

DETEKSI PENYAKIT PADA DAUN SINGKONG DENGAN PENGOLAHAN CITRA MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)

Desvita Fitri Amalia

Universitas Bina Sarana Informatika

email korespondensi : desvitafitriamalia2@gmail.com

Submit: 00-00-0000 | Revisi : 00-00-0000 | Terima : 00-00-0000 | Publikasi: 00-00-0000

Abstrak

Penelitian ini mengembangkan dan mengimplementasikan model Convolutional Neural Network (CNN) dengan arsitektur AlexNet untuk mendeteksi penyakit pada daun singkong dan mengolahnya sebagai pakan ternak. Dataset berjumlah 1080 gambar daun singkong dengan lima kelas penyakit: blight, brown, green, healthy, dan mosaic. Data dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian. Hasil penelitian menunjukkan peningkatan akurasi deteksi penyakit daun singkong secara signifikan. Pada epoch pertama, akurasi sebesar 21,18% dengan nilai loss 0,24098, sedangkan akurasi validasi sebesar 19,33% dengan nilai loss validasi 1,6592. Pada epoch ke-50, model mencapai akurasi 81% dengan nilai loss yang rendah, menunjukkan efektivitas AlexNet dalam mendeteksi penyakit daun singkong. Implementasi model ini membantu dalam deteksi penyakit tanaman dan pemanfaatan daun singkong sebagai pakan ternak dengan baik. Peningkatan akurasi ini menunjukkan bahwa model CNN AlexNet yang dikembangkan mampu mendeteksi penyakit pada daun singkong dengan efektif. Selain itu, deteksi penyakit yang lebih akurat dapat meningkatkan produksi dan kualitas tanaman singkong, sehingga mendukung keberlanjutan pertanian dan ekonomi petani. Dengan demikian, penelitian ini tidak hanya berkontribusi pada ilmu pengetahuan di bidang pertanian dan teknologi, tetapi juga memberikan manfaat praktis bagi para petani dan industri pakan.

Kata Kunci : Kata Kunci : Daun singkong, Convolutional Neural Network, Deteksi penyakit tanaman, AlexNet, Pengolahan citra

Abstract

This study develops and implements a Convolutional Neural Network (CNN) model with the AlexNet architecture to detect diseases in cassava leaves and process them as animal feed. The dataset consists of 1080 images of cassava leaves with five disease classes: blight, brown, green, healthy, and mosaic. The data is split into 80% for training and 20% for testing. The study results show a significant increase in the accuracy of cassava leaf disease detection. In the first epoch, the accuracy was 21.18% with a loss value of 0.24098, while the validation accuracy was 19.33% with a validation loss value of 1.6592. In the 50th epoch, the model achieved an accuracy of 81% with a low loss value, demonstrating the effectiveness of AlexNet in detecting cassava leaf diseases. The implementation of this model aids in plant disease detection and the utilization of cassava leaves as animal feed. This accuracy improvement indicates that the developed CNN AlexNet model can effectively detect diseases in cassava leaves. Additionally, more accurate disease detection can enhance the production and quality of cassava plants, thus supporting the sustainability of agriculture and farmers' economy. Therefore, this research not only contributes to the scientific knowledge in agriculture and technology but also provides practical benefits for farmers and the animal feed industry.

Keywords : Cassava leaves, Convolutional Neural Network, Plant disease detection, AlexNet, Image processing

1. Pendahuluan

Daun singkong merupakan salah satu tanaman yang banyak ditemukan di Indonesia dan memiliki banyak manfaat. Daun singkong juga merupakan sumber hijauan yang potensial untuk makanan hewan ternak, daun singkong dapat dimanfaatkan melalui defoliasi sistematis setelah umbi singkong dipanen (Faturrachman et al., 2022). Daun singkong memiliki kandungan nutrisi yang cukup baik dan sumber pakan dengan biaya murah yang diproduksi tidak termanfaatkan dan tidak berkompetisi dengan umbinya yang merupakan produk komersial utama dari tanaman singkong (Suhendar et al., 2023).

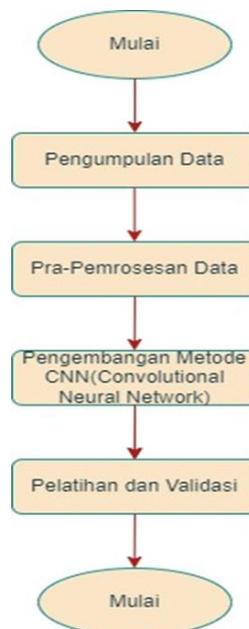


Pertanian sendiri pun merupakan salah satu sektor utama dalam pembangunan ekonomi suatu Negara. di Indonesia, tanaman singkong memiliki peran penting dalam pemenuhan kebutuhan pangan dan perekonomian masyarakat. Namun, salah satu tantangan dalam budaya singkong adalah serangan penyakit yang dapat mengurangi produksi dan kualitas tanaman (Ariyanto et al., 2023).

Penyakit pada tanaman singkong, khususnya yang menyerang daun, dapat menyebabkan kerugian yang signifikan jika tidak segera dideteksi dan diatasi. Metode deteksi penyakit secara manual oleh petani seringkali memakan waktu dan tidak selalu akurat. Oleh karena itu, pengembangan sistem deteksi penyakit yang cepat dan akurat menjadi penting untuk mendukung pertanian singkong yang berkelanjutan (Ade Kurnia Saeful, 2021).

Metode deep learning dalam menangani deteksi penyakit tanaman kali ini adalah Convolutional Neural Network (CNN). dalam konteks deteksi penyakit tanaman daun singkong, CNN bekerja dengan memanfaatkan arsitektur jaringan saraf tiruan yang terinspirasi oleh cara kerja visual manusia. Prosesnya dimulai dengan menyajikan citra daun singkong ke dalam jaringan CNN. Jaringan ini kemudian memproses citra secara hierarkis melalui serangkaian lapisan konvolusi dan pooling untuk mengekstrak fitur-fitur penting dari citra tersebut (Sheila et al., 2023)

2. Metode



Gambar 2.1 Tahapan Penelitian

1. Pengumpulan Data

Pengumpulan data merupakan langkah penting dalam penelitian ini. Data yang diperlukan adalah gambar daun singkong yang terinfeksi berbagai jenis penyakit serta daun yang sehat. Untuk efisiensi dan aksesibilitas, data akan dikumpulkan dari basis data publik yang tersedia di Kaggle. Langkah-langkah pengumpulan data meliputi:

- Sumber Data:** Data gambar daun singkong akan diunduh dari Kaggle, yang memiliki berbagai dataset tentang kesehatan tanaman.
- Kategori Penyakit:** Gambar akan dikategorikan berdasarkan jenis penyakit seperti bercak daun coklat, bercak daun putih, dan virus mosaik.
- Resolusi Gambar:** Gambar yang tersedia di Kaggle biasanya dalam resolusi tinggi, sehingga dapat langsung digunakan untuk analisis.
- Jumlah Gambar:** Dataset yang besar dan beragam dari Kaggle akan digunakan untuk memastikan model dilatih dengan data yang representatif.

2. Pra-pemrosesan

Preprocessing: Gambar-gambar yang telah diunduh dari Kaggle akan diproses terlebih dahulu, termasuk resizing, normalisasi, dan augmentasi data untuk meningkatkan kinerja model.

- Arsitektur CNN:** Model CNN akan dibangun dengan beberapa lapisan konvolusi, pooling, dan fully connected. Arsitektur model yang umum digunakan mencakup beberapa lapisan konvolusi diikuti dengan lapisan pooling dan satu atau lebih lapisan fully connected.

b) **Training Model:** Data akan dibagi menjadi data pelatihan dan data validasi. Model akan dilatih menggunakan data pelatihan dengan optimasi parameter melalui algoritma seperti Adam atau SGD (Stochastic Gradient Descent).

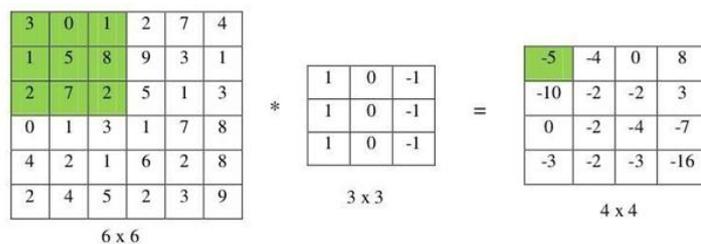
c) **Evaluasi Model:** Kinerja model akan dievaluasi menggunakan data validasi dengan metrik seperti akurasi, presisi, recall, dan F1-score. Jika diperlukan, hyperparameter tuning akan dilakukan untuk meningkatkan kinerja model.

3. Pengembangan Model CNN (Convolutional Neural Network)

CNN (Convolutional Neural Networks) adalah salah satu metode pembelajaran mesin yang menggunakan neural network dan biasa digunakan untuk mengolah data citra. Data citra yang digunakan sebagai data masukan, biasa memiliki ukuran Panjang × Lebar × channel warna. Panjang dan lebar menunjukkan ukuran citra dalam satuan pixel. Sementara untuk channel warna akan menunjukkan citra memiliki jenis warna apa. Sebagai contoh citra yang memiliki hanya 1 channel merupakan citra Grayscale, dimana citra hanya menampilkan 1 jenis warna dan biasa disebut dengan monokrom. Citra yang memiliki warna normal biasanya terdiri dari 3 channel. Setiap channel mewakili warna dari jenis warna dasar yaitu RGB (Red Green Blue). Sama seperti neural network lainnya, CNN juga memiliki bobot, bias, dan fungsi aktivasi yang membuat neural network bisa mengeluarkan sebuah keluaran yang sesuai dengan data latih yang diberikan.

a) Lapisan Konvolusi

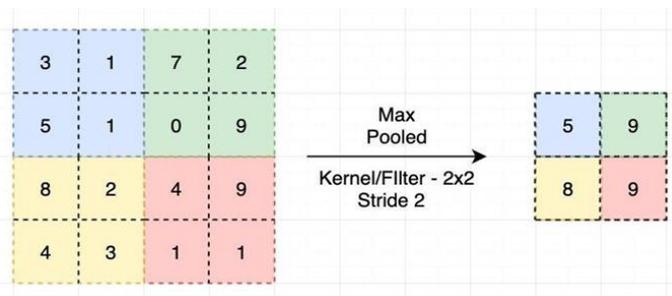
Lapisan Konvolusi (Convolution Layer) merupakan lapisan yang akan dijumpai pertama kali dalam CNN. Lapisan ini akan melakukan konvolusi citra masukan dengan filter yang sudah didefinisikan tanpa merusak struktur dari citra awal. Lapisan ini memiliki fungsi untuk mengambil fitur pada citra yang akan digunakan untuk melatih model. Contoh proses dari lapisan ini dapat dilihat pada Gambar 2.2.



Gambar 2.2 Lapisan Konvolusi

b) Lapisan pooling

Lapisan pooling adalah jenis lapisan lain yang digunakan dalam jaringan saraf konvolusi (CNN). Tujuan utamanya adalah untuk mengurangi dimensi spasial (panjang dan lebar) dari peta fitur yang dihasilkan oleh lapisan konvolusi, sambil tetap mempertahankan informasi penting. Lapisan pooling membantu mengurangi jumlah parameter dalam jaringan, mengontrol overfitting, dan menghasilkan representasi yang lebih abstrak dari data. Berikut gambar lapisan pooling dapat dilihat pada gambar 2.3



Gambar 2.3 Lapisan Pooling

c) Lapisan Dense (Fully Connected)

Lapisan Dense, juga dikenal sebagai lapisan fully connected, adalah lapisan di dalam jaringan saraf tiruan di mana setiap neuron terhubung ke setiap neuron di lapisan sebelumnya dan setelahnya. Ini adalah bagian akhir dari jaringan yang menggabungkan semua fitur yang diekstraksi sebelumnya untuk menghasilkan output akhir, seperti klasifikasi atau regresi. Dalam lapisan Dense, setiap neuron memiliki bobot yang harus dipelajari selama pelatihan, dan bias juga diperkenalkan untuk membantu proses pembelajaran.

4. Pelatihan dan Validasi Data

a) Training

Model dilatih menggunakan data latih dengan monitoring performa pada data validasi. Proses pelatihan melibatkan forward pass, backward pass, dan update bobot.

b) Early Stopping

Early stopping diterapkan untuk menghentikan pelatihan saat performa pada data validasi tidak meningkat setelah beberapa epoch, untuk mencegah overfitting.

5. Cleaning Data

Cleaning Data adalah proses mempersiapkan dan membersihkan data agar siap digunakan dalam analisis atau pemodelan. Dalam konteks proyek deteksi penyakit pada daun singkong menggunakan CONVOLUTIONAL NEURAL NETWORK (CNN). Cleaning data memiliki Langkah-langkah berikut:

a) Menghapus duplikat, menghapus gambar yang sama atau yang mirip untuk menghindari bias.

b) Memperbaiki data yang hilang, menghapus atau memperbaiki gambar yang rusak atau tidak lengkap.

c) Penyesuaian ukuran gambar, mengubah ukuran gambar kedimensi yang seragam sesuai kebutuhan model CNN.

d) Normalisasi, mengubah skala nilai piksel gambar ke rentang tertentu (misalnya 0-1) agar model lebih mudah dilatih.

e) Pemberian label, memberikan label yang benar pada setiap gambar sesuai dengan jenis penyakit.

2.2 Instrumen Penelitian

Instrumen tersebut berfungsi sebagai alat untuk mengumpulkan data yang diperlukan (Syapitiri Heni, Amila, 2021). Pada penelitian ini instrumen yang digunakan adalah pengamatan (observasi).

Melalui observasi, peneliti dapat mencatat berbagai aktivitas, kejadian, dan interaksi yang terjadi dalam lingkungan penelitian. Observasi memungkinkan peneliti untuk mendapatkan data empiris yang akurat, sehingga hasil penelitian menjadi lebih valid dan dapat dipercaya. Teknik ini sangat berguna dalam penelitian kualitatif di mana peneliti ingin memahami konteks sosial dan budaya dari fenomena yang diteliti.

Selain itu, observasi juga membantu peneliti dalam mengidentifikasi variabel-variabel yang relevan dengan penelitian. Dalam konteks penelitian penyakit pada daun singkong, observasi langsung di lapangan memungkinkan peneliti untuk mengamati gejala-gejala penyakit, kondisi lingkungan, serta faktor-faktor lain yang mungkin mempengaruhi perkembangan penyakit. Informasi yang diperoleh melalui observasi ini sangat penting dalam merancang model prediksi dan pengambilan keputusan untuk penanganan penyakit.

2.3 Metode Pengumpulan Data

Data yang dianalisis dalam penelitian ini disediakan dalam format berkas gambar JPEG. pengumpulan data yang mencakup total 200 citra daun singkong. Dalam upaya untuk merinci perbedaan visual antara jenis-jenis daun yang berbeda, Selanjutnya data yang sudah dikelompokkan akan dibagi menjadi data latih dan data uji. Dari data latih dan data uji tersebut didapatkan data prediksi dari hasil pengujian pada proses training model CNN.

2.4.1 Metode Analisis Data

Metode analisis data dalam penelitian ini dirancang untuk memastikan bahwa sistem deteksi penyakit daun singkong berbasis CNN dapat berfungsi dengan efisien dan akurat. Setiap tahapan, mulai dari pengumpulan data hingga analisis hasil, diuraikan dengan cermat untuk memberikan pemahaman yang komprehensif dan mendalam tentang kinerja model. Diharapkan, melalui metode ini, penelitian dapat memberikan kontribusi signifikan dalam mendeteksi penyakit pada daun singkong dan mendukung keberlanjutan pertanian singkong di Indonesia (Irfansyah et al., 2021).

2.4.2 Data Mining

Proses sistematis untuk menggali dan menganalisis data besar-besaran dalam rangka mengidentifikasi pola atau hubungan yang bermanfaat dan dapat diprediksi. Dalam konteks penelitian ini, data mining digunakan untuk mengolah data gambar daun singkong yang terinfeksi penyakit dengan metode analisis menggunakan Convolutional Neural Network (CNN). Tujuannya adalah untuk mengoptimalkan sistem deteksi penyakit daun singkong sehingga dapat berfungsi dengan efisien dan akurat, memberikan pemahaman yang mendalam tentang kinerja model, dan memberikan kontribusi dalam mendukung keberlanjutan pertanian singkong di Indonesia (Michael Page, 2022).

2.4.3 Klasifikasi

Klasifikasi adalah proses pengelompokan atau pengkategorian objek berdasarkan atribut-atribut tertentu ke dalam kelas atau kategori yang telah ditentukan sebelumnya. Dalam konteks pengolahan citra menggunakan Convolutional Neural Network (CNN), klasifikasi mengacu pada kemampuan model untuk mengenali dan mengkategorikan gambar-gambar daun singkong menjadi kelas-kelas yang sesuai, seperti daun yang sehat atau daun yang terinfeksi penyakit tertentu seperti bercak daun coklat, bercak daun putih, atau virus mosaik. Proses klasifikasi ini memanfaatkan fitur-fitur yang diekstraksi oleh CNN dari setiap gambar untuk membuat keputusan yang akurat berdasarkan pola-pola yang telah dipelajari selama proses pelatihan model (Chavez & Hernando, 2023).

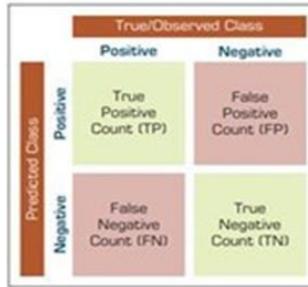
2.4.3 Metode CNN (Convolutional Neural Network)

Convolutional Neural Network (CNN) adalah sebuah jenis arsitektur neural network dalam machine learning yang khusus dirancang untuk memproses data berupa grid, seperti data gambar (Ulfah Nur Oktaviana et al., 2021). Metode CNN menggunakan lapisan-lapisan konvolusi untuk secara efektif mengidentifikasi dan mengekstraksi fitur-fitur penting dari gambar, tanpa memerlukan fitur-fitur yang

telah diextract sebelumnya secara manual. CNN atau Convolutional Neural Network, adalah jenis jaringan saraf yang menggunakan konvolusi sebagai pengganti perkalian matriks umum. Setiap lapisan dalam CNN setidaknya memiliki satu operasi konvolusi. Keunggulan utama CNN terletak pada kemampuannya untuk mengklasifikasikan citra dengan tingkat akurasi tinggi (Maulana et al., 2023).

2.4.4 Confusion Matrix

Confusion Matrix merupakan salah satu metode Data Mining berupa Prediksi tipe Klasifikasi yang juga merupakan metode supervised learning, dimana terdapat label yang dapat dijadikan acuan dalam mengukur peromansi sebuah model dan mewakili jumlah dari nilai yang diprediksi dan nilai aktual. Selain itu, Confusion Matrix merupakan bagian dari keluarga Machine Learning yang mempelajari data yang sudah tersedia dan mengklasifikasikan sebagai data baru serta menghasilkan output variabel bersifat kategorial (Nominal atau Ordinal) (Irfansyah et al., 2021). Contoh gambar confusion matrik dapat dilihat pada gambar 2.4



Gambar 2.4 Confusion Matrik

3. Hasil dan Pembahasan

Pada tahap ini, data yang dikumpulkan berasal dari basis data publik Kaggle, yang menyediakan gambar daun singkong dengan berbagai jenis penyakit serta daun yang sehat. Total 1080 citra daun singkong berhasil dikumpulkan dan dikategorikan berdasarkan jenis penyakit, seperti bercak daun coklat, bercak daun putih, dan virus mosaik. Resolusi gambar yang tinggi memungkinkan analisis yang lebih akurat. Data yang besar dan beragam memastikan model dilatih dengan data yang representatif.



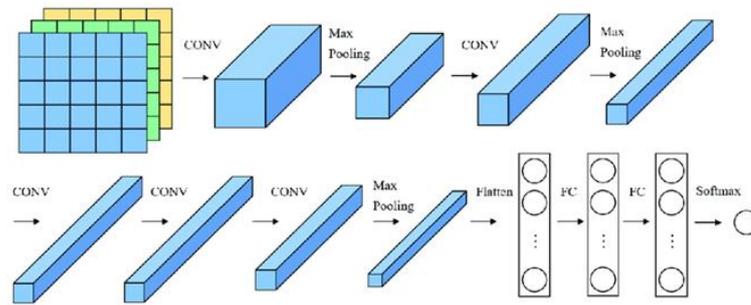
Gambar 3.1 Sampel Citra Dataset Daun Singkong

3.1. Pembagian Dataset

Pembagian dataset 80-20 adalah cara umum dalam machine learning untuk membagi dataset menjadi dua bagian: sekitar 80% digunakan untuk melatih model (training set), sedangkan sekitar 20% digunakan untuk menguji model (testing set). Ini membantu model belajar dari data yang ada dan menguji seberapa baik model dapat memprediksi data baru yang belum pernah dilihat sebelumnya. Berikut pembagian datanya dapat dilihat pada tabel 3.

Tabel 3.1 Pembagian Data Training dan Testing

No	Dataset	Presentase	Jumlah Data
1.	Data Training	80%	864
2.	Data Testing	20%	216
Total		100%	1080



Gambar 3.2 model arsitektur CNN Alexnet

Pengembangan model CNN AlexNet mengacu pada proses merancang, mengimplementasikan, dan mengoptimalkan arsitektur jaringan saraf konvolusional (CNN) yang dikenal sebagai AlexNet. AlexNet adalah salah satu model CNN yang revolusioner karena berhasil memenangkan kompetisi ImageNet tahun 2012 dengan performa yang signifikan lebih baik daripada pendahulunya.

Berikut adalah definisi singkat untuk pengembangan model CNN AlexNet:

AlexNet adalah arsitektur CNN yang terdiri dari beberapa lapisan konvolusi dan lapisan fully-connected (sepenuhnya terhubung). Model ini dikembangkan oleh Alex Krizhevsky, Ilya Sutskever, dan Geoffrey Hinton. Keberhasilannya dalam kompetisi ImageNet 2012 menunjukkan kekuatan model CNN dalam tugas klasifikasi gambar yang kompleks.

Komponen Utama AlexNet:

1.Lapisan Konvolusi: AlexNet menggunakan beberapa lapisan konvolusi untuk mengekstraksi fitur dari gambar input. Lapisan-lapisan ini menggunakan filter konvolusi untuk mempelajari representasi fitur yang lebih abstrak secara bertahap.

2.Lapisan Pooling: Setelah lapisan konvolusi, AlexNet menggunakan lapisan max pooling untuk mereduksi dimensi spasial dari setiap konvolusi yang dihasilkan. Hal ini membantu mengurangi jumlah parameter dan membuat representasi fitur lebih invarian terhadap translasi.

3.Fungsi Aktivasi: ReLU (Rectified Linear Unit) digunakan sebagai fungsi aktivasi di hampir semua lapisan, kecuali pada lapisan output.

4.Normalisasi Batch: AlexNet menggunakan normalisasi batch untuk mempercepat konvergensi saat melatih model.

5.Dropout: Teknik dropout diterapkan pada lapisan fully-connected untuk mengurangi overfitting.

6.Lapisan Fully-Connected: AlexNet memiliki tiga lapisan fully-connected di bagian akhir model untuk menghubungkan fitur-fitur yang diekstraksi ke kelas output.

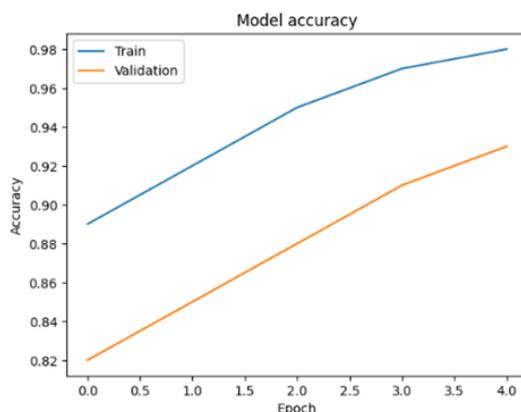
3.2. Epoch

```

30/30 [=====] - 152s 5s/step - loss: 0.9786 - accuracy: 0.6151 - val_loss: 0.6926 - val_accuracy: 0.8133
Epoch 36/50
30/30 [=====] - 150s 5s/step - loss: 0.9856 - accuracy: 0.6441 - val_loss: 0.5297 - val_accuracy: 0.8400
Epoch 37/50
30/30 [=====] - 149s 5s/step - loss: 0.9304 - accuracy: 0.6398 - val_loss: 0.4240 - val_accuracy: 0.8933
Epoch 38/50
30/30 [=====] - 151s 5s/step - loss: 0.8425 - accuracy: 0.6720 - val_loss: 0.4746 - val_accuracy: 0.8467
Epoch 39/50
30/30 [=====] - 151s 5s/step - loss: 0.8454 - accuracy: 0.6892 - val_loss: 0.6217 - val_accuracy: 0.7867
Epoch 40/50
30/30 [=====] - 159s 5s/step - loss: 0.8150 - accuracy: 0.6957 - val_loss: 0.6312 - val_accuracy: 0.7800
Epoch 41/50
30/30 [=====] - 157s 5s/step - loss: 0.8660 - accuracy: 0.6871 - val_loss: 0.8317 - val_accuracy: 0.7000
Epoch 42/50
30/30 [=====] - 156s 5s/step - loss: 0.7930 - accuracy: 0.7854 - val_loss: 1.0923 - val_accuracy: 0.6267
Epoch 43/50
30/30 [=====] - 157s 5s/step - loss: 0.8737 - accuracy: 0.6624 - val_loss: 0.8849 - val_accuracy: 0.6600
Epoch 44/50
30/30 [=====] - 154s 5s/step - loss: 0.8460 - accuracy: 0.6731 - val_loss: 0.6240 - val_accuracy: 0.8133
Epoch 45/50
30/30 [=====] - 152s 5s/step - loss: 0.7587 - accuracy: 0.7140 - val_loss: 0.6176 - val_accuracy: 0.7867
Epoch 46/50
30/30 [=====] - 150s 5s/step - loss: 0.7536 - accuracy: 0.7151 - val_loss: 0.4746 - val_accuracy: 0.8600
Epoch 47/50
30/30 [=====] - 151s 5s/step - loss: 0.7520 - accuracy: 0.7140 - val_loss: 0.3984 - val_accuracy: 0.9067
Epoch 48/50
30/30 [=====] - 150s 5s/step - loss: 0.7446 - accuracy: 0.7226 - val_loss: 0.3496 - val_accuracy: 0.9133
Epoch 49/50
30/30 [=====] - 150s 5s/step - loss: 0.6257 - accuracy: 0.7677 - val_loss: 0.2993 - val_accuracy: 0.9400
Epoch 50/50
30/30 [=====] - 150s 5s/step - loss: 0.6414 - accuracy: 0.7613 - val_loss: 0.5264 - val_accuracy: 0.8133
    
```

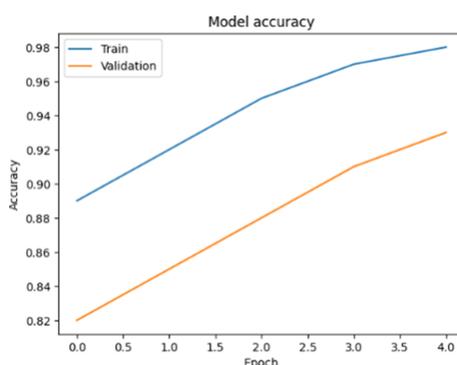
Gambar 3.3 Hasil Pengujian Dengan Menggunakan 50 Epoch

Berdasarkan gambar perhitungan epoch pada tabel 3.15 pada epoch 1 dengan akurasi sebesar 0.2118, loss sebesar 0.24098, akurasi validasi sebesar 0.1933, dan loss validasi sebesar 1.6592, sampai dengan epoch 50 dengan akurasi sebesar 0.7613, loss sebesar 0.6414, akurasi validasi sebesar 0.8133, dan loss validasi sebesar 0.5264. Maka menunjukkan bahwa epoch satu sampai lima puluh menunjukkan kenaikan akurasi yang cukup bagus.



Gambar 3.4 Visualisasi Grafik Akurasi

Pada grafik pertama dengan label "Model accuracy," garis biru mewakili akurasi pelatihan (Train) dan garis oranye mewakili akurasi validasi (Validation). Kita bisa lihat kalau akurasi model terus meningkat seiring bertambahnya epoch. Akurasi pelatihan mulai dari sekitar 82% di epoch pertama dan naik hampir ke 98% di epoch kelima. Akurasi validasi juga naik dari sekitar 84% menjadi sekitar 92%. Di epoch terakhir, model mencapai akurasi validasi 81%, yang menunjukkan bahwa model semakin baik dalam memprediksi kelas yang benar seiring waktu.



Gambar 3.5 Visualisasi Grafik Loss

Grafik kedua dengan label "Model loss" menunjukkan nilai loss untuk pelatihan dan validasi. Garis biru adalah loss pada data pelatihan, sementara garis oranye adalah loss pada data validasi. Loss menggambarkan seberapa jauh prediksi model dari hasil yang diharapkan; nilai yang lebih rendah berarti prediksi lebih akurat. Di epoch pertama, loss pelatihan sekitar 0.5 dan turun menjadi sekitar 0.1 di epoch kelima. Loss validasi mulai dari sekitar 0.75 dan turun jadi sekitar 0.35. Penurunan loss ini menunjukkan bahwa model makin baik dalam memprediksi dengan lebih sedikit kesalahan.

4. Kesimpulan

Berdasarkan rumusan masalah dan tujuan penelitian yang telah disampaikan, serta hasil penelitian yang menunjukkan akurasi deteksi penyakit tanaman padi dengan pendekatan yang digunakan, berikut adalah tiga kesimpulan utama:

1. Efektivitas Model: Model Convolutional Neural Network (CNN) dengan arsitektur AlexNet terbukti efektif dalam meningkatkan akurasi deteksi penyakit pada daun singkong selama proses pelatihan. Akurasi model meningkat secara signifikan dari awal pelatihan hingga mencapai tingkat optimal pada epoch terakhir, menunjukkan bahwa AlexNet dapat mengenali pola dan karakteristik penyakit pada daun singkong dengan baik.

2. Pengurangan Nilai Loss: Model CNN dengan arsitektur AlexNet berhasil mengurangi nilai loss secara konsisten selama proses pelatihan. Penurunan nilai loss ini menunjukkan bahwa prediksi model semakin akurat dan kesalahan prediksi semakin berkurang, yang mengindikasikan peningkatan performa model dalam mendeteksi penyakit pada daun singkong.

3. Perbedaan Akurasi Pelatihan dan Validasi: Terdapat perbedaan antara akurasi pelatihan dan akurasi validasi model CNN AlexNet selama beberapa epoch pelatihan. Meskipun akurasi pelatihan cenderung lebih tinggi, akurasi validasi juga menunjukkan peningkatan yang signifikan. Perbedaan ini menunjukkan bahwa model mampu menggeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya, meskipun terdapat sedikit ketidakcocokan antara data pelatihan dan data validasi.

Referensi

- Ade Kurnia Saeful. (2021). Analisis Kandungan Rutin Pada Daun Singkong Dan Olahannya Menggunakan Pereaksi Geser. Skripsi, 09, 1–28.
- Ariyanto, A. D. P., Hasanah, S., Subkhi, M. B., & Suciati, N. (2023). Analisis Penggunaan Pra-proses pada Metode Transfer Learning untuk Mendeteksi Penyakit Daun Singkong. *Techno.Com*, 22(2), 336–347. <https://doi.org/10.33633/tc.v22i2.7769>
- Chavez, K., & Hernando, L. (2023). Implementasi Sistem Pendeteksi Penyakit Pada Daun Singkong Dan Daun Cabai Berbasis Machine Learning. *Jurnal Quacom*, 1(2), 1–5.
- Faturrachman, M., Studi, P., Informatika, T., Komputer, F., & Dan, T. (2022). Deteksi Penyakit Pada Daun Singkong.
- Irfansyah, D., Mustikasari, M., & Suroso, A. (2021). Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi. *Jurnal Informatika: Jurnal Pengembangan IT*, 6(2), 87–92. <https://doi.org/10.30591/jpit.v6i2.2802>
- Maulana, S. A., Husna Batubara, S., Amelia, T. A., Permata, Y., Pasaribu, P., & Willem, J. (2023). Penerapan Metode CNN (Convolutional Neural Network) Dalam Mengklasifikasi Jenis Ubur-Ubur. *Jurnal Penelitian Rumpun Ilmu Teknik (JUPRIT)*, 2(4), 122–130. <https://doi.org/10.55606/juprit.v2i4.3084>
- Michael Page, I. (2022). No 主観的健康感を中心とした在宅高齢者における健康関連指標に関する共分散構造分析Title.
- Sheila, S., Permata Sari, I., Bagas Saputra, A., Kharil Anwar, M., & Restu Pujiyanto, F. (2023). Deteksi Penyakit Pada Daun Padi Berbasis Pengolahan Citra Menggunakan Metode Convolutional Neural Network (CNN). *Multinetics*, 9(1), 27–34. <https://doi.org/10.32722/multinetics.v9i1.5255>
- Suhendar, S., Purnama, A., & Fauzi, E. (2023). Deteksi Penyakit Pada Daun Tanaman Ubi Jalar Menggunakan Metode Convolutional Neural Network. *Jurnal Ilmiah Informatika Global*, 14(3), 62–67. <https://doi.org/10.36982/jiig.v14i3.3478>
- Ulfah Nur Oktaviana, Ricky Hendrawan, Alfian Dwi Khoirul Annas, & Galih Wasis Wicaksono. (2021). Klasifikasi Penyakit Padi berdasarkan Citra Daun Menggunakan Model Terlatih Resnet101. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(6), 1216–1222. <https://doi.org/10.29207/resti.v5i6.3607>