

Klasifikasi Citra Hasil Potret Daun Tanaman Jagung Menggunakan *Transfer Learning Deep Learning*

Zendi Iklima^{1*}, Yananto Mihadi Putra²

¹Teknik Elektro, Universitas Mercu Buana, Jakarta

²Akuntansi, Universitas Mercu Buana, Jakarta

*zendi.iklima@mercubuana.ac.id

Abstrak— Penyakit pada tanaman jagung dapat mempengaruhi produksi jagung, menghambat pertumbuhan tanaman jagung, penurunan kualitas jagung, dan kelangkaan jagung yang memicu kenaikan harga jagung. Hama serangga menjadi salah satu ancaman pada tanaman jagung. Kerusakan yang diakibatkan oleh hama serangga dapat dirasakan secara langsung dengan adanya daun – daun yang berlubang. Pendeteksian lebih dini dapat membantu para petani untuk memaksimalkan hasil panen. Teknik pembelajaran mesin menjadi salah satu teknologi yang telah digunakan untuk menyederhanakan proses klasifikasi penyakit pada daun. Dataset yang digunakan ialah hasil potret citra pada daun tanaman jagung yang sehat dan berlubang akibat hama. Dari beberapa metode yang ada, Convolutional Neural Network (CNN) menjadi metode yang paling optimal dalam domain klasifikasi tersebut. Penelitian ini menggunakan model deep learning terlatih yaitu transfer learning model yang sudah dilatih menggunakan berbagai macam dataset yang beragam. Adapun beberapa transfer learning model seperti MobileNet, VGG, Inception, dan lainnya. Hasil pengujian menunjukkan bahwa model VGG16 dan model Inception_V3 memiliki nilai akurasi paling tinggi dengan nilai akurasi 94.44%, dilanjutkan dengan model MobileNet dengan nilai akurasi 91.67%, model Xception dengan nilai akurasi 88.89%, dan model Inception_ResNet_V2 memiliki nilai akurasi paling rendah dengan nilai akurasi 87.50%.

Kata Kunci— Citra; Convolutional Neural Network (CNN); Daun; Jagung; Transfer Learning Model

DOI: 10.22441/jitkom.v8i2.008

Article History:

Received: August 21, 2023

Revised: June 3, 2024

Accepted: June 13, 2024

Published: July 13, 2024

I. PENDAHULUAN

Penyakit pada tanaman jagung dapat mempengaruhi produksi jagung, menghambat pertumbuhan tanaman jagung, penurunan kualitas jagung, dan kelangkaan jagung yang memicu kenaikan harga jagung.[1] Beberapa penyakit yang sering muncul pada tanaman jagung akibat adanya mikroorganisme adalah northern leaf blight, cercospora leaf spot, dan common rust. Selain mikroorganisme, hama serangga juga menjadi salah satu ancaman pada daun tanaman jagung. Kerusakan pada tanaman jagung yang diakibatkan oleh hama serangga dapat dirasakan secara langsung dengan adanya daun – daun yang berlubang. Luka pada daun yang berlubang dapat menciptakan akses bagi banyak mikroorganisme. [2] Salah satu contoh hama penyebab daun berlubang adalah larva atau ulat grayak jagung *spodoptera frugiperda* yang ditemukan pada awal tahun 2019 di daerah Sumatera. Hama ini menyerang pucuk daun baru sehingga menyebabkan kegagalan pembentukan daun baru [3]. Pada penelitian [4], disebutkan persebaran hama ini ditemukan dengan populasi rendah di Kabupaten Bandung dan Garut, serta ditemukan dengan populasi tinggi pada Kabupaten Sumedang dengan populasi 35 ekor di tiap tanaman. Melihat buruknya dampak yang dapat diakibatkan penyakit pada tanaman jagung, pendeteksian lebih dini penyakit pada tanaman jagung dapat bermanfaat serta membantu para petani untuk hasil panen yang

lebih maksimal. Namun, identifikasi penyakit tanaman jagung dengan cara konvensional juga akan membutuhkan banyak waktu dan biaya yang mana dapat merugikan para petani. Seiring berkembangnya teknologi, muncul kebutuhan untuk mengembangkan teknologi pertanian yang maju. Teknik pembelajaran mesin menjadi salah satu teknologi yang telah digunakan untuk menyederhanakan proses klasifikasi penyakit pada daun. Jaringan syaraf merupakan algoritma yang sering digunakan untuk klasifikasi objek. Beberapa metode jaringan syaraf yang sering digunakan adalah Artificial Neural Network (ANN), Probabilistic Neural Network (PNN), Convolutional Neural Network (CNN), K-Nearest Neighbor (KNN), dan Support Vector Machine (SVM) [5]. Dari beberapa metode jaringan syaraf tiruan yang sering digunakan, Convolutional Neural Network (CNN) telah mendominasi teknik pembelajaran mesin dalam bidang vision dalam beberapa tahun terakhir [6].

Beberapa penelitian telah menggunakan Convolutional Neural Network (CNN) untuk mengklasifikasikan penyakit daun pada tanaman, seperti klasifikasi penyakit daun bacterial spot, late blight, septoria spot, yellow curved, dan daun sehat pada tanaman tomat [7], klasifikasi penyakit daun rice blast, leaf blight, brown spot, dan daun sehat pada tanaman padi [8], klasifikasi penyakit daun apple scab, black rot, cedar rust, dan daun sehat pada tanaman apel [9], serta klasifikasi daun sehat dan daun berpenyakit pada tanaman kedelai. Pada tanaman

jagung sendiri, beberapa penelitian telah melakukan klasifikasi penyakit pada tanaman jagung yang diakibatkan oleh mikroorganisme seperti *Cercospora leaf spot*, common rust, dan northern leaf blight [1] [10] dengan menggunakan Convolutional Neural Network (CNN) [11]. Namun, belum ditemukan penelitian yang melakukan klasifikasi penyakit daun tanaman jagung yang diakibatkan oleh hama serangga dengan menggunakan teknik pembelajaran mesin. Penelitian ini akan mengklasifikasikan penyakit pada daun tanaman jagung yang diakibatkan oleh hama serangga dengan menggunakan teknik pembelajaran mesin jaringan syaraf, metode yang akan digunakan pada penelitian ini adalah Convolutional Neural Network (CNN).

II. LITERATURE REVIEW

Pendekatan Artificial Intelligence menjadi topik yang menarik guna mengembangkan sistem otomatisasi khususnya dalam meningkatkan kualitas dan kuantitas produksi. Proses pembersihan korosi pada produk telah dilakukan misalnya dengan cara grinding yang diintegrasikan dengan robot yang terinstall dengan perangkat penangkap visual/kamera. Jaringan Syaraf Tiruan (CNN) sebagai usulan untuk efisiensi dalam akurasi akuisisi dan klasifikasi yang akurat dari gambar resolusi tinggi dengan memindai mikroskop elektron. Dengan melakukan augmentasi data yang sesuai pada gambar pelatihan. CNN berhasil dilatih pada sejumlah kecil gambar dan mencapai akurasi klasifikasi cacat yang tinggi. Dalam penelitian ini VGG16 digunakan sebagai arsitektur CNN dasar karena kemudahan penggunaannya. Untuk mengklasifikasi cacat hanya mengganti lapisan VGG16 yang terhubung penuh. Hasil dari penelitian ini adalah CNN berbasis VGG16 untuk klasifikasi cacat sebaris. CNN dilatih pada gambar cacat manufaktur aktual yang diambil oleh SEM setelah proses Cu. Akurasi klasifikasi adalah sekitar 95% pada dataset pelatihan kecil (30 gambar per jenis cacat). Augmentasi data yang tepat meningkatkan akurasi klasifikasi [12].

Klasifikasi hasil potret citra penyakit tanaman tomat yang terbagi menjadi enam kategori yaitu (bacterial spot, early blight, late blight, leaf mold, yellow curl, dan mosaic virus) berhasil diimplementasikan menggunakan transfer learning model CNN. Tahap awal dalam klasifikasi adalah pemrosesan gambar untuk meningkatkan karakteristik gambar. Langkah yang dilakukan adalah mengubah ukuran gambar, menghapus latar belakang gambar, dan pendeteksian tepi objek (canny filters). Dari 100 dataset gambar untuk training, dataset diolah dan disimpan menjadi tiga jenis dataset yang berbeda yaitu: gambar asli RGB, blending images (canny filters), campuran RGB dan blending images. Training CNN dilakukan dengan menggunakan tiga dataset yang telah diolah dan disimpan sebelumnya. Matriks pengukuran yang digunakan adalah False Rejection Rate (FRR) dan Genuine Acceptance Rate (GAR). False Rejection Rate (FRR) merupakan kinerja model saat melakukan klasifikasi dan biasanya didapatkan dari persentase kesalahan palsu. Genuine Acceptance Rate (GAR) merupakan persentase kecocokan asli yang nilainya didapat dari 100% dikurangi FRR. Dengan menggunakan 3 dataset yang berbeda, nilai Genuine Acceptance Rate (GAR) paling tinggi (96.7%) diperoleh dengan menggunakan dataset campuran RGB dan

blending images. GAR yang diperoleh dengan menggunakan dataset gambar asli RGB adalah 93.3%, dan GAR paling rendah (80.0%) diperoleh dengan menggunakan dataset blending images [13].

Klasifikasi tiga jenis penyakit pada tanaman padi (leaf blast, leaf blight, dan brown spot) menggunakan CNN dengan transfer learning untuk mengembangkan model deep learning yang sudah ada sebelumnya. Tahap awal klasifikasi ini adalah pengambilan 1649 dataset daun padi berpenyakit dan 507 dataset daun padi sehat di dua tempat yang berbeda. Dari semua dataset yang telah diambil selanjutnya di ubah ukurannya dan terapkan teknik augmentasi seperti zoom, rotasi, pergeseran horizontal, dan pergeseran vertical menggunakan keras untuk menghasilkan gambar baru. Selanjutnya, sebanyak 70% dari keseluruhan dataset digunakan untuk training dan 30% sisanya digunakan untuk testing. Peneliti melakukan uji coba dengan mengembangkan CNN dengan transfer learning dan CNN tanpa transfer learning. Hasil percobaan menunjukkan akurasi yang didapat menggunakan CNN dengan transfer learning lebih besar (92.46%) daripada akurasi yang didapat menggunakan CNN tanpa transfer learning (74%) [8]. Klasifikasi tiga jenis penyakit pada daun jagung (*Cercospora leaf spot*, common rust, dan northern leaf blight) dan daun jagung sehat menggunakan Convolutional Neural Network (CNN). Proses klasifikasi diawali dengan mengolah dataset dengan mengubah ukuran menjadi 150x150 pixel menggunakan OpenCV. Selanjutnya adalah membangun arsitektur model CNN dimulai dari convolutional layer, activation function (ReLU), pooling layer, adam optimizer, dan dropout. Adam optimizer digunakan untuk mengoptimalkan parameter menggunakan algoritma optimasi. Optimasi ini akan memperbarui bobot jaringan untuk iterasi tertentu berdasarkan data training. Akurasi yang didapatkan untuk mendeteksi tiga jenis penyakit pada tanaman jagung adalah 98.78%. Hasil uji coba telah menunjukkan bahwa memungkinkan untuk meningkatkan nilai akurasi dengan beberapa penyesuaian parameter model, penambahan fungsi ReLU, adam optimizer, dan pooling operations [1].

Convolutional Neural Network digunakan untuk klasifikasi penyakit daun jagung (leaf spot, common rust, dan northern corn leaf blight) dan daun jagung sehat. CNN yang dibuat memiliki 50 lapisan tersembunyi untuk mengenal dan mengklasifikasi penyakit pada daun jagung ataupun daun jagung sehat. Training menggunakan 100 gambar berwarna dengan konfigurasi 10 x 20 x 3 (height x width x RGB). Sebanyak 70% dari jumlah dataset digunakan untuk training dan 30% sisanya digunakan untuk testing. Nilai akurasi yang diperoleh secara keseluruhan adalah 92.85% untuk mendeteksi dan klasifikasi 3 jenis penyakit pada daun jagung dan daun jagung sehat. Saat dilakukan uji coba terpisah, akurasi dalam mendeteksi penyakit northern corn leaf blight mencapai nilai tertinggi yaitu 99.9% dan akurasi terendah (87%) diperoleh dalam mendeteksi penyakit gray leaf spot [10]. Penggunaan model deep learning EfficientNet dalam klasifikasi penyakit pada daun serta perbandingan EfficientNet dengan model deep learning lainnya. Dataset yang digunakan memiliki 54305 gambar dari 14 jenis daun tanaman yang berbeda dengan 38 kelas didalamnya yang terdiri dari 12 kelas daun sehat dan 26 kelas daun berpenyakit. EfficientNet akan dibandingkan dengan

AlexNet, VGG16, ResNet50, dan InceptionV3. Untuk training, semua gambar dataset diubah ukurannya sesuai dengan model deep learning. AlexNet menggunakan ukuran 227 x 227 pixel, VGG16 menggunakan ukuran 224 x 224 pixel, ResNet50 menggunakan ukuran 224 x 224 pixels, Inception V3 menggunakan ukuran 299 x 299 pixel, dan EfficientNet menggunakan ukuran 132 x 132 pixels. Training dilakukan dengan menggunakan dataset asli dan dataset yang telah diolah menggunakan teknik augmentasi. sil yang diperoleh dari uji coba adalah EfficientNet memperoleh nilai akurasi 99.91% dan nilai presisi 98.42% pada dataset asli sedangkan pada dataset augmentasi EfficientNet memperoleh nilai akurasi 99.97% dan nilai presisi 99.39%. Nilai yang diperoleh EfficientNet merupakan nilai tertinggi jika dibandingkan dengan model lainnya [14]

Selain itu, beberapa model transfer learning CNN seperti VGG16, Resnet50, InceptionV3, DenseNet121, Xception dan MobileNet telah di uji pada beberapa kasus berbeda. Misalnya, model yang mengklasifikasikan kesegaran ikan bandeng yang dilatih menggunakan 153 citra. Model transfer learning yang dibandingkan ialah Xception, MobileNetV1, ResNet50 dan VGG16 dengan VGG16 mencapai kinerja terbaik dibandingkan arsitektur lainnya, dimana akurasi klasifikasi mencapai 97% [15]. Penelitian lainnya, dilakukan eksperimen untuk meklasifikasikan ukiran bermotif Jepara. Menggunakan cara membagi dataset berdasarkan color scape menjadi tiga bagian, yaitu LUV, RG dan YcrCb dan melakukan percobaan pengujian dengan beberapa model CNN. Hasil pengujian penelitian ini menunjukkan bahwa Xception pada pengujian memiliki nilai akurasi tertinggi, yaitu 95% untuk masing-masing dataset. Namun jika semua pengujian diterapkak pada identifikasi motif Jepara, ResNet50 memiliki nilai akurasi yang tertinggi dengan persentasi 84%, 79% dan 80% untuk masing masing color space [16].

Bila dibandingkan dengan studi literatur yang telah dilakukan, penelitian ini akan melakukan klasifikasi daun jagung sehat dan daun jagung berlubang akibat hama serangga. Pada pra-pemrosesan dataset akan dilakukan proses background removal untuk menghilangkan noise pada dataset. Model yang akan digunakan adalah VGG16, Inception_V3, Xception, Inception_ResNet_V2, dan MobileNet. Resolusi dataset yang digunakan pada penelitian akan disesuaikan dengan model yang digunakan. Selain itu, performa model akan diukur dengan menggunakan confusion matrix untuk melihat nilai akurasi, presisi, dan recall.

III. METODOLOGI PENELITIAN

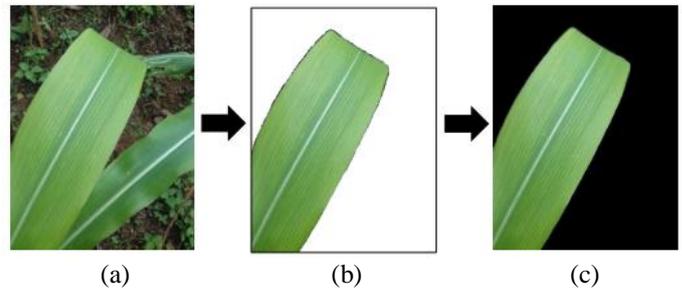
Pada BAB ini menjelaskan metode yang diajukan sehingga menjadi solusi pada latar belakang penelitian yang telah dibahas.

A. Penelitian Kualitatif

Dataset

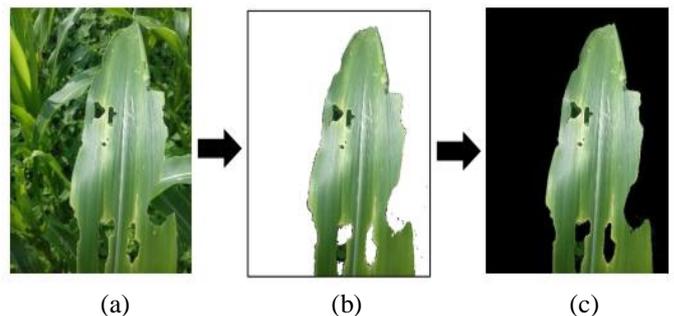
Dataset yang akan digunakan dalam penelitian merupakan dataset yang diambil dari Kaggle. Dataset berjumlah 240 gambar daun jagung yang terdiri dari 120 gambar daun jagung sehat dan 120 daun jagung berlubang akibat hama serangga.

Berikut adalah contoh dari dataset yang akan digunakan dalam penelitian.



Gambar 1. Sampel Dataset Daun Jagung Sehat (a) dengan background, (b) tanpa background, (c) dengan background warna hitam

Dapat dilihat pada gambar 4.1 bagian daun jagung sehat dengan background terdapat tumbuhan kecil yang warnanya mirip dengan warna daun jagung, hal ini dianggap sebagai noise dan dapat mempengaruhi proses klasifikasi.



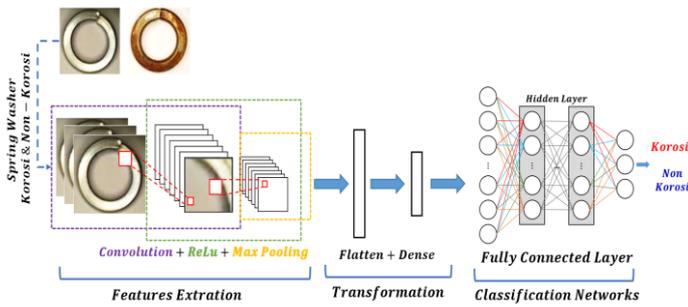
Gambar 2. Sampel Dataset Daun Jagung Berlubang (a) dengan background, (b) tanpa background, (c) dengan background warna hitam

Perbedaan yang terlihat pada daun jagung sehat dan daun jagung berlubang adalah adanya lubang- lubang di bagian tengah daun ataupun bagian tepian daun. Adanya tanaman kecil yang pada background gambar yang berwarna mirip dengan warna daun jagung dapat menyamarkan lubang – lubang pada daun jagung yang berlubang. Dengan menghilangkan background pada gambar diharapkan lubang – lubang pada daun jagung yang berlubang dapat lebih terlihat dengan jelas.

B. Penelitian Eksperimental

Convolutional Neural Networks (CNN)

Convolutional Neural Networks (CNN) adalah sub class dari deep neural networks yang dapat digunakan untuk menyelesaikan masalah pengenalan citra / gambar (image recognition) (Narin et al., 2020). CNN menjadi sarana yang dapat dimanfaatkan untuk mengklasifikasikan gambar. Secara dimanis, CNN terdiri dari proses utama yaitu Features Extraction, dan Fully Connected Layer [17][18].



Gambar 3. Arsitektur CNN

Lapisan Konvolusional (Convolutional layer) merupakan lapisan dasar dari CNN yang menentukan ciri-ciri pola citra. Pada lapisan ini, gambar masukan dilewatkan melalui sebuah filter [19][20]. Nilai-nilai yang dihasilkan dari pemfilteran terdiri dari peta fitur (feature map) yang terdiri dari beberapa kernel yang berpindah (slide) melalui pola untuk mengekstrak fitur tingkat rendah dan tinggi dalam pola tersebut. Stride adalah jumlah langkah yang disetel untuk menggeser matriks input [18].

Salah satu cara mereduksi waktu komputasi pada layer CNN, arsitektur CNN konvensional dapat dikonfigurasi dengan merubah layer pooling menjadi stride. Sebagai contoh, conv stride = 1 dilanjutkan dengan max pooling 2 bisa diganti dengan satu layer, yaitu conv stride = 2 dengan hasil yang hampir mirip. Misalkan f menunjukkan peta fitur yang dihasilkan oleh beberapa lapisan CNN, sedangkan N adalah jumlah filter di lapisan ini. Kemudian subsampling p-norm dengan pooling size m (atau setengah panjang $m/2$) dan langkah r diterapkan pada pemetaan fitur f adalah array 3 dimensi $s(f)$ dengan entri berikut [21]:

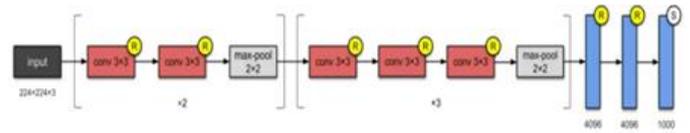
$$s_{i,j,u}(f) = \left(\sum_{h=-\lfloor m/2 \rfloor}^{\lfloor m/2 \rfloor} \sum_{w=-\lfloor m/2 \rfloor}^{\lfloor m/2 \rfloor} |f_g(h, w, i, j, u)|^p \right)^{\frac{1}{p}} \quad (1)$$

Dimana fungsi pemetaan dari s pada posisi stride f adalah $g(h, w, i, j, u) = (r \cdot i + h, r \cdot j + w, u)$. p adalah orde dari p-norm ($p \rightarrow \infty$ merepresentasikan max pooling). Jika $r > m$, pooling region tidak overlap. Definisi standar dari lapisan konvolusi c yang diterapkan pada peta fitur f dinyatakan sebagai berikut [22]:

$$c_{i,j,o}(f) = \sigma \left(\sum_{h=-\lfloor m/2 \rfloor}^{\lfloor m/2 \rfloor} \sum_{w=-\lfloor m/2 \rfloor}^{\lfloor m/2 \rfloor} \sum_{u=1}^N \theta_{h,w,u,o} \cdot f_g(h, w, i, j, u) \right) \quad (2)$$

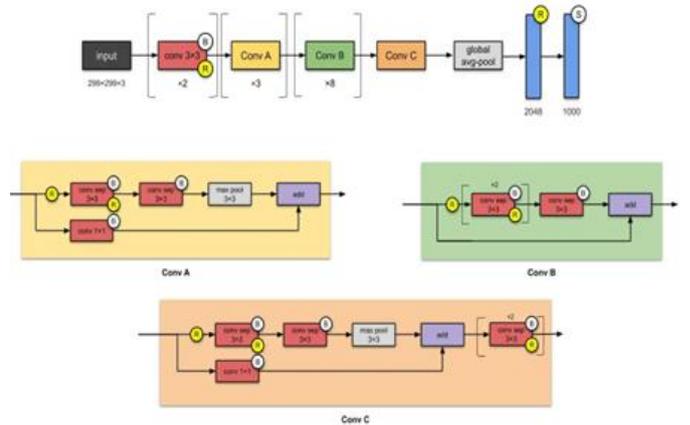
Di mana θ adalah bobot konvolusi, $\sigma(\cdot)$ adalah fungsi aktivasi, biasanya aktivasi linier terkoreksi ReLU, dan $o \in [1, M]$ adalah jumlah fitur keluaran dari lapisan konvolusi. Dari kedua persamaan tersebut, terlihat bahwa biaya komputasi akan berkurang.

Arsitektur pada model transfer learning CNN yang akan digunakan sebagai klasifikator citra spring washer korosi/non-korosi. Adapun layer pada arsitektur VGG16 memiliki jumlah parameter dilatih sebanyak 138,357,544 dan direpresentasikan sebagai berikut:



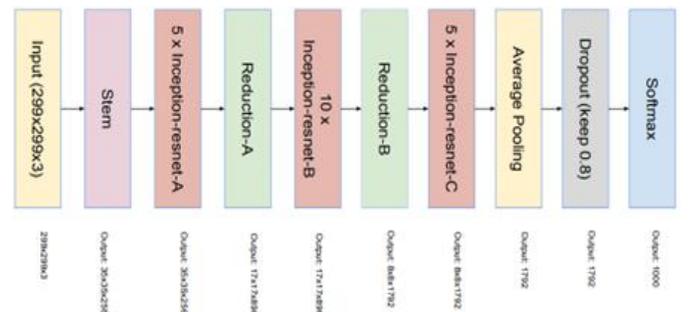
Gambar 4. Arsitektur VGG16

Adapun layer pada arsitektur Xception memiliki jumlah parameter dilatih sebanyak 22,910,480 dan direpresentasikan sebagai berikut:



Gambar 5. Arsitektur Xception

Inception_ResNet_V2 memiliki 164 lapisan dan telah dilatih pada lebih dari satu juta gambar dari database ImageNet. Model ini diformulasikan dengan kombinasi struktur inception dan koneksi residual. Pada blok Inception-ResNet, beberapa filter konvolusi digabungkan dengan koneksi residual. Input gambar untuk model Inception_ResNet_V2 memiliki ukuran 299x299.



Gambar 6. Arsitektur Inception ResNet V2

Confusion Matrix

Confusion Matrix / Matriks konfusi merupakan sebuah tabel pemetaan berbentuk matrix 2x2 yang terdiri dari banyaknya data uji yang diprediksi benar dan tidak benar oleh model klasifikasi. Tabel ini diperlukan untuk mengukur kinerja suatu model klasifikasi [23]. Matriks konfusi dapat digunakan untuk menganalisis potensi pengklasifikasi dengan sempurna. Semua elemen diagonal menunjukkan hasil yang diklasifikasikan dengan benar. Hasil yang salah klasifikasi direpresentasikan pada diagonal mati dari matriks kebingungan. Oleh karena itu, pengklasifikasi terbaik akan memiliki matriks kebingungan dengan hanya elemen diagonal dan elemen lainnya diatur ke nol. Matriks konfusi menghasilkan nilai aktual dan nilai prediksi

setelah proses klasifikasi. Efektivitas sistem ditentukan berdasarkan nilai berikut yang dihasilkan dalam matriks.

Tabel 1. Confusion Matrix

Predictive Class	Actual Class	
	True Positive (TP)	False Positive (FP)
False Negative (FN)	True Negative (TN)	

Entri dalam matriks kebingungan didefinisikan sebagai berikut:

- True Positive rate (TP) adalah jumlah total hasil atau prediksi yang benar ketika kelas sebenarnya positif.
- False Positive rate (FP) adalah jumlah total hasil atau prediksi yang salah ketika kelas yang sebenarnya positif.
- True Negative rate (TN) adalah jumlah total hasil atau prediksi yang benar ketika kelas sebenarnya negatif.
- False Negative rate (FN) adalah jumlah total hasil atau prediksi yang salah ketika kelas sebenarnya negatif.

Berdasarkan Tabel 1, Matriks konfusi merepresentasikan nilai TP yang diklasifikasikan dengan benar, nilai FP di kelas yang relevan saat seharusnya berada di kelas lain, dan nilai FN di kelas lain saat seharusnya berada di kelas yang relevan dan nilai TN yang diklasifikasikan dengan benar di kelas lain. Metrik kinerja yang paling sering digunakan untuk klasifikasi menurut nilai-nilai ini adalah nilai akurasi (Acc), presisi (P), sensitivitas (Sn), spesifisitas (Sp), dan skor-F. Perhitungan metrik kinerja ini menurut nilai-nilai dalam matriks kebingungan dibuat menurut Persamaan [24] [25]:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \tag{3}$$

$$P = \frac{TP}{TP + FP} \tag{4}$$

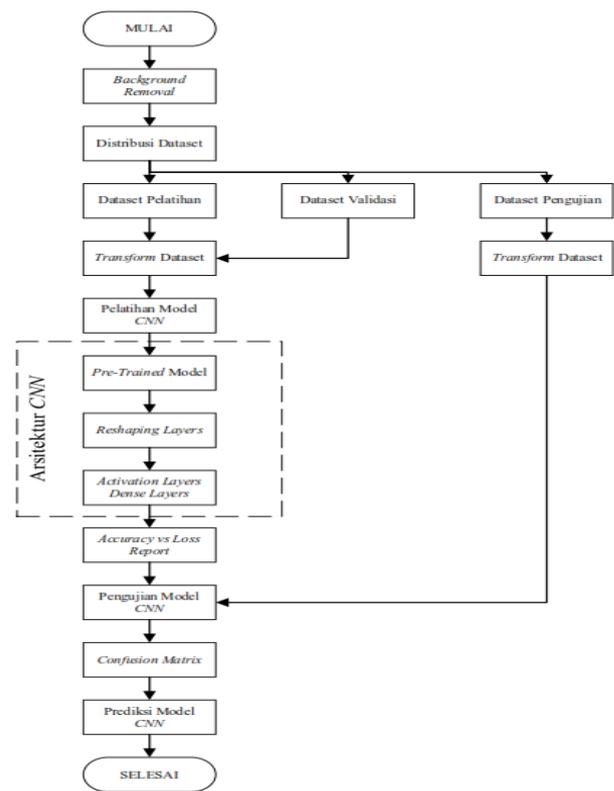
$$Sn = \frac{TP}{TP + FN} \tag{5}$$

$$Sp = \frac{TN}{TN + FP} \tag{6}$$

$$F - score = 2 \times \frac{P \times Sn}{P + Sn} \tag{7}$$

Diagram Alir

Pada sub bab ini akan dipaparkan diagram blok sistem, dimana tiap- tiap blok silih berhubungan antara yang satu dengan yang yang lain. Diagram blok mempunyai sebagian guna yaitu: menarangkan metode kerja sesuatu sistem secara simpel, menganalisa metode kerja sistem serta memudahkan dalam memeriksa kesalahan sesuatu sistem yang dibentuk. Ada pula diagram blok dari sistem yang dirancang merupakan semacam yang diperlihatkan pada gambar 7.



Gambar 7. Diagram Alir Penelitian

Pada gambar 7 ada diagram alir yang menampilkan secara garis besar proses berjalannya program pada riset ini. Semacam yang bisa dilihat pada gambar secara garis besar ada 2 proses yaitu proses pelatihan dan proses pengujian. Pertama- tama akan dibahas mengenai proses pelatihan terlebih dulu, pada proses pelatihan ada sebagian tahapan antara lain pelatihan dengan multilayer CNN yang dikombinasikan dengan lapisan softmax kemudian akan dihitung nilai eror pada tiap epochnya, nilai eror ini akan dikurangi dengan memakai bacpropagation algorithm pada tiap epoch. Bila menggunakan pre- trained model proses pelatihan tidak butuh dicoba sebab model sudah mempunyai pengetahuan serta keahlian buat mengklasifikasikan gambar. Proses berikutnya merupakan proses pengujian ataupun testing, model CNN yang telah dilatih digunakan buat mengekstraksi fitur- fitur yang terdapat pada gambar sehabis itu dilanjutkan dengan mengukur kesalahan dari klasifikasi serta keluarannya berupa akurasi dari pengujian.

IV. HASIL DAN ANALISA

Distribusi Dataset

Dataset melalui pra-pemrosesan data dengan menghilangkan background gambar dan mengganti background dengan warna hitam untuk mengurangi noise pada dataset. Warna hitam dipilih sebagai warna pengganti background gambar karena warna hitam dapat memperjelas kontur – kontur pada dataset. Semua dataset memiliki resolusi awal 400x300x3 dan akan disesuaikan kembali dengan kebutuhan model yang akan digunakan.

Dataset yang digunakan dalam penelitian dibagi menjadi tiga bagian dataset yaitu dataset untuk pelatihan, dataset untuk validasi, dan dataset untuk tes atau pengujian. Dataset untuk

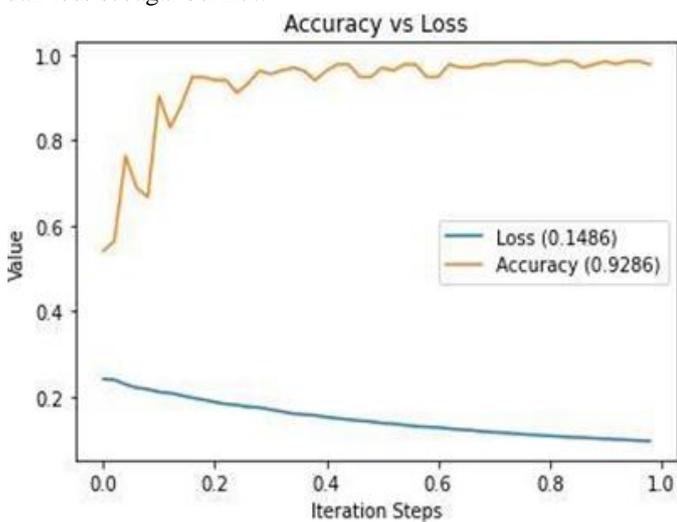
pelatihan terdiri dari 68 gambar daun jagung sehat dan 68 daun jagung berlubang, dataset untuk validasi terdiri dari 16 gambar daun jagung sehat dan 16 daun jagung berlubang, dan dataset untuk pengujian terdiri dari 36 gambar daun jagung sehat dan 36 gambar daun jagung berlubang

Pelatihan Data

Pelatihan data akan dilakukan dengan lima model yang berbeda yaitu model VGG16, Inception_V3, Xception, Inception_ResNet_V2, dan MobileNet. Pelatihan data akan menggunakan pre-trained model yang diadaptasi dari Keras dan disesuaikan jumlah keluarannya menjadi dua kelas, yang meliputi daun jagung sehat dan daun jagung berlubang.

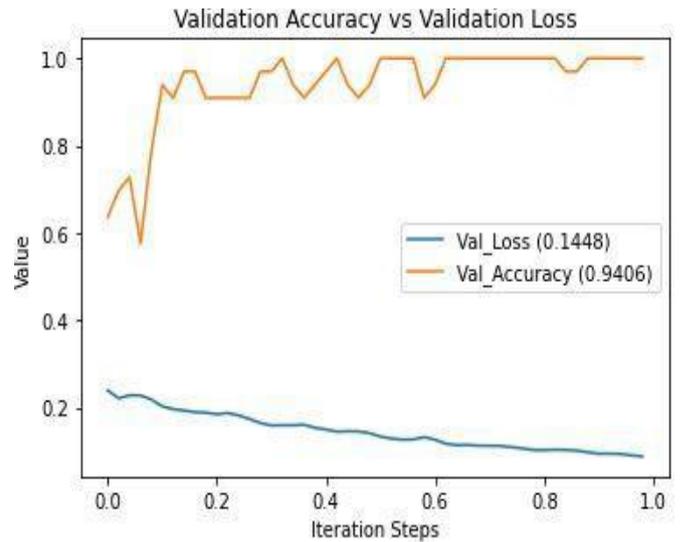
Pelatihan data akan menggunakan epochs sebanyak 50 kali, artinya proses pelatihan dan validasi akan diulang 50 kali. Resolusi dataset akan disesuaikan berdasarkan kebutuhan model yang digunakan, berikut resolusi dataset yang dibutuhkan oleh model: Model VGG16 menggunakan resolusi dataset 224x224, Model Inception_V3 menggunakan resolusi dataset 299x299, Model Xception menggunakan resolusi dataset 299x299, Model Inception_ResNet_V2 menggunakan resolusi dataset 299x299, Model MobileNet menggunakan resolusi dataset 224x2

Pelatihan model VGG16 memerlukan waktu 1 menit 1 detik untuk menjalankan 50 epochs dan menunjukkan nilai akurasi dan loss sebagai berikut:



Gambar 8. Grafik Nilai Akurasi dan Loss Model VGG16

Akurasi pelatihan model VGG16 mencapai nilai tertinggi pada 0.9852 dan mencapai nilai terendah pada 0.5407. Sedangkan nilai loss pada pelatihan model VGG16 mencapai nilai tertinggi pada 0.2405 dan mencapai nilai terendah pada 0.0953. Rata – rata nilai akurasi pelatihan model VGG16 adalah 0.9286 dan rata – rata nilai loss pelatihan model VGG16 adalah 0.1486.

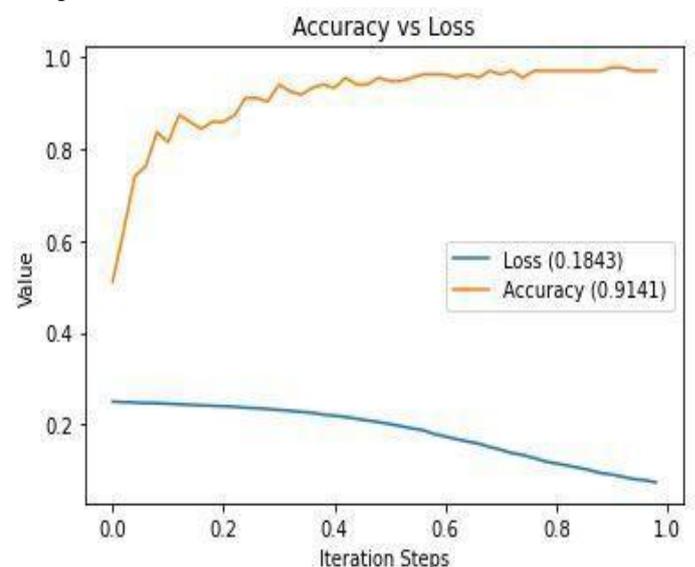


Gambar 9. Grafik Nilai Validasi Akurasi dan Validasi Loss Model VGG16

Pada proses validasi model VGG16, nilai akurasi validasi tertinggi mencapai 1.0 dan akurasi validasi terendah mencapai 0.5758. Sedangkan loss validasi model VGG16 tertinggi mencapai 0.2387 dan loss validasi terendah adalah 0.0876. Rata – rata nilai akurasi validasi pada model VGG16 adalah 0.9406 dan rata – rata nilai validasi loss adalah 0.1488.

Hasil penelitian disajikan dalam bentuk grafik, tabel, atau deskriptif. Analisis dan interpretasi hasil ini diperlukan sebelum dibahas.

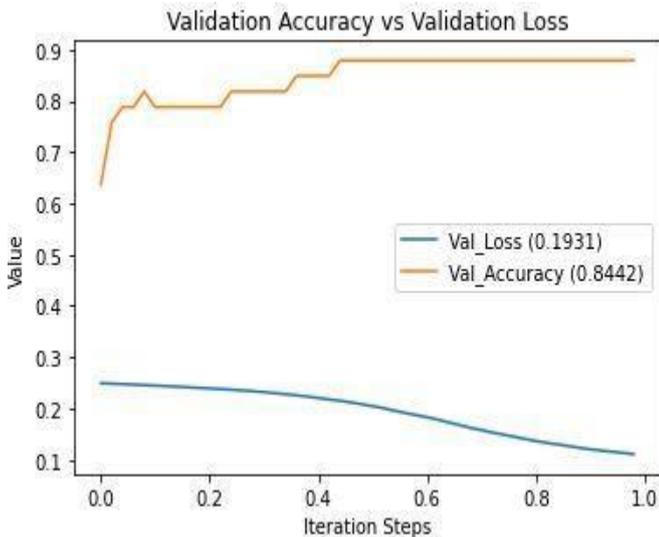
Model Inception_V3 memerlukan waktu 1 menit 22 detik untuk menjalankan 50 epochs pada pelatihan model Inception_V3. Berikut hasil dari pelatihan dan validasi model Inception_V3:



Gambar 10. Grafik Nilai Akurasi dan Loss Model Inception_V3

Pada proses pelatihan model Inception_V3 nilai akurasi pelatihan tertinggi mencapai 0.9778 dan nilai akurasi pelatihan terendah adalah 0.5111. Sedangkan nilai loss pelatihan model

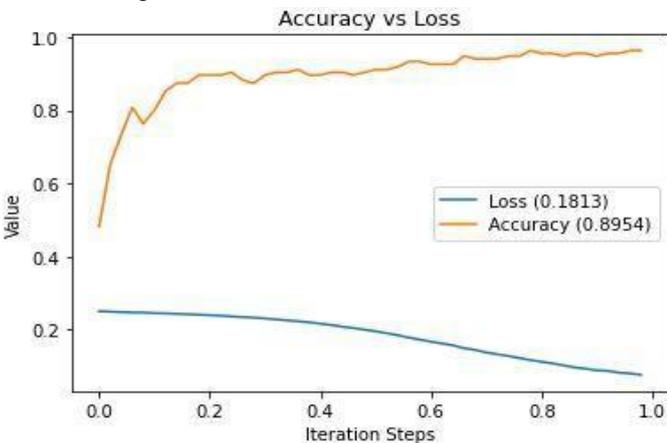
Inception_V3 tertinggi mencapai 0.2499 dan nilai loss pelatihan terendah adalah 0.0742. Nilai rata – rata akurasi pelatihan model Inception_V3 adalah 0.9141 dan nilai rata – rata loss pelatihan adalah 0.1843.



Gambar 11. Grafik Nilai Validasi Akurasi dan Validasi Loss Model Inception_V3

Akurasi validasi pada model Inception_V3 mencapai nilai tertinggi pada 0.8788 dan nilai terendah akurasi validasi pada model Inception_V3 adalah 0.6364. Untuk loss validasi pada model Inception_V3 mencapai nilai tertinggi pada 0.2491 dan nilai terendah loss validasi pada model Inception_V3 adalah 0.1108. Pada model Inception_V3, rata – rata nilai akurasi validasi adalah 0.8442 dan rata – rata nilai loss validasi adalah 0.1931.

Pelatihan Xception memerlukan waktu 1 menit 21 detik untuk menjalankan 50 epochs dan menunjukkan hasil akurasi dan loss sebagai berikut:

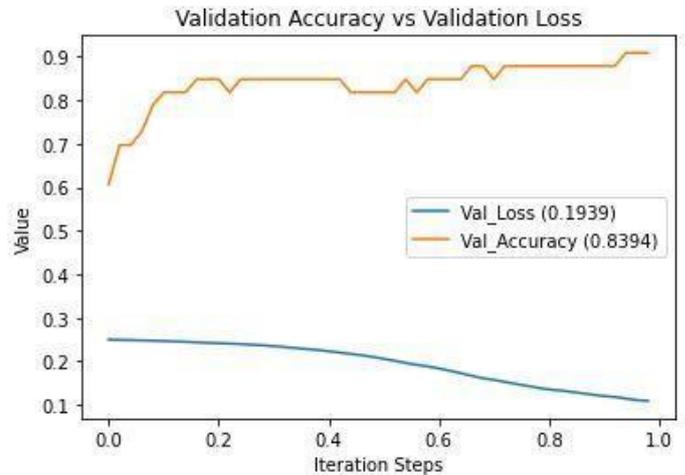


Gambar 12. Grafik Nilai Akurasi dan Loss Model Xception

Nilai akurasi tertinggi yang dapat dicapai pada pelatihan model Xception adalah 0.9556 dan nilai akurasi pelatihan terendah adalah 0.4815. Sedangkan nilai loss pelatihan tertinggi pada model Xception mencapai nilai 0.2504 dan nilai loss pelatihan terendah adalah 0.0763. Rata – rata nilai akurasi

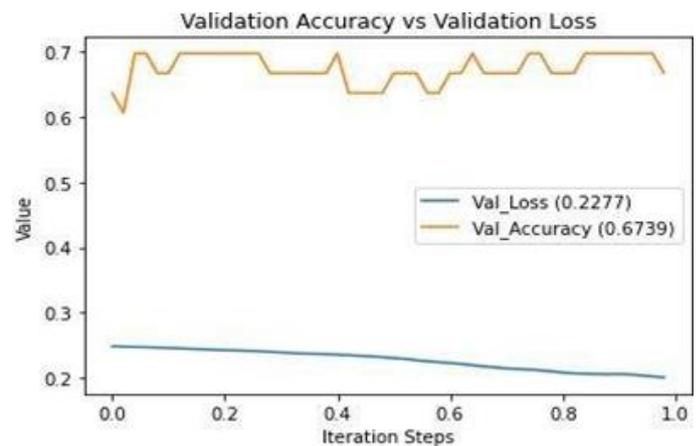
pelatihan pada model Xception adalah 0.8954 dan rata – rata nilai loss pelatihan adalah 0.1813.

Pada proses validasi model Xception, nilai akurasi validasi tertinggi mencapai nilai 0.9091 dan nilai akurasi validasi terendah adalah 0.6061. Nilai loss validasi tertinggi pada model Xception adalah 0.2497 dan nilai loss validasi terendah model Xception adalah 0.1088. Pada proses validasi model Xception, rata – rata nilai akurasi validasinya adalah 0.8394 dan rata – rata nilai loss validasinya adalah 0.1939.



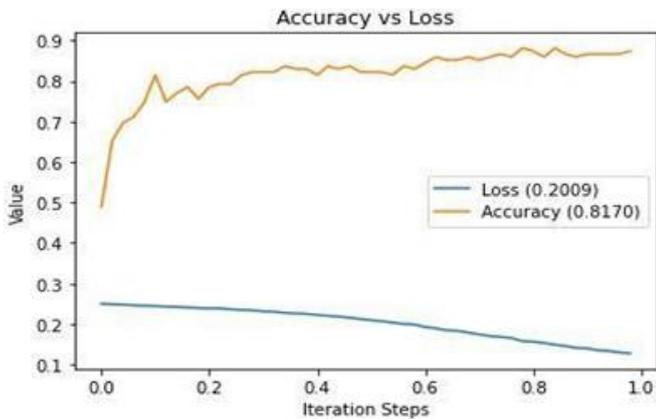
Gambar 13. Grafik Nilai Validasi Akurasi dan Validasi Loss Model Xception

Pelatihan model Inception_ResNet_V2 memerlukan waktu 2 menit 4 detik untuk menjalankan 50 epochs dan menunjukkan nilai akurasi dan loss sebagai berikut:



Gambar 14. Grafik Nilai Akurasi dan Loss Model Inception_ResNet_V2

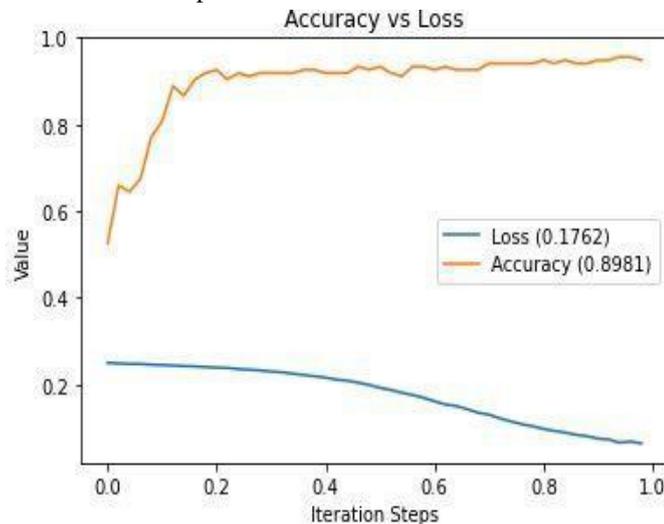
Akurasi pelatihan model Inception_ResNet_V2 mencapai nilai tertinggi pada 0.8741 dan mencapai nilai terendah pada 0.4889. Sedangkan nilai loss pada pelatihan model Inception_ResNet_V2 mencapai nilai tertinggi pada 0.2501 dan mencapai nilai terendah pada 0.1274. Rata – rata nilai akurasi pelatihan model Inception_ResNet_V2 adalah 0.8170 dan rata – rata nilai loss pelatihan model Inception_ResNet_V2 adalah 0.2009



Gambar 15. Grafik Nilai Validasi Akurasi dan Validasi Loss Model Inception_ResNet_V2

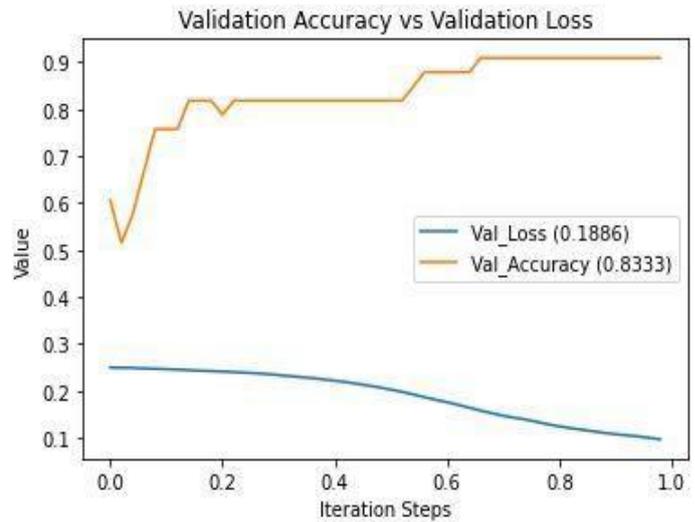
Pada proses validasi model Inception_ResNet_V2, nilai akurasi validasi tertinggi mencapai 0.6970 dan akurasi validasi terendah mencapai 0.6061. Sedangkan loss validasi model Inception_ResNet_V2 tertinggi mencapai 0.2488 dan loss validasi terendah adalah 0.2010. Rata – rata nilai akurasi validasi pada model Inception_ResNet_V2 adalah 0.6739 dan rata – rata nilai validasi loss adalah 0.2277.

Model MobileNet memerlukan waktu 50 detik untuk menjalankan 50 epochs pada pelatihan model MobileNet. Berikut hasil dari pelatihan dan validasi model MobileNet:



Gambar 16. Grafik Nilai Akurasi dan Loss Model MobileNet

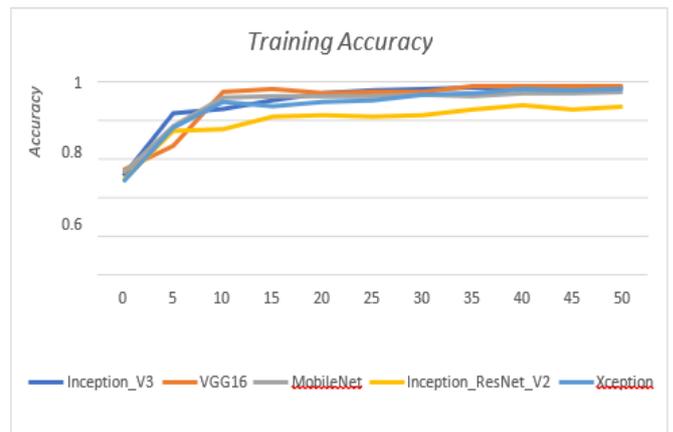
Pada proses pelatihan model MobileNet nilai akurasi pelatihan tertinggi mencapai 0.9556 dan nilai akurasi pelatihan terendah adalah 0.5259. Sedangkan nilai loss pelatihan model MobileNet tertinggi mencapai 0.2496 dan nilai loss pelatihan terendah adalah 0.0640. Nilai rata – rata akurasi pelatihan model MobileNet adalah 0.8981 dan nilai rata – rata loss pelatihan adalah 0.1762.



Gambar 17. Grafik Nilai Validasi Akurasi dan Validasi Loss Model MobileNet

Akurasi validasi pada model MobileNet mencapai nilai tertinggi pada 0.9091 dan nilai terendah akurasi validasi pada model MobileNet adalah 0.6061. Untuk loss validasi pada model MobileNet mencapai nilai tertinggi pada 0.2494 dan nilai terendah loss validasi pada model MobileNet adalah 0.0963. Pada model MobileNet, rata – rata nilai akurasi validasi adalah 0.8333 dan rata – rata nilai loss validasi adalah 0.1886.

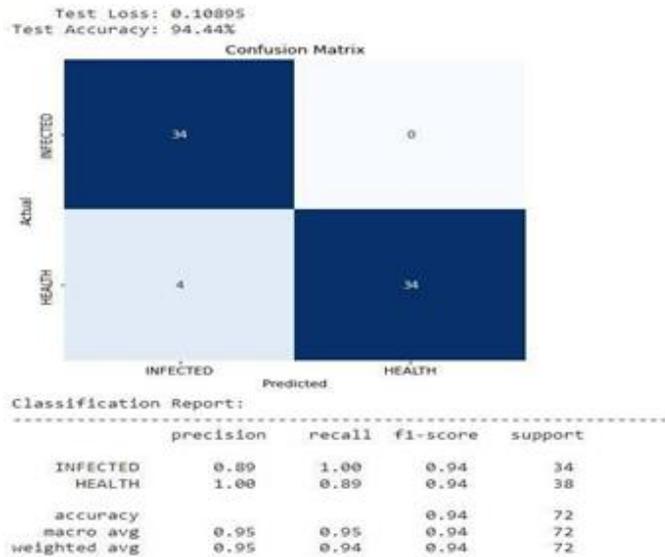
Setelah melakukan pelatihan pada lima model yang berbeda, didapatkan perbandingan akurasi pelatihan yang ditunjukkan pada grafik berikut:



Gambar 18. Grafik Perbandingan Akurasi Pelatihan

Berdasarkan grafik diatas, kelima model menunjukkan trend yang sama yaitu meningkatnya nilai akurasi seiring dengan bertambahnya epochs. Model VGG16 memiliki rata - rata nilai akurasi pelatihan paling tinggi dengan nilai 92.86%, rata- rata nilai akurasi pelatihan tertinggi kedua dimiliki oleh model Inception_V3 dengan nilai 91.41%, berikutnya model MobileNet dengan rata – rata nilai akurasi 89.81%, model Xception dengan rata – rata nilai akurasi 89.54%, dan rata – rata nilai akurasi pelatihan paling rendah dimiliki oleh model Inception_ResNet_V2 dengan nilai akurasi 81.70%.

Model yang telah dilatih selanjutnya diuji dengan menggunakan 72 dataset diluar dataset yang digunakan pada proses pelatihan dan validasi. Setiap model yang diuji akan dilihat kinerjanya melalui nilai akurasi, presisi, dan recall.



Gambar 19. Matriks Pengukuran Model VGG16

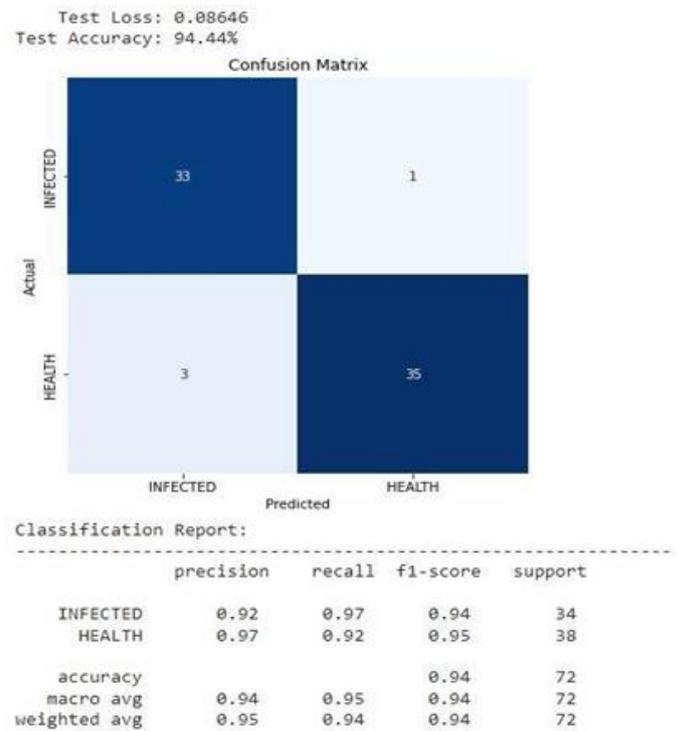
Hasil pengujian menunjukkan bahwa model VGG16 mampu mengklasifikasikan 34 dataset daun jagung sehat dan 34 dataset daun jagung berlubang dengan benar. Pada model VGG16 ada 4 dataset yang salah klasifikasi yaitu 4 dataset daun jagung sehat yang diklasifikasikan sebagai daun jagung berlubang.

Berdasarkan matriks pengukuran diatas, model VGG16 mampu mencapai nilai 94.44% untuk akurasi pengujian. Untuk nilai presisi, model VGG16 mampu mencapai 100% untuk daun jagung sehat dan 89% untuk daun jagung berlubang. Nilai recall yang dicapai model VGG16 adalah 89% untuk daun jagung sehat dan 100% untuk daun jagung berlubang.

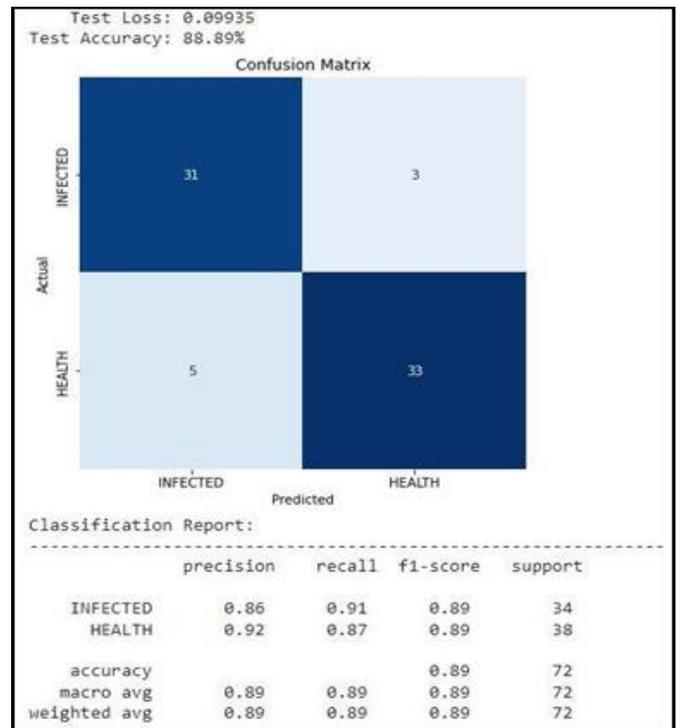
Hasil pengujian menunjukkan bahwa model Inception_V3 mampu mengklasifikasikan 36 dataset daun jagung sehat dan 33 dataset daun jagung berlubang dengan benar. Pada model Inception_V3 ada 4 dataset yang salah klasifikasi yaitu 3 dataset daun jagung sehat yang diklasifikasikan sebagai daun jagung berlubang, dan 1 dataset daun jagung berlubang yang diklasifikasikan sebagai daun jagung sehat.

Berdasarkan matriks pengukuran Gambar 20, model Inception_V3 mampu mencapai nilai 94.44% untuk akurasi pengujian. Untuk nilai presisi, model Inception_V3 mampu mencapai 97% untuk daun jagung sehat dan 92% untuk daun jagung berlubang. Nilai recall yang dicapai model Inception_V3 adalah 92% untuk daun jagung sehat dan 97% untuk daun jagung berlubang

Hasil pengujian menunjukkan bahwa model Xception mampu mengklasifikasikan 33 dataset daun jagung sehat dan 31 dataset daun jagung berlubang dengan benar. Pada model Xception ada 8 dataset yang salah klasifikasi yaitu 5 dataset daun jagung sehat yang diklasifikasikan sebagai daun jagung berlubang, dan 3 dataset daun jagung berlubang yang diklasifikasikan sebagai daun jagung sehat.



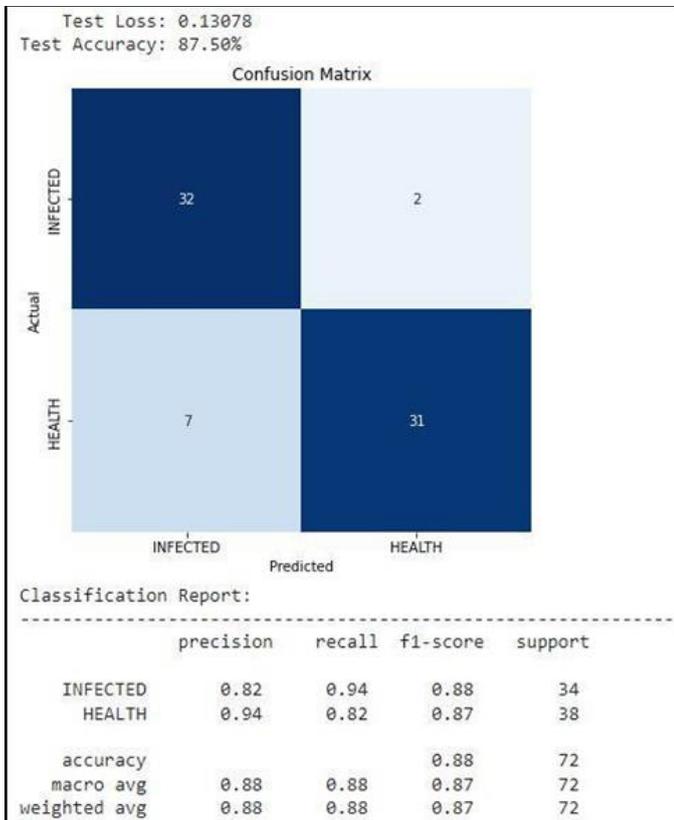
Gambar 20. Matriks Pengukuran Model Inception_V3



Gambar 21. Matriks Pengukuran Model Xception

Berdasarkan matriks pengukuran diatas, model Xception mampu mencapai nilai 88.89% untuk akurasi pengujian. Untuk nilai presisi, model Xception mampu mencapai 92% untuk daun jagung sehat dan 86% untuk daun jagung berlubang. Nilai recall yang dicapai model Xception adalah 87% untuk daun jagung sehat dan 91% untuk daun jagung berlubang

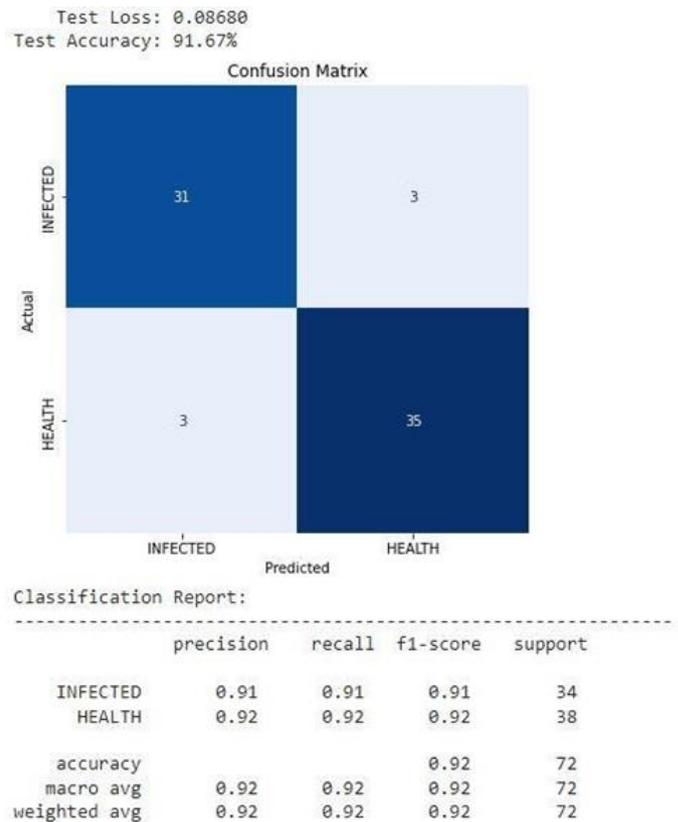
Hasil pengujian menunjukkan bahwa model Inception_ResNet_V2 mampu mengklasifikasikan 32 dataset daun jagung sehat dan 31 dataset daun jagung berlubang dengan benar. Pada model Inception_ResNet_V2 ada 9 dataset yang salah klasifikasi yaitu 7 dataset daun jagung sehat yang diklasifikasikan sebagai daun jagung berlubang, dan 2 dataset daun jagung berlubang yang diklasifikasikan sebagai daun jagung sehat.



Gambar 22. Matriks Pengukuran Model Inception_ResNet_V2

Berdasarkan matriks pengukuran diatas, model Inception_ResNet_V2 mampu mencapai nilai 87.50% untuk akurasi pengujian. Untuk nilai presisi, model Inception_ResNet_V2 mampu mencapai 94% untuk daun jagung sehat dan 82% untuk daun jagung berlubang. Nilai recall yang dicapai model Inception_ResNet_V2 adalah 82% untuk daun jagung sehat dan 94% untuk daun jagung berlubang.

Hasil pengujian menunjukkan bahwa model MobileNet mampu mengklasifikasikan 35 dataset daun jagung sehat dan 31 dataset daun jagung berlubang dengan benar. Pada model MobileNet ada 6 dataset yang salah klasifikasi yaitu 3 dataset daun jagung sehat yang diklasifikasikan sebagai daun jagung berlubang, dan 3 dataset daun jagung berlubang yang diklasifikasikan sebagai daun jagung sehat.



Gambar 23. Matriks Pengukuran Model MobileNet

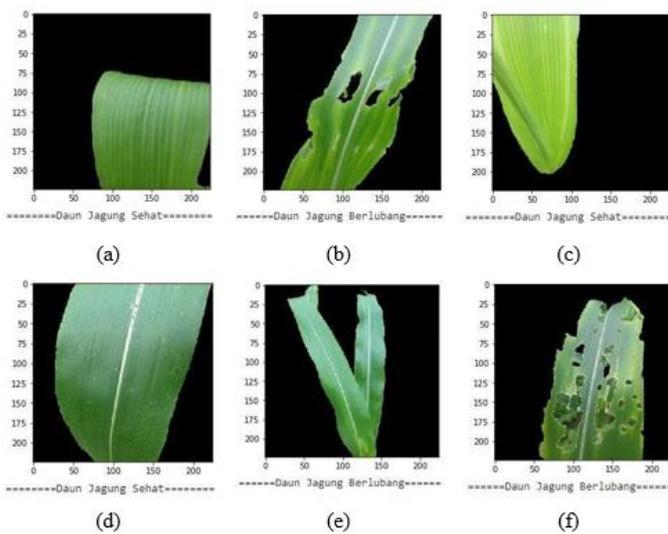
Berdasarkan matriks pengukuran diatas, model MobileNet mampu mencapai nilai 91.67% untuk akurasi pengujian. Untuk nilai presisi, model MobileNet mampu mencapai 92% untuk daun jagung sehat dan 91% untuk daun jagung berlubang. Nilai recall yang dicapai model MobileNet adalah 92% untuk daun jagung sehat dan 91% untuk daun jagung berlubang.

Prediksi model dilakukan setelah proses pelatihan dan pengujian dilakukan, proses prediksi ini bertujuan untuk melihat performa model yang sudah dilatih dan diuji dengan masukkan dataset baru yang belum pernah dipakai dalam pelatihan maupun pengujian.

Prediksi model yang telah dilakukan menggunakan 40 dataset yang dipilih secara acak dan sudah melalui proses augmentasi data untuk memastikan dataset yang digunakan untuk masukkan pada proses prediksi merupakan dataset baru yang belum pernah digunkana pada proses pelatihan maupun pengujian.

Prediksi Model VGG16

Berikut merupakan hasil proses prediksi pada model VGG16:

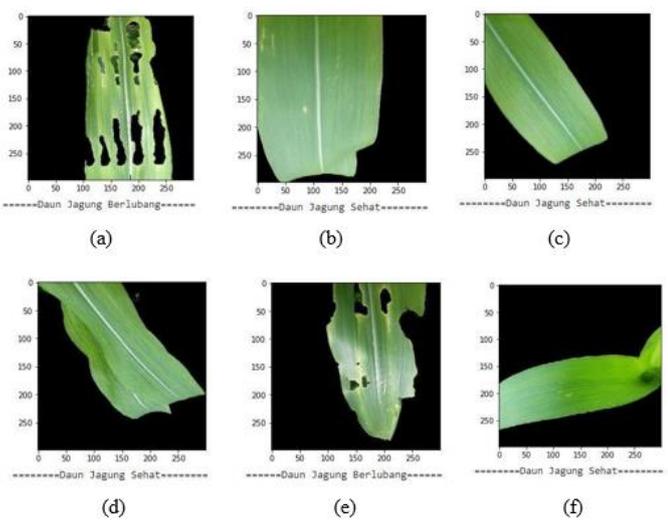


Gambar 25. Hasil Prediksi Model VGG16

Pada gambar 5.18, gambar (a), gambar(c), gambar (d), dan gambar (h) merupakan hasil prediksi benar untuk daun jagung sehat. Sedangkan gambar (b), gambar (f), gambar (g), dan gambar (i) merupakan hasil prediksi benar untuk daun jagung berlubang. Pada gambar (e), model VGG16 menunjukkan hasil prediksi salah dimana gambar masukkan merupakan gambar daun jagung sehat namun model VGG16 memprediksi sebagai gambar daun jagung berlubang.

Prediksi Model Inception_V3

Hasil dari proses prediksi pada model Inception_V3 adalah sebagai berikut:



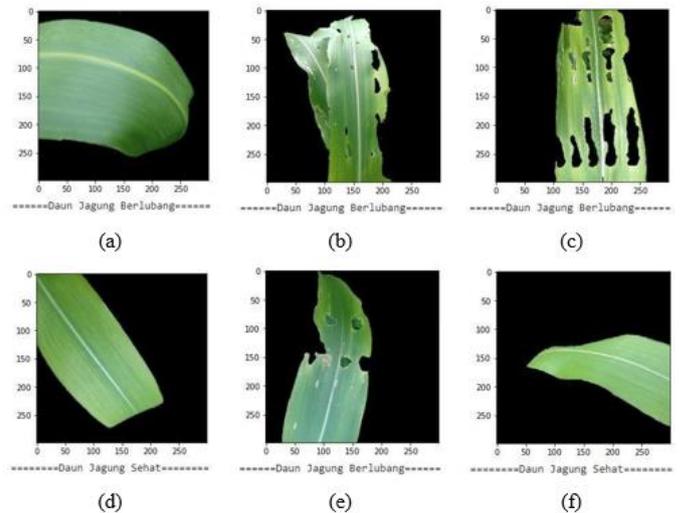
Gambar 26. Hasil Prediksi Model Inception_V3

Hasil prediksi model Inception_V3 menunjukkan hasil benar untuk daun jagung sehat pada gambar (b), gambar(c), gambar (d), dan gambar (f). Untuk hasil prediksi benar pada daun jagung berlubang, ditunjukkan pada gambar (a), gambar (e), dan gambar (g). Pada gambar (h) dan gambar (i), prediksi model Inception_V3 tidak sesuai dengan masukkan datasetnya. Pada gambar (h) seharusnya daun jagung berlubang namun hasil prediksi menunjukkan daun jagung sehat, sedangkan pada

gambar (i) seharusnya daun jagung sehat namun diprediksi sebagai daun jagung berlubang.

Prediksi Model Xception

Berikut merupakan hasil proses prediksi pada model Xception:

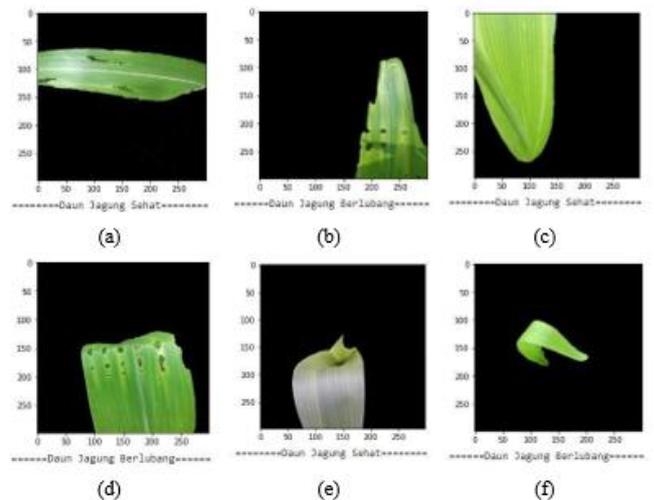


Gambar 27. Hasil Prediksi Model Xception

Hasil prediksi model Xception menunjukkan hasil benar untuk daun jagung sehat pada gambar (d), dan gambar (f). Hasil prediksi juga menunjukkan hasil benar untuk daun jagung berlubang pada gambar (b), gambar (c), gambar (e), dan gambar (g). Sedangkan pada gambar (a) dan gambar (h) seharusnya daun jagung sehat namun hasil prediksi menunjukkan daun jagung berlubang, dan pada gambar (i) seharusnya daun jagung berlubang namun diprediksi sebagai daun jagung sehat.

Prediksi Model Inception_ResNet_V2

Hasil proses prediksi pada model Inception_ResNet_V2 ditunjukkan sebagai berikut:



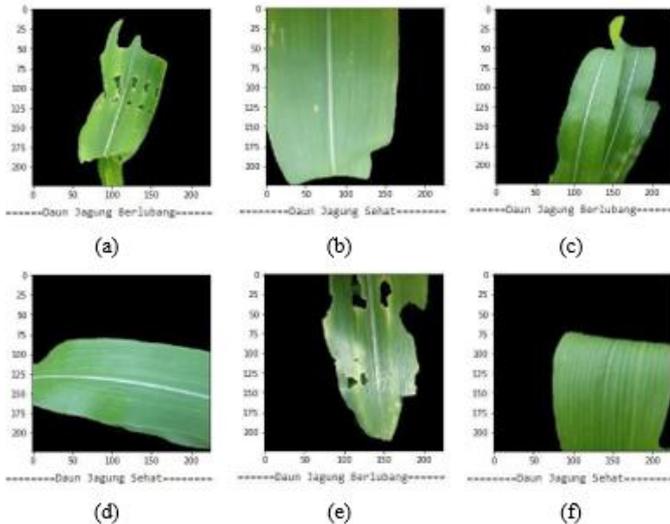
Gambar 28. Hasil Prediksi Model Inception_ResNet_V2

Berdasarkan gambar 5.21, proses prediksi model Inception_ResNet_V2 menunjukkan hasil prediksi benar pada daun jagung sehat pada gambar (c), gambar (e), gambar (g), dan

gambar (i). Untuk hasil prediksi benar pada daun jagung berlubang ditunjukkan pada gambar (b), gambar (d), dan gambar (h). Sedangkan pada gambar (a) masukkan dataset merupakan daun jagung berlubang namun diprediksi sebagai daun jagung sehat, dan pada gambar (f) seharusnya daun jagung sehat namun model Inception_ResNet_V2 memprediksi sebagai daun jagung berlubang.

Prediksi Model MobileNet

Berikut merupakan hasil proses prediksi pada model MobileNet:



Gambar 29. Hasil Prediksi Model MobileNet

Hasil prediksi pada model MobileNet, pada gambar (b), gambar (d), gambar (f), dan gambar (g) menunjukkan hasil prediksi benar untuk daun jagung sehat. Sedangkan pada gambar (a), gambar (e), dan gambar (h) menunjukkan hasil prediksi benar untuk daun jagung berlubang. Pada gambar (c) dan gambar (i), model MobileNet menunjukkan hasil prediksi yang tidak sesuai dengan masukkan datasetnya. Pada gambar (c) masukkan dataset merupakan daun jagung sehat namun hasil prediksi menunjukkan daun jagung berlubang, sedangkan pada gambar (i) seharusnya daun jagung berlubang namun hasil prediksi menunjukkan daun jagung sehat.

Berikut merupakan rekap performa model VGG16:

Tabel 2. Akurasi dan Loss Model VGG16

	Akurasi	Loss
Pelatihan	0.9826	0.1486
Validasi	0.9406	0.1448

Rata – rata nilai akurasi pelatihan pada model VGG16 adalah 0.9286 dan rata – rata nilai loss pelatihnannya adalah 0.1486. Pada proses validasi, model VGG16 mampu mencapai rata – rata nilai akurasi validasi 0.9406 dan rata – rata nilai loss validasi 0.1448.

Tabel 3. Akurasi, Presisi, dan Recall Model VGG16

	Presisi	Recall	Akurasi
Daun Sehat	1.00	0.89	94.44%
Daun Berlubang	0.89	1.00	

Pada pengujian model VGG16, nilai akurasi yang didapatkan adalah 94.4%. Nilai presisi untuk daun sehat adalah 1.00 dan daun berlubang adalah 0.89. Sedangkan nilai recall untuk daun sehat adalah 0.89 dan daun berlubang adalah 1.00.

Model Inception_V3

Performa model Inception_V3 adalah sebagai berikut:

Tabel 4. Akurasi dan Loss Model Inception_V3

	Akurasi	Loss
Pelatihan	0.9141	0.1843
Validasi	0.8442	0.1931

Model Inception_V3 mampu mencapai nilai rata – rata 0.9141 pada akurasi pelatihan dan nilai rata – rata 0.1843 pada loss pelatihan. Pada proses validasi, model Inception_V3 mampu mencapai rata – rata nilai akurasi validasi 0.8442 dan rata – rata nilai loss validasi 0.1931.

Tabel 5. Akurasi, Presisi, dan Recall Model Inception_V3

	Presisi	Recall	Akurasi
Daun Sehat	0.97	0.92	94.44%
Daun Berlubang	0.92	0.97	

Akurasi yang dieproleh model Inception_V3 pada proses pengujian adalah 94.44%. Nilai presisi untuk daun sehat adalah 0.97 dan daun berlubang adalah 0.92. Sedangkan nilai recall untuk daun sehat adalah 0.92 dan daun berlubang adalah 0.97.

Model Xception

Berikut merupakan hasil performa model Xception:

Tabel 6. Akurasi dan Loss model Xception

	Akurasi	Loss
Pelatihan	0.8954	0.1813
Validasi	0.8394	0.1939

Rata – rata nilai akurasi pelatihan pada model Xception adalah 0.8954 dan rata – rata nilai loss pelatihnannya adalah 0.1813. Pada proses validasi, model Xception mampu mencapai rata – rata nilai akurasi validasi 0.8394 dan rata – rata nilai loss validasi 0.1939.

Tabel 7. Akurasi, Presisi, dan Recall Model Xception

	Presisi	Recall	Akurasi
Daun Sehat	0.92	0.87	88.89%
Daun Berlubang	0.86	0.91	

Pada pengujian model Xception, nilai akurasi yang didapatkan adalah 88.89%. Nilai presisi untuk daun sehat adalah 0.92 dan daun berlubang adalah 0.86. Sedangkan nilai recall untuk daun sehat adalah 0.87 dan daun berlubang adalah 0.91.

Model Inception_ResNet_V2

Performa model Inception_ResNet_V2 dapat dilihat pada rangkuman berikut:

Tabel 8. Akurasi dan Loss Model Inception_ResNet_V2

	Akurasi	Loss
Pelatihan	0.8170	0.2009
Validasi	0.6739	0.2277

Model Inception_ResNet_V2 mampu mencapai nilai rata – rata 0.8170 pada akurasi pelatihan dan nilai rata – rata 0.2009 pada loss pelatihan. Pada proses validasi, model Inception_ResNet_V2 mampu mencapai rata – rata nilai akurasi validasi 0.6739 dan rata – rata nilai loss validasi 0.2277.

Tabel 9. Akurasi, Presisi, dan Recall Model Inception_ResNet_V2

	Presisi	Recall	Akurasi
Daun Sehat	0.94	0.82	87.50%
Daun Berlubang	0.82	0.94	

Akurasi yang dieproleh model Inception_ResNet_V2 pada proses pengujian adalah 87.50%. Nilai presisi untuk daun sehat adalah 0.94 dan daun berlubang adalah 0.82. Sedangkan nilai recall untuk daun sehat adalah 0.82 dan daun berlubang adalah 0.94.

Model MobileNet

Berikut merupakan performa model MobileNet:

Tabel 10. Akurasi dan Loss Model MobileNet

	Akurasi	Loss
Pelatihan	0.8981	0.1762
Validasi	0.8333	0.1886

Rata – rata nilai akurasi pelatihan pada model MobileNet adalah 0.8981 dan rata – rata nilai loss pelatihannya adalah 0.1762. Pada proses validasi, model MobileNet mampu mencapai rata – rata nilai akurasi validasi 0.8333 dan rata – rata nilai loss validasi 0.1886.

Tabel 11. Akurasi, Presisi, dan Recall Model MobileNet.

	Presisi	Recall	Akurasi
Daun Sehat	0.92	0.91	91.67%
Daun Berlubang	0.91	0.92	

Pada pengujian model MobileNet, nilai akurasi yang didapatkan adalah 91.67%. Nilai presisi untuk daun sehat adalah 0.92 dan daun berlubang adalah 0.91. Sedangkan nilai recall untuk daun sehat adalah 0.91 dan daun berlubang adalah 0.92.

Pada pelatihan dan validasi model CNN, dengan waktu 1 menit 1 detik model VGG16 mencapai rata – rata nilai akurasi tertinggi dengan nilai rata – rata akurasi pelatihan 0.9286 dan rata – rata nilai akurasi validasi 0.9406. Pada pengujian model CNN, model VGG16 mampu mencapai nilai akurasi 94.4%. Nilai presisi pada model VGG16 untuk daun sehat mencapai 1.00 dan daun berlubang mencapai 0.89, sedangkan nilai recall pada model VGG16 untuk daun sehat adalah 0.89 dan daun berlubang adalah 1.00. berdasarkan data – data yang telah dijabarkan, dapat disimpulkan model VGG16 merupakan model

CNN terbaik untuk klasifikasi daun jagung sehat dan daun jagung berlubang.

V. KESIMPULAN

Berdasarkan hasil pengujian menunjukkan bahwa model VGG16 dan model Inception_V3 memiliki nilai akurasi paling tinggi dengan nilai akurasi 94.44%, dilanjutkan dengan model MobileNet dengan nilai akurasi 91.67%, model Xception dengan nilai akurasi 88.89%, dan model Inception_ResNet_V2 memiliki nilai akurasi paling rendah dengan nilai akurasi 87.50%

DAFTAR PUSTAKA

- [1] K. P. Panigrahi, A. K. Sahoo and H. Das, "A CNN Approach for Corn Leaves Disease Detection to support Digital Agricultural System," *2020 4th International Conference on Trends in Electronics and Informatics (ICOEI)*(48184), Tirunelveli, India, 2020, pp. 678-683, doi: 10.1109/ICOEI48184.2020.9142871.
- [2] T. Miedaner and P. Juroszek, "Global warming and increasing maize cultivation demand comprehensive efforts in disease and insect resistance breeding in north-western Europe," *Plant Pathology*, vol. 70, no. 5, pp. 1032–1046, Feb. 2021, doi: <https://doi.org/10.1111/ppa.13365>.
- [3] A. Aripin *et al.*, "Serangan Ulat Grayak Jagung (Spodoptera Frugiperda) pada Tanaman Jagung di Desa Petir, Kecamatan Daramaga, Kabupaten Bogor dan Potensi Pengendaliannya Menggunakan Metarizhium Rileyi," *Jurnal Pusat Inovasi Masyarakat*, vol. 2, no. 6, pp. 931–939–931–939, 2020, Accessed: Jan. 15, 2025. [Online]. Available: <https://journal.ipb.ac.id/index.php/pim/article/view/33263>
- [4] Y. Maharani, V. K. Dewi, L. T. Puspasari, L. Rizkie, Y. Hidayat, and D. Dono, "Cases of Fall Army Worm Spodoptera frugiperda J. E. Smith (Lepidoptera: Noctuidae) Attack on Maize in Bandung, Garut and Sumedang District, West Java.," *Cropsaver Journal of Plant Protection*, vol. 2, no. 1, pp. 38–38, Jun. 2019, doi: <https://doi.org/10.24198/cropsaver.v2i1.23013>.
- [5] Muhammad, L. S. Chua, F. R. Rahmad, F. I. Abdullah, and W. Alwi, "Review on Techniques for Plant Leaf Classification and Recognition," *Computers*, vol. 8, no. 4, pp. 77–77, Oct. 2019, doi: <https://doi.org/10.3390/computers8040077>.
- [6] M. Hussain, J. J. Bird, and D. R. Faria, "A Study on CNN Transfer Learning for Image Classification," *Advances in intelligent systems and computing*, pp. 191–202, Aug. 2018, doi: https://doi.org/10.1007/978-3-319-97982-3_16.
- [7] M. Sardogan, A. Tuncer and Y. Ozen, "Plant Leaf Disease Detection and Classification Based on CNN with LVQ Algorithm," *2018 3rd International Conference on Computer Science and Engineering (UBMK)*, Sarajevo, Bosnia and Herzegovina, 2018, pp. 382-385, doi: 10.1109/UBMK.2018.8566635.
- [8] S. Ghosal and K. Sarkar, "Rice Leaf Diseases Classification Using CNN With Transfer Learning," *2020 IEEE Calcutta Conference (CALCON)*, Kolkata, India, 2020, pp. 230-236, doi: 10.1109/CALCON49167.2020.9106423.
- [9] Z. ur Rehman *et al.*, "Recognizing apple leaf diseases using a novel parallel real-time processing framework based on MASK RCNN and transfer learning: An application for smart agriculture," *IET Image Processing*, vol. 15, no. 10, pp. 2157–2168, Mar. 2021, doi: <https://doi.org/10.1049/ipr2.12183>.
- [10] M. Sibiyana and M. Sumbwanyambe, "A Computational Procedure for the Recognition and Classification of Maize Leaf Diseases Out of Healthy Leaves Using Convolutional Neural Networks," *AgriEngineering*, vol. 1, no. 1, pp. 119–131, Mar. 2019, doi: <https://doi.org/10.3390/agriengineering1010009>.
- [11] A. Waheed, M. Goyal, D. Gupta, A. Khanna, Aboul Ella Hassanien, and H. M. Pandey, "An optimized dense convolutional neural network model for disease recognition and classification in corn leaf," *Computers and Electronics in Agriculture*, vol. 175, pp. 105456–105456, Jun. 2020, doi: <https://doi.org/10.1016/j.compag.2020.105456>.

- [12] A. Fujishiro, Y. Nagamura, T. Usami and M. Inoue, "Minimization of CNN Training Data by using Data Augmentation for Inline Defect Classification," *2020 International Symposium on Semiconductor Manufacturing (ISSM)*, Tokyo, Japan, 2020, pp. 1-4, doi: 10.1109/ISSM51728.2020.9377504.
- [13] I. K. G. Darma Putra, R. Fauzi, D. Witarsyah, and I. P. D. Jayantha Putra, "Classification of Tomato Plants Diseases Using Convolutional Neural Network", *Int. J. Adv. Sci. Eng. Inf. Technol.*, vol. 10, no. 5, pp. 1821–1827, Oct. 2020.
- [14] Ü. Atila, M. Uçar, K. Akyol, and E. Uçar, "Plant leaf disease classification using EfficientNet deep learning model," *Ecological Informatics*, vol. 61, p. 101182, Mar. 2021, doi: <https://doi.org/10.1016/j.ecoinf.2020.101182>.
- [15] E. Prasetyo, R. Purbaningtyas, R. D. Adityo, E. T. Prabowo, and A. I. Ferdiansyah, "Perbandingan Convolution Neural Network Untuk Klasifikasi Kesegaran Ikan Bandeng Pada Citra Mata," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 8, no. 3, pp. 601–601, Jun. 2021, doi: <https://doi.org/10.25126/jtiik.2021834369>.
- [16] Sandhopi, Lukman Zaman P.C.S.W, and Y. Kristian, "Identifikasi Motif Jepara pada Ukiran dengan Memanfaatkan Convolutional Neural Network," *Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI)*, vol. 9, no. 4, pp. 403–413, Dec. 2020, doi: <https://doi.org/10.22146/jnteti.v9i4.541>.
- [17] M. R. Alwanda, R. P. K. Ramadhan, and D. Alamsyah, "Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle," *Jurnal Algoritme*, vol. 1, no. 1, pp. 45–56, Oct. 2020, doi: <https://doi.org/10.35957/algoritme.v1i1.434>.
- [18] D. Singh, V. Kumar, None Vaishali, and M. Kaur, "Classification of COVID-19 patients from chest CT images using multi-objective differential evolution-based convolutional neural networks," *European Journal of Clinical Microbiology & Infectious Diseases*, vol. 39, no. 7, pp. 1379–1389, Apr. 2020, doi: <https://doi.org/10.1007/s10096-020-03901-z>.
- [19] S. Gurung and Y. R. Gao, "Classification of Melanoma (Skin Cancer) using Convolutional Neural Network," *2020 5th International Conference on Innovative Technologies in Intelligent Systems and Industrial Applications (CITISIA)*, Sydney, Australia, 2020, pp. 1-8, doi: 10.1109/CITISIA50690.2020.9371829.
- [20] S. Hassantabar, M. Ahmadi, and A. Sharifi, "Diagnosis and detection of infected tissue of COVID-19 patients based on lung x-ray image using convolutional neural network approaches," *Chaos Solitons & Fractals*, vol. 140, pp. 110170–110170, Jul. 2020, doi: <https://doi.org/10.1016/j.chaos.2020.110170>.
- [21] E. Ihsanto, K. Ramli, D. Sudiana, and T. S. Gunawan, "An Efficient Algorithm for Cardiac Arrhythmia Classification Using Ensemble of Depthwise Separable Convolutional Neural Networks," *Applied Sciences*, vol. 10, no. 2, p. 483, Jan. 2020, doi: <https://doi.org/10.3390/app10020483>.
- [22] N. K. Chowdhury, M. M. Rahman, and M. A. Kabir, "PDCOVIDNet: a parallel-dilated convolutional neural network architecture for detecting COVID-19 from chest X-ray images," *Health Information Science and Systems*, vol. 8, no. 1, Sep. 2020, doi: <https://doi.org/10.1007/s13755-020-00119-3>.
- [23] S. Sukegawa *et al.*, "Deep Neural Networks for Dental Implant System Classification," *Biomolecules*, vol. 10, no. 7, pp. 984–984, Jul. 2020, doi: <https://doi.org/10.3390/biom10070984>.
- [24] F. Demir, "Deep autoencoder-based automated brain tumor detection from MRI data," *Elsevier eBooks*, pp. 317–351, Jan. 2022, doi: <https://doi.org/10.1016/b978-0-323-91197-9.00013-8>.
- [25] S. K. Arjaria, A. S. Rathore, and J. S. Cherian, "Kidney disease prediction using a machine learning approach: A comparative and comprehensive analysis," *Elsevier eBooks*, pp. 307–333, Jan. 2021, doi: <https://doi.org/10.1016/b978-0-12-821633-0.00006-4>.