

Klasifikasi Tingkat Kematangan Pucuk Daun Teh menggunakan Metode *Convolutional Neural Network*

NUR IBRAHIM¹, GITA AYU LESTARY², FANIESA SAUFANA HANAFI³,
KHAERUDIN SALEH⁴, NOR KUMALASARI CAECAR PRATIWI⁵, MUTHIA
SYAFIKA HAQ⁶, ADHI IRIANTO MASTUR⁷

^{1,2,3,4,5}Universitas Telkom, Indonesia

^{6,7}Pusat Penelitian Teh dan Kina (PPTK) Gamboeng, Indonesia

Email: nuribrahim@telkomuniversity.ac.id

Received 6 Agustus 2021 | *Revised* 15 September 2021 | *Accepted* 17 Oktober 2021

ABSTRAK

Indonesia merupakan salah satu negara besar pengekspor teh di dunia. Luasnya area perkebunan teh menyebabkan setiap blok tanam daun teh memiliki waktu petik dan tingkat kematangan yang berbeda. Sehingga salah satu upaya untuk mengetahui tingkat kematangan daun teh yaitu menerapkan sistem otomatisasi menggunakan pengolahan citra digital. Pada penelitian ini dirancang sebuah sistem klasifikasi tingkat kematangan pucuk daun teh dari jenis sampel varietas Assamica Klon (GMB 7) yang berada pada Pusat Penelitian Teh dan Kina Gambung. Penelitian ini menerapkan metode pengolahan citra digital dengan algoritma Convolutional Neural Network (CNN) menggunakan Arsitektur VGGNET19 dan ResNet50. Hasil pengujian sistem memperoleh nilai akurasi terbaik sebesar 97.5% dengan menggunakan arsitektur VGGNET19, Optimizer RMSprop, learning rate 0.01, batch size 32 dan epoch 100.

Kata kunci: *teh, klasifikasi, Convolutional Neural Network, VGGNET19, ResNet50*

ABSTRACT

Indonesia is one of the major tea exporting countries in the world. The large area of tea plantations causes each tea leaves planting block to have a different picking time and maturity level. So that one of the efforts to determine the maturity level of tea leaves is to apply an automation system using digital image processing. In this study, a classification system for the maturity level of tea leaves design from the Assamica Klon (GMB 7) variety sample located at the Gambung Tea and Quinine Research Center. This study applies a digital image processing method with the Convolutional Neural Network (CNN) algorithm using VGGNET19 and ResNet50 Architecture. The results of the system test obtained the best accuracy value of 97.5% using the VGGNET19 architecture, RMSprop Optimizer, learning rate 0.01, batch size 32 and epoch 100.

Keywords: *tea, classification, Convolutional Neural Network, VGGNET19, ResNet50*

1. PENDAHULUAN

Teh merupakan jenis tanaman yang memiliki banyak khasiat sebagai obat herbal. Teh dianggap sebagai sumber potensial antioksidan yang sehat. Teh atau *Camelia Sinensis* hidup pada kawasan beriklim tropis dengan ketinggian 200 - 2000 m di atas permukaan laut serta bertemperatur antara 14 - 25 derajat celcius. Sebagai salah satu negara yang menduduki peringkat besar untuk pengeksport teh di dunia (**Sita & Rohdiana, 2021**), maka mutu dan kualitas teh di Indonesia sangat diperhatikan. Penentuan kematangan pucuk daun teh dapat diklasifikasikan dari periode pemetikan sebelumnya. Periode pemetikan tergantung pada umur, kecepatan pembentukan tunas, ketinggian, iklim dan kesehatan tanaman. Pada umumnya perkebunan teh memiliki lahan yang cukup luas dan proses pengklasifikasian tingkat kematangan pucuk daun teh yang dilakukan oleh perusahaan pengolah maupun para petani masih secara manual berdasarkan penerapan aturan gilir petik, dimana aturan ini disesuaikan dengan kecepatan pertumbuhan pucuk dan umur pemangkasan terakhir terhadap tanaman teh. Penerapan aturan gilir petik menyebabkan petani tidak dapat mengetahui seluruh tingkat kematangan tanaman karena luasnya area perkebunan teh yang memiliki waktu petik dan tingkat kematangan yang berbeda pada setiap blok tanam daun teh. Salah satu upaya dalam mempermudah petani untuk mengetahui tingkat kematangan daun teh adalah dengan menerapkan sistem otomatisasi menggunakan pengolahan citra digital.

Beberapa penelitian yang menerapkan pengolahan citra digital telah dilakukan. Pada penelitian sebelumnya terkait identifikasi kematangan daun teh menggunakan metode ekstraksi ciri seperti *Hue Saturation Intensity* (HSI) dan *Hue Saturation Value* (HSV) (**Auliasari, dkk, 2020**) menghasilkan tingkat akurasi 100% dan 83,33%. Pada penelitian (**Wicaksono, dkk, 2019**) tentang identifikasi kematangan daun teh menggunakan *Centroid Clustering* berbasis ruang warna YCbCr menghasilkan nilai akurasi sebesar 80%. Penelitian lainnya tentang Identifikasi Jenis Tumbuhan menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur Alexnet (**Ilahiyah & Nilogiri, 2018**) mendapatkan nilai akurasi sebesar 90 %. Selanjutnya dilakukan penelitian klasifikasi jenis daun teh gambung menggunakan metode CNN dengan arsitektur Mobilenet (**Jaelani, dkk, 2020**), Alexnet (**Hayat, dkk, 2020**) dan LeNet-5 (**Suherman, dkk, 2021**), masing-masing memperoleh nilai akurasi 60%, 98,18% dan 94,55%. Apabila melihat dari hasil penelitian sebelumnya masih belum terdapat penelitian yang membahas berkaitan dengan klasifikasi kematangan daun teh menggunakan metode CNN, sehingga pada penelitian ini dilakukan pengklasifikasian tingkat kematangan pucuk daun teh menggunakan metode CNN dengan Arsitektur *Visual Geometry Group 19* (VGGNet19) dan *Residual Neural Network* (ResNet), yaitu ResNet50 yang memiliki 50 *layer*.

1.1 Tanaman Teh

Teh merupakan jenis tanaman dengan nama latin *Camellia Sinensis* yang kebanyakan hidup di wilayah tropis. Karakteristik tanaman teh adalah batangnya lebih tegak dan daunnya tunggal tumbuh berselang-seling, daun tehnya lonjong dan memiliki tulang runcing yang berbulu di ujungnya. Tepi daun teh tajam dengan gerigi halus. Dibandingkan dengan daun teh tua, daun teh muda warnanya lebih terang dan ukurannya lebih lebar. Warna daun teh tua berwarna hijau tua, dan permukaan daunnya lebih licin dibandingkan daun teh muda.

1.2 Klon Teh Gambung

Teh varietas *Assamica* klon GMB 7 yang ditunjukkan merupakan salah satu varietas teh yang ditanam pada Pusat Penelitian Teh dan Kina (PPTK) Gambung. Teh varietas *Assamica* klon GMB 7 memiliki usia petik dalam kurun waktu kurang lebih 1 bulan atau 28 hari. Varietas ini dipilih karena mempunyai ketahanan terhadap hama yang baik dan memiliki potensi produksi tinggi. Teh varietas *Assamica* klon GMB 7 memiliki ciri-ciri daun atau pucuk berbentuk elips

yang ukurannya besar dan lebar, permukaan daun bergelombang agak mengkilat dan tepi daunnya bergerigi teratur dan ujung daun runcing (**Karyudi, 2014**).



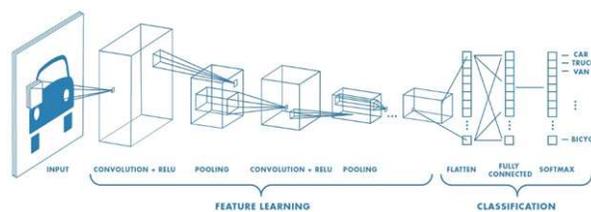
Gambar 1. Citra Pucuk Daun Teh dalam Berbagai Kelas

1.3 Pengolahan Citra

Pengolahan citra merupakan teknik memproses citra dengan komputer agar keluarannya berupa citra sesuai kebutuhan (**Al-Falah, dkk, 2019**). Teknik pengolahan citra digital dilakukan untuk meningkatkan kualitas gambar supaya mudah dipahami oleh manusia dan mesin komputer (**Effendi, dkk, 2017**). Pada umumnya proses pengolahan citra digital dilakukan dengan mengolah citra yang terdiri dari penajaman citra, kompresi citra, perbaikan citra, klasifikasi citra, penonjolan fitur tertentu dari suatu citra dan bentuk yang tidak sesuai sehingga dapat memperlambat proses pengenalan citra (**Muhimmah dkk, 2018**).

1.4 Convolutional Neural Network

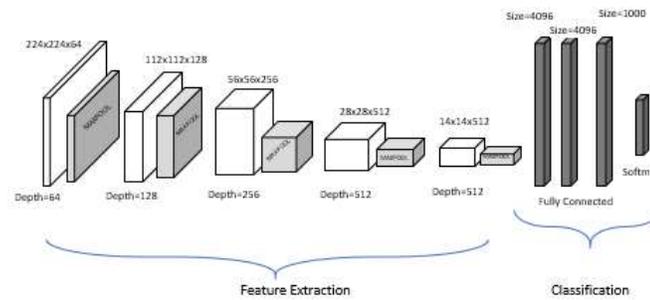
CNN merupakan suatu teknik dari *deep learning*. Pada prinsipnya, CNN meniru *visual cortex* pada mamalia. Jaringan CNN tersusun dalam tiga dimensi, sehingga memiliki panjang, lebar dan tinggi. Algoritma CNN adalah salah satu teknik yang sangat baik dalam menganalisis objek pada *image/gambar* (**Primartha, 2018**). Arsitektur jaringan CNN diinformasikan oleh Gambar 2. Konfigurasi Arsitektur CNN terdiri dari masukkan, proses ekstraksi fitur, proses klasifikasi serta keluaran. CNN mempunyai dua bagian yaitu *Feature Learning* dan *Classification*. Pada proses ekstraksi di CNN terdiri dari sejumlah *hidden layer*, yaitu *convolution layer*, *activation function* (ReLU), dan *pooling*. Sementara pada proses klasifikasi terdiri dari *fully connected layer* dan *activation function* (*softmax*) yang keluarannya adalah hasil klasifikasi.



Gambar 2. Struktur Jaringan CNN (Santoso & Ariyanto, 2018)

1.5 Visual Geometry Group Network (VGGNet)

VGGNet ialah arsitektur CNN yang dirancang oleh Karen Simonyan serta Andrew Zisserman untuk berpartisipasi diajang kompetisi ImageNet Challenge 2014. *Input* yang digunakan berupa gambar *Red Green Blue* (RGB) dengan dimensi 224×224 *pixel* (**Taslim, dkk, 2019**). Gambar 3 merupakan arsitektur VGGNet. Arsitektur VGG terbagi menjadi dua yaitu VGG-16 dan VGG-19. Pada *convolutional layer* memiliki jumlah *layer* bermacam-macam. Setiap akhir *convolutional layer* memakai aktivasi *Relu* dan proses *pooling layer* memakai *max pooling*. Pada *layer* terakhir yaitu *fully connected* menggunakan 4096 neuron yang selanjutnya adalah aktivasi *softmax*.



Gambar 3. Arsitektur VGGNet

1.6 Residual Neural Network (ResNet)

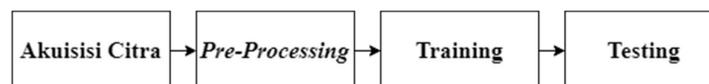
ResNet merupakan salah satu jenis arsitektur pada CNN. ResNet pertama kali diperkenalkan dan dibangun oleh **(He, dkk, 2016)** dan memenangkan kompetisi ILSVRC pada tahun 2015. Agar memiliki performansi yang baik, salah satu syarat penting untuk membangun model CNN adalah arsitektur CNN yang digunakan harus memiliki kedalaman yang lebih tinggi, namun model arsitektur CNN dengan banyak *layer* mempunyai kelemahan yaitu *Vanishing Gradient Problem*, hal ini terjadi ketika hasil gradien yang dipelajari oleh model CNN tidak sampai ke lapisan pertama karena telah mengalami operasi perkalian berulang, sehingga lapisan pertama tidak menerima gradien apa pun, yang membuat model CNN tidak dapat belajar dari kesalahan yang dikalkulasi **(Hu, dkk, 2018)**. Gambar 4 menunjukkan dari arsitektur ResNet. ResNet memiliki berbagai macam jenis, yang terdiri dari 18, 34, 50, 101, hingga 152 *layer*.

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112x112	7x7, 64, stride 2				
		3x3 max pool, stride 2				
conv2_x	56x56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28x28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14x14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7x7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1x1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10^9	3.6×10^9	3.8×10^9	7.6×10^9	11.3×10^9

Gambar 4. Arsitektur ResNet (He, dkk, 2016)

2. METODE

Pada penelitian ini dirancang sebuah sistem klasifikasi tingkat kematangan pucuk daun teh yang berada di PPTK Gambung untuk menentukan akurasi menggunakan metode pengolahan citra digital. Gambar 5 menunjukkan diagram blok sistem yang dirancang pada penelitian ini.



Gambar 5. Blok Diagram Sistem Secara Umum

Secara umum, sistematika blok diagram sistem yang ditunjukkan pada Gambar 5 adalah :

1. Pengambilan citra asli pucuk daun teh klon varietas Gambung (GMB 7) dengan ketentuan setiap tujuh hari sekali dalam kurun waktu satu bulan pada salah satu blok tanam teh yang berukuran 1x0.5 meter menggunakan Kamera *Smartphone*.
2. Citra pucuk daun teh di *preprocessing* dengan tahapan *resize* dan augmentasi data.
3. *Training* yaitu proses pembelajaran citra dengan metode CNN untuk mendapatkan model citra latih yang akan disimpan pada *database*.
4. Pengujian dilakukan dengan data citra uji yang diklasifikasikan dengan model dari citra latih menggunakan metode CNN untuk mendapatkan hasil dan akurasi sistem.

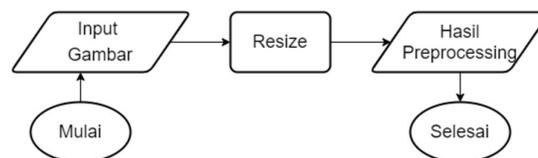
2.1 Akuisisi citra

Perancangan sistem diawali dengan proses akuisisi citra. Pada proses ini, dilakukan pengumpulan data untuk kebutuhan sistem sebagai data latih dan data uji. Data sampel pucuk daun teh varietas *Assamica* klon GMB 7 diambil dari PPTK Gambung dengan ketentuan pengambilan sampel dalam rentang waktu kurang lebih satu bulan masa panen. Tahapan proses akuisisi citra pucuk daun teh yaitu :

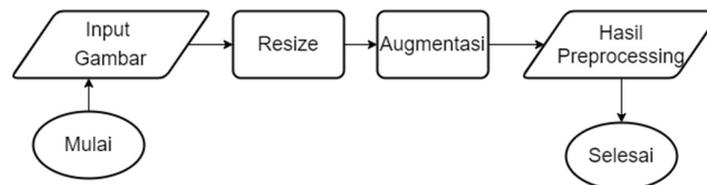
1. Menyiapkan tripod dan kamera *smartphone* untuk mengambil citra pucuk daun teh dari ketinggian 1 meter di atas permukaan pucuk daun teh.
2. Citra yang diambil memiliki format .JPEG atau .JPG.
3. Citra pucuk daun teh yang diambil memiliki kategori 4 kelas yaitu kelas 7 hari panen, 14 hari panen, 21 hari panen dan 28 hari panen.

2.2 Preprocessing

Setelah proses akuisisi citra, dilakukan *preprocessing* untuk mengoptimalkan mutu gambar, sehingga memudahkan dan memacu kemampuan sistem dalam mengidentifikasi objek. Tahapan *preprocessing* pada sistem ini terbagi kedalam dua tahap yaitu data asli dan data augmentasi. Pada data asli *preprocessing* hanya dilakukan dengan proses *resize image* saja. Sementara pada data augmentasi *pre-processing* dilakukan dengan *resize* dan augmentasi data. Gambar 6 menunjukkan diagram alir proses *preprocessing* data asli dan Gambar 7 menunjukkan diagram alir proses *preprocessing* data augmentasi.



Gambar 6. Diagram Alir *Preprocessing* Data Asli



Gambar 7. Diagram Alir *Preprocessing* Data Augmentasi

Penjelasan sistem kerja diagram alir *preprocessing* citra adalah sebagai berikut :

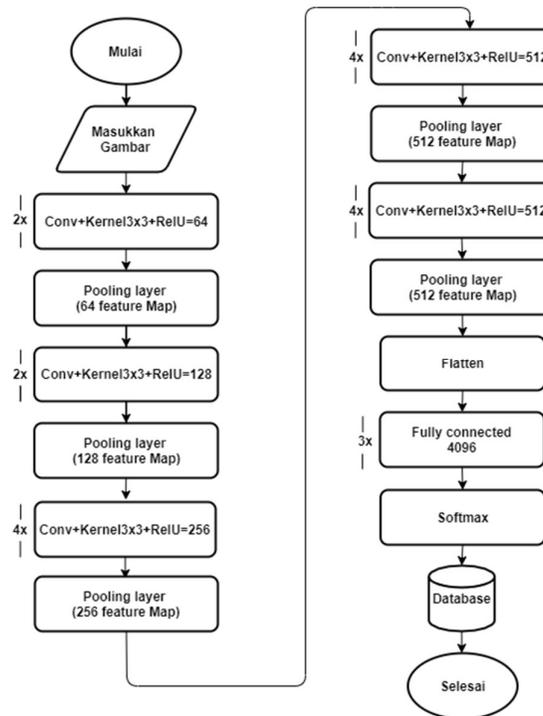
1. *Input* Citra yaitu tahap pengambilan data citra yang akan dipilih sebelum diproses.
2. *Resize* yaitu proses mengubah ukuran citra baik secara vertikal maupun *horizontal*. Pada proses ini dilakukan *resize* citra dari ukuran 4032x3024 *pixel* menjadi citra ukuran 224x224 *pixel*.

3. Augmentasi merupakan proses mengolah data citra dengan memodifikasi data citra. Pada sistem ini tahap augmentasi yang dilakukan yaitu Rotasi, *Horizontal flip*, Vertikal *flip*, menambah *noise* dan *Gaussian blur* pada *image*.
4. Hasil *Preprocessing* yaitu hasil keluaran citra yang telah melalui proses *resize* dan tahap augmentasi.

2.3 Training

Pada tahapan *training* dilakukan proses pembelajaran pada citra yang kemudian hasil keluarannya berupa model yang akan disimpan untuk digunakan dalam proses pengujian. Pembentukan model merupakan proses pelatihan data citra latih dalam mengidentifikasi objek dan mengategorikannya sesuai dengan kelasnya. Pada penelitian ini metode yang digunakan merupakan salah satu cabang algoritma *deep learning* yaitu CNN dengan arsitektur VGGNet19 dan ResNet-50.

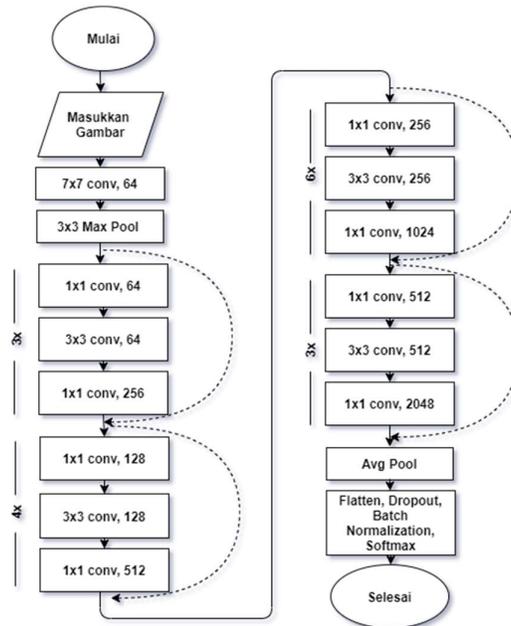
Secara umum, tahap pelatihan pada VGGNet19 ditunjukkan pada Gambar 8. *Input* citra pada model CNN mempergunakan citra dengan ukuran $224 \times 224 \times 3$. Kemudian citra masukan akan diproses melalui proses *convolution* dan proses *pooling*. Lapisan konvolusi berjumlah sebanyak 16 lapisan dan memiliki jumlah filter yang berbeda. Selanjutnya dilakukan proses *flatten* atau proses pengubahan hasil *pooling layer* berupa *feature map* ke dalam bentuk vektor. Proses ini disebut tahapan *fully connected layer*.



Gambar 8. Diagram Alir Tahapan *Training System* VGGNet19

ResNet 50 merupakan model arsitektur yang terdiri dari 50 lapisan. Pada tahapan *training* sistem yang ditunjukkan oleh Gambar 9, terdapat lapisan awal dengan ukuran kernel 7×7 dan dengan 64 filter, kemudian dilakukan *max pooling* dengan ukuran kernel 3×3 . Golongan lapisan pertama tersusun atas tiga blok, selanjutnya terdiri dari empat, enam, dan tiga blok yang di antaranya mengandung *ReLU* dan *batch-normalization*. Setiap blok lapisan dihubungkan oleh *skip connection*. Kemudian dilanjutkan *average pooling* dan diakhiri dengan

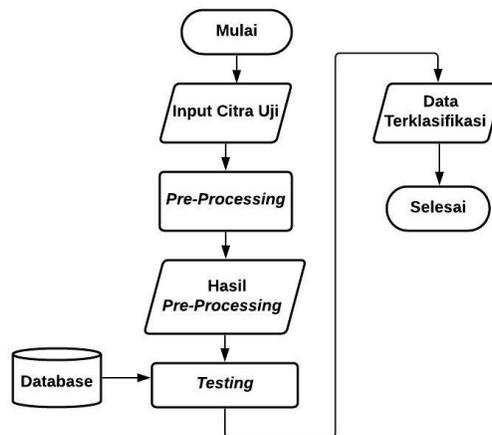
fully connected layer. Fungsi aktivasi yang digunakan pada *fully connected layer* yaitu *flatten* yang digunakan untuk mengonversikan matriks menjadi vektor, *dropout* untuk membatasi jumlah *neuron* yang masuk agar mencegah *overfitting*, dan ditambah parameter *batch normalization* untuk menormalkan sumbu aliran. Selepas citra melewati *fully connected layer*, maka hasil keluarannya digunakan sebagai *input* fungsi aktivasi *softmax* untuk memprediksi kemungkinan dari data hasil *training* atas objek citra yang terdiri dari empat kelas.



Gambar 9. Diagram Alir Tahapan *Training System Resnet50*

2.4 Testing

Gambar 10 menunjukkan diagram alir tahap pengujian sistem. Tahap pengujian yaitu berupa proses klasifikasi tingkat kematangan pucuk daun teh dengan menguji data citra uji dan membandingkannya dengan model hasil *training* data citra latih yang disimpan pada database. Data citra yang diambil sebanyak 600 untuk data asli kemudian 1800 data citra hasil augmentasi. Citra yang telah diambil akan diproses oleh algoritma CNN hingga kemudian menghasilkan keluaran sistem berupa informasi tingkat kematangan pucuk daun teh.



Gambar 10. Diagram Alir Tahap Pengujian Sistem

2.5 Perancangan Pengujian

Pada tahap perancangan pengujian terdapat empat skenario yang akan dilakukan pada saat pengujian sistem. Empat skenario tersebut akan diuji pada dua data, yaitu data asli dan data augmentasi, penjelasan skenario yang akan diuji adalah sebagai berikut :

1. Skenario pertama, yaitu mencari *Optimizer* terbaik dengan parameter yang ditentukan.
2. Skenario kedua, yaitu mencari ukuran *batch size* terbaik dengan menggunakan *Optimizer*, *epoch* dan *learning rate* yang ditentukan pada skenario sebelumnya.
3. Skenario ketiga, yaitu mencari nilai *learning rate* terbaik dengan menggunakan *Optimizer*, *batch size* dan *epoch* yang ditentukan pada dua skenario sebelumnya.
4. Skenario keempat, yaitu mencari jumlah *epoch* terbaik dengan menggunakan *Optimizer*, *batch size* dan *epoch* yang ditentukan pada tiga skenario sebelumnya.

2.6 Performa Sistem

Sistem yang dirancang akan dihitung hasil kinerjanya berdasarkan kesesuaian kinerja dari performa sistem. Serta untuk mengukur keunggulan serta kelemahan dari dari sistem yang dirancang berdasarkan parameter *accuracy*, *loss* dan *precision*.

Akurasi didefinisikan sebagai tingkat kebenaran dalam suatu penelitian yang menunjukkan hasil yang akurat. Presisi merupakan tingkat keberhasilan data dalam membandingkan jumlah yang diprediksi dengan jumlah total data keseluruhan. *Loss* merupakan parameter penggambaran perhitungan yang menghasilkan ketidakakuratan sistem dalam mengenali objek. Berikut adalah persamaan matematis akurasi, presisi dan *loss* :

$$\text{Akurasi (\%)} = \frac{TP+}{TP+TN+FP+F} \times 100\% \quad (1)$$

$$\text{Presisi (\%)} = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

$$\text{Loss (\%)} = \frac{FP+FN}{TP+TN+FP+F} \times 100\% \quad (3)$$

Keterangan :

1. *True Positive* (TP): Data yang tepat diklasifikasi oleh sistem sebagai nilai positif (benar).
2. *True Negative* (TN): Data yang tepat diklasifikasi oleh sistem sebagai nilai negatif (salah).
3. *False Positive* (FP): Data salah (*negative*) namun diklasifikasikan sebagai data benar (*positive*).
4. *False Negative* (FN): Data benar (*positive*) namun diklasifikasikan sebagai data salah (*negative*).

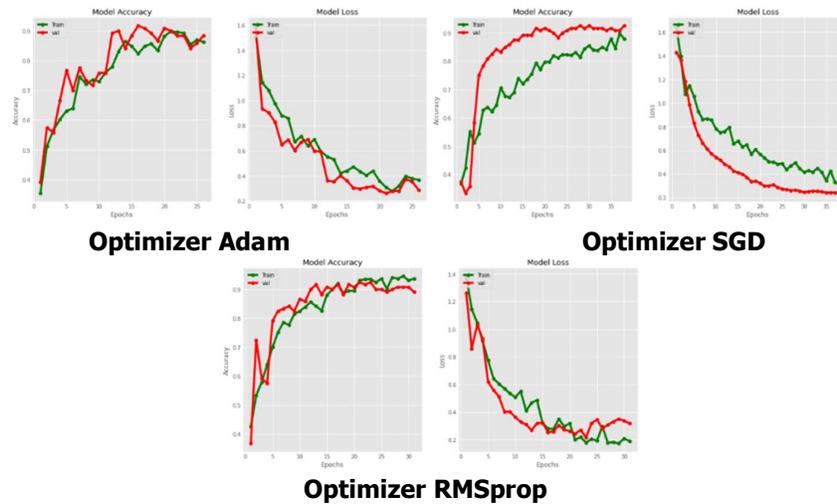
3. HASIL DAN PEMBAHASAN

Pengujian pada sistem yang telah dirancang menggunakan metode CNN dengan arsitektur VGGNet19 dan ResNet50 untuk mengetahui tingkat kematangan pucuk daun teh dari *dataset* citra varietas *Assamica* Klon GMB 7 yang terbagi ke dalam empat kelas yaitu 7 hari, 14 hari, 21 hari dan 28 hari dengan mempertimbangkan tingkat kematangan pucuk daun teh yang umumnya berusia satu bulan. Sistem pengujian dibentuk dengan memanfaatkan perubahan *hyperparameter* pada jumlah *dataset* sebelum augmentasi dan jumlah *dataset* setelah augmentasi. *Hyperparameter* yang digunakan yaitu perubahan pada jenis *Optimizer* yaitu

Adam, SGD dan RMSprop, perubahan ukuran *batch size* yaitu 8, 16, 32 dan 64, perubahan nilai *learning rate* yaitu 0.1, 0.01 dan 0.001 serta banyaknya iterasi pelatihan (*epoch*) yaitu pada *epoch* 50 dan *epoch* 100.

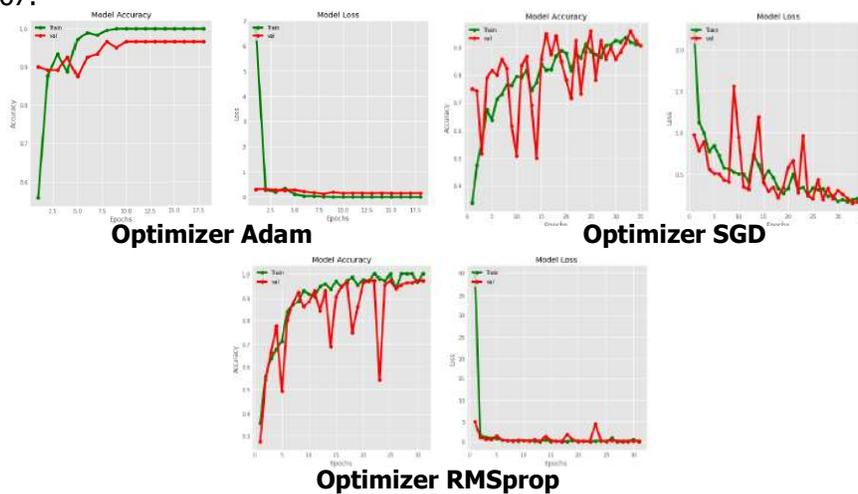
3.1 Pengujian dan Analisis pada Data Asli

Data pertama yang akan diuji merupakan data asli yang berjumlah 600 citra. Pada proses *training* data yang digunakan berjumlah 80% dari data keseluruhan atau 480 data. Sedangkan pada proses *testing* data yang digunakan berjumlah 20% dari total data keseluruhan atau 120 data. Pada pengujian ini menggunakan tiga *Optimizer* yaitu Adam, SGD dan RMSprop dengan parameter yaitu *batch size* berukuran 16, *learning rate* bernilai 0.001 dan *epoch* berjumlah 100.



Gambar 11. Hasil Grafik Accuracy dan Loss Tiap Optimizer pada Arsitektur Resnet50

Gambar 11 merupakan grafik *accuracy* dan *loss* dari data *training* dan data *testing* tiap *Optimizer* milik arsitektur ResNet50 menggunakan beberapa jenis *Optimizer* yaitu *Optimizer* Adam, SGD dan RMSprop. Berdasarkan gambar tersebut *Optimizer* SGD memperoleh nilai akurasi tertinggi dan *loss* terendah dibandingkan dengan *Optimizer* yang lain. *Accuracy* data *testing* tertinggi terjadi pada *epoch* 28 dan terjadi *early stopping* pada *epoch* 38 dengan nilai 92.5%, sementara *loss* data *testing* terus menurun dan stabil mendekati nilai nol dengan nilai akhir 0.2367.



Gambar 12. Hasil Grafik Accuracy Dan Loss Tiap Optimizer pada Arsitektur VGGNet19

Gambar 12 merupakan grafik *accuracy* dan *loss* dari data *training* dan data *testing* milik arsitektur VGGNet19 menggunakan beberapa jenis *Optimizer* yaitu *Optimizer* Adam, SGD dan RMSprop. Berdasarkan gambar tersebut *Optimizer* RMSprop mencapai nilai akurasi tertinggi dan *loss* dibandingkan dengan *Optimizer* lain. *Accuracy* tertinggi terjadi pada *epoch* 21 lalu terjadi *early stopping* pada *epoch* 31 dengan nilai 97.5%, sementara *loss* data *testing* terus menurun dan stabil mendekati nilai nol dengan nilai akhir 0.1928. Tabel 1, 2 dan 3 menunjukkan hasil *classification report* pada pengujian arsitektur ResNet50 menggunakan *Optimizer* Adam, SGD dan RMSprop. Apabila melihat dari hasil tabel, *Optimizer* SGD memperoleh nilai akurasi tertinggi yaitu 93% dan *precision* 94% dibandingkan dengan nilai akurasi pada *Optimizer* lain.

Tabel 1. Classification Report Arsitektur Resnet50 menggunakan Optimizer Adam

Class	Precision	Recall	F1-score	Support
7 hari	1.00	0.72	0.84	29
14 hari	0.71	0.96	0.82	28
21 hari	0.96	0.87	0.91	30
28 hari	0.94	0.97	0.96	33
Accuracy			0.88	120
Macro Avg	0.90	0.88	0.88	120
Weighted Avg	0.91	0.88	0.88	120

Tabel 2. Classification Report Arsitektur Resnet50 menggunakan Optimizer SGD

Class	Precision	Recall	F1-score	Support
7 hari	1.00	0.86	0.93	29
14 hari	0.76	1.00	0.86	28
21 hari	1.00	0.87	0.93	30
28 hari	1.00	0.97	0.98	33
Accuracy			0.93	120
Macro Avg	0.94	0.92	0.93	120
Weighted Avg	0.94	0.93	0.93	120

Tabel 3. Classification Report Arsitektur Resnet50 menggunakan Optimizer Rmsprop

Class	Precision	Recall	F1-score	Support
7 hari	1.00	0.76	0.86	29
14 hari	0.74	0.89	0.81	28
21 hari	0.90	0.93	0.92	30
28 hari	0.97	0.97	0.97	33
Accuracy			0.89	120
Macro Avg	0.90	0.89	0.89	120
Weighted Avg	0.91	0.89	0.89	120

Tabel 4. Classification Report Arsitektur Vggnet19 menggunakan Optimizer Adam

Class	Precision	Recall	F1-score	Support
7 hari	0.91	1.00	0.95	29
14 hari	1.00	0.89	0.94	28
21 hari	0.97	1.00	0.98	30
28 hari	1.00	0.97	0.98	33
Accuracy			0.97	120
Macro Avg	0.97	0.97	0.97	120
Weighted Avg	0.97	0.97	0.97	120

Tabel 5. Classification Report Arsitektur Vggnet19 menggunakan Optimizer SGD

Class	Precision	Recall	F1-score	Support
7 hari	0.78	0.97	0.86	29
14 hari	0.95	0.68	0.79	28
21 hari	1.00	1.00	1.00	30
28 hari	0.94	0.97	0.96	33
Accuracy			0.91	120
Macro Avg	0.92	0.98	0.90	120
Weighted Avg	0.92	0.98	0.91	120

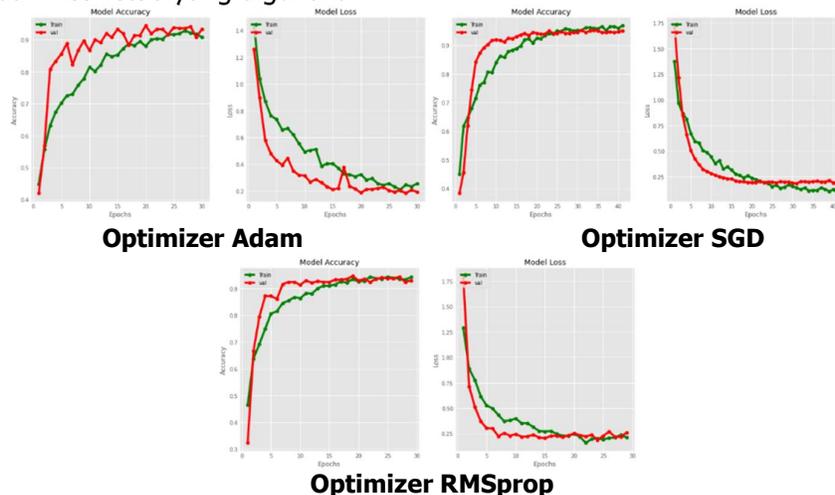
Tabel 6. Classification Report Arsitektur Vggnet19 menggunakan Optimizer Rmsprop

Class	Precision	Recall	F1-score	Support
7 hari	0.97	1.00	0.98	29
14 hari	0.96	0.93	0.95	28
21 hari	1.00	1.00	1.00	30
28 hari	0.97	0.97	0.97	33
Accuracy			0.97	120
Macro Avg	0.97	0.97	0.97	120
Weighted Avg	0.97	0.97	0.97	120

Tabel 4, 5 dan 6 menunjukkan hasil *classification report* pada pengujian arsitektur VGGNet19 menggunakan *Optimizer Adam*, SGD dan RMSprop. Apabila melihat dari hasil tabel, *Optimizer Adam* dan RMSprop memperoleh nilai akurasi tertinggi yaitu 97% dan *precision* 97% dibandingkan dengan nilai akurasi pada *Optimizer Adam*. Berdasarkan hasil analisis dari pengujian yang dilakukan pada kedua arsitektur, arsitektur VGGNet19 memperoleh nilai akurasi dan *precision* 3%-4% lebih tinggi dibandingkan arsitektur ResNet50.

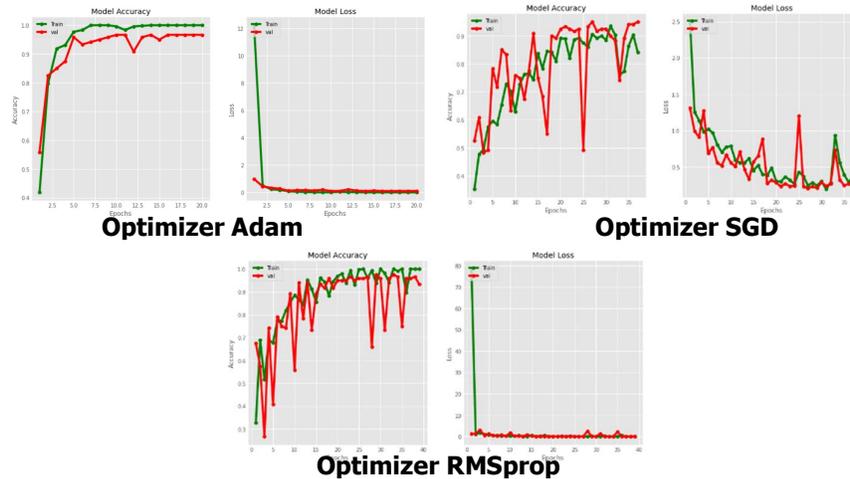
3.2 Pengujian dan Analisis pada Data Augmentasi

Pada pengujian kedua dilakukan augmentasi data yang semula berjumlah 600 data menjadi data 1800 citra. Pada proses *training* data yang digunakan berjumlah 80% dari data keseluruhan atau 1440 data. Sedangkan pada proses *testing* data yang digunakan berjumlah 20% dari total data keseluruhan atau 360 data. Augmentasi dilakukan untuk menambah jumlah sampel data yang digunakan pada proses *training* karena semakin banyak pula data yang dapat dipelajari oleh sistem dan proses augmentasi ini tidak mengubah arsitektur VGGNet19 dan ResNet50 yang digunakan.



Gambar 13. Grafik Akurasi Dan Loss Tiap Optimizer Arsitektur ResNet50

Pada pengujian ini menggunakan tiga *Optimizer* yaitu Adam, SGD dan RMSprop dengan parameter yaitu *batch size* berukuran 32, *learning rate* bernilai 0.01 dan *epoch* berjumlah 100. Gambar 13 merupakan grafik *accuracy* dan *loss* dari data *training* dan data *testing* tiap *optimizer* milik arsitektur ResNet50 menggunakan beberapa jenis *Optimizer* yaitu *Optimizer* Adam, SGD dan RMSprop. Berdasarkan gambar tersebut *Optimizer* SGD memperoleh nilai akurasi tertinggi dan *loss* terendah dibandingkan dengan *Optimizer* yang lain. *Accuracy* data *testing* tertinggi terjadi pada *epoch* 28 lalu terjadi *early stopping* pada *epoch* 38 dengan nilai 95%, sementara *loss* data *testing* terus menurun dan stabil mendekati nilai nol dengan nilai akhir 0.2032.



Gambar 14. Grafik Akurasi dan Loss Tiap *Optimizer* Arsitektur VGGNet19

Gambar 14 merupakan grafik *accuracy* dan *loss* dari data *training* dan data *testing* tiap *optimizer* milik arsitektur VGGNet19 menggunakan beberapa jenis *Optimizer* yaitu *Optimizer* Adam, SGD dan RMSprop. Berdasarkan gambar tersebut *Optimizer* RMSprop mencapai nilai akurasi tertinggi dan *loss* dibandingkan dengan *Optimizer* lain. Akurasi tertinggi terjadi pada *epoch* 19 lalu terjadi *early stopping* pada *epoch* 29 dengan nilai 97.5%. Sementara *loss* data *testing* terus menurun dan stabil mendekati nilai nol dengan nilai akhir 0.1208.

Tabel 7. Classification Report Arsitektur Resnet50 menggunakan *Optimizer* Adam

Class	Precision	Recall	F1-score	Support
7 hari	0.89	0.91	0.90	29
14 hari	0.86	0.88	0.87	28
21 hari	0.99	0.95	0.97	30
28 hari	0.99	0.99	0.99	33
Accuracy			0.93	120
Macro Avg	0.93	0.93	0.93	120
Weighted Avg	0.93	0.93	0.93	120

Tabel 8. Classification Report Arsitektur Resnet50 menggunakan *Optimizer* SGD

Class	Precision	Recall	F1-score	Support
7 hari	0.90	0.93	0.92	29
14 hari	0.92	0.91	0.91	28
21 hari	0.99	0.99	0.99	30
28 hari	0.99	0.97	0.98	33
Accuracy			0.95	120
Macro Avg	0.95	0.95	0.95	120
Weighted Avg	0.95	0.95	0.95	120

Tabel 9. Classification Report Arsitektur Resnet50 menggunakan Optimizer Rmsprop

Class	Precision	Recall	F1-score	Support
7 hari	0.91	0.91	0.91	29
14 hari	0.90	0.89	0.90	28
21 hari	0.98	0.98	0.98	30
28 hari	0.98	0.99	0.98	33
Accuracy			0.94	120
Macro Avg	0.94	0.94	0.94	120
Weighted Avg	0.94	0.94	0.94	120

Tabel 7, 8 dan 9 menunjukkan hasil *classification report* pada pengujian arsitektur ResNet50 menggunakan *Optimizer Adam, SGD dan RMSprop*. Apabila melihat dari hasil tabel, *Optimizer SGD* memperoleh nilai akurasi tertinggi yaitu 95% dan *precision* 95% dibandingkan dengan nilai akurasi pada *Optimizer* lain.

Tabel 10. Classification Report Arsitektur VGGNet19 menggunakan Optimizer Adam

Class	Precision	Recall	F1-score	Support
7 hari	0.96	0.96	0.96	29
14 hari	0.95	0.98	0.97	28
21 hari	1.00	1.00	1.00	30
28 hari	0.99	0.97	0.98	33
Accuracy			0.97	120
Macro Avg	0.97	0.97	0.97	120
Weighted Avg	0.98	0.97	0.98	120

Tabel 11. Classification Report Arsitektur VGGNet19 menggunakan Optimizer SGD

Class	Precision	Recall	F1-score	Support
7 hari	0.92	0.89	0.90	29
14 hari	0.90	0.94	0.92	28
21 hari	1.00	1.00	1.00	30
28 hari	0.98	0.97	0.97	33
Accuracy			0.95	120
Macro Avg	0.95	0.95	0.95	120
Weighted Avg	0.95	0.95	0.95	120

Tabel 12. Classification Report Arsitektur VGGNet19 menggunakan Optimizer Rmsprop

Class	Precision	Recall	F1-score	Support
7 hari	0.96	0.96	0.96	29
14 hari	0.94	0.98	0.96	28
21 hari	1.00	1.00	1.00	30
28 hari	1.00	0.97	0.98	33
Accuracy			0.97	120
Macro Avg	0.97	0.97	0.97	120
Weighted Avg	0.98	0.97	0.98	120

Tabel 10, 11 dan 12 menunjukkan hasil *classification report* pada pengujian arsitektur VGGNet19 menggunakan *Optimizer Adam, SGD dan RMSprop*. Apabila melihat dari hasil tabel, *Optimizer Adam* dan *RMSprop* memperoleh nilai akurasi tertinggi yaitu 97% dan *precision* 97% dibandingkan dengan nilai akurasi pada *Optimizer Adam*. Berdasarkan hasil analisis dari pengujian yang dilakukan pada kedua arsitektur, arsitektur VGGNet19 memperoleh hasil yang lebih baik dibandingkan dengan arsitektur ResNet50 karena memiliki nilai *accuracy* 97.5%, *loss* 0.1208 dan *precision* 97% apabila menggunakan *Optimizer RMSprop*.

Arsitektur VGGNet19 memiliki performa yang lebih baik jika dibandingkan dengan ResNet50 apabila melihat dari hasil akurasi saat pengujian dengan skenario data asli maupun data augmentasi. Hal ini disebabkan karena VGGNet19 memiliki jumlah *trainable parameter* yang lebih banyak dibandingkan dengan ResNet50. Kemudian hasil akurasi dari kedua skenario pengujian tersebut juga menghasilkan nilai akurasi yang identik.

4. KESIMPULAN

Perancangan sistem klasifikasi tingkat kematangan pucuk daun teh dengan metode CNN menggunakan arsitektur VGGNet19 dan ResNet50 mampu mengklasifikasi tingkat kematangan pucuk daun teh varietas *Assamica* Klon GMB 7 ke dalam kelas 7 hari, 14 hari, 21 hari dan 28 hari dengan performa sistem terbaik yaitu menggunakan arsitektur VGGNet19 dengan nilai *accuracy* 97.5%, *loss* 0.1208 dan *precision* 97%. Hasil ini diperoleh menggunakan data augmentasi dengan parameter terbaik yaitu *Optimizer* RMSprop, *learning rate* 0.01, *batch size* 32 dan *epoch* 100. Hasil akurasi yang identik dari skenario data asli maupun data augmentasi menunjukkan bahwa sistem ini mampu menangani berapapun banyaknya data gambar yang digunakan. Sistem ini dapat dikembangkan lagi dengan mengimplementasikannya ke dalam sistem yang mampu mengklasifikasi tingkat kematangan pucuk daun teh secara *real-time*.

DAFTAR RUJUKAN

- Al-Falah, H. N., & Purnamasari, K. K. (2019). Implementasi Convolutional Neural Network Pada Pengenalan Tulisan Tangan. *UNIKOM Library*, 112.
- Auliasari, R. N., Novamizanti, L., & Ibrahim, N. (2020). Identifikasi Kematangan Daun Teh Berbasis Fitur Warna Hue Saturation Intensity (HSI) dan Hue Saturation Value (HSV). *JUITA: Jurnal Informatika*, 8(2), 217. <https://doi.org/10.30595/juita.v8i2.7387>
- Effendi, M., Fitriyah, F., & Effendi, U. (2017). Identifikasi Jenis dan Mutu Teh Menggunakan Pengolahan Citra Digital dengan Metode Jaringan Syaraf Tiruan. *Jurnal Teknotan*, 11(2), 67. <https://doi.org/10.24198/jt.vol11n2.7>
- Hayat, M. H., Ibrahim, N., Rizal, S., & Eng, M. (2020). *Klasifikasi Daun Teh Jenis Gambung Menggunakan Convolutional Neural Network Dengan Arsitektur AlexNet*. 1–8.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, (pp. 770–778). <https://doi.org/10.1109/CVPR.2016.90>
- Hu, Y., Huber, A., Anumula, J., & Liu, S.-C. (2018). *Overcoming the vanishing gradient problem in plain recurrent networks*. <http://arxiv.org/abs/1801.06105>
- Ilahiyah, S., & Nilogiri, A. (2018). Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network. *JUSTINDO (Jurnal Sistem Dan Teknologi Informasi Indonesia)*, 3(2), 49–56. <https://doi.org/10.32528/JUSTINDO.V3I2.2254>

- Jaelani, A. A., Supratman, F. Y., & Ibrahim, N. (2020). *Perancangan Aplikasi Untuk Klasifikasi Klon Daun Teh Seri Gambung (Gmb) Menggunakan Algoritma Convolutional Neural Network*. *λ2*, 2920–2928.
- Karyudi. (2014). *Teh Nama Varietas GMB 5 | Pusat Perlindungan Varietas Tanaman dan Perizinan Pertanian*. <http://pvtppt.setjen.pertanian.go.id/cms2017/berita-resmi/pendaftaran-varietas-hasil-pemuliaan/teh-nama-varietas-gmb-5/>
- Muhimmah, I., Muchlis, N. F., & Kurniawardhani, A. (2018). Deteksi kemerahan pada kulit wajah dengan teknik pengolahan citra. *Dspace UII*, 1–8.
- Primartha, R. (2018). *Belajar Machine Learning Teori dan Praktik*. Informatika Bandung.
- Santoso, A., & Ariyanto, G. (2018). Implementasi Deep Learning Berbasis Keras Untuk Pengenalan Wajah. *Emitor: Jurnal Teknik Elektro*, *18*(1), 15–21. <https://doi.org/10.23917/emitor.v18i01.6235>
- Sita, K., & Rohdiana, D. (2021). Analisis Kinerja dan Prospek Komoditas Teh. *Radars Opini Dan Analisis Perkebunan*, *2*(1).
- Suherman, A. H., Ibrahim, N., Syahrian, H., Rahadi, V. P., & Prayoga, M. K. (2021). *Klasifikasi Daun Teh Gambung Varietas Assamica Menggunakan Convolutional Neural Network Dengan Arsitektur LeNet-5*. *4*. <https://doi.org/10.31289/jesce.v4i2.4136>
- Taslim, M. M., Gunadi, K., & Tjondrowiguno, A. N. (2019). Deteksi Rumus Matematika pada Halaman Dokumen Digital dengan Metode Convolutional Neural Network. *Jurnal Infra*, *λ2*, 123–129. www.arxiv.org
- Wicaksono, B. A., Novamizanti, L., & Ibrahim, N. (2019). Identifikasi Tingkat Kematangan Daun Teh Menggunakan Centroid Clustering Berdasarkan Ruang Warna YCbCr. *eproceeding universitas telkom*, (pp. 1–9).