



ISSN : 2339 - 1871

## JURNAL ILMIAH BETRIK

Besemah Teknologi Informasi dan Komputer

Editor Office : LPPM Sekolah Tinggi Teknologi Pagar Alam, Jln. Masik Siagim No. 75  
Simpang Mbacang, Pagar Alam, SUM-SEL, Indonesia

Phone : +62 852-7901-1390.

Email : [betrik@sttpagaralam.ac.id](mailto:betrik@sttpagaralam.ac.id) | [admin.jurnal@sttpagaralam.ac.id](mailto:admin.jurnal@sttpagaralam.ac.id)

Website : <https://ejournal.sttpagaralam.ac.id/index.php/betrik/index>

### ANALISIS PERBANDINGAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN) DAN ARTIFICIAL NEURAL NETWORK (ANN) DALAM KLASIFIKASI PENYAKIT DAUN JAGUNG

Eva Yuninsar<sup>1\*</sup>, Erfan Hasmin<sup>2</sup>, Indra Samsie<sup>3</sup>

Prodi Teknik Informatika Jurusan Teknik Informatika Universitas Dipa Makassar<sup>123</sup>  
Jl. Perintis Kemerdekaan No.KM.9, Tamalanrea Indah, Kec. Tamalanrea, Kota Makassar,  
Sulawesi Selatan

Sur-el : [eva.212112@undipa.ac.id](mailto:eva.212112@undipa.ac.id)<sup>1</sup>, [erfan.hasmin@undipa.ac.id](mailto:erfan.hasmin@undipa.ac.id)<sup>2</sup>, [indrasamsie@undipa.ac.id](mailto:indrasamsie@undipa.ac.id)<sup>3</sup>

**Abstrak:** Penelitian ini bertujuan untuk membandingkan efektivitas metode Convolutional Neural Network (CNN) dan Artificial Neural Network (ANN) dalam mengklasifikasikan penyakit pada daun jagung, termasuk Blight, Gray Leaf Spot, dan Common Rust. Jagung merupakan tanaman penting di Indonesia yang sering terpengaruh oleh berbagai penyakit, yang dapat mengakibatkan penurunan hasil panen secara signifikan. Untuk itu, deteksi dini dan akurat terhadap penyakit ini sangat diperlukan guna menjaga produktivitas pertanian. Dalam penelitian ini, digunakan dataset dari Kaggle yang terdiri dari 1506 gambar daun jagung yang terinfeksi oleh tiga jenis penyakit tersebut. Proses penelitian mencakup pengumpulan data, preprocessing, pelatihan model CNN dan ANN, serta evaluasi hasil yang diperoleh. Hasil penelitian menunjukkan bahwa model CNN mencapai akurasi 86,51% dengan nilai kehilangan (loss) 0,1921 setelah 50 epoch, sedangkan model ANN hanya mampu mencapai akurasi 77,16% dengan nilai kehilangan 0,3461. Selain itu, analisis menunjukkan bahwa CNN memiliki kemampuan yang lebih baik dalam belajar pola kompleks dan tidak mengalami overfitting, sementara ANN lebih rentan terhadap masalah tersebut. Penyesuaian hyperparameter, seperti initial learning rate, batch size, dan ukuran gambar, juga berperan penting dalam kinerja model yang optimal. Labeling, yaitu proses memberi label pada gambar, dilakukan untuk membantu model dalam mengklasifikasikan dengan benar. Hasil output klasifikasi ditampilkan melalui antarmuka yang mengirim dan menerima data dalam format JSON, yang memudahkan integrasi dengan aplikasi lain. Penelitian ini merekomendasikan penggunaan CNN untuk aplikasi di bidang pertanian, khususnya dalam deteksi penyakit tanaman, guna meningkatkan efisiensi dan akurasi dalam klasifikasi penyakit yang dapat berdampak pada hasil panen. Dengan demikian, penelitian ini memberikan kontribusi terhadap pengembangan teknologi dalam pertanian dan penerapan metode deep learning dalam klasifikasi penyakit tanaman.

**Kunci Utama:** Convolutional Neural Network; Artificial Neural Network; Klasifikasi Penyakit; Daun Jagung; Deteksi Penyakit.

**Abstract:** This study aims to compare the effectiveness of Convolutional Neural Network (CNN) and Artificial Neural Network (ANN) methods in classifying diseases in corn leaves, including Blight, Gray Leaf Spot, and Common Rust. Corn is an important crop in Indonesia that is often affected by various diseases, which can lead to a significant decrease in yield. Therefore, early and accurate detection of these diseases is essential to maintain agricultural productivity. In this research, a dataset from Kaggle consisting of 1,506 images of corn leaves infected by these three types of diseases was used. The research process includes data collection, preprocessing, training

of CNN and ANN models, and evaluation of the results obtained. The results show that the CNN model achieved an accuracy of 86.51% with a loss value of 0.1921 after 50 epochs, while the ANN model only reached an accuracy of 77.16% with a loss of 0.3461. Additionally, the analysis indicates that CNN has a better ability to learn complex patterns and does not experience overfitting, while ANN is more susceptible to this issue. Adjustments to hyperparameters, such as initial learning rate, batch size, and image size, also play a crucial role in optimal model performance. Labeling, which is the process of assigning labels to images, was performed to assist the model in accurate classification. The classification output results are displayed through an interface that sends and receives data in JSON format, facilitating integration with other applications. This study recommends the use of CNN for applications in agriculture, particularly in the detection of plant diseases, to enhance efficiency and accuracy in classifying diseases that can impact crop yields. Thus, this research contributes to the development of technology in agriculture and the application of deep learning methods in the classification of plant diseases.

**Keywords** : Convolutional Neural Network; Artificial Neural Network; Disease Classification; Corn Leaves; Disease Detection.

## 1. PENDAHULUAN

Jagung (*Zea mays*) merupakan salah satu tanaman pangan terpenting di Indonesia, dan berperan penting dalam memenuhi kebutuhan pangan negara dan industri pakan ternak. Tanaman ini memiliki nilai gizi yang tinggi dan dapat dikonversi menjadi sejumlah tanaman bernilai tinggi, yang merupakan sumber pendapatan utama bagi banyak petani di seluruh negeri. Seiring dengan pertambahan jumlah penduduk dan meningkatnya kebutuhan pangan, maka kebutuhan jagung pun terus meningkat. Hal ini meningkatkan permintaan stok jagung berkualitas tinggi sepanjang tahun [1].

Namun dalam upaya peningkatan produksi jagung banyak kendala yang dihadapi, salah satunya adalah serangan penyakit patogen tanaman (OPT), hama dan penyakit tanaman. Serangan hama ini tidak hanya merusak tanaman, namun juga menurunkan produktivitas, termasuk kegagalan panen sehingga berdampak pada produksi negara. Tantangan ini diperkuat oleh terbatasnya akses petani terhadap teknologi dan modal pertanian baru, serta perubahan iklim [2].

Jagung merupakan tanaman kebutuhan pokok nomor tiga di dunia setelah padi dan gandum, dan nomor dua di Indonesia. Jagung tumbuhan baik pada cuaca panas dan dingin dengan pengairan yang tepat. Pada siklus hidup jagung dari benih ke benih, seluruh bagian tanaman jagung, terutama bagian

daun, mudah terserang berbagai penyakit sehingga menyebabkan penurunan hasil dan mutu jagung [3].

Gejala penyakit pada tanaman jagung dapat dilihat dari perubahan pada daunnya. Beberapa penyakit pada tanaman jagung adalah hawar yang disebabkan oleh *Helminthosporium turcicum*, bercak daun abu-abu yang disebabkan oleh *Cercospora zea-maydis*, dan karat biasa yang disebabkan oleh *Puccinia sorgi* Schw dan *Puccinia polypore* Underw. Penyakit daun pada tanaman jagung disebabkan oleh virus, jamur dan bakteri. Kurangnya pengetahuan petani mengenai penyakit tanaman jagung dapat mengakibatkan berkurangnya hasil panen dan penyakit yang dapat timbul jika tidak dilakukan pengobatan [4].

Klasifikasi merupakan proses penting dalam komputasi yang melibatkan pengelompokan objek ke dalam kategori tertentu berdasarkan sifat dan karakteristiknya. Dalam ilmu komputer dan pembelajaran mesin, klasifikasi digunakan untuk membuat model prediktif yang dapat menyimpulkan kelas baru atau kelas objek berdasarkan data yang diketahui. Melalui langkah-langkah seperti pengumpulan data, pembuatan model, pelatihan model, evaluasi model, dan penerapan model, klasifikasi dapat diterapkan ke berbagai bidang seperti pengenalan model, pemrosesan gambar, dan analisis teks. Dengan klasifikasi, kita dapat mengekstrak informasi dalam data dan

membuat keputusan yang lebih baik berdasarkan prediksi yang akurat [5].

Terdapat sistem identifikasi otomatis untuk mengidentifikasi dan memprediksi penyakit tanaman menggunakan klasifikasi citra daun dengan metode convolution neural network (CNN) dan artificial neural network (ANN) sering di gunakan dalam sistem identifikasi penyakit tanaman. CNN efisien dalam klasifikasi citra daun dan mampu mencapai akurasi hingga 94,9% untuk mendeteksi penyakit daun apel dan 95,48% untuk mendiagnosa penyakit daun jagung [6].

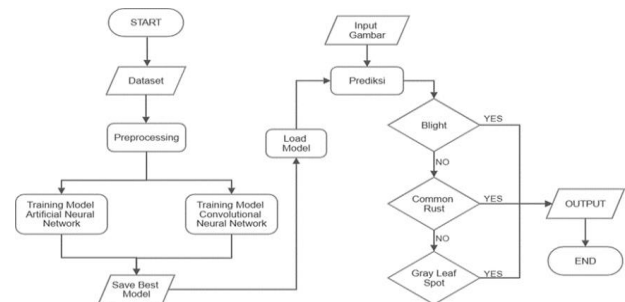
Algoritma Artificial Neural Network (ANN) adalah model berpikir yang didasarkan pada otak manusia. Jaringan saraf tiruan terdiri dari serangkaian prosesor yang sangat sederhana dan saling berhubungan yang disebut neuron [7]. ANN, model matematika yang terinspirasi oleh jaringan saraf biologis, juga penting dalam proses identifikasi. Kedua model ini bekerja sama untuk memproses data gambar dan memodelkan hubungan antara gambar daun dan penyakit tanaman, sehingga mencapai tingkat akurasi yang tinggi [8].

Dalam penelitian berjudul "Analisis Perbandingan Metode Convolutional Neural Network (CNN) dan Artificial Neural Network (ANN) dalam Klasifikasi Penyakit Daun Jagung," masalah utama yang dihadapi adalah bagaimana mengembangkan model yang akurat untuk mengidentifikasi penyakit pada daun jagung, seperti Blight, Gray Leaf Spot, dan Common Rust, menggunakan data citra digital. Penyakit ini dapat menyebabkan penurunan hasil panen yang signifikan jika tidak ditangani dengan cepat. Penelitian ini bertujuan untuk membandingkan kinerja dua pendekatan pembelajaran mesin, yaitu CNN dan ANN, dalam hal akurasi klasifikasi penyakit. Dengan membandingkan kedua metode ini, penelitian bertujuan membandingkan akurasi cnn dan ann dalam klasifikasi penyakit daun.

## 2. METODE PENELITIAN

Alur yang dilakukan dalam penelitian klasifikasi penyakit daun jagung dimulai dari pengumpulan dataset, preprocessing, trening

model CNN, trening model ANN, seve best model, loar model, input gambar, prediksi, output dan hasil penelitian [9]. Gambar 1 menunjukkan alur model penelitian.



**Gambar 1. Flowchart Alur Model Penelitian**

### 2.1 Pengumpulan Dataset

Penelitian klasifikasi penyakit tanaman daun jagung memerlukan dataset gambar penyakit tanaman daun jagung yang diperoleh dari sumber Kaggle. Dataset ini terdiri dari 2900 citra daun jagung dengan tiga jenis penyakit: Bright, Gray Leaf Sport, dan Common Rust [10]. Setiap citra dalam format JPG digunakan sebagai data pelatihan dan validasi dalam penelitian ini. Data daun jagung yang digunakan sebagai dataset ini diambil dari website [www.kaggle.com](https://www.kaggle.com) dengan URL: <https://www.kaggle.com/datasets/smaranjitghose/corn-or-maize-leaf-disease-dataset/data>. Dataset tersebut memberikan dasar untuk melatih dan menguji model klasifikasi penyakit tanaman daun jagung [11]. Gambar 2.2 menunjukkan Sampel data setiap kelas.



**Gambar 2. Sampel Data Setiap Kelas**

### 2.2 Preprocessing

Pre-processing daun jangung adalah penggunaan komputer untuk memproses gambar dua dimensi. Gambar digital direpresentasikan sebagai array yang berisi nilai nyata atau kompleks yang direpresentasikan dalam bentuk rangkayan bit tertentu. Dua pendekatan umum yang digunakan dalam pemrosesan gambar digital: Convolutional Neural Network (CNN) dan Artificial Neural Network (ANN) [12].

### 2.3 Training model Convolutional Neural Network (CNN)

Proses pelatihan model Convolutional Neural Network (CNN) merupakan tahapan kunci dalam pengembangan model untuk mencapai akurasi klasifikasi yang tinggi. CNN termasuk dalam kategori Deep Neural Network karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data gambar. Dalam proses ini, sebagian besar data digunakan untuk melatih model agar dapat mengidentifikasi pola dan fitur yang relevan dalam dataset [13].

### 2.4 Training model Artificial Neural Network (ANN)

Dalam proses pelatihan model Artificial Neural Network (ANN), dataset diproses menjadi data training. Hal ini sangat penting untuk mengoptimalkan kinerja model dengan menggunakan data training untuk melatih model [14].

### 2.5 Seve Beas Model

Penelitian ini memanfaatkan Convolutional Neural Network (CNN) dan Artificial Neural Network (ANN) untuk mengklasifikasikan gambar. Model dilatih menggunakan dataset yang sesuai dan dioptimalkan dengan parameter terbaik guna mencapai kinerja maksimum. Untuk memastikan kualitasnya, ModelCheckpoint diaplikasikan untuk menyimpan model dengan performa validasi tertinggi, yang kemudian akan dievaluasi dan diuji lebih lanjut. [2].

### 2.6 Load Model

Dalam Load Model ini, digunakan Convolutional Neural Network (CNN) dan Artificial Neural Network (ANN) digunakan sebagai arsitektur model tugas klasifikasi gambar. Setelah proses pelatihan yang tepat, model-model tersebut di simpan dalam format yang sesuai.

### 2.7 Input Gambar

Dalam menginput gambar merupakan langkah kunci dalam memasukkan data gambar kedalam model untuk menganalisis dan memperdiksi hasil deteksi penyakit daun jagung.

### 2.8 Prediksi

Dalam menginput gambar merupakan langkah kunci dalam memasukkan data gambar kedalam model untuk menganalisis dan memperdiksi hasil deteksi penyakit daun jagung.

### 2.9 Output

Jika untuk mengetahui output dari gambar penyakit daun jagung kita input, apakah gambar tersebut termaksud penyakit Bright, Healthy, Gray Leaf Sport atau Common Rus.

## 3. HASIL DAN PEMBAHASAN

Tahapan ini adalah proses untuk memperoleh output dari struktur model yang telah dikembangkan dalam penelitian ini dalam konteks pengklasifikasian penyakit pada daun jagung, yang kemudian akan dianalisis untuk mendapatkan hasil dan pembahasan terkait performa model dalam memprediksi jenis penyakit yang menyerang daun jagung.


### 3.1. Dataset

Data gambar yang akan digunakan untuk implementasi atau pengujian terdiri dari total 2900 gambar yang mewakili tiga jenis penyakit pada daun jagung, yaitu Blight, Common Rust, dan Gray Leaf Spot. Setiap jenis penyakit memiliki jumlah gambar yang berbeda, menyediakan keragaman yang diperlukan untuk analisis yang komprehensif dan valid. Data ini akan memungkinkan evaluasi yang lebih mendalam terhadap kinerja model dalam mengidentifikasi dan mengklasifikasikan berbagai jenis penyakit pada daun jagung.

#### 1. Blight

Penyakit Blight adalah penyakit tanaman yang disebabkan oleh infeksi patogen, terutama jamur atau bakteri, dan dicirikan oleh kerusakan cepat dan parah pada bagian tanaman, seperti daun, batang, bunga, atau buah. Blight diklasifikasikan berdasarkan penyebabnya (jamur atau bakteri), gejala (daun, batang, bunga), dan tanaman yang diserang (tanaman pangan, buah, atau hias). Blight dapat menyebabkan kerugian ekonomi yang signifikan pada sektor pertanian, dan pengendaliannya melibatkan berbagai metode, seperti penggunaan varietas tanaman yang tahan terhadap penyakit, rotasi tanaman, dan


aplikasi fungisida atau antibiotik. Gambar 3.1 menunjukkan dataset Blight.



Gambar 4. Dataset Blight

## 2. Common Rust

Common Rust adalah penyakit tanaman yang disebabkan oleh jamur *Puccinia sorghi*. Penyakit ini umumnya menyerang tanaman jagung, menciptakan bercak-bercak berwarna karat pada daun, batang, dan bahkan bunga tanaman. Gejala ini terjadi karena spora jamur menyebar melalui angin dan air, mempengaruhi pertumbuhan tanaman dan mengurangi hasil panen. Common Rust seringkali berkembang pada kondisi cuaca yang dingin dan lembap, memperburuk kondisi tanaman jagung. Pengendalian penyakit ini melibatkan penggunaan varietas tanaman yang tahan, menjaga kebersihan kebun, dan penggunaan fungisida yang tepat untuk mengendalikan penyebaran jamur *Puccinia sorghi*. Dengan langkah-langkah pencegahan yang tepat, Common Rust dapat dikelola dengan efektif untuk menjaga kesehatan dan produktivitas tanaman jagung. Gambar 3.2 menunjukkan dataset Common Rust.




Gambar 5. Dataset Common Rust

## 3. Gray Leaf Spot

Gray Leaf Spot adalah penyakit jamur yang menyerang rumput, terutama jenis rumput ryegrass tahunan, fescue tinggi, dan St. Augustine. Penyakit ini menyebabkan munculnya bercak-bercak kecil berwarna coklat keemasan dengan tepi coklat tua pada daun rumput. Ketika kondisi lembap, bercak-bercak ini akan berubah menjadi abu-abu dan berbulu karena pertumbuhan spora jamur. Gray Leaf Spot paling sering terjadi pada rumput yang baru ditanam, terutama pada tahun pertama, dan dapat menyebabkan

kerusakan yang signifikan pada rumput. Gambar 3.3 menunjukkan dataset Gray Leaf Spot.



Gambar 6. Dataset Gray Leaf Spot

## 3.2. Pemrosesan

Prapemrosesan citra adalah langkah krusial yang dilakukan sebelum citra digunakan untuk melatih model. Tahap ini mencakup berbagai proses penting, seperti:

### 1. Hyperparameter : Menentukan Ukuran Gambar

Hiperparameter dalam deep learning memainkan peranan penting dalam pengaturan proses pelatihan model, meskipun mereka tidak dipelajari oleh model itu sendiri. Hiperparameter ini sangat krusial karena mempengaruhi bagaimana model belajar dan beradaptasi terhadap data pelatihan yang tersedia. Beberapa contoh hiperparameter yang sering disesuaikan meliputi laju pembelajaran awal, yang mengatur seberapa cepat model belajar; ukuran batch, yang menentukan jumlah sampel data yang digunakan untuk setiap pembaruan model; dan ukuran gambar, misalnya 256x256 piksel, yang menetapkan dimensi standar untuk semua gambar yang digunakan dalam pelatihan.

Pengaturan hiperparameter yang tepat sangat penting untuk mencapai kinerja model yang optimal. Memilih nilai hiperparameter yang tepat dapat meningkatkan akurasi model, kecepatan pelatihan, dan kemampuan generalisasi model pada data yang belum pernah dilihat sebelumnya. Proses penyesuaian hiperparameter seringkali dilakukan melalui metode trial and error, dengan mencoba berbagai kombinasi nilai dan mengevaluasi kinerja model pada data validasi.

### 2. Labeling: Menentukan Kategori Gambar untuk Pembelajaran Model

Labeling merupakan langkah krusial dalam deep learning yang melibatkan pemberian label pada citra gambar, sehingga model dapat memahami dan

mengklasifikasikan gambar dengan akurat. Proses ini dilakukan setelah data terkumpul dan mencakup penentuan kategori atau kelas untuk setiap gambar berdasarkan objek utama yang ada di dalamnya. Sebagai contoh, apabila kumpulan data gambar berisi berbagai jenis penyakit tanaman, seperti Blight, Common Rust, dan Gray Leaf Spot, setiap gambar akan diberi label sesuai dengan jenis penyakit yang ditunjukkan.

Label yang diberikan pada setiap gambar menjadi acuan utama bagi model dalam proses pelatihan. Model akan mempelajari hubungan antara fitur-fitur yang ada dalam gambar dengan label yang diberikan, sehingga pada akhirnya dapat mengklasifikasikan gambar baru dengan benar berdasarkan fitur-fitur yang serupa. Oleh karena itu, proses labeling harus dilakukan dengan hati-hati dan akurat untuk memastikan bahwa model dapat belajar dengan benar dan menghasilkan hasil yang akurat. Kesalahan dalam labeling dapat menyebabkan model mempelajari pola yang salah dan menghasilkan klasifikasi yang tidak tepat.

Dalam penelitian klasifikasi penyakit daun jagung menggunakan Convolutional Neural Network, penggunaan berbagai layer seperti Conv2D, MaxPooling2D, Flatten, dan Dense telah memberikan hasil yang signifikan. Fungsi aktivasi ReLu digunakan dalam setiap layer untuk memperoleh representasi yang optimal. Ukuran kernel/filter 3x3 digunakan dalam setiap layer konvolusi, sementara ukuran pooling 2x2 digunakan untuk mereduksi dimensi. Jumlah filter/kernel bervariasi, dengan 512 filter untuk layer konvolusi 1, 256 filter untuk layer konvolusi 2, 128 filter untuk layer konvolusi 3, dan 64 filter untuk layer konvolusi 4. Total parameter yang dilatih dalam model ini mencapai 2,153,156 parameter. Proses training dilakukan dengan epoch 25, 50, 75, dan 100, di mana proses training akan berhenti saat mencapai kondisi yang ditentukan. Model Summary Klasifikasi CNN dan ANN dapat dilihat pada gambar 3.4 dan 3.5.

```

Model: "sequential_1"
-----
Layer (type)                Output Shape                Param #
-----
conv2d_3 (Conv2D)           (None, 256, 256, 512)      14336
activation_4 (Activation)   (None, 256, 256, 512)      0
max_pooling2d_3 (MaxPoolin (None, 85, 85, 512)        0
dropout_4 (Dropout)         (None, 85, 85, 512)        0
conv2d_4 (Conv2D)           (None, 85, 85, 256)        117904
activation_5 (Activation)   (None, 85, 85, 256)        0
max_pooling2d_4 (MaxPoolin (None, 28, 28, 256)        0
dropout_5 (Dropout)         (None, 28, 28, 256)        0
conv2d_5 (Conv2D)           (None, 28, 28, 128)        29504
activation_6 (Activation)   (None, 28, 28, 128)        0
max_pooling2d_5 (MaxPoolin (None, 9, 9, 128)          0
dropout_6 (Dropout)         (None, 9, 9, 128)          0
flatten_1 (Flatten)         (None, 10368)              0
dense_1 (Dense)             (None, 64)                 66816
activation_7 (Activation)   (None, 64)                 0
dropout_7 (Dropout)         (None, 64)                 0
dense_2 (Dense)             (None, 4)                  260
activation_8 (Activation)   (None, 4)                  0
-----
Total params: 2153156 (8.21 MB)
Trainable params: 2153156 (8.21 MB)
Non-trainable params: 0 (0.00 Byte)
    
```

Gambar 7. Model Summary Klasifikasi CNN

```

Model: "sequential_1"
-----
Layer (type)                Output Shape                Param #
-----
flatten_1 (Flatten)         (None, 196608)             0
dense_4 (Dense)             (None, 512)                100663808
activation_4 (Activation)   (None, 512)                0
dropout_4 (Dropout)         (None, 512)                0
dense_5 (Dense)             (None, 256)                131328
activation_5 (Activation)   (None, 256)                0
dropout_5 (Dropout)         (None, 256)                0
dense_6 (Dense)             (None, 128)                32896
activation_6 (Activation)   (None, 128)                0
dropout_6 (Dropout)         (None, 128)                0
dense_7 (Dense)             (None, 64)                 8256
activation_7 (Activation)   (None, 64)                 0
dropout_7 (Dropout)         (None, 64)                 0
dense_8 (Dense)             (None, 4)                  260
activation_8 (Activation)   (None, 4)                  0
-----
Total params: 100836548 (384.66 MB)
Trainable params: 100836548 (384.66 MB)
Non-trainable params: 0 (0.00 Byte)
    
```

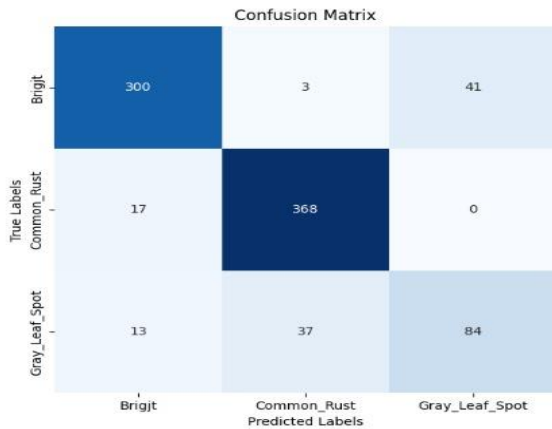
Gambar 8. Model Summary Klasifikasi ANN

### 3.3. Confusion Matrix

Confusion matrix merupakan metode evaluasi yang efektif untuk mengukur kinerja model klasifikasi dengan membandingkan hasil prediksi model terhadap data aktual. Dalam studi ini, total data yang digunakan berjumlah 2900, yang dibagi dengan proporsi 70:30, di mana 2030 data dialokasikan untuk pelatihan dan 870 data untuk pengujian. Confusion matrix menyajikan hasil prediksi dalam empat kategori: True Positive (TP), False Positive (FP), True Negative (TN), dan False Negative (FN). Melalui pendekatan ini, kita dapat mengevaluasi kinerja model secara menyeluruh, memahami pola kesalahan prediksi, dan menghitung berbagai metrik penting seperti akurasi, presisi, dan recall. Dengan menggunakan confusion matrix, kita dapat mengidentifikasi langkah-langkah optimasi yang diperlukan untuk meningkatkan performa model klasifikasi. Di bawah ini, kami sajikan analisis hasil evaluasi berdasarkan confusion matrix yang telah disusun dari total data 2900, serta evaluasi untuk masing-masing model yang diterapkan. Berikut ini adalah analisis untuk masing-masing model yang digunakan:

1. Convolutional Neural Network (CNN)

Confusion matrix CNN dapat dilihat pada Gambar 3.6



Gambar 9. Confusion Matrix CNN

Precision bertujuan untuk mengukur sejauh mana akurasi prediksi positif yang dihasilkan oleh model. Ukuran ini mengevaluasi seberapa efektif sistem dalam mengidentifikasi kelas positif dengan membandingkan jumlah prediksi positif yang benar terhadap total prediksi positif yang dibuat. Dengan demikian, precision mencerminkan kemampuan sistem dalam mengenali elemen-elemen yang benar-benar relevan dalam kategori positif, sekaligus meminimalkan kesalahan dalam pengklasifikasian data yang tidak sesuai. Perhitungan precision dapat dilakukan dengan rumus berikut:

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive} \times 100\%$$

Untuk setiap kelas dalam Matrix :

- Precision Bright
 
$$= \frac{300}{300 + 3 + 41} \times 100\%$$

$$= \frac{300}{344} \times 100\% = 87,20\%$$
- Precision Common Rust
 
$$= \frac{368}{17 + 368 + 0} \times 100\%$$

$$= \frac{368}{392} \times 100\% = 93,87\%$$
- Precision Gray Leif Spot
 
$$= \frac{84}{13 + 37 + 84} \times 100\%$$

$$= \frac{84}{134} \times 100\% = 62,68\%$$

Recall, yang juga dikenal sebagai sensitivitas, mengukur sejauh mana model mampu mendeteksi semua kasus positif. Metrik ini menghitung perbandingan antara jumlah data positif yang berhasil diprediksi dengan benar dan jumlah total data positif yang sebenarnya ada. Perhitungan recall dilakukan dengan rumus berikut:

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative} \times 100\%$$

Semakin tinggi nilai recall, semakin efektif sistem dalam mendeteksi elemen yang seharusnya diidentifikasi, meskipun beberapa prediksi mungkin tidak sepenuhnya akurat. Recall memegang peranan penting untuk menjamin bahwa tidak ada data krusial yang terlewat dalam proses klasifikasi. Untuk setiap kelas dalam matriks:

- Recall Bright
 
$$= \frac{300}{300 + 3 + 41} \times 100\%$$

$$= \frac{300}{344} \times 100\% = 87,20\%$$
- Recall Common Rust
 
$$= \frac{368}{17 + 368 + 0} \times 100\%$$

$$= \frac{368}{392} \times 100\% = 93,87\%$$
- Recall Gray Leif Spot
 
$$= \frac{84}{13 + 37 + 84} \times 100\%$$

$$= \frac{84}{134} \times 100\% = 62,68\%$$

Accuracy digunakan untuk membandingkan sejauh mana prediksi yang dihasilkan oleh sistem mendekati nilai sebenarnya. Accuracy mengukur seberapa banyak prediksi yang benar dibagi dengan total data yang diuji. Perhitungan accuracy dilakukan dengan rumus berikut:

$$Accuracy = \frac{Total\ True\ Positive}{Total\ Data\ Uji} \times 100\%$$


- Total True Positive adalah jumlah elemen diagonal dalam Confusion Matrix, yang menunjukkan jumlah prediksi yang benar.:

Total True Positive = 300 + 368 + 84 = 752

- Total data uji = 870
- Jadi Accuracy =  $\frac{752}{870} \times 100\% = 86\%$

## 2. Artificial Neural Network (ANN)

Confusion matrix ANN dapat dilihat pada Gambar 3.7:



Gambar 10. Confusion Matrix ANN

Precision bertujuan untuk mengukur sejauh mana akurasi prediksi positif yang dihasilkan oleh model. Ukuran ini mengevaluasi seberapa efektif sistem dalam mengidentifikasi kelas positif dengan membandingkan jumlah prediksi positif yang benar terhadap total prediksi positif yang dibuat. Dengan demikian, precision mencerminkan kemampuan sistem dalam mengenali elemen-elemen yang benar-benar relevan dalam kategori positif, sekaligus meminimalkan kesalahan dalam pengklasifikasian data yang tidak sesuai. Perhitungan precision dapat dilakukan dengan rumus berikut:

$$\text{Precision} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}} \times 100\%$$

Untuk setiap kelas dalam Matrix :

- Precision Bright
 
$$= \frac{344}{344 + 10 + 0} \times 100\%$$

$$= \frac{344}{356} \times 100\% = 96\%$$
- Precision Common Rust
 
$$= \frac{350}{35 + 350 + 0} \times 100\%$$

$$= \frac{350}{385} \times 100\% = 90\%$$
- Precision Gray Leif Spot
 
$$= \frac{0}{126 + 5 + 0} \times 100\%$$

$$= \frac{0}{131} \times 100\% = 0\%$$

Recall, yang juga dikenal sebagai sensitivitas, mengukur sejauh mana model mampu mendeteksi semua kasus positif. Metrik ini menghitung perbandingan antara jumlah data positif yang berhasil diprediksi dengan benar dan jumlah total data positif yang sebenarnya ada. Perhitungan recall dilakukan dengan rumus berikut:

$$\text{Recall} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}} \times 100\%$$

Semakin tinggi nilai recall, semakin efektif sistem dalam mendeteksi elemen yang seharusnya diidentifikasi, meskipun beberapa prediksi mungkin tidak sepenuhnya akurat. Recall memegang peranan penting untuk menjamin bahwa tidak ada data krusial yang terlewat dalam proses klasifikasi. Untuk setiap kelas dalam matriks:

- Recall Bright
 
$$= \frac{344}{344 + 10 + 0} \times 100\%$$

$$= \frac{344}{356} \times 100\% = 96\%$$
- Recall Common Rust
 
$$= \frac{350}{35 + 350 + 0} \times 100\%$$

$$= \frac{350}{385} \times 100\% = 90\%$$
- Recall Gray Leif Spot
 
$$= \frac{0}{126 + 5 + 0} \times 100\%$$

$$= \frac{0}{131} \times 100\% = 0\%$$

Accuracy digunakan untuk membandingkan sejauh mana nilai prediksi mendekati nilai sebenarnya. Accuracy mengukur proporsi dari seluruh prediksi yang benar dibagi dengan total data yang diuji. Perhitungan accuracy dilakukan dengan rumus berikut:

$$\text{Accuracy} = \frac{\text{Total True Positive}}{\text{Total Data Uji}} \times 100\%$$

- Total True Positive adalah jumlah elemen diagonal dalam Confusion Matrix, yang menunjukkan jumlah prediksi yang benar:

Total True Positive = 334 + 350 + 0 = 694

- Total data uji = 870

$$\text{Jadi Accuracy} = \frac{694}{870} \times 100\% = 79\%$$

Hasil dari Confusion Matrix untuk model *Convolutional Neural Network (CNN)* dan *Artificial Neural Network (ANN)* menunjukkan bahwa CNN memiliki kinerja yang lebih baik dibandingkan ANN. Model CNN menunjukkan akurasi 86%, dengan precision dan recall yang baik pada kelas Common Rust dan Blight (masing-masing 93,87% dan 87,20%). Namun, CNN masih kesulitan dalam mengklasifikasikan Gray Leaf Spot (precision dan recall 62,68%). Sebaliknya, ANN memiliki akurasi yang lebih rendah (79%) karena gagal mendeteksi Gray Leaf Spot sama sekali, meskipun memiliki precision dan recall tinggi pada Blight (96%) dan Common Rust (90%). Kelemahan utama ANN terletak pada ketidakmampuannya mengenali Gray Leaf Spot, sementara CNN menunjukkan hasil yang lebih konsisten dan akurat pada kelas-kelas lainnya. Secara keseluruhan, CNN lebih unggul dalam klasifikasi penyakit daun jagung.

### 3.4. Epoch Convolutional Neural Network (CNN)

Epoch model CNN selama 50 menunjukkan peningkatan kinerja yang signifikan. Pada epoch 1, model memiliki nilai loss pelatihan 0,4052 dengan akurasi pelatihan 73,78%. Sementara itu, nilai loss validasi pada epoch 1 adalah 0,2890 dengan akurasi validasi 80,57%. Seiring berjalannya epoch, nilai loss terus menurun, sedangkan akurasi terus meningkat. Pada epoch 50, nilai loss pelatihan mencapai 0,19 dengan akurasi pelatihan 86,51%. Berikut adalah table 3.1 epoch yang merangkum hasil pelatihan model CNN selama 50 epoch:

**Tabel 1. Epoch CNN**

Epoch	Training loss	Training Accuracy
1	0,4052	73,78%
2	0,3041	80,14%
3	0,3248	80,09%
4	0,3084	80,09%
5	0,3089	79,99%
6	0,3007	80,34%
7	0,3007	80,04%
8	0,3065	79,94%
.....		
50	0.1921	86,51%

Tabel ini menunjukkan bahwa model CNN mampu meningkatkan kinerjanya secara signifikan selama proses pelatihan. Nilai loss terus menurun, sementara accuracy terus meningkat, baik pada pelatihan maupun data validasi.

### 3.5. Epoch Artificial Neural Network (ANN)

Model ANN untuk klasifikasi penyakit daun jagung selama 50 epoch menunjukkan peningkatan kinerja yang signifikan. Pada epoch 1, model memiliki nilai Accuracy pelatihan 44,99% dengan loss pelatihan 6,0318. Sementara itu, nilai accuracy validasi pada epoch 1 adalah 45,52% dengan loss validasi 0,4262. Seiring berjalannya epoch, nilai accuracy terus meningkat, sedangkan loss terus menurun. Pada epoch 50, nilai accuracy pelatihan 77,16% dengan loss pelatihan 0,3461%. Berikut adalah tabel 3.2 epoch yang merangkum hasil pelatihan model ANN selama 50 epoch:

**Tabel 2. Epoch ANN**

Epoch	Training Accuracy	Training Loss
1	44,99%	6,0318
2	71,40%	0,5061
3	74,13%	0,4473
4	74,58%	0,4174
5	71,75%	0,4256
6	72,24%	0,4169
7	72,24%	0,4335
8	72,14%	0,4159
.....		
50	77,16%	0,3461

Tabel ini menunjukkan bahwa model ANN mampu meningkatkan kinerjanya secara signifikan selama proses pelatihan. Nilai Accuracy terus meningkat, sementara Loss terus menurun, baik pada data pelatihan maupun data validasi. Hasil terbaik dicapai pada epoch 50, dengan nilai accuracy pelatihan 77,16% dan nilai loss pelatihan 0,3461.

### 3.6. Hasil Training dan Testing

Berdasarkan hasil pelatihan kedua metode, yaitu Convolutional Neural Network (CNN) mengungguli model Artificial Neural Network (ANN) dalam klasifikasi penyakit daun jagung. Berikut adalah tabel 3.3 hasil perbandingan kinerja kedua model:

**Tabel 3. Hasil Perbandingan Kedua Model**

Model	Accuracy (%)	Loss (%)
CNN	86,51	0,1921
ANN	77,16	0,3461

### 3.7. Hasil Output

Hasil pelatihan menunjukkan bahwa model Convolutional Neural Network (CNN) mencapai akurasi tertinggi sebesar 86,51% dengan nilai loss 0,1921. Hasil ini lebih baik dibandingkan dengan model Artificial Neural Network (ANN) yang hanya mencapai akurasi 77,16% dengan nilai loss 0,3461. Performa CNN yang lebih unggul ini menunjukkan bahwa arsitektur CNN, yang dirancang khusus untuk memproses data visual, lebih efektif dalam menangani data citra dibandingkan dengan model ANN yang lebih sederhana.


Hal ini dapat dijelaskan karena CNN mampu mengekstrak fitur-fitur spasial yang kompleks dari citra, seperti bentuk, tekstur, dan orientasi, yang sulit ditangkap oleh model ANN. Kemampuan ini memungkinkan CNN untuk mempelajari pola yang lebih rumit dan menghasilkan prediksi yang lebih akurat pada data citra. CNN menggunakan lapisan konvolusi untuk mendeteksi pola-pola lokal dalam citra, yang kemudian digabungkan untuk membentuk representasi fitur tingkat tinggi. Proses ini memungkinkan CNN untuk memahami struktur dan hubungan spasial dalam data citra, yang sangat penting untuk tugas-tugas seperti klasifikasi gambar dan deteksi objek. Sebaliknya, model ANN tradisional biasanya menggunakan lapisan terhubung penuh yang tidak dapat menangkap hubungan spasial dalam data citra dengan baik. Oleh karena itu, CNN lebih cocok untuk tugas-tugas pengolahan citra dan menghasilkan hasil yang lebih baik dibandingkan dengan model ANN.

### 3. Convolutional Neural Network (CNN)

Grafik Gambar 3.8 dan 3.9 menampilkan hasil pelatihan model Convolutional Neural Network (CNN) dengan menggunakan data latih (merah) dan data uji (biru). Visualisasi ini memberikan gambaran tentang kinerja model CNN dalam mempelajari pola dari data latih dan kemudian menguji kemampuannya pada data yang belum pernah dilihat sebelumnya. Grafik ini memungkinkan kita untuk

mengamati bagaimana model CNN memberikan prediksi yang akurat pada data latih dan data uji, serta mengevaluasi kinerja model berdasarkan perbedaan antara data latih dan data uji.

Grafik tersebut menunjukkan bahwa model CNN mampu mencapai akurasi yang tinggi pada data latih dan data uji, yang ditunjukkan oleh kurva akurasi yang meningkat dan kurva loss yang menurun. Perbedaan yang kecil antara kinerja model pada data latih dan data uji mengindikasikan bahwa model CNN tidak mengalami overfitting, yaitu kondisi di mana model terlalu terlatih pada data latih sehingga tidak dapat menggeneralisasi dengan baik pada data baru. Hasil ini menunjukkan bahwa model CNN yang dirancang khusus untuk pengolahan citra mampu mempelajari pola-pola kompleks dalam data visual dan menghasilkan prediksi yang akurat pada data yang belum pernah dilihat sebelumnya. Lebih lanjut, model CNN ini mencapai akurasi tertinggi sebesar 86,51% dengan nilai loss 0,1921, yang menunjukkan performa yang sangat baik dalam mengklasifikasikan data citra. Gambar 3.8 dan 3.9 menunjukkan Accuracy dan Loss CNN.

**Gambar 11. Accuracy CNN****Gambar 12. Loss CNN**

### 4. Artificial Neural Network (ANN)

Model Artificial Neural Network (ANN) yang ditampilkan dalam grafik Gambar 3.9 dan 3.10 menunjukkan kinerja yang baik dalam mempelajari pola dari data latih dan melakukan prediksi pada data uji. Meskipun model ANN mampu mencapai akurasi yang cukup baik, namun model ini

lebih rentan terhadap overfitting dibandingkan dengan model Convolutional Neural Network (CNN). Hal ini terlihat dari perbedaan yang lebih besar antara kinerja model pada data latih dan data uji, yang mengindikasikan bahwa model ANN mungkin terlalu terlatih pada data latih dan kurang mampu menggeneralisasi ke data baru. Model ANN yang ditampilkan dalam grafik ini mencapai akurasi 77,16% dengan nilai loss 0,3461, yang menunjukkan bahwa model ANN ini kurang efektif dalam menangani data citra dibandingkan dengan model CNN yang mencapai akurasi 86,51% dengan nilai loss 0,1921. Gambar 3.9 dan 3.10 menunjukkan Accuracy dan Loss ANN.



Gambar 13. Accuracy ANN



Gambar 14. Loss ANN

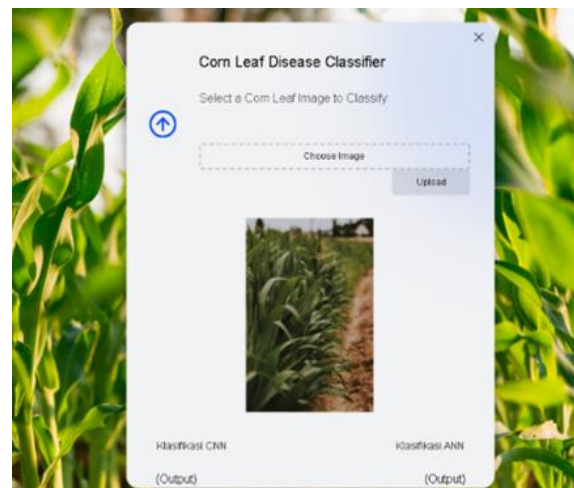
### 3.8. Pengujian Model Aplikasi

Hasil yang dihasilkan oleh model dapat terlihat dalam Gambar 3.13 dan 3.16. Antarmuka akan mengirimkan gambar yang akan diklasifikasikan dalam format JSON melalui API, dan akan menerima hasil klasifikasi yang dikirim oleh backend dalam format JSON juga. Output dari perbandingan hasil klasifikasi akan disajikan sebagai berikut: Gambar 3.13 menunjukkan hasil klasifikasi untuk dataset training, sementara Gambar 3.16 menunjukkan hasil klasifikasi untuk dataset testing. Perbandingan ini bertujuan untuk mengevaluasi kemampuan model dalam menggeneralisasi data baru yang belum pernah dilihat sebelumnya. Proses ini melibatkan pertukaran data antara antarmuka dan backend, di mana antarmuka berperan sebagai penghubung antara pengguna dan model, sementara backend bertanggung jawab untuk menjalankan model dan menghasilkan output klasifikasi. Informasi yang ditampilkan dalam kedua gambar tersebut akan memberikan gambaran tentang akurasi dan

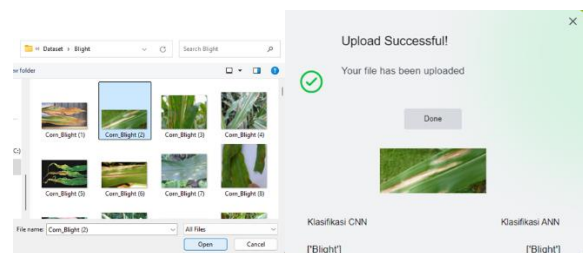
performa model dalam mengklasifikasikan penyakit pada daun jagung, yang selanjutnya akan dianalisis untuk mendapatkan kesimpulan dan rekomendasi. Tahapan ini ditunjukkan pada gambar 3.11 sampai gambar 3.16.



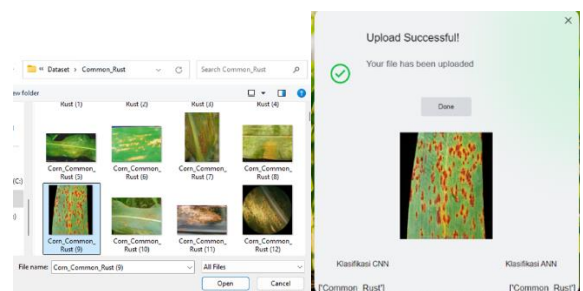
Gambar 3. 11 Tampilan Utama Klasifikasi Daun Jagung



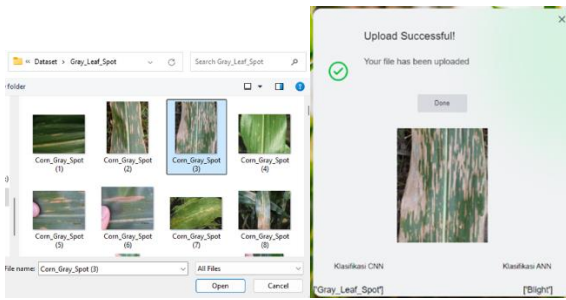
Gambar 3. 12 Mengupload Gambar Daun Jagung




Gambar 3. 13 Daun Jagung Blight



Gambar 3. 14 Daun Jagung Common Rust



Gambar 3. 15 Daun Jagung Gray Leaf Spot



Gambar 3. 16 Daun ubi

#### 4. SIMPULAN

Berdasarkan penelitian yang dilakukan, dapat disimpulkan bahwa penggunaan metode Convolutional Neural Network (CNN) lebih efektif dibandingkan dengan Artificial Neural Network (ANN) dalam klasifikasi penyakit daun jagung. Hasil penelitian menunjukkan bahwa model CNN mencapai akurasi pelatihan sebesar 86,51% dengan kehilangan (loss) 0,1921 setelah 50 epoch, sementara model ANN hanya mencapai akurasi 77,16% dengan kehilangan 0,3461. Selain itu, CNN menunjukkan kemampuan yang lebih baik dalam menangani data gambar, dengan kurangnya overfitting dan generalisasi yang lebih baik terhadap data yang tidak terlihat.

Dalam hal evaluasi kinerja model, Confusion Matrix digunakan untuk mengukur precision, recall, dan accuracy. CNN menunjukkan precision dan recall yang lebih baik pada kelas Common Rust dan Blight, dengan nilai accuracy mencapai 86%, sedangkan ANN memiliki kesulitan dalam mengidentifikasi Gray Leaf Spot, yang tercermin dalam nilai precision dan recall yang rendah pada kelas tersebut. Oleh

karena itu, CNN direkomendasikan untuk aplikasi pertanian, khususnya dalam deteksi penyakit pada tanaman, karena kemampuannya yang lebih unggul dalam klasifikasi dan akurasi prediksi.

#### DAFTAR RUJUKAN

- [1] U. Khaira, I. Weni, and W. Wilia, "Rancang Bangun Aplikasi Deteksi Penyakit Tanaman Jagung Melalui Citra Daun Berbasis Android Menggunakan Algoritma Convolutional Neural Network," *J. Pepadun*, vol. 5, no. 1, pp. 1–11, 2024, doi: 10.23960/pepadun.v5i1.210.
- [2] A. D. Nurcahyati, R. M. Akbar, and S. Zahara, "Klasifikasi Citra Penyakit pada Daun Jagung Menggunakan Deep Learning dengan Metode Convolution Neural Network (CNN)," *SUBMIT J. Ilm. Teknol. Infomasi dan Sains*, vol. 2, no. 2, pp. 43–51, 2022, doi: 10.36815/submit.v2i2.1877.
- [3] M. I. Rosadi and M. Lutfi, "Identifikasi Jenis Penyakit Daun Jagung Menggunakan Deep Learning Pre-Trained Model," vol. 5, no. 36, pp. 35–42, 2021.
- [4] G. Sarah Siti, "Identifikasi Penyakit Tanaman Jagung Berdasarkan Citra Daun Tinjauan Literatur Sistematis (Slr)," *Semaster*, vol. 278–289, no. Prosiding-Seminar Nasional Teknologi Informasi & Ilmu Komputer (SEMASTER), pp. 1–12, 2023.
- [5] N. W. S. Agustini, D. Priadi, and R. V. Atika, "Profil Kimia dan Aktivitas Antibakteri Fraksi Aktif Nannochloropsis sp. sebagai Senyawa Penghambat Bakteri Penyebab Gangguan Kesehatan Mulut," *J. Pascapanen dan Bioteknol. Kelaut. dan Perikan.*, vol. 17, no. 1, p. 19, 2022, doi: 10.15578/jpbkp.v17i1.781.
- [6] M. Khoiruddin, A. Junaidi, and W. A. Saputra, "Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network," *J. Dinda Data Sci. Inf. Technol. Data Anal.*, vol. 2, no. 1, pp. 37–45, 2022, doi: 10.20895/dinda.v2i1.341.
- [7] D. Pradana, M. Luthfi Alghifari, M. Farhan Juna, and D. Palaguna, "Klasifikasi Penyakit Jantung Menggunakan Metode Artificial Neural Network," *Indones. J. Data Sci.*, vol. 3,

- no. 2, pp. 55–60, 2022, doi: 10.56705/ijodas.v3i2.35.
- [8] L. A. Putri and Suwanda, “Implementasi Metode Artificial Neural Network (ANN) Algoritma Backpropagation untuk Klasifikasi Kualitas Udara di Provinsi DKI Jakarta Tahun 2021,” *Bandung Conf. Ser. Stat.*, vol. 3, no. 2, pp. 184–191, 2023, doi: 10.29313/bcss.v3i2.7826.
- [9] Ulfah Nur Oktaviana, Ricky Hendrawan, Alfian Dwi Khoirul Annas, and Galih Wasis Wicaksono, “Klasifikasi Penyakit Padi berdasarkan Citra Daun Menggunakan Model Terlatih Resnet101,” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 6, pp. 1216–1222, 2021, doi: 10.29207/resti.v5i6.3607.
- [10] D. Iswanto 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.
- [11] A. Lawi, N. S. Intizhami, R. Mukhtarom, and S. Amir, “Klasifikasi Penyakit Citra Daun Tanaman Tomat Dengan Ensemble Convolutional Neural Network,” *Sntei*, pp. 207–212, 2022.
- [12] R. Prabowo, Y. Heningtyas, machudor Yusman, M. Iqbal, and O. D. E. Wulansari, “Klasifikasi Image Tumbuhan Obat (Keji Beling) Menggunakan Artificial Neural Network,” *J. Komputasi*, vol. 9, no. 2541–0350, pp. 88–92, 2021, doi: 10.23960/komputasi.v9i2.2868.
- [13] A. Ibnul Rasidi, Y. A. H. Pasaribu, A. Ziqri, and F. D. Adhinata, “Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network,” *J. Tek. Inform. dan Sist. Inf.*, vol. 8, no. 1, pp. 142–149, 2022, doi: 10.28932/jutisi.v8i1.4314.
- [14] M. A. Putri and T. Sukmono, “Analisa Peramalan Penjualan Kerupuk Udang dengan menggunakan Metode Artificial Neural Network (ANN),” *Innov. Technol. Methodical Res. J.*, vol. 2, no. 4, pp. 1–11, 2024, doi: 10.47134/innovative.v2i4.93.