

Klasifikasi Citra Klon Teh Seri GMB Menggunakan Convolutional Neural Network (CNN) dengan Arsitektur Resnet, Vggnet, dan Alexnet

Classification of Gmb Series Tea Clone Image Using Convolutional Neural Network (CNN) with Resnet, Vggnet, and Alexnet Architecture

Nur Ibrahim^{1,*}, Syamsul Rizal¹, Sofia Saidah¹, Heri Syahrian², Sigit Adithyia Fardiansyah¹, Adilla Zaki Al Afghani¹, dan Muhammad Husnul Hayat¹

¹ Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom

² Pusat Penelitian Teh dan Kina

* Korespondensi : nuribrahim@telkomuniversity.ac.id

Received: 22 September 2022

Accepted: 10 Juni 2022

Published: 14 Aguatus 2022

Jurnal Sains Teh dan Kina
Pusat Penelitian Teh dan Kina
Desa Mekarsari, Kec. Pasirjambu,
Kab. Bandung, Jawa Barat 40972
redaksiptk@gmail.com
(022)

Abstract: The productivity of tea leaves in Indonesia gradually decreases. This is caused by an incompatibility in choosing GMB series tea clones used. GMB series tea clones consist of GMB 1 up to GMB 11. The limitation of Research Institute for Tea and Cinchona (RITC) workers and tea farmers in classifying GMB series tea clones to differentiate type between clones that morphologically have a degree of close similarity has becoming the reason of choosing GMB series tea clones that are suitable for use less optimal. This research designed a system visually capable of classifying tea clone type which consists of 11 different classes, that is GMB 1-11 with digital image processing. Data image were taken using handphone's camera, then followed by pre- processing resize and augmentation. Convolutional Neural Network (CNN) has becoming a training method in identifying object through system supported by ResNet, VGGNet and AlexNet architecture with better accuracy because its ability to simplify images through many layers. The system is able to classify the image of GMB series tea clones 1 until GMB 11. Test scenario are done by using the total amounts of 1100 datasets as original data and 2860 as pre- processing augmentation data. The best testing using augmentation data of 2640 training data and 220 test data. The best system parameters obtained accuracy on ResNet 97.80%, VGGNet 95.45% and AlexNet 98.18%.

Keywords: GMB tea clone series, Classification, CNN, ResNet, VGGNet, AlexNet

Abstrak: Produktivitas daun teh di Indonesia dari waktu ke waktu semakin menurun. Hal ini disebabkan oleh ketidakcocokan dalam memilih klon teh seri GMB yang digunakan. Klon teh seri GMB terdiri dari GMB 1 sampai dengan GMB 11. Keterbatasan karyawan Pusat Penelitian Teh dan Kina (PPTK) dan para petani teh dalam mengklasifikasi klon teh seri GMB untuk membedakan jenis antar klon yang secara morfologi memiliki tingkat kemiripan yang begitu dekat menjadi alasan kurang optimal dalam memilih klon teh seri GMB yang cocok untuk digunakan. Pada penelitian ini, dirancang suatu sistem secara visual yang mampu mengklasifikasi jenis klon teh yang terdiri dari 11 kelas yaitu GMB 1-11 dengan pengolahan citra digital. Citra data diambil menggunakan kamera handphone, kemudian dilakukan pre-processing resize dan augmentasi. Convolutional Neural Network (CNN) menjadi suatu metode pelatihan dalam mengenali objek melalui sistem yang ditunjang oleh arsitektur ResNet, VGGNet, dan AlexNet dengan keunggulan tingkat akurasi yang baik karena kemampuannya dalam menyederhanakan citra melalui banyak layer. Sistem mampu mengklasifikasikan citra klon teh seri GMB 1 sampai dengan GMB 11. Skenario pengujian yang digunakan adalah menggunakan jumlah dataset 1100 yang menjadi data asli dan 2860 yang menjadi data hasil pre-processing augmentasi. Pengujian terbaik menggunakan data hasil augmentasi sebanyak 2640 data latih dan 220 data uji. Parameter sistem terbaik didapatkan akurasi pada ResNet 97.80%, VGGNet 95.45% dan AlexNet 98.18%.

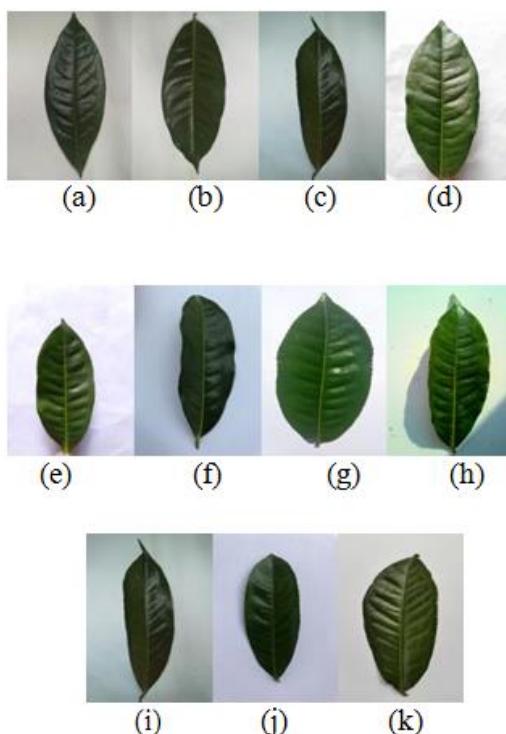
Kata Kunci: Klon teh seri GMB, Klasifikasi, CNN, ResNet, VGGNet, AlexNet

1. Pendahuluan

Indonesia merupakan salah satu negara dengan produsen teh terbesar di dunia. Produksi teh di Indonesia cukup tinggi dan menunjang kemajuan perekonomian Indonesia. Berdasarkan data dari Pusat Data dan Sistem Informasi Pertanian, produktivitas teh selama kurun waktu 1980-2016 cenderung meningkat dengan persentase 1,34% per tahun, namun saat ini kualitas dari hasil produksi teh di Indonesia semakin menurun. Produktivitas teh pada tahun 2016 sebesar 156.688 ton dan diperkirakan akan semakin menurun sampai tahun 2020 sebesar 153.970 ton. Presentase penurunan tiap tahunnya sebesar 0,11% (Nuryanti *et al.*, 2016). Penyebab utama penurunan kualitas tersebut diduga karena ketidaktelitian dalam pemilihan bibit, pengaruh polusi, dan cuaca yang bisa mempengaruhi perubahan warna daun, hama pada daun, dan bentuk daun yang tidak sempurna. Sampai saat ini, petani teh merupakan orang yang memiliki peranan penting dalam produksi teh. Keterbatasan petani teh untuk mengidentifikasi dan mengklasifikasi kualitas daun teh yang baik dengan akurat masih minim dan membutuhkan waktu yang lama dan tentu mempengaruhi perekonomian Indonesia dalam produktivitas teh ke pasar dunia (Pratama dan Adriani, 2015).

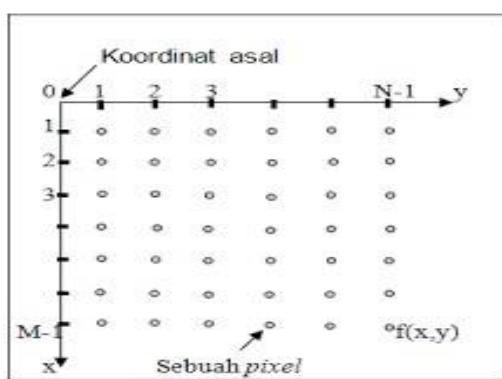
Ketelitian dalam memilih bibit unggul adalah solusi dalam meningkatkan produktivitas teh di Indonesia. Bibit klon teh yang banyak digunakan saat ini adalah klon teh seri GMB yang dihasilkan oleh Pusat Penelitian Teh dan Kina (PPTK), Kecamatan Pasirjambu, Kabupaten Bandung, Provinsi Jawa Barat. Sejak tahun 1988, bibit klon teh seri GMB terdiri dari GMB 1, GMB 2, GMB 3, GMB 4, dan GMB 5 dengan hasil produksi 3.500 kg/ha/tahun. Pada tahun 1998, Pusat Penelitian Teh dan Kina berupaya meningkatkan produktivitas teh dengan menambah bibit klon teh Gambung yang terdiri dari GMB 6 – GMB 11 dengan prediksi mampu menghasilkan produksi 5.000 kg/ha tahun. Saat ini klon seri GMB 1, GMB 3, GMB 4, GMB 7, dan GMB 9 menjadi bibit unggul diantara seri yang lain karena kualitas produktivitas dan waktu penanaman yang relatif lebih cepat dibandingkan klon seri jenis lainnya (Efendi *et al.*, 2010).

Klon teh seri GMB merupakan teh yang diproduksi dan melalui tahapan riset di PPTK. Klon teh Gambung mengandung banyak katekin dan anti-oksidan sehingga menghasilkan teh dengan kualitas yang baik, menyehatkan untuk dikonsumsi, dan mencegah berbagai penyakit. Klon teh seri GMB termasuk jenis spesies *camellia sinensis* varietas *assamica* dengan kadar antioksidan yang tinggi, cocok ditanam pada iklim tropis dan digunakan untuk produksi teh seperti teh hijau, teh hitam, dan teh olong. Klon teh seri GMB terdiri dari GMB 1, GMB 2, GMB 3, GMB 4, GMB 5, GMB 6, GMB 7, GMB 8, GMB 9, GMB 10, dan GMB 11. Klon teh GMB 6, GMB 7, dan GMB 9 cocok untuk ditanam pada segala daerah perkebunan, baik pada daerah rendah sampai dengan daerah tinggi. Sedangkan klon teh GMB 8, GMB 10, dan GMB 11 umumnya ditanam pada daerah tanam sedang sampai tinggi. Klon seri GMB 7 menjadi bibit berkualitas diantara klon seri lainnya, karena klon seri ini memiliki tingkat produktivitas yang tinggi. Tercatat rata-rata produktivitas dari klon seri GMB 7 ini adalah 3.500-5.000 kg/ha/tahun (Efendi *et al.*, 2010). Gambar 2 merupakan gambaran umum klon teh seri GMB 1 sampai dengan GMB 11.



Gambar 1. (a) Klon GMB 1; (b) Klon GMB 2; (c) Klon GMB 3; (d) Klon GMB 4; (e) Klon GMB 5; (f) Klon GMB 6; (g) Klon GMB 7; (h) Klon GMB 8; (i) Klon GMB 9; (j) Klon GMB 10; (k) Klon GMB 11

Citra digital merupakan data gambar dua dimensi yang diproses secara computer vision. Tujuan dari citra digital ini adalah mengimplementasikan computer vision sebagai *software* yang memiliki visi seperti manusia dalam hal melakukan input data, proses data, dan membuat kesimpulan hasil proses. Implementasi citra digital digunakan dalam berbagai bidang seperti pertanian, sosial, keamanan, kesehatan, industri, dan hiburan. Citra digital dibentuk oleh matriks berukuran $M \times N$, dimana M merupakan jumlah baris secara vertikal dan N adalah jumlah kolom secara horizontal (He *et al.*, 2015). Pertemuan antara titik M dan N disebut dengan piksel, seperti yang ditunjukkan oleh Gambar 2.

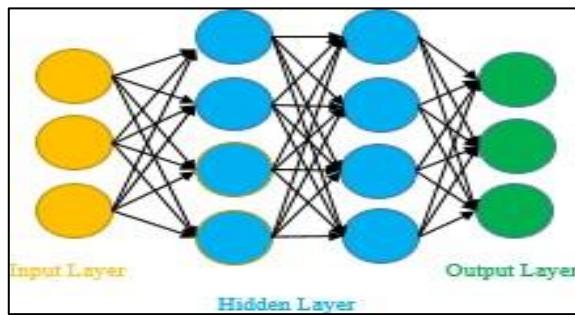


Gambar 2. Koordinat Citra Digital

Citra digital banyak digunakan untuk klasifikasi suatu objek berdasarkan perolehan nilai data citra. Sebelum dilakukan klasifikasi, citra diolah berdasarkan masalah yang sering muncul seperti ketajaman citra, *blurring*, dan bentuk yang tidak sesuai sehingga dapat menghambat pengenalan citra. Hal tersebut berguna untuk meningkatkan dan mendapatkan kualitas citra yang sesuai (Sulistiyanti dan Setyawan, 2016). Klasifikasi citra bertujuan untuk mengenali suatu objek secara spesifik. Metode yang digunakan dalam klasifikasi citra umumnya adalah *supervised learning* atau klasifikasi terbimbing yang merupakan metode klasifikasi melalui proses pembelajaran pada sistem dengan cara melatih model untuk mengenali objek berdasarkan data masukan yang sudah diberi label sampai semua data berhasil terbaca (Kushardono, 2017).

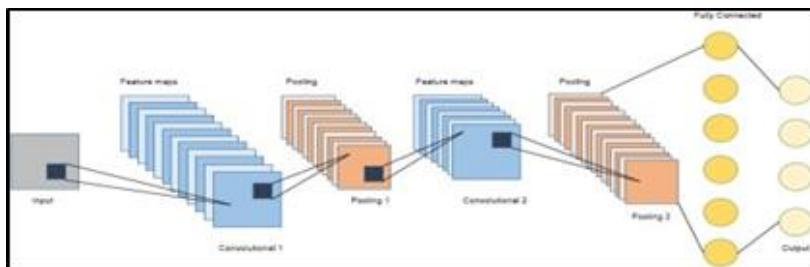
Machine Learning adalah suatu pembelajaran pada mesin terhadap suatu objek yang sifatnya berulang-ulang dan continue sehingga mesin memiliki tingkat kecerdasan sendiri. Umumnya konsep pembelajaran ini dibuat agar mesin memiliki kecerdasan yang tidak jauh berbeda dengan manusia. Kinerja dari mesin diukur dari seberapa besar mesin mampu memprediksi objek *dataset* dengan benar. *Machine Learning* terdiri dari dua konsep yaitu *supervised learning* merupakan konsep pembelajaran dengan melatih mesin terhadap data masukkan yang telah ditentukan. Proses pembelajaran dilakukan pada suatu objek sampai mesin mendapatkan jawaban dengan benar dan selanjutnya beralih kepada objek selanjutnya. Konsep kedua adalah *unsupervised learning* merupakan konsep pembelajaran pada mesin dengan proses pembelajaran secara serempak sehingga mesin tidak terlalu efektif seperti pada *supervised learning* (Simon *et al.*, 2015).

Deep Learning merupakan konsep *machine learning* dengan metode untuk mendeteksi fitur citra data berdasarkan kemampuan jaringan saraf tiruan (*neural network*) dan menggunakan algoritma dalam melakukan proses pada banyak lapisan untuk menghasilkan *output* yang lebih akurat. Jaringan saraf pada *deep learning* terdiri dari *input layer*, *hidden layer* dan *output layer*. Seperti pada Gambar 3. merupakan ilustrasi struktur jaringan saraf *deep learning* (Zhong *et al.*, 2019).



Gambar 3. Struktur Jaringan Saraf *Deep Learning*

Convolutional Neural Network (CNN) merupakan bagian dari *deep learning* yang diimplementasikan untuk pengolahan citra data dua dimensi dalam tingkat kedalaman lapisan yang tinggi dengan tujuan mampu mendeteksi dan mengklasifikasi citra data. CNN bekerja dengan input yang menembus beberapa lapisan untuk diproses sehingga menghasilkan *output* berupa hasil deteksi dan klasifikasi citra (Traoré *et al.*, 2018). Gambar 4. menunjukkan arsitektur CNN yang terdiri dari tiga *layer* utama yaitu *convolutional layer*, *pooling layer* dan *fully connected layer*.



Gambar 4. Arsitektur *Convolutional Neural Network*

Convolution Layer merupakan titik awal data input masuk ke lapisan CNN untuk dilakukan proses konvolusi dengan melalui beberapa filter untuk mendeteksi citra data. Proses konvolusi ini dilakukan dengan perkalian dot antara *input feature map* pada citra dengan suatu filter. Dari setiap *feature map* ditambahkan parameter yaitu *zero padding* atau penambahan jumlah pixel di setiap sisi *feature map* dengan nilai 0. Hal ini berguna agar tidak banyak data yang terbuang akibat dari konvolusi. Dalam proses perkalian *dot input feature map* dengan filter juga digunakan suatu parameter yang berguna untuk menentukan banyaknya pergeseran pixel pada *feature map* yang disebut *stride*. Fungsi aktivasi yang digunakan pada *layer* konvolusi ini adalah *Rectified Linear Unit* (ReLU) yang memiliki fungsi $f(x) = \max(0, x)$ yang artinya dilakukan aktivasi menggunakan nilai 0 terhadap *feature map* (Traoré *et al.*, 2018).

Pooling Layer merupakan lapisan yang memanfaatkan hasil dari proses konvolusi dengan kemampuannya untuk mempercepat proses deteksi CNN dengan memperkecil ukuran dimensi pada *feature map* hasil konvolusi dengan cara melakukan perhitungan pada matriks. Proses yang terjadi pada *pooling layer* adalah *max pooling* dan

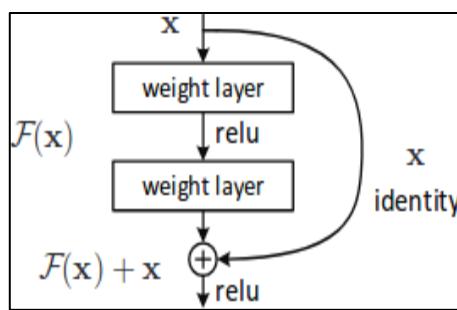
average pooling. Max pooling dilakukan untuk mengambil nilai tertinggi dari *feature map* dan *average pooling* berfungsi untuk menghitung nilai rata-rata dari *feature map* (Traoré *et al.*, 2018).

Fully Connected Layer merupakan proses akhir dari CNN dan menjadi tempat terhubungnya semua proses untuk dilakukan perhitungan setelah melalui beberapa lapisan untuk dilakukan pemetaan data. Hasil data dua dimensi *feature map* pada proses sebelumnya diubah menjadi satu dimensi, hal ini berguna untuk klasifikasi (Traoré *et al.*, 2018). Fungsi aktivasi yang digunakan menurut Pangestu dan Rahmat (2020) adalah sebagai berikut:

Dropout merupakan proses pembatasan neuron yang masuk dan dipilih secara random dan menghindari terjadinya overfitting. *Flatten* berfungsi untuk memetakan *feature map* menjadi suatu bentuk deretan vektor yang berguna untuk memudahkan klasifikasi tiap kelas. *Softmax* merupakan proses perhitungan nilai probabilitas dari suatu kelas untuk ditentukan kelas targetnya berdasarkan nilai *feature map* yang sudah *di-flatten* yang dinormalisasi menjadi nilai 0 atau 1. *Softmax* dapat dirumuskan sebagai berikut:

$$f(x) = \frac{e^{-xi}}{\sum_{z=1}^y e^{xz}}$$

Residual Neural Network merupakan arsitektur CNN yang terdiri dari beberapa variasi jenis *layer* diantaranya 18, 34, 50, 101, dan 152 *layer*. Tujuan dari arsitektur ResNet adalah melakukan pemetaan identitas data citra yang dilakukan dengan prinsip *skip connection* atau melewati beberapa *layer* untuk menghindari kehilangan *gradient*. Dapat dilihat seperti pada Gambar 5. menunjukkan blok *skip connection* dan Gambar 6. merupakan struktur arsitektur pada ResNet (He *et al.*, 2015).



Gambar 5. Blok Skip Connection

VGGNet adalah model CNN yang memanfaatkan *convolutional layer* dengan spesifikasi *convolutional filter* kecil atau (3*3). Karena mempunyai ukuran *convolutional filter* yang kecil maka kedalaman *neural network* bisa ditambah dengan beberapa *convolutional layer*. Dan hasil yang akan didapat adalah model CNN menjadi lebih akurat dari model CNN sebelumnya (Pangestu dan Bunyamin, 2018). VggNet yang menggunakan 16 *layer* akan mempunyai 13 lapisan konvolusi, 3 lapisan fully connected, dan 1 *softmax*. Arsitektur VGGNet dapat kita lihat pada Gambar 7.

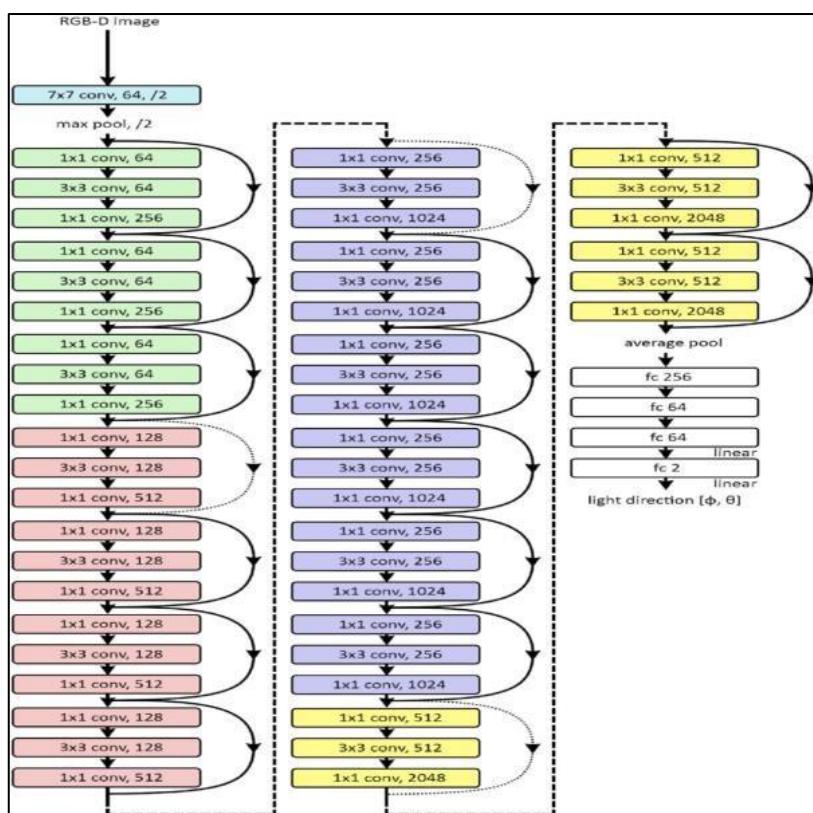
AlexNet diperkenalkan pada 2012, orang yang pertama kali merilis bernama Alex Krizhevsky, penulis pertama dari ImageNet Classification Paper. AlexNet, yang menggunakan 8 *layer* yang terdiri dari 5 *layer* konvolusi dan 3 *layer* *fully connected*, memenangkan *ImageNet Large Scale Visual Recognition Challenge* (ILSVRC) 2012 (Alom *et al.*, 2018) dengan besar margin yang cukup besar. Jaringan ini terbukti, untuk pertama kalinya, bahwa fitur yang diperoleh dengan deep learning dapat melampaui fitur desain secara manual, memecahkan paradigma sebelumnya dalam visi komputer. Secara garis besar, cara kerja sistem arsitektur Alexnet dibagi menjadi dua kelompok *layer*. Pertama adalah *layer* ekstrasi fitur yang tersusun dari *layer* konvolusi dan *pooling layer*, dan kedua adalah *classification layer*. Pemrosesan data pada arsitektur AlexNet ditunjukkan dengan Gambar 8.

Transfer Learning merupakan suatu konsep memberi informasi berdasarkan metode yang digunakan untuk dilatih dalam mengenali objek. Konsep ini bekerja pada sistem dengan memanfaatkan pengetahuan yang telah dipelajari pada jaringan sebelumnya untuk diterapkan kembali pada jaringan selanjutnya dan dilakukan secara berturut-turut sehingga sistem lebih mudah melakukan proses pembelajaran. *Transfer learning* ini terjadi bergantung pada *training step (epoch)* yang menjadi iterasi perputaran pembelajaran sistem dan batch size sebagai ukuran antrian data pembelajaran pada setiap step (Christodoulidis *et al.*, 2017).

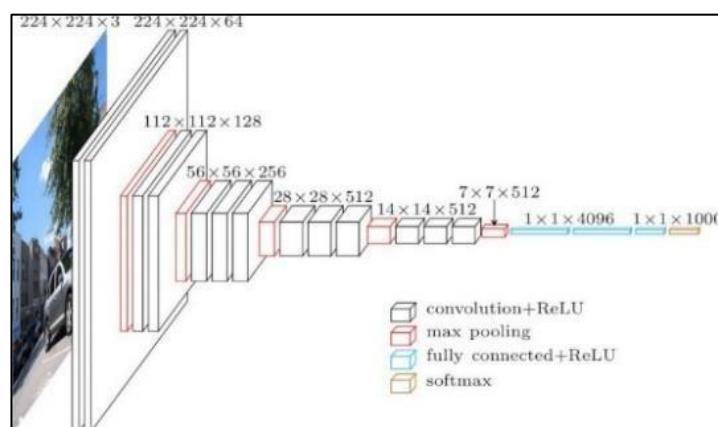
Fungsi *optimizer* merupakan parameter yang digunakan untuk meningkatkan pembelajaran pada sistem dengan menggunakan nilai learning rate atau tingkat pembelajaran tertentu dalam deteksi objek dan mengoptimalkan proses deep learning CNN yang melalui *layer* yang cukup dalam. Fungsi *optimizer* yang umum digunakan adalah *Adaptive with momentum* (Adam) dan *Stochastic Gradient Descent* (SGD). *Adaptive with momentum* adalah fungsi *optimizer* ini yang menjadi optimasi dari fungsi *optimizer* SGD yang memiliki keunggulan dalam

proses komputasi yang *lebih baik dari SGD dan banyak digunakan untuk jumlah data yang besar*. Nilai *learning rate* yang digunakan Adam adalah 0.001 (Kingma dan Ba, 2015). *Stochastic Gradient Descent* adalah fungsi *optimizer* ini bersifat stokastik atau mampu mengukur suatu peristiwa dengan data yang tidak stabil. SGD pada proses *machine learning* menggunakan tingkat pembelajaran atau *learning rate* sebesar 0.01 (Kingma dan Ba, 2015).

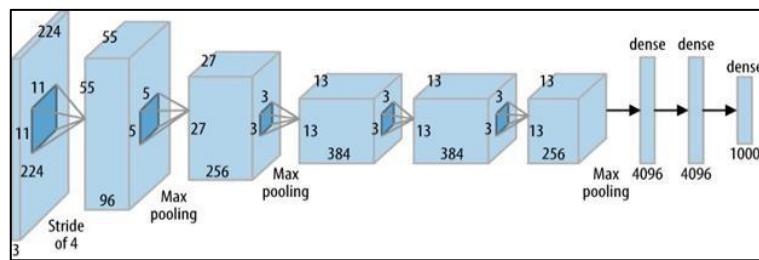
Tujuan dari penelitian ini adalah mengidentifikasi citra jenis klon teh berdasarkan bentuk dan pola daun untuk diklasifikasikan ke dalam seri jenis klon teh GMB 1 – GMB 11. Data citra yang digunakan adalah sebanyak 2640 data latih dan 220 data uji. CNN merupakan metode deep learning yang digunakan pada penelitian ini yang terdiri dari beberapa lapisan untuk klasifikasi citra data dua dimensi dalam identifikasi objek dengan kinerja sistem yang dinilai memiliki tingkat pembelajaran citra data yang baik. Arsitektur CNN yang digunakan adalah ResNet, VGGNet, dan AlexNet yang memiliki kedalaman *layer* yang bervariasi untuk mendeteksi objek dengan kemampuan lebih praktis untuk membawa data melewatkkan ke *layer* yang lebih dalam (He *et al.*, 2015).



Gambar 6. Struktur Arsitektur ResNet



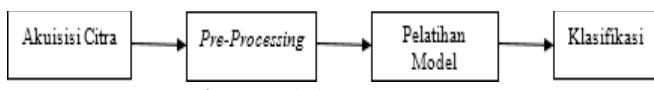
Gambar 7. Arsitektur VGGNet

**Gambar 8.** Arsitektur AlexNet

2. Metode

2.1. Desain Sistem

Penelitian ini bertujuan untuk merancang suatu sistem dengan menggunakan proses dan metode tertentu agar mampu mendeteksi dan mengklasifikasi citra klon daun teh seri GMB sesuai dengan kelasnya masing-masing. Sistem yang akan dirancang pada penelitian ini seperti Gambar 9.

**Gambar 9.** Blok Diagram Sistem

2.2. Akuisisi Data

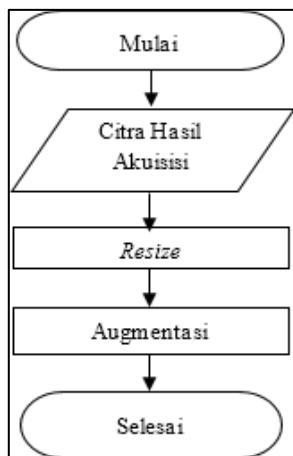
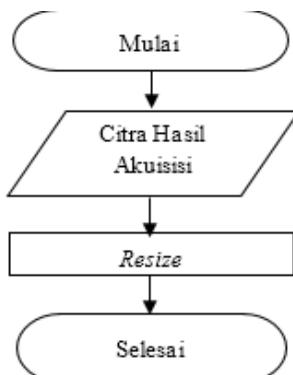
Akuisisi citra merupakan tahap awal dalam penelitian ini dengan melakukan pengambilan dan pengumpulan *dataset* objek klon daun teh seri GMB menjadi suatu data citra digital. Proses akuisisi citra ini dilakukan sebanyak 1100 citra daun teh yang terdiri dari seri GMB 1 sampai dengan GMB 11. Citra daun teh ini masing-masing berjumlah 100 citra tiap GMB dengan cara diambil gambarnya menggunakan kamera handphone. Penelitian ini menggunakan 80% data latih dan 20% data uji dari total citra berdasarkan tiap GMB.

**Gambar 10.** Contoh Akuisisi Menggunakan Kamera Handphone

2.3. Pre-processing

Pre-processing merupakan proses pengolahan data citra hasil dari akuisisi. Tujuan dari *pre-processing* ini adalah untuk meningkatkan kualitas citra dengan cara memperbaiki atau mengolah citra secara spesifik agar mudah dikenali guna dilakukan proses klasifikasi pada sistem. Gambar 11. dan Gambar 12. menunjukkan *flowchart* proses *pre-processing* yang terjadi pada penelitian kali ini.

Data Uji Gambar 11. dan Gambar 12. menjelaskan *pre-processing* dengan proses terjadinya *resize* yang merupakan proses mengubah ukuran pixel pada citra yang pada awalnya terdiri dari ukuran yang berbeda-beda menjadi satu ukuran yang sama dan *augmentasi* merupakan proses untuk mendapatkan *dataset* yang lebih banyak dengan cara membuat variasi bentuk dari data asli untuk meningkatkan kinerja dari sistem dalam mempelajari citra objek. Sebelumnya *dataset* yang telah terkumpul sebanyak 1,100 dan diaugmentasi menjadi 2,860 *dataset* namun yang diambil sebesar 80% sesuai dengan tujuan penelitian ini yaitu 2,640 *dataset* untuk data *training* dan untuk data uji diambil dari *dataset* sebelum *augmentasi* sebesar 20% yaitu 220 *dataset*.

Gambar 11. Proses *Pre-Processing* Data LatihGambar 12. Proses *Pre-Processing*

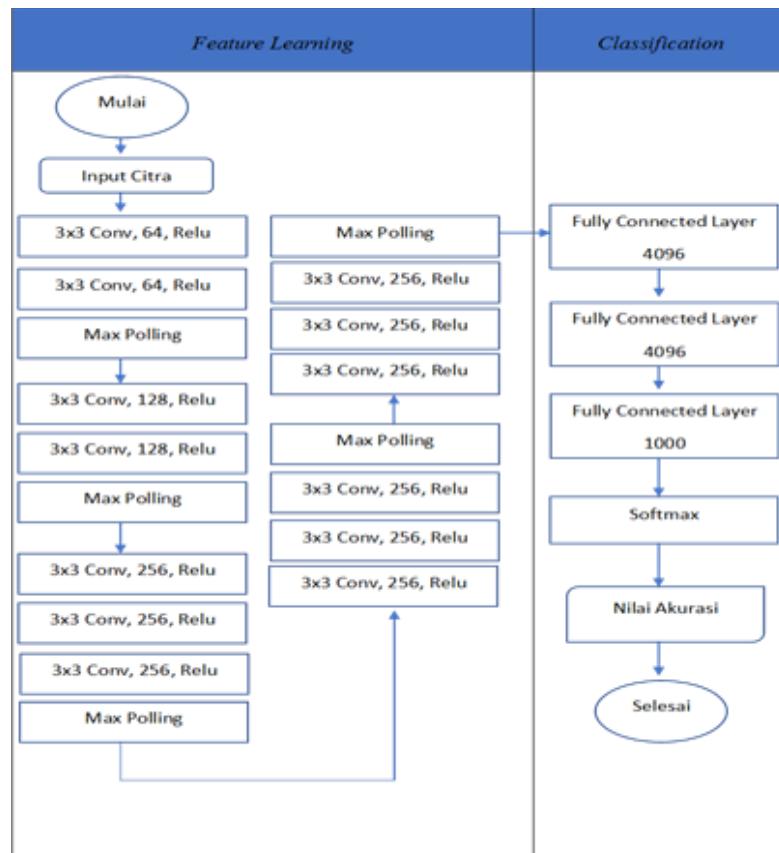
2.4. Pelatihan Model

Pelatihan model bertujuan agar sistem dapat mengenali objek dan mengklasifikasikannya sesuai dengan masing-masing kelas. ResNET, VGGNet, dan AlexNet menjadi arsitektur CNN yang digunakan dalam penelitian ini. Model ResNet yang digunakan adalah ResNet-101 yang terdiri dari 100 *layer CNN* dan 1 *layer fully connected*. Proses pelatihan model ResNet-101 dapat dilihat pada Gambar 13. Model VGGNet yang digunakan adalah VGG-Net-16 yang terdiri dari 16 *layer CNN* yang terdiri dari 13 *convolution layer*, 3 *fully connected layer*, dan 1 *softmax*. Proses pelatihan model VGGNet-16 dapat dilihat pada Gambar 14. Model AlexNet yang digunakan adalah AlexNet-8 yang terdiri dari 8 *layer CNN* yang terdiri dari 5 *convolution layer*, 3 *fully connected layer*, dan 1 *softmax*. Proses pelatihan model AlexNet-8 dapat dilihat pada Gambar 15.

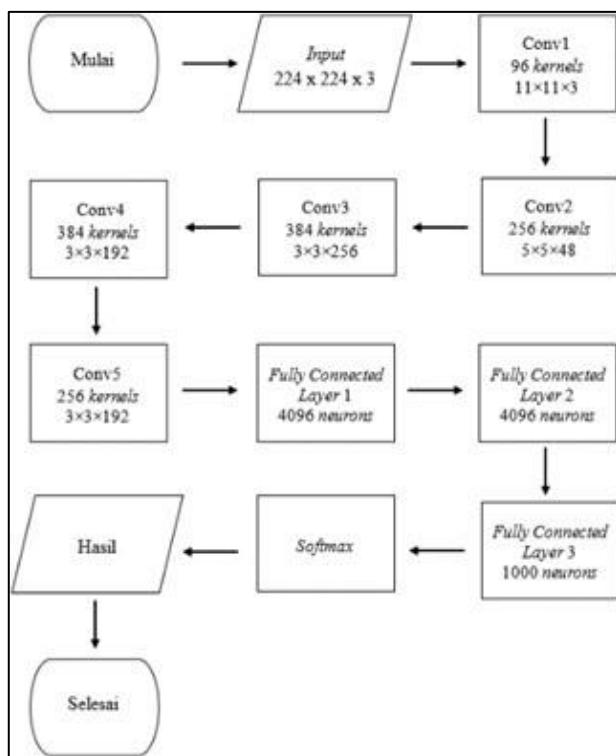
Berdasarkan Gambar 13, 14, dan 15 adalah pelatihan model ResNet-101, VGGNet-16, dan AlexNet-8 yang mempunyai jumlah konvolusi yang berbeda-beda. Perancangan sistem penelitian ini menambahkan parameter *zero padding* pada *layer* pertama konvolusi dan *batchnormalization* setelah setiap proses konvolusi yang berguna untuk mengurangi data informasi yang hilang dan menormalkan sumbu aliran. Fungsi aktivasi yang digunakan pada *layer fully connected* yaitu *flatten* yang berfungsi untuk membuat susunan data, *dropout* berfungsi untuk membatasi *neuron* yang masuk, dan *softmax* merupakan fungsi aktivasi untuk menghitung probabilitas dari data hasil pelatihan terhadap objek yang terdiri dari beberapa kelas.



Gambar 13 . Blok Proses Pelatihan Model ResNet- 101



Gambar 14. Blok Proses Pelatihan Model VGGNet-16



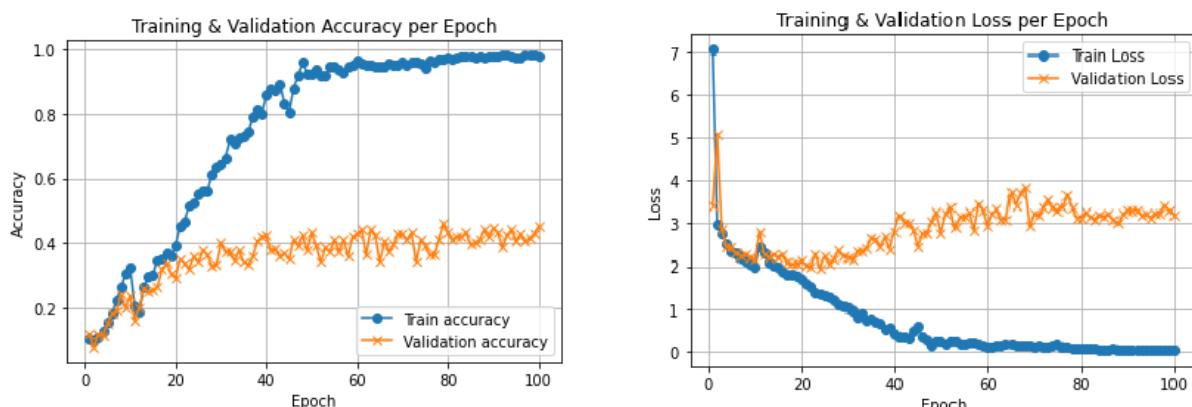
Gambar 15. Blok Proses Pelatihan Model AlexNet-8

3. Hasil dan Pembahasan

Pengujian pada sistem yang telah dibuat sesuai dengan metode yang digunakan untuk mengetahui tingkat akurasi dan *loss* dari sistem dalam klasifikasi *dataset* citra klon teh dari GMB 1-11. Sistem pengujian dibentuk dengan memanfaatkan perubahan parameter pada jumlah *dataset* sebelum augmentasi, jumlah *dataset* setelah augmentasi, jenis *optimizer*, dan banyaknya iterasi pelatihan (*epoch*).

3.1. 3.1 Pengujian ResNet Menggunakan 1100 Dataset

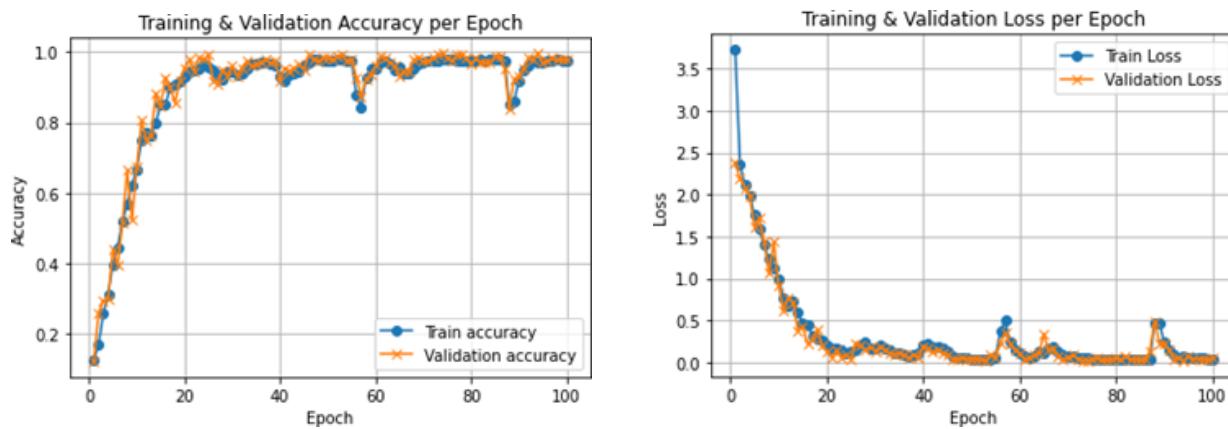
Skenario pengujian ResNet-101 pada sistem parameter yang pertama adalah membandingkan hasil tingkat akurasi dan *loss* berdasarkan jumlah *dataset* 1100. Sistem terbaik yang dihasilkan menggunakan parameter *epoch* 100, *batch_size* 32, *optimizer* Adam dan *learning rate* 0.001. Hasil yang didapatkan adalah *training accuracy* 0,9784 dengan *validation accuracy* 0,4500 dan *training loss* 0,0438 dengan *validation loss* 3,1909. Berdasarkan hasil yang didapatkan bahwa selisih antara nilai *training* dan *validation* masih cenderung berbeda jauh sehingga sistem belum mampu mengenali objeknya dengan baik. Grafik hasil pengujian ResNet-101 dengan menggunakan 1100 *dataset* atau data asli dapat dilihat pada Gambar 16.



Gambar 16. Grafik Hasil Pengujian Data Asli

3.2. Pengujian ResNet Menggunakan 2860 Dataset

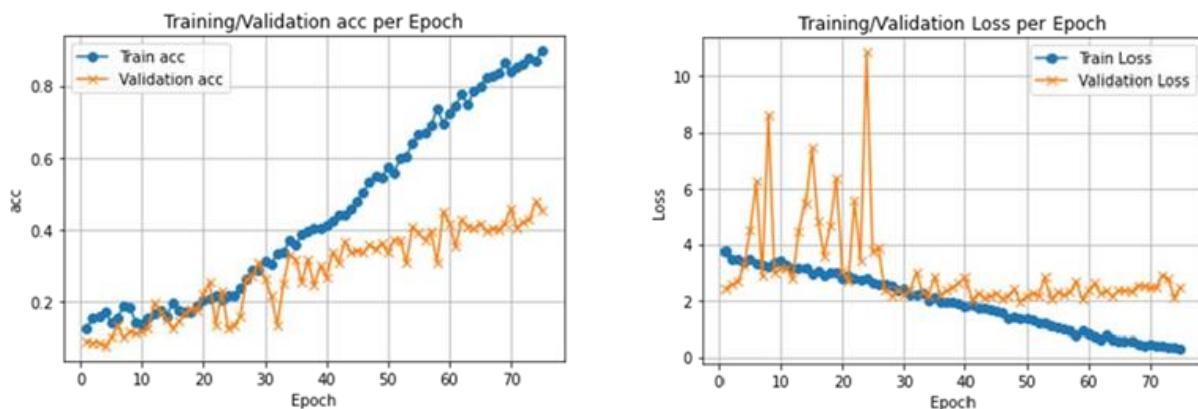
Skenario pengujian ResNet-101 pada sistem parameter yang kedua adalah membandingkan hasil tingkat akurasi dan *loss* berdasarkan jumlah *dataset* 2860. Sistem terbaik yang dihasilkan menggunakan parameter *epoch* 100, *batch_size* 32, *optimizer* Adam dan *learning rate* 0,001. Hasil yang didapatkan adalah *training accuracy* 0,9750 dengan *validation accuracy* 0,9773 dan *training loss* 0,0438 dengan *validation loss* 0,0537. Berdasarkan hasil yang didapatkan bahwa selisih antara nilai *training* dan *validation* tidak terlalu berbeda sehingga sistem sudah bisa dikatakan berhasil dalam mengenali objeknya dengan baik. Grafik hasil pengujian ResNet-101 dengan menggunakan 2860 *dataset* atau data augmentasi dapat dilihat pada Gambar 17.



Gambar 17. Grafik Hasil Pengujian Data Augmentasi

3.3. Pengujian VggNet 1100 Dataset

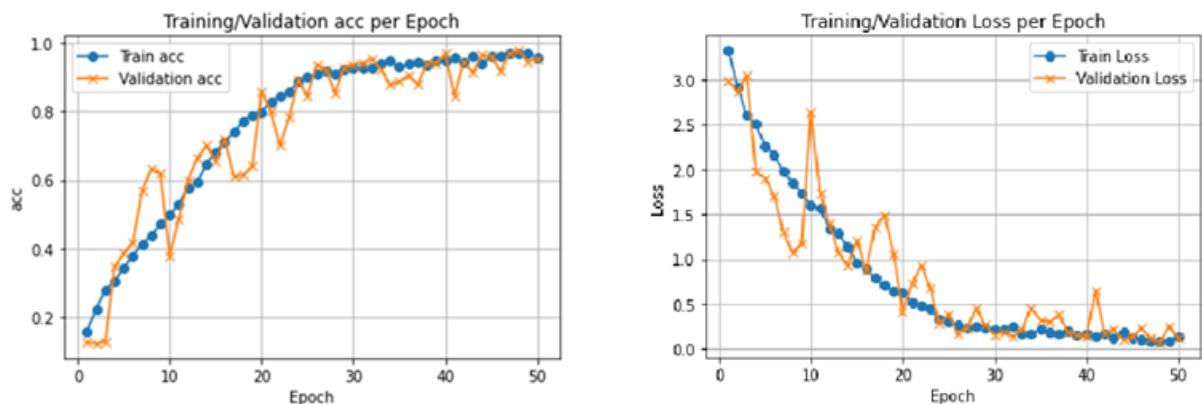
Dalam *dataset* 1100 atau data asli mendapatkan skenario terbaik dengan terbentuknya beberapa parameter. Parameter terbaik tersebut adalah *Size Citra* 224×224 , *Optimizer* RMSprop, *Learning Rate* 0,0001, dan *Epoch* 75. Hasilnya mendapatkan *training accuracy* sebesar 0,3028 dan *testing (validation) accuracy* sebesar 0,4545. Untuk hasil *loss* mendapatkan *training loss* sebesar 0,8966 dan *testing (validation) loss* sebesar 2,4782. Grafik hasil untuk *dataset* 1100 masih mengalami *overfitting*. Grafik hasil pengujian *dataset* 1100 atau data asli dapat dilihat pada Gambar 18.



Gambar 18. Grafik Hasil Pengujian Data Asli

3.4. Pengujian VggNet 2860 Dataset

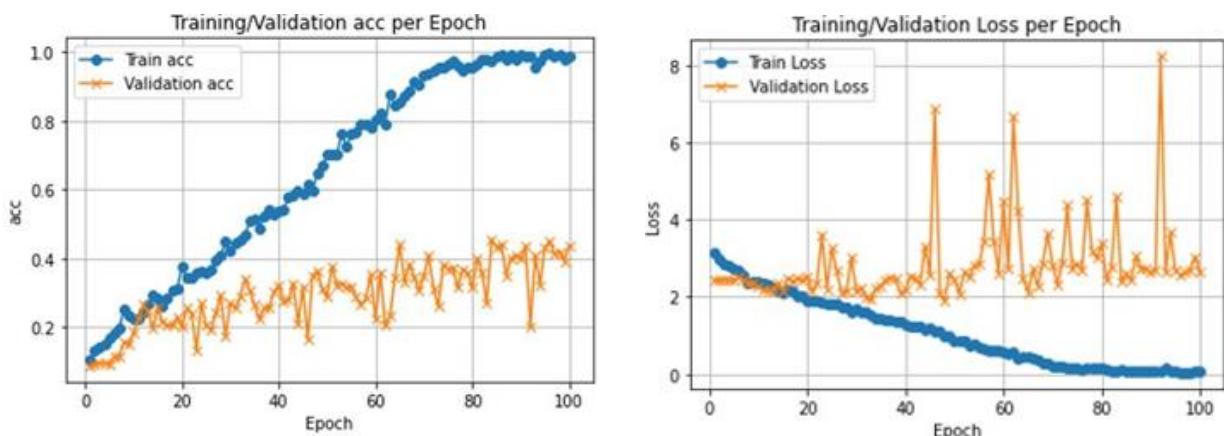
Dalam *dataset* 2860 atau data augmentasi mendapatkan skenario terbaik dengan terbentuknya beberapa parameter. Parameter terbaik tersebut adalah *Size Citra* 224×224 , *Optimizer* Adam, *Learning Rate* 0,0001, dan *Epoch* 50. Hasilnya mendapatkan *training accuracy* sebesar 0,9583 dan *testing (validation) accuracy* sebesar 0,9545. Untuk hasil *loss* mendapatkan *training loss* sebesar 0,1324 dan *testing (validation) loss* sebesar 0,1292. Grafik hasil untuk *dataset* 2860 tidak mengalami *overfitting*. Grafik hasil pengujian *dataset* 2860 atau data augmentasi dapat dilihat pada Gambar 19.



Gambar 19. Grafik Hasil Pengujian Data Augmentasi

3.5. Pengujian AlexNet 1100 Dataset

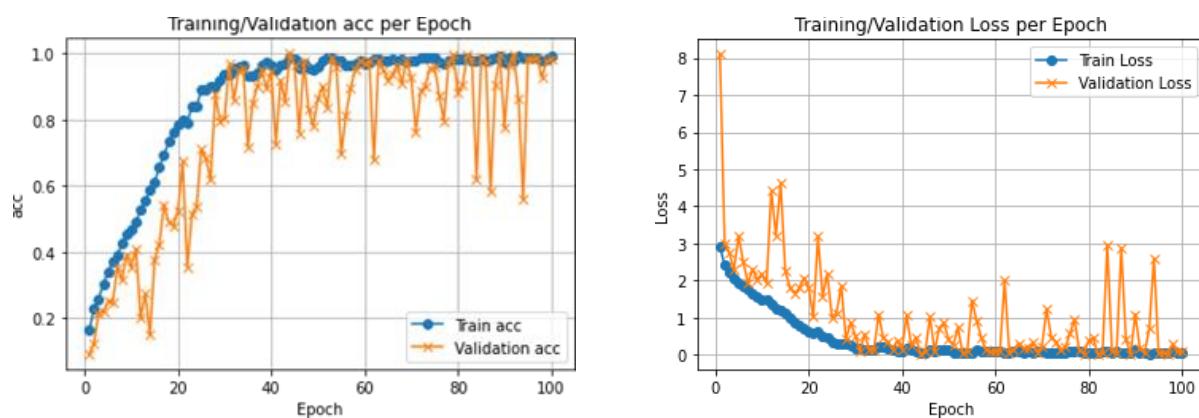
Parameter terbaik pada *dataset* 1100 atau data asli adalah menggunakan *Optimizer* SGD dengan nilai *learning rate* 0,01, dan nilai *epoch* 100. Hasil dari pelatihan menggunakan parameter tersebut mendapatkan akurasi pelatihan (*training accuracy*) 0,9886, dan akurasi pengujian (*testing accuracy*) 0,4364. Untuk hasil *loss* pada *training loss* mendapatkan 0,0503 dan *testing (validation) loss* 2,6509. Grafik yang didapat dari proses pelatihan dan pengujian ini masih mengalami *overfitting* atau hasil dari proses pelatihan belum sesuai dengan hasil pada proses pengujian sehingga didapat grafik akurasi dan *loss* seperti yang ditunjukkan pada Gambar 20.



Gambar 20. Grafik Hasil Pengujian Data Asli

3.6 Pengujian AlexNet 2860 Dataset

Pada *dataset* 2860 atau data augmentasi didapat skenario terbaik dari berbagai parameter yang ditentukan. Parameter yang didapat adalah menggunakan *optimizer* Adam dengan menggunakan nilai *learning rate* 0,001 dan nilai *epoch* 100. Hasil dari pelatihan menggunakan parameter tersebut mendapatkan nilai *training accuracy* 0,9871 dan *testing accuracy* sebesar 0,9818. Kemudian untuk *training loss* nya mendapatkan nilai sebesar 0,0444 dengan nilai *testing loss* yang didapat sebesar 0,0936. Grafik yang didapat dari hasil proses pelatihan dan pengujian untuk data augmentasi sudah optimal karena proses pelatihan sudah sesuai dengan proses pengujian. Grafik tersebut dapat dilihat pada Gambar 21.



Gambar 21. Grafik Hasil Pengujian Data Augmentasi

4. Kesimpulan

1. Perancangan sistem pengolahan citra dengan menggunakan metode CNN dan arsitektur ResNet, VGGNet, dan AlexNet mampu mengklasifikasikan daun teh Gambung klon seri GMB 1 sampai dengan GMB 11.
2. Pengujian terbaik dari penelitian ini adalah menggunakan parameter total *dataset* 2860 di semua arsitekturnya, seperti ResNet, VGGNet, dan AlexNet.
3. Pada Arsitektur ResNet didapatkan pada *optimizer* Adam, learning rate 0.001, dan *epoch* 100. Parameter tersebut menghasilkan tingkat akurasi 97,8%, *loss* 2,2%, dan presisi 97,9% dalam mengklasifikasi citra klon teh.
4. Pada Arsitektur VGGNet didapatkan pada *optimizer* Adam, learning rate 0,0001, dan *epoch* 50. Parameter tersebut menghasilkan tingkat akurasi 95,45%, *loss* 4,55%, dan presisi 95,81% dalam mengklasifikasi citra klon teh.
5. Pada Arsitektur AlexNet didapatkan pada *optimizer* Adam, learning rate 0.001, dan *epoch* 100. Parameter tersebut menghasilkan tingkat akurasi 98,18%, *loss* 1,82%, dan presisi 98,31% dalam mengklasifikasi citra klon teh.

Daftar Pustaka

- Alom, M. Z.; Taha, T.M.; Yakopcic, C.; Westberg, S.; Sidike, P.; Nasrin, M.S; Van Esen, B.C.; Awwal, A. A. S.; Asari V. K. The history began from alexnet: A comprehensive survey on deep learning approaches. arXiv preprint arXiv:1803.01164 2018, 53.
- Christodoulidis, S.; Anthimopoulos, M.; Ebner, L.; Christe, A.; Mougiakakou, S. Multisource Transfer Learning with Convolutional Neural Networks for Lung Pattern Analysis. *IEEE J. Biomed. Heal. Informatics* 2017, Volume 21 (1), 1–3.
- Effendi, D. S.; Syakrir, M.; Yusron, M.; Wiratno. Teh Budidaya dan Pengolahan Pascapanen. Pusat Penelitian dan Pengembangan Perkebunan: Bogor, Indonesia, 2010.
- Gonzalez, T. F. Handbook of approximation algorithms and metaheuristics. Handb. Approx. Algorithms Metaheuristics 2007, 1–1432.
- He, J. S. K.; Zhang, X.; Ren, S. Deep Residual Learning for Image Recognition. CVPR 2015, Voloume 1, 1–9.
- Kingma, D. P. dan Ba, J. L. Adam: A method for stochastic optimization. 3rd Int. Conf. Learn. Represent 2015, 1–10.
- Kushardono, D. Klasifikasi Digital pada Penginderaan Jauh. IPB Press: Bogor, Indonesia, 2017.
- Sulistiyanti, M. K. S. R. dan Setyawan, F. A. Pengolahan Citra Dasar Dan Contoh Penerapannya. Teknosain: Yogyakarta, Indonesia, 2016.
- Nuryati, L.; Yasin, A.; R.Zikria, Outlook Teh. Pusat Data dan Sistem Informasi Pertanian: Jakarta, Indonesia, 2016.
- Pangestu, F. T. A. R. A. dan Rahmat, B. Implementasi Algoritma CNN untuk Klasifikasi Citra Lahan dan Perhitungan Luas. *Inform. dan Sist. Inf.* 2020, Volume 1 (1), 166–174.
- Pangestu, M. A. dan Bunyamin, H. Analisis Performa dan Pengembangan Sistem Deteksi Ras Anjing pada Gambar dengan Menggunakan Pre-Trained CNN Model. *Tek. Inform. dan Sist. Inf.* 2018, Volume 4 (2), 337–344.
- Pratama, A. R. dan Andriani, D. R. Analysis of the Factors That Affected Tea Pickers Productivity in Ptpn XII (Persero) Kebun Wonosari. *Habitat* 2015, Volume 26 (1), 1–9.
- Simon, D. R. R. B. A.; Deo, M. S.; Venkatesan, S. An Overview of Deep Learning and Its Applications. ResearchGate 2015, Volume 1 (1), 22–44.
- Sukardi, M. R.; Arifin, Z. Klasifikasi Penentuan Gambar Berbasis Tensorform dan Framework dengan Algoritma CNN. Semin. Nas. APTIKOM 2017,1–4.

Traoré, B. B.; Kamsu-foguem, B.; Tangara, F.; Traoré, B. B.; Kamsu-foguem, B.; Tangara, F. Deep Convolution Neural Network For Image Recognition. *Ecol. Inform.* 2018, Volume 48 (1), 257–268.

Zhong, G.; Zhang, K.; Wei, H.; Zheng, Y.; Dong, J. Marginal Deep Architecture: Stacking Feature Learning Modules to Build Deep Learning Models. *IEEE Access* 2019, Volume 7 (1), 30220–30233.