

KLASIFIKASI PENYAKIT DAUN PISANG BERBASIS CNN MENGUNAKAN MODEL GLOBALAVERAGEPOOLING2D, AVERAGEPOOLING, DAN FLATTEN

Riko Ferdianysah*¹, Soffin Thoriq Arfian², Roma Arrizal Omar Syah³, Tinuk
Agustin⁴

¹²³⁴Prodi S1 Informatika, STMIK Amikom Surakarta

¹²³⁴Sukoharjo Indonesia

Email: ¹riko.10390@mhs.amikomsolo.ac.id, ²soffin.10406@mhs.amikomsolo.ac.id
, ³roma.10402@mhs.amikomsolo.ac.id, ⁴agustin.amikom@gmail.com

Abstract

Banana leaf diseases greatly affect the productivity and quality of banana plants, especially in tropical regions. It is very important to detect this disease quickly and precisely so that it does not spread. Using the Convolutional Neural Network (CNN) method, the aim of this research is to create a banana leaf disease classification model based on images. To achieve this goal, data augmentation techniques were used to process a dataset of banana leaf images containing various types of diseases. This is done to increase the robustness and accuracy of the model. This study compares three CNN models: Flatten, AveragePooling2D, and GlobalAveragePooling. The research results show that the GlobalAveragePooling model has the highest accuracy of 93.62%, followed by AveragePooling2D with an accuracy of 90.96%, and Flatten with an accuracy of 88.83%. This model has great potential to be integrated into mobile applications, allowing farmers to detect banana leaf diseases using their smartphone cameras quickly and accurately. It is hoped that this implementation will help better preventive measures, increase banana crop productivity, and encourage the development of smart agricultural technology.

Keywords: *Banana leaf disease, convolutional neural network, disease detection, image classification, data augmentation*

Abstraksi

Penyakit daun pisang sangat memengaruhi produktivitas dan kualitas tanaman pisang, terutama di wilayah tropis. Sangat penting untuk mendeteksi penyakit ini dengan cepat dan tepat agar tidak menyebar. Dengan menggunakan metode Convolutional Neural Network (CNN), tujuan penelitian ini adalah untuk membuat model klasifikasi penyakit daun pisang berbasis gambar. Untuk mencapai tujuan ini, teknik augmentasi data digunakan untuk memproses dataset gambar daun pisang yang mengandung berbagai jenis penyakit. Ini dilakukan untuk meningkatkan ketahanan dan akurasi model. Studi ini membandingkan tiga model CNN: Flatten, AveragePooling2D, dan GlobalAveragePooling. Hasil penelitian menunjukkan bahwa model GlobalAveragePooling memiliki akurasi tertinggi sebesar 93,62%, diikuti oleh

AveragePooling2D dengan akurasi sebesar 90,96%, dan Flatten dengan akurasi sebesar 88,83%. Model ini memiliki potensi besar untuk diintegrasikan ke dalam aplikasi mobile, memungkinkan petani untuk mendeteksi penyakit daun pisang dengan menggunakan kamera smartphone mereka secara cepat dan akurat. Diharapkan bahwa implementasi ini akan membantu tindakan pencegahan yang lebih baik, meningkatkan produktivitas tanaman pisang, dan mendorong pengembangan teknologi pertanian yang cerdas.

Kata Kunci: *Penyakit daun pisang, convolutional neural network, deteksi penyakit, klasifikasi citra, augmentasi dat*

1. PENDAHULUAN

Pisang merupakan salah satu jenis tanaman yang berasal dari Asia Tenggara dan saat ini ditemukan di seluruh dunia. Karena harganya yang murah, harga yang tinggi, dan harga yang relatif murah, pisang telah menjadi komoditas yang sangat digemari dalam kurun waktu yang lama [1]. Pisang merupakan salah satu hasil pertanian yang penting di Indonesia, meskipun seringkali mempunyai dampak buruk terhadap kesehatan yang dapat mengganggu tanaman dan menimbulkan kerugian.

Ada beberapa jenis penyakit pisang yang sering dijumpai di Indonesia, antara lain bercak daun cordana, gugur daun pestaliopsis, sigatoka, dan layu jamur dan bakteri. Oleh karena itu, penting untuk mendeteksi penyakit pada daun pisang untuk mengurangi kelembapan yang mempengaruhi produktivitas tanaman.

Badan Penelitian dan Pengembangan Pertanian serta Badan Karantina Pertanian bekerja sama dengan ACIAR pada tahun 2010 untuk mengembangkan PLF di Indonesia. Semua sampel dari 16 provinsi di Indonesia terinfeksi Foc, termasuk Papua. Pada tahun 2018, BalitbuBB Biogen melaporkan bahwa kejadian tertinggi terjadi di Aceh dan Sumatera Barat, namun Foc belum ditemukan di Papua Nugini. Foc menyebabkan kerusakan pada 1000 Ha Pisang Cavendish di Halmahera (1995), 1300 Ha Pisang Barangan di Sumatera Utara (1992-1997), 300 Ha Pisang Cavendish di Riau (1992-1995), dan 1700 Ha Pisang Cavendish di Lampung (1995-2000)). Penyebaran penyakit ini meluas di seluruh Indonesia pada tahun 2010 [2].

Sebuah sistem untuk mengklasifikasikan penyakit pisang diperlukan karena petani di Indonesia kesulitan mengidentifikasi jenis penyakit pada daun pisang karena mereka tidak tahu tentang jenis pathogen yang menyerang pisang, yang dapat menyebabkan kesalahan dalam pengobatan penyakit yang membuat pertumbuhan melambat atau gagal, menyebabkan banyak pisang yang gagal panen [3].

Cara tradisional yang digunakan untuk mengidentifikasi penyakit tanaman biasanya memerlukan banyak pengetahuan dan waktu, apalagi jika dilakukan secara manual oleh ahli tenaga yang dapat mengukur waktu dan biaya [4]. Namun seiring kemajuan teknologi, telah berkembang berbagai metode deteksi berbasis otomatis terlah berkembang, salah satunya adalah model Convolutional Neural Network (CNN) yang sangat berguna.

CNN (Convolutional Neural Network) menggunakan model kerja deep learning[5]. Bagian machine learning deep learning memungkinkan model komputasi yang terdiri dari berbagai lapisan pemrosesan untuk mempelajari representasi data [6].

Saat ini, metode Convolutional Neural Network (CNN) adalah yang paling efektif dalam analisis citra [7]. CNN adalah model pembelajaran mendalam yang dapat menganalisis isyarat visual dan karakteristik gambar kompleks [8]. Salah satu keunggulan metode CNN adalah bahwa itu tidak memerlukan ekstraksi khusus untuk mendapatkan fitur yang diperlukan dalam proses klasifikasi[9]. Oleh karena itu, CNN cocok untuk mengklasifikasikan penyakit tanaman berbasis visual.

Tujuan penelitian ini adalah untuk membuat model klasifikasi daun pisang menggunakan teknik berbasis CNN gambar[10]. Penelitian yang di lakukan membandingkan 3 jenis model GlobalAveragePooling, Averagepooling2D, dan Flatten, untuk menemukan akurasi terbaik dari 3 model yang digunakan.

Model ini menggunakan dataset citra daun pisang yang memiliki jenis penyakit yang beragam untuk mencapai akurasi klasifikasi yang tinggi. Dengan pemanfaatan teknologi ini diharapkan para petani dan petani dapat menggunakan alat yang efektif untuk mendeteksi penyakit daun pisang secara otomatis, cepat, dan akurat. Hasil penelitian ini diharapkan dapat membantu meningkatkan efisiensi tanaman pisang dan hasil panen.

2. TINJAUAN PUSTAKA

2.1. Penyakit Daun Pisang

Tanaman pisang (*Musa paadisiaca L.*) merupakan salah satu dari jenis tumbuhan herba. Tanaman pisang terdiri atas bagian akar, batang, daun, bunga atau buah, juga pisang merupakan salah satu suku Musaceae, berasal dari kawasan Asia Tenggara [11]. kami membatasi penelitian kami pada mengklasifikasikan penyakit daun pisang. Pisang terancam oleh berbagai jenis penyakit, seperti seperti pisang sigatoka dan pisang belu. Sigatoka hitam disebabkan oleh jamur *Mycosphaerella fijiensis*. Gejalanya dimulai dengan bercak klorotik yang sangat kecil dan kemudian berkembang menjadi garis-garis tipis berwarna coklat [12].

2.2. Metode Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah jenis jaringan saraf dalam pembelajaran mendalam yang digunakan untuk menganalisis gambar atau data visual. CNN dapat mengenali objek pada gambar berkat penggunaan operasi konvolusinya [13]. Convolutional Neural Network (CNN) hampir sama dengan neural network konvensional. CNN terdiri dari neuron yang bertanggung jawab atas berat, bias, dan fungsi aktivasi. Lapisan convolutional juga terdiri dari neuron yang disusun sedemikian rupa sehingga membentuk sebuah filter yang memiliki panjang dan tinggi (pixels) [14].

Untuk mengatasi overfitting dan meningkatkan generalisasi pada data yang tidak terlihat, penelitian[15] menggabungkan metode regularisasi tingkat lanjut seperti augmentasi data, normalisasi batch, dan dropout dengan pengumpulan rata-rata global.

Selain mengurangi masalah overfitting, studi [16] menyarankan penggunaan tiga jenis pelatihan dan pengujian pembagian data. Menurut evaluasi, pembagian data 90%:10% adalah pembagian data yang paling cocok untuk dataset dan arsitektur yang digunakan. Nilai akurasi pengujian untuk ketiga model tersebut adalah 69,33%, 77,33%, dan 76%, masing-masing. Model Deep Learning Convolutional Neural Network (CNN) juga digunakan untuk penelitian sebelumnya [17]. Hasil menunjukkan nilai akurasi 0,9990, nilai ketepatan 0,9981, nilai recall 1, dan nilai F1 0,9990.

Dalam studi sebelumnya [18] Hasil perhitungan algoritma mesin menunjukkan nilai akurasi 0,917 atau 91,7% dan kesalahan 0,088 atau 8,8%, yang menunjukkan tingkat kesalahan lebih rendah daripada tingkat ketepatan dalam melakukan prediksi. Dengan demikian, dapat disimpulkan bahwa dengan nilai akurasi ini, mereka cukup baik untuk mengklasifikasikan gambar jenis penyakit pada padi berdasarkan daun tepat sesuai.

Pada penelitian sebelumnya[19] menggunakan metode Deep Learning CNN, tiga kelas dipelajari: daun sehat, penyakit awal, dan penyakit lanjutan. Hasil penelitian ini dianggap baik karena pada epoch ke-10 dengan batch size 20, pengajaran memiliki akurasi 95% dan validasi 94%.

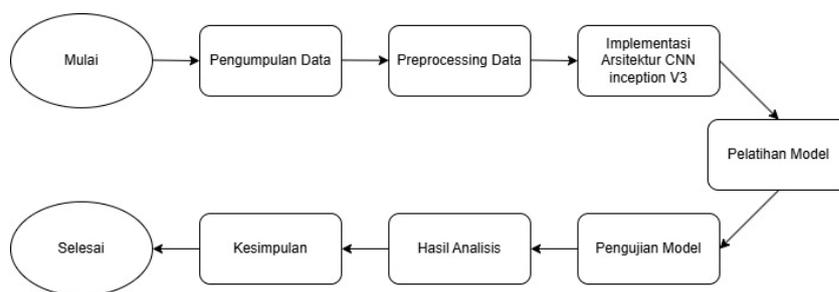
Pada penelitian ini[20] menunjukkan bahwa algoritma yang diuji memiliki tingkat akurasi 73,19%, yang kecil dibandingkan dengan metode lain; prediksinya melebihi batas 0,6. Penelitian tambahan menggunakan pemrosesan gambar TensorFlow untuk proses klasifikasi [21]. mencapai akurasi 90,42%. Di sisi lain, saat menggunakan pengoptimal SGD, 20 epoch, ukuran batch 16, dan laju pembelajaran 0,01, akurasi validasi mencapai 94,21%. Akurasinya adalah 80,83% untuk data pengujian.

Pada penelitian yang lain[22] Hasil pengujian klasifikasi menggunakan metode SVM dengan penambahan empat kernel (RBF, linear, dan polynomial) dan ekstraksi fitur tekstur dengan metode GLCM menunjukkan bahwa nilai akurasi, presisi, recall, dan F1-Score masing-masing mencapai 100%. Sebaliknya, hasil pengujian klasifikasi menggunakan SVM dengan kernel sigmoid menggunakan ekstraksi fitur tekstur dengan metode GLCM menunjukkan nilai akurasi 75 persen, presisi 75 persen, recall 73 persen, dan F1-Score 74 persen.

Pada penelitian sebelumnya[23] Hasil klasifikasi metode Random Forest menunjukkan akurasi sebesar 0.96, presisi sebesar 0,965, recall sebesar 0,965, dan skor f1-sebesar 0,965. Metode Random Forest sangat cocok untuk analisis data yang berukuran besar.

3. METODE PENELITIAN

Metode yang digunakan dalam klasifikasi penyakit daun pisang menggunakan metode Convolutional Neural Network (CNN) dapat dilihat pada gambar 1, dibawah ini:



Gambar 1. Alur Pemrosesan Data

Penelitian dimulai dengan membaca literatur untuk mendapatkan pemahaman yang lebih baik tentang dasar teori yang berkaitan dengan penelitian. Membaca berbagai penelitian tentang penyakit pisang di Indonesia membantu menemukan masalah. Pada langkah berikutnya, data, yang terdiri dari 2537 gambar yang dikumpulkan melalui Kaggle, akan diproses melalui tahap pra-proses menggunakan augmentasi data, dan kemudian dibagi menjadi data latihan dan validasi. Tahap selanjutnya adalah mengkonfigurasi arsitektur GlobalAveragePooling, AveragePooling2D, dan Flatten menggunakan Google Colab untuk melaksanakan implementasi model CNN. Tahap terakhir, setelah model dilatih, adalah melakukan pengujian pada model untuk mengetahui apakah model yang dihasilkan memenuhi persyaratan yang diinginkan.

3.1. Dataset

Sumber data pada penelitian ini diambil pada platform Kaggle. Data diambil dari Banana Leaf Spot Diseases (BananaLSD) Dataset. Data terdiri dari 2537 dari augmentasiSet dan OriginalSet dan terdapat 4 kelas (cordana, healthy, pestalotiopsis, dan sigatoka) dalam format jpeg. Seperti gambar 2 dibawah.



Gambar 2. Kelas daun pisang

3.2. Data Preprocessing

Data preprocessing adalah proses menyiapkan data mentah agar data yang dihasilkan lebih mudah dilatih dan hasil model lebih baik. Sebelum penelitian dimulai, gambar akan diresize dan dicrop untuk menonjolkan aspek yang ingin diklasifikasi. 20% dari pembagian ini digunakan untuk validasi data—data yang digunakan untuk

memvalidasi model klasifikasi untuk mencegah overfitting—dan 80% lagi untuk pembelajaran data. Hasil preprocessing kami menggunakan data, yang terdiri dari 937 gambar jpeg dari empat kelas: cordana, healthy, pestalotiopsis, dan sigatoka.

Dengan menambahkan augmentasi seperti table 1 di bawah ini.

Tabel 1. Augmentasi

datagen	ImageDataGenerator
rotation_range	20
horizontal_flip	True
fill_mode	nearest
brightness_range	[0.8, 1.2]

3.3. Implementasi Arsitektur CNN

Dalam penelitian ini kami menggunakan arsitektur cnn menggunakan arsitektur CNN costum. Penelitian juga Menggunakan 3 model : model GlobalAveragePooling, Averagepooling2D, dan Flatten.

3.3.1. Arsitektur CNN costum

Model: "sequential_2"

Layer (type)	Output Shape	Param #
conv2d_6 (Conv2D)	(None, 73, 73, 32)	896
max_pooling2d_6 (MaxPooling2D)	(None, 36, 36, 32)	0
conv2d_7 (Conv2D)	(None, 34, 34, 64)	18,496
max_pooling2d_7 (MaxPooling2D)	(None, 17, 17, 64)	0
conv2d_8 (Conv2D)	(None, 15, 15, 128)	73,856
max_pooling2d_8 (MaxPooling2D)	(None, 7, 7, 128)	0
global_average_pooling2d_1 (GlobalAveragePooling2D)	(None, 128)	0
dense_2 (Dense)	(None, 128)	16,512
dropout_1 (Dropout)	(None, 128)	0
dense_3 (Dense)	(None, 4)	516

Total params: 110,276 (430.77 KB)
 Trainable params: 110,276 (430.77 KB)
 Non-trainable params: 0 (0.00 B)

Gambar 3. Model

Arsitektur CNN ini dirancang untuk klasifikasi gambar dengan 4 kelas output. Model terdiri dari tiga lapisan konvolusi (Conv2D) dengan 32, 64, dan 128 filter berukuran 3x3, menghasilkan output berukuran (73, 73, 32), (34, 34, 64), dan (15, 15, 128) masing-masing. Setiap lapisan konvolusi diikuti oleh lapisan max-pooling untuk mengekstraksi fitur penting dan mengurangi dimensi data. Setelah lapisan konvolusi, GlobalAveragePooling2D mereduksi data menjadi vektor fitur 128. Dua lapisan dense digunakan: satu dengan 128 unit untuk pemrosesan fitur dan satu lagi dengan 4 unit sebagai output, menghasilkan probabilitas kelas. Model ini juga menggunakan dropout untuk mencegah overfitting dan memiliki total 110,276 parameter yang dapat dilatih. Arsitektur sederhana ini efektif untuk klasifikasi dasar.

3.3.2. Parameter Pengujian

Penelitian akan diuji menggunakan parameter seperti tabel 2 dibawah.

Tabel 2. Paramenter Pengujian

Paramenter	Keterangan
Dataset	937 Gambar
Optimizer	Adam
Fungsi Aktivasi	Softmax
Epoch	100
Batch Size	32
Learning Rate	0.001
Dropout	0.5

Tabel 2 menunjukkan parameter pengujian model CNN dengan tiga skenario pooling yaitu GlobalAveragePooling2D, AveragePooling, dan Flatten. Setiap model dilatih pada dataset 937 gambar dengan parameter yang sama: optimizer Adam, fungsi aktivasi Softmax, 100 epoch, batch size 32, learning rate 0.001, dan dropout 0.5. Ketiga skenario ini diuji dalam kondisi yang sama untuk membandingkan performa dalam hal akurasi dan loss pada data training dan validasi, sehingga dapat dilihat model mana yang paling optimal.

3.3.3. GlobalAveragePooling2D

GlobalAveragePooling2D merupakan lapisan pooling dalam jaringan saraf convolutional (CNN) yang melakukan perataan (average pooling) di seluruh dimensi spasial dari fitur, sehingga setiap channel dalam output memiliki satu nilai rata-rata. Lapisan ini sering digunakan di bagian akhir model convolutional untuk menggantikan lapisan fully connected, khususnya dalam tugas klasifikasi.

3.3.4. AveragePooling

AveragePooling adalah lapisan pooling dalam jaringan saraf convolutional (CNN) yang berfungsi untuk mengurangi dimensi spasial dari fitur-fitur yang dihasilkan oleh lapisan convolutional dengan mengambil nilai rata-rata dalam area tertentu (kernel). AveragePooling menjaga fitur penting sambil mengurangi ukuran data yang akan diproses oleh lapisan berikutnya, sehingga mempercepat komputasi dan mengurangi risiko overfitting.

3.3.5. Flatten

Flatten adalah lapisan dalam arsitektur jaringan saraf tiruan yang digunakan untuk meratakan atau mengubah data multidimensi (biasanya dari lapisan convolutional) menjadi vektor satu dimensi. Lapisan ini sangat penting ketika kita akan menghubungkan lapisan convolutional atau pooling dengan lapisan fully connected (dense), terutama dalam jaringan convolutional neural network (CNN).

3.4. Pelatihan Model

Pengujian dalam penelitian ini dilakukan untuk membandingkan kinerja tiga model arsitektur Convolutional Neural Network (CNN) yang populer, yaitu GlobalAveragePooling2D, AveragePooling, Flatten dalam klasifikasi penyakit pisang. Ketiga model ini dipilih karena keunggulannya dalam transfer learning, yang memungkinkan penggunaan model yang telah dilatih sebelumnya pada dataset besar untuk diterapkan pada dataset yang lebih spesifik. Ketiga model dilatih menggunakan dataset yang sama dengan parameter pelatihan yang serupa, seperti learning rate, batch size, dan jumlah epoch.

3.5. Pengujian Model

Setelah model selesai dibor, dilakukan pengujian untuk memutar kinerja model dalam mengklasifikasikan penyakit pada daun pisang. Pengujian ini dilakukan menggunakan validasi data yang telah disiapkan sebelumnya, yang tidak digunakan dalam proses pelatihan untuk memastikan hasil yang objektif. Metode pengujian ini melibatkan beberapa pengukuran metrik evaluasi yang umum digunakan dalam klasifikasi gambar, seperti akurasi, presisi, recall, dan F1-score. Metrik-metrik ini membantu dalam menilai seberapa baik model dalam mendeteksi setiap kelas penyakit pada daun pisang. Pengujian model dilakukan dengan cara sebagai berikut:

1. Akurasi: Mengukur persentase prediksi model yang benar dari seluruh data uji; persentase prediksi yang benar untuk kelas tertentu dibandingkan dengan semua prediksi untuk kelas tersebut.
2. Presisi: Mengukur seberapa akurat model dalam mengklasifikasikan data ke dalam kelas tertentu, yaitu persentase prediksi yang benar untuk kelas tertentu.
3. Recall: Mengukur seberapa baik model mampu menemukan semua data yang sebenarnya termasuk dalam kelas tersebut.
4. Skor F1: Merupakan skor harmonis rata-rata dari presisi dan recall. Nilai F1 yang tinggi menunjukkan keseimbangan yang baik antara presisi dan recall.

3.6. Hasil Analisis

Hasil pengujian model akan dianalisis untuk menentukan model arsitektur CNN mana yang paling optimal dalam klasifikasi penyakit daun pisang. Analisis ini dilakukan dengan membandingkan nilai akurasi, presisi, recall, dan F1-score yang dihasilkan oleh masing-masing model: GlobalAveragePooling2D, AveragePooling, dan Flatten. Model dengan performa terbaik akan menjadi rekomendasi untuk digunakan dalam aplikasi deteksi penyakit daun pisang.

3.7. Kesimpulan

Berdasarkan hasil analisis dan pengujian, dapat ditarik kesimpulan apakah model CNN dengan arsitektur GlobalAveragePooling2D, AveragePooling, atau Flatten memberikan hasil klasifikasi yang terbaik dalam mendeteksi penyakit daun pisang.

Kesimpulan ini diharapkan dapat memberikan wawasan bagi penelitian lebih lanjut dalam klasifikasi penyakit tanaman, khususnya dalam aplikasi CNN dan transfer learning.

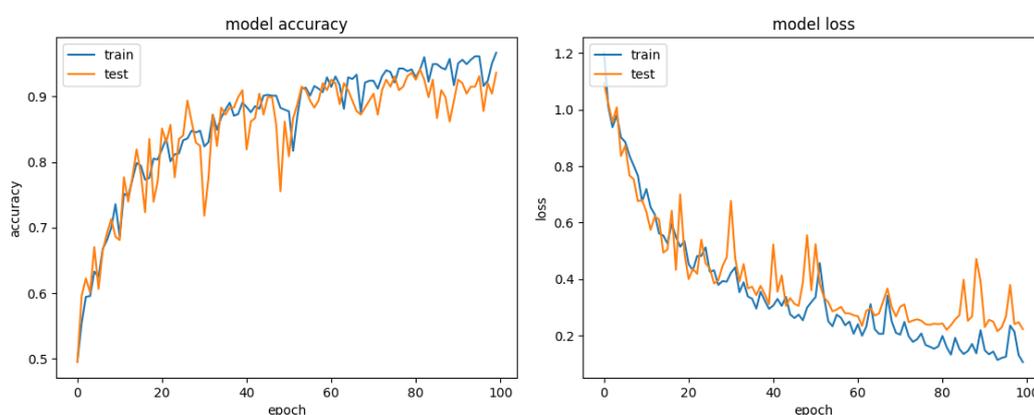
4. HASIL DAN PEMBAHASAN

Pada penelitian ini bertujuan untuk menganalisis kinerja tiga model cnn yang bertujuan untuk menentukan tingkat akurasi tertinggi dan untuk mengklasifikasikan daun sehat dan daun yang terinfeksi penyakit. Perbandingan akurasi validasi, lost validasi loss dan Convusion Matrix berdasarkan metode optimasi.

4.1. Hasil Klasifikasi Dengan 3 Model

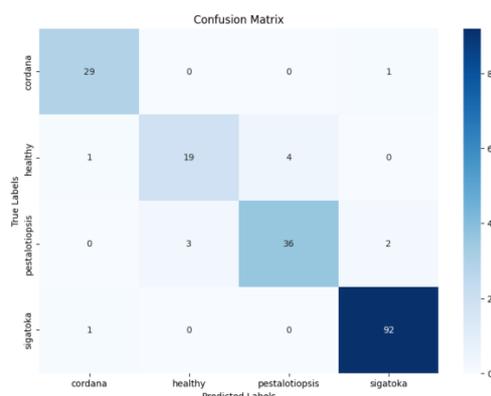
3 model yang digunakan adalah GlobalAveragePooling, Averagepooling2D, dan Flatten.

4.1.1. Hasil Klasifikasi Menggunakan GlobalAveragePooling2D



Gambar 4. Grafik Accuracy dan loss GlobalAveragePooling2D

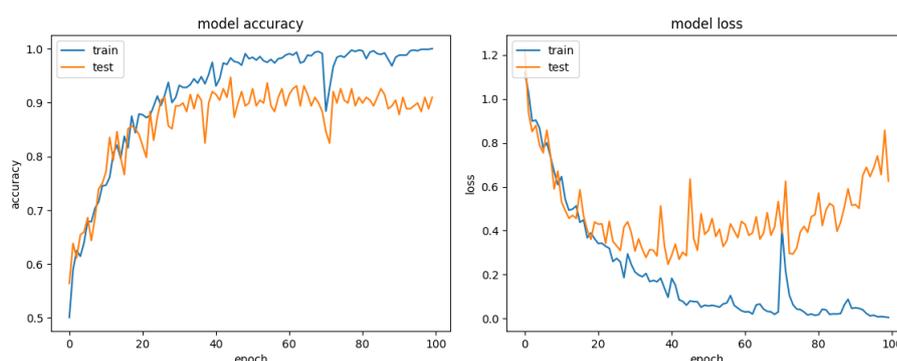
Hasil dari klasifikasi mendapatkan grafik accuracy dan loss sebesar 93.62% dari GlobalAveragePooling2D seperti digambar di gambar 4 diatas. Grafik akurasi menunjukkan peningkatan bertahap pada akurasi pelatihan dan pengujian selama 100 epoch, mencapai nilai mendekati 0,9 hingga 1,0 di akhir, yang mengindikasikan model mampu belajar dengan baik. Akurasi train dan test relatif berimbang dan konsisten tinggi, menunjukkan kemampuan model untuk menggeneralisasi ke data pengujian, meskipun terdapat fluktuasi kecil. Fluktuasi ini mungkin menunjukkan adanya variasi pada data atau ketidaksesuaian minor yang dapat diperbaiki. Pada grafik loss, terlihat penurunan loss pada data pelatihan dan pengujian seiring bertambahnya epoch, yang menunjukkan peningkatan kemampuan prediksi model. Setelah sekitar 60 epoch, loss pada data pelatihan stabil pada nilai rendah, sementara loss pengujian masih menunjukkan fluktuasi namun cenderung menurun.



Gambar 5. Hasil Confusion Matrix GlobalAveragePooling2D

Confusion matrix pada gambar 5, menunjukkan hasil klasifikasi model terhadap empat kelas: cordana, healthy, pestalotiopsis, dan sigatoka. Model berhasil memprediksi sebagian besar sampel dengan benar untuk setiap kelas, namun terjadi beberapa kesalahan. Pada kelas "cordana," satu sampel salah diklasifikasikan sebagai "sigatoka." Kelas "healthy" memiliki lima kesalahan, yaitu satu sampel diprediksi sebagai "cordana" dan empat sebagai "pestalotiopsis." Untuk kelas "pestalotiopsis," terdapat lima kesalahan, dengan tiga diprediksi sebagai "healthy" dan dua sebagai "sigatoka." Kelas "sigatoka" memiliki kinerja terbaik, dengan 92 prediksi benar dan satu kesalahan (diprediksi sebagai "cordana"). Secara keseluruhan, model berkinerja baik, terutama pada kelas "sigatoka" dan "cordana," namun menunjukkan beberapa kesalahan pada kelas "healthy" dan "pestalotiopsis." Confusion matrix ini bermanfaat untuk mengevaluasi kinerja model lebih lanjut dengan menghitung akurasi, presisi, recall, dan F1-score.

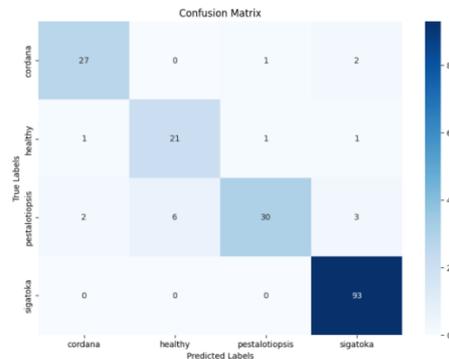
4.1.2. Hasil Klasifikasi Menggunakan AveragePooling



Gambar 6. Grafik Accuracy dan loss AveragePooling

Hasil dari klasifikasi mendapatkan grafik accuracy dan loss sebesar 90.96% dari GlobalAveragePooling2D seperti digambar di gambar 6 diatas. Grafik akurasi menunjukkan bahwa akurasi pelatihan meningkat tajam pada awal epoch dan stabil mendekati 100% setelah 40-50 epoch, menunjukkan keberhasilan model dalam mempelajari pola pada data pelatihan. Akurasi pengujian juga meningkat di awal pelatihan, namun stabil di sekitar 85-90%, sedikit lebih rendah dari akurasi pelatihan, yang mengindikasikan potensi overfitting.

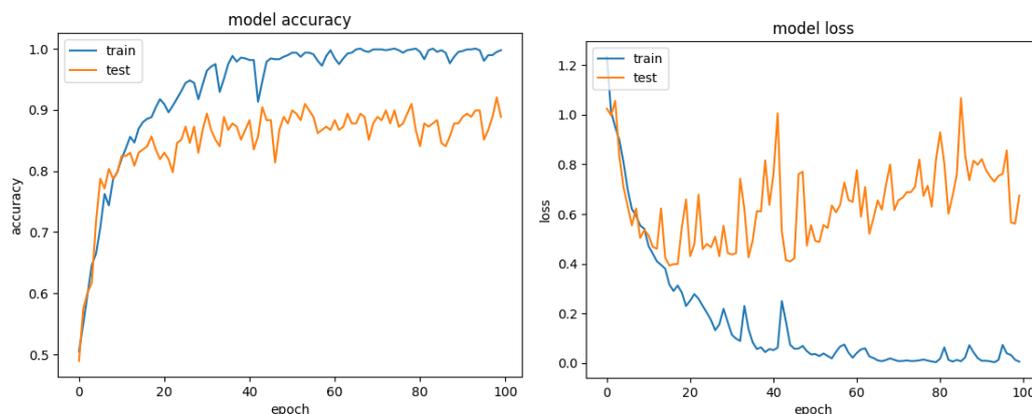
Pada grafik loss, loss pelatihan turun signifikan dan mendekati 0 setelah 50 epoch, menunjukkan kesalahan yang minimal pada data pelatihan. Namun, loss pengujian awalnya turun tetapi kemudian berfluktuasi dan cenderung meningkat, yang menguatkan indikasi bahwa model mengalami overfitting.



Gambar 7. Hasil Confusion Matrix AveragePooling

Confusion matrix pada gambar 7, menunjukkan hasil klasifikasi model terhadap empat kelas: cordana, healthy, pestalotiopsis, dan sigatoka. Pada kelas "cordana," model memprediksi 27 sampel dengan benar, tetapi salah mengklasifikasikan satu sampel sebagai "pestalotiopsis" dan dua sampel lainnya sebagai "sigatoka." Untuk kelas "healthy," model berhasil memprediksi 21 sampel dengan benar, namun ada satu sampel yang salah diprediksi sebagai "cordana" dan satu sebagai "pestalotiopsis." Pada kelas "pestalotiopsis," model memprediksi 30 sampel dengan benar, tetapi terjadi kesalahan pada enam sampel yang diklasifikasikan sebagai "healthy" dan tiga sebagai "sigatoka." Terakhir, untuk kelas "sigatoka," model menunjukkan performa sangat baik dengan memprediksi 93 sampel dengan benar dan tanpa kesalahan. Secara keseluruhan, model cukup akurat untuk kelas "sigatoka," tetapi masih terjadi kesalahan pada kelas lain, terutama antara "pestalotiopsis" dan "healthy."

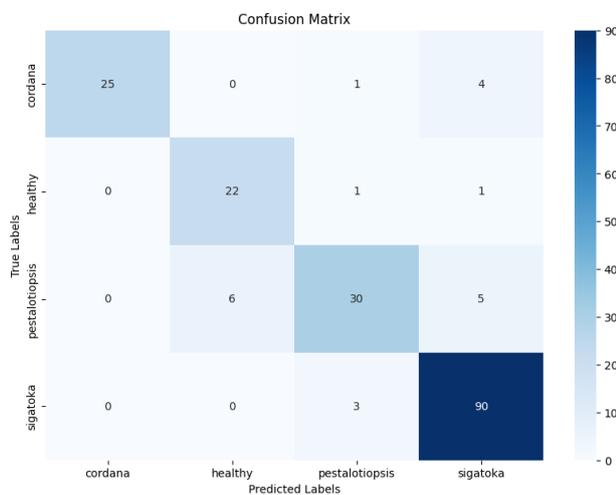
4.1.3. Hasil Klasifikasi Menggunakan Flatten



Gambar 8. Grafik Accuracy dan loss Flatten

Grafik akurasi pada gambar 8, menunjukkan bahwa akurasi pelatihan meningkat tajam pada awal epoch dan stabil mendekati 100% setelah 40-50 epoch, yang

menunjukkan kemampuan model mengenali pola pada data pelatihan dengan baik. Akurasi pengujian juga meningkat di awal pelatihan, namun mulai stabil di sekitar 85-90%, lebih rendah dari akurasi pelatihan. Perbedaan ini mengindikasikan kemungkinan overfitting, di mana model terlalu menyesuaikan dengan data pelatihan sehingga kurang efektif saat diuji pada data baru. Pada grafik loss, terlihat bahwa loss pada data pelatihan menurun signifikan dan mendekati 0 setelah sekitar 50 epoch, menunjukkan minimnya kesalahan pada data pelatihan. Sebaliknya, loss pada data pengujian awalnya menurun namun kemudian berfluktuasi dan cenderung meningkat, yang semakin menegaskan adanya overfitting, di mana model terlalu spesifik terhadap data pelatihan dan kurang mampu menggeneralisasi ke data baru.



Gambar 9. Hasil Confusion Matrix Flatten

Pada gambar 9, confusion matrix ini juga menggambarkan hasil prediksi model terhadap empat kelas yang sama. Untuk kelas "cordana," model berhasil memprediksi 25 sampel dengan benar, tetapi salah mengklasifikasikan satu sampel sebagai "pestalotiopsis" dan empat sampel sebagai "sigatoka." Untuk kelas "healthy," terdapat 22 prediksi yang benar, dan satu sampel salah diprediksi sebagai "cordana" dan satu lagi sebagai "pestalotiopsis." Pada kelas "pestalotiopsis," model berhasil memprediksi 30 sampel dengan benar, tetapi terjadi kesalahan pada enam sampel yang diklasifikasikan sebagai "healthy" dan lima sebagai "sigatoka." Sedangkan pada kelas "sigatoka," model menunjukkan performa yang sangat baik dengan memprediksi 90 sampel dengan benar, namun ada tiga sampel salah diprediksi sebagai "pestalotiopsis." Confusion matrix ini menunjukkan bahwa model bekerja baik untuk kelas "sigatoka" tetapi masih mengalami kesalahan pada kelas lainnya, terutama antara "pestalotiopsis" dan "sigatoka."

4.2. Hasil Klasifikasi Accuracy Tertinggi

Tabel ini menampilkan kinerja tiga model arsitektur Convolutional Neural Network (CNN) yang berbeda, yaitu GlobalAveragePooling2D, AveragePooling, dan Flatten, untuk klasifikasi penyakit daun pisang. Berikut penjelasan detail dari masing-masing

model berdasarkan akurasi (akurasi) dan loss pada data training dan validas, seperti di tabel 3.

Tabel 3. Perbandingan

Model	Accuracy		Loss	
	Training	Validasi	Training	Validasi
GlobalAveragePooling2D	0.9684	0.9362	0.1011	0.2222
AveragePooling	1.0000	0.9096	0.0063	0.6256
Flatten	0.9957	0.8883	0.0087	0.6739

Tabel membandingkan kinerja tiga model CNN dengan lapisan pooling berbeda: GlobalAveragePooling2D, AveragePooling, dan Flatten. Model GlobalAveragePooling2D menunjukkan keseimbangan terbaik antara akurasi dan loss pada data training (0.9684 akurasi, 0.1011 loss) dan validasi (0.9362 akurasi, 0.2222 loss), menunjukkan kemampuan generalisasi yang baik. AveragePooling memiliki akurasi training sempurna (1.0000) tetapi akurasi validasi lebih rendah (0.9096) dengan selisih loss besar, yang mengindikasikan overfitting. Model Flatten juga menunjukkan indikasi overfitting dengan akurasi tinggi pada training (0.9957) namun lebih rendah pada validasi (0.8883).

Model CNN ini dapat diimplementasikan dalam aplikasi mobile atau drone untuk deteksi dini penyakit tanaman, memungkinkan tindakan pencegahan yang lebih cepat dan efisien. Teknologi ini mendukung pengelolaan pertanian cerdas, mengurangi penggunaan pestisida yang tidak tepat, dan meningkatkan produktivitas.

Berdasarkan hasil ini dapat ditarik kesimpulan bahwa GlobalAveragePooling2D adalah model yang paling seimbang dan memiliki kemampuan generalisasi yang baik, dengan perbedaan kecil antara akurasi dan loss pada data training dan validasi. Model ini tidak terlalu mengalami overfitting. AveragePooling dan Flatten menunjukkan tanda-tanda overfitting, meskipun AveragePooling sedikit lebih baik dibandingkan Flatten. Rekomendasi Model GlobalAveragePooling2D lebih direkomendasikan untuk tugas klasifikasi penyakit daun pisang ini karena memiliki kinerja yang lebih stabil dan generalisasi yang lebih baik pada validasi data.

5. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi penyakit daun pisang menggunakan metode Convolutional Neural Network (CNN) dengan memperkenalkan tiga arsitektur yang berbeda: GlobalAveragePooling, AveragePooling2D, dan Flatten. Model GlobalAveragePooling menunjukkan performa terbaik dengan akurasi validasi sebesar 93,62%, diikuti oleh AveragePooling2D sebesar 90,96%, dan Flatten sebesar 88,83%. Hasil ini menunjukkan bahwa penggunaan CNN, khususnya model GlobalAveragePooling, efektif untuk mengklasifikasikan penyakit daun pisang. Perkiraan model ini dapat diterapkan di dunia pertanian untuk mendeteksi penyakit yang cepat dan akurat, membantu petani dalam menjaga kesehatan tanaman pisang dan meningkatkan hasil panen secara signifikan. Untuk penelitian mendatang, disarankan

menggunakan dataset yang lebih beragam dan mengeksplorasi metode deep learning lainnya untuk meningkatkan akurasi dan keandalan model.

DAFTAR PUSTAKA

- [1] Nugraha Lindu Anggana, "Identifikasi parasitoid pada hama ulat penggulung daun pisang (erionota thrax) sebagai dasar pengendalian hama terpadu," *FKIP UNPAS.*, no. 2504, pp. 1–9, 2024.
- [2] N. Saptayanti, "Penyakit Layu Fusarium Pada Pertanaman Pisang di Indonesia," *Bul. Teknol. dan Inov. Pertan.*, vol. 2, no. 3, pp. 13–18, 2023.
- [3] C. U. Aji, Wasito Galih, "Jurnal Teknologi Terpadu LEARNING," *J. Teknol. Terpadu*, vol. 8, no. 1, pp. 89–94, 2022.
- [4] S. Ainah, Y. N. C. Khotimah, A. Maharani, V. H. Pranatawijaya, and R. Priskila, "Implementasi Sistem Pakar Forward Chaining pada Deteksi Penyakit Tanaman Selada," *J. Minfo Polgan*, vol. 13, no. 1, pp. 241–253, 2024, doi: 10.33395/jmp.v13i1.13613.
- [5] F. M. Qotrunnada and P. H. Utomo, "Metode Convolutional Neural Network untuk Klasifikasi Wajah Bermasker," *Prisma*, vol. 5, pp. 799–807, 2022.
- [6] I. R. Ramadhani, A. Nilogiri, and A. Qurrota, "Klasifikasi jenis tumbuhan berdasarkan citra daun menggunakan metode convolutional neural network," *J. Smart Teknol.*, vol. 3, no. 3, pp. 249–260, 2022, [Online]. Available: <http://jurnal.unmuhjember.ac.id/index.php/JST>
- [7] D. Iswantoro and D. Handayani UN, "Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (CNN)," *J. Ilm. Univ. Batanghari Jambi*, vol. 22, no. 2, p. 900, 2022, doi: 10.33087/jiubj.v22i2.2065.
- [8] M. E. Prasetyo, M. R. Faza, R. Pratama, S. N. H. Alhabsy, H. Purwanti, and A. P. A. Masa, "Klasifikasi Ragam Kendaraan Menggunakan Metode Convolutional Neural Network (Cnn)," *Adopsi Teknol. dan Sist. Inf.*, vol. 2, no. 2, pp. 142–148, 2023, doi: 10.30872/atasi.v2i2.1156.
- [9] Anissa Ollivia Cahya Pratiwi, "Klasifikasi Jenis Anggur Berdasarkan Bentuk Daun Menggunakan Convolutional Neural Network Dan K-Nearest Neighbor," *J. Ilm. Tek. Inform. dan Komun.*, vol. 3, no. 2, pp. 201–224, 2023, doi: 10.55606/juitik.v3i2.535.
- [10] E. FAKULTAS, *analisis penyakit pohon pisang menggunakan metode convolutional neural network.pdf*. 2024. [Online]. Available: <https://repository.usni.ac.id/repository/c6ce37081f5e28cfbdbbee31a71ef5958.pdf>
- [11] N. L. Firda Ekayanti, F. Megawati, and N. L. K. A. Anita Dewi, "PEMANFAATAN TANAMAN PISANG (Musa Paradisiaca L.) SEBAGAI SEDIAAN KOSMETIK," *Usadha*, vol. 2, no. 2, pp. 19–24, 2023, doi: 10.36733/usadha.v2i2.6217.
- [12] J. Amara, B. Bouaziz, and A. Algergawy, "A deep learning-based approach for banana leaf diseases classification," *Lect. Notes Informatics (LNI), Proc. - Ser. Gesellschaft fur Inform.*, vol. 266, pp. 79–88, 2017.
- [13] I. Nihatul Husna, M. Ulum, A. Kurniawan Saputro, D. Tri Laksono, and D. Neipa Purnamasari, "Rancang Bangun Sistem Deteksi Dan Perhitungan Jumlah Orang Menggunakan Metode Convolutional Neural Network (CNN)," *Semin. Nas. Fortei Reg.*, vol. 7, pp. 1–6, 2022.
- [14] A. W. Suryanto and A. R. Kardian, "Deteksi Pelanggaran Lalu Lintas Tidak Menggunakan Helm Dengan YOLO V4 Pada Sistem ETLE," *J. Tek. Komput.*, vol. 9, no. 2, pp. 129–134, 2023, doi: 10.31294/jtk.v9i2.14798.

- [15] N. Aziz, N. Minallah, J. Frnda, M. Sher, M. Zeeshan, and A. H. Durrani, "Precision meets generalization: Enhancing brain tumor classification via pretrained DenseNet with global average pooling and hyperparameter tuning," *PLoS One*, vol. 19, no. 9, pp. 1–16, 2024, doi: 10.1371/journal.pone.0307825.
- [16] S. Yuliany, Aradea, and Andi Nur Rachman, "Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN)," *J. Buana Inform.*, vol. 13, no. 1, pp. 54–65, 2022, doi: 10.24002/jbi.v13i1.5022.
- [17] A. B. Prakosa, Hendry, and R. Tanone, "Implementasi Model Deep Learning Convolutional Neural Network (CNN) Pada Citra Penyakit Daun Jagung Untuk Klasifikasi Penyakit Tanaman," *J. Pendidik. Teknol. Inf.*, vol. 6, no. 1, pp. 107–116, 2023.
- [18] A. Jinan, B. H. Hayadi, and U. P. Utama, "Klasifikasi Penyakit Tanaman Padi Menggunakan Metode Convolutional Neural Network Melalui Citra Daun (Multilayer Perceptron)," *J. Comput. Eng. Sci.*, vol. 1, no. 2, pp. 37–44, 2022.
- [19] A. J. Rozaqi, A. Sunyoto, and M. rudyanto Arief, "Deteksi Penyakit Pada Daun Kentang Menggunakan Pengolahan Citra dengan Metode Convolutional Neural Network," *Creat. Inf. Technol. J.*, vol. 8, no. 1, p. 22, 2021, doi: 10.24076/citec.2021v8i1.263.
- [20] J. S. Iskandar and R. P. Kristianto, "Pengenalan dan Klasifikasi Ragam Kue Indonesia menggunakan Arsitektur ResNet50V2 pada Convolutional Neural Network (CNN)," no. November, pp. 81–92, 2023.
- [21] E. A. N. Munfaati and A. Witanti, "Klasifikasi Buah dan Sayuran Segar atau Busuk Menggunakan Convolutional Neural Network," *JISKA (Jurnal Inform. Sunan Kalijaga)*, vol. 9, no. 1, pp. 27–38, 2024, doi: 10.14421/jiska.2024.9.1.27-38.
- [22] A. Zalvadila, "Klasifikasi Penyakit Tanaman Bawang Merah Menggunakan Metode SVM dan CNN," *J. Inform. J. Pengemb. IT*, vol. 8, no. 3, pp. 255–260, 2023, doi: 10.30591/jpit.v8i3.5341.
- [23] R. Mardianto, Stefanie Quinevera, and S. Rochimah, "Perbandingan Metode Random Forest, Convolutional Neural Network, dan Support Vector Machine Untuk Klasifikasi Jenis Mangga," *J. Appl. Comput. Sci. Technol.*, vol. 5, no. 1, pp. 63–71, 2024, doi: 10.52158/jacost.v5i1.742.