

Implementasi Klasifikasi Citra Berbasis Tensorflow Untuk Mendeteksi Penyakit Tanaman Pada Aplikasi Agroscan

Jenny Rahma Hidayah¹, Jemakmun²

^{1,2}Teknik Informatika, Sains Teknologi, Universitas Bina Darma

1211420044@student.binadarma.ac.id*, jemakmun@binadarma.ac.id

Abstract

Identifying plant diseases is something that can affect productivity and sustainability of agricultural crops. This study utilizes the Convolutional Neural Network (CNN) algorithm with the aim of developing the Agroscan application to identify plant diseases. The method used is collecting datasets consisting of leaf images in various types of plants, such as peppers, potatoes, and tomatoes that have been infected with various diseases. The CNN model was trained using the PlantVillage dataset, which consists of 20,638 images, and was able to achieve a training accuracy of 97.30% and a validation accuracy of 95.02%. The results of the study prove that CNN is effective in identifying plant diseases, with the aim of increasing crop yields and supporting sustainable agriculture.

Keywords: artificial intelligence, machine learning, plant disease detection, convolutional neural network, agroscan application.

Abstrak

Mengidentifikasi penyakit pada tanaman merupakan hal yang dapat mempengaruhi produktivitas dan keberlanjutan hasil panen di bidang pertanian. Penelitian ini memanfaatkan algoritma *Convolutional Neural Network (CNN)* dengan tujuan mengembangkan aplikasi Agroscan untuk mengidentifikasi penyakit pada tanaman. Metode yang digunakan berupa pengumpulan *dataset* yang terdiri dari gambar daun di berbagai jenis tanaman, seperti paprika, kentang, dan tomat yang telah terinfeksi berbagai penyakit. Model CNN dilatih dengan menggunakan *dataset PlantVillage*, yang terdiri dari 20.638 citra, dan mampu mencapai akurasi pelatihan sebesar 97,30% serta akurasi validasi sebesar 95,02%. Hasil penelitian membuktikan bahwa CNN efektif dalam mengidentifikasi penyakit pada tanaman, dengan tujuan untuk meningkatkan hasil panen dan mendukung pertanian berkelanjutan.

Kata Kunci: kecerdasan buatan, pembelajaran mesin, deteksi penyakit tanaman, *convolutional neural network*, aplikasi agroscan.

©This work is licensed under a Creative Commons Attribution - ShareAlike 4.0 International License

1. Pendahuluan

Teknologi kecerdasan buatan (*Artificial Intelligence/AI*) dan pembelajaran mesin (*Machine Learning/ML*) telah membawa perubahan besar di berbagai sektor, termasuk pertanian. Penerapan AI dan ML di bidang ini berkontribusi signifikan terhadap peningkatan efisiensi, produktivitas, serta mendukung praktik pertanian presisi yang berkelanjutan. Menurut penelitian Syarovy, Nugroho, dan Sutiarso (2023), integrasi jaringan saraf tiruan dalam sistem pertanian presisi dapat meningkatkan hasil produksi sekaligus menekan risiko kegagalan panen [1]. Dengan kemampuan menganalisis data besar dan mengenali pola kompleks, AI membuka peluang besar untuk mengatasi tantangan utama dalam sektor pertanian, termasuk perubahan iklim, manajemen hama, dan deteksi dini penyakit tanaman. *Artificial Intelligence (AI)* merupakan cabang ilmu komputer yang mengembangkan sistem cerdas yang meniru cara berpikir manusia. Dengan AI, mesin dapat

menjalankan tugas secara cerdas layaknya manusia, dan bidang ini terus berkembang dalam dunia teknologi [2].

Salah satu permasalahan krusial dalam pertanian adalah penyakit tanaman yang tidak terdeteksi sejak dini. Penyakit yang terlambat teridentifikasi dapat menyebabkan kerugian besar, baik secara ekonomi maupun terhadap ketahanan pangan nasional. Metode deteksi penyakit secara manual, seperti inspeksi visual oleh ahli pertanian, membutuhkan waktu, biaya, dan keterampilan khusus yang tidak selalu tersedia, terutama di daerah terpencil dengan keterbatasan sumber daya. Kesalahan dalam deteksi dini penyakit tanaman dapat memperburuk tingkat kerusakan dan menurunkan hasil produksi. Oleh karena itu, diperlukan solusi teknologi yang efektif, efisien, dan dapat diakses secara luas untuk membantu petani dalam proses deteksi penyakit tanaman.

Deep Learning, khususnya *Convolutional Neural Network* (CNN), telah terbukti efektif dalam tugas pengolahan citra, termasuk untuk mendeteksi penyakit tanaman melalui analisis gambar daun [3]. CNN dikenal sebagai salah satu pendekatan yang paling umum dan efektif dalam implementasi *deep learning* [4]. CNN mampu secara otomatis mengekstraksi fitur penting dari gambar tanpa memerlukan teknik ekstraksi fitur manual, sehingga mempercepat proses klasifikasi dan meningkatkan akurasi. Dengan pendekatan ini, deteksi penyakit tanaman dapat dilakukan lebih cepat dan akurat, bahkan dengan menggunakan perangkat sederhana seperti kamera ponsel.

Dalam penelitian ini, dikembangkan sebuah model klasifikasi penyakit tanaman berbasis CNN dengan menggunakan arsitektur *InceptionV3*. *InceptionV3* dipilih karena kemampuannya dalam menangkap fitur multi-skala secara efisien serta performanya yang tinggi pada tugas klasifikasi gambar. Model dikembangkan melalui metode *transfer learning*, dengan memanfaatkan bobot pralatih dari *ImageNet*, sehingga mempercepat proses pelatihan meskipun dataset yang digunakan relatif lebih kecil. Dataset *PlantVillage* digunakan sebagai sumber data, yang menyediakan citra daun dari berbagai jenis tanaman sehat dan yang terinfeksi penyakit [5].

Pra-pemrosesan dilakukan dengan melakukan *resize* citra menjadi ukuran 128×128 piksel dan normalisasi piksel dari rentang $[0,255]$ menjadi sekitar $[-1,1]$. Model kemudian dikembangkan dengan menambahkan lapisan-lapisan kustom di atas arsitektur *InceptionV3* untuk mengklasifikasikan 15 kelas penyakit tanaman. Selanjutnya, model dilatih menggunakan optimizer *RMSProp* dan *loss function categorical crossentropy*, dengan penerapan mekanisme *early stopping* untuk menghindari *overfitting*.

Ruang lingkup penelitian ini difokuskan pada tahap pembuatan dan evaluasi model klasifikasi penyakit tanaman. Model yang telah dikembangkan disimpan dalam format yang siap untuk diintegrasikan ke dalam aplikasi *AgroScan*. Tahapan integrasi model ke platform mobile, pengembangan antarmuka pengguna, serta pengujian aplikasi di lingkungan nyata dilakukan oleh anggota tim pengembang aplikasi, dan tidak menjadi bagian dari cakupan pembahasan dalam artikel ini.

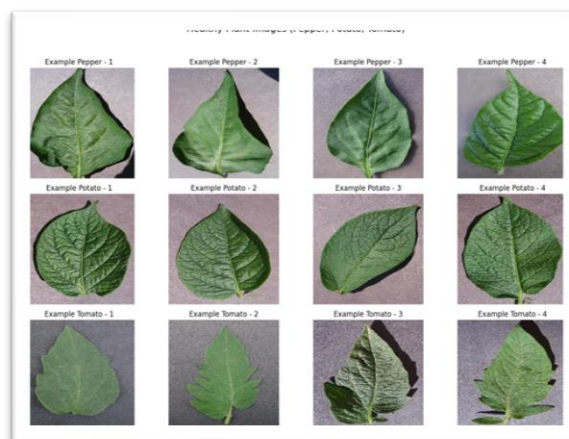
2. Metode Penelitian

Penelitian ini bertujuan untuk mendeteksi dan mengklasifikasikan penyakit pada tanaman menggunakan pendekatan *Machine Learning berbasis Transfer Learning*. *Transfer learning* merupakan pendekatan dalam *machine learning* yang memanfaatkan pengetahuan yang telah dipelajari dari suatu tugas untuk meningkatkan performa model dalam menyelesaikan tugas lain yang masih berkaitan. Model yang dikembangkan memanfaatkan arsitektur *Convolutional Neural Network* (CNN) dengan

menggunakan model pra-latih (*pre-trained model*) *InceptionV3*. Tahapan metode penelitian dijelaskan sebagai berikut:

2.1. Pemilihan Dataset

Dataset adalah sekumpulan data yang dapat digunakan sebagai bahan percobaan dalam penelitian [6]. Untuk memastikan metode *deep learning* dapat menjalankan tugasnya secara akurat, diperlukan *dataset* sebagai sumber informasi yang digunakan model dalam proses belajar dan penentuan keputusan [7]. Pada penelitian ini, *dataset* yang digunakan berasal dari *Kaggle*, sebuah sumber resmi yang menyediakan citra tanaman seperti cabai, tomat, dan kentang. *Dataset* yang digunakan dalam penelitian ini terdiri dari 20.638 citra tanaman yang terbagi ke dalam 15 kelas, mencakup tanaman sehat dan berbagai jenis penyakit. *Dataset* ini diperoleh dari sumber resmi yang menyediakan citra tanaman, seperti cabai, tomat, dan kentang. Untuk pelatihan model, sebanyak 16.511 citra digunakan sebagai data pelatihan, sementara 4.127 citra dialokasikan untuk data validasi. Pembagian ini bertujuan untuk memastikan bahwa model dapat belajar dengan baik dari data pelatihan dan diuji dengan data yang tidak pernah dilihat sebelumnya selama pelatihan. Seluruh citra dalam dataset diubah ukurannya menjadi 128×128 piksel dengan format RGB tiga kanal untuk memastikan keseragaman ukuran input pada model CNN. Dengan cara ini, model diharapkan dapat generalisasi dengan baik pada data baru.



Gambar 2.1 *Dataset PlantVillage*

2.2. Pra-pemrosesan Data

Setelah data diperoleh, langkah berikutnya adalah melakukan pra-pemrosesan guna mempersiapkan data sebelum digunakan dalam proses pelatihan model. Pra-pemrosesan data bertujuan untuk menyesuaikan format citra sehingga dapat diproses secara optimal oleh arsitektur CNN saat dimasukkan ke dalam model [8].

Tahapan ini mencakup berbagai proses penting, seperti:

a. Pemuatan dan *Resize* Gambar: Dalam tahap pra-pemrosesan data, seluruh citra daun tanaman dari *dataset PlantVillage* diubah ukurannya menjadi dimensi 128×128 piksel. *Resize* ini bertujuan untuk menyeragamkan ukuran semua gambar sehingga sesuai dengan kebutuhan input model *Convolutional Neural Network* (CNN) berbasis *InceptionV3*, yang mengharuskan dimensi *input* tetap dan konsisten. Selain itu, proses *resize* membantu mengurangi beban komputasi, mempercepat proses pelatihan, dan memastikan bahwa model dapat fokus pada fitur-fitur penting dari gambar tanpa dipengaruhi oleh variasi ukuran aslinya. Dengan citra yang seragam, model menjadi lebih efisien dalam mengenali pola-pola visual yang berkaitan dengan kondisi tanaman.

b. Normalisasi Data: Setelah gambar diubah ukurannya menjadi 128×128 piksel, setiap piksel citra dinormalisasi dengan mengubah skala nilainya dari rentang $[0, 255]$ menjadi rentang sekitar $[-1, 1]$. Proses normalisasi ini bertujuan untuk menyesuaikan distribusi nilai input agar lebih optimal untuk jaringan saraf dalam, sehingga dapat mempercepat proses pelatihan, meningkatkan stabilitas model, serta mencegah permasalahan seperti *vanishing gradient*. Dengan normalisasi ini, model dapat melakukan pembelajaran dari citra secara lebih efisien dan mencapai akurasi yang lebih tinggi.

c. Pembagian *Dataset*: *Dataset* dibagi menjadi tiga bagian utama. Sebanyak 80% dari data digunakan untuk data pelatihan, sementara 20% sisanya awalnya dialokasikan sebagai data validasi. Kemudian, dari data validasi tersebut, sekitar 20% dipisahkan kembali untuk membentuk data pengujian. Dengan demikian, komposisi akhir *dataset* adalah sekitar 80% untuk pelatihan, 16% untuk validasi, dan 4% untuk pengujian. Pembagian ini bertujuan untuk memastikan bahwa model dapat belajar secara efektif dari data yang cukup banyak serta dapat dievaluasi kinerjanya menggunakan data yang belum pernah dilihat selama pelatihan.

2.3. Pengembangan Model

Pengembangan model klasifikasi citra dilakukan dengan langkah-langkah berikut:

a. Pemilihan Arsitektur Model: Pada penelitian ini, arsitektur model yang dipilih adalah *InceptionV3*, sebuah model *pre-trained* yang terbukti efektif dalam tugas klasifikasi citra, termasuk citra tanaman. *InceptionV3* merupakan pengembangan dari *GoogleNet (Inception-v1)* yang dilengkapi dengan *batch normalization* dan faktorisasi konvolusi untuk mengurangi jumlah parameter tanpa menurunkan kinerja, sehingga lebih efisien dan stabil dalam proses pelatihan [9]. Pemilihan *InceptionV3* didasarkan pada sejumlah keunggulan dibandingkan model CNN lain seperti *ResNet*, *VGG16*, dan *EfficientNet*.

Salah satu alasan utama pemilihannya adalah kemampuannya dalam menangkap fitur dengan efisien

melalui penggunaan *Inception Module*, yang memungkinkan pemrosesan berbagai ukuran kernel konvolusi secara paralel dalam satu lapisan. Keunggulan ini sangat penting untuk deteksi penyakit tanaman, yang seringkali memiliki variasi bentuk dan tekstur yang kompleks.

Dibandingkan dengan *VGG16*, *InceptionV3* jauh lebih efisien secara komputasi karena menggunakan teknik *factorized convolutions* untuk mengurangi jumlah parameter tanpa mengorbankan akurasi. Dibandingkan dengan *ResNet*, yang mengandalkan *skip connections* untuk mengatasi *vanishing gradient*, *InceptionV3* menawarkan pendekatan arsitektural berbeda yang fokus pada efisiensi ekstraksi fitur multi-skala, meskipun secara kompleksitas struktur keduanya relatif sebanding.

Meskipun *EfficientNet* dikenal memiliki efisiensi tinggi dan performa unggul pada *benchmark modern*, *InceptionV3* menawarkan keseimbangan yang lebih baik antara akurasi, efisiensi komputasi, dan kebutuhan sumber daya, terutama dalam konteks *dataset* berukuran sedang seperti *PlantVillage*.

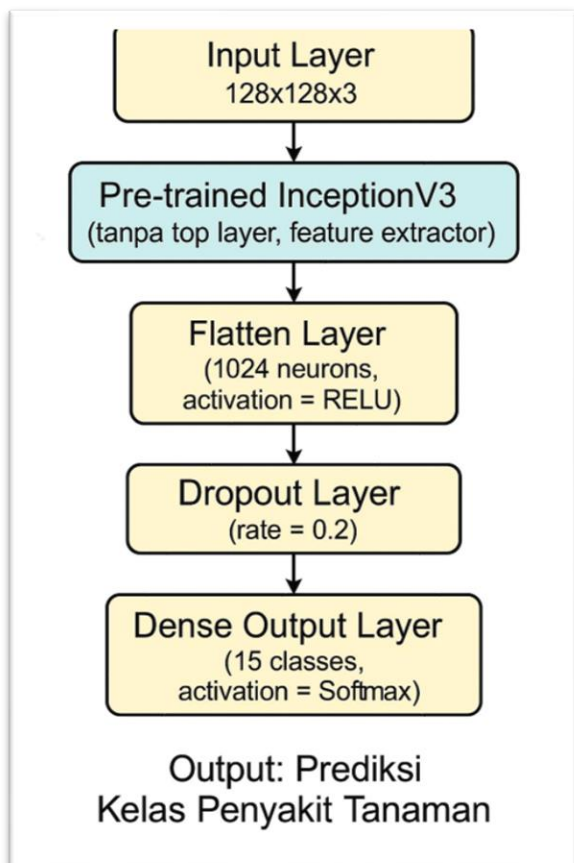
Selain itu, karena *InceptionV3* sudah dilatih pada *dataset* besar seperti *ImageNet*, model ini mendukung penerapan *transfer learning* yang kuat, sehingga memungkinkan adaptasi yang cepat pada tugas klasifikasi baru dengan kebutuhan pelatihan tambahan yang minimal.

Dengan mempertimbangkan kemampuan ekstraksi fitur yang efisien, stabilitas dalam proses *transfer learning*, serta keseimbangan performa dan komputasi, *InceptionV3* dipilih sebagai arsitektur yang paling optimal untuk mendeteksi penyakit tanaman dalam penelitian ini.

b. Pelatihan Model: Model dilatih menggunakan *dataset* yang telah melalui tahap pra-pemrosesan, meliputi *resize* gambar dan normalisasi piksel. *Dataset* dibagi menjadi data pelatihan 80%, validasi 16%, dan pengujian 4%. Proses pelatihan dijalankan hingga maksimal 50 *epoch* dengan pemantauan akurasi dan *loss* pada data pelatihan serta validasi. Untuk mencegah *overfitting*, diterapkan mekanisme *Early Stopping* yang menghentikan pelatihan lebih awal ketika akurasi pelatihan mencapai 99,5%. *Early Stopping* merupakan teknik dalam *machine learning* yang digunakan untuk menghentikan proses pelatihan model lebih awal guna menghindari terjadinya *overfitting* [10]. Selama pelatihan, perkembangan performa model dianalisis melalui grafik akurasi dan *loss*.

c. Evaluasi Model: Untuk menilai kinerja model, dilakukan pemantauan terhadap metrik akurasi dan *loss* selama proses pelatihan menggunakan data validasi yang tidak digunakan dalam proses pelatihan langsung. Akurasi dan *loss* pada data pelatihan dan validasi dianalisis untuk mengevaluasi sejauh mana model mampu belajar dan menggeneralisasi dengan baik terhadap data baru. Selain itu, hasil pelatihan

divisualisasikan dalam bentuk grafik perkembangan akurasi dan loss. Meskipun dalam penelitian ini belum dilakukan perhitungan metrik tambahan seperti presisi, *recall*, dan *F1-score*, pemantauan akurasi validasi digunakan sebagai acuan utama untuk menilai performa model.



Gambar 2.2 Arsitektur Model Agroscan

2.4. Pengembangan Model

Setelah model terlatih, langkah selanjutnya adalah mengimplementasikan model ke dalam aplikasi Agroscan. Proses ini meliputi:

a. Pengembangan Antarmuka Pengguna: Mendesain antarmuka aplikasi yang intuitif dan mudah digunakan oleh petani. Antarmuka ini dirancang agar pengguna dapat dengan mudah mengunggah citra tanaman dan menerima hasil deteksi penyakit dalam waktu singkat. Desain antarmuka mempertimbangkan aspek *usability*, sehingga petani yang tidak memiliki latar belakang teknis dapat dengan mudah memahami cara menggunakan aplikasi.

b. Integrasi Model: Mengintegrasikan model klasifikasi yang telah dilatih ke dalam aplikasi, sehingga aplikasi dapat melakukan prediksi secara *Real-Time*. Proses ini melibatkan pengujian model dalam lingkungan aplikasi untuk memastikan bahwa model dapat memberikan hasil yang akurat dan cepat.

c. Pengujian Aplikasi: Melakukan pengujian aplikasi guna memastikan setiap fitur beroperasi dengan baik dan hasil deteksi yang dihasilkan akurat. Pengujian ini mencakup aspek fungsionalitas, performa, serta keamanan aplikasi. Proses uji coba dilakukan dengan menggunakan berbagai gambar tanaman untuk memastikan aplikasi mampu menangani beragam kondisi yang mungkin dialami oleh pengguna.

2.5. Pengujian

Pengujian dilakukan untuk mengevaluasi performa model *Convolutional Neural Network* (CNN) yang telah dikembangkan dalam mengklasifikasikan citra daun tanaman berdasarkan kondisi kesehatannya. Pengujian ini bertujuan untuk mengukur efektivitas dan efisiensi model dalam menghasilkan klasifikasi yang akurat.

Model dilatih dan diuji menggunakan dataset yang telah dibagi dengan rasio 80% data latih dan 20% data uji, menggunakan fungsi `train_test_split`. Arsitektur CNN yang diterapkan terdiri atas beberapa lapisan konvolusi (*Conv2D*), *pooling* (*MaxPooling2D*), dan dropout untuk mencegah *overfitting*, serta diakhiri dengan lapisan *fully connected* (*Dense*) yang menggunakan fungsi aktivasi *softmax* untuk klasifikasi multi-kelas. Selama pelatihan, digunakan fungsi aktivasi ReLU, optimizer Adam, dan fungsi *loss* categorical *crossentropy*.

Selain itu, diterapkan teknik *EarlyStopping* selama pelatihan untuk menghentikan proses secara otomatis saat performa model pada data validasi tidak lagi meningkat, guna menghindari *overfitting*. Model dilatih selama maksimum 50 *epoch* dengan ukuran batch sebesar 32, dan performa dievaluasi pada setiap *epoch*.

Hasil pengujian menunjukkan bahwa model CNN yang dibangun mampu menghasilkan akurasi yang tinggi dan performa klasifikasi yang stabil di semua kelas, yang menunjukkan bahwa pendekatan ini efektif untuk tugas klasifikasi citra daun tanaman.

3. Hasil dan Pembahasan

Penelitian ini bertujuan membangun model klasifikasi citra penyakit tanaman menggunakan pendekatan deep learning berbasis *Convolutional Neural Network* (CNN) dengan memanfaatkan *transfer learning*. Model dikembangkan menggunakan arsitektur *InceptionV3* yang telah dilatih sebelumnya pada *dataset ImageNet*. Fokus dari pengembangan model adalah untuk mengklasifikasikan 15 kelas penyakit tanaman berdasarkan citra daun berukuran 128x128 piksel dalam format RGB.

3.1. Spesifikasi Arsitektur

Model dikembangkan berdasarkan arsitektur *InceptionV3*, sebuah CNN dalam-dalam (*deep CNN*) yang terdiri dari sekitar 48 lapisan utama. *InceptionV3* dirancang untuk efisiensi dan akurasi tinggi dalam

klasifikasi citra, dan menggabungkan Inception Module, yaitu blok konvolusi paralel dengan ukuran kernel 1×1, 3×3, dan 5×5, serta *max pooling*. Modul ini membantu menangkap fitur pada berbagai skala secara bersamaan.

Pada penelitian ini, model tidak menggunakan *top layer* (*fully connected* bawaan *InceptionV3*). Sebagai gantinya, arsitektur dilanjutkan dengan lapisan-lapisan kustom berikut:

- a. *Flatten Layer*: mengubah output tensor dari *InceptionV3* menjadi vektor 1 dimensi.
- b. *Dense Layer*: 1024 *neuron*, dengan fungsi aktivasi *ReLU*.
- c. *Dropout Layer*: dengan rate 0.2 untuk regularisasi, mencegah *overfitting*.
- d. *Dense Output Layer*: 15 neuron (jumlah kelas), dengan aktivasi *Softmax* untuk menghasilkan probabilitas klasifikasi.

3.2. Pelatihan Model

Model dilatih selama 6 *epoch* menggunakan optimizer Adam dengan *learning rate* 0.0001 dan *batch size* 32, selama maksimal 50 *epoch*. Proses pelatihan dihentikan lebih awal oleh mekanisme *early stopping* setelah akurasi validasi tidak mengalami peningkatan signifikan, guna mencegah *overfitting*. Tabel berikut merangkum hasil akurasi dan *loss* pada data pelatihan dan validasi:

Tabel 3. 1 Hasil Akurasi dan Loss

| Epoch | Akurasi | Akurasi Validasi | Loss Pelatihan | Loss Validasi |
|-------|---------|------------------|----------------|---------------|
| 1 | 65.23% | 83.98% | 8.6046 | 5.9343 |
| 2 | 89.86% | 90.90% | 3.4281 | 2.1017 |
| 3 | 92.40% | 93.10% | 1.9023 | 1.2219 |
| 4 | 95.00% | 94.20% | 0.9012 | 0.6623 |
| 5 | 96.45% | 94.80% | 0.5044 | 0.5113 |
| 6 | 97.30% | 95.02% | 0.3875 | 0.4019 |

Proses pelatihan ini divisualisasikan dalam log hasil training dan grafik akurasi serta loss berikut:

```
Epoch 1/10
WARNING:tensorflow: From c:\Users\LENOVO\AppData\Local\Programs\Python\Python311\Lib\site-packages\tensorflow\src\util\tf_util.py:482: The name tf.nn.conv2d is deprecated. Please use tf.nn.conv2d_v2 instead.

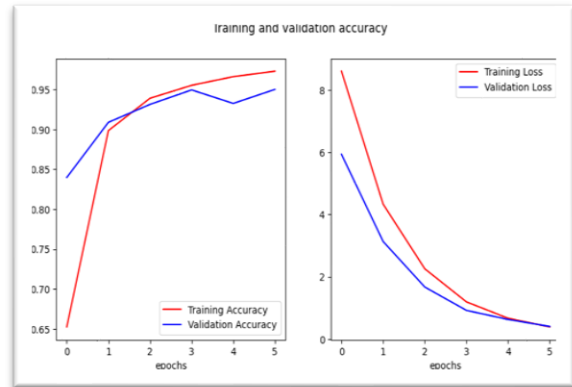
WARNING:tensorflow: From c:\Users\LENOVO\AppData\Local\Programs\Python\Python311\Lib\site-packages\tensorflow\src\ops\conv_ops.py:384: The name tf.nn.conv2d is deprecated. Please use tf.nn.conv2d_v2 instead.

250/250 [=====] - 520s 2s/step - loss: 8.6046 - accuracy: 0.6523 - val_loss: 5.9343 - val_accuracy: 0.8398
Epoch 2/10
250/250 [=====] - 483s 2s/step - loss: 4.3316 - accuracy: 0.8986 - val_loss: 3.1317 - val_accuracy: 0.9090
Epoch 3/10
250/250 [=====] - 514s 2s/step - loss: 2.2542 - accuracy: 0.9391 - val_loss: 1.6684 - val_accuracy: 0.9314
Epoch 4/10
250/250 [=====] - 474s 2s/step - loss: 1.1995 - accuracy: 0.9554 - val_loss: 0.9177 - val_accuracy: 0.9496
Epoch 5/10
250/250 [=====] - 492s 2s/step - loss: 0.6635 - accuracy: 0.9662 - val_loss: 0.6268 - val_accuracy: 0.9325
Epoch 6/10
250/250 [=====] - 574s 2s/step - loss: 0.3875 - accuracy: 0.9730 - val_loss: 0.4019 - val_accuracy: 0.9502
Validation accuracy exceeded threshold. Stopping training!
250/250 [=====] - 538s 2s/step - loss: 0.3875 - accuracy: 0.9730 - val_loss: 0.4019 - val_accuracy: 0.9502
```

Gambar 3.1 Log hasil pelatihan model tiap epoch

Log ini menampilkan nilai akurasi dan *loss* pada setiap *epoch* selama pelatihan. Terlihat bahwa akurasi pelatihan meningkat signifikan sejak awal, dan model mencapai akurasi validasi optimal sebesar 95.02% pada

epoch ke-6, saat proses pelatihan dihentikan secara otomatis.



Gambar 3.2 Grafik akurasi dan loss model

Grafik kiri menunjukkan tren peningkatan akurasi pelatihan dan validasi yang cenderung sejalan, menandakan proses pembelajaran yang efektif dan stabil. Grafik kanan menunjukkan penurunan loss yang konsisten pada kedua data, mengindikasikan bahwa model berhasil belajar dengan baik tanpa mengalami *overfitting*.

3.3. Evaluasi

Evaluasi dilakukan untuk mengukur sejauh mana model CNN yang dikembangkan mampu mengklasifikasikan gambar daun tanaman secara akurat ke dalam 15 kelas penyakit. Arsitektur model menggunakan pendekatan *transfer learning* dengan memanfaatkan *InceptionV3* sebagai *feature extractor*, tanpa lapisan klasifikasi akhir (*top layer*). Di atasnya ditambahkan beberapa lapisan khusus, yaitu *Flatten Layer*, *Dense Layer* dengan 1024 *neuron* dan aktivasi *ReLU*, diikuti oleh *dropout Layer* dengan rate 0.2 sebagai teknik regularisasi untuk mencegah *overfitting*, dan diakhiri dengan *dense output layer* sebanyak 15 neuron menggunakan aktivasi *Softmax*.

Evaluasi model dilakukan dengan memantau tiga metrik utama, yaitu akurasi, *loss*, dan *confusion matrix*. Akurasi digunakan untuk mengukur sejauh mana prediksi model sesuai dengan label sebenarnya, sedangkan *loss* menunjukkan seberapa besar kesalahan prediksi model dibandingkan dengan label yang benar. Sementara itu, *confusion matrix* memberikan informasi yang lebih detail tentang distribusi kesalahan dan keberhasilan klasifikasi pada masing-masing kelas penyakit.

Hasil pelatihan menunjukkan bahwa model mengalami peningkatan performa yang konsisten dalam setiap *epoch*. Pada *epoch* pertama, akurasi pelatihan masih berada pada angka 65,23%, sedangkan akurasi validasi sudah relatif tinggi yaitu 83,98%. Seiring berjalannya pelatihan, performa model meningkat secara signifikan. Pada *epoch* ke-6, model mencapai akurasi pelatihan sebesar 97,30% dan akurasi validasi sebesar 95,02%. Nilai *loss* pada pelatihan turun menjadi 0,3875, sedangkan pada validasi menjadi 0,4019,

menunjukkan konvergensi model yang stabil dan tidak mengalami *overfitting*.

Analisis terhadap *confusion matrix* menunjukkan bahwa sebagian besar kelas dapat diklasifikasikan dengan sangat baik oleh model. Namun, terdapat beberapa kelas penyakit yang masih sering tertukar, khususnya kelas dengan gejala visual yang sangat mirip, seperti antara penyakit Early Blight dan Late Blight pada tomat. Hal ini menunjukkan bahwa meskipun model telah menunjukkan performa yang tinggi, masih terdapat ruang untuk perbaikan lebih lanjut terutama dengan menambahkan augmentasi data visual atau teknik pelatihan lanjutan seperti fine-tuning yang lebih mendalam.

Secara keseluruhan, hasil evaluasi membuktikan bahwa arsitektur CNN yang dibangun efektif dalam mendeteksi dan mengklasifikasikan penyakit tanaman berdasarkan gambar daun. Dengan akurasi validasi yang tinggi dan hasil evaluasi metrik yang baik, model ini menunjukkan potensi kuat untuk diterapkan dalam sistem pendeteksian penyakit tanaman secara otomatis dan efisien.

3.4. Hasil Aplikasi

Model *Convolutional Neural Network* (CNN) yang dikembangkan diintegrasikan ke dalam aplikasi prototipe Agroscan untuk memvalidasi performa model dalam penggunaan nyata. Aplikasi ini menerima input citra daun, memprosesnya dengan model CNN, dan menampilkan hasil klasifikasi secara langsung.

Pengujian menggunakan citra daun baru menunjukkan bahwa hasil prediksi Agroscan konsisten dengan evaluasi sebelumnya, membuktikan stabilitas dan akurasi model. Aplikasi menampilkan label penyakit beserta tingkat keyakinannya, sehingga memudahkan pengguna memperoleh informasi secara cepat dan tepat.



Gambar 3. 3 Hasil klasifikasi daun di Agroscan

Gambar 3.3 memperlihatkan antarmuka aplikasi Agroscan saat memproses citra daun dan menampilkan hasil klasifikasi. Tampilan ini menggambarkan bahwa model CNN yang digunakan tidak hanya unggul secara kuantitatif dalam pengujian laboratorium, tetapi juga siap digunakan dalam konteks aplikasi praktis di bidang pertanian. Antarmuka sederhana dan waktu respon yang cepat menjadikan Agroscan sebagai sarana yang potensial untuk membantu petani dan penyuluh pertanian dalam mengenali kondisi daun secara dini.

Dengan keberhasilan integrasi model CNN ke dalam aplikasi Agroscan, dapat disimpulkan bahwa solusi ini tidak hanya efektif dalam konteks penelitian, tetapi juga relevan untuk diadopsi dalam skala operasional guna meningkatkan efisiensi deteksi penyakit tanaman berbasis teknologi.

4. Kesimpulan

Penelitian ini bertujuan untuk mengembangkan dan mengimplementasikan model klasifikasi citra berbasis *TensorFlow* untuk mendeteksi penyakit tanaman pada aplikasi *Agroscan*. Model dibangun menggunakan arsitektur *Convolutional Neural Network* (CNN) dengan pendekatan transfer learning melalui *InceptionV3*. Hasil pelatihan menunjukkan bahwa model mampu mengklasifikasikan citra daun tanaman ke dalam 15 kelas dengan akurasi validasi sebesar 95.02% dan tanpa tanda *overfitting*, meskipun dilatih tanpa augmentasi data.

Model ini menunjukkan bahwa klasifikasi penyakit tanaman secara otomatis dapat dilakukan dengan akurasi tinggi menggunakan arsitektur yang efisien dan struktur model yang relatif ringan. Dengan performa yang stabil dan presisi yang tinggi, model ini memiliki potensi untuk diterapkan dalam sistem berbasis mobile atau cloud untuk membantu petani dan pengguna akhir dalam mendiagnosis penyakit tanaman secara cepat dan mandiri.

Aplikasi model ini dalam *platform Agroscan* menunjukkan bahwa teknologi klasifikasi citra berbasis deep learning dapat diintegrasikan secara praktis ke dalam solusi pertanian berbasis digital. Implikasi dari penelitian ini adalah terbukanya peluang pemanfaatan kecerdasan buatan dalam meningkatkan produktivitas dan efisiensi di sektor pertanian.

Sebagai pengembangan lanjutan, model ini dapat ditingkatkan melalui penerapan teknik augmentasi data, evaluasi menggunakan metrik klasifikasi yang lebih lengkap seperti *precision*, *recall*, dan *F1-score*, serta pengujian pada data lapangan untuk menilai kinerja dalam kondisi nyata.

Daftar Rujukan

- [1] M. Syarovy, A. P. Nugroho, and L. Sutiarso, "Pemanfaatan Model Neural Network Dalam Generasi Baru Pertanian Presisi Di Perkebunan Kelapa Sawit," *WARTA Pusat Penelitian Kelapa Sawit*, vol. 28, no. 1, pp. 39-54, 2023.

-
- [2] M. Muchlis, "PENGGUNAAN ARTIFICIAL INTELLIGENCE (AI) DALAM PEMBELAJARAN PENDIDIKAN AGAMA ISLAM: MANFAAT DAN TANTANGAN," *Kreatif: Jurnal Pemikiran Pendidikan Agama Islam*, vol. 23, no. 1, pp. 100–109, 2025.
- [3] S. A. Bukhari, "IMPLEMENTASI METODE CONVOLUTIONAL NEURAL NETWORK (CNN) UNTUK DIAGNOSA PENYAKIT TANAMAN CABAI PADA CITRA DAUN," *Kohesi: Jurnal Multidisiplin Sainstek*, 2024, [Online]. Available: <https://ejournal.warunayama.org/kohesi>
- [4] Mochammad Toyib, Tegar Decky Kurniawan Pratama, and Ibnu Aqil, "Penerapan Algoritma CNN Untuk Mendeteksi Tulisan Tangan Angka Romawi dengan Augmentasi Data," *Algoritma : Jurnal Matematika, Ilmu pengetahuan Alam, Kebumihan dan Angkasa*, vol. 2, no. 3, pp. 108–120, May 2024, doi: 10.62383/algoritma.v2i3.69.
- [5] Y. F. Rachman, P. Susanti, A. B. R. P. A. Putra, and N. I. Rahmawati, "Sistem Informasi Deteksi Penyakit Pada Tanaman Padi (Brown Spot, Hispa, Leaf Blast) Menggunakan Metode Convolutional Neural Network (CNN)," *Decode: Jurnal Pendidikan Teknologi Informasi*, vol. 4, no. 3, pp. 1193–1204, Nov. 2024, doi: 10.51454/decode.v4i3.846.
- [6] D. Iskandar Mulyana and A. Akbar, "OPTIMASI KLASIFIKASI BATIK BETAWI MENGGUNAKAN DATA AUGMENTASI DENGAN METODE KNN DAN GLCM," *Jurnal Aplikasi Teknologi Informasi dan Manajemen (JATIM)*, vol. Vol.3 No.2, 2022.
- [7] M. Novela and T. Basaruddin, "DATASET SUARA DAN TEKS BERBAHASA INDONESIA PADA REKAMAN PODCAST DAN TALK SHOW," *JURNAL FASILKOM*, vol. 11, no. 2, pp. 61–66, Aug. 2021.
- [8] H. Mukhtar, F. Alfatico, H. Fu, adah Amran, F. Handayani, and R. Medikawati Taufiq, "Deep Learning Untuk Klasifikasi Kematangan Buah Mangrove Berdasarkan Warna," *JURNAL FASILKOM*, vol. 13 No. 3, Dec. 2023.
- [9] B. Karnadi and T. Handhayani, "Klasifikasi Jenis Buah dengan Menggunakan Metode MobileNetv2 dan Inceptionv3," *Jurnal Eksplora Informatika*, vol. 14, no. 1, pp. 35–42, Sep. 2024, doi: 10.30864/eksplora.v14i1.1067.
- [10] I. Anugrah, A. Cendekia Siregar, and B. C. Octariadi, "Perbandingan Model Arsitektur CNN Dengan Metode Transfer Learning Untuk Klasifikasi Spesies Ikan Laut," *Progresif: Jurnal Ilmiah Komputer*, vol. Vol. 20, No. 1, Feb. 2024, [Online]. Available: www.fishbase.com