

Identifikasi CNN dalam Deteksi Penyakit Daun Jagung Berbasis Pengenalan Gambar

ARYANTI ARYANTI, DEFINA APRILIANI, WULAN ZAHRA PUTRI, DWI RAMADHANI, THREA MALINDA, DIMAS ANDREANSYAH

Program Studi Teknik Telekomunikasi, Juruan Teknik Elektro
Politeknik Negeri Sriwijaya, Indonesia
Email: aryanti@polsri.ac.id

Received 9 Juli 2025 | Revised 12 Oktober 2025 | Accepted 21 November 2025

ABSTRAK

Produktivitas jagung sangat terancam oleh penyakit daun seperti common rust, gray leaf spot, dan leaf blight. Identifikasi penyakit yang lambat dan tidak akurat menjadi masalah utama yang mendesak. Oleh karena itu, penelitian ini bertujuan mengembangkan mekanisme identifikasi otomatis penyakit daun jagung menggunakan algoritma Convolutional Neural Network (CNN) berbasis citra digital, mendukung upaya pertanian presisi. Penelitian menggunakan 4.188 citra daun (sehat, leaf blight, rust, dan gray leaf spot) yang diproses melalui preprocessing seperti normalisasi dan augmentasi. Hasil pengujian menunjukkan efektivitas tinggi, di mana model CNN mencapai akurasi klasifikasi 95% dengan waktu inferensi cepat, hanya 0,48 detik per gambar. Kontribusi utama penelitian ini adalah penyediaan model CNN yang sangat akurat dan efisien, berpotensi besar menjadi dasar sistem diagnostik lapangan untuk membantu petani meningkatkan kualitas dan hasil produksi jagung.

Kata kunci: CNN, Deteksi Penyakit, Jagung, Pengenalan Citra, Deep Learning

ABSTRACT

Corn productivity is severely threatened by leaf diseases such as common rust, gray leaf spot, and leaf blight. Slow and inaccurate disease identification is a pressing issue. Therefore, this study aims to develop an automatic corn leaf disease identification mechanism using a digital image-based Convolutional Neural Network (CNN) algorithm, supporting precision agriculture efforts. The study used 4,188 leaf images (healthy, leaf blight, rust, and gray leaf spot) that were processed through preprocessing such as normalization and augmentation. The test results demonstrated high effectiveness, where the CNN model achieved 95% classification accuracy with a fast inference time of only 0.48 seconds per image. The main contribution of this study is the provision of a highly accurate and efficient CNN model, with great potential to become the basis of a field diagnostic system to help farmers improve corn quality and yield.

Keywords: CNN, Disease Detection, Corn, Image Recognition, Deep Learning

1. PENDAHULUAN

Setelah padi Jagung (*Zea mays L.*) merupakan salah satu komoditas pangan strategis paling penting di Indonesia. Ia berfungsi sebagai sumber karbohidrat utama bagi masyarakat, jagung juga sangat penting untuk industri peternakan (pakan ternak), industri makanan, dan bioenergi (**Setyawan, dkk, 2010**). Dalam beberapa tahun terakhir, produksi jagung di Indonesia menunjukkan tren peningkatan yang cukup signifikan. Hal ini didukung oleh data dari Badan Pusat Statistik (BPS) yang mencatat adanya lonjakan hasil panen jagung di berbagai wilayah, mencerminkan meningkatnya kebutuhan terhadap komoditas tersebut baik untuk konsumsi domestik maupun sebagai bahan baku industri pakan ternak. Jagung telah menjadi salah satu komoditas strategis nasional karena perannya yang vital dalam mendukung ketahanan pangan dan ekonomi nasional (**Bantacut, dkk, 2015**). Beberapa daerah, seperti Jawa Timur, Lampung, dan Sulawesi Selatan, bahkan menjadikan jagung sebagai produk unggulan dalam sektor pertanian mereka, dengan dukungan infrastruktur, teknologi budidaya, serta program-program pemerintah yang mendorong intensifikasi dan ekstensifikasi lahan. Oleh karena itu, upaya peningkatan produktivitas, efisiensi budidaya, dan mutu hasil panen jagung menjadi sangat penting, khususnya dalam menghadapi tantangan global seperti peningkatan jumlah penduduk, perubahan iklim, serta tekanan terhadap ketersediaan lahan pertanian (**Koukouli, dkk, 2025**). Dengan strategi yang tepat, jagung dapat menjadi tulang punggung dalam memperkuat sistem ketahanan pangan nasional di masa mendatang.

Salah satu faktor utama yang menghambat produktivitas jagung di lapangan adalah serangan patogen tanaman (**Albana, dkk, 2024**). Penyakit seperti *leaf blight*, *rust*, dan *gray leaf spot* sangat umum terjadi dan dapat menyebabkan kerusakan signifikan pada tanaman jika tidak terdeteksi secara dini (**M. A. Setyawan, dkk, 2022**). Penyakit-penyakit ini biasanya ditandai dengan munculnya bercak, perubahan warna, dan nekrosis pada daun yang menghambat proses fotosintesis (**Hamidson, dkk, 2019**). Deteksi penyakit secara manual oleh petani atau penyuluh lapangan sering kali tidak efektif karena keterbatasan tenaga ahli, keterlambatan identifikasi, dan subjektivitas dalam pengamatan (**Rosadi & Lutfi, 2021**). Sebagian besar petani di tanah air juga masih menggunakan teknik tradisional untuk memonitor kondisi tanaman, yang sangat rentan terhadap keterlambatan penanganan (**Nina, dkk, 2023**). Oleh karena itu, dibutuhkan metode otomatis dan cerdas yang dapat mendeteksi penyakit daun secara cepat, akurat, dan konsisten.

Dalam beberapa tahun terakhir, perkembangan kecerdasan *Artificial Intelligence* dan pembelajaran mesin (*Machine Learning*) sudah membuka banyak peluang dalam sektor pertanian presisi, salah satunya melalui pengenalan citra berbasis *Deep Learning* (**Syarovy, dkk, 2023**). Di antara berbagai algoritma yang ada, *Convolutional Neural Network* (CNN) menjadi pilihan utama dalam tugas klasifikasi dan deteksi objek berbasis gambar karena keunggulannya dalam mengenali pola visual kompleks dan fitur spasial (**Pathak, dkk, 2018**). CNN memakai lapisan konvolusi dan pooling untuk mengekstrak fitur penting dari foto atau gambar (**Adenia, dkk, 2024**), sehingga sangat efektif dalam membedakan citra daun yang sehat dan yang terinfeksi penyakit. Algoritma ini juga terbukti unggul dalam berbagai studi pengolahan citra tanaman seperti padi, tomat, dan kentang, yang menunjukkan akurasi tinggi dan efisiensi dalam klasifikasi penyakit daun (**Pangestu, dkk, 2025**). Dengan demikian, implementasi CNN untuk mendeteksi penyakit daun jagung merupakan pendekatan yang relevan, adaptif, dan potensial untuk meningkatkan produktivitas pertanian berbasis teknologi di Indonesia.

Dari penelitian sebelumnya, yang dilakukan oleh (**Rozaqi, dkk, 2021**) mengklasifikasikan penyakit daun kentang dengan tiga kategori klasifikasi, yaitu daun sehat, *early blight*, dan *late*

blight menggunakan CNN dan menghasilkan akurasi validasi sebesar 94,09%. Pada penelitian (**Sheila, dkk, 2023**) menerapkan arsitektur CNN berbasis Inception V3 untuk mendeteksi tiga macam penyakit yang sering menyerang daun padi yaitu tungro, hawar daun, dan blas mencapai akurasi pengujian sebesar 93,75%. Penelitian (**Putra, dkk, 2023**) mengklasifikasi penyakit daun alpukat (embun jelaga, kuning, cessospora) menerapkan metode CNN untuk deteksi penyakit daun alpukat berbasis aplikasi Android dengan hasil akurasi 94%.

Berdasarkan uraian latar belakang yang telah disampaikan, peneliti menetapkan judul "Identifikasi CNN dalam Deteksi Penyakit Daun Jagung Berbasis Pengenalan Gambar" sebagai representasi dari sinergi antara tantangan nyata di sektor pertanian dengan solusi inovatif yang ditawarkan oleh perkembangan teknologi kecerdasan buatan. Judul ini secara khusus mencerminkan tujuan utama penelitian, dengan menggunakan pendekatan algoritma CNN (*Convolutional Neural Network*) dalam proses identifikasi dan identifikasi kategori penyakit yang menyerang pada daun jagung melalui pemrosesan citra digital. *Convolutional Neural Network* (CNN) adalah proses transformasi data input melalui konvolusi yang diakukan secara berulang dan berurutan pada berbagai skala spasial, contohnya melalui operasi penggabungan (**Kattenborn, dkk, 2021**). *Convolutional Neural Network* (CNN) berfungsi sebagai alat klasifikasi untuk data yang telah memiliki label, memanfaatkan pendekatan *supervised learning* (**Prasiwiningrum & Lubis, 2024**). Pemilihan CNN sebagai inti metode Pemilihan metode ini didasari oleh kemampuannya yang tinggi dalam mendeteksi pola visual yang kompleks, seperti tekstur dan gejala penyakit pada permukaan daun. Teknologi ini diharapkan mampu membentuk sistem pendekripsi yang tidak hanya akurat dalam membedakan jenis penyakit tanaman, tetapi juga cepat dalam proses inferensinya dan praktis untuk diterapkan langsung di lapangan.

Meskipun jagung merupakan komoditas strategis nasional, studi komprehensif yang mengklasifikasikan secara otomatis empat kondisi utama daun jagung (sehat, *common rust*, *gray leaf spot*, dan *leaf blight*) secara simultan dengan penekanan pada efisiensi waktu inferensi masih terbatas. Penelitian ini berupaya mengisi kesenjangan tersebut dengan mengembangkan model CNN yang spesifik untuk mendeteksi keempat kelas penyakit daun jagung tersebut dan menunjukkan bahwa model tidak hanya akurat, tetapi juga memiliki waktu inferensi yang sangat cepat, yaitu 0,48 detik per gambar, menjadikannya layak untuk aplikasi waktu nyata di lapangan.

Dengan adanya sistem deteksi berbasis citra ini, petani dan praktisi pertanian dapat melakukan identifikasi penyakit secara dini tanpa perlu keahlian teknis mendalam di bidang patologi tanaman. Hal ini tentu akan sangat membantu dalam mengambil keputusan cepat terkait langkah pengendalian, sehingga mencegah penyebaran penyakit lebih luas dan meningkatkan efisiensi produksi. Secara keseluruhan, judul ini dipilih karena mampu mewakili integrasi antara kebutuhan di dunia pertanian khususnya dalam aspek pengendalian penyakit tanaman jagung dengan pendekatan pertanian presisi yang berbasis teknologi modern. Penelitian ini diharapkan dapat berkontribusi secara langsung terhadap menjembatani kesenjangan antara praktik pertanian tradisional dan pemanfaatan kecerdasan buatan dalam meningkatkan produktivitas dan ketahanan pangan.

2. METODOLOGI PENELITIAN

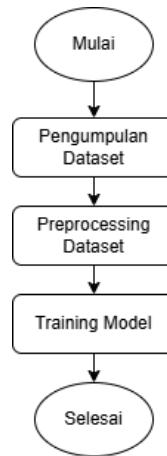
Penelitian ini menerapkan pendekatan metodologis yang sistematis dan terstruktur dengan baik, dimulai dari tahap awal hingga proses akhir pengembangan model. Rangkaian metodologi yang digunakan mencakup beberapa tahapan utama, yaitu pengumpulan dataset, pra-pemrosesan (*preprocessing*) data, pelatihan model (*model training*) menggunakan

algoritma *Convolutional Neural Network* (CNN), hingga evaluasi performa sistem. Setiap langkah dilaksanakan secara berurutan dan saling terkait guna memastikan keakuratan proses analisis serta efektivitas dari sistem klasifikasi yang dibangun.

Pengumpulan dataset citra daun jagung dilakukan dengan mencakup berbagai kondisi kesehatan daun, baik yang terinfeksi penyakit maupun yang sehat. Setelah data terkumpul, dilakukan *preprocessing* seperti normalisasi ukuran gambar, augmentasi data untuk meningkatkan keragaman sampel, serta konversi format agar sesuai dengan arsitektur CNN yang akan digunakan. Selanjutnya, arsitektur CNN mempelajari data hasil preprocessing guna mengenali pola pada citra daun dan menentukan klasifikasinya sesuai kategori penyakit. Proses pelatihan ini mencakup pengaturan parameter seperti jumlah epoch, ukuran batch, dan learning rate, serta penerapan teknik seperti *early stopping* untuk mencegah overfitting.

Arsitektur model *Convolutional Neural Network* (CNN) yang diterapkan dalam penelitian ini menggunakan konfigurasi *Sequential* dengan total 26.081.092 parameter yang semuanya dapat dilatih (*trainable*), dirancang untuk memproses citra daun jagung berukuran 224x224 piksel. Model ini tersusun atas serangkaian blok yang masing-masing terdiri dari lapisan konvolusi (*Conv2D*) dan lapisan pooling (*MaxPooling2D*), dengan jumlah filter yang berjenjang dari 32 di lapisan awal hingga 256 di lapisan akhir, memungkinkan ekstraksi fitur visual yang semakin kompleks. Proses ekstraksi fitur ini dikonsolidasikan oleh lapisan Flatten yang mengubah feature map spasial menjadi vektor 50.176 elemen, siap untuk dimasukkan ke lapisan klasifikasi akhir guna membedakan antara empat kondisi daun jagung.

Secara keseluruhan, pendekatan metodologis ini dirancang agar mampu menghasilkan sistem klasifikasi yang memiliki tingkat akurasi tinggi, serta efisiensi dan kemampuan untuk digunakan dalam lingkungan nyata. Diagram alir yang ditampilkan pada Gambar 1 menggambarkan secara visual keseluruhan proses metodologi yang diimplementasikan dalam penelitian ini, dan menjadi dasar pengembangan sistem deteksi otomatis penyakit pada daun tanaman jagung.



Gambar 1. Flowchart Analysis Data

2.1 Pengumpulan Dataset

Proses yang dilakukan dengan cara memanfaatkan data foto daun jagung yang diperoleh melalui sumber dataset publik (*kaggle*) dan dokumentasi lapangan. Kaggle merupakan sebuah platform komunitas untuk ilmuwan data, Kaggle menyediakan ribuan dataset terbuka dari berbagai disiplin, termasuk pengenalan gambar, prediksi data tabular, dan pemrosesan teks (**Peran, dkk, 2024**). Tahap pengumpulan data dilakukan dengan menghimpun citra daun

jagung yang mengandung beberapa jenis kondisi, yaitu daun sehat, *leaf blight*, *rust*, dan *gray leaf spot* yang terinfeksi penyakit. Data yang dikumpulkan dicantumkan pada Tabel 1.

Tabel 1. Detail Dataset

No	Kategori	Jumlah
1	<i>Common Rust</i>	1306
2	<i>Gray Leaf Spot</i>	574
3	<i>Leaf Blight</i>	1146
4	<i>Healthy</i>	1162
	Total	4188

Rincian data ditampilkan pada Tabel 1, dengan total sebanyak 4.188 citra daun tanaman jagung yang digunakan dalam studi ini. Adapun distribusi data yaitu 1306 citra dengan gejala *common rust*, 574 citra *gray leaf spot*, 1146 citra *leaf blight* dan 1652 citra daun dalam kondisi sehat atau normal. Meskipun data tidak seimbang, bagian ini mengandalkan teknik Augmentasi Citra sebagai mekanisme utama untuk meningkatkan keragaman dan ukuran dataset secara keseluruhan. Augmentasi Citra dapat berfungsi sebagai bentuk penanganan ringan terhadap ketidakseimbangan data, terutama pada kelas minoritas, meskipun tidak secara eksplisit menyeimbangkan jumlah citra. Seluruh gambar yang digunakan diubah ukurannya menjadi 224x224 piksel guna mempercepat proses pemrosesan. Gambar 2 menunjukkan gambar ilustrasi untuk masing-masing kategori yang digunakan dalam penelitian.



Gambar 2. Data Testing

2.2 Preprocessing Dataset

Preprocessing data adalah langkah awal sebelum penggunaan data dalam proses pelatihan dan klasifikasi yang dapat dipahami oleh model (**Maharana, dkk, 2022**). Preprocessing bertujuan untuk mengoptimalkan kualitas data dan masukan, sehingga meningkatkan efektivitas dan kinerja model dalam fase pelatihan (**Syaqialloh, 2025**). Pada persiapan data ini, data yang digunakan terdiri dari 4.188 citra daun tanaman jagung, yang terbagi ke dalam empat kelas, yaitu *leaf blight*, *rust*, *gray leaf spot*, dan daun sehat. Seluruh gambar diubah ukurannya menjadi 224x224 piksel agar sesuai dengan input model, dan dinormalisasi ke dalam rentang nilai [0,1] untuk mempercepat proses pelatihan serta meningkatkan stabilitas model.

```

model = model_1()
model.summary()

...
Model: "sequential"
-----  

Layer (type)      Output Shape       Param #
conv2d (Conv2D)    (None, 224, 224, 32)   896
max_pooling2d (MaxPooling2D) (None, 112, 112, 32)   0
conv2d_1 (Conv2D)    (None, 112, 112, 64)   18496
max_pooling2d_1 (MaxPooling2D) (None, 56, 56, 64)   0
conv2d_2 (Conv2D)    (None, 56, 56, 128)   73856
max_pooling2d_2 (MaxPooling2D) (None, 28, 28, 128)   0
conv2d_3 (Conv2D)    (None, 28, 28, 256)   295168
max_pooling2d_3 (MaxPooling2D) (None, 14, 14, 256)   0
flatten (Flatten)   (None, 50176)        0
...
Total params: 26,081,092
Trainable params: 26,081,092
Non-trainable params: 0

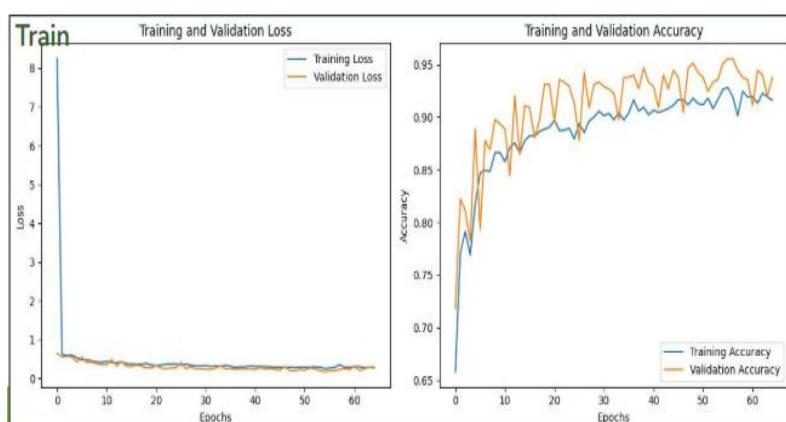
```

Gambar 3. Model CNN

Gambar 3 menunjukkan ringkasan arsitektur model *Convolutional Neural Network* (CNN) yang terdiri dari serangkaian lapisan konvolusi (*Conv2D*) dan pooling (*MaxPooling2D*), dengan jumlah filter yang meningkat secara bertahap dari 32 hingga 256, memungkinkan model untuk mengekstrak fitur visual yang semakin kompleks dari citra input 224x224 piksel. Proses ini menghasilkan fitur map yang kemudian diubah menjadi vektor berdimensi 50.176 melalui lapisan Flatten, yang akan digunakan untuk klasifikasi. Secara keseluruhan, model ini memiliki total 26.081.092 parameter yang semuanya merupakan parameter terlatih (*Trainable params*), menunjukkan kompleksitas model yang signifikan untuk tugas pengenalan pola dalam deteksi penyakit daun jagung.

2.3. Training Model

Proses utama dalam membangun sistem klasifikasi berbasis *Convolutional Neural Network* (CNN) adalah tahap pelatihan model. Pada titik ini, model diuji dengan data gambar daun tanaman jagung yang telah diproses sebelumnya. Pembagian data dilakukan menjadi data pelatihan dan validasi untuk memantau kinerja model selama proses training. Untuk menangani klasifikasi berbagai kelas, pelatihan model dilakukan selama 65 epoch dengan menerapkan fungsi aktivasi ReLU pada setiap lapisan konvolusi dan fungsi softmax pada lapisan output. Proses optimasi model dilakukan menggunakan algoritma yang disesuaikan, yaitu Adam. Jumlah batch yang digunakan selama pelatihan disesuaikan untuk menyeimbangkan kinerja komputasi dan efisiensi.

**Gambar 4. Grafik Loss dan Accuracy**

Pada Gambar 4 Grafik kurva *loss* terlihat bahwa nilai *training loss* dan *validation loss* menurun secara signifikan dan stabil mendekati nol setelah beberapa *epoch* pertama. Hal ini bukti bahwa model mempelajari fitur data dengan baik tanpa mengalami *overfitting*. Grafik *Accuracy* pelatihan dan validasi menunjukkan hasil yang terus meningkat hingga mencapai nilai di atas 93,7%. Kurva akurasi antara data pelatihan dan validasi tampaknya cukup konsisten dan tidak terlalu jauh, menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya.

3. HASIL DAN PEMBAHASAN

Hasil eksekusi training model menunjukkan pola kurva pembelajaran yang konsisten dan stabil, efektif, dan terkontrol dengan baik, yang tercermin dari penerapan strategi pelatihan yang cermat dan terintegrasi. Model dilatih hingga mencapai epoch ke-65 dari total target 100 epoch. Namun, proses pelatihan dihentikan secara otomatis oleh mekanisme early stopping (penundaan dini). Mekanisme ini memiliki peran krusial karena secara aktif memantau performa model pada data validasi yakni data yang tidak termasuk dalam data pelatihan utama untuk mendeteksi momen ketika peningkatan kinerja mulai melambat atau berhenti sama sekali.

Dalam eksperimen ini, akurasi validasi (*val_accuracy*) sempat mencapai nilai puncaknya sebesar 95,556%. Namun, setelah titik tersebut, tidak ada peningkatan lebih lanjut yang signifikan. Ini merupakan indikator bahwa model telah mencapai performa optimalnya pada data validasi, dan pelatihan tambahan hanya akan meningkatkan risiko *overfitting* yang terjadi saat model mempelajari data latih secara berlebihan, sehingga performanya menurun saat diuji dengan data baru seperti yang ditampilkan pada Gambar 5 dibawah ini.

Untuk mencegah hal tersebut, sistem secara otomatis menghentikan pelatihan dan memulihkan bobot terbaik dari epoch sebelumnya, yaitu epoch ke-55. Pemulihan bobot ini dinyatakan dalam log pelatihan dengan pesan, "*Restoring model weights from the end of the best epoch: 55*", yang menunjukkan bahwa model yang digunakan untuk pengujian akhir adalah versi paling optimal berdasarkan kinerja validasinya.

Pada akhir pelatihan (epoch ke-65), model mencatat nilai kehilangan (*loss*) sebesar 0,2889 dan memperoleh akurasi hingga 91,60% pada data pelatihan. Sementara itu, pada data validasi, model mencatat *val_loss* sebesar 0,2629 dan *val_accuracy* sebesar 95,556%. Selisih antara performa baik pada data training maupun data validasi ini menunjukkan bahwa model mampu memahami pola secara menyeluruh dari data pelatihan, sekaligus mempertahankan akurasi tinggi dan kemampuan generalisasi saat diuji dengan data uji yang belum pernah dipelajari oleh model.

```

Epoch 1/100
149/149 [=====] - ETA: 0s - loss: 8.2456 - accuracy: 0.6582
Epoch 1: val_accuracy improved from -inf to 0.71778, saving model to model/best_model.keras
149/149 [=====] - 95s 578ms/step - loss: 8.2456 - accuracy: 0.6582 - val_loss: 0.6444 - val_accuracy: 0.7178
Epoch 2/100
149/149 [=====] - ETA: 0s - loss: 0.6274 - accuracy: 0.7709
Epoch 2: val_accuracy improved from 0.71778 to 0.82222, saving model to model/best_model.keras
149/149 [=====] - 34s 231ms/step - loss: 0.6274 - accuracy: 0.7709 - val_loss: 0.5544 - val_accuracy: 0.8222
Epoch 3/100
149/149 [=====] - ETA: 0s - loss: 0.5829 - accuracy: 0.7914
Epoch 3: val_accuracy did not improve from 0.82222
149/149 [=====] - 71s 474ms/step - loss: 0.5829 - accuracy: 0.7914 - val_loss: 0.5593 - val_accuracy: 0.8111
Epoch 4/100
149/149 [=====] - ETA: 0s - loss: 0.6008 - accuracy: 0.7690
Epoch 4: val_accuracy did not improve from 0.82222
149/149 [=====] - 31s 297ms/step - loss: 0.6008 - accuracy: 0.7690 - val_loss: 0.5511 - val_accuracy: 0.7822
Epoch 5/100
149/149 [=====] - ETA: 0s - loss: 0.5272 - accuracy: 0.8169
Epoch 5: val_accuracy improved from 0.82222 to 0.88889, saving model to model/best_model.keras
149/149 [=====] - 32s 214ms/step - loss: 0.5272 - accuracy: 0.8169 - val_loss: 0.4205 - val_accuracy: 0.8889
Epoch 6/100
149/149 [=====] - ETA: 0s - loss: 0.4756 - accuracy: 0.8470
Epoch 6: val_accuracy did not improve from 0.88889
149/149 [=====] - 31s 210ms/step - loss: 0.4756 - accuracy: 0.8470 - val_loss: 0.5469 - val_accuracy: 0.7933
Epoch 7/100
...
Epoch 65: val_accuracy did not improve from 0.95556
Restoring model weights from the end of the best epoch: 55.
149/149 [=====] - 29s 194ms/step - loss: 0.2889 - accuracy: 0.9168 - val_loss: 0.2629 - val_accuracy: 0.9378
Epoch 65: early stopping

```

Gambar 5. Hasil Training Dataset

Perolehan ini memperkuat temuan bahwa model tidak hanya unggul dari sisi pelatihan, tetapi juga siap untuk diterapkan dalam skenario dunia nyata. Visualisasi hasil deteksi model yang ditampilkan pada Gambar 6 memperlihatkan bagaimana model mampu membedakan kondisi daun tanaman jagung dengan tepat, mengindikasikan efektivitas arsitektur CNN yang diterapkan dalam studi ini.



Gambar 6. Hasil Deteksi Model

Pada Gambar 6, model menunjukkan kemampuannya dalam mendeteksi penyakit daun jagung, di mana beberapa contoh "*Common Rust*" dan "*Gray Leaf Spot*" berhasil diidentifikasi dengan benar. Namun, terdapat juga kasus false positive yang signifikan, seperti daun jagung yang tampak sehat atau memiliki ciri penyakit yang berbeda, justru diklasifikasikan sebagai "*Common Rust*", menunjukkan bahwa model masih perlu ditingkatkan dalam membedakan kondisi sehat dari penyakit atau dalam mengklasifikasikan penyakit yang memiliki kemiripan visual. Pengujian model dilakukan sebanyak 5 kali dengan menggunakan 16 sample yang ditunjukkan pada Tabel 2.

Tabel 2. Hasil Pengujian

No.	Pengujian Ke-	Hasil Pengujian	
		True	False
1	Pengujian Ke-1	15	1
2	Pengujian Ke-2	14	2
3	Pengujian Ke-3	16	0
4	Pengujian Ke-4	16	0
5	Pengujian Ke-5	15	1

Nilai akurasi diperoleh melalui pengujian data uji menggunakan Persamaan (1) dan (2) seperti dibawah ini.

$$\text{Akurasi} = \frac{\text{jumlah data testing yang benar}}{\text{jumlah keseluruhan data testing}} \times 100\% \quad (1)$$

$$\text{Akurasi} = \frac{76}{80} \times 100\% = 95\% \quad (2)$$

4. KESIMPULAN

Penelitian ini berhasil menerapkan algoritma *Convolutional Neural Network* (CNN) untuk mengidentifikasi secara otomatis empat kondisi daun jagung: *common rust*, *gray leaf spot*, *leaf blight*, dan sehat, melalui pemrosesan citra digital. Model CNN yang dirancang membuktikan efektivitas dan efisiensinya, mencapai akurasi klasifikasi tinggi sebesar 95% pada data pengujian. Keunggulan sistem ini diperkuat oleh kecepatan pemrosesan yang sangat baik, dengan rata-rata waktu inferensi hanya 0,48 detik per gambar. Hasil temuan ini secara signifikan menunjukkan bahwa teknologi berbasis kecerdasan buatan, khususnya CNN, dapat memberikan kontribusi nyata terhadap pertanian presisi dengan mendukung deteksi dini, cepat, dan objektif untuk mencegah kerugian hasil panen jagung di lapangan. Berdasarkan temuan dan keterbatasan yang ada, disarankan untuk melakukan penelitian lanjutan dengan fokus pada penanganan ketidakseimbangan dataset secara lebih eksplisit, seperti menerapkan teknik oversampling atau penyesuaian bobot kelas, guna meningkatkan akurasi model pada kelas minoritas. Selain itu, pengembangan model dapat diperluas dengan mengintegrasikan sistem deteksi ini ke dalam aplikasi mobile yang memungkinkan pengujian langsung di lapangan menggunakan kamera perangkat. Dianjurkan pula untuk menguji model menggunakan dataset yang dikumpulkan dari berbagai kondisi lingkungan, pencahayaan, dan varietas jagung yang berbeda, untuk memvalidasi dan meningkatkan kemampuan generalisasi model dalam skenario dunia nyata yang lebih bervariasi.

DAFTAR RUJUKAN

- Adenia, R., Minarno, A. E., & Azhar, Y. (2024). Implementasi Convolutional Neural Network Untuk Ekstraksi Fitur Citra Daun Dalam Kasus Deteksi Penyakit Pada Tanaman Mangga Menggunakan Random Forest. *Jurnal Repotor*, 4(4), 473–482. <https://doi.org/10.22219/repositor.v4i4.32287>
- Albana, H., Resti, Z., Tanaman, D. P., Pertanian, F., & Andalas, U. (2024). Tingkat Serangan Penyakit Karat Daun Pada. 23(2), 305–312.
- Bantacut, T., Akbar, M. T., & Firdaus, Y. R. (2015). Pengembangan Jagung untuk Ketahanan Pangan, Industri dan Ekonomi. *Jurnal Pangan*, 24(2), 135–148.
- Hamidson, H., Suwandi, S., & Effendy, T. A. (2019). north Indralaya Sub-District Ogan Ilir District. *Prosiding Seminar Nasional Lahan Suboptimal*, September, 528–534.
- Kattenborn, T., Leitloff, J., Schiefer, F., & Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173(July 2020), 24–49. <https://doi.org/10.1016/j.isprsjprs.2020.12.010>
- Koukouli, P., Georgiou, P., & Karpouzos, D. (2025). Assessment of the Impacts of Climate Change Scenarios on Maize Yield and Irrigation Water Using the CropSyst Model: An Application in Northern Greece. *Agronomy*, 15(3), 1–28. <https://doi.org/10.3390/agronomy15030638>
- Maharana, K., Mondal, S., & Nemade, B. (2022). A review: Data pre-processing and data augmentation techniques. *Global Transitions Proceedings*, 3(1), 91–99.

<https://doi.org/10.1016/j.gltip.2022.04.020>

Nina, A. (2023). Efektifitas Drone Sebagai Media Penginderaan Jauh Untuk Pemantauan Kesehatan Tanaman. *Jurnal Technopreneur (JTech)*, 11(2), 50–55.
<https://doi.org/10.30869/jtech.v11i2.1186>

Pangestu, D. A., Aziz, O. Q., & Crysdiyan, C. (2025). Klasifikasi Penyakit pada Tanaman Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network. *JISKA (Jurnal Informatika Sunan Kalijaga)*, 10(2), 235–248.
<https://doi.org/10.14421/jiska.2025.10.2.235-248>

Pathak, A. R., Pandey, M., & Rautaray, S. (2018). Application of Deep Learning for Object Detection. *Procedia Computer Science*, 132(Iccids), 1706–1717.
<https://doi.org/10.1016/j.procs.2018.05.144>

Peran, M., Kecerdasan, P., Kualitas, B., & Hermawan, G. (2024). *Memahami Peran Dataset dalam Penelitian Kecerdasan Buatan: Kualitas, Aksesibilitas, dan Tantangan*. October.
<https://doi.org/10.13140/RG.2.2.34468.49288>

Prasiwiningrum, E., & Lubis, A. (2024). *Classification Of Palm Oil Maturity Using CNN (Convolution Neural Network) Modelling RestNet 50*. 4(3), 983–999.

Putra, J. V. P., Ayu, F., & Julianto, B. (2023). Implementasi Pendekripsi Penyakit pada Daun Alpukat Menggunakan Metode CNN. *Stains (Seminar Nasional Teknologi & Sains)*, 2(1), 155–162.

Rosadi, M. I., & Lutfi, M. (2021). Identifikasi Jenis Penyakit Daun Jagung Menggunakan Deep Learning Pre-Trained Model. *Jurnal Explore IT!*, 13(2), 36–42.

Rozaqi, A. J., Sunyoto, A., & Arief, M. rudyanto. (2021). Deteksi Penyakit Pada Daun Kentang Menggunakan Pengolahan Citra dengan Metode Convolutional Neural Network. *Creative Information Technology Journal*, 8(1), 22. <https://doi.org/10.24076/citec.2021v8i1.263>

Setyawan, I., Wahyono, T., & Lubis, Y. (2010). Peranan Komoditas Jagung (Zea mays L .) Terhadap Peningkatan Pendapatan Wilayah Kabupaten Karo. *Jurnal Agribisnis Sumatera Utara*, 3(2), 17–24.

Setyawan, M. A., Kasih, P., Ayu, M., & Widyadara, D. (2022). Klasifikasi Penyakit Daun Jagung Berdasarkan Ruang Warna HSV dan Fitur Tekstur Dengan Algoritma K-NN. *Seminar Nasional Inovasi Teknologi UN PGRI Kediri*, 67–72.

Sheila, S., Permata Sari, I., Bagas Saputra, A., Kharil Anwar, M., & Restu Pujiyanto, F. (2023). Deteksi Penyakit Pada Daun Padi Berbasis Pengolahan Citra Menggunakan Metode Convolutional Neural Network (CNN). *Multinetics*, 9(1), 27–34.
<https://doi.org/10.32722/multinetics.v9i1.5255>

Syaqialloh, F. (2025). *Klasifikasi dan Pengenalan Emosi dari Ekspresi Wajah Menggunakan CNN-BiLSTM dengan Teknik Data Augmentation*. 5(1), 79–91.

Syarovy, M., Nugroho, A. P., & Sutiarso, L. (2023). Pemanfaatan Model Neural Network Dalam Generasi Baru Pertanian Presisi Di Perkebunan Kelapa Sawit. *WARTA Pusat Penelitian Kelapa Sawit*, 28(1), 39–54. <https://doi.org/10.22302/iopri.war.warta.v28i1.97>