

KLASIFIKASI TANAMAN AGLAONEMA BERDASARKAN CITRA DAUN MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)

Satrio Muhammad¹, Agung Toto Wibowo²

^{1,2} Universitas Telkom, Bandung

satriosmandak@students.telkomuniversity.ac.id¹, agungtoto@telkomuniversity.ac.id²

Abstrak

Aglaonema adalah salah satu jenis tanaman hias yang terdiri dari tiga puluh spesies yang tersebar di seluruh wilayah tropis dan sebagian subtropis dunia. Jenis-jenis aglaonema juga terus bertambah seiring perkembangan aglaonema hibrida yang menciptakan sifat tanaman yang unggul dan memiliki corak, warna bentuk, ukuran daun yang menarik. Dengan beragamnya jenis aglaonema yang memiliki variasi-variasi yang unik dan mudah dirawat menjadikan tanaman ini diminati sebagai tanaman hias. Selain itu dengan seiringnya perkembangan zaman, banyak jenis aglaonema hibrida baru menjadikan masyarakat sulit membedakan tanaman aglaonema ini. Dengan demikian maka apabila ada sistem yang dapat mengidentifikasi tanaman aglaonema ini diharapkan dapat mempermudah masyarakat untuk mengenali jenisnya. Sistem yang akan dibuat ini menggunakan metode *Convolutional Neural Network* (CNN) dengan menggunakan arsitektur RestNet50v2. Sistem ini menggunakan dataset sebanyak 1960 citra gambar dari empat jenis aglaonema yang berbeda dengan ciri-ciri yang hampir sama yang sering ditemukan dijual di pasaran yaitu Red Anjamani, Red Majesty, Black Maroon, Ruby Garuda. Hasil dari penelitian ini adalah dengan model ber-*background* dengan akurasi *testing* sebesar 99% dengan *loss* sebesar 0.084 dengan *F1-score* tertinggi sebesar 100% dari jenis Red Majesty dengan Black Maroon, sementara pada model tidak ber-*background* menghasilkan akurasi *testing* sebesar 71%.

Kata Kunci: Identifikasi, Klasifikasi, Aglaonema, *Convolutional Neural Network*.

Abstract

Aglaonema is one type of ornamental plant consisting of thirty species spread throughout the tropical and subtropical regions of the world. The types of aglaonema also continue to grow along with the development of hybrid aglaonema which creates superior plant traits and has attractive color, shape, leaf size. With the various types of aglaonema that have unique variations and are easy to care for, this plant is in demand as an ornamental plant. In addition, with the development of the times, many types of new hybrid aglaonema make it difficult for people to distinguish this aglaonema plant. Thus, if there is a system that can identify the aglaonema plant, it is hoped that it will make it easier for people to recognize the type. The system to be built uses the Convolutional Neural Network (CNN) method using the RestNet50v2 architecture. This system uses a dataset of 1960 images of four different types of aglaonema with almost the same characteristics that are often found on the market, namely Red Anjamani, Red Majesty, Black Maroon, Ruby Garuda. The results of this study are the background model with a testing accuracy of 99% with a loss of 0.084 with the highest F1-score of 100% from the Red Majesty type with Black Maroon, while the non-background model produces a testing accuracy of 71%.

Keywords: Identification, Classification, Aglaonema, Convolutional Neural Network.

1. Pendahuluan

1.1 Latar Belakang

Tanaman hias daun pada saat ini menjadi trend lagi, dimana harganya bisa mencapai ratusan ribu sampai jutaan rupiah. Beberapa tanaman hias daun yang sedang menjadi trend saat ini diantaranya adalah Anthurium, Aglaonema, dan Philodendron. Namun dari ketiga tanaman hias tersebut tanaman Aglaonema ini yang sedikit

sulit untuk diidentifikasi jenisnya, karena mempunyai ragam jenis baik aglaonema alam maupun aglaonema hibrida.

Aglaonema adalah jenis tanaman hias dengan daun yang indah. Warna dan bentuk daun yang unik menjadikan daya tarik tersendiri untuk para pencintanya. Dari keindahan daunnya itu maka tanaman Aglaonema ini dikenal juga sebagai ratu tanaman hias karena sosoknya yang anggun dan harganya yang relatif mahal.

Dalam klasifikasinya, tumbuhan Aglaonema ini termasuk dalam famili Araceae, dimana tanaman yang berkerabat dekatnya yang mempunyai daun indah lainnya itu seperti Alocasia, Anthurium, Caladium, Dieffenbachia. Bahkan, banyak masyarakat awam yang salah dalam membedakan tanaman Aglaonema dengan tanaman Dieffenbachia atau yang lebih dikenal sebagai tanaman Blanceng karena banyaknya persamaan morfologinya.

Aglaonema ini memiliki banyak sekali jenisnya dan dikelompokkan menjadi dua, yaitu aglaonema spesies alam dan juga aglaonema hibrida. Aglaonema spesies alam terdiri dari 25 jenis yang biasanya mempunyai warna daun yang dominan hijau. Sedangkan aglaonema hibrida memiliki warna dan corak yang lebih bervariasi karena melalui hasil persilangan. Aglaonema hibrida ini dibedakan lagi menjadi dua kelompok, yaitu aglaonema hibrida paten dan aglaonema hibrida non-paten. aglaonema paten adalah tanaman yang sudah dipatenkan di lembaga pendaftaran paten tanaman hias di Amerika, contohnya peacock dan marry ann.

Sekarang varietas aglaonema sudah ratusan bahkan ribuan di dunia ini. Menurut catatan pengamat aglaonema di Indonesia sampai tahun 2006 terdapat 60 jenis aglaonema hibrida lokal [1]. Pada penelitian ini ada empat jenis aglaonema yang dipakai sebagai dataset, yaitu jenis Red Anjamani, Red Majesty, Black Maroon, dan Ruby Garuda. Pemilihan empat jenis ini karena dari bentuk fisik yang mirip dan sukar untuk dikenali oleh orang-orang. Karena banyak orang yang awam yang sulit mengidentifikasi jenis aglaonema tersebut ada oknum-oknum penjual yang menjual jenis aglaonema murah dengan nama aglaonema yang mahal. Apalagi harga aglaonema ini sangat variasi, mulai dari Red Anjamani yang harganya berkisar dari 65-395 ribu rupiah, Red Majesty berkisar dari 120-700 ribu rupiah, Black Maroon berkisar dari 150-970 ribu rupiah dan Ruby Garuda yang berkisar 200-540 ribu rupiah. Tentu akan ada kerugian apabila penjual atau pembeli salah mengidentifikasi jenis aglaonema tersebut.

Cara mengetahui jenis tanaman aglaonema ini bisa dibedakan/diidentifikasi berdasarkan bentuk, warna corak dari daunnya dan tulang daunnya. Agar mempermudah pengidentifikasian dan pengklasifikasian tanaman Aglaonema ini maka dilakukan pengambilan citra yang selanjutnya akan diproses atau diolah menjadi sebuah data yang akan diklasifikasikan menggunakan Convolutional Neural Network (CNN). CNN banyak diaplikasikan pada data berbentuk citra karena menyimpan informasi spesial dari data citra sehingga menghasilkan hasil klasifikasi yang baik. [2]

Convolutional Neural Network (CNN) merupakan salah satu metode deep learning yang mampu belajar secara mandiri untuk melakukan pengenalan objek 2D seperti gambar dan video [3][4]. CNN mempunyai banyak arsitektur yang bisa digunakan seperti alexNet, VGGNet, leNet, Restnet dan lain-lain [11][12].

1.2 Topik dan Batasannya

Berdasarkan identifikasi masalah dan keterbatasan yang ada pada peneliti, maka perlu adanya batasan masalah agar ruang lingkup penelitian menjadi jelas. Dalam perancangan sistem ini terdapat batasan masalah sebagai berikut :

1. Sistem ini dimodelkan untuk mengenali dan mengenali empat label/kelas dari tanaman Aglaonema dengan identifikasi citra daun.
2. Data set diambil menggunakan kamera handphone dari pembudidaya *aglaonema*.
3. Proses pembuatan model sistem menggunakan Google Colab.
4. Jumlah dataset yang digunakan sebanyak 1760 citra untuk data train dan 200 citra untuk data test yang dibagi untuk empat kelas/label.

1.3 Tujuan

Dari deskripsi latarbelakang yang sudah dibuat, maka rumusan masalah yang diajukan dalam penelitian ini adalah sebagai berikut:

1. Bagaimana membuat program aplikasi pengklasifikasian daun berdasarkan citra daun aglaonema?

2. Bagaimana performansi program aplikasi dalam mengidentifikasi perbedaan ciri pada masing-masing jenis daun dari hasil pengujiannya?
3. Bagaimana pengambilan dataset dilakukan?

1.4 Tujuan

Tujuan dari penelitian adalah sebagai media pembelajaran untuk masyarakat dan pembudidaya tanaman *aglaonema*, membuat sistem identifikasi tanaman *aglaonema* menggunakan metode *Convolution Neural Network* dengan arsitektur RestNet dan menguji performansi kinerja model yang sudah dibuat dan mengumpulkan dataset untuk empat jenis tanaman *aglaonema*.

2. Studi Terkait

Pada penelitian terdahulu terdapat berbagai pemecahan masalah dengan metode *machine learning* menggunakan metode *Convolutional Neural Network* untuk mengklasifikasi citra. Berikut ini adalah beberapa penelitian terdahulu:

Menurut (Felix, Jeffry, Stephan, Pyter dan Pahala) dengan penelitiannya yang berjudul "Implementasi Convolutional Neural Network untuk Identifikasi Jenis Tanaman Melalui Daun". Pengujian penelitian ini dilakukan dengan 375 gambar daun: 250 citra sebagai data latih dan 125 citra sebagai data uji. Hasil pengujian menggunakan metode Convolutional Neural Network ini menghasilkan akurasi yang baik dalam pengidentifikasian pixel dan dapat mengenali setiap jenis daun yang ada. Dari hasil pengujian ini didapatkan tingkat akurasi sebesar 76%. [5]

Menurut (Laila, Sitti dan Febriyana) dengan penelitiannya yang berjudul "Deteksi Kecacatan Permukaan Buah Manggis Menggunakan Metode Deep Learning dengan Konvolusi Multilayer". Penelitian ini tujuannya adalah untuk mendeteksi cacat pada permukaan buah manggis dihitung antara epoch dan layer. Metode ini mencapai nilai maksimum dengan parameter 4 layer dan nilai epoch 30 menghasilkan tingkat akurasi sebesar 98%. [6]

Menurut (Setiawan dan Imas) dengan penelitiannya yang berjudul "Klasifikasi Penyakit pada Citra Daun Menggunakan Convolutional Neural Networks" Penelitian ini bertujuan untuk mengidentifikasi penyakit pada daun tanpa harus mendefinisikan ciri dan proses segmentasinya. Penelitian ini menggunakan 9 jenis penyakit daun dengan masing-masing jenis penyakit terdiri dari 124 data citra. Dari hasil penelitian ini didapatkan rata-rata akurasi identifikasi sebesar 74,91% dengan akurasi terbaik 77,78%. [7]

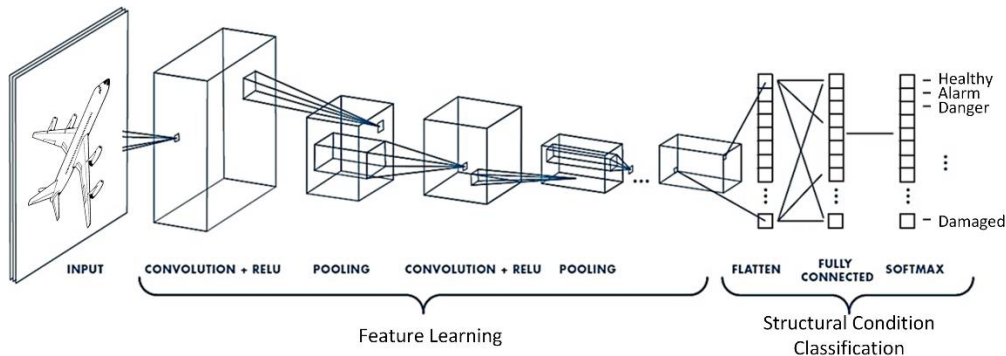
2.1 Aglaonema

Aglaonema atau tanaman Sri Rezeki termasuk dari suku talas-talasan atau Famili *Araceae*, aglaonema juga memiliki sekitar 30 genus spesies. Aglaonema merupakan tanaman hias populer dan mempunyai nilai ekonomis yang tinggi. Aglaonema ini memiliki keindahan dari bentuk daun dan komposisi warna pada daunnya. Habitat dari tanaman ini adalah di bawah hutan hujan tropis dengan intensitas penyiangan rendah dan kelembaban yang tinggi. Sekarang berbagai macam aglaonema hibrida sudah banyak dikembangkan dengan macam-macam warna, bentuk dan ukuran daun sehingga sudah jauh berbeda dengan spesies alaminya.

2.2 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah pengembangan dari Multilayer Perceptron (MLP) yang didesain untuk mengolah data dua dimensi. *Convolutional Neural Network* termasuk dalam jenis *Deep Neural Network* dan salah satu jenis neural network yang biasa digunakan pada data image untuk mendeteksi/mengenali *object* dari sebuah *image*. Cara kerja CNN adalah dengan memanfaatkan proses konvolusi dengan menggerakkan

sebuah kernel konvolusi kepada sebuah gambar. Komputer akan mendapatkan informasi *representative* baru dari hasil perkalian bagian gambar. Berikut adalah gambaran dari arsitektur *Convolutional Neural Network*:




Gambar 1 Arsitektur Convolutional Neural Network [17]

2.2.1 Input Layer

Komputer melihat gambar *input* pada *Input Layer* dengan melihat berapa jumlah *pixel* yang dimilikinya. Penilaian ini bergantung pada beberapa nilai dari *height x width x depth*, dimana *depth* ini mengacu ke channel suatu gambar (RGB). Nilai *depth* ini ada pada rentang 0 -225 sesuai dengan intensitas pixel pada masing-masing channel. Jadi jika memiliki gambar berwarna dengan ukuran 256x256 pixel maka representasi arraynya adalah 256x256x3.

2.2.2 Convolutional

Convolution layer adalah blok utama didalam CNN yang terdiri dari beragam filter yang diinisialisasi secara acak untuk melakukan operasi konvolusi yang berfungsi sebagai ekstraksi fitur untuk mempelajari representasi fitur dari suatu input gambar. Nilai awal acak ini akan di perbarui (update) pada saat proses training berlangsung. Pada proses ini dikalikan dan bergerak dari sudut kiri atas ke kanan bawah pada bagian citra gambar [14]. Setiap gambar kecil yang diambil dari hasil konvolusi akan dijadikan input untuk menghasilkan representasi fitur, dengan begitu CNN dapat mengenali sebuah objek dimanapun posisi objek itu muncul pada gambar.



Gambar 2 Ilustrasi Convolutional Layer [14]

Pada convolution layer, neuron tersusun menjadi feature maps. Setiap neuron pada feature map sebagai receptive field, terhubung pada neuron-neuron dari convolution layer sebelumnya melalui serangkaian bobot yang dilatih, biasa juga disebut dengan filter bank.

2.2.3 ReLu

ReLU merupakan fungsi aktivasi yang digunakan pada neuron seperti fungsi aktivasi lainnya, setiap node menggunakan fungsi aktivasi *rectifier* yang dikenal dengan node ReLU. Alasan utama ReLU digunakan karena lebih efisien dalam melakukan komputasi dibandingkan dengan fungsi aktivasi konvensional seperti *sigmoid* dan *hyperbolic tangent*, tanpa membuat perbedaan yang signifikan terhadap generalisasi pada akurasi.

Fungsi aktivasi *rectifier* digunakan sebagai pengganti fungsi aktivasi linier untuk menambahkan non-linearity kedalam network, jika *network* hanya dapat menghitung fungsi linier.

2.2.4 Max Pooling

Setelah ReLU, biasanya pada layer berikutnya diterapkan Max Pooling. Tujuan dari penggunaan max pooling adalah untuk melakukan *down sampling* dari representasi, mengurangi dimensi yang memungkinkan hal ini dilakukan untuk membantu penyesuaian secara berlebihan dengan menyediakan bentuk representasi dengan nilai maksimum dari input. Selain itu, maxpooling mengurangi biaya komputasi dengan mengurangi jumlah parameter untuk dipelajari dan memberikan inventarisasi translasi dasar ke representasi internal.

2.2.5 Flattening

Mengubah nilai masukan menjadi sebuah array hasil pooling, setiap hasil dari proses Pooling Layer akan diubah menjadi bentuk array satu dimensi.

2.2.6 Full Connection

Fully Connected layer adalah merupakan multi-layer perceptron tradisional yang menggunakan fungsi aktivasi softmax pada lapisan output. Istilah "Fully Connected" menyatakan bahwa setiap neuron pada layer sebelumnya adalah terhubung kedalam setiap neuron-neuron pada lapisan berikutnya.

Output dari convolution dan pooling layer merepresentasikan *high level features* hasil ekstraksi dari input gambar. Layer ini pada dasarnya mendapatkan *volume input* (*convolution*, ReLU atau pooling Layer) dan menghasilkan vektor dimensi N dimana N adalah jumlah kelas. Tujuannya adalah menggunakan fitur-fitur tersebut untuk mengklasifikasikan gambar kedalam berbagai kelas berdasarkan yang sudah diinisialisasi pada data *training*.

2.2.7 Softmax

Fungsi softmax menghitung distribusi probabilitas dari kejadian di atas 'n' dari berbagai kejadian. Secara umum, fungsi ini akan menghitung probabilitas masing-masing kelas tujuan melalui semua kelas yang ada. Kemudian probabilitas melakukan kalkulasi yang sangat membantu untuk menentukan kelas tujuan dari input yang diberikan.

Keuntungan utama menggunakan Softmax adalah output dengan rentang probabilitas. Rentang akan 0 sampai 1, dan jumlah semua probabilitas akan sama dengan satu. Jika fungsi softmax digunakan untuk model multi-classification, softmax dapat mengembalikan probabilitas masing-masing kelas dan kelas target akan memiliki probabilitas tinggi.

2.2.8 Dropout

Dropout adalah teknik yang digunakan untuk mempercepat proses *training* dan mengurangi *overfitting* [15] di dalam *neural network* dengan mencegah adaptasi kompleks pada data training, dengan demikian maka akan berdampak pada performa model dalam melatih. Idanya adalah beberapa neuron akan dipilih secara acak dan tidak dipakai selama pelatihan. *Neuron-neuron* ini dapat dibuang secara acak. *Dropout* mengacu pada penghapusan unit secara acak dan sementara, baik di dalam *hidden layer* atau *visible layer*, dan semua keterhubungan antara *input* dan *output*.

2.2.9 Learning Rate

Parameter yang mengontrol seberapa cepat atau lambat model mempelajari masalah pada saat pelatihan. Jika *learning rate* terlalu kecil, mungkin diperlukan waktu yang lama untuk mencapai bobot yang optimal. Jika terlalu besar, mungkin bobot yang optimal terlewatkan begitu saja. Maka ada titik dimana nilai *learning rate* tidak akan meningkatkan akurasi serta tidak membuat model lebih baik [13]. Selain itu juga *learning rate* jika terlalu besar maka tingkat ketelitiannya akan semakin berkurang, sementara semakin kecil *learning rate* maka ketelitian jaringan akan semakin besar atau bertambah namun dengan konsekuensi proses *training* akan memakan waktu yang semakin lama.

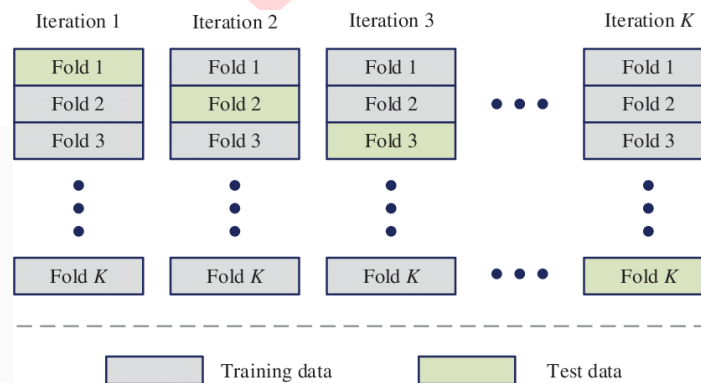
2.2.10 Epoch

Epoch adalah suatu representasi angka yang menunjukkan satu putaran penuh pada saat proses train terhadap seluruh dataset. Semakin tinggi nilai epoch maka nilai akurasi akan semakin tinggi dan nilai loss akan semakin rendah. Iterasi adalah satu kali forward dan backward pass dilakukan. Batch size adalah jumlah *datapoint* dalam satu batch.

2.3 Cross Validation

Cross validation adalah metode statistik untuk mengevaluasi dan membandingkan algoritma pembelajaran dengan cara membagi data menjadi dua jenis data yaitu data train dan juga data validasi. Data train digunakan untuk melatih model pembelajaran sedangkan data validasi digunakan untuk memvalidasi model pembelajaran. Data train dan data validasi akan disilangkan secara berturut - turut agar setiap data dapat divalidasi dan salah satu jenis *cross validation* adalah *k - fold cross validation* [8].

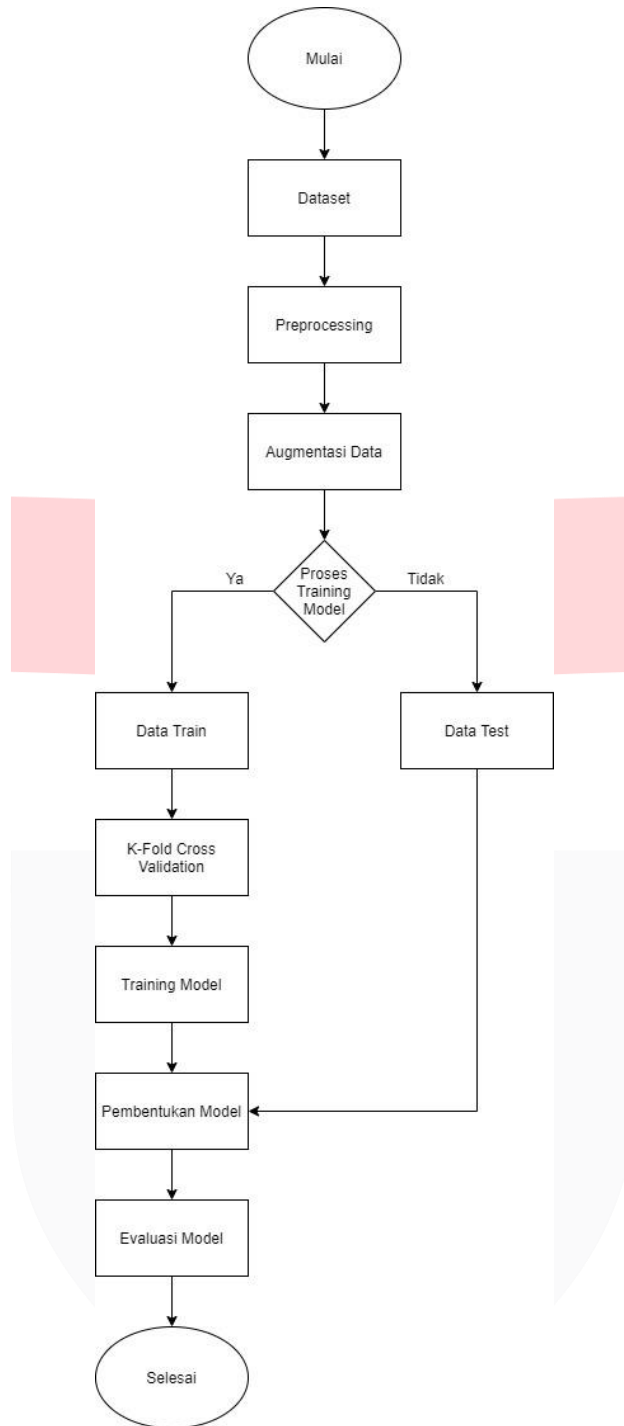
K-Fold Cross Validation adalah metode *cross validation*, caranya adalah dengan mempartisi data set menjadi dua yaitu data train dan juga data validasi yang dimana akan dipartisi ulang pada setiap iterasi dengan jumlah data validasi sama namun dengan data yang berbeda. Jadi data validasi pada iterasi sebelumnya menjadi data train dan data train sebelumnya diubah menjadi data validasi. Ini berfungsi agar setiap data didataset dapat divalidasi seluruhnya sehingga dapat menghasilkan akurasi yang akurat pada saat pembelajaran model.



Gambar 3 Ilustrasi K-Fold Cross Validation [16]

3. Sistem yang Dibangun

Pada tugas akhir ini, sistem yang akan dibangun dimulai dari menginputkan citra daun dari tanaman *Aglaonema*. Setelah itu akan dilakukan preprocessing data, yaitu *cropping*, *resize* dan augmentasi dataset. Lalu dilakukan pembagian data dengan rasio 90% data latih dan 10% data uji menggunakan CNN dengan arsitektur ResNet50V2.



Gambar 12. FlowChart Sistem

Berdasarkan *flowchart* pada gambar diatas, pengerjaan penelitian dimulai dari akuisisi citra, lalu dataset citra didapatkan. Setelah citra dataset didapatkan maka akan dilakukan preprocessing citra dataset, lalu setelah ter-processing data akan dibagi menjadi tiga bagian, yaitu data latih, data validasi, dan data uji. Data latih dan data validasi akan dilakukan proses training arsitektur CNN, setelah data hasil latih didapatkan maka akan dievaluasi menggunakan data uji.

3.1 Dataset




Dataset yang akan digunakan merupakan citra daun yang berjumlah 1960 citra dari empat jenis Aglaonema yang berbeda (Aglaonema Red Anjamani, Aglaonema Black Maroon, Red Majesty, dan Ruby Garuda). Berikut adalah tabel informasinya:

Tabel 1. Tabel Dataset

Nama	Jumlah dataTrain	Jumlah dataTest
Black Maroon	440	50
Red Anjamani	440	50
Red Majesty	440	50
Ruby Garuda	440	50

Dataset tersebut didapatkan dengan cara memfoto langsung dengan kamera handphone dari kebun milik pembudidaya aglaonema di Kabupaten Bogor. Tahap awal adalah memfoto daun dari tanaman aglaonema, lalu foto-foto tersebut dikelompokkan sesuai jenis/kelas yang sudah ditentukan. Berikut ini adalah bentuk dari empat jenis aglaonema tersebut:

Tabel 2. Tabel Jenis Aglaonema

Nama	Foto
Black Maroon	
Red Anjamani	
Red Majesty	



3.2 Preprocessing

Dataset secara keseluruhan berjumlah 1960 citra dengan komposisi tiap jenis sebanyak 490 citra ini adalah dari hasil dari preprocessing, data awal adalah hanya sebanyak 120 citra dimana setelah dilakukan preprocessing didapatkan hasil keseluruhan 1960 data tersebut. Hal ini dilakukan agar jumlah data yang digunakan untuk pelatihan model akan semakin banyak dan bervariasi sehingga hasil performansi model yang didapat juga akan semakin baik

Pada citra utuh hasil capture dari kamera berukuran 3472 x 4624 pixel. Karena keterbatasan komputasi dari ukuran asli citra dilakukan tahapan cropping dan proses resize pada citra dataset. Kedua proses ini dilakukan agar mempercepat proses komputasi pada sistem yang dibangun dan meningkatkan keakuratan pada ciri-ciri objek.

Cropping adalah proses pemotongan pada bagian citra yang tidak diperlukan, tujuannya adalah agar pada pemrosesan klasifikasi tidak terpengaruh pada bagian-bagian yang tidak diperlukan. Dengan begitu maka akan meningkatkan akurasi juga pada hasil akhir.

Resize adalah mengubah ukuran citra dari kecil ke besar atau sebaliknya, pada penelitian ini citra yang awalnya berukuran 3472x4624 diperkecil menjadi 256x256 pixel agar mempercepat proses komputasi pada saat running program. Karena dengan ukuran pixel yang lebih kecil maka ukuran file juga menjadi lebih kecil sehingga mempercepat proses load data nantinya.



Gambar 4 Ilustrasi Resize pada citra

Selain itu juga dilakukan rotate image dan flip untuk menambah variasi data agar model dapat mengidentifikasi data baru dengan lebih akurat.



Gambar 5 (A) Ilustrasi Rotate Gambar (B) Ilustrasi Flip Gambar

3.3 Augmentasi Data

Augmentasi data adalah suatu proses dalam pengolahan data gambar, augmentasi merupakan proses mengubah atau memodifikasi gambar sedemikian rupa sehingga komputer akan mendeteksi bahwa gambar yang diubah adalah gambar yang berbeda, namun manusia masih dapat mengetahui bahwa gambar yang diubah tersebut adalah gambar yang sama [9].

Dengan adanya augmentasi data dapat meningkatkan akurasi hasil model yang dilatih karena akan mendapatkan model-model tambahan yang berguna untuk melakukan generalisasi dengan lebih baik dan mampu mengatasi overfitting. Hal ini bertujuan untuk meningkatkan akurasi dari model CNN yang dilatih sehingga model akan melakukan generalisasi dengan baik dan mampu mengatasi masalah adanya overfitting [10].

3.4 Klasifikasi Model

Proses pengklasifikasian pada penelitian ini menggunakan arsitektur Resnet. Proses klasifikasi ini dimulai dengan membagi dua data, yaitu data uji dan data latih. Pada data latih digunakan untuk melatih model Deep Learning pada CNN [8], hasilnya akan dilakukan pengujian model dengan data uji yang sudah ada dan akan didapatkan hasil klasifikasi.

3.5 K-Fold Cross Validation

K-Fold Cross Validation adalah metode yang berfungsi untuk memvalidasi performansi pada model sistem yang telah dibuat. Caranya adalah dengan mengacak urutan citra data latih dengan membagi data menjadi beberapa lipatan yang masing-masing lipatan memiliki set validasi yang berbeda-beda untuk memvalidasi model dan dataset.

Dataset yang dipakai akan dipecah menjadi data train dan data validasi menggunakan k-fold cross validation dengan nilai $k = 5$. Ini berfungsi agar seluruh data train dapat divalidasi sehingga hasil akurasi model akan semakin akurat.

3.6 Evaluasi Model

Evaluasi model dilakukan dengan menggunakan confusion matrix dari masing-masing model. Selain itu dengan confusion matrix ini dapat dilihat rata-rata akurasi testing yang dihasilkan model selama iterasi pada fold K-fold cross validation.

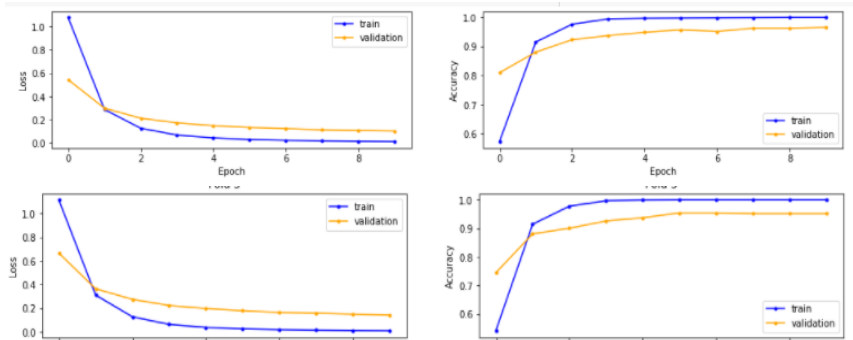
4. Evaluasi

3.1 Skenario Pengujian

Skenario pengujian yang dilakukan oleh penulis dilakukan beberapa tahapan. Pertama, penulis mencari nilai epoch terbaik. Selanjutnya penulis akan melakukan percobaan untuk mencari nilai learning rate terbaik. Terakhir, setelah mendapatkan nilai learning rate terbaik maka dilanjutkan dengan mencari nilai dropout terbaik dengan melakukan beberapa percobaan. Percobaan ini dilakukan dengan dua model dengan data latih ber-background dan data latih tidak ber-background.

4.1.1 Percobaan Epoch

Pada percobaan epoch dilakukan dengan cara melakukan beberapa kali training dengan nilai yang berbeda-beda. Semakin tinggi nilai epoch maka akurasi yang didapat akan semakin tinggi begitu juga dengan nilai loss-nya akan semakin rendah. Tetapi ada kondisi dimana ketika nilai loss dan akurasi sudah tidak berubah secara signifikan, maka bila sudah ada di kondisi tersebut nilai epoch sudah tidak perlu ditambahkan lagi.



Gambar 6 Grafik Loss (kiri) dan akurasi kanan

Model Ber-background (atas) dan Model tidak ber-background (bawah)

Pada gambar diatas, nilai akurasi dan loss sudah stabil tidak banyak perubahan, maka dari itu nilai epoch yang digunakan pada penelitian ini adalah 10 untuk pelatihan model.

4.1.2 Percobaan Learning Rate

Nilai learning rate ini berpengaruh terhadap kecepatan pelatihan dan performansi model. Pada percobaan untuk menentukan nilai learning rate, dilakukan beberapa percobaan menggunakan beberapa nilai learning rate. Pada penelitian ini dilakukan lima kali percobaan Hasil percobaan dapat dilihat pada Tabel berikut:

Tabel 3. Tabel Percobaan Learning Rate

Learning Rate	Model Ber-background	Model Tanpa background
0,00001	94.5%	68%
0.0001	98%	67.5%
0.001	98%	64.5%
0.01	96%	72%
0.1	60%	25%

Gambar 7 Diagram Akurasi Data Testing Learning Rate

Pada Gambar, dapat dilihat dari lima percobaan pada masing-masing model nilai learning rate yang menghasilkan akurasi tertinggi adalah nilai 0.0001 untuk kedua model dengan nilai 98% untuk model ber-background dan nilai 72% untuk yang tanpa background. Maka untuk nilai learning rate yang diambil adalah 0.0001 berbackground dan 0.01 untuk model tidak berbackground.

4.1.3 Percobaan Dropout

Untuk mencegah overfitting maka digunakanlah teknik dropout, selain itu juga dropout dapat meningkatkan hasil akurasi testing.

Tabel 4. Tabel Percobaan Dropout

Dropout	Model Ber-background	Model Tanpa background
0	98%	67%
0.12	97%	69%
0.25	98%	72%
0.37	98%	72%
0.5	99%	73%

Gambar 8 Diagram Akurasi Data Testing Drop Out

Pada gambar, dilakukan empat percobaan menggunakan dropout. Nilai paling besar pada model berbackground ialah di nilai dropout 0.5 dengan nilai akurasi sebesar 99%, sedangkan untuk model tidak ber-background nilai paling besar terdapat pada nilai dropout 0.5 juga dengan nilai akurasi 73%.

4.2 Hasil Pengujian

Pada tahap ini, penulis membuat model sesuai dengan rancangan arsitektur CNN dengan menggunakan K – Fold Cross – Validation dengan nilai k = 5. Nilai k = 5 diambil karena nilai k yang biasa digunakan pada penelitian adalah 5 yang dimana semakin besar nilai k maka komputasi yang dibutuhkan akan semakin berat oleh karena itu agar komputasi tidak terlalu berat dipilihlah nilai k = 5. Pengujian dilakukan penulis menggunakan parameter sebagai berikut :

1. Epoch : 10
2. Learning Rate : 0,0001(model background) & 0,01 (model tidak ber-background)
3. Dropout : 0.5
4. Fungsi Aktivasi : Relu
5. Ukuran Gambar : 224x224x3

Tabel 5. Tabel Hasil Cross Validation

Fold	Model Ber-background		Model Tanpa background	
	Akurasi	Validation	Akurasi	Validation
1	99.15%	98.86%	99.43%	99.71%
2	98.72%	97.72%	99.57%	99.43%
3	99.36%	99.43%	96.22%	96.30%
4	99.29%	99.01%	99.22%	99.43%
5	99.64%	99.71%	99.08%	98.58%

Rata-rata nilai akurasi dari ke-5 fold membuktikan seberapa baik model dalam melakukan klasifikasi secara umum. Dalam mengklasifikasi empat jenis aglaonema yang berwarna dominan merah dengan model data train ber-background menghasilkan akurasi dan validasi yang tinggi dimana rata-rata akurasi training sebesar 99.23% dan rata-rata validasi sebesar 98.94% dan untuk model dengan data train tanpa background didapatkan rata-rata akurasi training sebesar 98.70% dan rata-rata validasi sebesar 98.69%.

4.3 Hasil Akurasi Testing Model Ber-background

```

Accuracy : 99.000%
Loss      : 0.084

Classification Report :

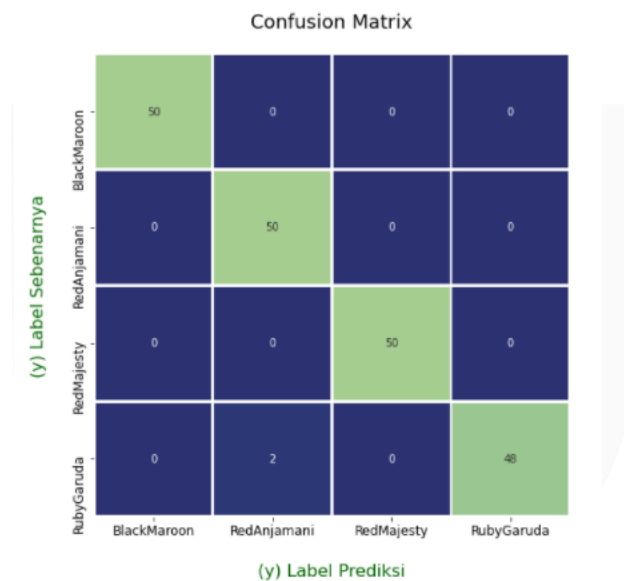
              precision    recall  f1-score   support

BlackMaroon      1.00      1.00      1.00        50
RedAnjamani      0.96      1.00      0.98        50
RedMajesty       1.00      1.00      1.00        50
RubyGaruda       1.00      0.96      0.98        50

   accuracy          0.99
  macro avg          0.99
 weighted avg          0.99
    
```

Gambar 9 Classification Report Model Ber-background

Berdasarkan classification report yang ada atas, model 1 memiliki akurasi sebesar 99% dengan nilai akurasi tertinggi didapat dari jenis Black Maroon dan Red Majesty dan Ruby Garuda yaitu sebesar 100% dan nilai akurasi terendah didapat dari jenis Red Anjamani dengan akurasi 96%.



Gambar 10 Confusion Matrix Model Ber-background

Berdasarkan confusion matrix yang ada dapat mengklasifikasikan dengan benar 50 dari 50 gambar untuk jenis BlackMaroon, 50 dari 50 gambar untuk RedAnjamani, 50 dari 50 gambar untuk jenis RedMajesty, 48 dari 50 gambar untuk jenis RubyGaruda. Kesalahan terjadi pada RedAnjamani dan RubyGaruda kemungkinan karena kemiripan antara kedua jenis daun itu.

4.4 Hasil Akurasi Testing Model Tidak Ber-background

```

Accuracy : 73.000%
Loss      : 1.000

Classification Report :

              precision    recall  f1-score   support

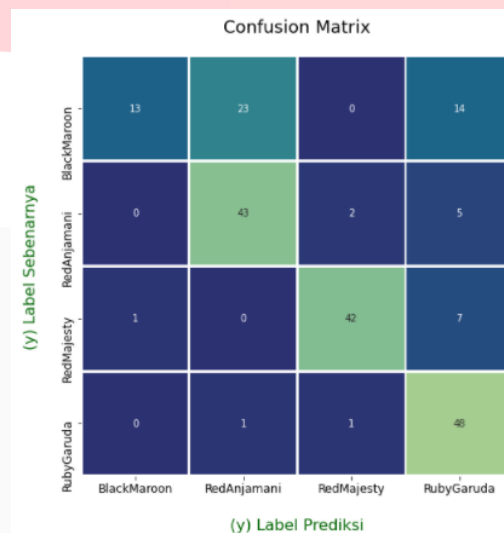
 BlackMaroon      0.93      0.26      0.41      50
 RedAnjamani      0.64      0.86      0.74      50
 RedMajesty       0.93      0.84      0.88      50
 RubyGaruda       0.65      0.96      0.77      50

 accuracy         0.73
 macro avg        0.79
 weighted avg     0.79

```

Gambar 11 Classification Report Model Tidak Ber-background

Berdasarkan classification report yang ada atas, model ini memiliki akurasi sebesar 73% dengan nilai akurasi tertinggi didapat dari jenis Red Majesty yaitu sebesar 93% dan nilai akurasi terendah didapat dari jenis Red Anjamani dengan akurasi 64%.



Gambar 12 Confusion Matrix Model Tidak Ber-background

Berdasarkan confusion matrix yang ada dapat mengklasifikasikan dengan benar 13 dari 50 gambar untuk jenis Black Maroon, 43 dari 50 gambar untuk Red Anjamani, 42 dari 50 gambar untuk jenis Red Majesty, 42 dari 50 gambar untuk jenis Ruby Garuda.

Banyak melesetnya identifikasi pada model ini dikarenakan data train tanpa background dengan data test ber-background memiliki background yang tidak sama yang menyebabkan saat melakukan testing hasil akurasi menjadi kecil.

5. Kesimpulan

Dari hasil penelitian yang telah dilakukan dapat ditarik kesimpulan bahwa metode CNN terbukti mampu mengklasifikasikan dengan baik untuk studi kasus jenis aglaonema dengan akurasi yang cukup besar yaitu 99% untuk 200 data testing ini membuktikan bahwa metode CNN mampu dengan baik mengidentifikasi citra daun aglaonema. Selain itu penelitian ini juga membuktikan bahwa model dengan data train ber-background memiliki akurasi lebih tinggi dibandingkan dengan model yang tidak memiliki background. Hal ini terjadi karena data train ber-background dengan data test ber-background memiliki background yang serupa yang menyebabkan saat melakukan testing hasil akurasi yang lebih bagus ada pada data train dengan background.

Saran

Saran untuk penelitian selanjutnya,

- Menambah jumlah dataset sehingga akurasi dapat lebih baik lagi dan juga dapat mengklasifikasikan jenis-jenis lainnya,
- Menggunakan dataset dengan background yang berbeda-beda agar lebih dataset bervariasi,
- Menguji dataset dengan dataset external seperti internet,
- Mencari tau hyperparameter yang lebih baik sehingga dapat menghasilkan performansi model yang lebih baik dan juga harapannya model yang telah dibuat,
- Mencoba menggunakan arsitektur yang lebih modern untuk kedepannya,
- Diimplementasikan pada sistem berbasis android ataupun website sehingga dapat digunakan dan bermanfaat bagi masyarakat luas.

Referensi

- [1] Redaksi. 2006. Pesona Aglaonema Indonesia. hal 3. Depok. AgroMedia Pustaka.
- [2] I. W. Suartika, A. Y. Wijaya and R. Soelaiman, "Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101," JURNAL TEKNIK ITS, vol. 5, p. 5, 2016.
- [3] Khan, Asifullah, et al. "A survey of the recent architectures of deep convolutional neural networks." *Artificial Intelligence Review* 53.8 (2020): 5455-5516.
- [4] Albawi, Saad, Tareq Abed Mohammed, and Saad Al-Zawi. "Understanding of a convolutional neural network." 2017 International Conference on Engineering and Technology (ICET). Ieee, 2017.
- [5] F. Felix, J. Wijaya, S. P. Sutra, P. W. Kosasih, and P. Sirait, "Implementasi Convolutional Neural Network Untuk Identifikasi Jenis Tanaman Melalui Daun," *J. SIFO Mikroskil*, vol. 21, no. 1, pp. 1–10, 2020.
- [6] L. Marifatul Azizah, S. Fadillah Umayah, and F. Fajar, "Deteksi Kecacatan Permukaan Buah Manggis Menggunakan Metode Deep Learning dengan Konvolusi Multilayer," *Semesta Tek.*, vol. 21, no. 2, pp. 230–236, 2018, doi: 10.18196/st.212229.
- [7] Setiawan, Muhammad Sitanggang and Imas Sukaesih, "Klasifikasi Penyakit pada Citra Daun Menggunakan Convolutional Neural Networks", 2018.
- [8] Perez, Luis, and Jason Wang. "The effectiveness of data augmentation in image classification using deep learning." *arXiv preprint arXiv:1712.04621* (2017).
- [9] A. A. Jaelani, F. Y. Supratman, and N. Ibrahim, "PERANCANGAN APLIKASI UNTUK KLASIFIKASI KLON DAUN TEH SERI GAMBUNG (GMB) MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK" vol. 7, no. 2, pp. 2920–2928, 2020.
- [10] A. A. Jaelani, F. Y. Supratman, and N. Ibrahim, "Perancangan Aplikasi untuk Klasifikasi Klon Daun The Seri Gembung (GMB) Menggunakan Algoritma Convolutional Neural Network" vol. 7, no. 2, pp. 2920–2928, 2020.
- [11] Nwankpa, Chigozie, et al. "Activation functions: Comparison of trends in practice and research for deep learning." *arXiv preprint arXiv:1811.03378* (2018).
- [12] Bayot, Roy, and Teresa Gonçalves. "A survey on object classification using convolutional neural networks." (2015).

- [13] Wilson, D. & Martinez, Tony. 2001. The need for small learning rates on large problems. 1. 115 - 119 vol.1. 10.1109/IJCNN.2001.939002.
- [14] Patel, Isha, and Sanskruti Patel. "Flower identification and classification using computer vision and machine learning techniques." *International Journal of Engineering and Advanced Technology (IJEAT)* 8.6 (2019).
- [15] NarasingaRao, M. R., et al. "A survey on prevention of overfitting in convolution neural networks using machine learning techniques." *International Journal of Engineering and Technology (UAE)* 7.2.32 (2018): 177-180.
- [16] Ren, Qiubing, Mingchao Li, and Shuai Han. "Tectonic discrimination of olivine in basalt using data mining techniques based on major elements: a comparative study from multiple perspectives." *Big Earth Data* 3.1 (2019): 8-25.
- [17] Tabian, Iuliana, Hailing Fu, and Zahra Sharif Khodaei. "A convolutional neural network for impact detection and characterization of complex composite structures." *Sensors* 19.22 (2019): 4933.