

# Rancang Bangun Alat Klasifikasi Buah Mangga Karbitan menggunakan CNN berbasis Android

## *Design and Development of Mango Ripeness Classification Tool using CNN Android-based Platform*

<sup>1</sup>Zaldy Gumilang\*, <sup>2</sup>Ahmad Taqwa, <sup>3</sup>Irma Salamah

<sup>1,2,3</sup>Teknik Telekomunikasi, Teknik Elektro, Politeknik Negeri Sriwijaya

<sup>1,2,3</sup>Jalan Sriwijaya Negara, Bukit Besar, Ilir barat 1, Kota Palembang

\*e-mail: [zaldygumilangmursalin@gmail.com](mailto:zaldygumilangmursalin@gmail.com)

(received: 28 June 2024, revised: 30 June 2024, accepted: 15 July 2024)

### Abstrak

Metode pematangan buatan menggunakan kalsium karbida (karbit) yang seringkali meninggalkan residu berbahaya pada buah mangga. Penelitian ini merancang alat klasifikasi buah mangga karbitan dan tidak karbitan menggunakan metode *InceptionV3 Convolutional Neural Network* berbasis Android. Dataset citra buah mangga terdiri dari 1622 gambar (881 gambar mangga karbitan dan 811 gambar buah mangga tidak karbitan) digunakan untuk melatih dan menguji model. Proses pengujian dilakukan dengan mengimplementasikan model pada Raspberry Pi B+ yang terhubung dengan camera pi untuk mengambil gambar mangga pada jarak 30 cm. Hasil penelitian penunjukan bahwa model CNN yang dikembangkan mencapai akurasi rata-rata 94,4% dalam mengklasifikasikan buah mangga karbitan dan tidak karbitan. Hasil ini menunjukkan bahwa alat klasifikasi yang dirancang dapat memberikan manfaat signifikan bagi petan, pedagang, dan konsumen dalam memastikan kualitas yang dipasarkan.

**Kata kunci:** buah mangga, convolutional neural network, inceptionV3, raspberry Pi B+, android

### Abstract

Artificial ripening methods use calcium carbide (carbide) which often leaves harmful residues on the mango fruit. This research designs a classification tool for carbide and non-carbide mango fruit using the Android-based *InceptionV3 Convolutional Neural Network* method. The mango fruit image dataset consists of 1622 images (881 images of carbide mangoes and 811 images of non-carbide mangoes) used to train and test the model. The testing process is done by implementing the model on a Raspberry Pi B+ connected to a camera pi to take pictures of mangoes at a distance of 30 cm. The results showed that the CNN model developed achieved an average accuracy of 94.4% in classifying carbide and non-carbide mangoes. This result shows that the classification tool designed can provide significant benefits for farmers, traders, and consumers in ensuring marketed quality.

**Keywords:** mango fruit, convolutional neural network, inceptionV3, raspberry Pi B+, android

## 1 Pendahuluan

Buah-buahan berdasarkan laju respirasi dapat dikategorikan menjadi dua jenis, yaitu buah klimaterik dan buah non-klimaterik. Buah klimaterik, seperti mangga, mengalami peningkatan produksi etilen dan laju respirasi saat pematangan. Sebaliknya buah non-klimaterik seperti jeruk, tidak menunjukkan kenaikan signifikan pada kadar etilen dan laju respirasi setelah dipanen [1].

Pada buah klimaterik seperti mangga, gas etilen alami dihasilkan selama proses pematangan. Untuk meminimalkan kerusakan selama pengiriman, mangga sering dipetik sebelum matang. Di tempat tujuan, proses pematangan buatan diperlukan agar buah mangga siapmdijual di pasar. Proses ini memerlukan gas etilen dan ruang khusus, yang sering seringkali mahal, sehingga para pedagang menggunakan metode pematangan yang lebih ekonomis [2].

Salah satu zat yang sering digunakan untuk mempercepat pematangan adalah kalsium karbida (karbit) yang relatif murah dan menjadi pilihan utama petani dan pedagang. Karbit menghasilkan gas

yang mempercepat kematangan buah dalam waktu 2x24 jam, namun dapat meninggalkan residu berbahaya pada kulit dan daging buah jika tertelan [3].

Seiring kemajuan teknologi, berbagai solusi inovatif telah dikembangkan untuk mengatasi masalah tersebut. Kecerdasan buatan atau Artificial Intelligence, adalah teknologi yang banyak digunakan yang memungkinkan komputer meniru perilaku manusia dan belajar dari pengalaman manusia. [4].

Metode *deep learning*, khususnya *Convolutional Neural Network* (CNN), telah diterapkan dalam berbagai bidang termasuk klasifikasi citra gambar. CNN dirancang untuk memproses data dua dimensi seperti gambar, dan telah terbukti efektif dalam berbagai aplikasi klasifikasi [5] [6].

Penelitian terdahulu menunjukkan bahwa CNN mampu mencapai akurasi tinggi dalam identifikasi kematangan buah, seperti pepaya dengan akurasi 97% [7], serta klasifikasi jenis kendaraan dengan akurasi hingga 94,4% pada tahap penelitian [8]. Meski begitu, belum ada penelitian yang secara khusus fokus pada klasifikasi buah mangga karbitan dan tidak karbitan menggunakan algoritma CNN.

Tujuan penelitian ini adalah pengembangan alat klasifikasi buah mangga karbitan dan tidak karbitan menggunakan algoritma *Convolutional Neural Network* berbasis *android*. Alat ini diharapkan dapat meningkatkan kualitas dan keamanan buah mangga yang dihasilkan. Memberikan manfaat besar bagi petani, pedagang, dan konsumen, serta menjadi solusi teknologi yang praktis dan efisien dalam proses klasifikasi buah mangga karbitan dan tidak karbitan.

## 2 Tinjauan Literatur

Beberapa penelitian terkait dengan topik ini telah dilakukan, baik yang memiliki kesamaan dalam metode, arsitektur, maupun objek penelitian. Metode *Convolutional Neural Network* (CNN) dan mikrokontroler ESP32 digunakan dalam penelitian ini untuk mengidentifikasi kematangan buah nanas. Peneliti menggunakan sistem ini dengan kamera ESP32 untuk mengambil gambar nanas yang kemudian diproses oleh mikrokontroler dengan data dari server Python. Sensor ultrasonik mengaktifkan kamera secara otomatis saat mendeteksi objek. Gambar yang diambil digunakan sebagai input untuk model CNN yang mengklasifikasikan kematangan buah berdasarkan warna kulitnya, dengan hasil ditampilkan pada LCD. Sistem ini mencapai akurasi rata-rata 83,33%, dengan akurasi tertinggi 86% dan terendah 80% [9].

Selain klasifikasi kematangan buah nanas, ada sebuah penelitian yang bertujuan untuk mengklasifikasikan buah mangga Badami berdasarkan tingkat kematangan menggunakan teknik CNN pada gambar. Mangga Badami, yang dikenal sangat manis dan kaya vitamin A dan C, memiliki berbagai variasi kematangan yang sulit ditentukan secara konvensional. Sistem yang dikembangkan dalam penelitian ini menggunakan 204 citra mangga, dengan 25 gambar sebagai data pengujian dan 179 digunakan untuk data pelatihan. Model CNN yang dihasilkan mampu mencapai akurasi 97,2% dalam mendeteksi kematangan mangga [10]. Penelitian lain yang menggunakan teknik yang sama juga menggunakan CNN untuk mengklasifikasikan sampah logam dan plastik berbasis Raspberry Pi. Penelitian ini menanggapi rendahnya tingkat daur ulang sampah rumah tangga di Indonesia (1,2 persen) dengan menciptakan sistem yang menggunakan kamera Pi dan Raspberry Pi untuk mengklasifikasikan sampah bekas minuman kemasan. Model CNN yang dilatih mencapai akurasi 98,66% dalam pelatihan dan 81,39% dalam pengujian [11].

Metode CNN juga digunakan untuk klasifikasi hama pada tanaman padi. Studi ini bertujuan untuk mengatasi masalah *overfitting* dengan menggunakan tiga pembagian data pelatihan dan pengujian pelatihan, data pertama dibagi menjadi 70% dan 30%, data kedua di bagi menjadi 80% dan 20% dan data terakhir dibagi menjadi 90% dan 10 serta berbagai parameter. Hasil penelitian menunjukkan bahwa pembagian data 90% dan 10% menghasilkan akurasi training terbaik dengan 83,02% dan 78,30%, dan 81,13%, serta akurasi pengujian sebesar 69,33%, 77,33%, 76% [12]. Penelitian lain mengulas penggunaan Metode *Faster-RCNN* pada Raspberry Pi 4B untuk Sistem Deteksi dan Klasifikasi Jenis Kendaraan berbasis citra gambar. Penelitian ini bertujuan untuk mengatasi masalah lalu lintas yang disebabkan oleh kendaraan yang melampaui kapasitas jalan, yang berpotensi menyebabkan kecelakaan. Sistem ini memberikan notifikasi kepada pengemudi tentang jumlah dan jenis kendaraan di depannya, meningkatkan kesadaran dan kehati-hatian dalam berkendara. Dengan menggunakan teknologi CNN, sistem ini mencapai akurasi sebesar 90,25% dengan waktu komputasi rata-rata 7,638 detik per gambar di Raspberry Pi 4B [13]. Penelitian terkait

aplikasi CNN dalam klasifikasi citra buah pir menggunakan dataset Fruit-360 untuk mengembangkan model CNN yang dapat membedakan antara buah pir Williams dan Forelle. CNN dirancang dengan lapisan *konvolusi*, *pooling*, dan *fully connected*. Proses pelatihan dilakukan dengan 15 *epoch*, mencapai akurasi 100% pada data training dan validasi. Pengujian pada 100 citra baru memberikan akurasi 98% dalam mengklasifikasikan jenis buah pir [14]. Penelitian lain menggunakan CNN untuk mengklasifikasikan jenis mangga berdasarkan bentuk dan tekstur daun. CNN efisien dalam tahapan pemrosesan citra, dengan waktu rata-rata 2 detik dan tingkat akurasi yang tinggi [15].

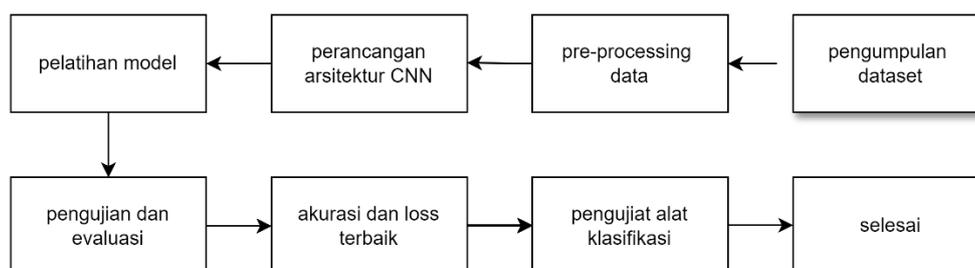
Setelah mempelajari penelitian-penelitian terkait, khususnya tentang klasifikasi buah dan sayuran, pada penelitian ini akan dirancang alat klasifikasi buah mangga karbitan dan tidak karbitan menggunakan metode CNN, dengan memanfaatkan inputan citra buah mangga untuk menghasilkan keluaran klasifikasi yang akurat.

### 3 Metode Penelitian

Tujuan utama dari penelitian ini adalah untuk menghasilkan model yang kuat untuk klasifikasi buah mangga dari dataset gambar 2 jenis mangga yaitu karbitan dan tidak karbitan dengan menggunakan arsitektur *InceptionV3* berbasis CNN. *InceptionV3* terkenal dengan prediksinya yang memiliki akurasi tinggi; oleh karena itu, kami menggunakan algoritma *supervised learning* ini untuk membuat pengklasifikasi biner yang dapat memetakan data gambar mangga ke dalam dua kategori. Langkah-langkah berikut diambil untuk membuat model. Pertama, kami memperoleh dataset dan menambah gambar. Kemudian, kami menyesuaikan model dengan data latih dan mendapatkan skor kinerja dengan akurasi dan *loss*. Hasil model akan diuji coba dengan alat pendeteksian buah karbit menggunakan *raspberry Pi 4 B+* yang terkoneksi dengan *camera pi OV5647* dalam jarak 30cm terhadap objek buah mangga yang dimonitoring *di android*.

Kerangka yang digunakan dalam pengembangan dan pengujian model Convolutional Neural Network (CNN) ditunjukkan pada Gambar 1. Tahap awal melibatkan pengumpulan data yang relevan dengan masalah klasifikasi yang ingin diselesaikan. Dataset ini akan menjadi dasar untuk melatih dan menguji model CNN. Data yang telah dikumpulkan perlu diproses agar sesuai dengan kebutuhan model CNN. Langkah ini meliputi normalisasi, augmentasi, dan transformasi lainnya untuk meningkatkan kualitas dan keberagaman data. Tahap perancangan struktur jaringan CNN menentukan jumlah lapisan, jenis lapisan (*convolutional*, *pooling*, *fully connected*), fungsi aktivasi, dan parameter lainnya. Pemilihan arsitektur yang tepat dapat mempengaruhi kinerja model secara signifikan. Model CNN yang telah dirancang dilatih menggunakan dataset yang telah diproses. Selama pelatihan, model belajar untuk mengenali pola-pola dalam data dan menyesuaikan bobotnya agar dapat melakukan klasifikasi dengan akurat.

Setelah melakukan pelatihan, model dievaluasi menggunakan data pengujian yang belum pernah dilihat sebelumnya. Evaluasi ini mengukur kinerja model dalam hal akurasi, presisi, recall, atau metrik lainnya yang relevan dengan tugas klasifikasi. Hasil evaluasi memberikan informasi tentang akurasi dan *loss* (tingkat kesalahan) model. Peneliti mencari kombinasi parameter yang menghasilkan akurasi terbaik dan *loss* terendah. Model CNN yang telah diuji dan dievaluasi kemudian diimplementasikan dalam sebuah alat klasifikasi. Data baru yang belum pernah dilihat sebelumnya dapat diklasifikasikan dengan alat ini.



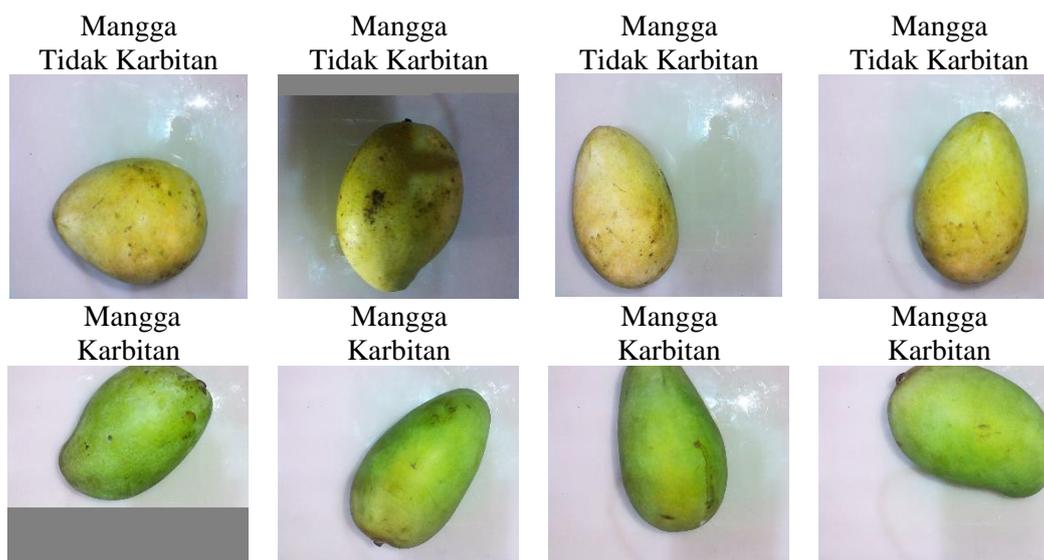
Gambar 1. Kerangka penelitian

### 3.1. Pengumpulan Dataset

Proses pengumpulan dataset dilakukan dengan mengambil citra buah mangga. Dataset tersebut disusun berdasarkan dua label klasifikasi, yaitu mangga karbitan dan mangga non-karbitan, dengan total 1622 gambar, masing-masing terdiri dari 811 gambar untuk setiap kategori. Citra diambil dengan resolusi 1944 x 1944 piksel. seluruh dataset diambil pada ketinggian 30 cm menggunakan smartphone dan *camera pi* untuk memastikan perbedaan ukuran terlihat signifikan. Tabel 1 dan Gambar 2 menunjukkan contoh data latih.

**Tabel 1. Dataset buah mangga**

Dataset	Samples
Data Training	1467 (90%)
Data Validiation	162 (10%)



**Gambar 2. Sample dataset buah mangga**

#### 3.1.1 Data Pre-Processing

Pada tahap ini, kami menambah gambar dalam set pelatihan dan validasi dengan melakukan proses berikut: mengubah skala, rotasi, pergeseran lebar dan tinggi, geser, pembesaran, dan membalik. Selama proses augmentasi, dataset dibagi menjadi pelatihan dan validasi. Disini, kami menetapkan mode pengisian sebagai pengisian terdekat, ukuran batch sebagai 16 dan ukuran target gambar sebagai 224x224 piksel. Setelah itu, kami mengkodekan kelas-kelas dengan indeks untuk menunjukkan label setiap jenis gambar buah mangga.

### 3.2. Klasifikasi

Metode klasifikasi menempatkan benda dalam kelompok tertentu berdasarkan karakteristik yang dimilikinya. Dalam proses ini, klasifikasi dapat dilakukan dengan berbagai cara, seperti secara manual atau dengan teknologi. Klasifikasi manual melibatkan klasifikasi yang dilakukan oleh manusia tanpa bantuan algoritma kecerdasan buatan, sedangkan klasifikasi melalui teknologi menggunakan banyak algoritma kecerdasan buatan. Pada penelitian ini memakai algoritma InceptionV3 berbasis CNN [16].

#### 3.2.1. InceptionV3

Metode InceptionV3, yang dikembangkan pada tahun 2015 oleh tim peneliti *Google*, merupakan salah satu arsitektur jaringan saraf konvolusi (CNN). InceptionV3 terdapat 4 *block architecture* yang terdiri dari 5x *inception modul A*, 4x *inception modul B*, 2x *inception modul*, dan *grid reduction*. Tujuan utama *InceptionV3* adalah meningkatkan efisiensi komputasi dan performa model dalam pengenalan citra [17].

### 3.2.2. CNN

Convolutional Neural Network (CNN) adalah jenis arsitektur neural network yang sering digunakan pada data gambar karena menggunakan algoritma deep learning untuk mengolah data citra gambar dengan mengidentifikasi bentuk dan warna yang relevan dengan berbagai elemen yang ada dalam gambar, sehingga CNN dapat membedakan objek satu dengan lainnya. Pembelajaran fitur (feature learning) dan klasifikasi adalah dua lapisan utama CNN [18].

#### 3.2.2.1 Feature Learning

Tahap ini merupakan proses pengkodean citra menjadi fitur-fitur yang mewakilinya. Proses ini terdiri dari beberapa lapisan yang bekerja sama untuk memperoleh karakteristik citra, yaitu lapisan konvolusi, fungsi aktivasi, dan pooling. Lapisan pertama adalah lapisan konvolusi, di mana proses penyaringan dengan konsep *sliding window* dilakukan menggunakan filter dengan ukuran dan nilai yang telah ditentukan. Filter ini bertindak sebagai pengali, di mana perkalian titik dilakukan pada setiap intensitas area *matriks* tempat *filter* berada. *Matriks* yang dihasilkan kemudian diteruskan ke lapisan berikutnya untuk perhitungan lebih lanjut. Pelatihan model menggunakan filter dalam lapisan ini dan *back-propagation* dari parameter model. Selanjutnya adalah fungsi aktivasi, di mana ReLU adalah salah satu yang paling dikenal. ReLU memetakan semua bilangan *non-positif* menjadi nol, sementara sisanya linier. Lapisan pooling sangat penting dalam mengurangi dimensi matriks konvolusi yang dihasilkan. Proses ini memungkinkan perhitungan lebih cepat karena membutuhkan jumlah parameter yang lebih sedikit untuk diperbarui, sehingga mengurangi risiko *overfitting*. Ada dua jenis utama lapisan pooling: *max pooling* dan *average pooling*. *Average pooling* menghitung nilai rata-rata dari semua entri dalam jangkauan filter matriks, sedangkan *Max pooling* mengambil nilai maksimum dari setiap input matriks. [19].

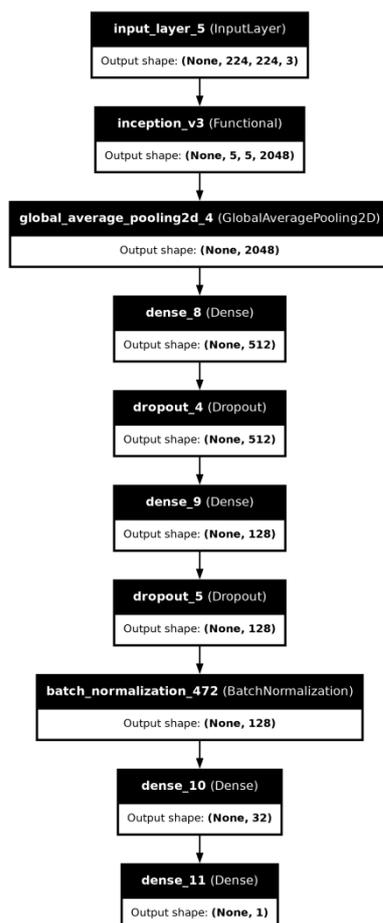
#### 3.2.2.2 Klasifikasi

Klasifikasi setiap neuron yang telah diekstraksi dalam pembelajaran fitur dilakukan melalui beberapa lapisan, yaitu lapisan input, lapisan tersembunyi dengan regularisasi *dropout*, dan lapisan keluaran. Lapisan input berupa *array* satu dimensi yang diratakan dari *matriks* peta fitur yang telah dihitung sebelumnya, dengan setiap *neuron* di lapisan ini terhubung ke *neuron* di lapisan tersembunyi. Lapisan tersembunyi menggunakan perceptron multi-lapis (MLP) untuk mengubah dimensi data agar dapat diklasifikasikan secara linier melalui propagasi maju dan mundur. *Dropout* adalah teknik regularisasi yang efektif untuk menonaktifkan neuron di lapisan tersembunyi, membatasi kontribusi neuron tertentu terhadap keluaran, mengurangi risiko *overfitting* yang umum dalam CNN, dan memungkinkan komputasi yang lebih efisien. Lapisan keluaran adalah lapisan akhir di mana setiap input diproses melalui fungsi aktivasi, biasanya *softmax*, untuk menghasilkan keluaran probabilistik antara 0 dan 1.

### 3.2.3. Modelling

Pada model penelitian ini terdiri dari beberapa parameter, yaitu lapisan *inceptionv3*, 1 lapisan *max global pooling average2D*, 1 lapisan *flatten*, 2 lapisan *dropout*, dan 3 lapisan *dense*. Lapisan *dense* pertama berfungsi sebagai lapisan tersembunyi, sedangkan lapisan *dense* kedua berfungsi sebagai lapisan keluaran, yang menghasilkan keluaran berupa angka antara 0-1

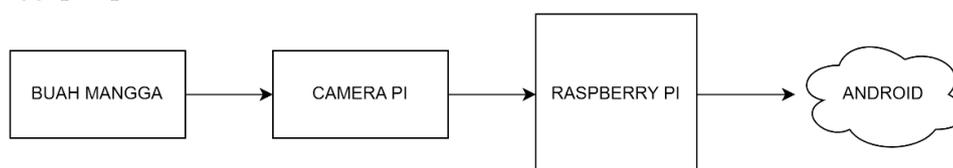
Arsitektur model klasifikasi mangga karbit ditunjukkan pada Gambar 3 dibawah ini. Model dibangun di atas arsitektur Inception V3 dan menyertakan beberapa lapisan tambahan untuk pemrosesan dan klasifikasi fitur. Layer awal model menerima gambar input dengan ukuran tetap 224x224 piksel dan 3 saluran warna. Layer awal akan meneruskan input pada lapisan Inception V3 dan menghasilkan dimensi 5x 5x2048, yang menunjukkan fitur ekstraksi dari gambar input. Layer global average pooling2d akan merata-ratakan fitur spasial dari output Inception V3 di setiap saluran, menghasilkan vektor fitur 1D dengan 2048 elemen. Vektor tersebut akan diteruskan pada layer dense dengan tambahan layer dropout dan batch normalization. Layer akhir memakai aktivasi sigmoid untuk menentukan buah mangga karbit atau alami.



Gambar 3. Arsitektur model CNN klasifikasi mangga

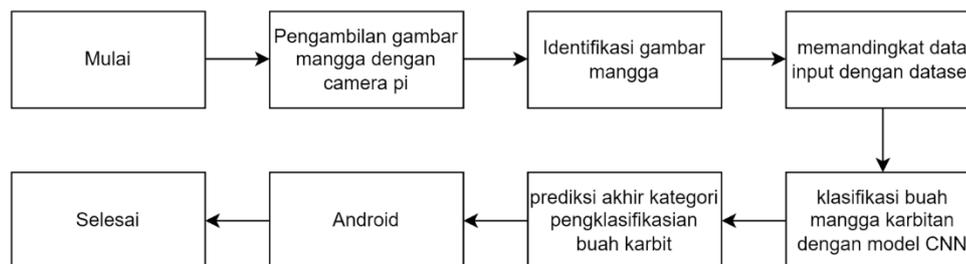
### 3.2.4. Sistematika Alat

Pada proses sistemasi alat diperlukannya perancangan perangkat keras (*hardware*) serta perangkat lunak (*software*) membutuhkan beberapa bantuan protokol komunikasi yang digunakan untuk menghubungkan antar keduanya agar sistem mampu berjalan dengan baik dan benar. Dalam proses penggabungan sistem keseluruhan alat dimulai dari saat menghidupkan alat. Alat akan melakukan proses booting untuk masuk ke sistem operasi berbasis linux. Kode *python* akan dieksekusi oleh service linux setelah melakukan booting secara otomatis dan menjalankan software. Software akan menjalankan *Flask* untuk melayani API hasil prediksi dan tensorflow sebagai library untuk memprediksi citra. *Software* akan diekspos menggunakan *avahi* dengan *domain hostname, local* sehingga dapat diakses pada *localhost*. Raspberry Pi yang berfungsi sebagai mikrokontroler akan menerima tanggapan perintah dari API.



Gambar 3. Blog diagram perangkat keras (hardware)

Pi camera akan mengambil foto buah mangga yang ada, kemudian foto tersebut dibandingkan dengan data set yang sudah diuji untuk menentukan apakah mangga tersebut termasuk dalam klasifikasi yang sama. Data yang diperoleh kemudian diproses oleh Raspberry Pi dan disimpan di server. Setelah itu, hasil deteksi ditampilkan dalam bentuk aplikasi Android, memungkinkan pengguna untuk memantau proses pengklasifikasian buah mangga secara langsung. Kategori hasil pengklasifikasian buah mangga terdiri dari dua jenis, yaitu buah mangga karbitan dan buah mangga tidak karbitan. Gambar 4 menunjukkan blok diagram perangkat keras.



**Gambar 4. Blog diagram perangkat lunak (software)**

Perangkat lunak untuk pendeteksian buah mangga karbitan akan diimplementasikan pada raspberry pi 4 B+ dengan menggunakan bahasa pemrograman *python* dan *library tensorflow*. Perangkat lunak tersebut berfungsi untuk mengambil gambar melalui kamera yang terkoneksi pada raspberry pi, mengklasifikasikan gambar merupakan mangga karbit atau non karbit dan mengirimkan hasil klasifikasi beserta gambar melalui jaringan *localhost* via kabel LAN atau Wi-Fi. Hasil pendeteksian tersebut akan diterima pada aplikasi android menggunakan metode WebRTC pada jaringan *localhost*.

Setelah alat dinyalakan, camera pi akan secara otomatis menangkap citra untuk dilakukan prediksi buah mangga karbit atau tidak. Model yang telah dibuat yang disimpan di raspberry Pi akan dijalankan sehingga didapat hasil klasifikasi dari citra mangga tersebut. Hasil deteksi akan dikirimkan ke akan dikirimkan ke aplikasi android melalui protokol HTTPS. Blok diagram perangkat lunak ditunjukkan pada Gambar 4.

#### 4 Hasil dan Pembahasan

Dalam penelitian ini, perangkat komputasi yang digunakan adalah GPU Nvidia P100. Pengaturan *epoch* yang digunakan adalah 100 selama fase pelatihan dan pengujian. Untuk mengoptimalkan perhitungan, kami menggunakan kriteria penghentian awal dan mengurangi laju pembelajaran pada dataran tinggi untuk pemanggilan kembali dengan parameter pada *library tensorflow*, seperti yang tercantum pada Tabel 2

**Tabel 2. Parameter callbacks**

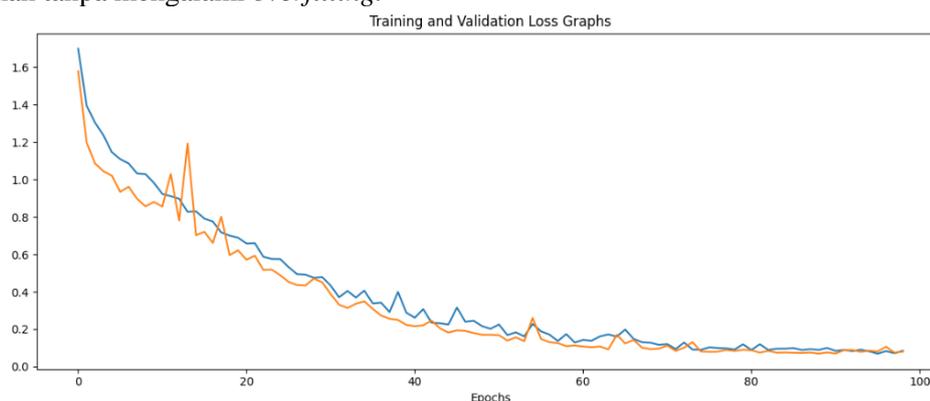
Callbacks	Parameter	Value
<b>Early Stopping</b>	min_delta	0.01
	patience	10
	restore_best_weights	True
<b>Reduce Learning Rate On Plateau</b>	factor	0.1
	patience	5
	min_delta	0.01
<b>ModelCheckpoint</b>	monitor	val_loss
	save_best_only	True
	mode	min

Penelitian ini juga memvariasikan jenis *optimizer* dan memasang kernel regulizer L2 yang pada setiap *layer Convolution* dengan ukuran yang sama untuk mendapatkan hasil terbaik berdasarkan akurasi model yang diterapkan pada alat. Tabel di bawah ini memberikan rincian pada hasil yang diperoleh dengan pengaturan *optimizer* yang berbeda, dan Gambar 4 dan 5 menunjukkan visualisasi dari metrik untuk setiap konfigurasi.

**Tabel 3. Hasil eksperimen**

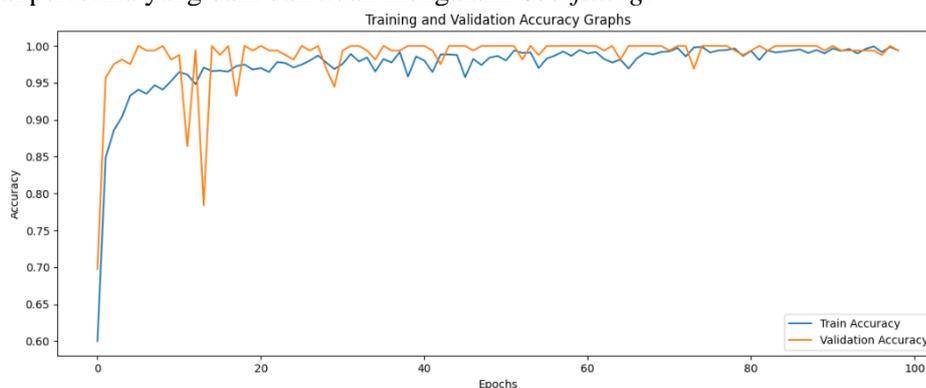
Model	Batch	Optimizer	Train Loss	Train Accuracy	Validation Loss	Validation Accuracy
1	8	Adam	0.0896	0.9945	0.0692	1.0000
2	16	Adam	0.0383	1.0000	0.0392	1.0000
3	8	RMSprop	0.0315	0.9945	0.0195	1.0000
4	16	RMSprop	0.3972	0.8753	0.0923	0.9938
5	8	SGD	0.3482	0.9400	0.1888	1.0000
6	16	SGD	0.4036	0.9945	0.4281	0.9753
7	8	Adamax	0.2350	0.9925	0.2155	1.0000
8	16	Adamax	0.0323	1.0000	0.0331	1.0000

Berdasarkan hasil yang ditunjukkan dalam Tabel 3, konfigurasi yang paling optimal berdasarkan akurasi dan loss adalah model 8 dengan pengoptimal *Adamax* dengan *16 training batch* mendapatkan akurasi 100% dengan *loss train* dan validasi yang kecil dan menurun secara bertahap tidak jauh berbeda seperti Gambar 5. Hal ini menandakan model dapat mempelajari pola mengenai buah mangga karbit atau bukan tanpa mengalami *overfitting*.



**Gambar 5. Graph loss model 8**

Grafik akurasi dari model machine learning selama proses pelatihan (*train accuracy*) dan validasi (*validation accuracy*) pada setiap epoch seperti Gambar 6. Sumbu X menunjukkan epoch, yaitu satu siklus lengkap di mana seluruh dataset telah melewati proses pelatihan model serta Sumbu Y menunjukkan akurasi. Garis biru akurasi pelatihan, ini cenderung meningkat seiring bertambahnya *epoch*, karena model belajar mengenali pola dalam data. Akurasi validasi diukur dengan garis jingga, yang menunjukkan seberapa baik model dapat digeneralisasi ke data baru. Terjadi peningkatan akurasi yang signifikan baik pada data pelatihan maupun validasi. Ini menunjukkan model belajar dengan cepat. Akurasi pelatihan dan validasi cenderung stabil di sekitar 99%. Ini menunjukkan model telah mencapai performa yang baik dan tidak mengalami *overfitting*.



**Gambar 6. Graph accuracy model 8**

Setelah memperoleh model CNN yang sangat akurat, model tersebut akan diterapkan pada alat pengklasifikasi buah mangga karbitan dan tidak karbitan. Proses pengujian dilakukan menggunakan buah mangga asli dengan camera pi dan raspberry pi 4 B+ sebagai mikrokontroler untuk memprediksi

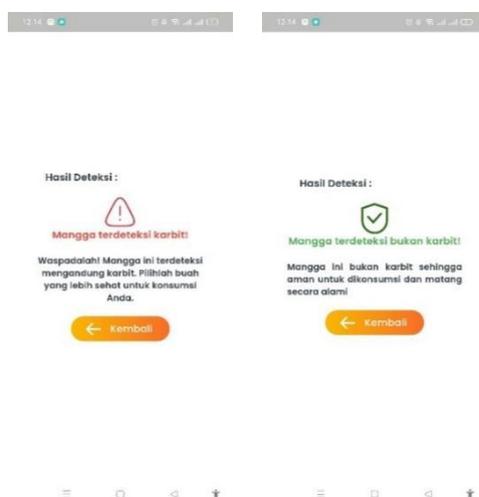
hasil klasifikasi. Hasil klasifikasi akan dikirimkan ke aplikasi Android sebagai sarana monitoring untuk pengujian lebih lanjut. Pengujian dilakukan sebanyak 9 kali untuk setiap kategori mangga karbitan dan mangga alami. Data hasil pengujian dapat dilihat pada Tabel 4 hasil testing.

**Tabel 4. Hasil testing**

Data Testing	Total	Prediksi Benar	Prediksi Salah	Akurasi
<b>Buah Mangga Karbitan</b>	09	08	01	0.888
<b>Buah Mangga Tidak Karbitan</b>	09	09	09	1
<b>Rata-rata akurasi</b>				0.944

Hasil klasifikasi untuk 18 data percobaan diperoleh berdasarkan hasil keseluruhan pengujian real-time. Hasil prediksi mangga menunjukkan akurasi pengujian yang cukup tinggi, yaitu 94.4%. Hal ini menunjukkan bahwa arsitektur CNN yang dirancang dengan *InceptionV3* mampu membedakan antara mangga karbitan dan bukan karbitan berdasarkan label yang diberikan. Dari hasil percobaan, akurasi setiap label dapat dihitung, dengan akurasi label karbitan sebesar 88.8% dan label bukan karbitan sebesar 100%.

Berikut tampilan aplikasi Android yang menunjukkan hasil klasifikasi data yang berhasil. Pada Gambar 7, ditunjukkan hasil deteksi buah mangga karbitan dan tidak karbitan, dengan inialisasi warna merah untuk mangga yang terdeteksi sebagai karbitan dan warna hijau untuk mangga yang terdeteksi sebagai bukan karbitan.



**Gambar 7. Tampilan hasil deteksi mangga karbitan dan tidak karbitan**

Alat pendeteksian mangga karbit menggunakan kotak akrilik bening dengan kamera di atasnya yang terhubung ke Raspberry Pi dirancang untuk memberikan solusi praktis dalam memverifikasi kualitas buah mangga. Kotak akrilik bening memungkinkan cahaya untuk masuk dan memberikan visibilitas yang jelas bagi kamera untuk mengambil gambar mangga di dalamnya. Kamera yang terpasang di bagian atas kotak ini terhubung ke Raspberry Pi, sebuah komputer mini yang mengontrol sistem pendeteksian seperti pada Gambar 8. Raspberry Pi menjalankan algoritma khusus yang mampu menganalisis gambar mangga dan menentukan apakah mangga tersebut telah dikarbit atau tidak, berdasarkan warna, tekstur, dan karakteristik lainnya yang terdeteksi dari gambar. Sistem ini dapat digunakan oleh pedagang dan konsumen untuk memastikan kualitas mangga yang lebih baik secara cepat dan efisien.



Gambar 8. Perangkat keras secara keseluruhan

## 5 Kesimpulan

Dapat disimpulkan bahwa konfigurasi yang paling optimal berdasarkan loss dan akurasi adalah pembuatan model CNN memakai InceptionV3 dengan pengoptimal Adamax dengan 16 batch pelatihan. Augmentasi dapat menjadi solusi pelatihan model dengan jumlah dataset yang relatif sedikit sehingga menghasilkan representasi dataset yang bervariasi *Dropout* dan *Regulizer l2* pada layer klasifikasi juga diperlukan untuk menangani overfitting yang terjadi pada saat pelatihan model. Pada penelitian selanjutnya, dapat digunakan algoritma lain untuk meningkatkan model ini dengan menggunakan arsitektur *Generative Adversarial Network (GAN)* dan *Graph Convolutional Network (GCN)*. Untuk menghasilkan akurasi yang lebih tinggi, kita dapat menggunakan jaringan syaraf tiruan dinamis dengan fitur-fitur tambahan yang dapat dikembangkan.

## Referensi

- [1] S. Sudarti, S. N. Laili, and N. A. Akriema, "Pengaruh Kematangan Buah Terhadap Massa Jenis Pisang Ambon," *GRAVITASI Jurnal Pendidikan Fisika dan Sains*, vol. 4, no. 2, pp. 10–16, Dec. 2021, doi: <https://doi.org/10.33059/gravitasi.jpfs.v4i02.4308>.
- [2] P. P. Wahyudi and B. Harsono, "Identifikasi Mangga Arumanis yang Dimatangkan dengan Kalsium Karbida (CaC<sub>2</sub>) Menggunakan Metode Spektroskopi," *Techné Jurnal Ilmiah Elektroteknika*, vol. 22, no. 1, pp. 143–156, Apr. 2023, doi: <https://doi.org/10.31358/techne.v22i1.368>.
- [3] M. A. Siahaan and D. G. R. A. Aruan, "Pengaruh Kalsium Karbida Terhadap Konsentrasi Vitamin C pada Buah Mangga Samosir (Mangifera Indica)," *Jurnal Analis Laboratorium Medik*, vol. 5, no. 2, Dec. 2020.
- [4] W. Puspitaningrum and S. Supatman, "Identifikasi Mangga Harum Manis Karbitan dan Tidak Karbitan Dengan Learning Vector Quantization," *Jurnal Multimedia & Artificial Intelligence*, vol. 2, no. 2, 2018.
- [5] L. Anggraini and Y. Yamasari, "Klasifikasi Citra Wajah Untuk Rentang Usia Menggunakan Metode *Artificial Neural Network*," *Journal of Informatics and Computer Science*, vol. 05, no. 02, 2023, doi: <https://doi.org/10.26740/jinacs.v5n02.p185-192>.
- [6] A. Jamhari, F. M. Wibowo, and W. A. Saputra, "Perancangan Sistem Pengenalan Wajah Secara Real-Time pada CCTV dengan Metode Eigenface," *Journal of Informatics, Information System, Software Engineering and Applications*, vol. 2, no. 2, pp. 20–32, 2020, doi: 10.20895/INISTA.V2I2.
- [7] B. Yanto, B. Baorudin, J. Jufri, and B. H. Hayadi, "Identifikasi Pola Aksara Arab Melayu dengan Jaringan Syaraf Tiruan Convolutional Neural Network (CNN)," *JSAI: Journal Scientific and Applied Informatics*, vol. 3, no. 3, pp. 106–114, 2020, doi: 10.36085.

- [8] B. Yanto, E. Rouza, L. Fimawahib, B. H. Hayadi, and R. R. Pratama, "Penerapan Algoritma *Deep Learning Convolutional Neural Network* dalam Menentukan Kematangan Buah Jeruk Manis Berdasarkan Citra Red Green Blue (RGB)," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 10, no. 1, pp. 59–66, 2023, doi: 10.25126/jtiik.2023105695.
- [9] Y. B. E. Purba, N. F. Saragih, A. P. Silalahi, S. Sitepu, and A. Gea, "Perancangan Alat Pendeteksi Kematangan Buah Nanas Dengan Menggunakan Mikrokontroler Dengan Metode *Convolutional Neural Network (CNN)*," *Jurnal Ilmiah Teknik Informatika*, vol. 2, no. 1, pp. 13–21, 2022, [Online]. Available: <http://ojs.fikom-methodist.net/index.php/METHOTIKA>
- [10] A. Arkadia, S. A. Damayanti, and D. S. Prasvita, "Klasifikasi Buah Mangga Badami Untuk Menentukan Tingkat Kematangan dengan Metode CNN," *Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya (SENAMIKA)*, vol. 2, no. 2, Sep. 2021.
- [11] A. A. Rahman, A. Fauzi, and J. Indra, "Klasifikasi Sampah Logam Dan Plastik Berbasis Raspberry Pi Dengan Metode Convolution Neural Network," *Scientific Student Journal for Information, Technology and Science*, vol. IV, no. 1, 2023.
- [12] S. Yuliany, A. Aradea, and A. N. Rachman, "Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN)," *Jurnal Buana Informatika*, vol. 13, no. 1, pp. 54–65, Apr. 2022, doi: <http://dx.doi.org/10.24002/jbi.v13i1.5022>.
- [13] M. T. Audina, F. Utamingrum, and D. Syaui, "Sistem Deteksi dan Klasifikasi Jenis Kendaraan berbasis Citra dengan menggunakan Metode Faster-RCNN pada Raspberry Pi 4B," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 5, no. 2, pp. 814–819, Feb. 2021, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [14] S. Juliansyah and A. D. Laksito, "Klasifikasi Citra Buah Pir Menggunakan *Convolutional Neural Networks*," *Jurnal Telekomunikasi dan Komputer*, vol. 11, no. 1, pp. 65–72, Apr. 2021, doi: 10.22441/incomtech.v10i2.10185.
- [15] D. Hidayat, "Klasifikasi Jenis Mangga Berdasarkan Bentuk dan Tekstur Daun Menggunakan Metode *Nalneural Network Convolution Nalneural Network (CNN)*," *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 5, no. 1, Jun. 2022.
- [16] A. P. Wibawa, M. G. A. Purnama, M. F. Akbar, and F. A. Dwiyanto, "Metode-Metode Klasifikasi," *Prosiding Seminar Ilmu Komputer dan Teknologi Informasi*, vol. 3, no. 1, 2018.
- [17] A. W. Kosman, Y. Wahyuningsih, and F. Mahendrasusila, "Pengujian Metode Inception V3 dalam Mengidentifikasi Penyakit Kanker Kulit," *Jurnal Teknologi Informatika dan Komputer*, vol. 10, no. 1, pp. 132–142, Mar. 2024, doi: 10.37012/jtik.v10i1.1940.
- [18] K. Azmi and S. Defit, "Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat," *Jurnal Untek*, vol. 16, no. 1, Jun. 2023.
- [19] R. B. M. A. A. Wijaya, D. N. A. Putri, and D. R. Fudholi, "Smart GreenGrocer: Automatic Vegetable Type Classification Using the CNN Algorithm," *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 17, no. 3, p. 271, Jul. 2023, doi: 10.22146/ijccs.82377.