

# KLASIFIKASI JENIS BUNGA DENGAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK* (CNN) MENGGUNAKAN METODE *REGION-BASED CONVOLUTIONAL NEURAL NETWORK* (R-CNN)

Eko Predianto<sup>1</sup>, Budi Sutomo<sup>2</sup>

<sup>1,2,3</sup>Program Studi Teknik Informatika, STMIK, Dharma Wacana Metro, Jl. Kenangan  
No. 3 Mulyojati 16 C Metro Barat, Kota Metro, 34125, Indonesia  
E-mail: ekopredianto15@gmail.com

## Abstract

This research about "Classification of Flower Types with Convolutional Neural Network Algorithm" aims to develop a model using Convolution Neural Network (CNN) and Region-Based Convolutional Neural Network (R-CNN) to classify different types of orchid flowers. The dataset consists of images of three main classes of orchids: Moon Orchid (*Phalaenopsis*), Dendrobium Orchid, and Ground Orchid (*Paphiopedilum*), around 40 images per class. Those images collected from some of the best resources such as Department of Food Security and Food Crops and Horticulture of Lampung Province, Department of Food Security, Fisheries and Agriculture of Metro City, and sellers of flowers in Lampung Province and from public databases, horticulture website sites, private collection, to get the visual variation from each class. Collecting data process convert take and download high resolution image, categories and labeling, along pre-processing to increase images quality. The dataset divided to training and test data in 70:30 ratios for train and evaluate model performance. By utilizing advanced techniques in data collection, pre-processing and analytic, this research aims to develop strong model that can qualified species of orchid flowers accurately based on visual characteristic.

**Keywords:** *Classification, Orchid Flowers, CNN, R-CNN*

## Abstrak

Penelitian tentang "Klasifikasi Jenis Bunga dengan Algoritma *Convolutional Neural Network*" bertujuan untuk mengembangkan model menggunakan *Convolutional Neural Network* (CNN) dan *Region-Based Convolutional Neural Network* (R-CNN) untuk mengklasifikasikan berbagai jenis bunga anggrek. *Dataset* terdiri dari gambar-gambar tiga kelas utama anggrek: Anggrek Bulan (*Phalaenopsis*), Anggrek Dendrobium, dan Anggrek Tanah (*Paphiopedilum*), dengan sekitar 40 gambar per kelas. Gambar-gambar tersebut dikumpulkan dari berbagai sumber yang tepercaya seperti diperoleh di Dinas Ketahanan Pangan dan Tanaman Pangan dan Hortikultura Provinsi Lampung serta Dinas Ketahanan Pangan, Pertanian dan Perikanan Kota Metro dan para UMKM toko bunga di Provinsi Lampung serta berbagai sumber termasuk *database* publik, situs web hortikultura, dan koleksi pribadi, untuk mencakup variasi visual dalam setiap kelas. Proses pengumpulan data melibatkan pengambilan dan pengunduhan gambar beresolusi tinggi, pengkategorian dan pelabelan, serta pra-pemrosesan untuk meningkatkan kualitas gambar. *Dataset* kemudian dibagi menjadi data pelatihan dan pengujian dalam rasio 70:30 untuk melatih dan mengevaluasi performa model. Dengan memanfaatkan teknik lanjutan dalam pengumpulan data, pra-pemrosesan, dan analisis, penelitian ini bertujuan untuk mengembangkan model yang tangguh mampu mengklasifikasikan spesies bunga anggrek secara akurat berdasarkan karakteristik visualnya.

**Kata Kunci:** Klasifikasi, Bunga Anggrek, Algoritma CNN, R-CNN

# KLASIFIKASI JENIS BUNGA DENGAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK* (CNN) MENGGUNAKAN METODE *REGION-BASED CONVOLUTIONAL NEURAL NETWORK* (R-CNN)

## 1. Pendahuluan

Pada era digital ini, teknologi kecerdasan buatan (*Artificial Intelligence/AI*) telah memberikan kontribusi signifikan dalam berbagai bidang, termasuk dalam pengenalan dan klasifikasi gambar. Salah satu aplikasi AI yang populer adalah penggunaan *Convolutional Neural Network* (CNN) dalam bidang pengolahan citra. CNN merupakan jenis jaringan saraf tiruan yang dirancang khusus untuk mengenali pola visual dalam gambar, sehingga mampu melakukan tugas klasifikasi, segmentasi, dan deteksi objek dengan akurasi tinggi.

Di antara berbagai jenis algoritma CNN, *metode Region-Based Convolutional Neural Network* (R-CNN) telah menunjukkan performa yang unggul dalam mendeteksi dan mengklasifikasikan objek dalam gambar. R-CNN bekerja dengan cara memetakan area tertentu dalam gambar yang kemungkinan besar mengandung objek yang ingin dikenali, kemudian melakukan klasifikasi pada area tersebut. Keunggulan R-CNN dalam mengidentifikasi objek dengan akurasi tinggi membuatnya banyak digunakan dalam aplikasi-aplikasi yang memerlukan deteksi dan klasifikasi yang presisi.

Bunga anggrek merupakan salah satu jenis tanaman yang memiliki nilai ekonomi dan estetika tinggi. Bunga anggrek di Provinsi Lampung memiliki ribuan spesies dengan berbagai bentuk, warna, dan ukuran yang berbeda, membuatnya menjadi subjek yang menarik dan menantang untuk diidentifikasi dan diklasifikasikan. Keanekaragaman ini juga menimbulkan tantangan tersendiri dalam hal pengenalan dan klasifikasi, terutama jika dilakukan secara manual oleh manusia yang rentan terhadap kesalahan dan memerlukan waktu yang lama.

Dalam konteks klasifikasi bunga anggrek, penggunaan teknologi AI, khususnya CNN, dapat memberikan solusi yang lebih efisien dan akurat. Dengan menggunakan R-CNN, model AI dapat dilatih untuk mengenali berbagai spesies bunga anggrek berdasarkan karakteristik visualnya, seperti bentuk kelopak, pola warna, dan tekstur. Hal ini akan sangat bermanfaat dalam bidang botani, agrikultur, dan konservasi, dimana identifikasi yang cepat dan akurat sangat diperlukan.

Implementasi R-CNN untuk klasifikasi bunga anggrek juga dapat mendukung penelitian dalam bidang botani dan biologi. Dengan adanya model klasifikasi yang akurat, para peneliti dapat lebih mudah mengidentifikasi spesies baru, mempelajari hubungan antar spesies, serta memantau populasi anggrek di alam liar. Selain itu, implementasi R-CNN untuk klasifikasi bunga anggrek ini juga dapat digunakan dalam industri hortikultura untuk membantu para petani dan usaha mikro, kecil dan menengah (UMKM) toko bunga khususnya di daerah Provinsi Lampung dalam mengidentifikasi dan mengategorikan produk bunga anggrek.

Selain manfaat ilmiah dan ekonomi, klasifikasi bunga anggrek menggunakan R-CNN juga memiliki potensi untuk meningkatkan kesadaran masyarakat tentang pentingnya konservasi tumbuhan. Dengan aplikasi yang *user-friendly*, masyarakat umum dapat lebih mudah mengenali berbagai jenis anggrek, memahami karakteristiknya, dan mengetahui status konservasinya. Hal ini dapat mendorong partisipasi masyarakat dalam upaya pelestarian flora, terutama spesies anggrek yang terancam punah.

Dengan demikian, pengembangan dan penerapan algoritma CNN, khususnya R-CNN, dalam klasifikasi jenis bunga anggrek merupakan langkah penting yang dapat memberikan manfaat luas, baik dari segi ilmiah, ekonomi, maupun lingkungan. Penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam bidang pengolahan citra, kecerdasan buatan, dan konservasi tumbuhan, serta membuka peluang baru untuk aplikasi teknologi AI dalam berbagai bidang kehidupan.

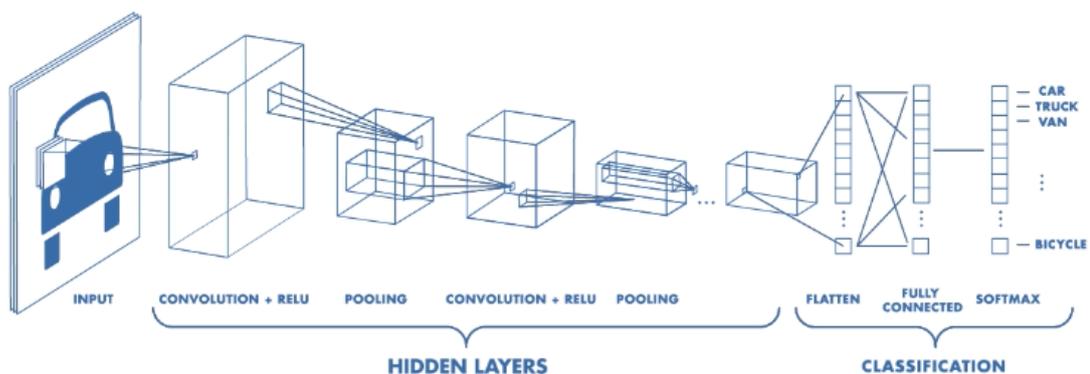
## 2. Tinjauan Pustaka

### 2.1 Convolutional Neural Network

Jaringan saraf tiruan (JST) telah menjadi alat yang revolusioner dalam pengolahan citra, menawarkan arsitektur yang terinspirasi oleh otak manusia untuk memproses dan menganalisis informasi visual. Kemampuannya dalam belajar fitur secara hierarki melalui operasi konvolusi dan *pooling* menjadikannya unggul dalam berbagai tugas, seperti klasifikasi gambar, deteksi objek, dan segmentasi gambar[1]

Jaringan saraf tiruan untuk pengolahan citra, seperti *Convolutional Neural Network* (CNN), memiliki arsitektur yang unik yang memungkinkan mereka belajar fitur secara hierarkis dari gambar[2]. Operasi konvolusi menggunakan *filter* kecil untuk meluncur di atas gambar, menangkap pola dan aktivasi lokal. Hasil konvolusi kemudian digabungkan melalui operasi *pooling* yang mengurangi dimensi spasial sambil mempertahankan informasi penting. Proses ini diulang melalui beberapa lapisan, memungkinkan jaringan untuk belajar fitur yang semakin abstrak dan kompleks pada tingkat yang lebih tinggi.

Kemampuan JST dalam belajar fitur hierarkis membuka berbagai aplikasi dalam pengolahan citra. Dalam klasifikasi gambar, JST dapat mengidentifikasi dan mengkategorikan objek dalam gambar dengan tingkat akurasi yang tinggi. Dalam deteksi objek, JST dapat menemukan dan melokalisasi objek dalam gambar, bahkan jika objek tersebut terhalang atau muncul dalam berbagai pose. Dalam segmentasi gambar, JST dapat memisahkan objek yang berbeda dalam gambar, menghasilkan representasi yang lebih rinci dari adegan. Kemampuan JST dalam pengolahan citra telah memberikan dampak yang signifikan pada berbagai bidang, termasuk medis, industri, dan *riset*. JST digunakan dalam diagnosis medis untuk mendeteksi penyakit seperti kanker, dalam kontrol kualitas industri untuk mengidentifikasi cacat pada produk, dan dalam penelitian ilmiah untuk memahami struktur dan fungsi objek kompleks.



Gambar 1. CNN

## KLASIFIKASI JENIS BUNGA DENGAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK* (CNN) MENGGUNAKAN METODE *REGION-BASED CONVOLUTIONAL NEURAL NETWORK* (R-CNN)

Lapisan konvolusi adalah inti dari CNN. Lapisan ini terdiri dari *filter* kecil (biasanya berukuran 3x3 atau 5x5 piksel) yang bergerak di atas gambar *input*. Setiap *filter* berisi bobot yang akan dipelajari selama proses pelatihan. *Filter* ini mengalikan setiap nilai piksel dalam gambar *input* dengan nilai bobot yang sesuai, dan menjumlahkan hasil perkalian tersebut. Hasilnya adalah peta fitur yang menunjukkan aktivasi *filter* pada berbagai lokasi dalam gambar[3]

Lapisan *pooling* bertujuan untuk mengurangi dimensi spasial dari peta fitur sambil mempertahankan informasi penting. Ada beberapa jenis operasi *pooling*, seperti *pooling* maksimum dan *pooling* rata-rata. *Pooling* maksimum mengambil nilai maksimum dari jendela kecil yang bergerak di atas peta fitur, sedangkan *pooling* rata-rata mengambil nilai rata-rata dari jendela tersebut[4].

Fungsi aktivasi digunakan untuk menambahkan non-linearitas pada model CNN. Fungsi aktivasi yang umum digunakan dalam CNN termasuk ReLU (*Rectified Linear Unit*) dan fungsi sigmoid. Fungsi ReLU menghasilkan *output* 0 jika *input* kurang dari 0, dan inputnya sendiri jika inputnya lebih besar dari atau sama dengan 0. Fungsi sigmoid menghasilkan *output* antara 0 dan 1[5].

Lapisan *fully connected* (FC) terletak di akhir arsitektur CNN. Lapisan ini menghubungkan semua neuron di lapisan sebelumnya dengan semua neuron di lapisan ini. Lapisan FC digunakan untuk mengklasifikasikan gambar *input* berdasarkan fitur yang telah diekstraksi oleh lapisan-lapisan sebelumnya.

Lapisan *output* menghasilkan probabilitas untuk setiap kelas yang mungkin dalam gambar *input*. Kelas dengan probabilitas tertinggi dianggap sebagai kelas yang paling mungkin untuk gambar tersebut.

Perhitungan dalam CNN melibatkan berbagai operasi matematis yang kompleks. Berikut adalah beberapa perhitungan kunci yang terlibat dalam CNN:

### 1. Operasi Konvolusi:

Operasi konvolusi dapat direpresentasikan secara matematis sebagai berikut:

$$F_{ij}(x, y) = \sum \sum W_{ij} * I(x + i, y + j)$$

di mana:

F adalah peta fitur

I adalah gambar *input*

W adalah *filter*

i dan j adalah indeks piksel dalam *filter*

x dan y adalah koordinat piksel dalam gambar *input*

### 2. Operasi *Pooling*:

Operasi *pooling* dapat dihitung dengan mengambil nilai maksimum atau rata-rata dari jendela kecil yang bergerak di atas peta fitur.

### 3. Fungsi Aktivasi:

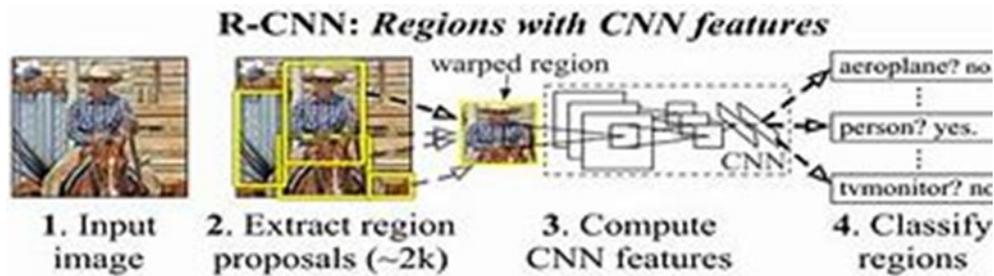
Fungsi aktivasi ReLU dapat dihitung sebagai berikut:

$$\text{ReLU}(x) = \max(0, x)$$

Fungsi aktivasi sigmoid dapat dihitung sebagai berikut:

$$\text{sigmoid}(x) = 1 / (1 + \exp(-x))$$

## 2.1 Region-Based Convolutional Neural Network



Gambar 2. R-CNN

*Region-Based Convolutional Neural Network* (R-CNN) merupakan algoritma *Convolutional Neural Network* (CNN) yang dirancang khusus untuk deteksi dan klasifikasi objek dalam gambar. Algoritma ini terbagi menjadi tiga tahapan utama:

### 1. *Region Proposal*:

Pada tahap ini, algoritma R-CNN menghasilkan proposal *region* yang berpotensi mengandung objek dalam gambar. Proposal *region* ini dapat diperoleh dengan berbagai metode, seperti *Selective Search*, *Edge Boxes*, atau *Region Proposal Network* (RPN). Setiap proposal *region* didefinisikan oleh koordinat batas (*bounding box*) yang mengelilingi area yang diduga mengandung objek[6].

### 2. *Feature Extraction*:

Setelah proposal *region* dihasilkan, algoritma R-CNN mengekstraksi fitur dari setiap *region* proposal menggunakan CNN. Fitur-fitur ini mewakili karakteristik visual dari objek dalam proposal *region*, seperti bentuk, tekstur, dan warna. CNN yang digunakan dalam R-CNN biasanya dilatih terlebih dahulu pada *dataset* gambar yang besar dengan label objek yang sesuai[7].

### 3. Klasifikasi:

Pada tahap akhir, algoritma R-CNN mengklasifikasikan objek dalam setiap proposal *region* berdasarkan fitur yang telah diekstraksi pada tahap sebelumnya. Klasifikasi dilakukan dengan menggunakan *classifier*, seperti *Support Vector Machine* (SVM) atau *softmax* layer, yang dilatih pada *dataset* yang sama dengan CNN. *Classifier* menghasilkan probabilitas untuk setiap kelas objek yang mungkin dalam proposal *region*. Kelas dengan probabilitas tertinggi dianggap sebagai kelas yang paling mungkin untuk objek dalam proposal *region* tersebut.

## 3. Metode Penelitian

### 3.1 Metode Pengumpulan Data

Data yang digunakan dalam penelitian ini terdiri dari gambar bunga anggrek yang terbagi menjadi tiga kelas utama, yaitu Anggrek Bulan (*Phalaenopsis*), Anggrek *Dendrobium*, dan Anggrek Tanah (*Paphiopedilum*). Setiap kelas terdiri dari sekitar 40 gambar, yang diperoleh dari Dinas Ketahanan Pangan dan Tanaman Pangan dan

**KLASIFIKASI JENIS BUNGA DENGAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK* (CNN) MENGGUNAKAN METODE *REGION-BASED CONVOLUTIONAL NEURAL NETWORK* (R-CNN)**

Hortikultura Provinsi Lampung serta Dinas Ketahanan Pangan dan Pertanian dan Perikanan Kota Metro dan para UMKM toko bunga di Provinsi Lampung dan berbagai sumber termasuk database publik, situs web hortikultura, dan koleksi pribadi. Pemilihan *dataset* yang beragam ini bertujuan untuk mencakup variasi dalam setiap kelas, seperti perbedaan warna, ukuran, dan kondisi pencahayaan, sehingga model yang dilatih dapat mengenali berbagai variasi visual dari setiap spesies anggrek.

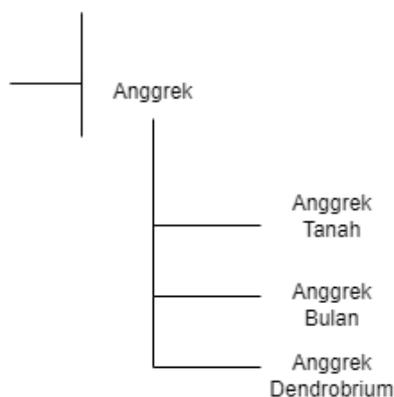
Proses pengumpulan data dilakukan dengan mengambil gambar dan mengunduh gambar dari sumber-sumber yang tepercaya dan memastikan setiap gambar memiliki resolusi yang memadai untuk analisis lebih lanjut. Gambar-gambar yang diunduh kemudian dikategorikan dan diberi label sesuai dengan kelasnya masing-masing. Selanjutnya, dilakukan proses pra-pemrosesan untuk meningkatkan kualitas gambar, yang meliputi perubahan ukuran, normalisasi warna, dan penghapusan noise. Proses ini penting untuk memastikan bahwa data yang digunakan untuk melatih model memiliki kualitas yang konsisten dan memadai.

Setelah proses pra-pemrosesan selesai, *dataset* dibagi menjadi dua bagian: data pelatihan dan data pengujian, dengan perbandingan 70:20. Data pelatihan digunakan untuk melatih model R-CNN, sementara data pengujian digunakan untuk mengevaluasi performa model. Pembagian ini dilakukan secara acak untuk menghindari bias dan memastikan bahwa model dapat menggeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya. Dengan *dataset* yang telah diproses dan dibagi dengan baik, diharapkan model yang dihasilkan mampu melakukan klasifikasi jenis bunga anggrek dengan akurasi yang tinggi.

Tabel 1. Kategori *Dataset*

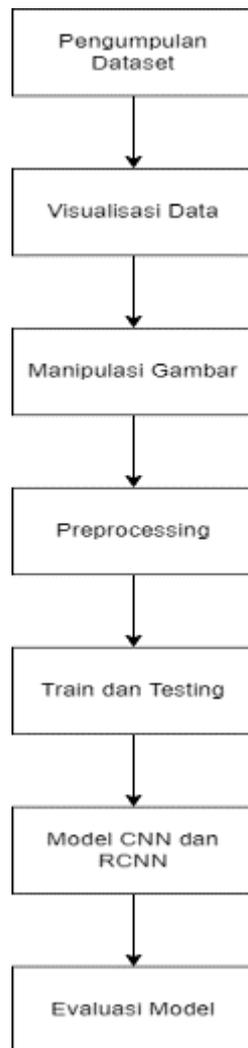
Kategori	Jumlah Gambar
Anggrek Tanah	20
Anggrek Bulan	20
Anggrek Dendrobium	20

Untuk *dataset*nya dibuat di dalam google drive dan dimountkan pada codingan. Untuk *Path* dari *dataset* tersebut ialah sebagai berikut ini :



Gambar 3. Direktori *Dataset* Anggrek

### 3.2 Rancangan Penelitian



Gambar 4. Teknik Analisis Data

### 3.3 Tempat Penelitian

Penelitian ini dilakukan di laboratorium atau pusat riset di Provinsi Lampung yang dilengkapi dengan perangkat keras dan perangkat lunak komputer yang diperlukan untuk pengembangan dan pelatihan model *Convolutional Neural Network* (CNN) dan *Region-Based Convolutional Neural Network* (R-CNN). Selain itu, pengumpulan data gambar bunga dapat melibatkan kunjungan ke kebun botani, kebun anggrek, Dinas Ketahanan Pangan dan Tanaman Pangan dan Hortikultura Provinsi Lampung serta Dinas Ketahanan Pangan dan Pertanian dan Perikanan Kota Metro dan para UMKM toko bunga di Provinsi Lampung dan sumber data lain yang menyediakan koleksi gambar bunga yang diperlukan.

**KLASIFIKASI JENIS BUNGA DENGAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK* (CNN) MENGGUNAKAN METODE *REGION-BASED CONVOLUTIONAL NEURAL NETWORK* (R-CNN)**

### 3.4 Waktu Penelitian

Penelitian ini dilakukan mulai bulan Mei sampai dengan Juli 2024.

Tabel 2. Tahapan Penelitian

Kegiatan	Mei	Juni	Juli
Pengumpulan Dataset			
Training dan Testing			
Evaluasi			

### 3.5 Populasi

Populasi dalam penelitian ini adalah semua jenis bunga yang termasuk dalam kategori yang akan diklasifikasikan, khususnya anggrek. Populasi ini mencakup berbagai spesies anggrek dengan berbagai karakteristik visual seperti bentuk kelopak, pola warna, dan tekstur.

### 3.6 Sampel

Sampel dalam penelitian ini adalah sejumlah gambar bunga anggrek yang dipilih secara representatif dari populasi untuk digunakan dalam pelatihan dan pengujian model klasifikasi. Sampel ini terbagi menjadi tiga kelas utama, yaitu Anggrek Bulan (*Phalaenopsis*), Anggrek Dendrobium, dan Anggrek Tanah (*Paphiopedilum*), dengan sekitar 40 gambar untuk setiap kelas. Sampel ini mencakup variasi dalam setiap kelas, seperti perbedaan warna, ukuran, dan kondisi pencahayaan, sehingga model yang dilatih dapat mengenali berbagai variasi visual dari setiap spesies anggrek.

### 3.7 Teknik Pengumpulan Data

1. Pengunduhan dan Pengambilan Gambar: Gambar-gambar bunga anggrek dapat diunduh dan diambil di Dinas Ketahanan Pangan dan Tanaman Pangan dan Hortikultura Provinsi Lampung serta Dinas Ketahanan Pangan dan Pertanian dan Perikanan Kota Metro dan para UMKM toko bunga di Provinsi Lampung serta dari sumber-sumber yang terpercaya, seperti database publik, situs web hortikultura, koleksi pribadi, atau sumber lain yang menyediakan gambar bunga dengan resolusi yang memadai.
2. Kategorisasi dan Pelabelan: Setiap gambar bunga yang diunduh kemudian dikategorikan berdasarkan jenisnya, misalnya Anggrek Bulan, Anggrek Dendrobium, atau Anggrek Tanah. Selanjutnya, setiap gambar diberi label sesuai dengan kelasnya masing-masing.
3. Pra-Pemrosesan Gambar: Gambar-gambar yang telah dikategorikan dan dilabeli akan melalui proses pra-pemrosesan untuk meningkatkan kualitasnya. Pra-pemrosesan ini dapat mencakup pengubahan ukuran gambar, normalisasi warna, dan penghapusan *noise* untuk memastikan kualitas gambar yang konsisten dan memadai.
4. Augmentasi Data: Selain itu, teknik augmentasi data juga dapat diterapkan pada *dataset* gambar bunga. Augmentasi data dapat membantu meningkatkan generalisasi model dengan memperkenalkan variasi kecil

pada gambar-gambar pelatihan, seperti rotasi, pembalikan horizontal, *zoom*, dan penyesuaian cahaya.

### 3.8 Teknik Analisis Data

1. Pembagian *Dataset*: *Dataset* gambar bunga anggrek yang telah dikumpulkan dan diproses dapat dibagi menjadi dua bagian, yaitu data pelatihan dan data pengujian. Pembagian ini biasanya dilakukan dengan perbandingan 70:30 atau 80:20, di mana data pelatihan digunakan untuk melatih model dan data pengujian digunakan untuk mengevaluasi performa model.
2. Pelatihan Model: Model *Convolutional Neural Network* (CNN) dan *Region-Based Convolutional Neural Network* (R-CNN) dapat dilatih menggunakan data pelatihan yang telah disiapkan. Proses pelatihan ini melibatkan iterasi berulang untuk mengoptimalkan parameter model agar dapat mengenali dan mengklasifikasikan gambar bunga dengan akurasi tinggi.
3. Evaluasi Model: Setelah pelatihan selesai, model yang telah dilatih akan dievaluasi menggunakan data pengujian yang belum pernah dilihat sebelumnya. Evaluasi dilakukan untuk mengukur performa model dalam mengklasifikasikan jenis bunga anggrek, seperti akurasi, presisi, recall, dan *F1-score*.
4. Analisis Hasil: Hasil evaluasi model akan dianalisis untuk mengevaluasi keefektifan dan keakuratan model dalam klasifikasi jenis bunga anggrek. Analisis ini dapat mencakup identifikasi kelemahan model, perbandingan performa antara berbagai jenis model, dan saran perbaikan untuk meningkatkan performa model di masa depan.

## 4. Hasil dan Pembahasan

### 4.1 Pembuatan Model CNN

Model CNN ini adalah model *Sequential* yang terdiri dari beberapa lapisan konvolusi dan *pooling* yang bertujuan untuk ekstraksi fitur dari gambar, diikuti dengan lapisan *dense* untuk klasifikasi. Model ini dimulai dengan lapisan konvolusi (Conv2D) dengan 32 *filter* berukuran 3x3 diikuti dengan lapisan *pooling* (*MaxPooling2D*) untuk mengurangi dimensi, diulang dengan lapisan konvolusi kedua dan ketiga masing-masing dengan 64 dan 96 *filter*, serta lapisan konvolusi keempat dengan 128 *filter*. Setiap lapisan konvolusi diikuti oleh lapisan *pooling* untuk mengurangi dimensi spasial. Setelah ekstraksi fitur, lapisan *Flatten* digunakan untuk meratakan *output* sebelum masuk ke lapisan *dense* dengan 256 *neuron*, dan akhirnya lapisan *dense* terakhir dengan 5 *neuron* untuk klasifikasi akhir. Model ini memiliki total 2.841.253 parameter yang dapat dilatih.

```
def create_model():
    model = Sequential()
    # Layer 1: Convolutional layer with 32 filters, kernel size 3x3
    model.add(Conv2D(32, (3, 3), input_shape=(150, 150, 3), padding='same', activation='relu'))
    model.add(MaxPooling2D((2, 2)))

    # Layer 2: Convolutional layer with 64 filters, kernel size 3x3
    model.add(Conv2D(64, (3, 3), padding='same', activation='relu'))
    model.add(MaxPooling2D((2, 2)))

    # Layer 3: Convolutional layer with 96 filters, kernel size 3x3
    model.add(Conv2D(96, (3, 3), padding='same', activation='relu'))
    model.add(MaxPooling2D((2, 2)))

    # Layer 4: Convolutional layer with 128 filters, kernel size 3x3
    model.add(Conv2D(128, (3, 3), padding='same', activation='relu'))
    model.add(MaxPooling2D((2, 2)))

    # Add Dense layers on top
    # 1. Flatten the 4th layer output to 1D
    # 2. Add dense layer to top
    model.add(Flatten())
    model.add(Dense(256, activation='relu'))
    model.add(Dense(5, activation='softmax'))

    return model
```

Model: "sequential\_1"

**KLASIFIKASI JENIS BUNGA DENGAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK* (CNN) MENGGUNAKAN METODE *REGION-BASED CONVOLUTIONAL NEURAL NETWORK* (R-CNN)**

Layer (type)	Output Shape	Param #
conv2d_4 (Conv2D)	(None, 150, 150, 32)	896
max_pooling2d_4 (MaxPooling2D)	(None, 75, 75, 32)	0
conv2d_5 (Conv2D)	(None, 75, 75, 64)	18496
max_pooling2d_5 (MaxPooling2D)	(None, 37, 37, 64)	0
conv2d_6 (Conv2D)	(None, 37, 37, 96)	55392
max_pooling2d_6 (MaxPooling2D)	(None, 18, 18, 96)	0
conv2d_7 (Conv2D)	(None, 18, 18, 128)	110720
max_pooling2d_7 (MaxPooling2D)	(None, 9, 9, 128)	0
flatten_1 (Flatten)	(None, 10368)	0
dense_2 (Dense)	(None, 256)	2654464
dense_3 (Dense)	(None, 5)	1285

Total params: 2841253 (10.84 MB)  
 Trainable params: 2841253 (10.84 MB)  
 Non-trainable params: 0 (0.00 Byte)

Gambar 5. Pembuatan Model *Sequential*

Model *Convolutional Neural Network* (CNN) ini terdiri dari empat lapisan konvolusi berturut-turut, masing-masing diikuti oleh lapisan *max pooling* untuk mengekstraksi fitur dari gambar. Dimulai dengan lapisan *input* yang menerima gambar berukuran 150x150 piksel dengan 3 *channel* warna (RGB), setiap lapisan konvolusi menggunakan *filter* 3x3 dengan jumlah *filter* berturut-turut 32, 64, 96, dan 128. Setelah setiap lapisan konvolusi, dilakukan *max pooling* dengan *filter* 2x2 untuk mengurangi dimensi spasial gambar. Lalu, hasilnya *diflatten* menjadi vektor satu dimensi sebelum melewati dua lapisan *Dense*: yang pertama dengan 256 neuron menggunakan fungsi aktivasi ReLU untuk mempelajari representasi fitur yang lebih abstrak, dan yang kedua dengan 5 *neuron* dan aktivasi *softmax* untuk klasifikasi multi-kelas. Model ini ditujukan untuk memproses gambar dan mengklasifikasikan mereka ke dalam salah satu dari lima kategori yang berbeda berdasarkan arsitektur yang telah dijelaskan.

#### 4. 2 *Training Model*

Langkah selanjutnya adalah memulai proses pelatihan model CNN yang telah

dibuat sebelumnya. Proses ini dilakukan dengan menentukan ukuran batch sebesar 32 dan jumlah epoch sebanyak 50. Model dilatih menggunakan metode `fit()` yang memanfaatkan objek `ImageDataGenerator` (`datagen`) untuk melakukan augmentasi data secara *real-time* pada data pelatihan (`trainImg` dan `trainLabel`). Proses ini bertujuan untuk memperluas variasi data yang diberikan ke model selama pelatihan guna mengurangi *overfitting*. Validasi dilakukan menggunakan data validasi (`validImg` dan `validLabel`) untuk memonitor kinerja model pada data yang tidak digunakan selama pelatihan. Hasil dari pelatihan, termasuk akurasi dan *loss*, akan dicatat dalam objek `History` untuk analisis dan evaluasi lebih lanjut.

```

# Start training
batch_size = 32
epochs = 50

History = model.fit(
    datagen.flow(training, trainLabel, batch_size=batch_size),
    epochs=epochs,
    validation_data=(validing, validLabel),
    verbose=1
)

# Start training
batch_size = 32
epochs = 50

History = model.fit(
    datagen.flow(training, trainLabel, batch_size=batch_size),
    epochs=epochs,
    validation_data=(validing, validLabel),
    verbose=1
)

Epoch 1/50 [.....] - 40 40/step - loss: 1.1016 - accuracy: 0.4444 - val_loss: 5.1470 - val_accuracy: 0.5000
Epoch 2/50 [.....] - 00 180m/step - loss: 3.3951 - accuracy: 0.6667 - val_loss: 0.8312 - val_accuracy: 0.5000
Epoch 3/50 [.....] - 00 180m/step - loss: 0.8030 - accuracy: 0.6667 - val_loss: 1.2593 - val_accuracy: 0.5000
Epoch 4/50 [.....] - 00 180m/step - loss: 1.7160 - accuracy: 0.3333 - val_loss: 0.4998 - val_accuracy: 0.5000
Epoch 5/50 [.....] - 00 180m/step - loss: 0.7637 - accuracy: 0.3333 - val_loss: 0.7504 - val_accuracy: 0.5000
Epoch 6/50 [.....] - 00 180m/step - loss: 0.5560 - accuracy: 0.6667 - val_loss: 0.8306 - val_accuracy: 0.5000
Epoch 7/50 [.....] - 00 180m/step - loss: 0.4454 - accuracy: 0.6667 - val_loss: 0.8812 - val_accuracy: 0.5000
Epoch 8/50 [.....] - 00 180m/step - loss: 0.8214 - accuracy: 0.6667 - val_loss: 0.7363 - val_accuracy: 0.5000
Epoch 9/50 [.....] - 00 180m/step - loss: 0.8724 - accuracy: 0.6667 - val_loss: 0.7359 - val_accuracy: 0.5000
Epoch 10/50 [.....] - 00 122m/step - loss: 0.5319 - accuracy: 0.6667 - val_loss: 0.6955 - val_accuracy: 0.5000
Epoch 11/50 [.....] - 00 180m/step - loss: 0.4468 - accuracy: 0.6667 - val_loss: 0.4945 - val_accuracy: 0.5000
Epoch 12/50 [.....] - 00 180m/step - loss: 0.4029 - accuracy: 0.6667 - val_loss: 0.6277 - val_accuracy: 0.5000
Epoch 13/50 [.....] - 00 180m/step - loss: 0.3646 - accuracy: 0.7778 - val_loss: 0.4026 - val_accuracy: 0.5000
Epoch 14/50 [.....] - 00 180m/step - loss: 0.2760 - accuracy: 1.0000 - val_loss: 0.4026 - val_accuracy: 0.5000
Epoch 15/50 [.....] - 00 180m/step - loss: 0.2448 - accuracy: 0.8889 - val_loss: 0.4068 - val_accuracy: 0.5000

```

Gambar 6. Proses *Training Model*

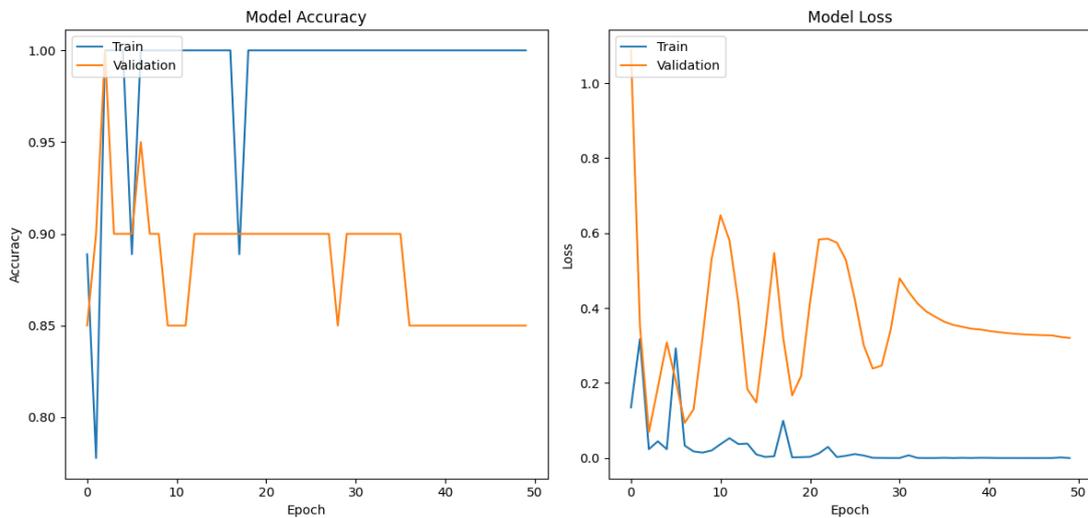
Dari hasil pelatihan yang ditampilkan, dapat dilihat bahwa model CNN sedang dilatih dengan 50 *epoch* menggunakan *batch size* sebesar 32. Pada *epoch* pertama, *loss training* sebesar 1.1016 dengan akurasi 44.44%, sedangkan pada data validasi, terdapat *loss* sebesar 5.1470 dengan akurasi 50.00%. Pada *epoch* kedua, terjadi peningkatan akurasi pada data training menjadi 66.67% dengan *loss* 3.3951, namun akurasi pada data validasi tetap pada 50.00% dengan *loss* 0.8312. *Epoch* berikutnya menunjukkan variasi dalam kinerja model, di mana terjadi fluktuasi antara akurasi dan *loss* baik pada data *training* maupun validasi.

Secara umum, model ini menunjukkan kemampuan untuk mempelajari pola dari data *training*, terlihat dari peningkatan akurasi pada beberapa *epoch* awal. Namun, fluktuasi yang terjadi pada akurasi dan *loss* pada data validasi menunjukkan bahwa model mungkin menghadapi tantangan dalam generalisasi pada data yang tidak terlihat selama pelatihan. Untuk *loss*, pada iterasi hingga epoch ke-15, terlihat bahwa *loss* pada data training menurun secara konsisten dari 1.1016 menjadi 0.2448, sedangkan *loss* pada data validasi mengalami perubahan yang lebih variatif dari 5.1470 menjadi 0.4068. Hal ini menunjukkan bahwa model mulai menyesuaikan diri dengan data *training* dan menunjukkan tanda-tanda untuk lebih baik dalam hal generalisasi pada data validasi dengan mempertahankan *loss* yang rendah.

### 4.3 Evaluasi

Berikut ialah hasil *training* dan testing dari model yang dibuat untuk melatih *dataset* dari 3 kategori jenis bunga anggrek tersebut.

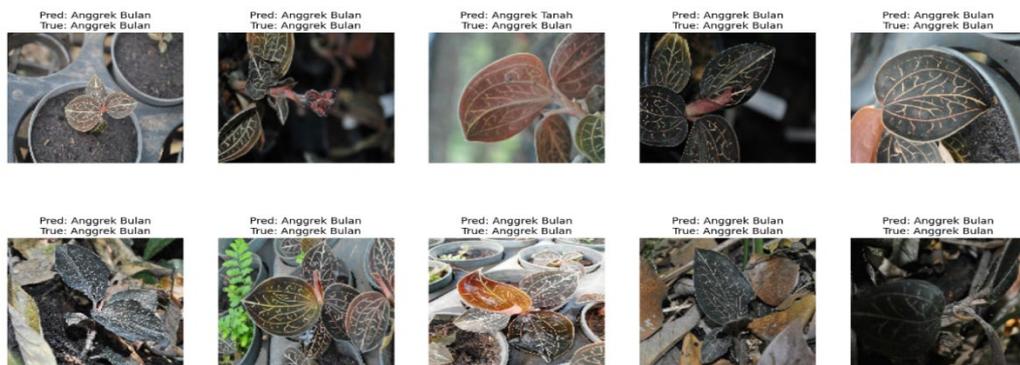
# KLASIFIKASI JENIS BUNGA DENGAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK* (CNN) MENGGUNAKAN METODE *REGION-BASED CONVOLUTIONAL NEURAL NETWORK* (R-CNN)



Gambar 7. Visualisasi *Training* dan *Testing* Model

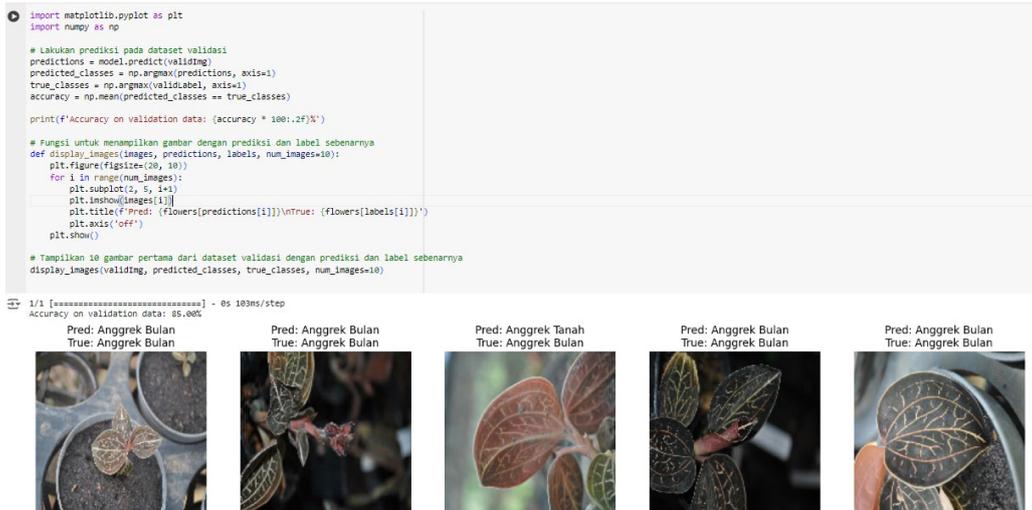
Grafik akurasi model pada Gambar 7 menunjukkan tren yang menarik. Pada awal pelatihan, model mengalami peningkatan akurasi yang signifikan, baik pada data latih maupun validasi. Namun, setelah beberapa *epoch*, akurasi model mencapai *plateau* (datar) dan fluktuasi secara signifikan. Hal ini mengindikasikan bahwa model telah mempelajari fitur-fitur utama dari data latih dan kesulitan dalam menggeneralisasi ke data yang belum pernah dilihat sebelumnya. Fluktuasi yang besar pada akurasi validasi menunjukkan adanya keseimbangan, di mana model baik untuk digunakan.

Setelah melakukan model Evaluasi, maka akan dilakukan prediksi terhadap kebenaran dari hasil prediksi model CNN yang telah dibuat tersebut.



Gambar 8. Gambar untuk Prediksi

Berikut ialah codingan yang memperjelas bagaimana gambar prediksi tersebut dapat dihasilkan.



Gambar 9. Hasil Prediksi Gambar

Program tersebut memiliki beberapa tahapan penting untuk melakukan prediksi gambar menggunakan model CNN yang telah dilatih sebelumnya. Pertama, dilakukan prediksi menggunakan model terhadap *dataset* validasi (*valid\_img*). Prediksi dilakukan dengan memanggil metode `predict` pada model, yang mengembalikan probabilitas prediksi untuk setiap kelas. Selanjutnya, dari hasil prediksi tersebut, digunakan fungsi `np.argmax(predictions, axis=1)` untuk mendapatkan kelas dengan nilai probabilitas tertinggi sebagai prediksi akhir. Variabel *predicted\_classes* dan *true\_classes* digunakan untuk menyimpan kelas prediksi dan kelas sebenarnya dari *dataset* validasi.

Selanjutnya, untuk mengevaluasi akurasi prediksi, dilakukan perhitungan persentase akurasi dengan menghitung rata-rata dari hasil perbandingan antara *predicted\_classes* dan *true\_classes*. Hasil akurasi kemudian dicetak ke layar untuk memberikan gambaran seberapa baik model dapat mengklasifikasikan gambar pada *dataset* validasi.

Fungsi `display_images` digunakan untuk menampilkan visualisasi dari hasil prediksi. Fungsi ini menerima *input* berupa gambar (*images*), prediksi kelas (*predictions*), label sebenarnya (*labels*), dan jumlah gambar yang ingin ditampilkan (*num\_images*). Dalam fungsi ini, digunakan `plt.subplot` untuk menampilkan masing-masing gambar dengan label prediksi dan label sebenarnya. Grafik tersebut menggambarkan 10 gambar pertama dari *dataset* validasi, dimana setiap gambar diberi judul yang menunjukkan prediksi kelas dan label sebenarnya menggunakan kelas yang sesuai dari *array flowers*.

Hasil akurasi sebesar 85.00% yang didapatkan dari model pada *dataset* validasi menunjukkan tingkat keberhasilan model dalam mengklasifikasikan gambar-gambar yang belum pernah dilihat sebelumnya. Akurasi ini dihitung berdasarkan perbandingan antara kelas-kelas yang diprediksi oleh model dengan kelas sebenarnya dari gambar-gambar tersebut. Semakin tinggi nilai akurasi, semakin baik model dalam mempelajari pola-pola yang ada pada data latih dan mampu menggeneralisasi pola-pola tersebut pada data yang baru. Dengan akurasi sebesar 85.00%, ini menunjukkan bahwa model CNN yang telah dilatih telah mampu menghasilkan prediksi yang konsisten dan tepat dalam konteks klasifikasi gambar yang digunakan

# KLASIFIKASI JENIS BUNGA DENGAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK* (CNN) MENGGUNAKAN METODE *REGION-BASED CONVOLUTIONAL NEURAL NETWORK* (R-CNN)

## 5. Kesimpulan

Dalam konteks pembuatan dan evaluasi model *Convolutional Neural Network* (CNN) menggunakan metode *Region-Based Convolutional Neural Network* (R-CNN) untuk klasifikasi gambar bunga anggrek dengan hasil akurasi sebesar 85.00% pada *dataset* validasi menunjukkan bahwa model yang dikembangkan mampu menghasilkan prediksi yang baik dalam mengenali pola-pola yang telah dipelajari dari data latih. Akurasi yang tinggi ini mengindikasikan bahwa model dapat mengklasifikasikan gambar-gambar baru dengan tingkat keberhasilan yang signifikan. Hal ini merupakan hasil dari penggunaan arsitektur CNN yang tepat, termasuk lapisan-lapisan konvolusi untuk mengekstrak fitur-fitur visual dari gambar, dilanjutkan dengan lapisan-lapisan *Dense* untuk melakukan klasifikasi.

Untuk aplikasi praktisnya, model ini dapat diimplementasikan dalam sistem otomatis untuk identifikasi jenis-jenis anggrek, yang dapat digunakan dalam bidang botani atau agrikultur untuk pengelolaan dan konservasi spesies anggrek. Namun, untuk penelitian lebih lanjut, disarankan untuk mengeksplorasi peningkatan model dengan menggabungkan teknik augmentasi data atau menggunakan arsitektur CNN yang lebih kompleks untuk menangani variasi yang lebih luas dalam gambar. Selain itu, studi lanjutan juga dapat mencakup eksperimen dengan *dataset* yang lebih besar atau lebih beragam untuk meningkatkan generalisasi model serta investigasi pada optimasi *hyperparameter* untuk mencapai performa yang lebih optimal.

## 6. Saran

Untuk meningkatkan performa model *Convolutional Neural Network* (CNN) yang telah dikembangkan, berikut adalah beberapa saran yang dapat dipertimbangkan:

1. **Penyetelan Hyperparameter:** Lakukan eksperimen lebih lanjut untuk menyesuaikan hyperparameter seperti *learning rate*, jumlah *epoch*, dan ukuran batch. *Learning rate* yang optimal dapat mempercepat konvergensi dan menghindari masalah seperti overshooting atau stagnasi dalam proses pelatihan. Selain itu, jumlah *epochs* yang cukup tetapi tidak berlebihan juga penting untuk memastikan model mencapai titik konvergensi tanpa *overfitting*.
2. **Augmentasi Data:** Terapkan augmentasi data pada *dataset* latih. Augmentasi data dapat membantu meningkatkan generalisasi model dengan memperkenalkan variasi kecil pada gambar-gambar pelatihan, seperti rotasi, pembalikan horizontal, *zoom*, dan penyesuaian cahaya. Ini akan membantu model untuk lebih baik dalam mengenali berbagai variasi dari objek yang sama.
3. **Regularisasi:** Pertimbangkan penggunaan teknik regularisasi seperti *dropout* atau *L2 regularization* pada lapisan-lapisan *dense*. Hal ini dapat membantu mengurangi *overfitting* dengan mengurangi ketergantungan antar-neuron dan mendorong representasi yang lebih umum.
4. **Pemilihan Arsitektur:** Evaluasi alternatif arsitektur CNN yang lebih kompleks atau yang sudah terbukti dalam tugas klasifikasi gambar. Model-model yang lebih dalam atau yang menggunakan blok-blok residual (seperti ResNet) atau inception modules (seperti *InceptionV3*) sering kali dapat menghasilkan performa yang lebih baik dalam mengenali fitur-fitur yang kompleks.
5. **Evaluasi Tambahan:** Lakukan evaluasi lebih lanjut terhadap *dataset* validasi yang lebih besar atau *dataset* yang belum dilihat sebelumnya (test set). Hal ini akan memberikan gambaran yang lebih komprehensif tentang kemampuan generalisasi model terhadap data baru.

## Daftar Pustaka

- [1] J. Saraf, T. Dengan, M. *Backpropagation*, U. Mendeteksi Gangguan, P. Kiki, and S. Kusumadewi, "Media Informatika," *Media Informatika*, vol. 2, no. 2, 2004.
- [2] Suartika, "KLASIFIKASI CITRA MENGGUNAKAN *CONVOLUTIONAL NEURAL NETWORK* (CNN) PADA CALTECH 101."
- [3] "Algoritma Convolutional Neural Network - EPG 2".
- [4] D. R. R. Putra and R. A. Saputra, "IMPLEMENTASI *CONVOLUTIONAL NEURAL NETWORK* (CNN) UNTUK MENDETEKSI PENGGUNAAN MASKER PADA GAMBAR," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, Aug. 2023, doi: 10.23960/jitet.v11i3.3286.
- [5] "PaperJSI-MadeSatriaWibawa".
- [6] H. D. Hekmatyar, W. A. Saputra, and C. Ramdani, "Klasifikasi Pneumonia Dengan *Deep Learning Faster Region Convolutional Neural Network* Arsitektur VGG16 dan ResNet50," *InComTech : Jurnal Telekomunikasi dan Komputer*, vol. 12, no. 3, p. 186, Dec. 2022, doi: 10.22441/incomtech.v12i3.15112.
- [7] I. LAKI-LAKI DAN PEREMPUAN Honainah, "Honainah,-Penerapan Metode *Faster Region Convolutional Neural Network (Faster R-CNN)* Untuk Deteksi Otomatis Interaksi Laki-Laki dan Perempuan PENERAPAN METODE *FASTER REGION CONVOLUTIONAL NEURAL NETWORK (FASTER R-CNN)* UNTUK DETEKSI OTOMATIS."