

## IMPLEMENTASI DEEP LEARNING ALGORITMA *CONVOLUTIONAL NEURAL NETWORK* UNTUK KLASIFIKASI KESEGRAN BUAH DAN SAYUR

Annisa Latifa<sup>1</sup>, Nor Hikmah<sup>\*2</sup>, Hendra Kurniawan<sup>3</sup>, Kardilah Rohmat Hidayat<sup>4</sup>

<sup>1,2,3,4</sup>Universitas Amikom Yogyakarta, Yogyakarta

Email: <sup>1</sup>annisaltf@students.amikom.ac.id, <sup>2</sup>hikmah@amikom.ac.id, <sup>3</sup>hendrakurniawan@amikom.ac.id,

<sup>4</sup>kardilah.rh@amikom.ac.id

\*Penulis Korespondensi

(Naskah masuk: 7 Maret 2025, diterima untuk diterbitkan: 17 September 2025)

### Abstrak

Buah dan sayur merupakan sumber utama vitamin, mineral, dan serat yang sangat penting untuk menjaga kesehatan tubuh. WHO merekomendasikan konsumsi sebesar 400 gram per hari untuk gizi seimbang. Namun, kualitas dan kesegaran buah dan sayur sering kali sulit diidentifikasi secara manual, terutama dalam skala besar, karena metode tradisional memiliki keterbatasan akurasi dan rentan terhadap kesalahan manusia. Kemajuan kecerdasan buatan, khususnya *deep learning*, memberikan solusi inovatif dalam klasifikasi citra. *Convolutional Neural Network* (CNN), telah terbukti efektif dalam pengenalan dan klasifikasi gambar. Penelitian ini menerapkan CNN dengan arsitektur *Inception V3* dalam mengklasifikasikan kesegaran buah dan sayuran menjadi dua kategori utama, yaitu segar dan busuk. Model dikembangkan menggunakan dataset yang terdiri dari 11.441 citra yang gambar, yang dibagi ke dalam tiga subset utama, yaitu data latih ( $\pm 44.38\%$ ), data validasi ( $\pm 11.07\%$ ), dan data uji ( $\pm 44.55\%$ ). Dengan data kelas terbagi 14 kelas. Hasil penelitian dengan menggunakan *confusion matrix* nilai *accuracy* sebesar 95% dan hasil evaluasi *validation accuracy* sebesar 100% pada *epoch* ke-4, dengan *val\_loss* terendah sebesar 0.0260 serta nilai MAE 0.26, yang artinya model memiliki kinerja yang sangat baik dalam mendeteksi kesegaran buah dan sayur. Penelitian lanjutan disarankan untuk meningkatkan generalisasi model dengan menggunakan dataset yang lebih beragam, dan mengintegrasikan komputasi tepi (*edge computing*) untuk inspeksi kualitas langsung di Lokasi.

**Kata kunci:** buah, sayur, klasifikasi, convolutional neural network, inception v3.

## IMPLEMENTATION OF DEEP LEARNING CONVOLUTIONAL NEURAL NETWORK FOR FRUITS AND VEGETABLES FRESHNESS CLASSIFICATION

### Abstract

Fruits and vegetables are primary sources of vitamins, minerals, and fiber, which are essential for maintaining a healthy body. The World Health Organization (WHO) recommends a daily intake of 400 grams for a balanced diet. However, the quality and freshness of fruits and vegetables are often difficult to identify manually, especially at large scale, as traditional methods have limitations in accuracy and are prone to human error. Advances in artificial intelligence, particularly deep learning, offer innovative solutions in image classification. Convolutional Neural Networks (CNNs) have proven effective in image recognition and classification tasks. This study implements a CNN using the Inception V3 architecture to classify the freshness of fruits and vegetables into two main categories: fresh and rotten. The model was developed using a dataset consisting of 11,441 images, divided into three main subsets: training data (approximately 44.38%), validation data (approximately 11.07%), and test data (approximately 44.55%), with 14 distinct classes. The results of the study, based on the confusion matrix, show an accuracy of 95%, and a validation accuracy of 100% at the 4th epoch, with the lowest validation loss recorded at 0.0260 and a MAE of 0.26. These results indicate that the model performs very well in detecting the freshness of fruits and vegetables. Further research is recommended to improve model generalization using more diverse datasets and to integrate edge computing for on-site quality inspection.

**Keywords:** fruits, vegetables, classification, convolutional neural network, inception v3.

### 1. PENDAHULUAN

Buah dan sayur diperlukan tubuh sebagai sumber vitamin, mineral, dan serat yang bermanfaat

bagi kesehatan tubuh. Mengonsumsi sayur dan buah merupakan salah satu syarat dalam memenuhi menu gizi seimbang. *World Health Organization* (WHO) menganjurkan konsumsi buah dan sayur

sebanyak 400 gram/hari, yang terdiri dari 250gram sayur dan 150 gram buah (Rarastiti, 2022). Salah satu hal yang perlu diperhatikan sebelum mengonsumsi buah dan sayur adalah kualitas dan kesegarannya karena sangat berpengaruh pada nilai gizi.

Dalam kehidupan sehari-hari, pengecekan kesegaran buah dan sayur masih sangat bergantung pada kemampuan manusia untuk mengidentifikasi perubahan fisik seperti warna, tekstur, aroma, dan rasa. Tentunya cara ini memiliki beberapa kelebihan seperti membutuhkan waktu yang relatif lebih lama terutama untuk pertanian atau perkebunan besar, dan manusia juga cenderung dapat melakukan kelalaian dalam pengklasifikasian (Setya Nugraha and Hermawan, 2023). Kemampuan manusia rentan terhadap kesalahan dikarenakan persepsi visual dapat bervariasi dari satu individu ke individu lainnya. Di Indonesia sendiri kualitas buah nasional dilihat dari sisi konsistensi ukuran, kematangan petik, warna, rasa dan kesegaran masih jauh dari harapan konsumen karena banyaknya buah yang tak dapat diklasifikasi kesegaran secara keseluruhan (Parajun et al., 2022).

Dengan perkembangan teknologi yang semakin pesat salah satunya kecerdasan buatan (*Artificial Intelligence/ AI*) menawarkan solusi yang lebih efisien dan akurat untuk masalah ini. *Deep learning*, sebagai cabang dari AI, telah menunjukkan kemampuannya yang unggul dalam berbagai aplikasi, terutama dalam pemrosesan citra. Salah satu arsitektur *deep learning* yang paling efektif dalam tugas pengenalan dan klasifikasi gambar adalah *Convolutional Neural Network (CNN)*. CNN sendiri merupakan salah satu algoritma dari *deep learning* yang digunakan dalam *image processing* yang dimanfaatkan untuk membantu manusia dalam mengenali dan/atau mengklasifikasi objek (Ananda et al., 2023). Penerapan *deep learning* khususnya CNN, dalam klasifikasi kesegaran buah dan sayur merupakan langkah penting menuju sistem pangan yang lebih modern, efisien, dan ramah lingkungan.

Beberapa penelitian terdahulu telah memanfaatkan CNN untuk mengklasifikasikan data berupa citra dalam penelitian ekspresi wajah dengan akurasi memperoleh akurasi sebesar 64,8% untuk data pelatihan dan akurasi sebesar 63,3% untuk data validasi (Norhikmah & dkk, 2022). Arsitektur CNN yang digunakan merupakan arsitektur dasar dengan beberapa layer konvolusi, max pooling, dan fully connected layer. Model dilatih dan diuji menggunakan citra buah yang dikumpulkan secara manual. Hasil pengujian menunjukkan bahwa model mampu mencapai akurasi sebesar 93%, yang menunjukkan efektivitas CNN dalam membedakan citra buah berdasarkan tingkat kesegarannya (Parajun et al., 2022).

Mengembangkan aplikasi Android yang mampu mengklasifikasikan tingkat kematangan buah Tin (varietas Green Jordan Fig) menggunakan

algoritma Convolutional Neural Network (CNN). Buah Tin sulit dibedakan antara matang dan belum matang karena warnanya yang mirip (Yusman et al, 2023). Pendekatan gabungan Inception V3 + SVM efektif untuk klasifikasi gambar medis beresolusi tinggi dan bisa diadaptasi untuk tugas-tugas sejenis di domain lain (Reddy et al, 2021). Penggunaan transfer learning dari Inception V3 memungkinkan efisiensi pelatihan tanpa harus membangun model dari awal (yanto et al, 2021).

Penelitian ini melakukan pendekatan terstruktur dan aplikatif dalam pemanfaatan *deep learning* untuk klasifikasi citra buah dan sayuran berdasarkan tingkat kesegarannya. Secara khusus, kontribusi utama dari penelitian ini meliputi: (1) merancang pipeline transfer learning menggunakan arsitektur Inception V3 yang disesuaikan untuk klasifikasi 14 kelas buah dan sayur berdasarkan citra. Dataset yang digunakan terdiri dari citra multi-kelas berjumlah besar yang telah melalui proses pembersihan dan penyesuaian, sehingga menghasilkan 14 kelas yang representatif antara kondisi segar dan busuk. Evaluasi model dilakukan secara menyeluruh menggunakan metrik evaluasi yang mencakup confusion matrix, classification report, dan mean absolute error (MAE) guna memperoleh gambaran kinerja model secara komprehensif. Selain itu, penelitian ini juga menyusun skema pembagian data train, validation, dan test secara proporsional untuk memastikan kualitas pelatihan dan generalisasi model. (2) menyediakan prototipe aplikasi dalam bentuk web-demo yang mampu melakukan proses inferensi secara real-time terhadap gambar yang diunggah atau ditangkap langsung melalui kamera.

## 2. TINJAUAN PUSTAKA

### 2.1. Perbandingan Penelitian

Berikut pada tabel 1 perbandingan penelitian sebelumnya berdasarkan perbedaan arsitektur dan dataset yang digunakan dengan metode pengujian menggunakan confusion matrix didapatkan hasil perbandingan sebagaimana Tabel 1.

Arsitektur Custom CNN yang dikembangkan untuk berjalan di perangkat mobile. Fokus utama penelitian adalah pada klasifikasi kematangan buah tin dengan akurasi mencapai 94%, menunjukkan bahwa CNN kustom dapat efektif jika didesain dengan baik untuk skenario spesifik, seperti implementasi berbasis Android (Safrina et al., 2022). Menerapkan CNN standar (basic CNN) tanpa transfer learning atau arsitektur pretrained. Meskipun demikian, model mampu mencapai akurasi 93%, yang mencerminkan efektivitas pendekatan konvensional dalam lingkungan data terbatas (Mubarak & Maulana, 2023).

Menggunakan MobileNetV2, sebuah arsitektur ringan untuk klasifikasi citra, penelitian ini menghasilkan akurasi 93%. Model ini cocok untuk

deployment di perangkat dengan sumber daya terbatas dan menunjukkan kinerja yang stabil di berbagai jenis dataset (Liandaputra & Zahra, 2024). Menerapkan Inception V3 sebagai bagian dari transfer learning untuk klasifikasi kematangan buah pisang. Dengan akurasi 94%, penelitian ini menegaskan keunggulan pretrained model untuk meningkatkan generalisasi pada klasifikasi berbasis citra (Wulansari & Muslih, 2023).

Tabel 1. Matrix Perbandingan Penelitian

No	Judul	Tahun	Arsitektur	Akurasi
1	Klasifikasi Kematangan Buah Tin Menggunakan Convolutional Neural Network Berbasis Android	2022	Custom CNN Mobile-based	94%
2	Implementasi Algoritma Convolutional Neural Network Dalam Mengklasifikasi Kesegaran Buah Berdasarkan Citra Buah	2023	Basic CNN	93%
3	Klasifikasi Tingkat Kematangan Buah Nanas Menggunakan CNN	2024	MobileNetV2	93%
4	Implementasi Metode Convolutional Neural Network Untuk Deteksi Kematangan Buah Pisang Menggunakan Inception V3	2023	Inception V3	94%
5	<b>Implementation of Deep Learning Convolutional Neural Network for Fruits and Vegetables Freshness Classification</b>	2025	<i>Inception V3</i>	<b>95%</b>


Sedangkan penelitian ini mengimplementasikan arsitektur *Inception V3* pada algoritma *Convolutional Neural Network (CNN)* untuk klasifikasi kesegaran buah dan sayuran ke dalam 14 kelas citra. Model dilatih menggunakan pendekatan *transfer learning* dengan pembekuan bobot pretrained dari *Inception V3*, disertai penambahan *fully connected layer* sebagai classifier. Proses pelatihan dilakukan selama 4 epoch dan menghasilkan kinerja optimal dengan nilai *validation accuracy* mencapai 100%, *validation loss* terendah sebesar 0.0260, serta *MAE* sebesar 0.26.

Evaluasi menggunakan *confusion matrix* menunjukkan akurasi klasifikasi sebesar 95%, yang menandakan bahwa model memiliki tingkat ketepatan yang sangat tinggi dalam mendeteksi kesegaran buah dan sayur dari citra visual. Jika dibandingkan dengan beberapa penelitian sejenis, pendekatan ini menunjukkan hasil paling unggul, baik dari sisi arsitektur, jumlah kelas yang diklasifikasi, maupun akurasi model. Hal ini menunjukkan bahwa pemanfaatan arsitektur *Inception V3* dalam konteks klasifikasi multikategori berbasis citra sangat potensial untuk diterapkan dalam sistem inspeksi kualitas produk pertanian secara otomatis dan presisi tinggi.

### 2.2 Convolutional Neural Network (CNN)

*Convolutional Neural Network (CNN)* adalah pengembangan dari *Multiplayer Perceptron (MLP)* yang didesain untuk mengolah data dua dimensi. CNN termasuk dalam jenis *Deep Neural Network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. Kemampuan CNN diklaim sebagai model terbaik untuk memecahkan masalah *object recognition* karena merupakan pengembangan dari metode *backpropagation* dan tidak memerlukan komputasi yang besar dalam prosesnya (Alam et al., 2019).

Cara kerja CNN mempunyai kemiripan pada MLP. Pada CNN, data yang dipropagasikan pada jaringan adalah data dua dimensi, sehingga operasi linear dan parameter bobot pada CNN berbeda Cahya, 2021). *Convolutional Neural Network (CNN)* merupakan metode yang berfungsi untuk mengenali objek, visual, serta mendeteksi data citra digital. Metode ini melibatkan neuron yang memiliki bobot (*weight*), bias, dan fungsi aktivasi. CNN beroperasi dengan menggunakan lapisan konvolusi, yaitu dengan menggeser kernel (filter) yang memiliki ukuran tertentu pada sebuah gambar (Salamah et al., 2023). Arsitektur CNN terbagi menjadi beberapa layer seperti pada Gambar 1.



Gambar 1. Arsitektur CNN

Tahapan convolutional layer melibatkan proses konvolusi filter (kernel) di setiap posisi gambar untuk menghasilkan feature map 2D. Kernel melakukan dot product antara data input dan nilai filter. *Pooling layer*, yang mengikuti lapisan konvolusi, berfungsi untuk mengecilkan ukuran data dengan filter berukuran dan stride tertentu. Jenis *pooling* yang umum digunakan adalah *Max Pooling* dan *Average Pooling* (Salamah et al., 2023).

Lapisan berikutnya menghubungkan lapisan sebelumnya ke *fully connected layer*, yang hanya dapat menerima data dalam bentuk satu dimensi setelah proses *flatten*. Selain itu, *Dropout layer* digunakan untuk menonaktifkan neuron secara acak selama pelatihan guna mencegah *overfitting*.

### 2.3. Inception V3

*Inception V3* adalah arsitektur *Convolutional Neural Network* (CNN) yang dikembangkan oleh Google untuk tugas klasifikasi gambar. Ini merupakan versi ketiga dari arsitektur yang diperkenalkan pada tahun 2015 oleh Szegedy et al. (Minarno et al., 2023). Komponen utama dari *Inception V3* meliputi konvolusi, *max pooling*, *concat*, *dropouts*, lapisan terhubung penuh (*fully connected layers*), dan *average pooling* (Reddy et al., 2021). Normalisasi batch juga diterapkan secara menyeluruh untuk menormalkan input ke jaringan. Normalisasi batch membantu menstabilkan proses pelatihan dan mengurangi *internal covariate shift*, yaitu perubahan distribusi input jaringan selama pelatihan.

Arsitektur *Inception V3* sangat mendalam dan kompleks, terdiri dari tumpukan *inception module* yang saling terhubung satu sama lain. Setiap *inception module* menggabungkan berbagai jenis lapisan konvolusi dan pooling yang dirancang untuk mengekstraksi berbagai fitur dari gambar input.

### 2.4. Confusion Matrix

*Confusion Matrix* adalah metode yang digunakan untuk menampilkan dan membandingkan nilai aktual dengan nilai prediksi dari sebuah model. Metode ini membantu dalam mengevaluasi nilai aktual dengan nilai beberapa matrik seperti akurasi, *Precision*, *Recall*, *F1-Score*.

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Gambar 2. Confusion Matrix

Gambar 2 menunjukkan representasi dari *Confusion Matrix*. Penjelasan terkait *Confusion Matrix*, antara lain (Liandaputra and Zahra, 2024):

- TP (*True Positive*) adalah jumlah data yang kelas aktualnya adalah positif dan prediksinya juga positif.
- FN (*False Negative*) adalah jumlah data yang kelas aktualnya adalah positif namun prediksinya negatif.

- FP (*False Positive*) adalah jumlah data yang kelas aktualnya adalah negatif tetapi prediksinya sebagai positif.
- TN (*True Negative*) adalah jumlah data yang kelas aktualnya adalah negatif dan prediksinya juga negatif.

Akurasi mengukur seberapa sesuai hasil prediksi dengan nilai sebenarnya, seperti yang dirumuskan pada (1). *F1-Score* digunakan untuk mengevaluasi kemampuan *classifier* dalam mengidentifikasi suatu kelas. Dalam kasus *multiclass*, *F1-Score* dihitung sebagai rata-rata tertimbang (*weighted average*) dari hasil *F1-Score* untuk setiap kelas, dengan bobot berupa jumlah data (*support*) di setiap kelas, seperti terlihat pada (2). *Precision* menunjukkan tingkat ketepatan antara informasi yang diminta dengan hasil yang diberikan oleh model, sebagaimana dirumuskan pada (3). *Recall* mengukur tingkat keberhasilan model dalam mengambil informasi yang relevan, seperti yang dirumuskan pada (4).

$$\text{Akurasi} = \frac{\text{True Positive}}{\text{Total Data}} \quad (1)$$

$$\text{F1 Score} = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2)$$

$$\text{Precision} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}} \quad (3)$$

$$\text{Recall} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}} \quad (4)$$

## 3. Metode Penelitian

Penelitian ini dilakukan melalui berbagai tahapan yang memiliki peran dan fungsi berbeda, disusun secara bertahap dan terstruktur. Pendekatan ini bertujuan untuk mempermudah jalannya penelitian yang sedang berlangsung, sehingga diharapkan dapat meningkatkan efektivitas dan ketepatan proses penelitian. Alur penelitian dapat dilihat pada Gambar 3.

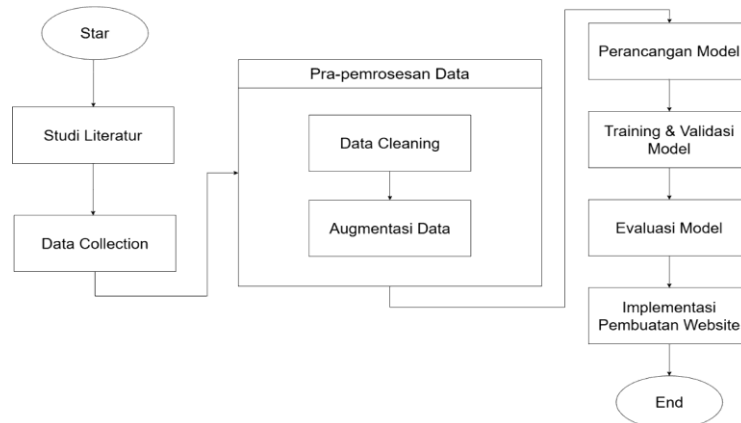
### 3.1. Studi Literatur

Studi literatur merupakan langkah awal penelitian ini, di mana peneliti mengumpulkan dan menganalisis berbagai sumber yang relevan dengan topik "Penerapan *Deep Learning* CNN untuk Klasifikasi Kesegaran Buah dan Sayur". Sumber yang dikaji meliputi buku, jurnal ilmiah, artikel, dan publikasi online yang membahas teknik klasifikasi citra, CNN, serta model *Inception V3* secara mendetail.


### 3.2. Data Collection

Penelitian ini menggunakan data sekunder dari Kaggle dengan dataset "*Multi label Classification: Name + Freshness*", yang berisi gambar buah dan sayuran dalam dua kategori: segar dan busuk. Dataset terdiri 30.357 gambar dalam format RGB,

dengan 6.738 gambar untuk pelatihan dan 23.619 untuk pengujian.



Gambar 3. Alur Penelitian



Gambar 4. Ilustrasi Arsitektur CNN

Untuk menyelaraskan jumlah kelas antara data *train* dan *test*, penelitian ini menghapus empat kelas (*fresh bittergourd*, *fresh capsicum*, *rotten bittergourd*, *rotten capsicum*), sehingga hanya menggunakan 14 kelas dengan total 11.441 gambar. Dataset ini tersedia secara publik di Kaggle dan mendukung penelitian dalam klasifikasi citra untuk membedakan kesegaran buah dan sayuran.

### 3.3. Data Cleaning

Pada tahap ini, data dibersihkan dengan hanya menyertakan citra buah dan sayuran seperti *apple*, *banana*, *cucumber*, *okra*, *orange*, *potato*, dan *tomato*. Citra *bittergourd* dan *capsicum* dihapus dengan menghilangkan 4 kelas pada data *train*. Setelah pembersihan, dataset tersisa terdiri 14 kelas pada data *train* dan *test* untuk proses klasifikasi.

### 3.4. Augmentasi Data

Augmentasi data adalah teknik penting dalam pelatihan model CNN untuk meningkatkan ketahanan terhadap variasi data. Dalam penelitian ini, augmentasi dilakukan menggunakan *Image Data Generator* dari TensorFlow, termasuk teknik *rescale* untuk menormalkan nilai piksel guna meningkatkan stabilitas dan kinerja model. Selain itu semua citra diubah ukurannya menjadi 224x224 piksel untuk memastikan keseragaman dan efisiensi pemrosesan, sesuai dengan standar model *pre-trained* seperti *Inception V3*.

### 3.5. Perancangan Model

Pada tahap ini, model CNN dengan arsitektur *Inception V3* dirancang untuk klasifikasi citra buah dan sayuran menggunakan *transfer learning* dengan model pra-latih dari ImageNet. Lapisan awal dibekukan (*freeze*) agar parameternya tetap, sementara lapisan akhir dilatih ulang dengan dataset buah dan sayuran untuk klasifikasi spesifik. Setelah pembekuan, model ditambahkan *Global Average Pooling 2D*, *Dense Layer* dengan 100 neuron (*ReLU*), dan *Denser Layer* dengan 14 neuron (*softmax*). Lapisan ini membantu model mengekstraksi fitur penting dan mengklasifikasikan citra ke dalam 14 kelas. Terdapat juga beberapa *hyperparameter* dari model. Adapun *hyperparameter* yang dioptimasi beserta nilainya akan ditunjukkan pada tabel 2.

Tabel 2. *Hyperparameter* dan nilainya

<b>Hyperparameter</b>	<b>Nilai yang Digunakan</b>
<i>Learning Rate</i>	0.001
Jumlah <i>Epoch</i>	4
<i>Batch Size</i>	32
<i>Activation Function</i>	<i>ReLU</i> dan <i>softmax</i>
<i>Optimizer</i>	<i>Adam</i>

```

base_model.trainable = False

model = Sequential()
model.add(base_model)
model.add(GlobalAveragePooling2D())
model.add(Dense(100, activation='relu'))
model.add(Dense(14, activation='softmax'))

model.compile(optimizer=Adam(learning_rate=0.01), loss='categorical_crossentropy', metrics=['accuracy'])
model.summary()

```

Model: "sequential"

Layer (type)	Output Shape	Param #
inception_v3 (Functional)	(None, 5, 5, 2048)	21,802,784
global_average_pooling2d (GlobalAveragePooling2D)	(None, 2048)	0
dense (Dense)	(None, 100)	204,900
dense_1 (Dense)	(None, 14)	1,414

Total params: 22,009,098 (83.96 MB)  
Trainable params: 206,314 (805.91 KB)  
Non-trainable params: 21,802,784 (83.17 MB)

Gambar 5. Model Inception V3

Gambar 5 memperlihatkan model klasifikasi dalam penelitian ini dibangun menggunakan pendekatan transfer learning dengan arsitektur Inception V3 sebagai feature extractor. Seluruh lapisan Inception V3 dibekukan (non-trainable) untuk mempertahankan bobot pralatih dari ImageNet dan menghindari overfitting. Di atasnya, ditambahkan lapisan Global Average Pooling 2D untuk meratakan fitur spasial, diikuti oleh Dense layer berjumlah 100 neuron dengan aktivasi ReLU, dan Dense output layer dengan 14 neuron serta aktivasi softmax untuk klasifikasi multi-kelas.

Model dikompilasi menggunakan optimizer Adam dengan learning rate 0.01, fungsi loss categorical crossentropy, dan metrik accuracy. Berdasarkan hasil model.summary(), model memiliki total 22.009.098 parameter, dengan 206.314 parameter yang dilatih ulang pada lapisan atas. Arsitektur ini dirancang untuk memanfaatkan kekuatan representasi fitur dari model pralatih sambil tetap memungkinkan adaptasi terhadap karakteristik citra buah dan sayur dalam 14 kelas yang digunakan.

### 3.6. Training & Validasi Model

Pada tahap pelatihan dan validasi, model dilatih menggunakan dataset yang telah disiapkan, dengan data latih digunakan secara bertahap dalam beberapa *epoch* dan data validasi untuk mengevaluasi performa serta mencegah *overfitting*. Dua *callback* digunakan untuk mengoptimalkan pelatihan: *ReduceLROnPlateau*, yang menyesuaikan learning rate jika tidak ada peningkatan kinerja, dan *EarlyStopping*, yang menghentikan pelatihan lebih awal jika model tidak mengalami perbaikan setelah beberapa *epoch*.

### 3.7. Evaluasi

Pada tahap evaluasi, kinerja model dinilai menggunakan *Confusion Matrix* dan *Classification Report*. *Confusion Matrix* menunjukkan jumlah prediksi benar dan salah untuk setiap kelas, sementara *Classification Report* merangkum matrik evaluasi seperti *Precision*, *Recall*, dan *F1-Score*.

- *Precision* mengukur akurasi prediksi positif.
- *Recall* menilai kemampuan model dalam mengidentifikasi data positif.
- *F1-Score* adalah rata-rata harmonis *Precision* dan *Recall*, berguna saat data tidak seimbang.

Selain itu, digunakan *Mean Absolute Error* (MAE) untuk menghitung rata-rata kesalahan absolut antara prediksi dan nilai aktual, mengukur seberapa dekat prediksi dengan nilai sebenarnya tanpa memperhatikan arah kesalahan.


## 4. Hasil dan Pembahasan

Pada penelitian ini dilakukan proses klasifikasi dengan menggunakan dataset "Multi Label Classification: Name + Freshness" diunduh dari Kaggle dan berisi 30.357 gambar buah dan sayuran dalam format JPEG. Dataset ini awalnya memiliki 18 kelas pada data train dan 14 kelas pada data test, tetapi untuk menyederhanakan analisis, 4 kelas dihapus (*fresh bittergourd*, *fresh capsicum*, *rotten bittergourd*, *rotten capsicum*), sehingga total dataset menjadi 11.441 gambar dengan 14 kelas. Setelah pembersihan, dataset akhir terdiri dari 6.348 gambar untuk *train* dan 5.093 untuk *test*, memastikan kualitas dan konsistensi data sebelum pelatihan model CNN *Inception V3*.

### 4.1. Augmentasi Data

Augmentasi data meningkatkan variasi dataset dengan teknik pemrosesan gambar. Dalam penelitian ini, digunakan TensorFlow melalui *Image Data Generator* dengan teknik *rescale*. Augmentasi ini membantu model lebih robust terhadap variasi data dan meningkatkan akurasi klasifikasi.

1. Image data Generator  
Fitur dari keras yang memungkinkan augmentasi gambar secara *real-time* selama pelatihan, termasuk preprocessing seperti transformasi dan normalisasi.



Gambar 6. Proses Pelatihan Model


2. Rescale = 1/255  
Menyesuaikan nilai piksel gambar dari rentang 0-255 menjadi 0-1 untuk meningkatkan stabilitas dan kinerja model.

#### 4.2. Hasil Training & Validasi Model

Hasil evaluasi performa model selama proses pelatihan dan validasi. Seperti ditunjukkan pada gambar 6, model menunjukkan peningkatan performa secara signifikan dari epoch pertama hingga keempat, ditandai dengan:

- a) Kenaikan akurasi pelatihan dari 47.83% menjadi 87.50%
- b) Kenaikan akurasi validasi dari 79.09% menjadi 100.00%
- c) Penurunan loss validasi secara konsisten dari 0.6174 ke 0.0260


Akurasi validasi yang mencapai angka sempurna (1.0000) serta penurunan nilai *val\_loss* hingga ke titik minimum menunjukkan bahwa model telah mencapai titik konvergensi optimal pada epoch ke-4. Pelatihan lebih lanjut setelah titik ini berisiko menyebabkan *overfitting*, di mana model terlalu menyesuaikan diri terhadap data pelatihan dan kehilangan kemampuan generalisasi terhadap data baru. Selain itu, penetapan jumlah epoch yang relatif kecil mendukung efisiensi proses pelatihan tanpa mengorbankan performa dengan beban komputasi yang tetap efisien.



Gambar 7. Grafik Loss Logs

Gambar 7 merupakan grafik *loss logs* yang menggambarkan perkembangan *training loss* (biru) dan *validation loss* (oranye) selama 4 *epoch*. Dari grafik dapat dilihat bahwa *training loss* terus


menurun menunjukkan bahwa model semakin baik dalam mempelajari pola pada data pelatihan. *Validation loss* stabil setelah *epoch* pertama, menunjukkan bahwa model memiliki kemampuan generalisasi yang cukup baik pada data validasi. Tidak ada tanda *overfitting* yang signifikan, karena perbedaan antara *training loss* dan *validation loss* tetap kecil di semua *epoch*.



Gambar 8. Grafik Accuracy Logs

Gambar 8 merupakan grafik *accuracy logs* yang memvisualisasikan metrik evaluasi akurasi model selama proses pelatihan (*training*) dan validasi. Dari grafik dapat dilihat bahwa model menunjukkan *accuracy* terus meningkat pada setiap *epoch*, menunjukkan bahwa model belajar dengan baik dari data pelatihan. *Validation accuracy* stabil pada tingkat tinggi menandakan model memiliki kemampuan generalisasi yang baik. Tidak ada tanda *overfitting* yang signifikan, karena gap antara *accuracy* dan *validation accuracy* tetap kecil.

#### 4.3. Hasil Evaluasi Model



Gambar 9. Hasil Confusion Matrix

Pada bagian ini, akan dipaparkan hasil evaluasi performa hasil *Convolutional Neural Network* dengan arsitektur *Inception V3* dalam melakukan klasifikasi citra buah dan sayuran.

*Confusion matrix* pada gambar 9 menunjukkan performa model dalam mengenali 14 kelas buah dan sayuran yang terbagi dalam kategori segar (*fresh*) dan busuk (*rotten*). Nilai pada diagonal utama (kiri atas ke kanan bawah) mewakili jumlah prediksi yang benar (*True Positive*) untuk masing-masing kelas, sementara nilai di luar diagonal menunjukkan kesalahan prediksi (*False Positive* atau *False Negative*).

Dari hasil *Confusion Matrix* dapat dilihat akurasi tinggi pada sebagian besar kelas, dengan prediksi benar lebih dominan. Kesalahan kecil terjadi pada kategori mirip (misalnya, *freshapples* diprediksi sebagai *freshoranges*) dan *rotten categories* terkadang dikira *fresh*, namun jumlah sedikit.

Hal ini menunjukkan kinerja model sangat baik, dengan kesalahan prediksi yang minim dan mayoritas kelas memiliki prediksi yang akurat *False Negative* cenderung terjadi pada kelas seperti '*rottentomato*' karena kemiripan visual dengan kelas lain (misalnya warna, bentuk, atau kondisi pencahayaan). Hal ini menunjukkan bahwa model menghadapi kesulitan membedakan fitur visual halus antar kelas mirip, yang bisa disebabkan oleh ketidakseimbangan jumlah data atau variasi *intrakelas* yang tinggi.

	precision	recall	f1-score	support
freshapples	0.89	1.00	0.94	477
freshbanana	1.00	1.00	1.00	497
freshcucumber	0.99	0.96	0.97	279
freshokra	0.98	0.98	0.98	370
freshoranges	0.92	0.93	0.93	388
freshpatato	0.90	0.97	0.94	270
freshtamto	0.97	0.95	0.96	255
rottenapples	0.99	0.89	0.94	479
rottenbanana	1.00	0.98	0.99	473
rottencucumber	0.86	0.98	0.92	255
rottenokra	0.88	0.99	0.93	224
rottenoranges	0.93	0.92	0.93	403
rottenpatato	0.93	0.89	0.91	370
rottentamto	0.99	0.84	0.91	353
accuracy			0.95	5093
macro avg	0.95	0.95	0.95	5093
weighted avg	0.95	0.95	0.95	5093

Gambar 10. Hasil Classification Report

Gambar 10 Menunjukkan hasil *classification report* dalam mengidentifikasi 14 kelas buah dan sayuran berdasarkan matrik berikut:

- Precision*: tinggi, menunjukkan model jarang salah memprediksi kelas positif.
- Recall*: umumnya tinggi, kecuali pada beberapa kelas seperti *rottentomato* (0.84).

- F1-Score*: seimbang antara *precision* dan *recall*.
- Support*: jumlah sampel per kelas.

Model memiliki akurasi keseluruhan 95% dengan performa terbaik pada *freshbanana* & *rottenbanana* (*precision* sempurna, *recall* hampir sempurna). Namun, masih ada ruang perbaikan untuk kelas tertentu seperti *rottentomato*.

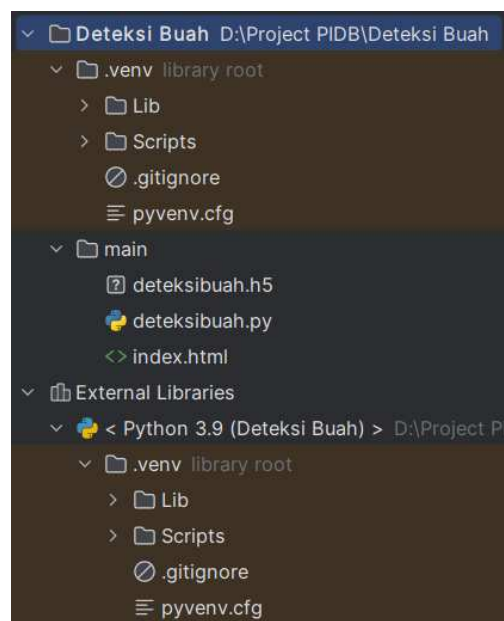
```
Found 5093 images belonging to 14 classes.
160/160 [=====] - 39s 232ms/step
Mean Absolute Error (MAE): 0.26958570587080305
```

Gambar 11. Hasil Mean Absolute Error (MAE)

Gambar 11 adalah hasil *Mean Absolute Error* (MAE) mengukur rata-rata selisih absolute antara prediksi model dan nilainya sebenarnya. MAE = 0.269 menunjukkan kesalahan klasifikasi rata-rata yang rendah dalam 14 kelas buah dan sayuran. MAE rendah (0.269) mengindikasikan model cukup akurat. Kelas dengan performa rendah (*rottentomato*, *recall* 0.84) berkontribusi pada kenaikan MAE. Kelas dengan performa tinggi (*freshbanana*, *precision* & *recall* sempurna) membantu menjaga MAE tetap rendah. Hasil ini sejalan dengan akurasi 95%, menunjukkan model bekerja dengan baik dalam klasifikasi buah dan sayuran.

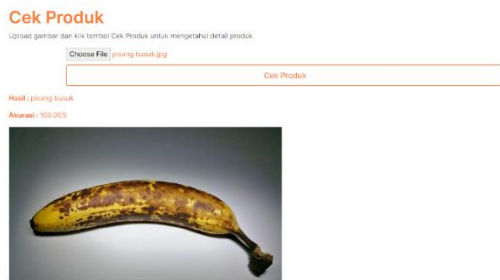
#### 4.1. Implementasi Pembuatan Web

Pengembangan aplikasi deteksi buah dan sayuran dilakukan menggunakan PyCharm dengan Python sebagai bahasa utama. Teknologi web seperti HTML, CSS, dan JavaScript digunakan untuk tampilan antarmuka. Pip install flask flask-cors tensorflow numpy pillow, merupakan instalasi pustaka yang diperlukan.



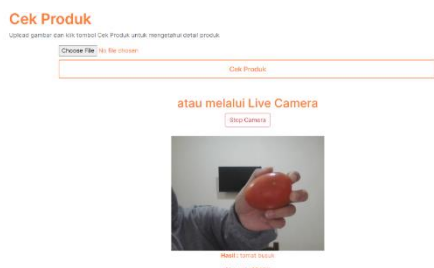
Gambar 12. Struktur Proyek

Struktur proyek pada gambar 12 menunjukkan bagian *backend* (deteksibuah.py) adalah API Flask yang berguna untuk memproses gambar dan memprediksi label menggunakan model TensorFlow (deteksibuah.h5) dan *frontend* (index.html) yaitu antarmuka pengguna untuk mengunggah gambar dan menampilkan hasil prediksi. Pengembangan *frontend* dilakukan di Visual Studio Code, menggunakan *Model-View-Template* (MVT) untuk pemisahan logika aplikasi.



Gambar 13. Deteksi dengan Upload Gambar

Gambar 13 menunjukkan bahwa pembeli dapat mendeteksi buah dan sayuran dengan mengunggah gambar, lalu menekan tombol “Cek Produk”. Hasil deteksi dan tingkat akurasi akan ditampilkan setelah proses selesai.



Gambar 14. Deteksi dengan Live Camera

Gambar 14. menunjukkan bahwa pembeli dapat mendeteksi buah dan sayuran langsung dengan kamera. Dengan menekan tombol “Start Camera”, kamera akan aktif, dan sistem otomatis menampilkan hasil deteksi serta akurasi. Setelah selesai, pembeli dapat menekan “Stop Camera” untuk menghentikan proses.

## 5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan dan mengevaluasi model Convolutional Neural Network (CNN) untuk mengklasifikasikan gambar buah dalam 14 kelas berdasarkan kondisi segar dan busuk. Dataset yang digunakan terdiri dari total 11.441 gambar, yang dibagi ke dalam tiga subset utama, yaitu data latih ( $\pm 44.38\%$ ), data validasi ( $\pm 11.07\%$ ), dan data uji ( $\pm 44.55\%$ ). Pembagian dilakukan dengan mempertahankan distribusi kelas secara merata (stratifikasi) guna memastikan keadilan dalam proses pelatihan dan pengujian.

Model dilatih selama 4 epoch dengan teknik augmentasi data untuk meningkatkan keragaman input. Hasil evaluasi menunjukkan bahwa model mencapai akurasi validasi sebesar 100% pada epoch ke-4, dengan *val\_loss* terendah sebesar 0.0260. Hasil *classification report* pada data uji juga menunjukkan performa yang tinggi dengan akurasi keseluruhan sebesar 91%, serta nilai rata-rata *precision*, *recall*, dan *F1-score* masing-masing sebesar 0.92, 0.91, dan 0.91.

Untuk pengembangan lebih lanjut, disarankan untuk memperluas jumlah kelas dan jenis buah serta sayuran dalam dataset guna meningkatkan generalisasi model. Selain itu, teknik augmentasi data, *fine-tuning* arsitektur, serta optimasi parameter pelatihan dapat diterapkan untuk meningkatkan akurasi. Pengembangan ini diharapkan dapat meningkatkan kualitas penelitian serta berkontribusi lebih luas dalam penerapan *machine learning* untuk klasifikasi kesegaran buah dan sayuran.

## DAFTAR PUSTAKA

- CAHYA, F.N., 2021. Perbandingan identifikasi Wajah Dengan Ekstraksi FITUR haralick dan CNN: Informatics and Digital Expert (INDEX), 2(2). doi:10.36423/index.v2i02.594.
- LIANDAPUTRA, D., ZAHRA, A., 2024. Klasifikasi Tingkat Kematangan Buah Nanas menggunakan metode deep learning, G-Tech: Jurnal Teknologi Terapan, 8(2), pp. 1091–1103. doi:10.33379/gtech.v8i2.4122.
- MINARNO, A.E., ARIPA, L., AZHAR, Y., MUNARKO, Y., 2023. Classification of Malaria Cell Image using inception-V3 architecture: JOIV: International Journal on Informatics Visualization, 7(2), p. 273. doi:10.30630/joiv.7.2.1301.
- MUBAROK, S., & MAULANA, R. 2023. Implementasi algoritma convolutional neural network dalam mengklasifikasi kesegaran buah berdasarkan citra buah. Jurnal Teknik Informatika CIT Medicom, 15(2), 71–78. https://doi.org/10.31294/citmed.v15i2.19989
- NORHIKMAH, LUTFI AFDHAL, RUMINI The Effect of Layer Batch Normalization and Dropout of CNN model Performance on Facial Expression Classification, JOIV (Internasional Journal On Informatic Visualization), 6/2-2. pp.481-488. <http://dx.doi.org/10.30630/joiv.6.2-2.921>
- PARAIJUN, F., AZIZA, R.N., KUSWARDANI, D., 2022. Implementasi algoritma convolutional neural network Dalam

- Mengklasifikasi kesegaran Buah Berdasarkan citra buah: KILAT, 11(1), pp. 1-9. doi:10.33322/kilat.v10i2.1458.
- PUTRI ANANDA, T., WIDYASARI, S.V., MUTTAQIN, M.I., STEFANIE, A., 2023. Identifikasi Tingkat Kematangan Buah Pepaya menggunakan metode convolutional neural network (CNN): *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(3), pp. 2094-2097. doi:10.36040/jati.v7i3.7137.
- RARASTITI, C.N., 2022. Hubungan Pengetahuan gizi Seimbang Dengan Konsumsi Buah dan sayur pada remaja: *Jurnal Penelitian Inovatif*, 2(2), pp. 281-288. doi:10.54082/jupin.80.
- REDDY, M. A., KRISHNA, G. S. S. R., & KUMAR, T. T. 2021. Malaria cell-image classification using InceptionV3 and SVM. *International Journal of Engineering Research & Technology (IJERT)*, 10(8), 6–10. <https://www.ijert.org/research/malaria-cell-image-classification-using-inceptionv3-and-svm-IJERTV10IS080009.pdf>
- SALAMAH, I., HUMAIROH, S., SOIM, S., 2023. Implementasi Convolutional Neural Network Pada Alat klasifikasi Kematangan dan Ukuran buah nanas berbasis android: *INOVTEK Polbeng - Seri Informatika*, 8(2), p. 243. doi:10.35314/isi.v8i2.3413.
- SAFRINA, D., YULIANI, R., & RAHAYU, D. P. (2022). Klasifikasi kematangan buah tin menggunakan convolutional neural network. *Jurnal Teknologi dan Sistem Informasi*, 3(2), 99–106. <https://doi.org/10.33387/jtsi.v3i2.6056>
- SETYA NUGRAHA, R., HERMAWAN, A., 2023. OPTIMASI Akurasi metode convolutional neural network Untuk Klasifikasi Buah Apel Hijau: *Jurnal Mnemonic*, 6(2), pp. 149-156. doi:10.36040/mnemonic.v6i2.6730.
- WULANSARI, N.W., MUSLIH, M., 2023. Implementasi metode convolutional neural network untuk Deteksi Kematangan Buah pisang menggunakan inception V3, *JOINS (Journal of Information System)*, 8(2), pp. 147–155. doi:10.33633/joins.v8i2.9074.
- YANTO, B., FIMAWAHIB, L., SUPRIYANTO, A., HAYADI, B.H., PRATAMA, R.R., 2021. Klasifikasi Tekstur Kematangan buah jeruk Manis Berdasarkan tingkat kecerahan warna dengan metode deep learning convolutional neural network, *INOVTEK Polbeng - Seri Informatika*, 6(2), p. 259. doi:10.35314/isi.v6i2.2104.
- YUSMAN, M.A., EVANITA, E., RIADI, A.A., 2023. Klasifikasi kematangan buah tin menggunakan convolutional neural network Berbasis Android, *Jurnal Teknik Informatika dan Sistem Informasi*, 9(2). doi:10.28932/jutisi.v9i2.5701.