

KLASIFIKASI TINGKAT KEMATANGAN BUAH JENGKOL MENGUNAKAN CNN DENGAN ARSITEKTUR MOBILENETV3

Cindy Meilani, Abdul Rahman

Teknik Informatika, Universitas Multi Data Palembang
Jalan Rajawali 14 Palembang, Indonesia
cindymeilani_2226250107@mhs.mdp.ac.id

ABSTRAK

Buah jengkol merupakan komoditas pertanian bernilai ekonomi tinggi yang memerlukan proses penyortiran berdasarkan tingkat kematangan untuk menjaga kualitas dan nilai jual. Namun, proses penyortiran yang masih dilakukan secara manual sering menimbulkan ketidakkonsistenan dan membutuhkan waktu yang relatif lama. Permasalahan utama yang dihadapi adalah keterbatasan pendekatan klasifikasi tingkat kematangan buah jengkol yang mampu memberikan akurasi tinggi sekaligus efisiensi komputasi. Oleh karena itu, penelitian ini bertujuan untuk membandingkan performa dan efisiensi komputasi arsitektur *MobileNetV3-Large* dan *MobileNetV3-Small* dalam mengklasifikasikan tingkat kematangan buah jengkol. Metode yang digunakan adalah computer vision berbasis *Convolutional Neural Network* (CNN) dengan dataset citra buah jengkol yang dibagi ke dalam tiga kelas, yaitu muda, sedang, dan tua. Evaluasi dilakukan menggunakan metrik akurasi serta analisis efisiensi komputasi. Hasil penelitian menunjukkan bahwa *MobileNetV3-Large* mampu mencapai akurasi sebesar 97,79%, namun memerlukan sumber daya komputasi yang lebih besar. Sementara itu, *MobileNetV3-Small* menghasilkan performa terbaik dengan akurasi sebesar 98,53%, serta memiliki kebutuhan komputasi dan waktu inferensi yang lebih rendah. Dengan demikian, *MobileNetV3-Small* dinilai lebih efektif dan efisien untuk klasifikasi tingkat kematangan buah jengkol.

Kata kunci : CNN, *MobileNetV3-Small*, *MobileNetV3-Large*, Klasifikasi, Kematangan Buah

1. PENDAHULUAN

Buah jengkol merupakan komoditas pertanian yang memiliki nilai ekonomi tinggi dan banyak dibudidayakan di Indonesia. Jengkol dimanfaatkan masyarakat sebagai bahan berbagai olahan makanan tradisional, sehingga permintaan pasar terhadap buah ini relatif stabil [1]. Selain bernilai ekonomi, buah jengkol juga memiliki kandungan gizi seperti protein, zat besi, kalsium, fosfor, dan vitamin yang bermanfaat bagi Kesehatan [2].

Dalam proses pascapanen, buah jengkol perlu disortir berdasarkan tingkat kematangannya, yaitu jengkol muda, jengkol sedang, dan jengkol tua. Perbedaan tingkat kematangan tersebut ditandai oleh variasi warna dan tekstur daging buah yang memengaruhi kualitas rasa serta nilai jual jengkol di pasaran [3]. Namun, hingga saat ini penentuan tingkat kematangan jengkol masih dilakukan secara manual dengan mengandalkan pengamatan visual petani atau petugas penyortiran.

Proses penyortiran secara manual sering menimbulkan ketidak konsistenan karena perbedaan persepsi serta keterbatasan penglihatan manusia. Karakteristik visual antar tingkat kematangan yang relatif mirip membuat proses identifikasi menjadi kurang akurat dan membutuhkan waktu yang cukup lama [4]. Kondisi tersebut berpotensi menghasilkan kualitas produk yang tidak seragam dan dapat memengaruhi nilai jual jengkol di pasaran [5]. Berdasarkan kondisi tersebut, permasalahan yang dihadapi adalah keterbatasan pendekatan klasifikasi tingkat kematangan buah jengkol dalam mencapai akurasi yang tinggi sekaligus efisiensi komputasi.

Dari permasalahan yang ada, penelitian ini bertujuan untuk membandingkan performa dan efisiensi komputasi *MobileNetV3-Large* dan *MobileNetV3-Small* dalam mengklasifikasikan tingkat kematangan buah jengkol secara otomatis agar proses penyortiran menjadi lebih cepat, konsisten, dan objektif.

Pemanfaatan teknologi *computer vision* dengan metode *Convolutional Neural Network* (CNN) menjadi salah satu solusi yang dapat digunakan untuk membantu proses klasifikasi tingkat kematangan buah jengkol. CNN mampu mengekstraksi fitur visual dari citra secara otomatis dan mengenali pola dengan baik, sehingga sesuai digunakan untuk tugas klasifikasi citra pada bidang pertanian [6]. Dengan kemampuan tersebut, CNN diharapkan dapat membantu proses identifikasi tingkat kematangan buah secara lebih cepat dan konsisten.

Oleh karena itu, diperlukan arsitektur CNN yang mampu menyeimbangkan antara akurasi dan efisiensi komputasi. Arsitektur *MobileNetV3*, yang merupakan arsitektur CNN dengan rancang sebagai model ringan dengan kebutuhan komputasi yang lebih rendah. *MobileNetV3* yang digunakan, yaitu *MobileNetV3-Large* dan *MobileNetV3-Small*, yang di mana kedua arsitektur ini memiliki perbedaan karakteristik dari sisi akurasi dan efisiensi.

2. TINJAUAN PUSTAKA

Landasan teori merupakan dasar ilmiah yang digunakan untuk mendukung penelitian ini. Bagian ini berisi teori-teori, konsep, serta hasil penelitian terdahulu yang relevan dengan topik klasifikasi tingkat

kematangan buah jengkol menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNetV3*. Teori-teori yang dipaparkan di dalamnya mencakup klasifikasi, buah jengkol, CNN, arsitektur *MobileNetV3*, *Transfer Learning*, pengolahan citra, dan *Optimizer AdamW*.

2.1. Penelitian Sebelumnya

Penelitian sebelumnya terkait pengenalan tingkat kematangan buah jengkol telah dilakukan dengan memanfaatkan metode deep learning berbasis computer vision. Salah satu penelitian menggunakan arsitektur YOLOv5 untuk mendeteksi dan mengenali tingkat kematangan buah jengkol secara real-time. Penelitian tersebut menunjukkan hasil yang cukup baik dengan akurasi sebesar 80%, serta nilai *precision* 98%, *recall* 99%, dan *mean Average Precision* (mAP) sebesar 98%. Hasil ini menunjukkan bahwa pendekatan deep learning mampu mengenali karakteristik visual buah jengkol dengan baik, meskipun dari sisi efisiensi komputasi masih perlu diperhatikan untuk implementasi yang lebih optimal [7].

Penelitian lain juga mengkaji penggunaan arsitektur *Convolutional Neural Network* (CNN) seperti InceptionV3 dan VGG-16 dalam melakukan klasifikasi objek, termasuk pada citra buah jengkol. Hasil penelitian menunjukkan bahwa arsitektur InceptionV3 mampu mencapai akurasi sebesar 84,5%, sedangkan VGG-16 memperoleh akurasi sebesar 77,5%. Perbedaan hasil tersebut menunjukkan bahwa pemilihan arsitektur CNN sangat berpengaruh terhadap performa klasifikasi. Meskipun menghasilkan akurasi yang relatif baik, arsitektur CNN yang digunakan masih memiliki kompleksitas model yang cukup tinggi sehingga berdampak pada kebutuhan komputasi yang besar [8].

2.2. Klasifikasi

Klasifikasi merupakan cara pengelompokan benda berdasarkan ciri – ciri yang dimiliki oleh objek klasifikasi. Dalam prosesnya, klasifikasi dapat dilakukan dengan banyak cara baik secara manual ataupun dengan bantuan teknologi [9]. Klasifikasi sering diterapkan untuk membangun model prediksi yang dapat membantu dalam pengambilan keputusan. Proses klasifikasi adalah mengelompokkan data ke dalam kategori tertentu berdasarkan aturan yang telah ditetapkan.[10]

2.3. Buah Jengkol

Jengkol (*Archidendron pauciflorum*) merupakan salah satu hasil hutan yang dikenal di berbagai wilayah di Indonesia yang persebarannya cukup banyak karena termasuk sebagai tanaman endemik khas Asia Tenggara [11]. Jengkol merupakan salah satu tanaman yang berasal dari *famili Fabaceae*. Jengkol merupakan sumber makanan yang sangat digemari terutama masyarakat Indonesia.

Tanaman jengkol termasuk jenis tanaman semak berkayu dengan ketinggian rata-rata mencapai 20 meter, buahnya berwarna coklat dan berbentuk bundar. Buah jengkol memiliki banyak manfaat di bidang lingkungan sebagai tanaman konservasi karena kemampuan tanaman jengkol menyerap air.

2.4. Pengolahan Citra Digital

Pengolahan Citra Digital atau (Digital Image Processing) merupakan bidang ilmu yang mempelajari tentang bagaimana suatu citra itu dibentuk, diolah, dan dianalisis sehingga menghasilkan informasi yang dapat dipahami oleh manusia [12]. Pengolahan citra digital (image processing) merupakan proses pengolahan data citra berdasarkan suatu metode yang menghasilkan output bentuk citra lain, yang mengandung ataupun memperkuat informasi khusus pada output dari citra tersebut [13].

2.5. Convolutional Neural Network (CNN)

CNN merupakan salah satu jenis *neural network* dimana metode ini dapat digunakan pada data image. CNN memiliki kemampuan untuk mengenali objek pada suatu *image*. *Convolutional Neural Network* merupakan salah satu model dari Deep Learning yang banyak digunakan untuk menganalisis citra/visual [14]. *Convolutional Neural Network* (CNN) terdiri dari lapis masukan (input layer), lapis keluaran (output layer) dan sejumlah lapisan tersembunyi (hidden Layers) [15].

2.6. Transfer Learning

Transfer learning merupakan metode terkini untuk mempercepat waktu training pada CNN dan untuk mendapatkan performa klasifikasi yang lebih baik [16]. *Transfer learning* merupakan model arsitektur CNN yang sudah dilatih oleh suatu dataset sebelumnya yang bisa digunakan untuk klasifikasi pada dataset lain. *Transfer learning* memiliki arsitektur lapisan *convolution* dan *pooling* yang lebih dalam dibandingkan arsitektur CNN sederhana, sehingga dapat melakukan ekstraksi tekstur citra lebih banyak dan menghasilkan informasi dari citra yang lebih baik [17].

2.7. MobileNetV3-Small

MobileNetV3-Small merupakan varian yang ditujukan untuk perangkat dengan kapasitas komputasi rendah, seperti IoT atau sistem tertanam berdaya terbatas. Berikut tabel spesifikasi arsitektur *MobileNetV3-Small* di tunjukan pada Tabel 1.

Tabel 1. Arsitektur *MobileNetV3-Small*

Input	Operator	exp size	#out	SE	NL	s
$224^2 \times 3$	conv2d, 3×3	–	16	–	HS	2
$112^2 \times 16$	bneck, 3×3	–	16	✓	RE	1
$56^2 \times 16$	bneck, 3×3	72	24	–	RE	2
$28^2 \times 24$	bneck, 5×5	88	24	–	RE	1
$28^2 \times 24$	bneck, 5×5	96	40	✓	HS	2

Input	Operator	exp size	#out	SE	NL	s
$14^2 \times 40$	bneck, 5×5	240	40	✓	HS	1
$14^2 \times 40$	bneck, 5×5	240	40	✓	HS	1
$14^2 \times 40$	bneck, 5×5	120	48	✓	HS	1
$14^2 \times 48$	bneck, 5×5	144	48	✓	HS	1
$14^2 \times 48$	bneck, 5×5	288	96	✓	HS	2
$7^2 \times 96$	bneck, 5×5	576	96	✓	HS	1
$7^2 \times 96$	bneck, 5×5	576	96	✓	HS	1
$7^2 \times 96$	conv2d, 1×1	—	576	—	HS	1
$7^2 \times 576$	pool, 7×7	—	—	—	—	—
$1^2 \times 576$	conv2d 1×1, NBN	—	1024	—	HS	1
$1^2 \times 1024$	conv2d 1×1, NBN	—	k	—	—	1

2.8. MobileNetV3-Large

MobileNetV3-Large merupakan varian yang ditujukan untuk perangkat dengan sumber daya komputasi lebih tinggi, seperti smartphone modern dan sistem *embedded* berperforma menengah ke atas. Berikut tabel spesifikasi *arsitektur MobileNetV3-Large* di tunjukan pada Tabel 2.

Tabel 2. Arsitektur *MobileNetV3-Large*

Input	Operator	exp size	#out	SE	NL	s
$224^2 \times 3$	conv2d	—	16	—	HS	2
$112^2 \times 16$	bneck, 3×3	16	16	—	RE	1
$112^2 \times 16$	bneck, 3×3	64	24	—	RE	2
$56^2 \times 24$	bneck, 3×3	72	24	—	RE	1
$56^2 \times 24$	bneck, 5×5	72	40	✓	RE	2
$28^2 \times 40$	bneck, 5×5	120	40	✓	RE	1
$28^2 \times 40$	bneck, 5×5	120	40	✓	RE	1
$28^2 \times 40$	bneck, 3×3	240	80	—	HS	2
$14^2 \times 80$	bneck, 3×3	200	80	—	HS	1
$14^2 \times 80$	bneck, 3×3	184	80	—	HS	1
$14^2 \times 80$	bneck, 3×3	480	112	✓	HS	1
$14^2 \times 112$	bneck, 5×5	672	112	✓	HS	1
$14^2 \times 112$	bneck, 5×5	672	160	✓	HS	2
$7^2 \times 160$	bneck, 5×5	960	160	✓	HS	1
$7^2 \times 160$	bneck, 5×5	960	160	✓	HS	1
$7^2 \times 160$	conv2d, 1×1	—	960	—	HS	1
$7^2 \times 960$	pool, 7×7	—	—	—	—	—
$1^2 \times 960$	conv2d 1×1, NBN	—	1280	—	HS	1
$1^2 \times 1280$	conv2d 1×1, NBN	—	k	—	HS	1

2.9. Optimazer AdamW

Optimizer AdamW adalah sebuah variasi dari *optimizer Adam* yang memperkenalkan teknik *Weight Decay* secara lebih eksplisit dalam proses optimisasi. *AdamW* memodifikasi *Adam* dengan memisahkan *weight decay* dari proses update parameter. Ini mengatasi beberapa kekurangan *Adam* dalam mengelola regularisasi *weight decay* [18]. Berikut persamaan *AdamW* yang dapat dilihat pada persamaan (1).

$$\theta t + 1 = \theta t - \frac{\alpha \cdot \hat{m}t}{\sqrt{\hat{v}t + \epsilon}} - \alpha \omega d \theta t \quad (1)$$

Dimana ωd adalah *weight decay* yang diterapkan pada parameter.

3. METODE PENELITIAN



Gambar 1. Metodologi Penelitian

Pada gambar 1 tahapan penelitian diatas dapat dilihat langkah-langkah dalam penelitian ini. Metodologi yang di gunakan dirancang secara sistematis agar penelitian dapat lebih tersusun sesuai degan tujuan yang ditetapkan. Tahapan Penelitian ini dimulai dari studi literatur, pengumpulan dataset, perancangan model, implementasi, dan pengujian.

3.1. Studi Literatur

Tahapan ini dimulai dengan melakukan pembelajaran literatur berupa jurnal, dan buku serta penelitian terdahulu yang berkaitan dan relevan terkait topik penelitian ini, yaitu klasifikasi tingkat kematangan buah khususnya buah jengkol menggunakan metode CNN (Convolutional Neural Network) dengan arsitektur *MobileNetV3*.

3.2. Pengumpulan Dataset

Pada tahap ini, dilakukan proses pengumpulan ataset berupa citra buah jengkol yang diperoleh dari dataset publik pada platform *RoboFlow* dengan judul “Pendeteksi Kematangan Jengkol” yang dapat diakses melalui tautan: <https://universe.roboflow.com/tugas-skripsi/pendeteksi-kematangan-jengkol/model/3>. Dataset ini berisi gambar dari tingkat kematangan jengkol yang telah dikategorikan kedalam beberapa kelas tingkat kematangan yaitu tua, sedang, muda. Semua citra pada dataset memiliki format .jpg dengan ukuran citra 640 x 640 piksel dan dengan background berwarna putih. Dataset kematangan buah jengkol yang digunakan dapat dilihat pada Tabel 3.

Tabel 3. Dataset Jengkol

Kelas	Gambar/ Citra
Muda	
Sedang	
Tua	


3.3. Perancangan

Pada tahap ini dilakukan perancangan sistem identifikasi tingkat kematangan buah jengkol menggunakan arsitektur *MobileNetV3-Large* dan *MobileNetV3-Small*. Dataset terdiri dari tiga kelas, yaitu jengkol muda, sedang, dan tua, yang digunakan sebagai dasar dalam membangun sistem yang mampu mengenali tingkat kematangan secara cepat dan objektif.

Seluruh citra diproses melalui tahap preprocessing dengan penyesuaian ukuran menjadi 224×224 piksel dan normalisasi sesuai standar *MobileNetV3*. Selain itu, dilakukan augmentasi citra seperti random *flip*, *rotation*, *zoom*, *contrast*, dan *brightness* untuk meningkatkan variasi data dan mengurangi risiko *overfitting*. Dataset kemudian dibagi dengan rasio 80% data latih, 10% validasi, dan 10% data uji.

Perancangan model menggunakan pendekatan transfer learning dengan *MobileNetV3-Large* dan *MobileNetV3-Small* yang telah dilatih pada ImageNet sebagai *backbone*. Lapisan akhir model disesuaikan dengan tiga kelas kematangan jengkol, serta dilakukan fine-tuning pada beberapa lapisan akhir untuk menyesuaikan karakteristik citra jengkol.

Proses pelatihan model menggunakan *optimizer AdamW* untuk menjaga kestabilan pembelajaran. *Callback EarlyStopping* dan *ReduceLROnPlateau* digunakan untuk mencegah *overfitting* dan mengoptimalkan proses pelatihan. Evaluasi model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Diagram rancangan sistem *MobileNetV3-Small* dan *MobileNetV3-Large* ditampilkan pada Gambar 2.



Gambar 2. Skema Perancangan

3.4. Implementasi

Pada tahapan ini akan dilakukan implementasi dari sistem klasifikasi citra dengan menggunakan bahasa pemrograman python, dengan tujuan agar sistem dapat mengenali dan mengklasifikasikan data pelatihan yang telah melalui proses preprocessing dan augmentasi. Implementasi ini direncanakan sebagai tahap realisasi rancangan model berbasis *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNetV3*, sehingga sistem mampu mempelajari pola visual dari citra dan mengelompokkannya sesuai kategori yang telah ditentukan.

3.5. Pengujian

Pada tahapan ini, sistem yang telah dibuat sebelumnya akan melakukan uji coba terhadap data uji. Setelah tahapan uji coba, hasil pengujian dihitung untuk mendapatkan tingkat keberhasilan metode yang digunakan dengan *Confusion Matrix* dalam menghitung nilai *accuracy*, *precision*, *recall*, dan *F1-Score* yang dapat untuk memahami kemampuan model dalam mengenali tingkat kematangan jengkol. Ditunjukkan pada Persamaan (2), (3), (4) dan (5) sebagai berikut :

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100 \quad (2)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \times 1 \quad (4)$$

$$F1 - Score = \frac{2 \times (Precision \times Recall)}{Precision + Recall} \quad (5)$$

Keterangan:

- TP : Jumlah citra jengkol pada kelas kematangan tertentu (misalnya: matang) yang berhasil diklasifikasikan dengan benar sebagai kelas tersebut oleh sistem.
- TN : Jumlah citra jengkol dari kelas lain (bukan kelas yang sedang dievaluasi) yang berhasil diklasifikasikan dengan benar sebagai bukan kelas tersebut.
- FN : Jumlah citra jengkol dari kelas tertentu yang gagal dikenali, sehingga diklasifikasikan sebagai kelas lain (misalnya: jengkol matang tetapi diprediksi sebagai mentah).
- FP : Jumlah citra jengkol dari kelas lain yang salah diklasifikasikan sebagai kelas tertentu (misalnya: jengkol mentah tetapi terdeteksi sebagai matang).

4. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil implementasi, pengujian, dan analisis kinerja model dalam klasifikasi tingkat kematangan buah jengkol dengan mempertimbangkan efisiensi komputasi. Pengujian dilakukan melalui beberapa skenario pelatihan untuk mengevaluasi stabilitas dan performa model. Hasil efisiensi komputasi dinilai berdasarkan jumlah

parameter, total *FLOPs*, dan waktu inferensi per gambar, guna menilai sejauh mana model mampu mengidentifikasi tingkat kematangan buah jengkol secara optimal dengan penggunaan sumber daya yang efisien.

4.1. Skenario Pengujian

Pengujian pada penelitian ini dilakukan dengan menggunakan dataset berupa citra gambar sebanyak 1.356 citra yang dibagi menjadi 80:10:10 yang terdiri dari data latih, uji dan validasi. Seluruh citra tersebut melalui tahap *preprocessing* yang disesuaikan ukurannya menjadi 224 x 224 piksel serta dilakukan augmentasi seperti *flip*, *rotation*, *zoom*, *contrast*, dan *brightness* agar mengurangi resiko *overfitting* pada model. Model dikonfigurasi menggunakan *transfer learning* dengan arsitektur *MobileNetV3-Small* dan *Large*, di uji menggunakan *optimizer AdamW* *Learning rate* dengan nilai tetap pada 0.00005 dan *Weight decay* dengan nilai tetap pada 0.0001. Evaluasi yang dilakukan menggunakan metrik penilaian berupa *Accuracy*, *Precision*, *Recall*, dan *F1-Score* serta *FLOPs*, dan waktu inferensi guna mengetahui optimal dan efisien dalam komputasi dalam tingkat kematangan buah jengkol, sebagaimana dipengujian pada penelitian ini rangkum pada Tabel 3.

Tabel 3. Skenario Pengujian

No	Arsitektur	BatchSize	Learning Rate	Weight Decay	Epoch
1	<i>MobileNetV3-Small</i>	16	0.00005	0.0001	30
2	<i>MobileNetV3-Small</i>	32	0.00005	0.0001	30
3	<i>MobileNetV3-Large</i>	16	0.00005	0.0001	30
4	<i>MobileNetV3-Large</i>	32	0.00005	0.0001	30

4.2. Hasil Pengujian

Hasil pengujian pada penelitian ini digunakan untuk mengavluasi kinerja model *MobileNetV3-Small* dan *MobileNetV3-Large* yang dimana membandingkan waktu inferasi untuk efisiensi komputasi dan

memebandingkan arsitektur *MobileNetV3-Small* dan *Large* untuk menghasilkan ketepatan dalam menentukan tingkat kematangan buah pada jengkol. Evaluasi yang di lakukan dapat dilihat pada Tabel 4 dan Tabel 5.

Tabel 4. Hasil Evaluasi 1

No	Arsitektur	Batch Size	Accuracy	Precision	Recall	F1-Score
1	<i>MobileNetV3-Small</i>	16	92.65%	92.89%	92.65%	92.27%
2	<i>MobileNetV3-Small</i>	32	98.53%	98.61%	98.53%	98.53%
3	<i>MobileNetV3-Large</i>	16	94.85%	95.69%	94.85%	94.78%
4	<i>MobileNetV3-Large</i>	32	97.79%	97.96%	97.79%	97.79%

Tabel 5. Hasil Evaluasi 2

No	Arsitektur	Batch Size	Jumlah Parameter	FLOPs	Waktu Inferasi
1	<i>MobileNetV3-Small</i>	16	940,851	118,253,850	0.1414 sec
2	<i>MobileNetV3-Small</i>	32	940,851	118,253,850	0.0667 sec
3	<i>MobileNetV3-Large</i>	16	2,999	450,379,594	0.1316 sec
4	<i>MobileNetV3-Large</i>	32	2,999	450,379,594	0.1105 sec

Berdasarkan hasil evaluasi pada Tabel 4, kedua arsitektur *MobileNetV3* mampu mengklasifikasikan tingkat kematangan buah jengkol dengan performa yang sangat baik. Namun, *MobileNetV3-Small* dengan batch size 32 memberikan hasil terbaik dengan akurasi tertinggi sebesar 98,53%, serta nilai precision, recall, dan F1-score yang seimbang. Hal ini


menunjukkan bahwa model tersebut mampu mengenali tingkat kematangan buah jengkol secara konsisten pada seluruh kelas.

Dari sisi efisiensi komputasi dari Tabel 5, *MobileNetV3-Small* memiliki jumlah parameter dan *FLOPs* yang lebih rendah serta waktu inferensi yang lebih cepat dibandingkan *MobileNetV3-Large*.

Dengan demikian, *MobileNetV3-Small* tidak hanya unggul dalam akurasi, tetapi juga lebih efisien secara komputasi, sehingga lebih sesuai untuk diterapkan pada sistem dengan keterbatasan sumber daya maupun aplikasi real-time.

4.3. Analisis Kurva dan Confusion Matrik


Untuk memperkuat hasil evaluasi yang telah disajikan pada Tabel 4 dan Tabel 5, dilakukan analisis secara visual melalui kurva pelatihan serta confusion matrix pada data uji.



Gambar 3. Hasil Visualisasi Confusion Matrik

Gambar 3 menunjukkan hasil confusion matrix pada data uji. Berdasarkan visualisasi tersebut, mayoritas data pada setiap kelas tingkat kematangan buah jengkol berhasil diklasifikasikan dengan benar, yang ditunjukkan oleh dominasi nilai pada diagonal utama. Kesalahan klasifikasi hanya terjadi pada sebagian kecil data, terutama pada kelas yang memiliki kemiripan ciri visual, seperti antara kelas muda dan sedang. Namun, jumlah kesalahan tersebut relatif kecil dan tidak mempengaruhi performa model secara keseluruhan.

Hasil analisis *confusion matrix* ini sejalan dengan nilai *precision*, *recall*, dan *F1-score* yang tinggi pada Tabel 4, sehingga dapat disimpulkan bahwa model mampu membedakan setiap kelas tingkat kematangan buah jengkol secara konsisten dan akurat.



Gambar 4. Hasil Visualisasi Training dan validation Accuracy

Selanjutnya Gambar 4, yang menampilkan kurva training dan validation accuracy, terlihat bahwa model mengalami peningkatan akurasi yang stabil selama proses pelatihan. Selisih antara akurasi pelatihan dan validasi relatif kecil, yang menunjukkan bahwa model tidak mengalami *overfitting* secara signifikan serta mampu melakukan generalisasi dengan baik terhadap data uji. Kondisi ini mendukung nilai akurasi yang tinggi pada hasil evaluasi, khususnya pada skenario *MobileNetV3-Small* dengan *batch size 32*.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa arsitektur *MobileNetV3-Small* dan *MobileNetV3-Large* mampu mengklasifikasikan tingkat kematangan buah jengkol dengan performa yang sangat baik. Skenario terbaik diperoleh pada *MobileNetV3-Small* dengan *batch size 32*, yang menghasilkan akurasi tertinggi sebesar 98,53% serta nilai *precision*, *recall*, dan *F1-score* yang seimbang. Dari sisi efisiensi komputasi, *MobileNetV3-Small* memiliki jumlah parameter dan FLOPs yang lebih rendah serta waktu inferensi yang lebih cepat dibandingkan *MobileNetV3-Large*. Hal ini menunjukkan bahwa *MobileNetV3-Small* tidak hanya unggul dalam akurasi, tetapi juga lebih efisien dalam penggunaan sumber daya komputasi, sehingga lebih sesuai untuk diterapkan pada sistem dengan keterbatasan sumber daya maupun aplikasi *real-time*.

DAFTAR PUSTAKA

- [1] A. K. Nissa, Y. Yusniwati, and A. Zainal, "Eksplorasi dan Karakterisasi Morfologi Tanaman Jengkol (*Pithecellobium Jiringa*) di Kabupaten Agam Sumatera Barat," *Jagur J. Agroteknologi*, vol. 6, no. 1, pp. 9–16, 2024, doi: 10.25077/jagur.6.1.9-16.2024.
- [2] M. Thressia and M. Mulyadi, "Teknologi Pengolahan Buah Jengkol Dan Pemasaran Bagi Masyarakat Di Desa Sido Makmur Kecamatan Sipora Utara Kabupaten Kepulauan Mentawai," *J. Hilirisasi IPTEKS*, vol. 5, no. 3, pp. 157–171, 2022, doi: 10.25077/jhi.v5i3.608.
- [3] H. Sanjaya, R. Kurniawan, and Rusdiyanto, "Pemanfaatan Pengenalan Citra Kematangan Jengkol Untuk Saran Masakan Menggunakan Metode Algoritma Deep Learning," *Bull. Comput. Sci. Res.*, vol. 4, no. 4, pp. 356–367, 2024, doi: 10.47065/bulletincsr.v4i4.358.
- [4] M. Rizzo, M. Marcuzzo, A. Zangari, A. Gasparetto, and A. Albarelli, "Fruit ripeness classification: A survey," *Artif. Intell. Agric.*, vol. 7, pp. 44–57, 2023, doi: 10.1016/j.iaia.2023.02.004.
- [5] R. Triyogi, R. Magdalena, and B. Hidayat, "Mendeteksi Kematangan Buah Kelapa Sawit Menggunakan Convolutional Neural Network Deep Learning," *J. Nas. SAINS dan Tek.*, vol. 1, no. 1, pp. 22–27, 2023, doi: 10.25124/jnst.v1i1.6732.
- [6] E. Prasiwinigrum and A. Lubis, "Classification of palm oil maturity using CNN (Convolution Neural Network) modelling ResNet-50," *Decode: Jurnal Pendidikan Teknologi Informasi*, vol. 4, no. 3, pp. 983–999, 2024, doi: 10.51454/decode.v4i3.822.
- [7] H. Sanjaya, R. Kurniawan, and Rusdiyanto, "Pemanfaatan Pengenalan Citra Kematangan Jengkol Untuk Saran Masakan Menggunakan Metode Algoritma Deep Learning," *Bull. Comput. Sci. Res.*, vol. 4, no. 4, pp. 356–367,

- 2024, doi: 10.47065/bulletincsr.v4i4.358.
- [8] Agus P., Akbarsyah N., F. M., and Andri A. W., "Classification of Jengkol (*Archidendron pauciflorum*) Varieties Using Deep Learning," *Proc. IEEE Int. Colloq. Signal Process. Its Appl. (CSPA)*, pp. 1–6, 2024, doi: 10.1109/CSPA60979.2024.10525630.
- [9] A. P. Wibawa, M. G. A. Purnama, M. F. Akbar, and F. A. Dwiyanto, "Metode-metode Klasifikasi," *Pros. Semin. Ilmu Komput. dan Teknol. Inf.*, vol. 3, no. 1, p. 134, 2021.
- [10] F. Reynaldi Valerian, M. Syarief, and D. Abdul Fatah, "Klasifikasi Tingkat Obesitas Menggunakan Metode Gbm Dan Confusion Matrix," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 2, pp. 2242–2249, 2025, doi: 10.36040/jati.v9i2.13062.
- [11] T. Cahyanto *et al.*, "Kajian Etnobotani Tanaman Jengkol (*Pithecellobium jiringa*) di Desa Cimanggu Kecamatan Cibeber Kabupaten Cianjur," *Semin. Nas. Perhimpun. Masy. Etnobiologi Indones.*, vol. 1, pp. 186–189, 2020.
- [12] Y. Yuhandri, A. Ramadhanu, and H. Syahputra, "Pengenalan Teknologi Pengolahan Citra Digital (Digital Image Processing) Untuk Santri Di Rahmatan Lil'Alamin International Islamic Boarding School," *Community Dev. J. J. Pengabd. Masy.*, vol. 3, no. 2, pp. 1239–1244, 2022, doi: 10.31004/cdj.v3i2.5868.
- [13] Aminatus Syarifah, Aditya Akbar Riadi, and Arief Susanto3, "Klasifikasi Tingkat Kematangan Jambu Bol Berbasis Pengolahan," *JIMP J. Inform. Merdeka Pasuruan*, vol. 7, no. 1, pp. 27–35, 2022.
- [14] I. Nihayatul Husna, M. Ulum, A. Kurniawan Saputro, D. Tri Laksono, D. Neipa Purnamasari, and H. Haryanto, "Rancang Bangun Sistem Deteksi Dan Perhitungan Jumlah Orang Menggunakan Metode Convolutional Neural Network (CNN)," *Semin. Nas. Fortei Reg.*, vol. 7, pp. 3–8, 2021.
- [15] M. R. Alwanda, R. P. K. Ramadhan, and D. Alamsyah, "Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle," *J. Algoritm.*, vol. 1, no. 1, pp. 45–56, 2020, doi: 10.35957/algoritme.v1i1.434.
- [16] A. N. Dhaifullah, N. Yudistira, and W. F. Mahmudy, "Klasifikasi Emosi Manusia pada Citra Digital dengan MobileNetV3 dan Spatial Transformer," vol. 9, no. 10, pp. 1–10, 2025.
- [17] Abdul Jalil Rozaqi, M. R. Arief, and A. Sunyoto, "Implementation of Transfer Learning in the Convolutional Neural Network Algorithm for Identification of Potato Leaf Disease," *Procedia Eng. Life Sci.*, vol. 1, no. 1, 2021, doi: 10.21070/pels.v1i1.820.
- [18] N. S. Mahajaya, P. D. W. Ayu, and R. R. Huizen, "Pengaruh optimizer adam, adamw, sgd, dan lamb terhadap model vision transformer pada klasifikasi penyakit paru-paru," *Spinter 2024*, vol. 1, no. 2, pp. 818–823, 2024.