

## Klasifikasi Bunga Anggrek untuk Genus *Grammatophyllum* Menggunakan Metode Convolutional Neural Network(CNN)

Puspitasari<sup>1</sup>, Agung Toto Wibowo<sup>2</sup>

<sup>1,2</sup> Universitas Telkom, Bandung

<sup>1</sup>ppitasharry@students.telkomuniversity.ac.id, <sup>2</sup>agungtoto@telkomuniversity.ac.id

### Abstrak

Bunga anggrek merupakan salah satu jenis tanaman berbunga yang memiliki banyak genus. *Grammatophyllum* termasuk kedalam salah satu genus bunga anggrek, pada genus ini terdapat 13 spesies anggrek. Bagi manusia yang memiliki pengetahuan akan bunga anggrek akan mudah untuk mengklasifikasikan spesies bunga anggrek tersebut, namun bagi komputer pengklasifikasian bunga merupakan tugas yang cukup kompleks. Dengan adanya sistem klasifikasi bunga anggrek dapat membantu seseorang yang belum memiliki pengetahuan tentang bunga anggrek untuk mengenali spesies bunga anggrek genus *grammatophyllum*. Metode yang banyak digunakan dalam klasifikasi citra adalah *Convolutional Neural Network* (CNN), Pada penelitian ini dilakukan klasifikasi bunga anggrek untuk genus *grammatophyllum* dengan menggunakan metode CNN dengan mengimplementasikan arsitektur AlexNet dan custom arsitektur CNN. Data bunga anggrek *grammatophyllum* ini dikumpulkan secara *primary* dan *secondary*. Performansi terbaik pada arsitektur Alexnet didapat dengan mengimplementasikan dropout 30% yaitu precision 79.76%, recall 83.33%, f score 84.10% dan akurasi sebesar 86.07%. Sedangkan untuk custom arsitektur CNN didapat dengan hasil implementasi dropout 20% yaitu precision 93.75%, recall 91.66%, f score 91.74% dan akurasi sebesar 91.42%.

Kata kunci : bunga anggrek, klasifikasi, CNN, genus *grammatophyllum*, arsitektur CNN.

---

### Abstract

Orchid flowers are one type of flowering plant that has many genera. *Grammatophyllum* belongs to one genus of orchids, in this genus there are 13 species of orchids. For humans who have knowledge of orchids, it will be easy to classify the species of orchids, but for computers, classifying flowers is a fairly complex task. With the orchid flower classification system, it can help someone who does not have knowledge of orchids to identify species of orchids of the *grammatophyllum* genus. The method that is widely used in image classification is the *Convolutional Neural Network* (CNN). In this study, the classification of orchids for the *grammatophyllum* genus was carried out using the CNN method by implementing AlexNet architecture and custom CNN architecture. This *grammatophyllum* orchid flower data was collected *primary* and *secondary*. The best performance on the Alexnet architecture is obtained by implementing a dropout of 30%, namely 79.76% precision, 83.33% recall, 84.10% f score and 86.07% accuracy. As for the custom CNN architecture, the results of the implementation of a dropout of 20% are 93.75% precision, 91.66% recall, 91.74% f score and 91.42% accuracy.

Keywords : orchid flowers, classification, CNN, genus *grammatophyllum*, CNN architecture

---

## 1. Pendahuluan

### Latar Belakang

Bunga anggrek merupakan salah satu jenis tanaman berbunga yang memiliki banyak spesies. Terdapat sekitar 26.000 spesies bunga anggrek yang ada di seluruh dunia, di Indonesia sendiri ditemukan sekitar 5.000-6.000 spesies. *Grammatophyllum* termasuk kedalam salah satu genus bunga anggrek, pada genus ini terdapat spesies *Tiger orchid*, *grammatophyllum rumphianum*, *grammatophyllum ravanii*, *grammatophyllum measuresianum* dan masih banyak lagi.

Bagi manusia yang memiliki pengetahuan akan bunga anggrek akan mudah untuk mengklasifikasikan spesies bunga anggrek tersebut, namun bagi komputer pengklasifikasian bunga merupakan tugas yang cukup kompleks dan memerlukan perancangan sistem yang baik. Akan tetapi pengklasifikasian manual merupakan pekerjaan yang melelahkan dan memerlukan waktu yang banyak. Sistem klasifikasi oleh komputer akan membantu dalam pengenalan bunga anggrek secara otomatis. Dengan adanya sistem klasifikasi bunga anggrek ini, diharapkan dapat membantu seseorang yang belum memiliki pengetahuan tentang bunga anggrek untuk mengenali spesies bunga anggrek genus *grammatophyllum*.

Beberapa studi penelitian mengenai klasifikasi bunga telah dilakukan baik berbasis citra maupun berdasarkan karakter morfologi bunga. Metode yang banyak digunakan dalam klasifikasi citra bunga adalah *Convolutional Neural Network (CNN)* yang diterapkan pada dataset Oxford 102 dan Oxford 17 [1, 2], 8 jenis bunga lokal Bangladesh [3], dan bunga mawar, tulip dan matahari [4]. CNN telah diimplementasikan pada kasus dataset Oxford 102 dan Oxford 17 menerapkan *automatic segmentation* sebelum dilakukan klasifikasi [1]. Implementasi augmentasi data dilakukan dengan menerapkan 8 teknik augmentasi dan dapat meningkatkan akurasi [3]. Proses *preprocessing* data meliputi *cropping* dan pembersihan *noise* sebelum dilakukan klasifikasi [4]. Dari banyak penelitian, CNN banyak diaplikasikan pada analisis citra [5]. Klasifikasi citra pada tanaman herbal Thailand mengimplementasikan teknik *boost up feature* [6].

### Topik dan Batasannya

Penelitian ini merupakan studi klasifikasi bunga anggrek untuk genus *grammatophyllum* dengan menggunakan metode CNN. Beberapa penelitian sebelumnya dijadikan sebagai acuan dan landasan perancangan sistem dimana dalam aplikasinya disesuaikan dengan kebutuhan. Batasan lingkup penelitiannya terdiri dari skenario pengujian dilakukan pada dua arsitektur yaitu arsitektur Alexnet dan custom arsitektur CNN. Pada program *batch size* yang digunakan 64, dimana skenario validasi dilakukan dengan  $1r 10^3$ ,  $1r 10^4$  dan  $1r 10^7$ . Sedangkan pada arsitektur model diimplementasikan dropout 20% dropout 30% dan dropout 40%.

### Tujuan

Penelitian ini dilakukan untuk melakukan *image recognition* terhadap bunga anggrek genus *grammatophyllum* terhadap empat spesies bunga menggunakan algoritma CNN, dimana prosesnya meliputi pengumpulan dataset sampai evaluasi hasil klasifikasi.

### Organisasi Tulisan

Secara umum pada laporan ini memuat :


1. Pendahuluan, berisi latar belakang, topik dan tujuan dari penelitian.
2. Studi Terkait, berisi tentang literatur review dan landasan teori yang digunakan untuk membangun model klasifikasi.
3. Perancangan sistem, berisi langkah-langkah atau prosedur yang dilakukan dalam penelitian ini mulai dari pengumpulan data, pre-process data yaitu *cropping* data secara manual, augmentasi data, pembangunan dan evaluasi model.
4. Evaluasi, berisi pemaparan hasil penelitian dan analisis hasil pengujian model.
5. Kesimpulan, berisi poin-poin hasil analisis penelitian.

## 2. Studi Terkait

### Augmentasi Data

Augmentasi data sangat bermanfaat jika dataset akan digunakan relatif sedikit [7]. Dengan augmentasi data kombinasi dari suatu citra akan bertambah, dilakukan augmentasi pada kasus klasifikasi 8 jenis bunga lokal Bangladesh yang memiliki 800 samples data dan setelah dilakukan augmentasi dengan 8 teknik augmentasi data,

datanya menjadi 6400 gambar [3]. Pada penelitian ini jumlah data train sebanyak 270 image dikali 4 kelas lalu diimplementasikan lima teknik augmentasi data, maka kombinasi data train yang didapat adalah 1350 image untuk setiap kelas. Dalam supervised learning jumlah data juga mempengaruhi hasil performansi sebuah model. Semakin banyak datanya, maka proses learning nya juga semakin baik. Berikut ilustrasi hasil lima teknik augmentasi yang dilakukan pada penelitian ini :





Tabel 2.1. Ilustrasi lima teknik augmentasi data

Terdapat banyak teknik augmentasi yang dapat dilakukan, seperti *Flip*, *Random cropping*, *Color Jitter* dan *Random Combination* [8]. Pada Tabel 2.1. diilustrasikan lima teknik augmentasi pada dataset, yaitu dua teknik *Flip*, *Random cropping*, *Color Jitter* dan Rotasi. *Flip* merupakan proses untuk membalikan suatu image, dapat dilakukan secara vertikal maupun horizontal. *Random cropping* dilakukan agar gambar yang di input kedalam CNN memiliki ukuran yang sama. *Color Jitter* dilakukan untuk mendapatkan variasi kontras dari suatu image. *Random combination* adalah gabungan dari beberapa teknik augmentasi seperti *translation*, *rotation*, *stretching*, *shearing* dan *lens distortions*. Gambar hasil augmentasi dianggap valid apabila maknanya tidak berubah, misal gambar buah apabila dilakukan horizontal flip maknanya akan tetap buah. Tetapi jika melakukan horizontal flip pada peta makna dari peta tersebut akan berubah yang artinya sudah tidak data tersebut tidak valid.

### Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan algoritma pengembangan dari *Multilayer Perceptron* (MLP) yang bekerja secara *supervised learning* atau proses pembelajaran yang diawasi. CNN dapat mengolah data dalam bentuk dua dimensi seperti gambar dan suara. Secara umum CNN terdiri dari dua lapisan yaitu *feature extraction layer* dan *classification layer*. *Feature extraction layer* terdiri dari *convolutional layer*, *pooling layer* dan *ReLU layer*. *Classification layer* terdiri dari *Fully Connected Layer*, *loss layer* dan *Dropout*. Namun tidak semua layer tersebut digunakan untuk setiap penelitian, penggunaan layer disesuaikan dengan arsitektur atau beberapa pertimbangan, misal penelitian [6] menggunakan *dropout* pada *classification layer* dengan pertimbangan dapat mencegah terjadinya *overfitting* dan mempercepat proses *learning*.

1. Convolution layer  
Konvolusi merupakan layer pertama dari CNN dimana pada layer ini membuat fitur baru, yaitu image diberi kernel untuk kemudian menghasilkan *feature map*. Pada layer konvolusi menghitung *output* dari *neuron* yang ke daerah lokal input[9].
2. Pooling layer  
Pooling layer berfungsi menjaga ukuran data setelah dilakukan konvolusi, yaitu dengan melakukan *downsampling* [7]. Pooling juga dapat membantu mengurangi *overfitting*. Terdapat dua jenis pooling yaitu, *max pooling* dan *average pooling*.
3. ReLU (Rectified Linear Units) layer  
Merupakan lapisan aktivasi CNN yang mengaplikasikan fungsi  $f(x) = \max(0, x)$ . Aktivasi ReLU membuat nilai piksel yang kurang dari 0 dijadikan nilai 0.
4. Fully-Connected (FC) layer  
Dari feature extraction layer, citra akan masuk ke FC layer. Namun sebelum masuk ke FC layer citra harus di *flatten* terlebih dahulu. *Flatten* adalah proses membentuk ulang fitur menjadi sebuah vektor untuk input ke FC layer [9]. FC layer mirip dengan MLP dimana setiap neurons memiliki koneksi ke

semua layer. Layer ini berfungsi untuk melakukan klasifikasi atau prediksi final kelas atau label dari citra.

#### 5. Loss layer

Loss layer merupakan lapisan yang menentukan penalti dari hasil prediksi dan label atau kelasnya [7]. Terdapat beberapa jenis loss function diantaranya; softmax loss, sigmoid cross-entropy loss dan euclidean loss.

### Bunga Anggrek Genus *Grammatophyllum*

*Grammatophyllum* merupakan salah satu genus bunga anggrek (*Famili Orchidaceae*), berasal dari bahasa Yunani *Gramma* yang berarti karakter atau huruf dan *phyllum* yang berarti daun. Genus ini pertama kali ditemukan oleh C. L. Blume pada tahun 1825 dengan spesies pertamanya yaitu *grammatophyllum speciosum*[10]. *Grammatophyllum* memiliki 13 spesies bunga anggrek. Spesies tersebut tersebar di Filipina, Indonesia, Malaysia, Indo-Cina, Pasifik selatan, Fiji sampai Selandia Baru .


Jika dilihat dari bentuknya terdapat beberapa spesies yang mirip, seperti spesies *grammatophyllum multiflorum* dan *tiger orchid*, *grammatophyllum measuresianum* dan *grammatophyllum ravanii*. Dari sisi warna, genus ini didominasi oleh warna kuning dan bercorak. Spesies *Grammatophyllum* pada umumnya memiliki bentuk daun linier dengan panjang sekitar 50 – 60 cm dan daunnya sendiri merupakan tulang daun tunggal. Untuk akarnya kebanyakan spesies memiliki akar angin [11].

### 3. Sistem yang

#### Dibangun Alur

#### Pemodelan Sistem

Pada penelitian ini mengimplementasikan algoritma CNN untuk klasifikasi bunga anggrek genus *grammatophyllum*. Untuk mengetahui gambaran secara umum dari penelitian yang akan dilakukan, di buatlah alur perancangan sistem. Adapun alur pemodelan sistemnya adalah sebagai berikut :



Gambar 3.1 Alur Pemodelan Sistem

#### 1. Analisa kebutuhan

Sebelum masuk ke alur pemodelan sistem Gambar 3.1, dilakukan analisa kebutuhan sistem terlebih dahulu. Tahap ini meliputi kajian pustaka untuk mengetahui perkembangan dari topik yang akan diajukan, mencari metode yang relevan dan menentukan objek penelitian. Dari tahap analisis menyimpulkan kebutuhan sistem seperti data dan *output* yang diharapkan dari sistem ini.

#### 2. Dataset

Dataset yang digunakan untuk penelitian ini adalah data image bunga anggrek genus *grammatophyllum*. Dari genus tersebut akan diambil empat spesies yaitu *grammatophyllum scriptum*, *grammatophyllum speciosum*, *grammatophyllum martae* dan *grammatophyllum measuresianum*. Keempat spesies ini akan dijadikan label kelas. Pengumpulan data melalui dua cara yaitu untuk satu spesies yaitu *measuresianum* diambil secara langsung menggunakan kamera (data primer dengan) yang dibantu oleh dosen pembimbing dan tiga spesies lainnya merupakan data sekunder yaitu didapat dengan mengunduh dari internet. Lalu sebelum masuk ke program data *image* ini dilakukan pre-process berupa *cropping* data secara manual agar noise pada image berkurang. Berikut keempat spesies bunga yang telah dilakukan *cropping* :

Martae	Measuresianum
--------	---------------



Tabel 3.1. Empat spesies bunga anggrek genus *grammatophyllum*

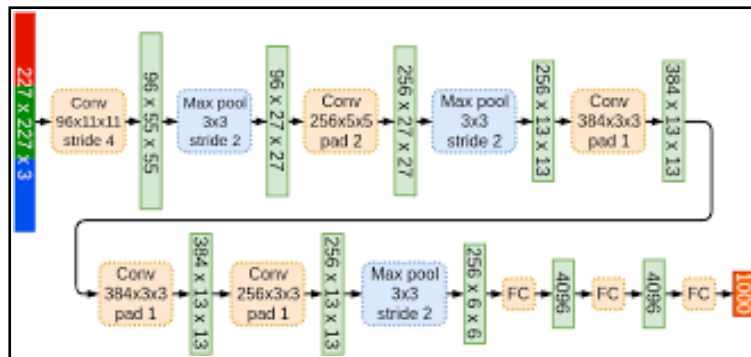
Pada Tabel 3.1. setelah gambar di *cropping* secara manual lalu data dibagi menjadi *image train* dan *image test*. Pembagian dataset sebesar 80% untuk data *train* dan 20% untuk data *test*, perbandingan ini didasarkan pada pareto principle yang umum digunakan untuk *data mining*. Jumlah image untuk masing-masing kelas sebanyak 340, sehingga untuk data *train* berjumlah 270 *image* dan data *test* 70 *image*.

Untuk augmentasi data *image* dilakukan secara terpisah dikarenakan proses augmentasi terhadap dua dataset image tersebut berbeda. Untuk augmentasi data *train image*, akan dilakukan lima teknik augmentasi selama *image* tersebut masih dapat dikenali oleh manusia bahwa image tersebut merupakan gambar bunga anggrek dari spesies tertentu atau data masih valid, dengan menerapkan lima teknik augmentasi di *train image* harapannya saat di *test image* sistem dapat mengenali pola *feature image* dengan baik. Jadi setelah dilakukan teknik augmentasi, kombinasi data train menjadi 1350 image (270 x 5) untuk setiap kelasnya. Sebaliknya data *test image*, tidak akan dilakukan augmentasi data, hanya akan melakukan *resize* dan *crop* saja karena input gambar untuk CNN harus sama.

### 3. Proses training, testing dan evaluasi model

Berdasarkan Gambar 3.1 data yang telah di augmentasi masuk ke model CNN untuk dilakukan konfigurasi training dan testing untuk memperoleh hasil klasifikasi. Proses validasi model menggunakan *k-fold cross validation*. CNN memiliki beberapa jenis optimizer function, diantaranya *metode gradient descent momentum (GDM)*, *metode Root Mean Square Propagation (RMSProp)* dan kombinasi dari kedua kedua metode tersebut yaitu *Adaptive Moment Optimization (Adam)*[12]. Pada penelitian ini akan menggunakan metode *Adam optimizer*. *Adam optimizer* telah dipergunakan untuk mengklasifikasikan 8 jenis bunga lokal Bangladesh [3].

AlexNet ditemukan oleh Alex Krizhevsky pada kompetisi ImageNet ILSVRC dengan error rate hanya sebesar 16%[13]. Berikut adalah arsitektur AlexNet:

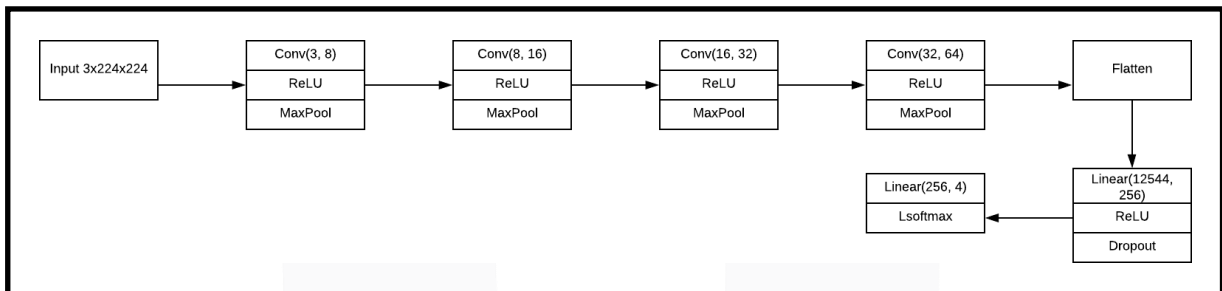


Gambar 3.2. Arsitektur AlexNet<sup>1</sup>

Input size dari arsitektur AlexNet adalah 227 x 227, dari Gambar 3.2 dapat dilihat untuk setiap layer memiliki input sekuensial, dimana untuk *stride* dan *padding* berbeda-beda. Konvolusi dilakukan sebanyak lima kali, *pooling* tiga kali dan terdapat tiga layer klasifikasi (*FC layer*). Dalam implementasinya layer *softmax* dan *dropout* juga dapat diaplikasikan di layer klasifikasi.

#### Custom Arsitektur CNN

Selain arsitektur Alexnet, penelitian ini juga menggunakan custom arsitektur lainnya dengan memanfaatkan fitur convolutional block seperti github wiraDKP[15]. Berikut adalah arsitektur CNN nya :



Gambar 3.3. Custom Arsitektur CNN

Pada Gambar arsitektur 3.3. diatas terdapat 5 layer konvolusi dan 2 layer klasifikasi. Fungsi aktivasi pada layer konvolusi menggunakan ReLU dan pooling menggunakan metode MaxPool. Sedangkan pada layer klasifikasi fungsi aktivasi Softmax digunakan untuk menangani klasifikasi 4 kelas. Selain itu dropout juga diimplementasikan pada layer klasifikasi ini.

## 4. Evaluasi

### 4.1 Hasil Pengujian

Proses pengujian model menggunakan metode k-Fold cross validation terhadap dua arsitektur CNN, yaitu arsitektur Alexnet dan custom arsitektur CNN. Skenario pengujian menggunakan k-fold cross validation pada penelitian ini digunakan untuk memilih parameter dengan hasil terbaik berdasarkan parameter *learning ratenya*. Dalam k-fold cross validation data training dan data testing akan di partisi secara acak sebanyak k fold, untuk penelitian ini jumlah k-fold yang dipilih sebanyak 10. Citra pada dataset sebanyak 340 citra dikali 4 kelas, jadi 1360 citra ini pada setiap fold akan berisi 136 objek data (1360 dibagi 10 fold), dan setiap kelasnya diwakili 34 objek data (136 dibagi 4 kelas). Pada skenario pengujian k-Fold cross validation ini jumlah epoch yang dipilih sebanyak 1, jadi untuk setiap epoch pertama ini menunjukkan 1 Fold untuk setiap pengujian. Adapun untuk satu kali pengujian dilakukan tiga kali percobaan karena k-Fold cross validation ini membangkitkan *initial*

<sup>1</sup> <https://subscription.packtpub.com/book/data/9781789956177/5/ch05lv1sec13/introducing-alexnet>

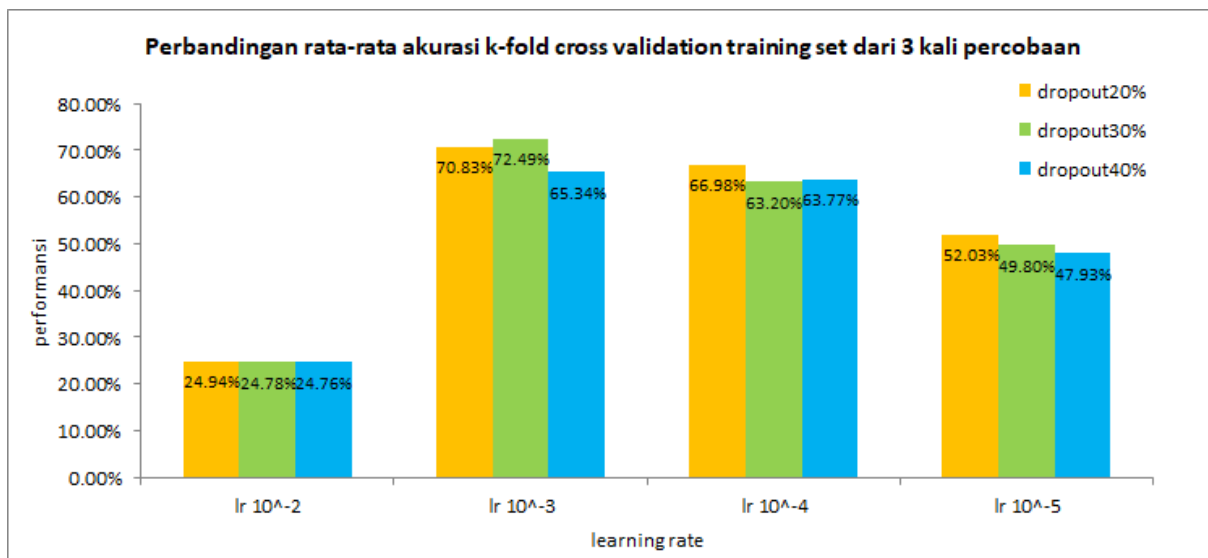
*state* yang random, maka proses learning kurang *valid* apabila hanya dilakukan satu kali percobaan karena *weight* yang dibangkitkan di awal berbeda-beda.

Parameter yang dijadikan bahan uji adalah dropout pada arsitektur CNN dan *learning rate* (lr). Untuk drop out dicoba adalah dropout sebesar 20%, dropout 30% dan dropout 40%. Sedangkan untuk *learning rate* (lr) dari  $10^{-2}$  sampai  $10^{-7}$ . Percobaan ini dilakukan untuk melihat seberapa besar pengaruh dari dua parameter tersebut terhadap performansi model. Untuk parameter *learning rate* (lr) digunakan pada skenario pertama yaitu skenario validasi model menggunakan k-fold cross validation untuk memilih parameter learning rate terbaik yang akan digunakan untuk proses learning model. *Learning rate* adalah salah satu parameter penting yang mengontrol seberapa besar perubahan sensitivitas model berdasarkan error yang dihasilkan untuk per epoch nya.


Untuk hasil pengukuran selain dilihat dari akurasi, recall, presisi dan f score juga diperhatikan. Presisi adalah ukuran kepastian, yaitu *True Positif* dibagi dengan *True Positif* ditambah *False Positif* dan *recall* adalah ukuran kelengkapan, yaitu *True Positif* dibagi dengan *True Positif* ditambah *False Negatif*. Sementara itu, jika ukuran presisi dan recall digabungkan maka rata-rata harmonik dari kedua ukuran ini disebut dengan f score [15], dimana pada program perhitungan ketiga pengukuran ini didapat dengan memanggil fungsi dari *library Scikit Learn*.

### Hasil Pengujian Arsitektur AlexNet

Pada percobaan pertama dataset diimplementasikan menggunakan arsitektur Alexnet dengan dropout 20%, 30% dan 40%. Dilakukan proses pada dataset bunga anggrek genus *grammatophyllum* ini dimana jumlah *image* pada data train sebanyak 270 gambar dan data test sebanyak 70 gambar. *Input size* pada arsitektur Alexnet adalah  $227 \times 227$ . Proses model validasi menggunakan k-fold cross validation dilakukan untuk dropout 20% dropout 30% dan dropout 40% yang masing-masing dilakukan sebanyak empat kali. Berikut hasil perbandingannya :

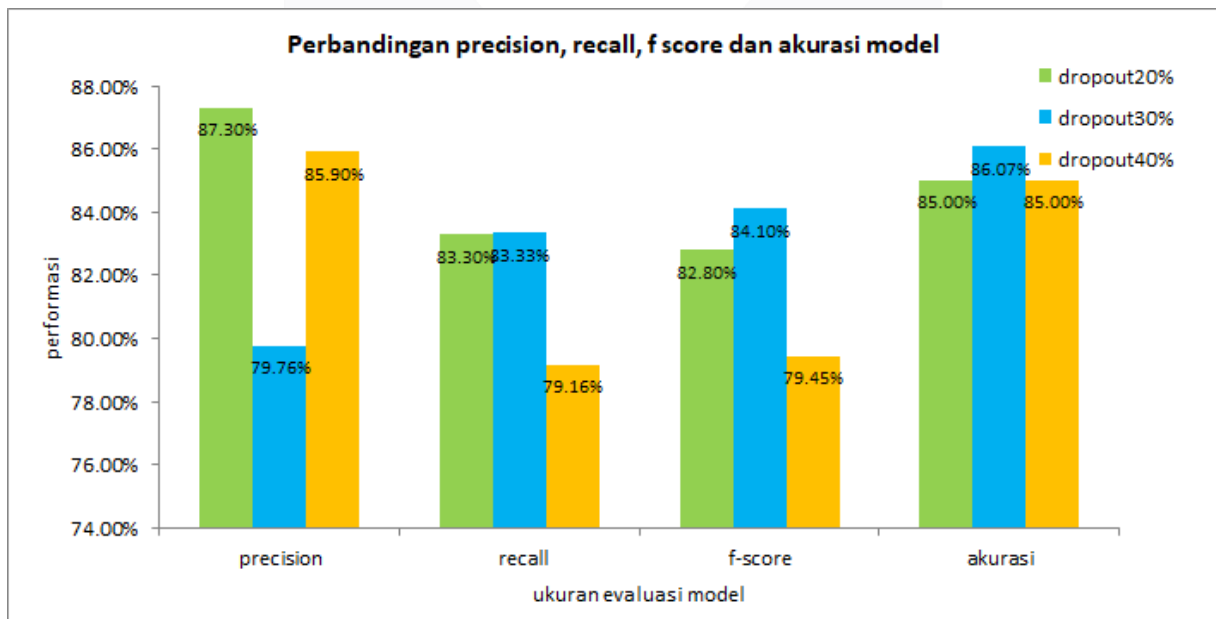


Gambar 4.1. Perbandingan rata-rata akurasi training arsitektur Alexnet dari 3 kali percobaan



Gambar 4.2. Perbandingan rata-rata akurasi training arsitektur Alexnet dari 3 kali percobaan

Jika dilihat dari hasil rata-rata k fold cross untuk training dan testing atau validasi seperti Gambar 4.1. dan 4.2. *learning rate*  $10^3$  menunjukkan hasil performansi terbaik dibandingkan dengan *learning rate*  $10^3, 10^0$  dan *learning rate*  $10^{-7}$ . Dilihat dari diagramnya *learning rate*  $10^{-2}$  berada di rata-rata akurasi 22% untuk setiap dropout, *learning rate*  $10^3$  memiliki akurasi testing di rentang 76% sampai 83%, *learning rate*  $10^0$  di rentang 65% sampai 66% dan *learning rate*  $10^{-7}$  di rentang 51% sampai 53%. Dengan demikian dapat disimpulkan bahwa parameter *learning rate* sangat mempengaruhi performansi model. Pemilihan nilai *learning rate* sangat penting untuk proses training model. Berikut hasil pengujiannya:




Gambar 4.3. Perbandingan precision, recall, f score dan akurasi arsitektur Alexnet

Berdasarkan hasil pengujian Gambar 4.3. dengan  $10^3$  performansi terbaik model adalah dengan implementasi dropout 30% yaitu precision 95.00%, recall 95.80%, f score 95.50% dan akurasi 88.00%. Perbandingan hasil pengukuran dari tiga implementasi dropout pada arsitektur CNN perbedaannya tidak terlalu signifikan, seperti pada salah satu hasil pengukuran model yaitu akurasi, dropout 20% dan 40% menghasilkan nilai akurasi yang sama yaitu sebesar 85.00%. Maka dapat disimpulkan untuk penelitian ini, parameter uji yang paling berpengaruh terhadap hasil performansi model adalah parameter learning rate, sedangkan untuk perbedaan implementasi pada arsitektur model, hasilnya tidak terlalu signifikan. Untuk melihat apakah pernyataan ini tepat, maka skenario pengujian dilakukan kembali dengan mengimplementasikan arsitektur CNN

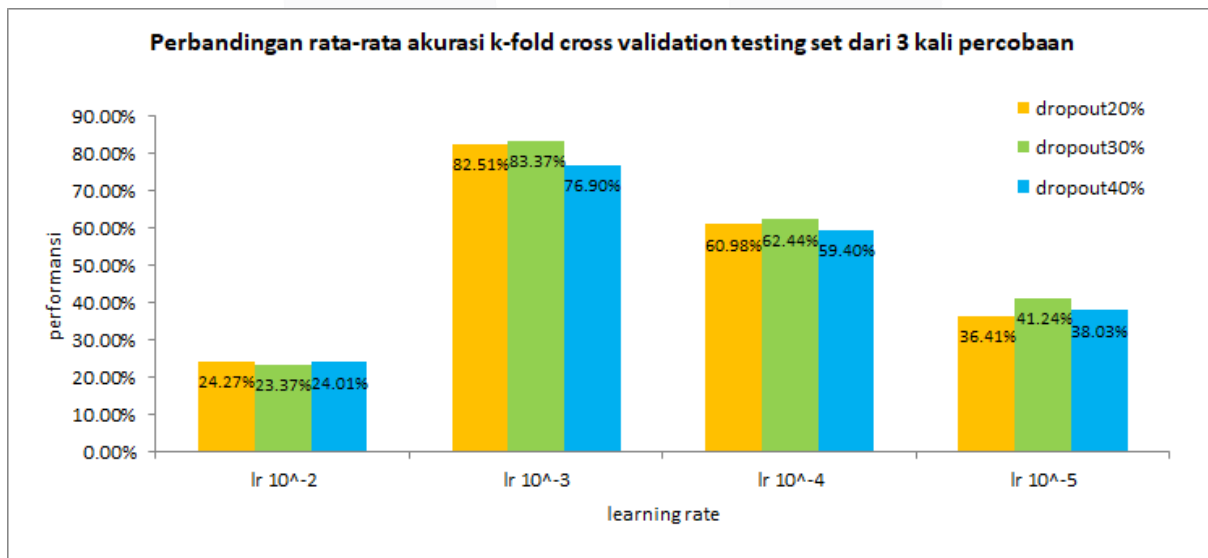
yang berbeda.

### Hasil Pengujian Custom Arsitektur CNN

Untuk percobaan kedua dengan custom arsitektur ini, input size dari image adalah 224x224 sesuai dengan input standar CNN seperti ZFNet dan VGGNet16. Jumlah parameter input sebesar 150524 parameter ( $3 \times 224 \times 224$ ) dan setelah dilakukan konvolusi dengan lima layer konvolusi jadi 12544 parameter. Dropout yang diimplementasikan pada layer klasifikasi adalah 20%, 30% dan 40%, sama seperti arsitektur Alexnet sebelumnya. Berikut adalah hasil skenario k-fold cross validation dari lr dari  $10^{-2}$  sampai  $10^{-7}$ :

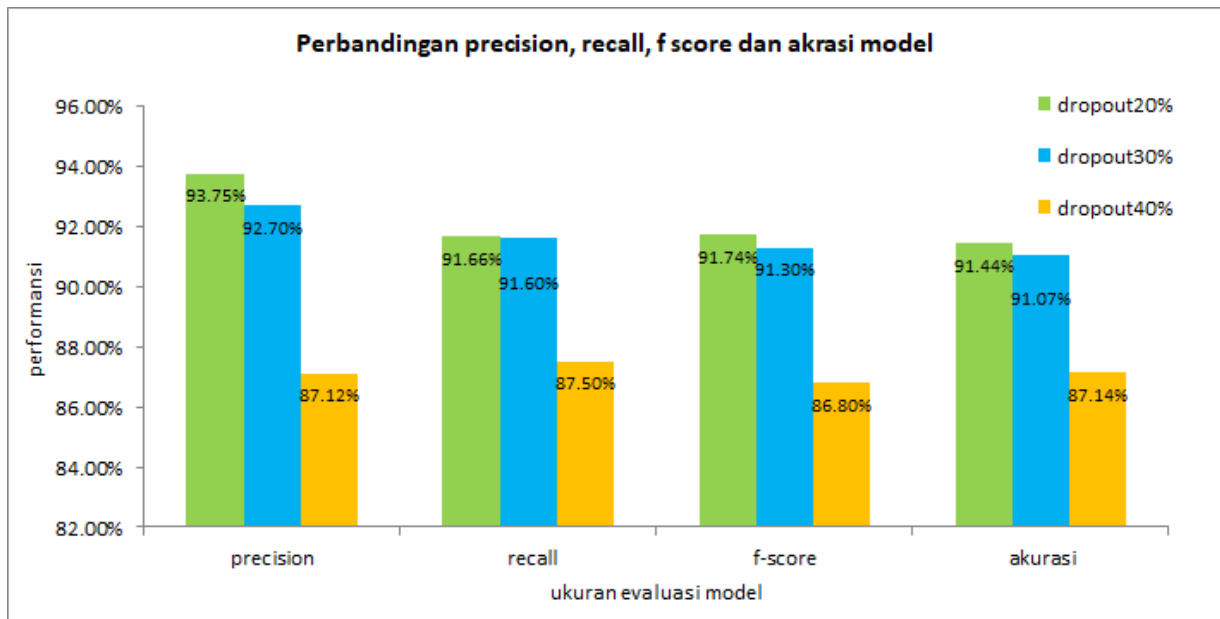


Gambar 4.4. Perbandingan rata-rata akurasi training custom arsitektur CNN dari 3 kali percobaan



Gambar 4.5. Perbandingan rata-rata akurasi testing custom arsitektur CNN dari 3 kali percobaan

Berdasarkan hasil perbandingan rata-rata k fold validation untuk training dan testing seperti Gambar 4.4. dan Gambar 4.5. performansi terendah sampai tertinggi secara berturut-turut didapat dengan parameter learning rate  $10^2$ ,  $10^1$ ,  $10^0$  dan  $10^{-1}$ . Dapat dilihat untuk skenario pengujian dengan custom arsitektur CNN ini, parameter lr dengan nilai  $10^{-3}$  menunjukkan hasil performansi terbaik seperti pengujian k fold cross validation Alexnet sebelumnya. Selanjutnya  $10^{-3}$  digunakan untuk proses learning. Berikut hasil pengujiannya:



Gambar 4.6. Perbandingan precision, recall, f score dan akurasi custom arsitektur CNN

Berdasarkan Gambar 4.6. hasil pengukuran terbaik didapat dengan mengimplementasikan dropout 20% pada arsitektur model. Namun hasilnya tidak terlalu jauh signifikan dengan implementasi dropout 30%. Sedangkan pada dropout 40% menurun cukup signifikan dari dropout 30%. Artinya pada skenario pengujian dengan menggunakan custom arsitektur CNN ini, apabila terlalu banyak menonaktifkan sel saraf atau dropout terlalu besar mengakibatkan banyak informasi yang hilang untuk proses *learning*, sehingga hasil performansi model menurun.

#### 4.2 Analisis Hasil Pengujian.

Penelitian telah dilakukan pada dataset bunga angrek genus *grammatophyllum* yang memiliki 4 spesies atau 4 kelas didalamnya. Selain memperhatikan beberapa hyperparameter, pada penelitian ini juga sangat memperhatikan dari segi arsitektur model. Arsitektur CNN yang digunakan sendiri adalah Arsitektur Alexnet dari penelitian Alexnet tahun 2012[14], dan custom arsitektur CNN dari Github WiraDKP. Selain sebagai bahan perbandingan, mengimplementasikan dua arsitektur CNN ini juga untuk menganalisis seberapa baik kualitas dataset, apakah hanya bagus dalam satu arsitektur saja, atau dataset memiliki kualitas yang cukup baik sehingga menghasilkan performansi model yang cukup baik pada kedua arsitektur.

Dari hasil penelitian menggunakan dua skenario pengujian k fold cross validation, yaitu dengan arsitektur Alexnet dan custom arsitektur CNN parameter uji learning rate terbaik adalah  $10^{-3}$ . Selain itu jika diperhatikan kembali pada beberapa percobaan, hasil akurasi testingnya lebih baik dibanding dengan akurasi training, salah satu penyebab hal ini adalah karena pada saat testing drop out dimatikan. Berdasarkan hasil validasi testing set arsitektur Alexnet dan custom arsitektur CNN, learning rate yang terlalu besar ( $10^2$ ) mengakibatkan ketidakmampuan model untuk belajar dengan baik karena model konvergen terlalu cepat pada *sub optimal solution*, dengan kata lain mengatur nilai learning rate dengan terlalu besar dapat beresiko terjadinya overshooting pada local minimum. Sedangkan dari learning rate  $10^{-3}$  ke  $10^{-7}$  akurasi model menurun yang berarti pada pengujian ini jika mengatur nilai learning rate yang terlalu kecil dapat mengakibatkan proses *learning stuck*. Oleh sebab itu, untuk proses skenario pengujian berikutnya nilai konstanta *learning rate* yang akan digunakan adalah  $10^{-3}$ .

input	dropout	lr	precision	recall	f-score	akurasi
Alexnet	20%	$10^{-3}$	87.30%	83.30%	82.80%	85.00%
	30%	$10^{-3}$	79.76%	83.33%	84.10%	86.07%

	40%	10 <sup>3</sup>	85.90%	79.16%	79.45%	85.00%
3x224x224	20%	10 <sup>3</sup>	93.75%	91.66%	91.74%	91.42%
	30%	10 <sup>3</sup>	92.70%	91.60%	91.30%	91.07%
	40%	10 <sup>3</sup>	87.12%	87.50%	86.80%	87.14%

Tabel 4.1. Perbandingan hasil pengujian arsitektur Alexnet dan custom arsitektur CNN

Pada klasifikasi bunga anggrek untuk genus *grammatophyllum* ini, arsitektur CNN yang paling baik diimplementasikan pada dataset adalah custom arsitektur CNN. Arsitektur dari kedua skenario memiliki karakteristik yang berbeda mulai dari jumlah layer filter dan sebagainya. Arsitektur Alexnet memiliki layer yang lebih kompleks dibanding dengan custom arsitektur CNN, hal ini dapat menjadi salah satu penyebab performansi custom arsitektur CNN lebih baik dibanding arsitektur Alexnet. Namun jika ditinjau kembali hasil dari kedua arsitektur ini cukup baik hasil pengujiannya.

Teknik regularisasi yang diimplementasikan pada penelitian ini adalah drop out pada arsitektur model. Dari Tabel 4.1. dropout 20%, dropout 30% dan dropout 40% telah diimplementasikan pada kedua arsitektur. Perbedaannya pada custom arsitektur CNN, dropout diimplementasikan pada satu layer di fully connected layer, sedangkan untuk arsitektur Alexnet dropout diimplementasikan pada dua layer di fully connected layer. Hal ini karena pada custom arsitektur CNN memiliki dua fully connected layer dimana untuk layer pertama diimplementasikan dropout dan layer terakhir fungsi aktivasi softmax, sedangkan untuk arsitektur Alexnet memiliki tiga fully connected layer dimana untuk kedua layer pertama diimplementasikan dropout dan untuk layer terakhir fungsi aktivasi softmax. Dari ketiga drop out yang diimplementasikan Performansi terbaik pada arsitektur Alexnet didapat dengan mengimplementasikan dropout 30% yaitu precision 79.76%, recall 83.33%, f score 84.10% dan akurasi sebesar 86.07%. Sedangkan hasil pengukuran terbaik untuk custom arsitektur CNN didapat dengan hasil implementasi dropout 20% yaitu precision 93.75%, recall 91.66%, f score 91.74% dan akurasi sebesar 91.42%.

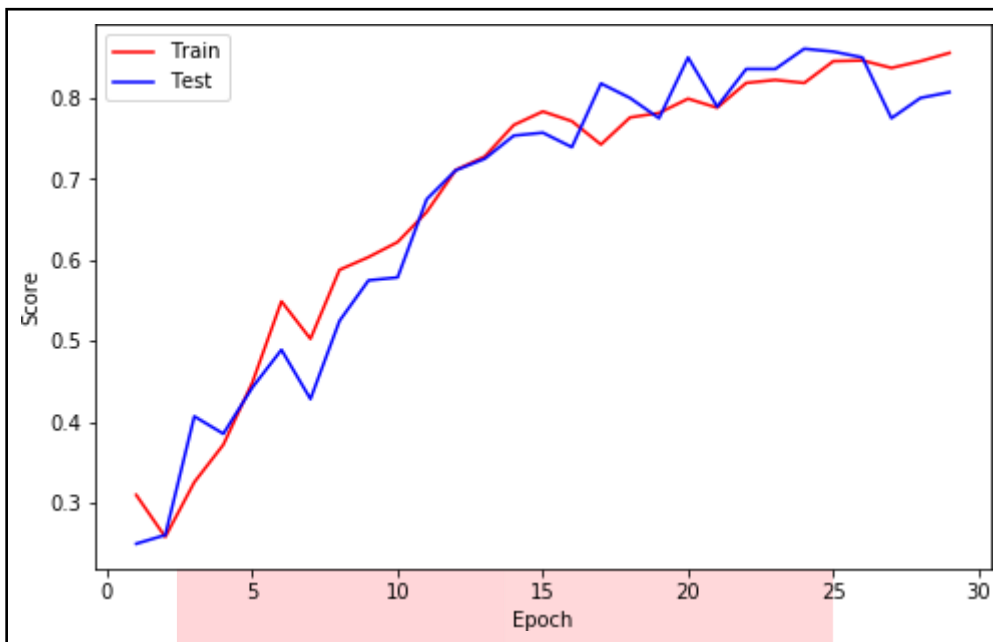
Dari hasil performansi terbaik custom arsitektur CNN terlihat akurasi model sedikit lebih kecil dibanding dengan hasil pengukuran f score nya, yaitu akurasi sebesar 91.41% dan f score nya sebesar 91.74%, sedangkan untuk arsitektur Alexnet berbanding terbalik yaitu akurasi model lebih besar dibanding f score dengan nilai akurasi sebesar 86.10% dan f score 84.10%. Namun jika diperhatikan kembali hasil akurasi dan f score pada kedua arsitektur ini nilainya tidak terlalu berbeda tinggi hal ini karena pada kasus ini datasetnya merupakan *balance class*.

Pada skenario pengujian ini, parameter epoch tidak diinisiasi nilainya di awal, karena programmer tidak mengetahui pada epoch berapa model terbaik dicapai sehingga dari grafik perbandingan train dan test tidak terlalu *overfitting*. Maka pada pengujian ini *early stopping* model memanfaatkan fungsi dari *early stopping callback*, dimana pada fungsi ini akan memonitor hasil akurasi test yang mana model akan berhenti melakukan proses learning apabila *early patience* nya sudah menyentuh angka 5 atau akurasi test model di lima epoch terakhir turun secara berturut-turut. Berikut salah satu contoh *early stopping* dari model arsitektur Alexnet drop out 30%:

```
==> EarlyStop patience = 5 | Best test_score: 0.8607
==> Execute Early Stopping at epoch: 29 | Best test_score: 0.8607
```


Gambar 4.7. Early Stopping arsitektur Alexnet

Pada gambar 4.7. terlihat model berhenti saat *early patience* mencapai 5 dan akurasi terbaik yang dihasilkan adalah 86.10%. Berikut grafik perbandingan train dan testnya:



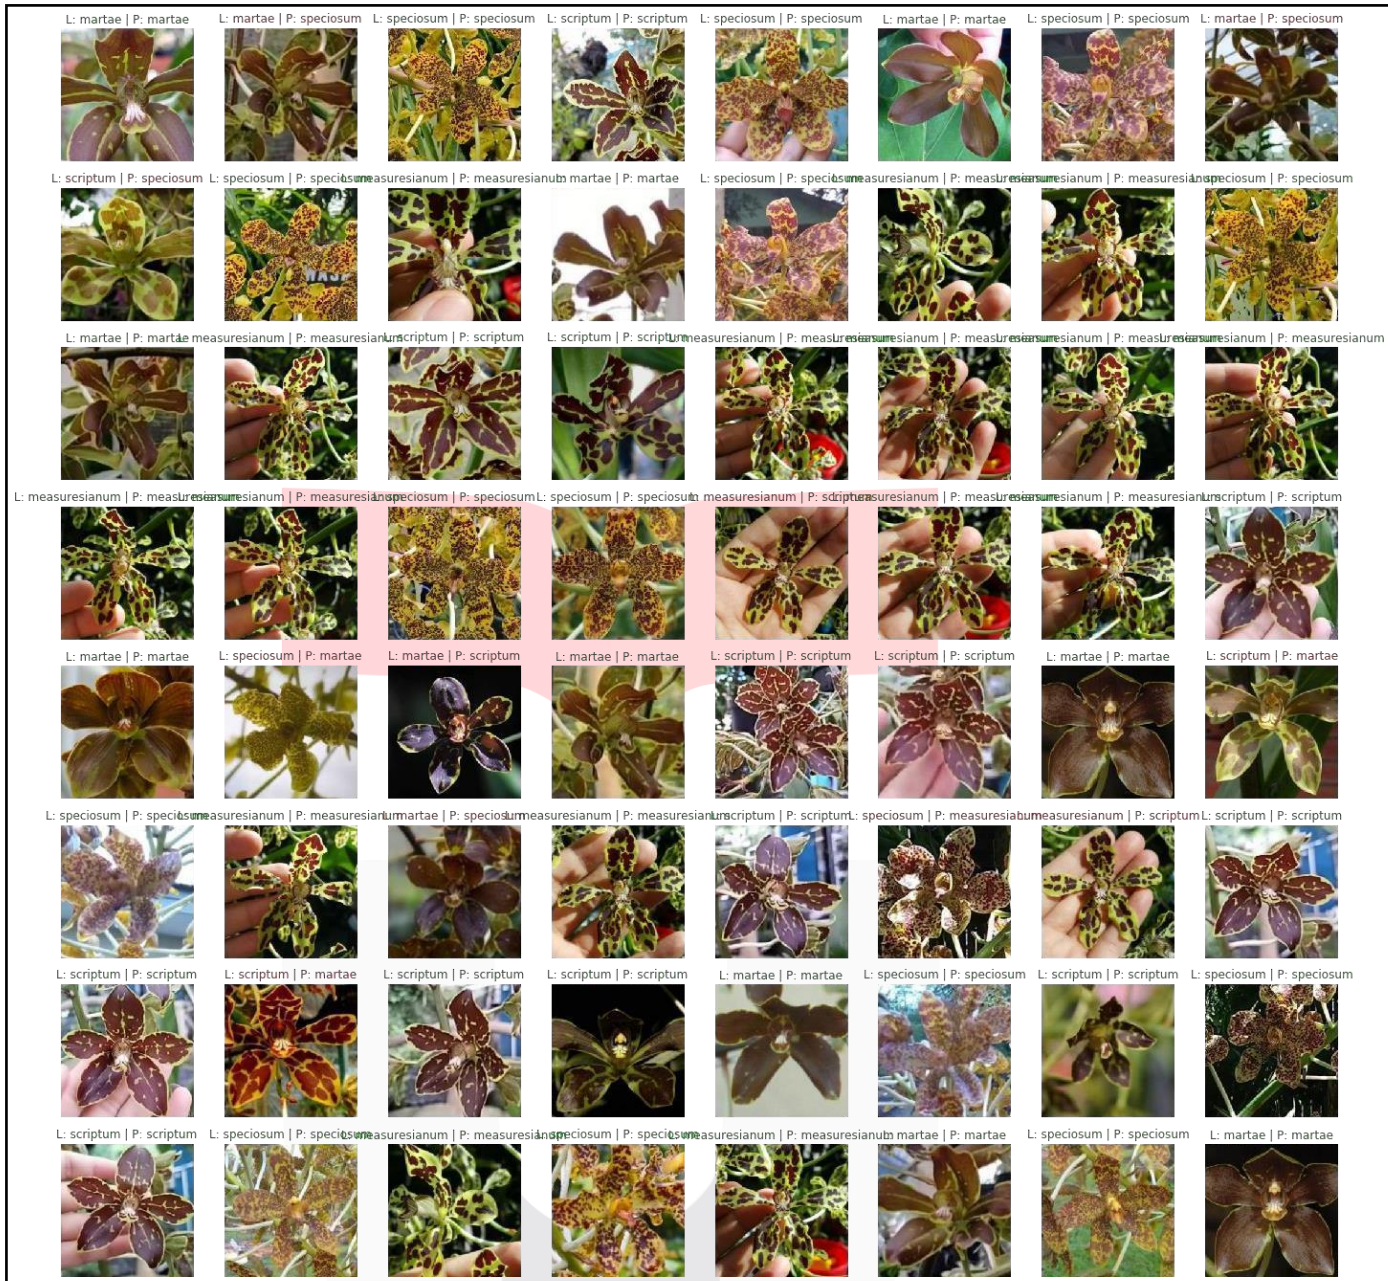
Gambar 4.8. Grafik akurasi train dan test arsitektur Alexnet

Pada gambar 4.8. terlihat proses learning berhenti di epoch 29 atau dengan kata lain akurasinya tidak lebih baik atau bertambah dari epoch 24 yang memiliki akurasi test sebesar 86.10%. Begitu pula dengan custom arsitektur CNN dari fungsi *early stopping* yang diimplementasikan berikut grafik perbandingan train dan testnya:




Gambar 4.9. Grafik akurasi train dan test custom arsitektur CNN

Dari gambar 4.9. untuk custom arsitektur CNN berhenti melakukan learning pada epoch 29 yang berarti akurasinya tidak bertambah dari 91.41% dari epoch 24. Dari model terbaik arsitektur Alexnet dan custom arsitektur CNN, proses selanjutnya adalah melihat prediksi data atau image terhadap label aslinya. Untuk satu batch data yang ditarik ke dataloader adalah 64 gambar, sesuai inisiasi *batch size* diawal. Pada laporan ini tidak semua batch akan ditampilkan, hanya ditampilkan untuk batch pertama dari hasil learning model untuk melihat beberapa data yang salah prediksi atau *misclassification*, berikut hasil prediksi dari arsitektur alexnet dan custom arsitektur CNN:









Gambar 4.10. Hasil prediksi arsitektur Alexnet untuk satu batch



Gambar 4.11. Hasil prediksi custom arsitektur CNN untuk satu batch

Pada gambar 4.10. terlihat hasil prediksi untuk arsitektur alexnet dan gambar 4.11. hasil prediksi custom arsitektur CNN untuk satu *batch*. Title 'L' merupakan Label sebenarnya dari dataset dan 'P' merupakan hasil Prediksi model. Apabila model memprediksi benar maka antara label dan prediksinya menunjukkan spesies yang sama dan diberi tanda warna hijau, sedangkan untuk warna merah merupakan data-data yang *misclassification*. Dari kedua model ada irisan data yang *mispredict*, berikut beberapa data tersebut:

Arsitektur model	Data <i>mispredict</i> 1	Data <i>mispredict</i> 2	Data <i>mispredict</i> 3
Arsitektur Alexnet	L: <i>scriptum</i>   P: <i>speciosum</i> 	L: <i>martae</i>   P: <i>scriptum</i> 	L: <i>measuresianum</i>   P: <i>scriptum</i> 
Custom Arsitektur CNN	L: <i>scriptum</i>   P: <i>martae</i> 	L: <i>martae</i>   P: <i>scriptum</i> 	L: <i>measuresianum</i>   P: <i>scriptum</i> 

Tabel 4.2. Irisan data *mispredict* dari arsitektur Alexnet dan custom arsitektur CNN

Dari Tabel 4.2. untuk satu *batch* dari masing-masing arsitektur model, terdapat tiga irisan data *mispredict*, untuk data *mispredict* pertama memiliki Label *Scriptum*, oleh model arsitektur Alexnet diprediksi sebagai *speciosum* dan model custom arsitektur CNN memprediksi sebagai *martae*. Sedangkan dua data *mispredict* lainnya yaitu data *mispredict* 2 dan data *mispredict* 3, baik oleh model arsitektur Alexnet maupun custom arsitektur CNN diprediksi salah sebagai spesies *scriptum* dan *scriptum* dari label aslinya yaitu spesies *martae* dan *measuresianum*. Pada *batch* selanjutnya, karena setiap *batch* dari train loader diambil secara acak (*shuffle*) akan terdapat irisan data *mispredict* lainnya ataupun tidak. Dari irisan data *mispredict* ini, dapat disimpulkan bahwa model CNN tidak dapat memprediksi data dengan benar untuk beberapa data tertentu.

## 5. Kesimpulan

Proses penelitian klasifikasi bunga anggrek untuk genus *grammatophyllum* ini diimplementasikan di *google collaboratory* menggunakan metode CNN dengan bahasa pemrograman python dan *library pytorch* dan *library sklearn*. Proses penelitian yang dilakukan mulai dari pengumpulan data, *cropping* data, augmentasi data, pembangunan model, proses learning sampai evaluasi hasil model.

Parameter yang dijadikan bahan uji pada penelitian ini adalah *learning rate* (lr) dengan Adam optimizer dan dropout pada arsitektur CNN. Dari model validation konstanta learning terbaik adalah  $10^{-3}$ . Performansi terbaik pada arsitektur Alexnet didapat dengan mengimplementasikan dropout 30% yaitu precision 79.76%, recall 83.33%, f score 84.10% dan akurasi sebesar 86.07%. Sedangkan hasil pengukuran terbaik untuk custom arsitektur CNN didapat dengan hasil implementasi dropout 20% yaitu precision 93.75%, recall 91.66%, f score 91.74% dan akurasi sebesar 91.42%.

Penelitian ini telah dilakukan untuk proses klasifikasi atau image recognition terhadap bunga anggrek untuk genus *grammatophyllum* dengan menerapkan beberapa skenario pengujian. Saran untuk penelitian berikutnya dapat melakukan skenario pengujian dengan batch size dan optimizer yang berbeda-beda dan melihat korelasinya dengan *learning rate* (lr).

## Referensi

- [1] Hiary H., Saadeh H., Saadeh M dan Yaqub M., 2015, Flower Classification using Deep Convolutional Neural Networks, IET Research Journals, pp.1-8.
- [2] Mete R, B., 2019, Flower Classification with Deep CNN and Machine Learning Algorithms, IEEE.
- [3] Islam S., Foysal A. F. Md. dan Jahan N., 2020, A Computer Vision Approach to Classify Local Flower using Convolutional Neural Network, IEEE, Proceedings of the International Conference on Intelligent Computing and Control Systems 2020.
- [4] Peryanto A., Yudhana A. dan Umar R., 2020, Klasifikasi Citra Menggunakan Convolutional Neural Network dan K Fold Cross Validation, Journal of Applied Informatics and Computing, pp.45-51.
- [5] Alom, M. Z. et al., 2018, The History Began from Alexnet : A Comprehensive Survey on Deep Learning Approaches, Cornell University Library's arXiv.org.
- [6] Visavakitcharoen A., Ratanasanya S. dan Polvichai J., 2019 ,Improving Thai Herb Image Classification using Convolutional Neural Networks with Boost up Features, IEEE, International Technical Conference on Circuits/Systems, Computers and Communications.
- [7] Dr. Suyanto., Ramadhani N. R. dan Mandala S., 2019, Deep Learning : Modernisasi Machine Learning Untuk Big Data, Informatika Bandung.
- [8] Wang J. dan Perez L., 2017, The Effectiveness of Data Augmentation in Image Classification Using Deep Learning, Cornell University Library's arXiv.org.
- [9] N. Bagas W. Hr., Mailoa E. dan Purnomo D. H., 2019, Deteksi Buah Untuk Klasifikasi Berdasarkan Jenis dengan Algoritma CNN Berbasis YOLOv3, Jurnal Rekayasa Sistem dan Teknologi Informasi.
- [10] Tropicals, 2008, Grammatophyllum Orchids, Orchids 'R' Us, Inc. [Online]. Available at : <http://www.clanorchids.com/culture/gramcult.html> . [Accessed 28 November 2020].
- [11] Didik Y. S., 2019, Mengenal Anggrek Grammatophyllum.[Online]. Available at : <https://kampoengangrek.com/mengenal-anggrek-grammatophyllum/> . [Accessed 28 November 2020].
- [12] Setiawan W., 2019, Perbandingan Arsitektur Convolutional Neural Network untuk Klasifikasi Fundus, Jurnal SimanteC.
- [13] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, 1097-1105.
- [14] WiraDKP, Arsitektur CNN.[Online]. Available at : [https://github.com/WiraDKP/deep\\_learning/tree/master/](https://github.com/WiraDKP/deep_learning/tree/master/) . [Accessed 28 November 2020].
- [15] Dr. Suyanto., 2019, DATA MINING Untuk Klasifikasi dan Klasterisasi Data Edisi Revisi, Informatika Bandung.