



Implementasi Convolutional Neural Network pada Klasifikasi Citra Daun Tanaman Hias

Betty Suswati^{1*}

¹Program Studi Informatika, Universitas Gunadarma, Indonesia.

Artikel Info

Kata Kunci:

Citra;
CNN;
Daun;
Klasifikasi;
Tanaman Hias.

Keywords:

Image;
CNN;
Daun;
Classification;
Ornamental Plants.

Riwayat Artikel:

Submitted: 17 Mei 2024

Accepted: 5 Juni 2024

Published: 26 Juni 2024

Abstrak: Tanaman hias yang diminati adalah memiliki variasi genetik yang tinggi seperti bentuk, tekstur daun dan warna bunga. Variasi jenis spesies tanaman hias mengakibatkan kesulitan dalam mengenali jenis dari tanaman ini. Penelitian ini mengusulkan model klasifikasi menggunakan citra daun dalam melakukan klasifikasi daun kedalam 7 kelas yaitu: Aglaonema Big Roy, Aglaonema Dona Carmen, Aglaonema Snow White, Philodenron Mercy, Philodenron Plowmanii, Syngonium Alussion dan Syngonium Pink Spot. Tahapan penelitian dimulai dengan mengidentifikasi fitur citra daun yg digunakan untuk membentuk model klasifikasi dengan menentukan parameter model klasifikasi CNN berdasarkan epochs, batch size, dan split data. Penelitian ini menggunakan rasio data pelatihan dan data pengujian 8:2. Penelitian ini juga membentuk ulang *feature map* yang dihasilkan pada proses *pooling* menjadi vektor input pada layer *fully connected* sehingga model dapat mengklasifikasikan citra daun dengan *loss* yang lebih rendah. Hasil pengujian dengan 50 epoch menunjukkan semakin besar *epoch* yang digunakan maka nilai *loss* yang dihasilkan pada pelatihan data semakin rendah. Model klasifikasi berhasil melakukan klasifikasi dengan akurasi pada data uji mencapai 100%. Hasil penelitian ini diharapkan dapat mempermudah pengguna khususnya penggemar tanaman hias untuk mengenali jenis dari tanaman hias berdasarkan daunnya.

Abstract: Ornamental plants that are in demand have high genetic variations such as shape, leaf texture and flower color. Variations in ornamental plant species result in difficulties in recognizing the type of this plant. This research proposes a classification model using leaf images to classify leaves into 7 classes, namely: Aglaonema Big Roy, Aglaonema Dona Carmen, Aglaonema Snow White, Philodenron Mercy, Philodenron Plowmanii, Syngonium Alussion and Syngonium Pink Spot. The research stage begins by identifying leaf image features that are used to form a classification model by determining the parameters of the CNN classification model based on epochs, batch size, and split data. This research uses a ratio of training data to testing data of 8:2. This research also reshapes the feature map produced in the pooling process into an input vector for the fully connected layer so that the model can classify leaf images with lower loss. The test results with 50 epochs show that the larger the epochs used. The classification model succeeded in carrying out classification with accuracy on test data reaching 100%. It is hoped that the results of this research will make it easier for users, especially ornamental plant fans, to recognize types of ornamental plants based on their leaves.

Corresponding Author:

Betty Suswati

Email: betty_s@staff.gunadarma.ac.id

PENDAHULUAN

Permintaan tanaman hias yang semakin tinggi (Salachna, 2022) membuat masyarakat ingin mengetahui lebih dalam mengenai tanaman hias untuk dijadikan ladang bisnis maupun koleksi (Olewnicki et al., 2019) karena bentuk daunnya unik. Hal ini membuat pecinta tanaman hias, ingin mengetahui lebih dalam mengenai jenis dari tanaman hias yang dikoleksi (Suminah et al., 2021). Para petani dan masyarakat pecinta tanaman hias sendiri terkadang tidak dapat membedakan jenis tanaman hias dikarenakan terdapat banyak variasi dari tanaman hias dan bentuk dari tanaman yang relatif sama(Rambey & Permana, 2022). Identifikasi pada sebuah tanaman hias dapat dilakukan dengan mengambil sebuah sampel yang akan diklasifikasi dengan melihat kemiripan yang ada (Mariska Putri et al., 2021), salah satunya menggunakan karakteristik pada bagian daun (Minarno et al., 2022). Daun pada tanaman hias memiliki sebuah karakteristik tersendiri, sehingga dapat diambil beberapa fitur yang akan digunakan untuk proses klasifikasi, seperti bentuk, tekstur, dan warna dari daun tersebut (Syahrir & Eri Prasetyo Wibowo, 2021).

Salah satu metode yang dapat digunakan untuk melakukan identifikasi dengan citra daun adalah *Convolutional Neural Network* (CNN). CNN merupakan salah satu jenis neural network yang dapat digunakan untuk mendekripsi dan mengenali objek dari sebuah citra dengan melatih beberapa fitur ciri dari objek yang akan diklasifikasikan(Tugrul et al., 2022). Cara kerja model CNN dalam melakukan klasifikasi yaitu dengan melakukan pelatihan (*training*) (Muhammad & Wibowo, 2021) pada citra daun sebagai citra masukan dari tanaman hias yang memiliki karakteristik sama, sehingga dapat diklasifikasikan kedalam satu genus dengan berbagai variasi (ADAK, 2020).

Penelitian terkait klasifikasi jenis tanaman hias berdasarkan daun menggunakan CNN sudah dilakukan oleh beberapa peneliti terdahulu. Penelitian (Jessar et al., 2021) melakukan klasifikasi terhadap genus anggrek dengan mengimplementasikan model CNN menjadi beberapa *target class* antara lain : genus Cattleya, Dendrobium, Oncidium, Phalaenopsis dan Vanda. Penelitian ini melakukan augmentasi untuk mengatasi imbalanced dataset yang menghasilkan 800 citra/genus yang digunakan sebagai data pelatihan dan 500 citra/genus yang digunakan sebagai data test. Penelitian(Jessar et al., 2021) juga melakukan resizing untuk menyesuaikan dengan *input shape* pada arsitektur CNN. Model terbaik dengan skor akurasi pada data pengujian menghasilkan *F1-Score* tertinggi sebesar 98% dari genus Dendrobium. Penelitian (Pratiwi et al., 2021) dengan mengimplementasikan model CNN dilakukan untuk mengklasifikasikan bunga menjadi 5 target class antara lain : Mawar, Matahari, Kembang Sepatu, Telang, dan Cornflower. Implementasi model CNN pada *smartphone* berbasis android ini menghasilkan akurasi sejumlah 99,30%. Penelitian (Muhammad & Wibowo, 2021) melakukan klasifikasi terhadap tanaman aglaonema dengan ciri khas yang terletak pada daun dengan bentuk, warna dan corak yang beraneka ragam. Penelitian ini menggunakan citra dengan 5 jenis daun aglaonema, dengan sejumlah 100 citra/jenis. Klasifikasi pada penelitian ini menggunakan model CNN yang dipakai dalam penelitian ini adalah model Alexnet dan penggunaan *optimizer* serta nilai epoch yang berbeda-beda. Akurasi data pengujian pada penelitian ini menghasilkan nilai akurasi sejumlah 96% dari 50 citra yang diuji.

Penelitian ini akan melakukan klasifikasi tanaman hias menggunakan fitur pada citra daun dengan 7 *target class* yaitu : Aglaonema Big Roy, Aglaonema Dona Carmen, Aglaonema Snow White, Philodendron Mercy, Philodenron Plowmanii, Syngonium Alussion dan Syngonium Pink Spot. Klasifikasi pada penelitian ini berbeda pada penelitian terdahulu dimana penelitian ini menggunakan model CNN dengan lima lapisan layer konvolusi dan *max pooling* untuk menghasilkan fitur citra daun yang lebih efektif. Hasil dari proses konvolusi dan *pooling* ini dilakukan *flatten* untuk mengubah *feature map* hasil dari *pooling* menjadi bentuk vektor, kemudian melakukan *deployment* hasil model ke dalam aplikasi android menggunakan TensorFlow Lite. Hasil pengujian menunjukkan akurasi model klasifikasi dengan CNN pada tanaman hias mencapai 100% pada data pengujian. Hasil penelitian ini diharapkan dapat memudahkan para pecinta tanaman hias untuk mengenali jenis tanaman hias yang ingin dibudidaya.

METODE

Pada penelitian ini terdapat beberapa tahap penelitian dimulai dari pengumpulan dataset, tahap penentuan parameter yang sesuai untuk dimasukkan kedalam model klasifikasi dan tahap akhir pembentukan model klasifikasi menggunakan citra daun sebagai masukan untuk mengklasifikasikan 7 *target class* tanaman hias.

Dataset Citra Daun Tanaman Hias

Penelitian ini menggunakan dataset sejumlah 422 citra daun dengan rincian jumlah data yang digunakan adalah 60 citra *Aglaonema Big Roy*, 60 citra *Aglaonema Dona Carmen*, 60 citra *Aglaonema Snow White*, 60 citra *Philodenron Mercy*, 62 citra *Philodenron Plowmanii*, 60 citra *Syngonium Alussion*, dan 60 citra *Syngonium Pink Spot*. Tabel 1 merupakan hasil pembagian dataset yang berjumlah 422 citra daun tanaman hias dengan rasio 8:2.

Tabel 1. Pembagian Dataset Citra Daun Tanaman Hias

No	Target Class	Jumlah Dataset	Split Rasio
1	Aglaonema Big Roy	60	
2	Aglaonema Dona Carmen	60	
3	Aglaonema Snow White	60	
4	Philodenron Mercy	62	8:2
5	Philodenron Plowmanii	60	
6	Syngonium Alussion	60	
7	Syngonium Pink Spot	60	

Contoh masing-masing citra yang mewakili target class tersebut dapat dilihat pada Gambar 1.



Gambar 1. Citra Daun Tanaman Hias

Penentuan Parameter Neural Network

Penelitian ini melakukan pembagian data dengan rasio 8:2 untuk data pelatihan (*training dataset*) dan data pengujian (*testing dataset*). Rasio 8:2 pada penelitian ini digunakan dengan melihat bahwa loss pada rasio ini lebih kecil dibandingkan jika split data dilakukan pada rasio lain (misal: 6:4, 7:3 atau 9:1). Parameter yang digunakan dalam membentuk model untuk mengklasifikasikan tanaman hias berdasarkan citra daun terdiri dari *epochs*, *batch_size*, serta *split data*. *Epochs* merupakan jumlah lintasan

dataset pelatihan yang akan diselesaikan, dimana pada penelitian ini menggunakan *epochs* sebesar 40. Parameter *batch_size* merupakan jumlah sampel data yang akan disebar kedalam *neural network* sebesar 7 *class*.

Pembuatan Model Klasifikasi dengan Arsitektur CNN

Model yang digunakan untuk mengklasifikasi jenis tanamanan hias menggunakan arsitektur CNN dengan rancangan arsitektur dapat dilihat pada Tabel 2.

Tabel 2. Arsitektur CNN Model Klasifikasi

Layer (type)	Output Shape	Parameter
sequential (Sequential)	(32, 256, 256, 3)	0
sequential_1 (Sequential)	(None, 256, 256, 3)	0
conv2d (Conv2D)	(32, 254, 254, 32)	896
max_pooling2d (MaxPooling2D)	(32, 127, 127, 32)	0
conv2d_1 (Conv2D)	(32, 125, 125, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(32, 62, 62, 64)	0
conv2d_2 (Conv2D)	(32, 60, 60, 64)	36928
max_pooling2d_2 (MaxPooling2D)	(32, 30, 30, 64)	0
conv2d_3 (Conv2D)	(32, 28, 28, 64)	36928
max_pooling2d_3 (MaxPooling2D)	(32, 14, 14, 64)	0
conv2d_4 (Conv2D)	(32, 12, 12, 64)	36928
max_pooling2d_4 (MaxPooling2D)	(32, 6, 6, 64)	0
conv2d_5 (Conv2D)	(32, 4, 4, 64)	36928
max_pooling2d_5 (MaxPooling2D)	(32, 2, 2, 64)	0
flatten (Flatten)	(32, 256)	0
dense (Dense)	(32, 64)	16448
dense_1 (Dense)	(32, 7)	455

Total params: 184,007
Trainable params: 184,007
Non-trainable params: 0

Pada Tabel 2 merupakan arsitektur CNN dari metode *Deep Learning* yang diusulkan pada penelitian ini, dapat dilihat pada arsitektur ini menggunakan lima lapisan layer konvolusi. Pembuatan

arsitektur CNN pada penelitian ini terdiri dari 2 tahapan, yaitu tahap *feature learning* dan *classification* (Fitrianingsih & Rodiah, 2021). Citra daun pada model klasifikasi dengan CNN ini menggunakan citra berukuran 256x256x3, dimana 256x256 merupakan ukuran piksel citra tersebut, dan 3 merupakan citra yang memiliki 3 channel, yaitu *Red*, *Green*, *Blue* (RGB). Citra daun akan diproses terlebih dahulu oleh proses konvolusi dan proses *pooling* pada *feature learning*. Penelitian ini menggunakan jumlah proses konvolusi terdiri dari 5 lapisan dengan pembagian jumlah filter pada setiap lapisan 64 filter. Proses *pooling* memiliki 6 lapisan dengan fungsi aktivasi ReLU. Pada pembentukan arsitektur ini juga digunakan *flatten* untuk mengubah *feature map* hasil *pooling layer* kedalam bentuk vektor (Wu & Zhou, 2021). Vektor ini yang akan digunakan sebagai masukan pada tahap *fully connected layer*. Arsitektur CNN untuk model klasifikasi pada penelitian ini melakukan penambahan *fully connected layer* dan *dropout layer* untuk mencegah terjadinya *overfitting* (Kant & Singh, 2022) sehingga model dapat mengklasifikasikan citra daun pada tanaman hias sesuai *target class* dengan akurasi tinggi. Pada *layer* konvolusi Tabel 2, parameter yang dihasilkan dapat dihitung menggunakan persamaan (Ahmad et al., 2022) :

$$P = (K^2 \times C \times N) + B \text{ dengan } B = N \quad (1)$$

Variabel P merupakan jumlah *parameters* pada *layer* konvolusi, B adalah jumlah *bias* pada layer konvolusi, K merupakan ukuran *filter* yang digunakan, C jumlah *channel* dari citra yang diinput dan N merupakan jumlah *filter* yang digunakan. Perhitungan parameter pada *layer* konvolusi pertama dapat dihitung dengan persamaan (1), dimana ukuran *filter* yang digunakan berukuran 3x3, dengan *channel* dari citra yang diinput menggunakan 3 *channel* (RGB), dan jumlah *filter* yang digunakan adalah 32. Berdasarkan perhitungan menggunakan persamaan (1), didapatkan hasil $P = (3^2 \times 3 \times 32) + 32 = 896$.

Proses *layer* konvolusi selanjutnya dilakukan untuk menghitung parameter yang dihasilkan. Perhitungan ini dapat dilakukan dengan menggunakan persamaan yang sama, dimana nilai pada parameter C diganti menjadi nilai dengan parameter N *filter* yang digunakan pada *layer* konvolusi sebelumnya, menggunakan persamaan (Ahmad et al., 2022) :

$$P = (K^2 \times N_0 \times N) + B \text{ dengan } B = N \quad (2)$$

Persamaan (2) digunakan untuk menentukan P yang merupakan jumlah *parameters* pada *layer* konvolusi, B sebagai jumlah *bias* pada *layer* konvolusi, K merupakan ukuran *filter* yang digunakan, N_0 sebagai jumlah *filter* pada *layer* konvolusi sebelumnya dan parameter N yang merupakan jumlah *filter* yang digunakan. Perhitungan parameter pada *layer* konvolusi kedua, dengan ukuran *filter* yang digunakan berukuran 3x3, *filter* yang digunakan pada *layer* konvolusi sebelumnya adalah 64, dan jumlah *filter* yang digunakan pada *layer* konvolusi selanjutnya adalah 64. Perhitungan parameter pada proses konvolusi kedua dan seterusnya, dapat menggunakan rumus yang sama dengan rumus proses konvolusi kedua, sehingga *parameter* yang didapatkan yaitu $W = (3^2 \times 32 \times 64) + 64 = 18496$ (*konvolusi kedua*).

Perhitungan pada proses perubahan yang terjadi ketika citra diinput kedalam model CNN pada *layer* konvolusi, dapat dihitung menggunakan Persamaan (3) (Ahmad et al., 2022):

$$O = \left(\frac{I - K + 2P}{S} \right) + 1 \quad (3)$$

O merupakan ukuran citra *output*, I merupakan ukuran citra *input*, K merupakan ukuran *filter* yang digunakan pada *layer* konvolusi, S adalah *stride* yang digunakan pada *layer* konvolusi dan P merupakan *padding*. Citra yang diinput kedalam model CNN, akan mengalami perubahan ukuran, dimana ukuran awal 254x254 dengan menggunakan *filter* berukuran 3x3, *stride* berjumlah 1, dan tanpa adanya *padding*. Perubahan ukuran yang terjadi pada citra, dihitung dengan menggunakan Persamaan (3), sehingga didapatkan hasil perubahan citra pada *layer* konvolusi pertama menjadi berukuran 127 x 127 piksel. Perhitungan pada *layer* konvolusi dan *layer max pooling* selanjutnya, dapat dihitung dengan

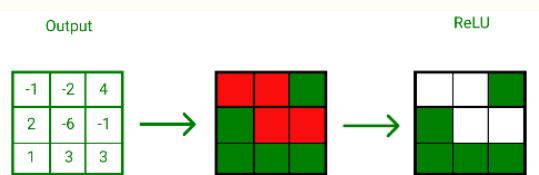
menggunakan Persamaan (3) sehingga menghasilkan *output* citra dengan piksel yang kecil. Pada perhitungan pada proses *flatten* dalam membentuk model klasifikasi, merupakan hasil perkalian antara citra *output* beserta dengan *layer pooling* paling terakhir, dimana citra yang dihasilkan berukuran 4x4 dengan *filter* yang digunakan berjumlah 64, sehingga hasil dari perkalian tersebut menghasilkan 1024 *flatten*.

Perhitungan pada proses *dense* pada model klasifikasi didapatkan dari hasil *flatten* yang dikalikan dengan jumlah unit yang digunakan pada proses *dense* dan ditambahkan dengan *bias* *dense* tersebut menghasilkan 16448. Hasil perhitungan untuk proses *dense* kedua, berisi kelas untuk klasifikasi, dimana jenis daun pada Tanaman Hias yang digunakan pada penelitian ini terdiri dari 7 jenis, maka dengan menggunakan perhitungan yang sama seperti *dense* pertama, didapatkan hasil untuk *dense* kedua adalah 455. Total dari keseluruhan parameter yang digunakan pada penelitian ini adalah 184,007 yang dilatih untuk melakukan klasifikasi dari 7 *target class* citra daun tanaman hias, yang terdiri dari : Aglaonema Big Roy, Aglaonema Dona Carmen, Aglaonema Snow White, Philodenron Mercy, Philodenron Plowmanii, Syngonium Alussion dan Syngonium Pink Spot.

Model Klasifikasi Citra Daun Tanaman Hias

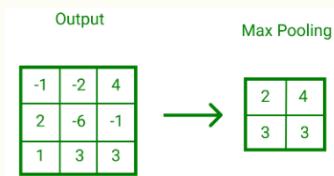
Proses identifikasi citra daun tanaman hias dilakukan dengan menggunakan model yang telah dibuat. Pada saat model melakukan proses *training* dan *testing*, model dipanggil kembali untuk melakukan penentuan hasil klasifikasi. Hasil klasifikasi akan menentukan citra masukan termasuk kedalam golongan jenis citra berdasarkan 7 *target class* dengan langkah sebagai berikut:

1. Melakukan proses konvolusi pertama dilakukan dengan hasil perkalian menggunakan filter berukuran 3x3 dan citra input berukuran 256x256 piksel dengan 3 *channel* warna RGB. Layer konvolusi berjumlah 64 filter dan padding yang digunakan untuk memproses citra masukan tanpa adanya penambahan *padding*. Hal ini dilakukan untuk menghindari terjadinya perubahan bentuk dari citra input.
2. Melakukan konversi nilai negatif menjadi 0 menggunakan fungsi aktivasi *Rectified Linear Unit* (ReLU). Pada tahap ini dilakukan proses *pooling* yang bertujuan untuk mengurangi ukuran matriks menggunakan fungsi *max pooling*. Fungsi *max pooling* akan mengambil nilai terbesar dari proses konvolusi dengan ukuran 2x2. Ukuran citra yang dihasilkan dari proses konvolusi pertama ini berubah dari 256x256 piksel menjadi 127x127 piksel. *Pooling layer* pada model klasifikasi penelitian ini digunakan untuk mengurangi ukuran spasial dari fitur konvolusi sehingga menurunkan komputasi saat model melakukan klasifikasi. Proses ini menghasilkan citra berukuran 127x127 piksel yang merupakan melalui pengurangan dimensi *feature map* dari ukuran citra asal 256x256 piksel sehingga komputasi model dalam melakukan klasifikasi 7 *target class* citra daun menjadi lebih rendah. Max pooling mengembalikan nilai. Ilustrasi pada proses konvolusi sampai dengan proses *pooling* dapat dilihat pada Gambar 2.



Gambar 2. Ilustrasi Proses Konversi Nilai Negatif

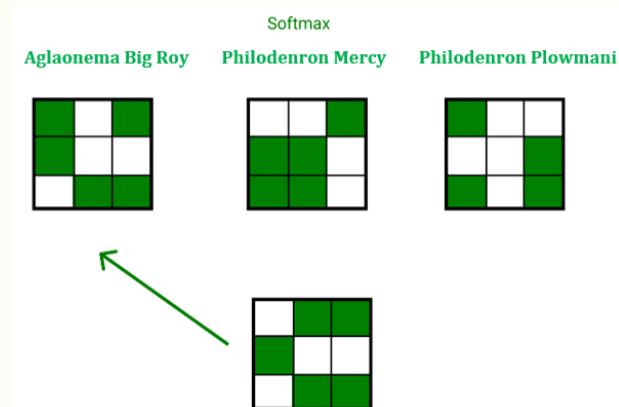
Seperti dapat dilihat pada Gambar 2, hasil dari proses konvolusi yang menghasilkan nilai negatif yang ditandai dengan kotak warna merah. Penggunaan fungsi aktivasi ReLU menghilangkan nilai negatif menjadi 0 yang ditandai dengan warna putih, untuk kemudian dilakukan proses selanjutnya yaitu pooling seperti dapat dilihat pada Gambar 3.



Gambar 3. Ilustrasi Proses Max Pooling

Max pooling yang digunakan pada penelitian ini berukuran 2x2 dengan melakukan pergeseran (*stride*) sebanyak 2. Fungsi ini pada layer konvolusi akan mengambil nilai terbesar, sehingga bentuk citra daun yang dimasukkan sebelumnya akan mengalami perubahan ukuran menjadi lebih kecil. Proses ini akan terus berlangsung sesuai dengan jumlah layer konvolusi pada model klasifikasi yang dibentuk.

3. Melakukan proses konvolusi kedua menggunakan konfigurasi yang sama pada konvolusi pertama, dengan masukan citra berukuran 127 x 127 piksel yang dikalikan dengan filter berukuran 3x3 dengan jumlah 64 filter dan padding. Proses konvolusi terus dilakukan sampai pada konvolusi ke 5, dimana hasil dari citra konvolusi keempat yang berukuran 12x12 piksel akan berubah menjadi 4x4 piksel.
4. Membentuk ulang *feature map* yang dihasilkan pada proses *pooling* terakhir menjadi sebuah bentuk vektor yang akan diinput pada *fully connected layer (flatten)* untuk dilakukan klasifikasi dari citra daun yang dimasukkan.
5. Tahap akhir pembentukan model klasifikasi adalah menggunakan dense sebesar 2 unit yang merupakan jumlah dari kelas yang ada dan fungsi aktivasi *softmax* yang digunakan untuk memprediksi probabilitas pada setiap kelas, seperti dapat dilihat pada ilustrasi Gambar 4.



Gambar 4. Ilustrasi Proses Max Pooling

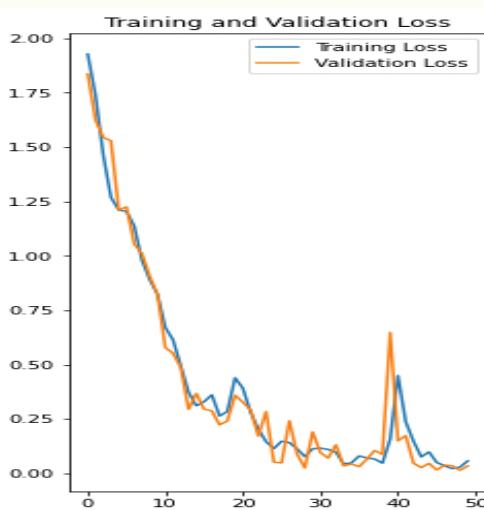
HASIL DAN PEMBAHASAN

Klasifikasi dengan sejumlah 422 citra daun, dilakukan split data dengan rasio 8:2, 80% untuk data *training* yaitu sejumlah 338 citra daun dan 20% untuk data *testing* yaitu sejumlah 84 citra daun. Pada tahap klasifikasi dilakukan pelatihan data pada citra tanaman hias dengan 50 *epochs* yang mana akan dilakukan sebanyak 50 kali algoritma pembelajaran akan bekerja mengolah seluruh dataset *training*. Tabel 3 menunjukkan hasil dari pelatihan data pada citra tanaman hias dengan 10 sampel yang diambil secara berurutan.

Tabel 3. Hasil Fit Model Klasifikasi

Epoch	Data Training		Data Testing	
	Loss	Acc	Val Loss	Val Acc
1	1.9274	0.1871	1.8359	0.3125
2	1.2041	0.5215	1.2245	0.3438
3	0.6710	0.7454	0.5783	0.8438
4	0.3289	0.8896	0.2948	0.8750
5	0.3913	0.8681	0.3271	0.8750
6	0.1476	0.9540	0.0479	1.0000
7	0.1154	0.9601	0.0952	0.9375
8	0.0798	0.9724	0.0303	1.0000
9	0.4493	0.8313	0.1492	0.9062
10	0.0572	0.9785	0.0339	1.0000

Pada Tabel 3 dapat dilihat pada data *training* bahwa *epoch* pertama menunjukkan hasil yang kurang baik dengan nilai *loss* 1,9274 dengan akurasi yang sangat kecil, yaitu 0.1871, kemudian pada *epochs* kedua memiliki nilai *loss* 1,2041 dan akurasi sebesar 0.5215, dan seterusnya. Hal ini menunjukkan, semakin besar *epoch* yang digunakan maka nilai *loss* yang dihasilkan pada pelatihan data semakin rendah. Pada nilai akurasi menunjukkan korelasi positif, artinya penggunaan jumlah *epoch* yang besar dapat menghasilkan nilai akurasi yang tinggi terhadap data *training*(Bhelkar, 2022). Seperti dapat dilihat pada Gambar 5, hal ini berbanding terbalik dengan nilai pada loss.



Gambar 5. Grafik Loss pada *Traning* dan *Testing* Dataset

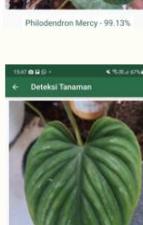
Nilai *loss* pada Gambar 5 merupakan korelasi negatif, maka semakin tinggi jumlah *epoch* yang digunakan maka nilai *loss* terhadap data *training* dapat menjadi rendah. Salah satu cara untuk

memperoleh nilai *loss* yang rendah, adalah dengan menambah jumlah *epoch* yang akan digunakan untuk data *training*.

Hasil Klasifikasi Citra Daun Tanaman Hias

Tabel 4 merupakan hasil klasifikasi citra daun pada tanaman hias yang diusulkan pada penelitian ini. Terdapat 7 *class* dengan masing-masing jenis yang menunjukkan keadaan sebenarnya (*citra groundtruth*) dan citra prediksi. Model terlihat berhasil memprediksi jenis tanaman hias dengan benar sesuai dengan citra asli terlihat dari hasil persentase akurasi yang mencapai hampir 100%.

Tabel 4. Hasil Klasifikasi Citra Daun Tanaman Hias

Citra <i>Groundtruth</i>	Citra Deteksi	Hasil
Aglaonema Big Roy	Aglaonema Big Roy	 Aglaonema Big Roy - 100.00%
Aglaonema Dona Carmen	Aglaonema Dona Carmen	 Aglaonema Dona Carmen - 98.42%
Aglaonema Snow White	Aglaonema Snow White	 Aglaonema Snow White - 97.03%
Philodenron Mercy	Philodenron Mercy	 Philodenron Mercy - 99.13%
Philodenron Plowmanii	Philodenron Plowmanii	 Philodenron Plowmanii - 99.99%

Citra <i>Groundtruth</i>	Citra Deteksi	Hasil
Syngonium Alussion	Syngonium Alussion	 Syngonium Mango Alussion - 91.62%
Syngonium Pink Spot	Syngonium Pink Spot	 Syngonium Pink Spot - 99.95%

Selanjutnya model yang telah dibuat disimpan ke dalam file dengan ekstensi h5 agar dapat dilakukan proses prediksi tanpa harus melakukan *training* model kembali. Model yang telah disimpan dalam file h5 hanya dapat dijalankan pada komputer. Proses *deployment* ke dalam aplikasi android, maka model harus diubah ke dalam bentuk *tensorflow lite* dengan ekstensi tflite, menghasilkan tampilan seperti dapat dilihat pada Gambar 6.



Gambar 6. Hasil Tampilan pada Smartphone

KESIMPULAN

Berdasarkan hasil penelitian dengan mengklasifikasikan citra daun tanaman hias menggunakan CNN dengan 7 *target class* menggunakan 5 *convolutional layer* dengan aktivasi ReLu, *max pooling*, 1 flatten layer, dan 2 dense layer. Terdapat dense yang menggunakan aktivasi ReLu dan dense yang menggunakan aktivasi softmax bertujuan untuk mengklasifikasi 7 kelas tanaman hias. Tingkat akurasi model klasifikasi mencapai 100% pada dataset pengujian, sehingga dapat disimpulkan bahwa model klasifikasi jenis tanaman hias ini termasuk kedalam *excellent classification*. Setelah melakukan *deployment*

hasil model ke dalam aplikasi android menggunakan *TensorFlow Lite*, fitur deteksi tanaman dapat berjalan dengan baik yang dapat bermanfaat bagi pengguna untuk mengetahui jenis tanaman hias melalui aplikasi android. Pengembangan penelitian lebih lanjut dapat dilakukan dengan menambahkan lebih banyak jenis tanaman agar lebih banyak tanaman yang dapat dideteksi dan akan semakin bermanfaat karena tanaman hias memiliki banyak variasi. Menambahkan banyak dataset foto pada setiap kelasnya agar program lebih baik dalam mengenali sebuah citra dan pada aplikasi di *smartphone* dapat ditambahkan fitur informasi detail tanaman.

DAFTAR PUSTAKA

- Adak, M. F. (2020). Identification of Plant Species by Deep Learning and Providing as A Mobile Application. *Sakarya University Journal of Computer and Information Sciences*, 3(3), 231-237. <https://doi.org/10.35377/saucis.03.03.773465>
- Ahmad, M. U., Ashiq, S., Badshah, G., Khan, A. H., & Hussain, M. (2022). Feature Extraction of Plant Leaf Using Deep Learning. *Complexity*, 2022. <https://doi.org/10.1155/2022/6976112>
- Bhelkar, N. S. (2022). *Identification and classification of medicinal plants using leaf with deep convolutional neural networks*. 6(May), 11596–11605.
- Fitrianingsih, F., & Rodiah, R. (2021). Klasifikasi Jenis Citra Daun Mangga Menggunakan Convolutional Neural Network. *Jurnal Ilmiah Teknologi dan Rekayasa*, 25(3), 223-238. <http://dx.doi.org/10.35760/tr.2020.v25i3.3519>
- Jessar, H. F., Toto Wibowo, A., & Rachmawati, E. (2021). Klasifikasi Genus Tanaman Sukulen Menggunakan Convolutional Neural Network. *Proceeding of Engineering*, 8(2), 3180–3195.
- Kant, J., & Singh, P. (2022). *Plant Leaf Classification using Convolutional Neural Network*. June. <https://doi.org/10.2174/2666255813999200904162029>
- Mariska Putri, D., Indrawan Junaedi, D., & Hendrian. (2021). Ornamental Plant 's Potentials of Indonesian Native Rubiaceae Collected in Cibodas Botanical Garden. *International Journal of Agricultural System*, 9(1), 1-9. <https://doi.org/10.20956/ijas.v9i1.2718>
- Minarno, A. E., Ibrahim, Z., Nur, A., Hasanuddin, M. Y., Diah, N. M., & Munarko, Y. (2022). Leaf Based Plant Species Classification Using Deep Convolutional Neural Network. *2022 10th International Conference on Information and Communication Technology, ICoICT 2022*, 99–104. <https://doi.org/10.1109/ICoICT55009.2022.9914851>
- Muhammad, S., & Wibowo, A. T. (2021). Klasifikasi Tanaman Aglaonema Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network (Cnn. *E-Proceeding of Engineering*, 8(5), 10621–10636.
- Olewnicki, D., Jabłońska, L., & Dudek, H. (2019). The demand for ornamental plants in poland after its integration into the eu: A quantitative approach. *Bulgarian Journal of Agricultural Science*, 25(5), 932–943.
- Pratiwi, H. A., Cahyanti, M., & Lamsani, M. (2021). Implementasi Deep Learning Flower Scanner Menggunakan Metode Convolutional Neural Network. *Sebatik*, 25(1), 124–130. <https://doi.org/10.46984/sebatik.v25i1.1297>

- Rambey, R., & Permana, J. (2022). Identification of ornamental plant species in the Martelu Purba Nature Reserve, North Sumatra. *IOP Conference Series: Earth and Environmental Science*, 1115(1), 2–7. <https://doi.org/10.1088/1755-1315/1115/1/012024>
- Salachna, P. (2022). Trends in Ornamental Plant Production. *Horticulturae*, 8(5), 10–12. <https://doi.org/10.3390/horticulturae8050413>
- Suminah, Suwarto, Sugihardjo, Anantanyu, S., & Padmaningrum, D. (2021). Self reliance of ornamental plants agribusiness actors during the Covid pandemic in Surakarta. *IOP Conference Series: Earth and Environmental Science*, 905(1), 1–9. <https://doi.org/10.1088/1755-1315/905/1/012062>
- Syahrir, R. Z., & Eri Prasetyo Wibowo. (2021). Classification of Leaves Based on the Shape of Leaves Using Convolutional Neural Network Methods. *IAIC Transactions on Sustainable Digital Innovation (ITSDI)*, 3(1), 1–7. <https://doi.org/10.34306/itsdi.v3i1.491>
- Tugrul, B., Elfatimi, E., & Eryigit, R. (2022). Convolutional Neural Networks in Detection of Plant Leaf Diseases: A Review. *Agriculture (Switzerland)*, 12(8). <https://doi.org/10.3390/agriculture12081192>
- Wu, P., & Zhou, Q. (2021). Leaf Classification Based on Convolutional Neural Network. 1820, 1–6. <https://doi.org/10.1088/1742-6596/1820/1/012161>