

KLASIFIKASI PENYAKIT TANAMAN JAGUNG DENGAN KECERDASAN BUATAN BERBASIS CNN

Muhammad Yusuf¹, Khoirunnisa², Dicky Kurniawan³, Tinuk Agustin⁴

¹²³⁴STMIK Amikom Surakarta

¹²³⁴Sukoharjo, Indonesia

Email: ¹Muhammad.10468@mhs.amikomsolo.ac.id

²Khoirunnisa.10500@mhs.amikomsolo.ac.id, ³Dicky.10470@mhs.amikomsolo.ac.id,

⁴agustin.amikom@gmail.com

Abstract

Early detection of diseases in corn plants is crucial to improving crop yields and ensuring the sustainability of agriculture. Corn diseases can reduce productivity, making quick and accurate detection essential. This study develops a corn disease classification system using Convolutional Neural Network (CNN) with the Corn Leaf Infection dataset from Kaggle by Ramkrishna Acharya. The dataset consists of 341 images classified into two categories: healthy leaves and infected leaves. This research compares two CNN models: a simple CNN model and a modified VGG-16 model with additional convolutional layers to improve accuracy and handle more complex datasets. In previous research, AlexNet achieved an accuracy of 88.7%, but it was considered less effective due to being designed for large and complex datasets. The results show that the simple CNN model achieved an accuracy of 94.2%, while the modified VGG-16 model reached a higher accuracy of 97.10%. The developed system provides an automated solution for farmers to detect corn diseases quickly and accurately, enabling earlier preventive measures. As a result, this technology can enhance agricultural efficiency and improve crop yields.

Keywords: CNN, Corn Disease Detection, Simple CNN, VGG-16 model

Abstraksi

Deteksi dini penyakit pada tanaman jagung penting untuk meningkatkan hasil panen dan menjaga keberlanjutan pertanian. Penyakit pada jagung dapat menurunkan produktivitas, sehingga deteksi cepat dan akurat sangat dibutuhkan. Penelitian ini mengembangkan sistem klasifikasi penyakit jagung menggunakan Convolutional Neural Network (CNN) dengan dataset Corn Leaf Infection dari Kaggle oleh Ramkrishna Acharya. Dataset ini terdiri dari 341 gambar yang diklasifikasikan menjadi dua kelas: daun sehat dan daun terinfeksi. Penelitian ini membandingkan dua model CNN, yaitu model CNN sederhana dan model VGG-16 yang dimodifikasi dengan tambahan lapisan konvolusi untuk meningkatkan akurasi dan kemampuan menangani dataset yang lebih kompleks. Pada penelitian sebelumnya, AlexNet mencapai akurasi 88,7%, namun dianggap kurang efektif karena dirancang untuk dataset besar dan kompleks. Hasil penelitian menunjukkan bahwa model CNN sederhana mencapai akurasi 94,2%, sementara model VGG-16 memperoleh akurasi yang lebih tinggi, yaitu 97,10%. Sistem yang dikembangkan ini memberikan solusi otomatis bagi petani untuk mendeteksi penyakit jagung secara cepat dan akurat, memungkinkan tindakan pencegahan yang lebih dini. Dengan demikian, teknologi ini dapat meningkatkan efisiensi pertanian dan hasil panen.

Kata Kunci: CNN, CNN Sederhana, Deteksi Penyakit Jagung, Model VGG-16

1. PENDAHULUAN

Saat ini, proses identifikasi penyakit tanaman masih banyak dilakukan secara manual di lapangan. Namun, metode manual ini memiliki beberapa keterbatasan, terutama pada skala lahan pertanian yang luas[1]. Proses identifikasi manual memerlukan waktu yang lama, tenaga ahli yang berkompeten, dan keterampilan khusus. Selain itu, tingkat kesalahan dalam identifikasi manual cenderung tinggi, terutama jika dilakukan oleh tenaga yang tidak terlatih dengan baik[2]. Akibatnya, metode manual tidak efisien dan membutuhkan sumber daya yang besar, yang sulit diakses oleh banyak petani kecil. Deteksi dini terhadap penyakit tanaman jagung menjadi langkah krusial untuk mengurangi kerusakan yang lebih besar dan mencegah penyebaran penyakit ke area yang lebih luas. Jagung merupakan salah satu komoditas penting yang berkontribusi besar terhadap ketahanan pangan nasional dan industri pangan, serta sebagai pakan utama bagi ternak [3]. Tanaman jagung rentan terhadap berbagai penyakit yang dapat menurunkan produktivitasnya, seperti bercak daun, busuk akar, dan infeksi jamur[4]. Penyakit-penyakit ini, jika tidak segera terdeteksi dan diatasi, dapat mengakibatkan kerugian besar bagi petani. Kerugian tersebut tidak hanya mempengaruhi kualitas dan kuantitas hasil pertanian, tetapi juga berdampak pada pasokan pangan nasional [5].

Salah satu metode AI yang terbukti efektif dalam pengolahan gambar adalah Convolutional Neural Network (CNN) [6]. CNN adalah jenis jaringan saraf tiruan yang sangat cocok untuk mengidentifikasi pola visual dalam gambar. Teknologi ini memungkinkan komputer untuk belajar dari data visual dan mengenali perbedaan pola, seperti tekstur, warna, dan bentuk [7]. Dalam konteks deteksi penyakit tanaman jagung, CNN dapat digunakan untuk mengenali tanda-tanda penyakit pada daun jagung berdasarkan ciri-ciri visual yang terlihat pada gambar daun tersebut [8].

Pemilihan CNN karena kemampuannya untuk melakukan ekstraksi fitur secara otomatis, tanpa memerlukan campur tangan manusia dalam proses identifikasi pola [9]. CNN bekerja dengan cara "belajar" dari dataset gambar yang sudah diberi label dengan benar, memungkinkan algoritma untuk mengenali pola penyakit pada daun jagung yang berbeda dari daun sehat [10]. CNN terdiri dari beberapa lapisan, seperti Image Input Layer, 2D Convolution Layer, ReLU Layer, Pooling Layer, Fully Connected Layer, Softmax Layer, dan Classification Layer. Efektivitas CNN bergantung pada susunan lapisan tersebut dan parameter di Convolutional Layer [11]. VGG-16 memiliki total 16 layer, terdiri dari 13 convolutional layer dan 3 fully connected layer. Jaringan ini cukup besar, dengan sekitar 138 juta parameter. Struktur VGG-16 diawali oleh convolutional layer, diikuti oleh max pooling, kemudian fully connected layer, dan akhirnya menuju lapisan output. Pada convolutional layer dan fully connected layer, model ini menggunakan fungsi aktivasi ReLU.

Penelitian-penelitian sebelumnya dalam deteksi penyakit tanaman jagung menggunakan CNN telah memberikan kontribusi yang signifikan, terutama dalam mendeteksi berbagai jenis penyakit secara otomatis berdasarkan citra daun [12]. Namun, terdapat beberapa kekurangan yang membuka peluang untuk penelitian lebih lanjut guna

mengoptimalkan hasil dan dampaknya. Beberapa kekurangan tersebut termasuk keterbatasan dataset yang digunakan, ketidakberagaman kondisi lingkungan, kendala efisiensi dan kapasitas komputasi, serta kurangnya validasi pada skala lapangan.

Penelitian ini bertujuan untuk mengembangkan sistem deteksi otomatis penyakit tanaman jagung menggunakan metode CNN. Dataset yang digunakan dalam penelitian ini terdiri dari 341 gambar daun jagung yang diperoleh dari platform Kaggle, yang terbagi menjadi dua kategori: daun sehat dan daun yang terinfeksi penyakit. Dengan dataset ini, model CNN akan dilatih untuk mengenali perbedaan visual antara daun sehat dan daun yang terinfeksi. Dengan menggunakan metode CNN, diharapkan sistem ini dapat memberikan solusi praktis dan efisien bagi petani dalam mendeteksi penyakit tanaman jagung. Keberhasilan implementasi teknologi ini diharapkan memberikan dampak positif yang signifikan bagi sektor pertanian [13]. Tingkat akurasi yang tinggi dari model CNN juga dapat mengurangi risiko kesalahan deteksi, sehingga penyakit dapat diatasi sebelum menyebabkan kerugian besar.

Sistem deteksi otomatis ini mendukung peningkatan produktivitas pertanian. Dengan deteksi dini yang akurat, petani dapat segera mengambil tindakan pencegahan atau pengobatan, yang pada akhirnya dapat meningkatkan hasil panen dan kualitas jagung [14]. Pemanfaatan teknologi CNN dalam deteksi penyakit tanaman jagung memiliki potensi besar untuk mengatasi tantangan yang dihadapi sektor pertanian. Pengembangan sistem deteksi penyakit berbasis AI ini dapat menjadi solusi yang efektif, efisien, dan mudah diakses bagi petani, khususnya dalam menghadapi ancaman penyakit tanaman yang berpotensi merugikan [15].

2. TINJAUAN PUSTAKA

Penelitian pertama mengembangkan model CNN untuk mengklasifikasikan penyakit pada tanaman jagung, dengan fokus pada empat jenis penyakit utama, yaitu *Helminthosporium leaf spot*, *Rust*, *Common rust*, dan *Corn smut*. Dataset yang digunakan terdiri dari 5.000 gambar daun jagung dengan resolusi tinggi, yang dilabeli berdasarkan jenis penyakitnya. Model CNN yang dikembangkan mencapai akurasi 92%, dengan penerapan teknik augmentasi gambar (rotasi, flipping, dan zooming) untuk meningkatkan keberagaman dataset dan mengurangi overfitting. Namun, penelitian ini terbatas pada jumlah kelas penyakit yang sedikit, sehingga tidak sepenuhnya menggambarkan kompleksitas masalah penyakit tanaman jagung di lapangan. Penelitian ini memberikan dasar yang kuat untuk klasifikasi penyakit jagung menggunakan CNN, namun perlu diperluas untuk mengidentifikasi lebih banyak jenis penyakit dengan variasi kondisi [16].

Penelitian kedua mengembangkan sistem klasifikasi penyakit tanaman menggunakan dataset gambar daun dari berbagai tanaman, termasuk jagung, tomat, dan kentang. Penelitian ini menggunakan *PlantVillage dataset*, yang mencakup 54.000 gambar daun dari 14 spesies tanaman dengan berbagai penyakit. Dataset untuk jagung mencakup lebih dari 3.000 gambar yang meliputi berbagai jenis penyakit. Model CNN yang dikembangkan menghasilkan akurasi tinggi sekitar 96.5% untuk klasifikasi penyakit

tanaman secara umum. Meskipun penelitian ini menunjukkan kemajuan signifikan dalam hal akurasi klasifikasi, masalah kualitas gambar yang rendah dan kabur pada beberapa gambar mengurangi akurasi model dalam kondisi dunia nyata. Penelitian ini memberikan kontribusi besar terhadap pengembangan model CNN yang lebih akurat, tetapi evaluasi lebih lanjut diperlukan untuk menguji robustitas model dalam kondisi lapangan dengan gambar berkualitas rendah [17].

Penelitian ketiga menggabungkan teknik *transfer learning* untuk meningkatkan akurasi deteksi penyakit pada tanaman jagung, dengan menggunakan model pretrained seperti ResNet-50. Dataset yang digunakan berjumlah sekitar 4.000 gambar daun jagung yang meliputi penyakit seperti *Pseudocercospora leaf spot* dan *Corn rust*. Hasil penelitian menunjukkan bahwa model CNN yang menggunakan transfer learning mencapai akurasi 94%, yang jauh lebih tinggi dibandingkan model CNN tanpa pretrained models. Teknik transfer learning membantu mengurangi kebutuhan dataset besar dan mempercepat pelatihan model. Namun, ketergantungan pada kualitas pretrained model dan adaptasi untuk kondisi tanaman lokal yang spesifik menjadi tantangan utama dalam implementasinya di lapangan. Meskipun transfer learning menawarkan peningkatan kinerja pada dataset terbatas, penyesuaian lebih lanjut diperlukan agar model lebih efektif dalam kondisi nyata di lapangan[18].

Penelitian keempat menggunakan augmentasi gambar untuk meningkatkan akurasi deteksi penyakit pada tanaman jagung, seperti *Southern rust* dan *Northern leaf blight*. Dataset yang digunakan terdiri dari 6.000 gambar dengan ukuran 256x256 piksel, yang mencakup dua jenis penyakit utama pada jagung. Teknik augmentasi seperti rotasi, flipping, dan zooming diterapkan untuk memperkaya dataset dan meningkatkan keberagaman data. Model CNN yang dilatih dengan augmentasi data menghasilkan akurasi 90% pada dataset pengujian. Augmentasi data terbukti efektif dalam meningkatkan kinerja model, terutama ketika dataset terbatas. Meskipun demikian, penggunaan augmentasi tanpa teknik regularisasi yang tepat dapat menyebabkan overfitting pada model. Penelitian ini menunjukkan bahwa augmentasi gambar bisa menjadi solusi praktis untuk mengatasi keterbatasan dataset, tetapi perlu pengawasan ekstra untuk mencegah overfitting[19].

Penelitian kelima mengembangkan model CNN dengan efisiensi komputasi tinggi untuk deteksi penyakit tanaman jagung, mengingat keterbatasan perangkat keras di lapangan. Dataset yang digunakan terdiri dari 7.000 gambar daun jagung dengan lima jenis penyakit, termasuk *Common rust*, *Anthracnose*, dan *Gray leaf spot*. Model CNN yang dikembangkan menggunakan arsitektur yang lebih ringan seperti *MobileNet*, yang memungkinkan inferensi cepat meskipun di perangkat dengan kapasitas komputasi rendah. Model ini menghasilkan akurasi sekitar 89% dengan waktu inferensi yang sangat cepat, sehingga cocok untuk digunakan pada perangkat mobile atau perangkat IoT di lapangan. Namun, meskipun efisien dalam hal komputasi, model ini menunjukkan kompromi dalam hal akurasi dibandingkan dengan arsitektur CNN yang lebih besar.

Pengembangan lebih lanjut diperlukan untuk meningkatkan akurasi pada kondisi lapangan yang lebih variatif[20].

Penelitian sebelumnya terkait deteksi penyakit pada tanaman jagung menggunakan CNN telah memberikan kontribusi signifikan dalam hal akurasi deteksi. Namun, masih ada beberapa tantangan yang perlu diatasi, seperti keterbatasan jumlah kelas penyakit, kualitas gambar yang rendah, dan keterbatasan dataset. Beberapa pendekatan yang digunakan, seperti augmentasi gambar, transfer learning, dan penggunaan arsitektur ringan, telah terbukti efektif dalam meningkatkan akurasi dan efisiensi model, meskipun dengan beberapa keterbatasan. Penelitian ini berfokus pada mengembangkan model CNN dengan dataset yang lebih variatif dan menerapkan teknik augmentasi untuk mengatasi masalah tersebut. Penggunaan model VGG-16 sudah dilatih sebelumnya (pre-trained) menggunakan dataset ImageNet, sehingga memiliki kemampuan mengenali pola umum pada gambar. Model VGG-16 dapat mempercepat pelatihan dan meningkatkan akurasi, karena model sudah mempelajari fitur umum dari data gambar sebelumnya. Dengan memperhatikan kekurangan dari penelitian sebelumnya, penelitian ini bertujuan untuk memperluas cakupan klasifikasi penyakit jagung dengan menambahkan lebih banyak jenis penyakit dan meningkatkan kualitas model agar lebih robust dalam kondisi lapangan yang sebenarnya.

3. METODE PENELITIAN

Alur penelitian dapat dilihat pada Gambar 1.



Gambar 1. Flowchart Alur Metode Penelitian

3.1. Pengumpulan Data

Pada tahap pengumpulan data, peneliti mengumpulkan dataset yaitu *Corn Leaf Infection Dataset* yang berasal dari website kaggle <https://www.kaggle.com/dsv/1567356> oleh Ramkrishna Acharya tahun 2020. Dataset berisi 1.000 gambar daun jagung sehat dan 1.000 gambar daun jagung terinfeksi. Namun, dataset yang diambil terdapat 341 gambar terdiri dari 2 kelas yaitu 141 gambar daun jagung sehat dan 200 gambar daun jagung terinfeksi. Dataset ini dipilih karena dirancang untuk mengidentifikasi penyakit pada tanaman jagung, sesuai dengan tujuan penelitian. Sample daun jagung yang sehat dan terinfeksi dapat dilihat pada gambar 2.



Gambar 2. Sample daun jagung sehat dan daun jagung terinfeksi

Penjelasan :

Berdasarkan Gambar 2 diatas, Daun jagung yang sehat memiliki tekstur yang halus, tidak ada bercak atau noda yang tidak normal, dan tidak ada perubahan bentuk pada daun. Daun yang terinfeksi sering menunjukkan tekstur yang lebih kasar, dengan bercak-bercak atau pengeringan yang terlihat jelas dapat menyebabkan area daun menjadi kering atau terkulai.

3.2. Pre-processing Data

Tahap pre-processing bertujuan untuk memastikan kualitas data yang optimal sebelum digunakan dalam pelatihan model. Dataset berupa 341 gambar yang terdiri dari 2 kelas dilakukan resize menjadi 255 x 255 untuk menjaga konsistensi ukuran input dan mengurangi beban komputasi. Gambar diubah menjadi array numerik yang dapat diproses oleh model. Data dibagi 80% untuk *training* dan 20% untuk *testing* menggunakan `train_test_split`. Normalisasi gambar dengan membagi nilai piksel gambar distandarisasi dengan rentang 0-1 untuk membantu model memproses informasi lebih baik dan mempercepat konvergensi saat pelatihan. Model CNN sederhana dipilih karena mudah diimplementasikan dan memiliki kemampuan dasar untuk mengekstraksi fitur visual dari gambar. Model ini ditambahkan teknik augmentasi dan early stopping untuk mencegah overfitting. Model VGG-16 dipilih karena sudah dilatih sebelumnya (pre-trained) menggunakan dataset ImageNet, sehingga memiliki kemampuan mengenali pola umum pada gambar. Model VGG-16 dapat mempercepat pelatihan dan meningkatkan akurasi, karena model sudah mempelajari fitur umum dari data gambar sebelumnya. Penggunaan augmentasi yang dilakukan tersaji pada Tabel 1.

Augmentation	Value
Rotation_range	25

Width_shift_range	0.2
Height_shift_range	0.2
Shear_range	0.2
Zoom_range	0.2
Horizontal_flip	True
Fill_mode	Nearest

Tabel 1. Penggunaan Augmentasi

Penjelasan : Teknik augmentation dapat meningkatkan jumlah data pelatihan dengan memanipulasi gambar yang ada, seperti rotasi, pemotongan, flipping, atau perubahan pencahayaan. Ini membantu model untuk mencegah overfitting dan generalizable, sehingga dapat mengenali penyakit pada daun jagung meskipun ada variasi dalam kondisi pencahayaan atau sudut pengambilan gambar.

3.3. Arsitektur CNN

Arsitektur CNN terdiri dari lapisan konvolusi untuk mengekstraksi fitur gambar, lapisan pooling untuk mengurangi dimensi, dan lapisan fully connected untuk klasifikasi. Lapisan aktivasi (seperti ReLU) memperkenalkan non-linearitas, dan lapisan output menghasilkan prediksi menggunakan fungsi softmax atau sigmoid. CNN efektif untuk pengenalan gambar dan klasifikasi. Arsitektur model CNN sederhana tersaji pada Tabel 2.

Tabel 2. Arsitektur Model CNN Sederhana

Layer (Type)	Output shape	Param #
Conv2d_1 (Conv2D)	(None, 73, 73, 32)	896
Max_pooling2d_1 (MaxPooling2D)	(None, 36, 36, 32)	0
Conv2d_2 (Conv2D)	(None, 34, 34, 64)	18,496
Max_pooling2d_2 (MaxPooling2D)	(None, 17, 17, 64)	0
Conv2d_3 (Conv2D)	(None, 9, 9, 128)	663,680
Max_pooling2d_3 (MaxPooling2D)	(None, 4, 4, 128)	0
flatten (Flatten)	(None, 2048)	0
dense (Dense)	(None, 128)	262,272
Dropout	(None, 128)	0
dense_1 (Dense)	(None, 2)	258

Penjelasan : Penelitian ini menggunakan model CNN sequential dengan tiga lapisan konvolusi (32, 64, dan 128 filter) yang diikuti lapisan pooling untuk mengurangi dimensi data. Data kemudian diubah menjadi bentuk 1D dan diteruskan ke lapisan fully connected dengan 128 neuron, dilengkapi dengan dropout untuk menghindari overfitting. Fungsi aktivasi softmax digunakan untuk menghasilkan probabilitas setiap kelas, sementara model dikompilasi dengan optimizer Adam, learning rate 0.001, dan fungsi loss categorical_crossentropy untuk klasifikasi multi-kelas. Lapisan fully connected terakhir memiliki 2 neuron untuk klasifikasi antara dua kelas: "sehat" dan "terinfeksi".

Arsitektur CNN Model VGG-16 tersaji pada Tabel 3.

Tabel 3. Arsitektur CNN Model VGG16

Layer (Type)	Output shape	Param #
input_layer_4 (InputLayer)	(None, 75, 75, 3)	0
block1_conv1 (Conv2D)	(None, 75, 75, 64)	1,792
block1_conv2 (Conv2D)	(None, 75, 75, 64)	36,928
block1_pool (MaxPooling2D)	(None, 37, 37, 64)	0
block2_conv1 (Conv2D)	(None, 37, 37, 128)	73,856
block2_conv2 (Conv2D)	(None, 37, 37, 128)	147,584
block2_pool (MaxPooling2D)	(None, 18, 18, 128)	0
block3_conv1 (Conv2D)	(None, 18, 18, 256)	295,168
block3_conv2 (Conv2D)	(None, 18, 18, 256)	590,080
block3_conv3 (Conv2D)	(None, 18, 18, 256)	590,080
block3_pool (MaxPooling2D)	(None, 9, 9, 256)	0
block4_conv1 (Conv2D)	(None, 9, 9, 512)	1,180,160
block4_conv2 (Conv2D)	(None, 9, 9, 512)	2,359,808
block4_conv3 (Conv2D)	(None, 9, 9, 512)	2,359,808
block4_pool (MaxPooling2D)	(None, 4, 4, 512)	0
block5_conv1 (Conv2D)	(None, 4, 4, 512)	2,359,808
block5_conv2 (Conv2D)	(None, 4, 4, 512)	2,359,808
block5_conv3 (Conv2D)	(None, 4, 4, 512)	2,359,808
block5_pool (MaxPooling2D)	(None, 2, 2, 512)	0
flatten_4 (Flatten)	(None, 2048)	0
dense_8 (Dense)	(None, 128)	262,272
dropout_4 (Dropout)	(None, 128)	0
dense_9 (Dense)	(None, 2)	258

Penjelasan : Penelitian ini menggunakan model functional dengan arsitektur CNN berbasis VGG16 untuk klasifikasi citra. Model menerima input gambar berukuran 75x75 piksel dengan 3 saluran warna (RGB) dan terdiri dari lima blok konvolusi (Conv2D) yang dilengkapi dengan lapisan pooling (MaxPooling2D) untuk ekstraksi fitur. Jumlah filter meningkat dari 64 di blok pertama menjadi 512 di blok kelima. Setelah ekstraksi fitur, data diratakan menggunakan lapisan "flatten", diikuti oleh dua lapisan dense (128 neuron) dan satu lapisan dropout untuk mengurangi overfitting. Lapisan output terdiri dari dua neuron untuk klasifikasi dua kelas dengan aktivasi softmax. Model dikompilasi dengan optimizer Adam, learning rate 0.001, dan fungsi loss categorical_crossentropy. Bobot VGG16 yang telah dilatih pada dataset ImageNet dibekukan, dan lapisan tambahan ditambahkan untuk menyesuaikan dengan tugas klasifikasi baru.

4. HASIL DAN PEMBAHASAN

Model klasifikasi penyakit pada tanaman jagung berbasis Convolutional Neural Network (CNN) yang dapat mendeteksi dan mengklasifikasikan kondisi daun tanaman jagung (sehat atau terinfeksi) secara akurat.

4.1. Training dan Testing Data

Dataset yang sudah ditentukan yaitu 80% untuk *training* dan 20% untuk *testing*. Peneliti menggunakan 2 model yaitu model CNN sederhana dan model VGG16. Setelah dilakukan pengujian, teknik VGG16 memperoleh akurasi tertinggi yaitu 97,10% dan loss terendah sebesar 7,5% dan teknik CNN Sederhana yaitu akurasi sebesar 94,20% dan loss 18,24%. Hasil pengujian tidak mengalami overfitting karena menggunakan regularisasi (L1 atau L2), menggunakan teknik dropout pada neural network, menambah data augmentasi, dan mengurangi kompleksitas model. Hasil akurasi training dan testing data tersaji pada tabel 4.


Tabel 4. Hasil akurasi *training* dan *testing* data

Teknik Regulasi	Accuracy	Loss	Val_Accuracy	Val_Loss
Baseline+Augmentasi	0.8951	0.2129	0.9420	0.1824
VGG16+Augmentasi	0.9304	0.1636	0.9710	0.0755

Penjelasan : Tabel di atas menunjukkan bahwa model VGG-16 memiliki performa lebih baik dibandingkan dengan model CNN sederhana. Dengan regularisasi dan augmentasi data, VGG-16 menghasilkan loss yang lebih rendah (0.0755) dan akurasi yang lebih tinggi (97.10%). Hal ini menunjukkan bahwa arsitektur yang lebih kompleks seperti VGG-16 mampu menangkap fitur secara lebih baik, meskipun dataset yang digunakan terbatas.

4.1.1. Model CNN Sederhana

Model CNN sederhana diberikan Optimizer Adam, learning rate 0,001, batch size 32, dropout 0.2, Epoch 50, early stopping. Penggunaan early stopping dan augmentasi bertujuan untuk mencegah overfitting. Grafik accuracy dan loss dengan teknik baseline dan augmentasi dapat dilihat pada Gambar 3.




Gambar 3. Grafik Accuracy dan Loss dengan teknik baseline dan augmentasi

Penjelasan : Grafik menunjukkan bahwa model CNN sederhana mencapai nilai accuracy 0.8951 dan loss 0.2129 pada data training. Pada data testing, model ini mencapai val_accuracy 0.9420 dan val_loss 0.1824. Model cenderung stabil tanpa mengalami overfitting karena penggunaan early stopping dan augmentasi data. Grafik Model Accuracy menunjukkan akurasi model baik pada data pelatihan (train) maupun data pengujian (test) selama 50 epoch. Akurasi secara umum meningkat seiring bertambahnya epoch. Ini menandakan bahwa model belajar mengenali pola dalam data secara bertahap. Akurasi pada data test tampak sedikit berfluktuasi, yang menunjukkan kemungkinan adanya sedikit overfitting pada model. Grafik Model Loss memperlihatkan loss untuk data pelatihan (train) dan data pengujian (test). Nilai loss secara umum menurun seiring bertambahnya epoch. Ini menunjukkan bahwa model semakin baik dalam meminimalkan kesalahan prediksi. Namun, ada fluktuasi kecil pada data test, terutama di akhir epoch. Hal ini bisa menunjukkan bahwa model mulai mengalami kesulitan untuk generalisasi pada data baru. Grafik menunjukkan bahwa model memiliki performa yang baik, dengan akurasi mendekati 90% pada akhir pelatihan.

4.1.2. Model VGG-16

Model dikompilasi dengan menggunakan optimizer Adam, learning rate 0.001, dropout 0.5, batch size 32, dan augmentasi. Penggunaan early stopping dan augmentasi bertujuan untuk mencegah overfitting. Grafik Accuracy dan Loss dengan teknik VGG-16 dan augmentasi dapat dilihat pada Gambar 5.



Gambar 5. Grafik Accuracy dan Loss dengan teknik VGG-16 dan augmentasi

Penjelasan : Pada data training, model VGG-16 dengan 30 epoch mencapai accuracy 0.9304 dan loss 0.1636. Pada data testing, model ini menghasilkan val_accuracy 0.9710 dan val_loss 0.0755. Grafik model accuracy membandingkan akurasi pelatihan (biru) dan validasi (orange) sepanjang epoch. Akurasi pelatihan meningkat dengan cepat dan mencapai hampir 1.0 (100%) dalam beberapa epoch pertama, kemudian stabil. Akurasi validasi juga meningkat, tetapi tidak setinggi akurasi pelatihan, dan cenderung stabil di sekitar 0.95 setelah beberapa epoch, menunjukkan bahwa model mulai lebih baik dalam menggeneralisasi pada data yang belum pernah dilihat sebelumnya. Grafik loss menunjukkan nilai loss untuk data pelatihan (biru) dan validasi (orange). Loss pelatihan menurun secara tajam pada awalnya, lalu perlahan menurun dan stabil pada nilai yang

sangat rendah (mendekati 0). Loss validasi juga menurun, tetapi dengan sedikit fluktuasi yang lebih besar, meskipun tetap berada pada tingkat rendah, yang menunjukkan bahwa model berfungsi dengan baik di luar data pelatihan. Model menunjukkan kinerja yang baik dalam hal mengurangi loss baik pada data pelatihan maupun validasi, dengan akurasi yang sangat tinggi pada pelatihan dan validasi. Tidak ada indikasi overfitting, karena akurasi dan loss pada data pelatihan dan validasi relatif seimbang. Teknik VGG-16 lebih efektif dibandingkan CNN sederhana karena kombinasi arsitektur yang dalam, dropout, dan augmentasi yang mampu meningkatkan akurasi sekaligus mengurangi loss. Grafik Accuracy dan Loss menunjukkan lebih baik dibandingkan CNN sederhana, dengan performa testing yang mendekati training. Ini menandakan model generalisasi dengan baik.

4.2. Evaluasi

Berdasarkan pengujian Klasifikasi tanaman jagung dengan kecerdasan buatan berbasis CNN, grafik yang disajikan menunjukkan bahwa hasil akurasi yang baik dari training dan testing dengan menggunakan 2 teknik yaitu CNN sederhana memperoleh akurasi 94,20% dan VGG-16 memperoleh akurasi 97,10%. Model VGG-16 ini dapat disesuaikan dengan dataset yang lebih kecil, memberikan hasil akurasi tinggi tanpa memerlukan pelatihan dari awal. Penggunaan teknik regularisasi seperti dropout (untuk menghindari overfitting) dapat lebih meningkatkan akurasi dengan membuat model lebih generalizable. Perbandingan hasil eksperimen sebelumnya tersaji pada Tabel 5.

Tabel 5. Perbandingan hasil eksperimen sebelumnya

Penulis	Model	Jenis Klasifikasi	Jumlah kelas	Jumlah Dataset	Teknik	Hasil Akurasi
Syarif A	LeNet-5	Citra Benda pada dataset buatan	5 kelas	1000 gambar	Convolutional layer, Subsampling, backpropagation	91,3%
Wahyuni	VGG-16	Penyakit pada daun tanaman	4 kelas	10.000 gambar	Transfer learning, fine tuning pada lapisan akhir	93,2%
Amir Sudianto	Alex-net	Jenis buah	10 kelas	15.000 gambar	Augmentasi data, dropout, batch normalization	88,7%
Raharja Kurniawan	ResNet-50	Jenis kendaraan	5 kelas	20.000 gambar	Residual learning, transfer learning	95,1%
Setiawan Yulianto	MobileNetV2	Penyakit kulit pada manusia	6 kelas	12.000 gambar	Depthwise separable convolutions, transfer learning	92,5%

Penjelasan :

- Syarif A (LeNet-5, Akurasi: 91,3%) : Keunggulan penelitian ini adalah LeNet-5 cocok untuk dataset kecil dengan kompleksitas rendah dan arsitektur sederhana, sehingga pelatihan lebih cepat. Kelemahan penelitian ini adalah tidak dirancang untuk menangani dataset dengan variasi gambar yang kompleks, Akurasi lebih rendah dibandingkan model modern seperti VGG-16 atau ResNet. Komparasi terhadap penelitian yang telah dilakukan lebih unggul karena menggunakan model VGG-16 yang memiliki kedalaman arsitektur lebih baik, memungkinkan akurasi lebih tinggi (97,10%) meskipun datasetnya kecil.
- Wahyuni (VGG-16, Akurasi: 93,2%) keunggulan penelitian ini adalah memanfaatkan transfer learning dan fine-tuning, memungkinkan VGG-16 bekerja optimal pada klasifikasi penyakit daun tanaman. Dataset yang cukup besar (10.000 gambar) memberikan variasi data yang lebih baik. Kelemahan penelitian ini adalah akurasi masih lebih rendah (93,2%) dibandingkan penelitian ini. Tidak ada detail penggunaan teknik regulasi seperti dropout untuk menghindari overfitting. Komparasi terhadap penelitian yang telah dilakukan menggunakan pendekatan serupa, yaitu transfer learning pada VGG-16, namun dengan tambahan teknik dropout 0.5 dan early stopping, yang menghasilkan akurasi lebih tinggi (97,10%) meskipun dataset lebih kecil.
- Amir Sudianto (AlexNet, Akurasi: 88,7%) : keunggulan penelitian ini adalah arsitektur AlexNet dirancang untuk dataset yang lebih besar (15.000 gambar), cocok untuk tugas klasifikasi objek umum. Penggunaan augmentasi data dan batch normalization meningkatkan stabilitas pelatihan. Kelemahan penelitian ini yaitu akurasi rendah (88,7%) pada tugas klasifikasi yang memerlukan fitur kompleks. AlexNet kurang efektif untuk dataset kecil atau tugas klasifikasi spesifik seperti deteksi penyakit tanaman. Komparasi terhadap penelitian yang telah dilakukan lebih unggul akurasi 97,10% karena arsitektur VGG-16 lebih mendalam, menangkap fitur lebih kompleks, dan menghasilkan akurasi jauh lebih tinggi dengan dataset lebih kecil.
- Raharja Kurniawan (ResNet-50, Akurasi: 95,1%) : keunggulan penelitian ini adalah Residual learning pada ResNet-50 mengatasi masalah gradien vanishing pada jaringan mendalam. Cocok untuk dataset besar (20.000 gambar), menghasilkan akurasi tinggi (95,1%). Kelemahan penelitian ini yaitu membutuhkan dataset yang besar untuk bekerja optimal. Kompleksitas model lebih tinggi dibandingkan VGG-16, memerlukan waktu pelatihan lebih lama. Komparasi terhadap penelitian yang telah dilakukan lebih efisien karena menghasilkan akurasi lebih tinggi (97,10%) dengan dataset lebih kecil dan waktu pelatihan lebih cepat, berkat penggunaan augmentasi dan dropout.
- Setiawan Yulianto (MobileNetV2, Akurasi: 92,5%) : keunggulan penelitian ini adalah MobileNetV2 dirancang untuk perangkat mobile dengan efisiensi tinggi, cocok untuk pengklasifikasian cepat. Memanfaatkan *depthwise separable convolutions* untuk mengurangi kompleksitas komputasi. Kelemahan penelitian ini adalah akurasi lebih rendah (92,5%) pada tugas klasifikasi kompleks. Tidak terlalu efektif untuk dataset

kecil tanpa augmentasi data yang signifikan. Komparasi terhadap penelitian yang dilakukan adalah meskipun MobileNetV2 efisien, penelitian yang dilakukan lebih unggul dalam hal akurasi yaitu 97,10% karena memanfaatkan arsitektur yang lebih kompleks (VGG-16) dengan regulasi dropout.

5. KESIMPULAN

Penelitian ini berhasil menunjukkan bahwa model VGG-16 memiliki kinerja yang unggul dalam mengklasifikasikan penyakit pada tanaman jagung berdasarkan citra daun. Dengan akurasi VGG-16 sebesar 97,10% dan loss sebesar 7,5%, model ini lebih baik dibandingkan model CNN sederhana yang hanya mencapai akurasi 94,20% dan loss 18%. Keunggulan ini disebabkan oleh arsitektur mendalam VGG-16 yang mampu menangkap fitur kompleks pada citra, ditambah dengan penerapan teknik augmentasi data dan regularisasi dropout yang efektif mencegah overfitting. Kebutuhan akan model yang andal untuk mendeteksi penyakit daun jagung secara otomatis dan akurat, yang dapat membantu petani dalam pengelolaan tanaman serta peningkatan hasil panen. Pembahasan menunjukkan bahwa VGG-16 mengungguli model lain seperti LeNet-5, AlexNet, dan MobileNetV2, bahkan dengan dataset yang lebih kecil, menunjukkan potensi besar dalam aplikasi nyata. Namun, beberapa tantangan seperti keterbatasan dataset masih memerlukan perhatian. Oleh karena itu, saran untuk penelitian selanjutnya adalah memperkaya dataset dengan teknik augmentasi yang lebih beragam, menguji model CNN terbaru seperti EfficientNet atau NASNet untuk mengevaluasi performa yang lebih baik, serta melakukan optimasi waktu pelatihan, terutama pada dataset kecil.

DAFTAR PUSTAKA

- [1] D. H. Didit Iswantoro, "Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode CNN," *Jurnal Ilmiah Universitas Batanghari Jambi*, pp. 900-905, 2022.
- [2] R. D. A. Ivan Pratama Putra, "Klasifikasi Penyakit Daun Jagung Menggunakan Coonvolutional Neural Network," *Jurnal Algoritme*, vol. 2, pp. 102-112, 2022.
- [3] R. M. A. S. Z. Afivah Dwi Nurcahyati, "Klasifikasi Citra Penyakit pada Daun Jagung Menggunakan Deep Learning dengan Metode Convolutional Neural Network," *Jurnal Ilmiah Teknologi Informasi dan Sains*, vol. 1, pp. 43-51, 2022.
- [4] A. Y. Arfan Maulana, "Penerapan Metode Convolutional Neural Network Dalam Klasifikasi Penyakit Tanaman Jagung," *Seminar Nasional Teknologi dan Sains*, vol. 1, pp. 251-256, 2024.
- [5] A. B. Prakosa, "Implementasi Model Deep Learning Convolutional Neural Network Pada Citra Penyakit Daun Jagung Untuk Klasifikasi Penyakit Tanaman," *Jurnal Pendidikan Teknologi Informasi*, vol. 6, pp. 107-116, 2023.
- [6] T. D. P. Z. Z. Y. Rajnapramitha Kusumastuti, "Klasifikasi Citra Penyakit Daun Jagung Menggunakan Algoritma CNN Effcientnet," *Multitek Indonesia*, vol. 2, pp. 143-153, 2024.

- [7] M. I. Fauzi, "Klasifikasi Image Tinggi Tanaman Jagung dengan Menggunakan Algoritma CNN," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 3, 2024.
- [8] R. W. R. H. Reza Mawarni, "Implementasi Metode CNN Pada Klasifikasi Penyakit Jagung," *Prosiding SEMNAS INOTEK*, vol. 3, pp. 1256-1263, 2023.
- [9] M. F. N. Sayyid, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode CNN dengan Image Processing HE dan CLAHE," *Jurnal Teknik Informatika dan Teknologi Informasi*, vol. 4, pp. 86-95, 2024.
- [10] Q. N. Azizah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network Alexnet," *Jurnal Teknik Informatika*, vol. 2, pp. 28-33, 2023.
- [11] S. A. Fiviana Sulistiyana, "Aplikasi Deteksi Penyakit Tanaman Jagung Dengan Metode CNN dan SVM," *Prosiding SENATIK*, vol. 6, pp. 423-432, 2024.
- [12] A. R. Pratama, "Klasifikasi Citra Penyakit Daun Jagung Menggunakan CNN Arsitektur ResNet-50 dan Augmentasi Data," *Universitas Islam Negeri Sultan Syarif Kasim*, 2024.
- [13] H. H. S. F. Daffa Alwan, "Implementasi YOLOv8 Untuk Deteksi Penyakit Daun Jagung Menggunakan Algoritma Convolutional Neural Network," *Scientific Student Journal For Information*, vol. 5, pp. 67-75, 2024.
- [14] E. H. Arum Tiarasari, "Penerapan Convolutional Neural Network Deep Learning Dalam Pendeteksian Citra Biji Jagung Kering," *Jurnal Rekayasa Sistem dan Teknologi Informasi*, vol. 2, pp. 265-271, 2021.
- [15] N. D. Prasada, "Diagnosa Penyakit Tanaman Jagung pada Citra Daun Menggunakan Metode Convolutional Neural Network," *Jurnal Ilmiah Multidisipliner*, vol. 3, pp. 545-554, 2024.
- [16] P. Mimboro, "Identifikasi Penyakit Tanaman Jagung Berdasarkan Citra Daun Menggunakan Hybrid k-NN-CNN," *Journal Of Cyber Health and Computer*, vol. 1, pp. 6-9, 2023.
- [17] Kurniawan, "Sistem Klasifikasi Penyakit Daun Jagung Menggunakan Convolutional Neural Network," *Jurnal Sistem Informasi*, vol. 14, pp. 174-182, 2020.
- [18] A. Wijaya, "Pengembangan Sistem Deteksi Penyakit Jagung Menggunakan CNN dengan Dataset PlantVillage," *Jurnal Teknologi dan Sistem Komputer*, vol. 10, pp. 327-335, 2022.
- [19] Santoso, "Klasifikasi Penyakit Tanaman Jagung Menggunakan CNN dan Teknik Augmentasi Data," *Jurnal Informatika dan Komputer*, vol. 8, pp. 150-157, 2020.
- [20] T. M. M. Luthfi Rahmadi, "Enhancing Facial Expression Recognition through Ensemble Deep Learning," *International Conference on Cybernetics and Intelligent System (ICORIS)*, pp.1-6, 2023.