



IMPLEMENTASI MODEL KLASIFIKASI KEMATANGAN PISANG MENGUNAKAN ARSITEKTUR CNN INCEPTION V3 DAN VGG16

Sephia Mulyawati¹, Dr. Miftah Andriansyah, ST., MMSI²

Program Studi Informatika, Fakultas Teknologi Industri, Universitas Gunadarma,
Depok, Indonesia

Email penulis pertama: mulyawati.sephia@gmail.com

Abstract

Banana ripeness level is a crucial factor in determining the quality and freshness of agricultural products. This research aims to develop a Convolutional Neural Network (CNN) model to classify the ripeness levels of bananas—from unripe to overripe—with the goal of assisting farmers in the sorting process more consistently and efficiently. Two CNN architectures, InceptionV3 and VGG16, were utilized to evaluate their respective performances. This research employed the CRISP-DM methodology, which consists of business understanding, data understanding, data preparation, modeling, and evaluation. The dataset used was obtained from Dataverse Telkom University and consists of four classes: unripe, semi-ripe, ripe, and overripe. The results showed that the VGG16 model achieved the highest accuracy of 92%, while InceptionV3 achieved an accuracy of 87%. However, both models struggled with classifying the "Ripe" and "Overripe" categories, which could be attributed to data imbalance, lighting variations, and color variations in the "Semi-ripe" class. Therefore, the test results indicate that VGG16 performed better compared to InceptionV3, but improvements in dataset quality are necessary to enhance the overall model performance.

Keywords: *Convolutional Neural Network (CNN), banana ripeness classification, InceptionV3, VGG16*

Abstrak

Tingkat kematangan pisang merupakan faktor penting dalam menentukan kualitas dan kesegaran produk pertanian. Penelitian ini bertujuan mengembangkan model Convolutional Neural Network (CNN) untuk mengklasifikasikan tingkat kematangan pisang—dari mentah hingga terlalu matang—dengan harapan dapat membantu petani dalam proses penyortiran secara lebih konsisten dan efisien. Dua arsitektur CNN, yaitu InceptionV3 dan VGG16, digunakan untuk mengevaluasi performa masing-masing. Penelitian ini menggunakan metode CRISP-DM yang terdiri dari

business understanding, data understanding, data preparation, modeling, dan evaluation. Dataset yang digunakan diperoleh dari Dataverse Telkom University dan terdiri dari empat kelas: mentah, setengah matang, matang, dan terlalu matang. Hasil penelitian menunjukkan bahwa model VGG16 mencapai akurasi tertinggi sebesar 92%, sementara InceptionV3 mencapai akurasi 87%. Namun, kedua model mengalami kesulitan dalam mengklasifikasikan kategori "Matang" dan "Terlalu matang," yang dapat disebabkan oleh ketidakseimbangan data, variasi pencahayaan, dan variasi warna pada kelas "setengah-matang." Maka, dari hasil pengujian VGG16 menunjukkan performa lebih baik dibandingkan dengan InceptionV3, akan tetapi peningkatan kualitas dataset diperlukan untuk meningkatkan kinerja model secara keseluruhan.

Kata Kunci: *Convolutional Neural Network (CNN), Klasifikasi kematangan pisang, VGG16, InceptionV3*

1. PENDAHULUAN

Pertanian memegang peranan penting sebagai penopang utama ekonomi dunia dan juga memenuhi salah satu kebutuhan dasar manusia yaitu makanan (Meshram et al., 2021). Di negara agraris seperti Indonesia, sektor pertanian tentunya memiliki peran esensial dalam berbagai aspek. Tak hanya menunjang kehidupan dan penghidupan masyarakat, sektor ini juga menjadi penjaga kelestarian alam dan motor penggerak pembangunan ekonomi nasional (Badan Pusat Statistik, 2021). Menurut Consultative Group on International Agricultural Research (CGIAR) tanaman umbi-umbian dan pisang merupakan beberapa tanaman pangan pokok terpenting di daerah termiskin di dunia. Mereka menyumbang sekitar 15% atau lebih dari asupan kalori harian per orang untuk 763 juta orang yang tinggal di negara-negara berkembang paling miskin. Pisang merupakan salah satu produk pertanian yang memiliki produksi tertinggi dibandingkan dengan buah lainnya. Selain itu, tanaman pisang juga termasuk dalam sepuluh tanaman produksi dengan luasan area hasil produksi dan nilai kalori global yang terbesar (Dwivany, 2021) Pada statistik hortikultura menurut Badan Pusat Statistik, tahun 2022 menandakan peningkatan 5,77% dalam panen pisang, mencapai 9,24 juta ton. Konsumsi pisang di sektor rumah tangga juga

mengalami kenaikan 1,35% menjadi 2,42 juta ton, dengan kontribusi hampir setengah (49,35%) dari total konsumsi pisang (Amelia Dertta Irjayanti et al., 2022).

Pada sebuah penelitian menunjukkan bahwa petani merupakan aktor vital dalam rantai pasok pisang, bertindak sebagai pemasok bahan baku utama yang diolah oleh industri, selain itu kualitas pisang segar dipengaruhi secara signifikan oleh perencanaan panen dan sortasi yang dilakukan oleh petani (Andanu et al., 2021). Oleh karena itu, pemilahan pascapanen pisang sangatlah penting dalam produksi buah pisang. Saat ini, proses pemilahan masih banyak dilakukan secara manual, sedangkan pemilahan pisang manual memakan waktu, tenaga, dan ketidak konsistenan karena penilaian kematangan petani bervariasi. Maka, teknologi dapat menjadi solusi (Shorif et al., 2021).

Indonesia memiliki potensi besar dalam memanfaatkan teknologi kecerdasan buatan (AI) untuk meningkatkan berbagai sektor, salah satunya sektor pertanian. AI dapat meningkatkan produktivitas bisnis, memanfaatkan sumber daya manusia dengan lebih efisien, dan mendorong inovasi (Wisjnu et al., 2020). Saat ini, dua istilah dalam bidang informatika yang sangat populer yaitu, Machine Learning dan Deep Learning. Pemanfaatan Machine Learning dan Deep Learning di sektor pertanian semakin populer karena potensinya yang besar. Namun, penerapannya di Indonesia masih terbilang minim. Oleh karena itu, perlu dilakukan penelitian, pengkajian, dan penerapan Machine Learning dan Deep Learning untuk mendukung kemajuan pertanian di Indonesia (Hilman Ferdinandus Pardede, 2023). Dalam beberapa tahun terakhir, paradigma komputasi Deep Learning dianggap sebagai standar emas dalam komunitas Machine Learning. Selain itu, Deep Learning secara bertahap menjadi pendekatan komputasi yang paling banyak digunakan di bidang Machine Learning. Hal ini terbukti dengan pencapaian hasil luar biasa pada berbagai tugas kognitif kompleks, bahkan menyamai atau bahkan melampaui kinerja manusia. Salah satu keuntungan dari Deep Learning adalah kemampuannya untuk mempelajari data dalam jumlah besar. Bidang Deep Learning berkembang pesat dalam beberapa tahun

terakhir dan telah digunakan secara luas untuk menangani berbagai aplikasi tradisional secara sukses (Alzubaidi et al., 2021).

Para peneliti telah melakukan penelitian tentang berbagai teknologi canggih terkait computer vision yang membantu pemilihan dan penyortiran buah pisang, serta identifikasi kematangan buah pisang berdasarkan pemrosesan citra (Shuprajhaa et al., 2023). Pada sebuah kasus buah dan sayur busuk dalam penyimpanan dapat merusak buah dan sayur segar lainnya. Kerusakan persediaan ini menyebabkan kerugian yang cukup besar dalam bisnis buah dan sayur. Deteksi dini buah dan sayur busuk dapat mengurangi kerusakan pada persediaan atau di toko, serta meningkatkan keamanan pangan. Namun, deteksi otomatis menjadi tantangan tersendiri bagi peneliti karena komputer harus mengenali buah dan sayur busuk hanya berdasarkan perubahan ciri-ciri permukaannya. Para peneliti membahas solusi untuk permasalahan deteksi dini buah dan sayur menggunakan teknik Deep Learning dengan mengusulkan arsitektur Convolutional Neural Network (CNN) untuk mengklasifikasikan buah dan sayur busuk atau segar berdasarkan gambar yang diambil (Shorif et al., 2021).

Convolutional Neural Network (CNN) merupakan teknik yang banyak diminati untuk menangani data berdimensi tinggi, seperti gambar dan data deret waktu. Berbeda dengan metode ekstraksi fitur manual, CNN secara otomatis mempelajari fitur-fitur tersebut selama proses pelatihan (Khan & Yairi, 2018). Sebuah penelitian juga dilakukan dalam melatih suatu algoritma klasifikasi Convolutional Neural Network (CNN) menggunakan fitur kontur dan histogram yang diekstraksi dari gambar buah jeruk bali RGB dan HSV yang diambil di lapangan. Tujuannya adalah untuk mengklasifikasikan setiap buah menjadi matang atau belum matang (Kangune et al., 2019). Penelitian terbaru juga mengusulkan sebuah model Deep Learning untuk klasifikasi dan penilaian kematangan pada 32 jenis buah dan sayur. Sistem ini terdiri dari dua Convolutional Neural Network (CNN) yang dilatih secara terpisah, satu untuk klasifikasi jenis dan satu untuk penilaian kematangan. Hasil menunjukkan bahwa sistem ini mencapai akurasi tinggi, yaitu 97.86% untuk klasifikasi jenis dan

100% untuk penilaian kematangan. Keunggulan utama model ini adalah kemampuannya untuk mengidentifikasi jenis dan kematangan buah dan sayur secara simultan, yang belum dicapai oleh penelitian lain. Model ini memanfaatkan teknik transfer learning untuk meningkatkan performa dan efisiensi pelatihan. Penggunaan dua CNN terpisah memungkinkan model untuk fokus pada tugas spesifiknya, menghasilkan performa yang lebih baik dibandingkan dengan yang menggunakan satu model (Tapia-Mendez et al., 2023).

Pada penelitian lain model CNN yang diimplementasikan berhasil mengklasifikasikan empat tingkat kematangan pisang dengan akurasi yang lebih baik menggunakan data augmented. Waktu yang dibutuhkan untuk melatih model juga tergolong singkat. Menurut penelitian tersebut berpotensi dikembangkan untuk mengklasifikasikan berbagai jenis pisang dan tingkat kematangannya, serta mendeteksi kerusakan pada buah (Saranya et al., 2022).

Berdasarkan uraian di atas, sektor pertanian penting untuk kehidupan, penghidupan, kelestarian alam, dan pembangunan ekonomi nasional. Pisang merupakan produk pertanian Indonesia yang menunjukkan potensi besar karena nilai produksi dan konsumsinya tinggi. Maka, untuk meningkatkan produktivitas, efisiensi, dan konsistensi pada sektor pertanian pisang dibutuhkan sebuah teknologi untuk menjaga hal tersebut. Teknologi yang dapat digunakan salah satunya adalah Deep Learning, karena menurut para peneliti Deep Learning mampu mempelajari data dalam jumlah besar dan telah digunakan untuk berbagai aplikasi dan mampu mengklasifikasikan dan menilai kematangan buah, termasuk pisang. Model Deep Learning dengan menggunakan Convolutional Neural Network pada penelitian sebelumnya juga telah menunjukkan keberhasilannya dalam mengklasifikasikan buah dan sayur, termasuk pisang. Oleh karena itu, model ini diharapkan dapat membantu meningkatkan efisiensi dan efektivitas pemilahan pisang, serta meningkatkan kualitas produk pisang yang dipasarkan.

2. METODE

Metode penelitian yang digunakan pada penelitian ini adalah CRISP-DM yang terdiri dari enam fase iteratif yaitu, *business understanding*, *data understanding*, *data preparation*, *modelling*, *evaluation* dan *deployment*.

2.1 Business Understanding

Masalah busuknya pisang selama distribusi menimbulkan kerugian finansial yang signifikan bagi seluruh rantai pasok, mulai dari petani hingga konsumen akhir. Pengembangan aplikasi pendeteksi kondisi pisang berbasis *deep learning* yaitu, *Convolutional Neural Network (CNN)* menawarkan solusi inovatif untuk mengatasi permasalahan ini. Dengan memberikan informasi yang akurat dan real-time tentang kualitas pisang, aplikasi ini berpotensi mengurangi tingkat pemborosan, meningkatkan efisiensi operasional, dan pada akhirnya meningkatkan profitabilitas bisnis dalam industri pisang.

2.2 Data Understanding

Tahap pemahaman data melibatkan analisis mendalam terhadap dataset pisang dari Dataverse Telkom. Proses ini mencakup evaluasi kualitas data, distribusi kelas, dan relevansi fitur untuk memastikan kesesuaian data dengan model yang akan dikembangkan.

2.3 Data Preparation

Pada tahap persiapan data untuk proyek klasifikasi kematangan pisang menggunakan *Convolutional Neural Network (CNN)*, beberapa langkah penting dilakukan untuk memastikan dataset siap digunakan dalam pelatihan model. Dataset dari Dataverse sudah dilabeli oleh penyedia data, dengan kategori matang, terlalu matang, setengah matang, dan mentah, sehingga tidak memerlukan pelabelan manual tambahan. Langkah-langkah persiapan data meliputi pengumpulan, *preprocessing*, augmentasi, pembagian dataset, dan normalisasi. Setiap langkah dirancang untuk memastikan kualitas data yang tinggi dan mendukung proses pelatihan model yang efisien.

2.4 Modeling

Tahap pemodelan adalah inti dari penelitian ini, di mana arsitektur *Convolutional Neural Network* (CNN) dipilih karena efektif untuk klasifikasi gambar. Penelitian ini membandingkan performa dua model pra-latih, VGG16 dan Inception V3, yang dikenal unggul dalam ekstraksi fitur dan klasifikasi. VGG16 menggunakan lapisan konvolusi sederhana dan dalam, sementara Inception V3 menggunakan blok Inception untuk menangkap fitur pada berbagai skala. Parameter seperti learning rate, batch size, dan jumlah epoch disesuaikan untuk mengoptimalkan kinerja model. Data pelatihan yang sudah dipersiapkan dengan augmentasi digunakan untuk melatih model, dan data validasi digunakan untuk mencegah *overfitting*. Hasil akhirnya adalah model yang terlatih dengan baik dan mampu mengklasifikasikan kematangan pisang dengan akurasi tinggi, termasuk kategori segar, matang, terlalu matang, dan setengah matang.

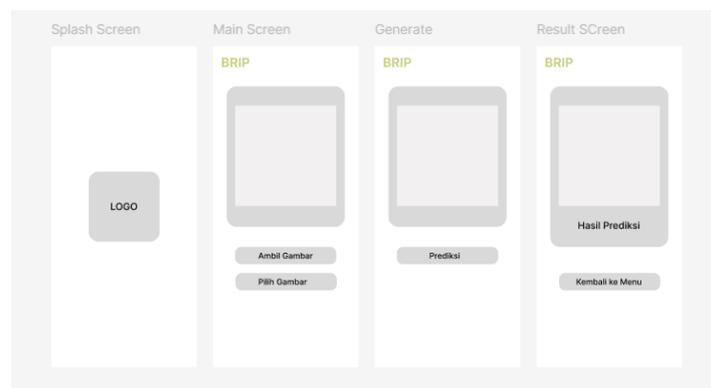
2.5 Evaluation

Evaluasi model dilakukan untuk mengukur kemampuan model dalam memprediksi data uji yang belum pernah dilihat sebelumnya, dengan tujuan memahami kinerjanya melalui visualisasi hasil dan berbagai metrik. Selain visualisasi, metrik seperti akurasi, kerugian (*loss*), *classification report*, dan *confusion matrix* digunakan. Akurasi memberikan gambaran umum tentang persentase prediksi yang benar, sementara kerugian menunjukkan seberapa jauh prediksi dari nilai sebenarnya. *Classification report* menilai kinerja model dengan metrik *precision*, *recall*, dan *F1-score*, sedangkan *confusion matrix* menunjukkan detail prediksi yang benar dan salah untuk setiap kelas. Metrik-metrik ini membantu membandingkan dan memilih model terbaik secara objektif berdasarkan hasil evaluasi yang menyeluruh.

2.6 Deployment

Proses *deployment* ini menggunakan metode SDLC Model Waterfall dengan proses requirements, system dan software desain, implementasi dan pengujian. Proses requirements ini dilakukan pengumpulan kebutuhan pengguna dengan menyebar

kuisisioner mengenai kebutuhan pengguna. Proses *deployment* model mencakup integrasi model yang telah dilatih ke dalam aplikasi Android dengan mengonversinya ke format TensorFlow Lite. Setelah integrasi, aplikasi memiliki beberapa layar utama sesuai *wireframe* pada Gambar 1, termasuk splash screen, layar utama untuk memilih atau mengambil gambar, layar prediksi untuk menjalankan model, dan layar hasil untuk menampilkan prediksi. Pengguna dapat mengambil atau memilih gambar di layar utama, menekan tombol "Prediksi" untuk memproses gambar, dan melihat hasil di layar hasil. *Deployment* dilakukan secara terstruktur agar aplikasi mudah digunakan untuk pengujian.



Gambar 1 Wireframe Aplikasi

3. HASIL DAN PEMBAHASAN

Pada bagian ini akan membahas hasil dari penelitian dengan memasukkan hasil dari pengujian pada model CNN.

3.1 Hasil Pengumpulan Data

Dataset yang digunakan dalam penelitian ini didapat dari Dataverse University, dataset berformat zip yang perlu diekstrak, lalu isi dari folder tersebut merupakan gambar-gambar pisang cavendis dan ambon yang sudah dikategorikan sesuai dengan foldernya. Data tersebut mempunyai data sebanyak 1865 dengan 2 folder utama, yaitu test dan train, di mana masing-masing folder terdiri dari 4 subfolder yaitu, matang,

mentah, setengah matang dan terlalu matang. Berikut ini jumlah data pada masing-masing folder tergambar dalam Tabel 1.

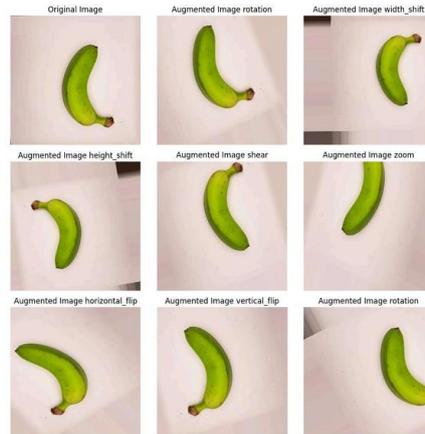
Tabel 1 Jumlah Data pada Dataset

Nama Folder	Jumlah	
	Train	Test
Matang	235	59
Mentah	392	99
Setengah Matang	379	95
Terlalu Matang	484	122

Dataset yang dijelaskan di Dataverse ini berasal dari sumber aslinya dan mencakup tingkat kematangan pisang jenis Cavendish dan Ambon. Pisang Cavendish digunakan untuk kategori setengah matang, matang, dan terlalu matang, sedangkan pisang Ambon digunakan untuk kategori mentah dan untuk memberikan variasi warna pada kategori terlalu matang. Dataset ini terdiri dari 491 gambar mentah, 606 gambar setengah matang, 294 gambar matang, dan 474 gambar terlalu matang. Setiap gambar dalam dataset memiliki resolusi 224 x 224 piksel. Secara keseluruhan, dataset berisi 1.865 gambar yang dibagi menjadi dua bagian: 1.490 gambar untuk pelatihan dan 375 gambar untuk pengujian, yang masing-masing mewakili 80% dan 20% dari total dataset.

3.2 Hasil Data Preparation

Preprocessing ini akan menghasilkan pemerataan pada dataset, sehingga data yang digunakan seragam dan konsisten, dengan ukuran 224x224 piksel berformat RGB standar umum yang digunakan pada data gambar. Selanjutnya, augmentasi data dilakukan untuk meningkatkan variasi dalam dataset. Teknik augmentasi yang digunakan mencakup rotasi, pergeseran lebar dan tinggi, shear, zoom, serta flip horizontal dan vertikal. Augmentasi ini menghasilkan gambar yang lebih bervariasi dan meningkatkan kemampuan model dalam mengenali berbagai pola dalam data.



Gambar 2 Hasil Augmentasi Data

Dataset dibagi menjadi tiga bagian: *training set*, *validation set*, dan *test set*. Dalam penelitian ini, 20% dari data pelatihan digunakan sebagai data validasi untuk memastikan model tidak *overfit* dan memiliki performa yang baik pada data yang tidak terlihat selama pelatihan. Data uji disimpan secara terpisah untuk pengujian akhir model. Sehingga detail jumlah data yang digunakan seperti pada Gambar 3 menunjukkan 296 gambar digunakan untuk validasi.

```
train_generator = datagen_train.flow_from_directory(
    train_path,
    target_size=(224, 224),
    color_mode='rgb',
    class_mode='categorical',
    batch_size=32,
    shuffle=True,
    subset='training'
)

validation_generator = datagen_train.flow_from_directory(
    train_path,
    target_size=(224, 224),
    color_mode='rgb',
    class_mode='categorical',
    batch_size=32,
    shuffle=True,
    subset='validation'
)

test_generator = datagen_test.flow_from_directory(
    test_path,
    target_size=(224, 224),
    color_mode='rgb',
    class_mode='categorical',
    batch_size=32,
    shuffle=False
)
```

Found 1194 images belonging to 4 classes.
Found 296 images belonging to 4 classes.
Found 375 images belonging to 4 classes.

Gambar 3 Jumlah Pembagian Data

Normalisasi data juga dilakukan untuk memastikan bahwa nilai piksel pada gambar konsisten dan berada dalam rentang yang sama yaitu 0-1 per 255. Maka setiap gambar

memiliki nilai piksel yang sama. Proses ini penting untuk mempercepat konvergensi selama pelatihan dan memastikan model dapat belajar dengan efektif.

3.3 Hasil Modeling

Model CNN ini keduanya dibangun model *sequential*-nya dengan base model yang berbeda, model pertama menggunakan arsitektur InceptionV3 dan model kedua menggunakan arsitektur VGG16. Lapisan lainnya terdiri dari global average dan dropout untuk menghindari overfitting. Berikut Gambar 4 dan 5 yang menunjukkan model *sequential* untuk kedua model.

```

Model: "sequential"
-----
Layer (type)                Output Shape                Param #
-----
inception_v3 (Functional)   (None, 5, 5, 2048)        21802784

global_average_pooling2d ( GlobalAveragePooling2D) (None, 2048)                0

dense (Dense)                (None, 512)                1049088

dropout (Dropout)           (None, 512)                0

dense_1 (Dense)              (None, 4)                  2052

-----
Total params: 22853924 (87.18 MB)
Trainable params: 1051140 (4.01 MB)
Non-trainable params: 21802784 (83.17 MB)
-----

```

Gambar 4 Model Sequential Arsitektur InceptionV3

```

Model: "sequential"
-----
Layer (type)                Output Shape                Param #
-----
vgg16 (Functional)          (None, 7, 7, 512)         14714688

global_average_pooling2d ( GlobalAveragePooling2D) (None, 512)                0

dense (Dense)                (None, 512)                262656

dropout (Dropout)           (None, 512)                0

dense_1 (Dense)              (None, 4)                  2052

-----
Total params: 14979396 (57.14 MB)
Trainable params: 264708 (1.01 MB)
Non-trainable params: 14714688 (56.13 MB)
-----

```

Gambar 5 Model Sequential Arsitektur VGG16

3.4 Hasil Training Model

Pelatihan model pada keduanya menggunakan teknik yang sama, namun kedua model berhenti pada epoch yang berbeda dan hasil yang berbeda. Berikut hasil pelatihan pada kedua model yang ditunjukkan pada Tabel 2.

Tabel 2 Hasil Pelatihan Model

Model	Epoch	Akurasi	Val. Akurasi
InceptionV3	65	87%	88%
VGG16	100	92%	94%

Dari hasil pelatihan model, model VGG16 memiliki performa yang lebih baik dibandingkan dengan model InceptionV3.

3.5 Hasil Evaluasi

Evaluasi model Inception V3 dan VGG16 dilakukan melalui visualisasi hasil pelatihan menggunakan grafik akurasi dan loss, confusion matrix, dan classification report. Pada Inception V3, akurasi pelatihan meningkat dari 0,3 menjadi 0,87 dalam 60 epoch, sementara pada VGG16, akurasi meningkat dari 0,3 menjadi 0,9 dalam 100 epoch. Grafik loss pada kedua model menunjukkan penurunan yang signifikan, dengan Inception V3 dari 2,4 menjadi 0,4, dan VGG16 dari 1,4 menjadi 0,2. Confusion matrix pada Inception V3 menunjukkan bahwa kelas "Mentah" memiliki performa terbaik, sedangkan kelas "Matang" dan "Terlalu Matang" mengalami kesulitan dalam membedakan satu sama lain. VGG16, dengan akurasi keseluruhan 92%, juga menunjukkan performa terbaik pada kelas "Mentah" dan "Setengah Matang", tetapi masih ada beberapa kesalahan klasifikasi antara kelas "Matang" dan "Terlalu Matang". Secara keseluruhan, VGG16 menunjukkan performa yang sedikit lebih baik dengan

akurasi yang lebih tinggi, meskipun kedua model memiliki kekurangan dalam membedakan kelas-kelas tertentu.

Tabel 3 Hasil Evaluasi Model

Metrik Evaluasi	InceptionV3	VGG16
Performa terbaik	Mentah (Precision: 0,84, Recall: 0,99)	Mentah (Precision: 0,95, Recall: 0,99)
Kesulitan Klasifikasi	Matang vs Terlalu Matang	Matang vs Terlalu Matang
Precision	0,78	0,9
Recall	0,89	0,94
F1-Score	0,83	0,92
Kelas dengan kesalahan terbanyak	Terlalu Matang (Precision: 0,78)	Terlalu Matang (Precision: 0,88, Recall: 0,93)

Perbandingan ini memperlihatkan bahwa meskipun kedua model memiliki performa yang baik, VGG16 menunjukkan kinerja yang sedikit lebih unggul dengan akurasi keseluruhan yang lebih tinggi dan lebih sedikit kesalahan klasifikasi dibandingkan Inception V3.

3.6 Hasil Uji Coba Real-time Model

Uji coba dilakukan dalam berbagai situasi dengan 35 sampel, termasuk pencahayaan rendah, pencahayaan memadai, dan variasi jarak dari objek pisang yang dideteksi. Selain itu, model diuji pada variasi jumlah pisang yang muncul dalam satu gambar. Tujuan dari kondisi-kondisi ini adalah untuk menguji seberapa baik model dapat mengenali kematangan pisang dalam berbagai skenario dunia nyata. Berikut Tabel 4 yang menunjukkan hasil dari pengujian kedua model.

Tabel 4 Hasil Pengujian Model

Model	Jumlah benar	Akurasi
InceptionV3	22	62.85%
VGG16	30	85.71%

Analisis dari kedua model, InceptionV3 dan VGG16, menunjukkan bahwa kondisi pencahayaan dan jarak memiliki pengaruh signifikan terhadap ketepatan prediksi kematangan pisang. Baik InceptionV3 maupun VGG16 cenderung memberikan prediksi yang lebih akurat pada kondisi pencahayaan normal dengan jarak jauh atau dekat. Sebaliknya, pada pencahayaan cerah dengan jarak sangat dekat, terjadi lebih banyak ketidakakuratan, seperti pisang yang diprediksi matang ternyata terlalu matang atau mentah. Model InceptionV3 memiliki tingkat ketepatan prediksi sebesar 62,85%, dengan kelas "Matang" menunjukkan akurasi yang lebih tinggi pada pencahayaan normal dan jarak yang lebih stabil, namun mengalami kesulitan pada kondisi pencahayaan cerah dengan jarak sangat dekat. Sebaliknya, model VGG16 menunjukkan performa yang lebih unggul dengan tingkat ketepatan prediksi sebesar 85,71%. Sama seperti InceptionV3, model ini juga menunjukkan beberapa ketidakakuratan pada kelas "Terlalu Matang" di kondisi pencahayaan cerah dengan jarak sangat dekat. Secara keseluruhan, VGG16 memberikan prediksi yang lebih konsisten dibandingkan InceptionV3, namun kedua model sama-sama dipengaruhi oleh kondisi pencahayaan dan jarak, terutama pada kondisi ekstrim seperti pencahayaan cerah dan jarak yang sangat dekat. Kesimpulannya, untuk meningkatkan akurasi prediksi pada kedua model, perlu dilakukan penyesuaian lebih lanjut pada faktor jarak dan pencahayaan.

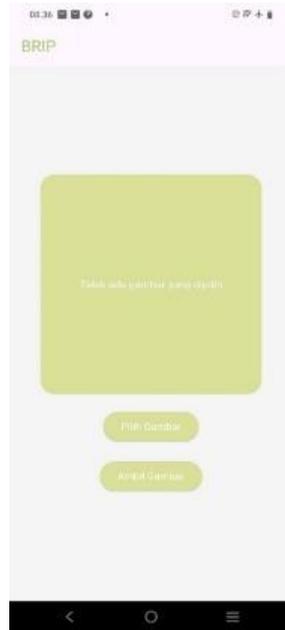
3.7 Hasil Deployment

Hasil *deployment* ini berupa aplikasi klasifikasi kematangan pisang dengan model yang sudah dibuat sebelumnya dengan berdasarkan hasil dari pengisian kuisioner oleh pengguna. Kedua model InceptionV3 dan VGG16 ini dibuatkan aplikasi android yang sama dengan menggunakan flutter, hanya berbeda pada model yang diimplementasikan. Aplikasi yang dibuat sesuai dengan wireframe yang telah dibuat sebelumnya. Aplikasi ini akan mendeteksi kematangan pisang menggunakan camera atau upload gambar.



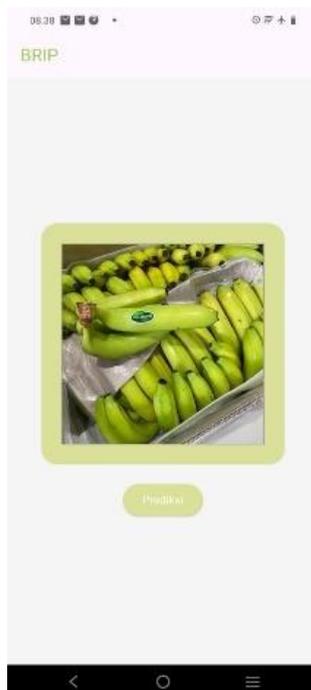
Gambar 6 Splash Screen

Pada Gambar 6 Adalah tampilan splash screen aplikasi yang akan ditampilkan selama 3 detik ketika aplikasi dibuka.



Gambar 7 Home Screen

Pada Gambar 7 adalah tampilan halaman utama yang berisi 2 tombol untuk melakukan prediksi, yaitu ambil gambar atau pilih gambar. Jika dipilih ambil gambar maka akan langsung terintegrasi ke galeri handphone, lalu jika dipilih pilih gambar maka akan otomatis membuka kamera.



Gambar 8 Halaman Cek Prediksi

Setelah mengambil atau memilih gambar lalu masuk ke halaman prediksi, pada gambar 8 adalah tampilan halaman untuk prediksi, terdapat satu tombol yaitu prediksi dan gambar yang telah dipilih.



Gambar 9 Halaman Hasil Prediksi

Pada gambar 9 adalah halaman hasil prediksi, setelah menekan tombol cek prediksi maka akan keluar hasil prediksi berupa kelas yang yang model prediksi. Pada tampilan halan hasil prediksi berisi gambar pisang yang dipilih lalu hasil prediksi dan tombol untuk kembali ke menu utama.

3.8 Hasil Uji Coba Model pada Aplikasi Android

Uji coba dilakukan pada handphone Android Samsung s10 + dengan android versi 12. Gambar untuk melakukan pengujian ini diambil di AEON Tanjung Barat, AlfaMidi Kebagusan, dan penjual pisang di Kebagusan Dalam 1. Gambar yang diambil adalah

180 gambar dengan berbagai jenis kematangan, namun untuk pengujian yang dimasukan ke dalam penelitian hanya 10 Gambar. Berikut tabel yang menunjukan hasil dari percobaan dengan 10 sampel:

Tabel 5 Hasil Pengujian Model pada Aplikasi

Model	Jumlah benar	Akurasi
InceptionV3	7	70%
VGG16	8	80%

Uji terhadap 10 sampel menggunakan model InceptionV3 dan VGG16 menunjukkan bahwa VGG16 lebih akurat dalam memprediksi kematangan pisang. InceptionV3 memprediksi 7 dari 10 sampel dengan benar, tetapi mengalami kesalahan signifikan pada kelas "Setengah-matang," yang sering diklasifikasikan sebagai "Mentah" atau "Matang" karena variasi warna yang mirip. Sebaliknya, VGG16 berhasil memprediksi 8 sampel dengan benar, termasuk kelas "Setengah-matang" dengan lebih akurat, dan hanya membuat satu kesalahan pada kelas "Terlalu matang." Meskipun VGG16 lebih unggul, kedua model menghadapi tantangan serupa dalam membedakan kelas yang berdekatan dalam spektrum kematangan.

3.9 Hasil Perbandingan Model InceptionV3 dan VGG16

Hasil analisis perbandingan dua arsitektur CNN yaitu, InceptionV3 dan VGG16 menunjukkan bahwa meskipun InceptionV3 adalah model yang lebih kompleks dan dirancang untuk menangkap fitur dari berbagai skala, performanya pada dataset ini sedikit tertinggal dibandingkan dengan VGG16. InceptionV3 mencatatkan akurasi keseluruhan sebesar 87%, dengan precision 86%, recall 87%, dan f1-score 86%. Di sisi lain, VGG16 berhasil mencapai akurasi 92%, precision 91%, recall 91%, dan f1-score 91%, menunjukkan keunggulan yang konsisten di semua metrik evaluasi. Tabel 4.6 menunjukkan perbandingan metrik evaluasi kedua model.

Tabel 6 Hasil Perbandingan Model

Metrik Evaluasi	InceptionV3	VGG16
Epoch	65/100	100/100
Total Parameter	22,853,924 (<i>Trainable:</i> 1,051,140)	14,979,396 (<i>Trainable:</i> 264,708)
Akurasi Pelatihan	0.87	0.92
Akurasi Validasi	0.88	0.94
Kerugian Pelatihan	1.1477	0.2745
Kerugian Validasi	1.0830	0.2293
Precision (Matang)	0.69	0.80
Precision (Mentah)	0.84	0.95
Precision (Setengah Matang)	0.96	0.94
Precision (Terlalu Matang)	0.94	0.93
Recall (Matang)	0.86	0.80
Recall (Mentah)	0.99	0.99

Recall (Setengah Matang)	0.84	0.95
Recall (Terlalu Matang)	0.78	0.88
F-1 Score (Matang)	0.77	0.80
F-1 Score (Mentah)	0.91	0.97
F-1 Score (Setengah Matang)	0.89	0.95
F-1 Score (Terlalu Matang)	0.85	0.91
Kelas dengan performa terbaik	Mentah	Mentah
Kelas dengan kesalahan terbanyak pada data uji	Terlalu matang	Terlalu matang

Dari Tabel 4.6 dapat dilihat keunggulan dari model VGG16 berdasarkan evaluasi metrik. Keunggulan VGG16 ini bisa dijelaskan oleh beberapa faktor. Pertama, arsitektur VGG16 yang lebih sederhana dan terfokus memungkinkan model ini untuk lebih efektif dalam mengekstraksi fitur penting dari dataset yang relatif kecil. Dengan hanya menggunakan filter berukuran kecil (3x3) dalam urutan konvolusi yang dalam, VGG16 mampu mempertahankan konsistensi dalam mengekstraksi pola dasar seperti

tekstur dan tepi, yang sangat penting dalam tugas klasifikasi kematangan pisang. Pada dataset yang terbatas, model VGG16 dapat lebih stabil dan mengurangi risiko overfitting dapat dilihat pada nilai kerugian yang cenderung lebih kecil dari nilai akurasi, berbeda dengan arsitektur InceptionV3 yang lebih kompleks dan rentan terhadap overfitting pada data pelatihan kecil, dapat dilihat juga nilai kerugian lebih besar daripada nilai akurasi. InceptionV3 dapat lebih efektif untuk dataset yang besar dan beragam, pada dataset yang lebih kecil seperti 1194 data pelatihan, kompleksitas ini bisa menyebabkan model overfit terhadap data pelatihan. VGG16, dengan arsitekturnya yang lebih sederhana, cenderung lebih stabil dan dapat lebih mudah untuk di-generalize ke data baru.

Selain itu, VGG16 memiliki jumlah parameter yang lebih sedikit dibandingkan dengan InceptionV3, sehingga lebih efisien dalam pembelajaran pada dataset dengan ukuran terbatas. Sementara InceptionV3 membutuhkan lebih banyak data untuk memanfaatkan sepenuhnya kemampuan arsitekturnya yang canggih, VGG16 dapat mencapai performa optimal dengan data yang lebih sedikit. Oleh karena itu, dalam penelitian ini, VGG16 terbukti lebih unggul dalam menangani tugas klasifikasi dengan dataset yang lebih kecil dan lebih homogen.

4. PENUTUP

4.1 Kesimpulan

Penelitian ini bertujuan untuk mengembangkan model Convolutional Neural Network (CNN) yang dapat mengidentifikasi tingkat kematangan pisang. Model dibangun dengan membandingkan dua arsitektur CNN, yaitu InceptionV3 dan VGG16 untuk menemukan performa yang terbaik. Model InceptionV3 menunjukkan performa baik dengan akurasi keseluruhan 87%, precision 86%, recall 87%, dan f1-score 86%. Sementara itu, model VGG16 menunjukkan performa dengan akurasi 92%, precision 91%, recall 91%, dan f1-score 91%. Meskipun VGG16 lebih unggul dibanding InceptionV3, kedua model mengalami kesulitan dalam memprediksi kelas "Matang"

dan "Terlalu matang," yang dapat disebabkan oleh ketidakseimbangan dataset, serta variasi warna dominan hijau dalam dataset kelas "Setengah matang." Hasil prediksi model juga dapat dipengaruhi oleh faktor pencahayaan, latar belakang dan jarak. Pada penelitian ini VGG16 memberikan performa lebih baik dibandingkan InceptionV3, tetapi kualitas dataset tetap menjadi faktor krusial dalam kinerja kedua model.

4.2 Saran

Berdasarkan hasil penelitian, beberapa saran untuk meningkatkan performa model adalah sebagai berikut:

1. Menggunakan Dataset yang lebih seimbang: Pastikan dataset memiliki jumlah gambar yang seimbang untuk setiap kelas dan mencakup variasi yang luas. Ini akan membantu model dalam belajar lebih baik selama pelatihan dan meningkatkan kemampuannya dalam memprediksi berbagai kondisi.
2. Menambahkan fitur pada aplikasi mobile: Kembangkan fitur tambahan pada aplikasi mobile untuk memberikan informasi yang lebih lengkap dan menarik bagi pengguna.
3. Fitur klasifikasi berdasarkan jenis pisang: Tambahkan fitur untuk mengidentifikasi jenis pisang saat mengklasifikasikan kematangannya, agar model lebih spesifik dalam penilaian.

REFERENSI

- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1). <https://doi.org/10.1186/s40537-021-00444-8>
- Amelia Dertta Irjayanti, S. AP. , M. SE., Agung Setyo Wibowo, S., Hanik Stiyarningsih, S. M. Sc., Ike Mahlida Putri, S., Oktya Putri Gitaningtyas, S. M. S. E., Satria Kurnia Areka, S. Tr. S., Wati Suprapti, S. Pd., & Zelani Nurfalalah, S. (2022). *Statistik Hortikultura 2022*. BPS RI/BPS-Statistics Indonesia.

- Andanu, O., Udin, F., & Titi Candra Sunarti. (2021). STRATEGI PENINGKATAN KUALITAS PRODUK DALAM RANTAI PASOK KOMODITI PISANG DI PROVINSI BENGKULU. *Jurnal Teknologi Industri Pertanian*, 220–231. <https://doi.org/10.24961/j.tek.ind.pert.2021.31.2.220>
- Badan Pusat Statistik. (2021, December 18). Mencatat Pertanian Indonesia. <https://www.bps.go.id/id/news/2021/12/18/446/mencatat-pertanian-indonesia.html>
- Dwivany, F. M. Et. al. (2021). Pisang Indonesia. In ITB Press (Vols. 978-623–29, Issue March).
- Hilman Ferdinandus Pardede. (2023). Penerapan Pembelajaran Mesin (Machine Learning) dan Pembelajaran Dalam (Deep Learning) Berkinerja Tinggi untuk Mendukung Sektor Pertanian di Indonesia. In Penerapan Pembelajaran Mesin (Machine Learning) dan Pembelajaran Dalam (Deep Learning) Berkinerja Tinggi untuk Mendukung Sektor Pertanian di Indonesia. Penerbit BRIN. <https://doi.org/10.55981/brin.872>
- Kangune, K., Kulkarni, V., & Kosamkar, P. (2019). Grapes Ripeness Estimation using Convolutional Neural network and Support Vector Machine. 2019 Global Conference for Advancement in Technology (GCAT), 1–5. <https://doi.org/10.1109/GCAT47503.2019.8978341>
- Khan, S., & Yairi, T. (2018). A review on the application of deep learning in system health management. In *Mechanical Systems and Signal Processing* (Vol. 107, pp. 241–265). Academic Press. <https://doi.org/10.1016/j.ymsp.2017.11.024>
- Meshram, V., Patil, K., Meshram, V., Hanchate, D., & Ramkteke, S. D. (2021). Machine learning in agriculture domain: A state-of-art survey. *Artificial Intelligence in the Life Sciences*, 1(October), 100010. <https://doi.org/10.1016/j.aailsci.2021.100010>
- Saranya, N., Srinivasan, K., & Kumar, S. K. P. (2022). Banana ripeness stage identification: a deep learning approach. *Journal of Ambient Intelligence and Humanized Computing*, 13(8), 4033–4039. <https://doi.org/10.1007/s12652-021-03267-w>
- Shorif, M., Jagdish, U., & Bansal, C. (2021). Computer Vision and Machine Learning in Agriculture. <http://www.springer.com/series/16171>
- Shuprajhaa, T., Mathav Raj, J., Paramasivam, S. K., Sheeba, K. N., & Uma, S. (2023). Deep learning based intelligent identification system for ripening stages of banana. *Postharvest Biology and Technology*, 203, 112410. <https://doi.org/https://doi.org/10.1016/j.postharvbio.2023.112410>
- Tapia-Mendez, E., Cruz-Albarran, I. A., Tovar-Arriaga, S., & Morales-Hernandez, L. A. (2023). Deep Learning-Based Method for Classification and Ripeness

Assessment of Fruits and Vegetables. *Applied Sciences*, 13(22), 12504.
<https://doi.org/10.3390/app132212504>

Wisjnu, S. S., Wardhani, Ismunandar, Michael A, Purwoadi, & Anto S. (2020). STRATEGI NASIONAL KECERDASAN ARTIFISIAL INDONESIA. In *Strategi nasional kecerdasan artifisial Indonesia 2020-2045*.
<https://karya.brin.go.id/id/eprint/13918/>