untuk lebih jelasnya informasi mengenai hasil pengujian pada data *testing*, disajikan secara visual pada gambar 4.4 dalam tabel *confusion matrix*.



Gambar 4.4 Tabel *Confusion Matrix* Skenario A4

4.1.5 Skenario Uji B1

Pada skenario ini pengujian dengan kombinasi parameter jumlah *epoch* 50, *k-fold cross validation* sebanyak 5 *fold*, dan *zoom range* sebesar 0.3. Dataset dibagi menjadi 10% untuk pengujian dan 90% sisanya yang terbagi menjadi 9% data pada setiap *fold*-nya digunakan untuk pelatihan.


Pengujian pada skenario ini, sebagian besar data diklasifikasi dengan benar sesuai dengan kelas sebenarnya. Hal ini bsai terlihat dari jumlah prediksi benar dan jumlah prediksi salah yang tidak terpaut selisih yg terlalu jauh. Di mana jumlah

kesalahan prediksi terbanyak hanya 13 data dari 100 data yang diujikan. Meskipun jumlah *epoch* ditambah menjadi 50, hal ini tidak merusak kemampuan model dalam mengenali pola karakteristik dari citra data dan mengklasifikasinya sesuai dengan kelas sebenarnya. Hasil klasifikasi skenario B1 dikumpulkan dalam tabel 4.5.

Tabel 4.5 Hasil Klasifikasi CNN Skenario B1

Kategori	Prediksi Benar	Prediksi Salah	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Bercak Daun	94	6	93.07%	94%	93.53%
Daun Sehat	87	13	98.86%	87%	92.55%
Hawar Daun	87	13	98.86%	87%	92.55%
Karat Daun	151	9	82.51%	94.38%	88.05%

Sebagai visual dari hasil pengujian model CNN pada *testing*, ditunjukkan oleh gambar 4.5 berupa tabel *confusion matrix*.



Gambar 4.5 Tabel *Confusion Matrix* Skenario B1

4.1.6 Skenario Uji B2


Pada skenario ini pengujian dengan kombinasi parameter jumlah *epoch* 50, *k-fold cross validation* sebanyak 5 *fold*, dan *zoom range* sebesar 0.5. Dataset dibagi menjadi 10% untuk pengujian dan 90% sisanya yang terbagi menjadi 9% data pada setiap *fold*-nya digunakan untuk pelatihan.

Hasil klasifikasi pada skenario ini menunjukkan hasil yang lebih stabil dibanding pada skenario A4 yang sama menggunakan parameter *zoom range* 0.5. Penggunaan *epoch* sebesar 50, mampu memberikan kemampuan lebih pada model dalam mempelajari dan mengenali pola-pola citra dengan lebih lama lagi. Hal ini terlihat dari hasil klasifikasi dari setiap kelasnya, menunjukkan nilai persen yang tidak terpaut terlalu jauh dengan selisih yang kecil. Hasil klasifikasi skenario B2 ditampilkan pada tabel 4.6.

Table 4.6 Hasil Klasifikasi CNN Skenario B2

Kategori	Prediksi Benar	Prediksi Salah	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Bercak Daun	92	8	88.46%	92%	90.20%
Daun Sehat	88	12	95.65%	88%	91.67%
Hawar Daun	97	3	91.51%	97%	94.17%
Karat Daun	138	22	87.34%	86.25%	86.79%

Sebagai visualiasi dari hasil prediksi pada data *testing* dengan model CNN ditampilkan dalam gambar 4.6 berupa tabel *confusion matrix*.



Gambar 4.6 Tabel *Confusion Matrix* Skenario B2

4.1.7 Skenario Uji B3

Pada skenario ini pengujian dengan kombinasi parameter jumlah *epoch* 50, *k-fold cross validation* sebanyak 10 *fold*, dan *zoom range* sebesar 0.3. Dataset


dibagi menjadi 10% untuk pengujian dan 90% sisanya yang terbagi menjadi 9% data pada setiap *fold*-nya digunakan untuk pelatihan.

Melalui skema pengujian ini, mayoritas data pada tiga kategori yaitu bercak daun, daun sehat, serta hawar daun mampu dipetakan secara akurat sesuai dengan label aslinya. Hal tersebut dijustifikasi oleh konsistensi nilai metrik evaluasi seperti *precision*, *recall*, dan *f1-score* yang stabil, berdampingan dengan minimnya kekeliruan estimasi dari model. Kendati terdapat 13 sampel pada kelompok bercak daun yang salah diidentifikasi oleh sistem, kuantitas galat tersebut masih dikategorikan dalam batas yang sangat rendah. Sedangkan pada kelas karat daun menunjukkan hasil klasifikasi yang berbanding terbalik, di mana jumlah kesalahan kesalahan prediksi pada kelas ini jauh lebih banyak dibanding pada ketiga kelas sebelumnya. Nilai *recall* memperoleh nilai paling rendah pada kelas ini sebesar 79.38%, yang menunjukkan bahwa kelas ini merupakan salah satu kelas yang paling sulit dikenali oleh model. Rendahnya nilai *recall* mengindikasikan adanya cukup banyak kasus *false negative*, yakni data yang sebenarnya pada kelas tersebut tetapi diprediksi sebagai kelas yang berbeda. Hasil klasifikasi skenario B3 pada tabel 4.7.

Tabel 4.7 Hasil Klasifikasi CNN Skenario B3

Kategori	Prediksi Benar	Prediksi Salah	<i>Precision</i>	<i>Recall</i>	F1-Score
Bercak Daun	87	13	95.60%	87%	91.10%
Daun Sehat	96	4	91.43%	96%	93.66%
Hawar Daun	99	1	82.50%	99%	90%
Karat Daun	127	33	88.19%	79.38%	83.55%

Sebagai visualisasi dari hasil prediksi pada data *testing* dengan model CNN ditampilkan dalam gambar 4.7 berupa tabel *confusion matrix*.

Gambar 4.7 Tabel *Confusion Matrix* Skenario B3

4.1.8 Skenario Uji B4

Pada skenario ini pengujian dengan kombinasi parameter jumlah *epoch* 50, *k-fold cross validation* sebanyak 10 *fold*, dan *zoom range* sebesar 0.5. Dataset dibagi menjadi 10% untuk pengujian dan 90% sisanya yang terbagi menjadi 9% data pada setiap *fold*-nya digunakan untuk pelatihan.


Hasil klasifikasi pada skenario ini menjadi yang terburuk dibanding dengan skenario-skenario sebelumnya. Hal ini bisa terlihat dari banyaknya jumlah kesalahan prediksi yang dihasilkan oleh model pada kelas daun sehat dan karat daun. Sementara itu, rendahnya nilai *recall* pada kelas daun sehat dan kelas karat daun mengindikasikan bahwa adanya kasus *false negative* di mana sebesar nilai tersebut data sebenarnya termasuk dalam kelas sebenarnya, namun diprediksi ke dalam kelas lain. Kasus kelas daun sehat dan karat daun, pada skenario ini kemungkinan yang terjadi disebabkan oleh penggunaan parameter *zoom range* sebesar 0.5 yang mengganggu kemampuan model untuk mempelajari karakteristik sederhana pada citra dan juga kemungkinan terjadi *overfitting* dikarenakan

penggunaan jumlah parameter pengujian yang terlalu banyak. Hasil klasifikasi skenario B4 ditampilkan dalam tabel 4.8.

Tabel 4.8 Hasil Klasifikasi CNN Skenario B4

Kategori	Prediksi Benar	Prediksi Salah	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Bercak Daun	94	6	88.68%	94%	91.26%
Daun Sehat	63	37	91.30%	63%	74.56%
Hawar Daun	100	-	83.33%	100%	90.91%
Karat Daun	129	31	78.18%	80.63%	79.38%

Sebagai visualiasi dari hasil prediksi pada data *testing* dengan model CNN ditampilkan dalam gambar 4.8 berupa tabel *confusion matrix*.



Gambar 4.8 Tabel *Confusion Matrix* Skenario B4

4.2 Analisis Hasil

Hasil yang dianalisis serangkaian skema eksperimen diimplementasikan guna menguji sekaligus menakar kapabilitas serta efektivitas algoritma *Convolutional Neural Network* (CNN) dalam mengelompokkan gambar infeksi pada daun jagung. Proses bedah data disandarkan pada indikator performa yang mencakup nilai precision, recall, maupun F1-score di tiap-tiap kelas, dengan turut memperhitungkan dampak dari integrasi berbagai parameter yang diaplikasikan.

Selanjutnya, capaian dari eksperimen tersebut ditelaah secara mendalam untuk meninjau efisiensi sistem pada tiap skenario, sekaligus memetakan variabel kunci yang memengaruhi tingkat ketepatan prediktif serta daya generalisasi jaringan dalam mengeksekusi proses klasifikasi.

Skenario A1, menggunakan kombinasi parameter 20 jumlah *epoch*, 5 *fold* pada *cross validation*, dan *zoom range* sebesar 0.3, model berhasil mengklasifikasi sebagian besar data sesuai dengan kelas sebenarnya. Meskipun masih terdapat kesalahan prediksi, namun pada klasifikasi awal kombinasi skenario A1 terbilang cukup efektif dalam mengklasifikasi data. Nilai yang diperoleh dari hasil klasifikasi di setiap kelasnya juga relatif tinggi, seperti pada *precision* yang memperoleh angka di atas 91%, *recall* memperoleh angka di atas 92%, dan *f1-score* memperoleh angka di atas 93%. Hal ini menjadi indikator bahwa penggunaan *epoch* sejumlah 20 memberikan kesempatan yang cukup bagi model untuk mempelajari pola dan karakteristik setiap kelas tanpa mengalami pelatihan yang terlalu singkat maupun terlalu lama. Kondisi ini tercermin dari tingginya nilai *recall* pada kelas penyakit hawar daun dengan nilai mencapai 99% yang menunjukkan model telah berhasil mempelajari ciri khas penyakit tersebut dengan sangat baik. Selain itu, nilai *f1-score* di setiap kelas yang melampaui 92% mengindikasikan bahwa jumlah *epoch* yang digunakan sudah cukup optimal untuk menghasilkan keseimbangan antara kemampuan belajar dan kemampuan generalisasi model. Metode *5-fold cross validation* berperan penting dalam meningkatkan keandalan model karena setiap data pelatihan memperoleh kesempatan untuk digunakan sebagai data pengujian pada salah satu *fold*. Oleh karena itu, model tidak hanya belajar dari satu subset data

tertentu, melainkan diuji pada berbagai kombinasi subset data yang berbeda. Kemudian pengaruh dari parameter *zoom range* sebesar 0.3 pada data augmentation memungkinkan citra diperbesar dan diperkecil hingga 30% dari ukuran aslinya. Variasi skala ini membantu model mempelajari objek pada berbagai ukuran dan posisi sehingga tidak terlalu bergantung pada ukuran daun tertentu. Pengaruh *zoom range* 0.3 terlihat dari tingginya nilai *recall* pada kelas hawar daun sebesar 99%, sedangkan kelas penyakit bercak daun serta daun sehat masing-masing mencapai *recall* sebesar 94% dan 92%. Hasil tersebut mengindikasikan bahwa model dapat mempertahankan kemampuan identifikasi meskipun terdapat variasi ukuran objek akibat proses augmentasi.

Pada skenario A2 yang menggunakan kombinasi parameter *epoch* sejumlah 20, 5 *fold* pada *cross validation*, dan *zoom range* sebesar 0.5, model mengalami penurunan performa secara signifikan. Terlihat dari jumlah kesalahan klasifikasi yang terjadi pada kedua kelas yakni kelas daun sehat sebesar 41 data dari 100 data dan karat daun sebesar 28 data dari 160 data. Hasil klasifikasi pada skenario ini jika dibandingkan dengan hasil dari skenario A1 dapat memunculkan spekulasi bahwa penggunaan *zoom range* 0.5 dapat mempengaruhi kemampuan model dalam menggeneralisir. Nilai *zoom range* 0.5 menghasilkan variasi data yang jauh lebih ekstrem dibandingkan *zoom range* 0.3. Augmentasi yang semakin beragam berkontribusi terhadap peningkatan kemampuan menggeneralisasi data. Namun, jika variasi yang diberikan terlalu besar, sebagian informasi penting pada citra dapat hilang atau berubah sehingga karakteristik penyakit menjadi kurang jelas. Pada citra daun jagung, gejala penyakit umumnya ditentukan oleh bentuk bercak, tekstur,

warna, dan pola penyebaran penyakit pada permukaan daun. Ketika dilakukan *zoom* hingga 50%, sebagian area penting dapat mengalami perubahan skala yang terlalu besar sehingga ciri khas penyakit menjadi sulit lebih dikenali.

Melalui skenario pengujian A3 yang mengonfigurasi parameter *epoch* 20, *cross validation* berjumlah 10 *fold*, serta tingkat *zoom range* sebesar 0.3, performa pengelompokan yang dicapai cenderung konsisten dalam memetakan data sesuai dengan label kategorinya. Kendati akumulasi kekeliruan estimasi belum mampu mengungguli performa pada skenario A1, metrik evaluasi dari *confusion matrix* seperti *precision*, *recall*, dan *f1-score* tetap menyuguhkan nilai yang seimbang walaupun terdapat peningkatan jumlah *fold* dalam sistem validasinya. Pada implementasi 10-fold *cross validation*, himpunan data pembelajaran dipisahkan ke dalam 10 fraksi. Dengan demikian, pada setiap siklus iterasi, sistem akan dilatih menggunakan 90% porsi data, sementara fraksi sisanya dialokasikan sebagai sampel uji. Jika disandingkan dengan skema 5-fold, model 10-fold menyelenggarakan kuantitas proses pelatihan serta pengujian yang jauh lebih intensif, sehingga memicu proses penaksiran kinerja sistem yang lebih ketat. Kondisi ini memberikan peluang bagi setiap data untuk merepresentasikan data uji secara lebih dinamis, yang pada akhirnya menghasilkan penilaian performa yang lebih nyata dan representatif terhadap kapabilitas asli dari algoritma tersebut.

Pada skenario A4 kombinasi parameter 20 *epoch*, *zoom range* sebesar 0.5, dan 10-fold *cross validation*, hasil klasifikasi pada skenario ini bisa dibilang “*versi upgrade*” dari skenario A2 yang sama menggunakan *zoom range* sebesar 0.5 hanya beda jumlah *fold*. Jika jumlah kesalahan prediksi pada skenario A2 di kelas daun

sehat sebesar 41 data dan kelas karat daun sebesar 28 data, pada skenario A4 jumlah kesalahan prediksi pada kelas daun sehat turun menjadi 17 data dan kelas karat daun juga turun menjadi 14 data. Jumlah kesalahan prediksi sebesar 17 data dan 14 data merupakan pengaruh dari penggunaan *zoom range* 0.5, sedangkan penurunan jumlah prediksi yang terjadi pada skenario A4 merupakan pengaruh dari jumlah *fold* yang ditambah. Ketika model mulai kehilangan informasi penting seperti karakteristik penyakit yang kurang jelas karena variasi yang diberikan terlalu besar, jumlah *fold* yang tinggi membantu model dalam memberikan tambahan kesempatan untuk mempelajari kembali informasi-informasi penting yang terdapat di dalam data citra.

Pada skenario B1 yang menggunakan jumlah *epoch* sebesar 50, *5-fold cross validation*, dan *zoom range* sebesar 0.3, model menghasilkan klasifikasi yang cukup baik. Hal tersebut diperoleh dari hasil evaluasi berada dalam rentang 87% hingga 98%. Meskipun begitu, pada kelas karat daun nilai *precision*-nya memperoleh angka yang paling rendah yakni sebesar 82%. Namun jumlah kesalahan prediksi yang diperoleh pada kelas karat daun hanya berjumlah 9 data. Meskipun jumlah *epoch* ditambah hingga sebesar 50, jika nilai parameter seperti yang diterapkan pada penelitian ini bernilai rendah, maka model masih mendapatkan waktu pelatihan yang panjang untuk mempelajari pola dan karakteristik setiap kelas. Dengan jumlah iterasi yang lebih banyak, model memiliki kesempatan untuk melakukan penyesuaian bobot secara lebih optimal sehingga fitur-fitur penyakit dapat dipelajari dengan lebih mendalam.

Pada skenario B2 menggunakan kombinasi parameter *epoch* 50, *5-fold cross validation*, dan *zoom range* sebesar 0.5, hasil pengujian pada skenario B2 menunjukkan perbedaan yang tidak terlalu jauh dari skenario B1. Namun, seperti hasil klasifikasi pada skenario-skenario sebelumnya, kelas daun sehat dan karat daun memperoleh jumlah kesalahan prediksi yang banyak dibanding kelas bercak daun dan hawar daun. Penggunaan *zoom range* yang terlalu besar menyebabkan sebagian fitur penting menjadi kurang terlihat. Gejala penyakit seperti perubahan warna atau pola kerusakan daun dapat mengalami perubahan proporsi sehingga karakteristik visual yang sebenarnya menjadi lebih sulit dikenali. Meskipun demikian, pada skenario ini performa model masih tergolong baik karena *epoch* yang lebih tinggi membantu model beradaptasi terhadap variasi data yang dihasilkan oleh proses augmentasi.

Pada Skenario B3 yang menggunakan kombinasi *epoch* 50, *10-fold cross validation*, dan *zoom range* sebesar 0.3, hasil klasifikasi skenario ini hasilnya tidak jauh berbeda dari skenario sebelumnya yakni skenario B2. Jika pada skenario B2 yang memperoleh jumlah kesalahan prediksi paling banyak adalah kelas daun sehat dan kelas karat daun, skenario B3 justru kelas bercak daun dan kelas karat daun yang memperoleh jumlah kesalahan prediksi paling banyak. Kelas bercak daun sebanyak 13 data salah diprediksi dalam kelas karat daun, sedangkan pada kelas karat daun sebanyak 33 data samar diprediksi dalam kelas bercak daun, daun sehat, dan hawar daun. Hasil sedemikian rupa ini merupakan pengaruh dari penggunaan jumlah *epoch* yang tinggi dan jumlah *fold cross validation* yang telah diterapkan. Model memperoleh pengujian pada lebih banyak variasi data sehingga evaluasi

menjadi lebih representatif. Namun, jumlah *fold* yang lebih banyak juga dapat meningkatkan variasi distribusi data sehingga model menjadi lebih sensitif terhadap karakteristik tertentu seperti yang terjadi pada kelas karat daun. Kondisi ini menunjukkan meskipun proses validasi lebih banyak dilakukan, model masih mengalami kesulitan dalam mempelajari karakteristik karat daun secara konsisten.

Skenario terakhir yakni B4 yang menggunakan kombinasi parameter 50 *epoch*, 10-*fold cross validation*, dan *zoom range* sebesar 0.5, hasil klasifikasi memperoleh hasil yang terendah daripada skenario-skenario sebelumnya. Terlihat dari banyaknya kesalahan yang prediksi oleh model pada kategori daun sehat dan kelas karat daun. Kelas daun sehat sebanyak 37 data dari 100 data, salah diprediksi pada kelas karat daun dan sebanyak 31 data dari 160 data salah pada kelas karat daun, salah diprediksi pada tiga kelas yaitu kelas bercak daun, daun sehat dan hawar daun. Selain itu nilai *recall* pada kelas daun sehat memperoleh nilai yang paling rendah yaitu sebesar 63% saja. Artinya, dengan penggunaan jumlah *epoch* yang ditingkatkan menjadi 50 dan *fold* yang juga ditambah menjadi 10-*fold*, jika menggunakan *zoom range* sebesar 0.5 tidak akan memperbaiki hasil klasifikasi. Dengan kata lain, meskipun model diberikan kesempatan sebanyak mungkin untuk mempelajari dan mengenali fitur-fitur penting dan juga karakteristik pada data citra, jika data citra terlalu dibesarkan visualnya, model tetap tidak dapat mengenali fitur-fitur penting pada data citra bahkan pola sederhana sekalipun, khususnya pada kelas daun sehat dan kelas karat daun. Hal ini juga menjadi faktor dari data yang digunakan, kurangnya pencahayaan, tidak terlalu menonjolnya tekstur dari daun

yang berpenyakit dan kurangnya variasi data yang menjadikan faktor kegagalan model dalam mengklasifikasi data sesuai dengan kelas sebenarnya.

Berdasarkan analisis hasil, beberapa penelitian sebelumnya dapat dijadikan sebagai pembandingan, metode CNN yang menggunakan dua lapisan konvolusi dan dua lapisan *pooling layer* menghasilkan akurasi terbaik sebesar 92,68% pada skenario *zoom range* 0.2, *epoch* 20 dan *validation split* 0.2 (Wirabowo & Susilawati, 2025), kemudian *VGG16* dengan *transfer learning* dibandingkan dengan *VGG16 baseline* membuktikan *VGG16* dengan *transfer learning* lebih unggul akurasi klasifikasi mencapai 96,25% (Ismiaty Ramadhona *et al.*, 2025), kemudian metode CNN yang menggunakan arsitektur *LenNet* dengan rasio *split* data 80:20 menghasilkan akurasi terbaik dengan rata-rata 80% pada metode *single-stage classification* (Pangestu *et al.*, 2025), selanjutnya penelitian dengan metode CNN menunjukkan hasil akurasi sebesar 92% dengan rasio *split* data 70:20 (M. D. Pratama *et al.*, 2024). Sementara metode yang diusulkan mendapatkan akurasi sebesar 87% menggunakan tiga lapisan konvolusi dan tiga lapisan *pooling layer* serta pada skenario *zoom range* 0.2 dan *epoch* 20, yang mampu menghasilkan kinerja yang optimal dan stabil serta kemampuan generalisasi model terhadap data citra yang baik selama pelatihan dan pengujian.

4.3 Integrasi Sains dan Islam

Fokus utama dari riset ini bermuara pada pengadopsian metode *Convolutional Neural Network* (CNN) untuk mengukur sejauh mana keandalan sistem saat mengidentifikasi infeksi daun jagung melalui ekstraksi citra. Capaian dari kajian ini diantisipasi dapat menghadirkan sumbangsih nyata dalam

memfasilitasi prosedur deteksi anomali tanaman jagung dengan standar akurasi yang lebih mumpuni. Lebih jauh lagi, skema klasifikasi yang diaplikasikan dalam studi ini sangat sejalan dengan pandangan ajaran Islam mengenai filosofi penggolongan, sebagaimana makna yang direpresentasikan di dalam teks *Surah Ali 'Imran* ayat 110,

كُنْتُمْ خَيْرَ أُمَّةٍ أُخْرِجَتْ لِلنَّاسِ تَأْمُرُونَ بِالْمَعْرُوفِ وَتَنْهَوْنَ عَنِ الْمُنْكَرِ وَتُؤْمِنُونَ بِاللَّهِ وَلَوْ آمَنَ أَهْلُ الْكِتَابِ لَكَانَ خَيْرًا لَهُمْ مِنْهُمْ الْمُؤْمِنُونَ وَأَكْثَرُهُمُ الْفَاسِقُونَ

“Kamu adalah umat yang terbaik yang dilahirkan untuk manusia, menyuruh kepada yang ma'ruf, dan mencegah dari yang mungkar, dan beriman kepada Allah. Sekiranya ahli kitab beriman, tentulah itu lebih baik bagi mereka, di antara mereka ada yang beriman, dan kebanyakan mereka adalah orang-orang yang fasik.” (Q.S Ali 'Imran:110)

Merujuk pada literatur Tafsir At-Thabari, Ibnu Jarir At-Thabari menjabarkan setidaknya dua pandangan berbeda terkait definisi "umat" pada firman tersebut. Pandangan perdana mengartikan "umat" sebagai kelompok Muhajirin, yakni golongan yang melakukan hijrah mendampingi Rasulullah saw. dari Makkah menuju Madinah. Interpretasi ini disandarkan pada riwayat Ibnu Abbas melalui jalur Sa'id bin Jubair, al-Suddi, serta Ikrimah. Di sisi lain, pandangan kedua yang bersumber dari riwayat Abu Hurairah dan Mujahid mendeskripsikan makna "umat" sebagai setiap individu yang sanggup mengamalkan tiga syarat esensial, yakni menegakkan kebaikan (*amar ma'ruf*), mencegah keburukan (*nahi munkar*), serta memiliki landasan iman kepada Allah Swt., sesuai dengan redaksi ayat terkait.

Ditinjau dariacamata keislaman, substansi Surah Ali 'Imran ayat 110 mengukuhkan predikat kaum muslimin sebagai khairu ummah (sebaik-baik umat) lantaran berpegang teguh pada ketiga atribut fundamental tersebut. Secara tersirat,

firman ini membuktikan bahwa Al-Qur'an telah mewariskan filosofi dasar dari sistem klasifikasi, yakni proses pemilahan suatu entitas ke dalam golongan spesifik berdasarkan pada karakteristik pembedanya. Jika ditarik ke dalam ranah riset ini, konsep penggolongan tersebut terepresentasi secara jelas melalui proses pemisahan anomali visual daun tanaman jagung ke dalam kelas-kelas tertentu berdasarkan ciri khas patologi yang dimilikinya. Dengan demikian, terdapat keterkaitan konseptual antara pesan-pesan yang terkandung dalam Al-Qur'an dan pendekatan ilmiah modern, di mana keduanya sama-sama menggunakan kriteria spesifik untuk menentukan suatu kelompok.

Selain menjelaskan konsep klasifikasi yang digambarkan dengan umat Islam dengan sebutan *khairu ummah*, penelitian ini juga mencerminkan nilai – nilai dalam ajaran Islam yang menekankan pentingnya usaha, kerja keras, dan kesungguhan dalam mencapai hasil yang terbaik. Dalam ajaran Islam, amal perbuatan manusia akan dilihat dan dinilai, sehingga mendorong manusia untuk senantiasa berusaha secara optimal dan bertanggung jawab dalam setiap pekerjaan yang dilakukan, sebagaimana termuat dalam *Surah Al-Mulk ayat 2*,

الَّذِي خَلَقَ الْمَوْتَ وَالْحَيَاةَ لِيَبْلُوَكُمْ أَيُّكُمْ أَحْسَنُ عَمَلًا وَهُوَ الْعَزِيزُ الْعَفُورُ

“yaitu yang menciptakan kematian dan kehidupan untuk menguji kamu, siapa diantara kamu yang lebih baik amalnya. Dia Mahaperkasa lagi Maha Pengampun.” (Q.S Al-Mulk:2)

Dalam Tafsir Al-Azhar, Prof. Dr. Haji Abdulmalik Abdulkarim Amrullah, menjelaskan bahwa kehidupan dan kematian merupakan ketentuan Allah yang menunjukkan kekuasaan-Nya. Hidup manusia di dunia bukan merupakan tujuan utama, melainkan sebagai suatu sarana untuk menilai kualitas amal perbuatan

manusia. Pada ayat ini, Allah tidak menyebut “siapa yang paling banyak amalnya”, tetapi “siapa yang paling baik amalnya”. Hal tersebut menunjukkan bahwa kualitas amal lebih utama dibanding kualitasnya. Selaras dengan penelitian ini karena mengandung nilai tentang menghasilkan sesuatu yang terbaik melalui usaha dan proses yang sungguh-sungguh. Dalam penelitian penggunaan metode *Convolutional Neural Network* untuk mengklasifikasi penyakit daun jagung, proses pelatihan model dilakukan untuk memperoleh performa terbaik dalam mempelajari dan mengelompokkan citra daun berdasarkan karakteristiknya. Prinsip “*ahsanu ‘amala*” atau amal terbaik dapat dimaknai sebagai dorongan untuk melakukan penelitian secara teliti, sistematis, dan bertanggung jawab agar menghasilkan model klasifikasi yang akurat dan bermanfaat. Dengan demikian, penelitian bukan sekedar aktivitas akademik, melainkan juga menjadi usaha atau manusia memanfaatkan ilmu pengetahuan untuk memberikan manfaat yang lebih baik bagi kehidupan.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Temuan akhir dari studi ini mengindikasikan bahwa arsitektur Convolutional Neural Network (CNN) memiliki kapabilitas yang sangat optimal ketika diaplikasikan untuk memilah anomali daun jagung. Algoritma ini sukses mengidentifikasi citra ke dalam empat kelas utama, yakni bercak daun, hawar daun, karat daun, maupun kondisi daun normal. Skenario terbaik diperoleh pada skenario A1 yang menggunakan *epoch* 20, *zoom range* 0.3, dan *5-fold cross validation* yang menghasilkan jumlah kesalahan paling sedikit pada setiap kelasnya dan memperoleh nilai *precision* sebesar 95.92%, 97.87%, 96.12%, dan 90.91%, *recall* sebesar 94%, 92%, 99%, dan 93.75%; serta *f1-score* sebesar 94.95%, 94.85%, 97.54%, dan 92.31%. Sebaliknya pada skenario B4 yang menggunakan *epoch* 50, *10-fold*, dan *zoom range* 0.5 menunjukkan performa yang relatif lebih rendah disertai jumlah kesalahan prediksi yang lebih banyak dibandingkan dengan skenario A1. Hasil tersebut menunjukkan peningkatan *epoch*, jumlah *fold*, maupun *zoom range* tidak selalu menghasilkan peningkatan performa klasifikasi. Berdasarkan hasil pengujian dari delapan skenario, metode CNN mampu mengekstraksi dan mengenali karakteristik pada citra daun jagung, mulai dari fitur sederhana seperti tepi, tekstur, warna serta fitur yang lebih kompleks sebagai pembeda antar kelas penyakit. Penelitian juga membuktikan bahwa pemilihan kombinasi parameter pelatihan memiliki pengaruh yang signifikan terhadap

performa model. Kombinasi *epoch* 20, *zoom range* 0.3, dan *5-fold cross validation* merupakan konfigurasi yang paling optimal karena berhasil menghasilkan performa klasifikasi yang memiliki akurasi tinggi, stabil, serta memiliki tingkat kesalahan prediksi paling rendah.

5.2 Saran

Merujuk pada *output* eksperimen sekaligus mengevaluasi batasan-batasan yang muncul selama proses kajian berlangsung, penulis merumuskan beberapa usulan. Hal ini diharapkan mampu menjadi bahan evaluasi dan referensi berharga untuk pengembangan studi sejenis ke depannya. Pertama, penelitian selanjutnya dapat memanfaatkan jumlah dataset yang lebih besar dan beragam, dari segi kondisi pencahayaan maupun dari tingkat keparahan penyakit agar model yang dihasilkan menjadi lebih *robust* dengan kemampuan generalisasi yang lebih optimal. Kedua, penelitian selanjutnya dapat mencoba menggunakan metode lain seperti model CNN berbasis *transfer learning* atau *deep learning* yang lebih kompleks menggunakan model versi tahun yang memiliki arsitektur terbaru guna meningkatkan performa akurasi klasifikasi. Terakhir, penelitian ini masih berfokus pada tahap klasifikasi citra, sehingga diharapkan pada penelitian selanjutnya dapat dikembangkan ke tahap implementasi sistem secara langsung.

DAFTAR PUSTAKA

- Adhinata, F. D., Fitriana, G. F., Wijayanto, A., Pajar, M., & Putra, K. (2021). *Corn Disease Classification Using Transfer Learning and Convolutional Neural Network*. 9(2), 211–217.
- Akhyari, M. W., Suyoto, A., & Wibowo, F. W. (2021). *Klasifikasi Penyakit Pada Daun Jagung Menggunakan Convolutional Neural Network*. 7, 3–6.
- Akram, A., Adinda Rachmadinasya, Safira Hafidz Melvandino, F., & Ramza, H. (2024). KLASIFIKASI AKTIVITAS OLAHRAGA BERDASARKAN CITRA FOTO DENGAN MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK. *JITET (Jurnal Informatika Dan Teknik Elektro Terapan)*, 11(3), 1081–1086. <https://doi.org/10.23960/jitet.v11i3s1.3496>
- Alwan, D. N., Faisal, S., & Handayani, H. H. (2024). *Implementasi YOLOv8 Untuk Deteksi Penyakit Daun Jagung Menggunakan Algoritma Convolutional Neural Network (CNN)*. V(Juli), 67–75.
- Anugrah, M. N., & Rachmat, N. (2025). *Klasifikasi Penyakit Daun Tanaman Jagung Menggunakan Pendekatan Transfer Learning Arsitektur MobileNetV4*. 4(4), 2174–2182.
- Askale, G. T., Yibel, A. B., Taye, B. M., & Wubneh, G. D. (2025). Mobile based deep CNN model for maize leaf disease detection and classification. *Plant Methods*. <https://doi.org/10.1186/s13007-025-01386-5>
- Azizah, Q. N. (2023). Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network AlexNet. *Sudo Jurnal Teknik Informatika*, 2(1), 28–33. <https://doi.org/10.56211/sudo.v2i1.227>
- Bin Abdurrahman bin Ishaq Al-Sheikh, Abdullah bin Muhammad. (2001). *Lubaabut Tafsir Min Ibnu Katsiir Jilid VI*. Jakarta: Pustaka Imam Asy-Syafi'i.
- Abdulkarim Abdullah, Abdulmalik (Hamka). (1989). *Tafsir Al-Azhar Jilid X*. Singapura: Pustaka Nasional PTE LTD.
- Abdurraziq Al-Bakri, A., Adil Muhammad, M., Abdul Latif Khalaf, M., & Mursi Abdul Hamid, M. (2002). *Tafsir Ath-Thabari: Jami' Al-Bayan Fi Ta'wil Al-Qur'an Jilid V*. Jakarta Selatan: Pustaka Azzam.
- Batool, A., Kim, J., & Byun, Y. C. (2025). A compact deep learning approach integrating depthwise convolutions and spatial attention for plant disease classification. *Plant Methods*. <https://doi.org/10.1186/s13007-025-01325-4>
- Bhagawanta, B., & Budy Santoso, C. (2025). Deteksi Penyakit Daun Kapas Dengan Deep Learning Berbasis Convolutional Neural Network (CNN). *IDEALIS: InDonEsiA Journal Information System*, 8(2), 220–227. <https://doi.org/10.36080/idealis.v8i2.3517>

- Bhat, S. S., Ananth, A., & Venugopala, P. S. (2023). Design and Evolution of Deep Convolutional Neural Networks in Image Classification - A Review. *International Journal of Integrated Engineering*, 15(1), 213–225. <https://doi.org/10.30880/ijie.2023.15.01.019>
- Cahya Pratiwi, A. O. (2023). Klasifikasi Jenis Anggur Berdasarkan Bentuk Daun Menggunakan Convolutional Neural Network Dan K-Nearest Neighbor. *Jurnal Ilmiah Teknik Informatika Dan Komunikasi*, 3(2), 201–224. <https://doi.org/10.55606/juitik.v3i2.535>
- Elroy, S. J., Nurdyansyah, F., & Priyandoko, G. (2024). Klasifikasi Daun Durian Pada Citra Dalam Menentukan Jenis Menggunakan Convolutional Neural Network. *3RD MDP Student Conference (MSC)*, 56–62.
- Fithratul Zalmi, W., Hari Saputro, P., Sitanggang, J., & Leatemia, K. (2025). PENERAPAN CONVOLUTIONAL NEURAL NETWORK (CNN) UNTUK KLASIFIKASI PENYAKIT DAUN TOMAT. *JURNAL INFORMATIK*, 4(2), 58–67.
- Gautam, V., Quraishi, A., Alghamdi, A., Kaur, G., Alghayadh, F., Byeon, H., & Bhatt, M. W. (2025). Maize leaf disease multiclass classification and recognition for sustainable agriculture using multi preceptive deep learning model. *Discover Sustainability*. <https://doi.org/10.1007/s43621-025-01256-z>
- Gayatri Devi, T., Patil, N., Rai, S., & Sarah Philipose, C. (2023). *Gaussian Blurring Technique for Detecting and Classifying Acute Lymphoblastic Leukemia Cancer Cells from Microscopic Biopsy Images*.
- Gumelar, G., Sugiharto, T., & Lesmana, I. (2025). *Jurnal Computer Science and Information Technology (CoSciTech) Implentation of CNN for Corn Leaf Disease Identification*. 6(2), 175–180.
- Ismiaty Ramadhona, A., Wiwik, S. A., Anjar, W., & Solikhun, S. (2025). *Optimisasi VGG16 dengan Transfer Learning dalam Mendeteksi Penyakit Pada Daun Jagung*. 5(5), 1049–1058. <https://doi.org/10.47065/bulletincsr.v5i5.631>
- Iswantoro, D., & Handayani, D. (2022). Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Ilmiah Universitas Batanghari Jambi*, 22(2), 900. <https://doi.org/10.33087/jiubj.v22i2.2065>
- Mulya Lesmana, A., Putri Fadhillah, R. \, & Rozikin, C. (2022). Identifikasi Penyakit pada Citra Daun Kentang Menggunakan Convolutional Neural Network (CNN). *Jurnal Sains Dan Informatika*, 8(1), 21–30. <https://doi.org/10.34128/jsi.v8i1.377>
- O'Shea, K., & Nash, R. (2022). An Introduction to Convolutional Neural Networks Keiron. *International Journal for Research in Applied Science and Engineering Technology*, 10(12), 943–947.

<https://doi.org/10.22214/ijraset.2022.47789>

- Pangestu, D. A., Aziz, O. Q., & Crysdiyan, C. (2025). *Klasifikasi Penyakit pada Tanaman Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network*. 10(2), 235–248.
- Paraijun, F., Nur Aziza, R., & Kuswardani, D. (2022). Implementasi Algoritma Convolutional Neural Network Dalam Mengklasifikasi Kesegaran Buah Berdasarkan Citra Buah. *Kilat*, 11(1), 1–9. <https://doi.org/10.33322/kilat.v10i2.1458>
- Peryanto, A., Yudhana, A., & Umar, R. (2020). Klasifikasi Citra Menggunakan Convolutional Neural Network dan K Fold Cross Validation. *Journal of Applied Informatics and Computing*, 4(1), 45–51. <https://doi.org/10.30871/jaic.v4i1.2017>
- Pratama, A. Y., & Pristyanto, Y. (2023). Classification of Corn Plant Diseases Using Various Convolutional Neural Network. *JITK (Jurnal Ilmu Pengetahuan Dan Teknologi Komputer)*, 9(1), 49–56. <https://doi.org/10.33480/jitk.v9i1.4258>
- Pratama, M. D., Gustriansyah, R., & Purnamasari, E. (2024). *KLASIFIKASI PENYAKIT DAUN PISANG MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN)*. 10(1), 1–6.
- Putra, A., & Prihartono, W. (2025). Klasifikasi Penyakit Daun Cabai Dengan Metode CNN Untuk Deteksi Awal. *Jurnal Profesi Insinyur Universitas Lampung*, 6(1), 11–16. <https://doi.org/10.23960/jpi.v6n1.147>
- Putra, I. P., Rusbandi, R., & Alamsyah, D. (2022). Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network. *Jurnal Algoritme*, 2(2), 102–112. <https://doi.org/10.35957/algoritme.v2i2.2360>
- Resti, Y., Herlina Saraswati, D., A.Zayanti, D., & Eliyati, N. (2022). *CLASSIFICATION OF DISEASES AND PESTS OF MAIZE USING MULTINOMIAL LOGISTIC REGRESSION BASED ON RESAMPLING TECHNIQUE OF*. 3(3), 69–76.
- Rosadi, M. I., & Lutfi, M. (2021). *Identifikasi Jenis Penyakit Daun Jagung Menggunakan Deep Learning Pre- Trained Model*. 5(36), 35–42.
- Sarah, S., & Guntoro. (2023). Identifikasi Penyakit Tanaman Jagung Menggunakan Citra Daun. *Jurnal Agroindustri*, 12(x), 278–289.
- Sarasati, F., Nugraha, F. S., & Radiyah, U. (2022). *Pemanfaatan Metode Deep Learning untuk Klasifikasi Penyakit pada Tanaman Jagung*. 4(2).
- Satoto, B. D., Wahyuningrum, R. T., & Khotimah, B. K. (2023). *Classification of Corn Seed Quality Using Convolutional Neural Network with Region Proposal and Data Augmentation*. 9(2), 348–362. <https://doi.org/10.26555/jiteki.v9i2.26222>

- Satria Yudha, R., Imanuel, C., Yoga Saputra, M., & Dwi Irawan, R. (2025). Klasifikasi Kondisi Tanaman Cabai Sehat dan Tidak Sehat Menggunakan Convolutional Neural Network Berbasis Teachable Machine. *Prosiding Seminar Nasional Teknologi Informasi Dan Bisnis*, 354–357. <https://doi.org/10.47701/a0nwc842>
- Sheila, S., Kharil Anwar, M., Bagas Saputra, A., Restu Pujianto, F., & Permata Sari, I. (2023). Deteksi Penyakit Pada Daun Padi Berbasis Pengolahan Citra Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Ilmiah Informatika Global*, 9, 27–34. <https://doi.org/10.36982/jiig.v14i3.3478>
- Statistik, B. P. (2023). *Luas Panen dan Produksi Jagung di Indonesia 2023 (Angka Sementara)*. 2023(69).
- Ubaidillah, A., Rochman, Fatah, & Rachmad, A. (2022). Classification of Corn Diseases using Random Forest, Neural Network, and Naïve Bayes Methods. *Journal of Physics: Conference Series*. <https://doi.org/10.1088/1742-6596/2406/1/012023>
- Wahyuningrum, R. T., Erfian, R., Kusumaningsih, A., & Tjahyaningtijas, H. P. A. (2025). Klasifikasi Penyakit Daun Jagung Menggunakan Model Deep Learning EfficientNetB5. *Jurnal Pekommas*, 10(1), 1–8. <https://doi.org/10.56873/jpkm.v9i1.5322>
- Wahyuningrum, R. T., Kusumaningsih, A., Wijanarko, P. R., & Purnama, I. K. E. (2021). Classification of Corn Leaf Disease Using the Optimized DenseNet-169 Model. *ICIT*, 67–73.
- Wang, H., & Song, Y. (2025). *Adaptive Low Light Enhancement via Joint Global-Local Illumination Adjustment*.
- Widianto, B., Utami, E., & Ariatmanto, D. (2023). Identifikasi Penyakit Tanaman Jagung Berdasarkan Citra Daun Menggunakan Convolutional Neural Network. *Techno.Com*, 22(3), 599–608. <https://doi.org/10.33633/tc.v22i3.8425>
- Wirabowo, I., & Susilawati, I. (2025). Implementasi Convolution Neural Network (CNN) untuk Deteksi Penyakit pada Daun Jagung Berbasis Citra Digital. *Jurnal Pustaka Data (Pusat Akses Kajian Database, Analisa Teknologi, Dan Arsitektur Komputer)*, 5(1), 233–241. <https://doi.org/10.55382/jurnalpustakadata.v5i1.1046>
- Wulandari, I., Yasin, H., & Widiharih, T. (2024). Klasifikasi Citra Digital Bumbu dan Rempah Dengan Algoritma Convolutional Neural Network (CNN). *Repeater: Publikasi Teknik Informatika Dan Jaringan*, 2(3), 26–34. <https://doi.org/10.62951/repeater.v2i3.81>
- Yoggyanto, A., Maulana, A., & Tri Cahyo, D. A. (2024). Penerapan Metode Convolutional Neural Network (CNN) Dalam Klasifikasi Penyakit Tanaman Jagung. *Prosiding Seminar Nasional Teknologi Dan Sains*, 3(2022), 251–256.

<https://proceeding.unpkediri.ac.id/index.php/stains/article/view/4300%0Ahttps://proceeding.unpkediri.ac.id/index.php/stains/article/download/4300/3027>

Yusuf, M., Kurniawan, D., & Agustin, T. (2024). *KLASIFIKASI PENYAKIT TANAMAN JAGUNG DENGAN KECERDASAN BUATANBUATAN BERBASIS CNN*. November, 355–368.