

Deteksi Image Berbasis Mobile

Mealdi Arwintoro¹, Shania Dila Vanesa²

^{1,2}Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri
Aldiarwin25@gmail.com²shaniashania1717@gmail.com

Abstrak – Kemajuan teknologi mobile membuka peluang baru dalam pengolahan citra secara cepat dan efisien. Penelitian ini bertujuan untuk mengembangkan sistem deteksi citra berbasis mobile yang dapat diimplementasikan pada perangkat pintar dengan keterbatasan sumber daya. Metode yang digunakan melibatkan algoritma deep learning dengan model arsitektur ringan yang dioptimalkan untuk platform mobile. Dataset citra yang digunakan terdiri dari berbagai kategori, dengan proses pelabelan untuk pelatihan dan validasi model. Hasil pengujian menunjukkan bahwa sistem yang dikembangkan mampu mendeteksi objek dengan tingkat akurasi rata-rata 92%, waktu respon kurang dari 1 detik per citra, dan kompatibilitas tinggi pada perangkat dengan spesifikasi menengah ke bawah. Temuan ini menegaskan bahwa deteksi citra berbasis mobile dapat memberikan solusi praktis untuk berbagai aplikasi, termasuk keamanan, pendidikan, dan hiburan. Penelitian ini memberikan kontribusi signifikan dalam memperluas penerapan teknologi deteksi citra di lingkungan mobile, terutama untuk memenuhi kebutuhan pengguna akan efisiensi dan portabilitas.

Kata Kunci — algoritma,citra,deteksi,mobile.

I. PENDAHULUAN

Teknologi berbasis mobile telah berkembang pesat dan memberikan dampak yang signifikan dalam berbagai aspek kehidupan manusia. Salah satu bidang yang banyak terpengaruh oleh perkembangan ini adalah pengolahan data visual. Perangkat mobile kini tidak hanya berfungsi sebagai alat komunikasi, tetapi juga sebagai platform yang mendukung berbagai aplikasi berbasis citra. Popularitas perangkat ini didorong oleh keunggulannya, seperti portabilitas, kemudahan akses, dan kemampuan untuk menjalankan aplikasi dengan fleksibilitas tinggi. Namun, pengolahan citra pada perangkat mobile menghadapi berbagai tantangan teknis yang signifikan. Tantangan utama yang sering ditemui mencakup keterbatasan daya komputasi, kapasitas memori, serta efisiensi energi. Hal ini menjadi kendala khusus, terutama ketika perangkat harus mendukung aplikasi berat yang membutuhkan pengolahan citra secara real-time [1]. Oleh karena itu, pengembangan teknologi deteksi citra yang efisien, cepat, dan kompatibel dengan perangkat mobile menjadi kebutuhan yang mendesak. Salah satu solusi utama dalam pengolahan citra adalah penerapan algoritma deep learning, khususnya Convolutional Neural Networks (CNN). CNN telah terbukti sebagai alat yang sangat efektif untuk mengenali pola dan mengklasifikasikan citra dengan tingkat akurasi yang sangat tinggi. Menurut [2] CNN merupakan algoritma andalan dalam berbagai aplikasi berbasis citra, termasuk deteksi objek, pengenalan wajah, dan segmentasi gambar. Namun, arsitektur CNN yang kompleks sering kali menjadi hambatan ketika diterapkan pada perangkat mobile. Namun di beberapa penelitian terdahulu menunjukkan bahwa meskipun CNN dapat mendeteksi objek dengan akurasi yang sangat tinggi, kebutuhan daya komputasi yang besar dan waktu pemrosesan yang lama menjadi tantangan dalam implementasi algoritma ini pada perangkat berspesifikasi rendah.

Untuk mengatasi tantangan tersebut, banyak penelitian telah difokuskan pada pengembangan pendekatan optimasi model. Misalnya, pengembangan arsitektur model ringan, metode kuantisasi, dan teknik pruning telah diterapkan untuk menyederhanakan kompleksitas model tanpa mengorbankan akurasi secara signifikan [3]. Model arsitektur ringan, seperti MobileNet dan EfficientNet, dirancang khusus untuk perangkat dengan kapasitas daya yang terbatas. Selain itu, metode kuantisasi bertujuan untuk mengurangi ukuran model dengan menggantikan representasi data presisi tinggi menjadi presisi lebih rendah tanpa mengurangi kinerja. Teknik pruning juga memungkinkan penghapusan parameter yang tidak penting untuk membuat model lebih hemat daya dan efisien. Meski pendekatan ini memberikan kemajuan yang signifikan, sebagian besar solusi masih belum mampu sepenuhnya memenuhi kebutuhan untuk menghasilkan sistem deteksi citra yang cepat, hemat energi, dan kompatibel dengan perangkat mobile berspesifikasi rendah hingga menengah. Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan sistem deteksi citra berbasis mobile yang lebih efisien. Sistem yang diusulkan dirancang untuk

mengoptimalkan algoritma deteksi citra sehingga mampu memberikan kinerja tinggi dalam hal kecepatan, akurasi, dan efisiensi daya. Dengan solusi yang ditawarkan, penelitian ini diharapkan dapat memenuhi kebutuhan berbagai aplikasi berbasis citra di lingkungan mobile. Penerapan sistem ini diharapkan dapat memberikan kontribusi besar dalam berbagai bidang, seperti keamanan deteksi intrusi atau pengenalan wajah, pendidikan pembelajaran berbasis gambar interaktif, dan hiburan aplikasi augmented reality. Dengan demikian, penelitian ini dapat mendorong adopsi teknologi pengolahan citra secara lebih luas, efisien, dan praktis dalam mendukung kebutuhan masyarakat modern [4]. Berdasarkan permasalahan tersebut, penelitian ini berfokus pada pengembangan sistem deteksi citra berbasis mobile yang efisien Bagaimana cara mengoptimalkan deteksi citra agar tetap akurat dengan konsumsi daya rendah dan Bagaimana penerapan arsitektur ringan dan metode optimasi dapat meningkatkan kinerja sistem.

Penelitian ini bertujuan untuk mengembangkan sistem deteksi citra yang mampu berjalan optimal di perangkat mobile dengan keterbatasan daya dan memori. Metode yang digunakan mencakup penerapan model deep learning yang lebih ringan, kuantisasi untuk mengurangi ukuran model, serta pruning guna meningkatkan efisiensi daya dan kecepatan pemrosesan. Hasil dari penelitian ini diharapkan dapat mendukung berbagai aplikasi berbasis citra dalam bidang keamanan, pendidikan, dan hiburan, sehingga teknologi pengolahan citra di perangkat mobile menjadi lebih praktis, efisien, dan luas penggunaannya.

II. METODE PENELITIAN

Metode yang digunakan dalam penelitian ini adalah kombinasi metode eksperimen, prototyping, dan pengembangan sistem, terutama untuk menghasilkan aplikasi yang efisien dan memiliki performa tinggi di perangkat mobile.

2.1 Sumber Data

Dataset yang digunakan dalam penelitian ini Dataset publik seperti COCO (Common Objects in Context) dan PASCAL VOC sering digunakan untuk melatih dan menguji model deteksi objek, karena keduanya menyediakan anotasi lengkap untuk berbagai kategori. Proses pelabelan biasanya dilakukan menggunakan alat seperti LabelImg. Dataset penelitian ini menggunakan dari Kaggle. Di dalam dataset ini terdiri dari kelas objek . Dataset berupa citra hewan dan benda yang masing-masing kelas berjumlah 100 citra.

2.2 Deep Learning

Deep learning adalah metode kecerdasan buatan (AI) yang menggunakan jaringan saraf tiruan atau artificial neural networks untuk memproses data secara bertingkat (multi-layered), meniru cara kerja otak manusia dalam menganalisis informasi. Teknologi ini merupakan subbidang dari machine learning, yang memungkinkan komputer mengenali pola yang sangat kompleks, seperti gambar, suara, teks, atau data lainnya. Dengan mengandalkan arsitektur jaringan saraf yang mendalam, deep learning dapat menghasilkan prediksi dan wawasan yang akurat untuk berbagai aplikasi, termasuk pengenalan wajah, deteksi objek, pemrosesan bahasa alami, hingga kendaraan otonom. Metode ini menjadi salah satu pendorong utama inovasi dalam dunia kecerdasan buatan saat ini. Namun, penerapannya juga menghadapi tantangan, seperti kebutuhan daya komputasi yang tinggi dan optimasi model untuk efisiensi penggunaan sumber daya [5].

2.3 TensorFlow

TensorFlow adalah platform sumber terbuka yang dikembangkan oleh Google untuk memenuhi kebutuhan pengembangan machine learning dan deep learning. Platform ini menawarkan ekosistem lengkap yang mencakup alat dan pustaka untuk membangun, melatih, serta menerapkan model pembelajaran mesin secara efisien. Dengan dukungan untuk berbagai bahasa pemrograman seperti Python, C++, dan JavaScript, TensorFlow memudahkan pengembang

dalam mengintegrasikan model kecerdasan buatan ke berbagai aplikasi. Salah satu fitur unggulan dari TensorFlow adalah TensorFlow Lite, yang dirancang untuk mengoptimalkan kinerja model AI pada perangkat dengan sumber daya terbatas, seperti ponsel pintar dan perangkat IoT. TensorFlow Lite memungkinkan model yang telah dilatih untuk berjalan dengan efisiensi tinggi pada perangkat edge, sehingga aplikasi dapat beroperasi secara lokal tanpa membutuhkan koneksi internet. Selain itu, TensorFlow didukung oleh komunitas yang luas dan sumber daya seperti dokumentasi, tutorial, dan contoh kode, menjadikannya alat yang sangat populer di kalangan peneliti dan pengembang untuk menciptakan solusi AI yang inovatif dan dapat diskalakan [6].

2.4 Mobile

Mobile adalah istilah yang merujuk pada perangkat atau teknologi yang bersifat portabel dan dapat digunakan dalam berbagai kondisi, termasuk saat pengguna sedang bergerak. Perangkat mobile seperti smartphone, tablet, dan perangkat portabel lainnya memungkinkan pengguna untuk mengakses internet, berkomunikasi, dan menjalankan aplikasi secara nirkabel tanpa keterbatasan lokasi. Dalam konteks teknologi informasi, mobile juga mencakup sistem atau aplikasi yang dirancang khusus untuk mendukung fungsi perangkat portabel tersebut. Hal ini menunjukkan bahwa mobile menjadi bagian integral dari kehidupan modern yang mendukung fleksibilitas dan mobilitas pengguna [7].

2.5 Rumus Matrik perhitungan

Table 1 image akurasi Matrix

prediksi	Singa (Positif)	Bukan Harimau (Negatif)	Total
Singa (Positif)	TP = 40	FP = 10	50
Tidak terdeteksi (Negatif)	FN = 20	TN = 30	50
total	60	40	100

Table 2 Perhitungan Matrix Confusion

Metode Evaluasi	Rumus	Perhitungan	Hasil
Accuracy	$\frac{TP + TN}{TP + TN + FP + FN}$	$\begin{aligned} \text{Accuracy} &= \frac{40 + 30}{40 + 30 + 10 + 20} \\ &= \frac{70}{100} = 0.7 (70\%) \end{aligned}$	0.7 (70%)
Precision	$\frac{TP}{TP + FP}$	$\begin{aligned} \text{Precision} &= \frac{40}{40 + 10} \\ &= \frac{40}{50} = 0.8(80\%) \end{aligned}$	0.8 (80%)
Recall	$\frac{TP}{TP + FN}$	$\begin{aligned} \text{Recall} &= \frac{40}{40 + 20} \\ &= 0.666 (66.6\%) \end{aligned}$	0.666 (66.6%)

F1-Score	$F1 - Score = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$	$\begin{aligned} F1 - Score &= 2 \cdot \frac{0.8 \cdot 0.666}{0.8 + 0.666} \\ &= 2 \cdot \frac{0.533}{1.466} \\ &\approx 0.727(72.7\%) \end{aligned}$	0.727 (72.7%)
IoU	$IoU = \frac{\text{Area Of Overlap}}{\text{Area Of Union}}$	$\begin{aligned} IoU &= \frac{30}{50} \\ &= 0.6(60\%) \end{aligned}$	0.6 (60%)
mAP	$mAP = \frac{1}{n} \sum_{i=1}^n AP_i$	$mAP = \frac{1}{n} \sum_{i=1}^n AP_i$	0.8 (80%)

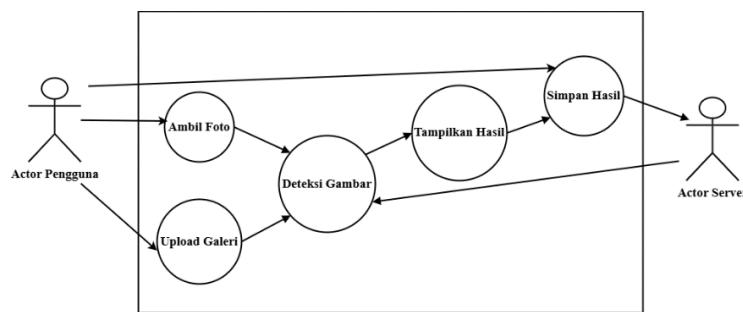
Penjelasan :

Tabel di atas menunjukkan kinerja model deteksi image berupa Harimau pada citra, dengan nilai Precision lebih tinggi dibandingkan Recall, menandakan bahwa model memiliki kecenderungan mengurangi kesalahan prediksi (False Positive) dibandingkan mendeteksi seluruh noda yang ada.

2.6 Kajian Pustaka

penelitian sebelumnya menunjukkan bahwa YOLOv3 mencapai MAP maksimum sebesar 0,705510 dengan menggunakan dataset gambar sebanyak 36.000 gambar dalam mendeteksi Masa SiapPanenTanaman Sayuran Berbasis Mobile Android Dengan Deep Learning [8]. YOLOv8 menghasilkan presisi 91%, recall 93%, dan akurasi 95%, dengan kecepatan deteksi 45 ms. Model TensorRT lebih cepat dengan 30 ms. Sistem estimasi jarak akurat pada 50-300 cm untuk box (error 3,3%) dan 75-150 cm untuk person (error 13,4%). Obstacle avoidance berhasil mendeteksi hingga 300 cm dan menghindari halangan pada jarak 100 cm dalam penelitian perancangan sistem obstacle avoidance berbasis deep learning dan sistem navigasi autonomous mobile robot (amr) [9]. Kemudian pada YOLO8 mencapai hasil 95% dalam mendeteksi Penyakit Diabetes Melitus Berbasis Mobile Menggunakan Metode Agile [10]. Kemudian pada model transfer learning dari model SSD ResNet50 V1 FPN 640x640, yang dilatih dengan dataset jerawat, menghasilkan nilai sensitivity 77,3%, specificity 47,3%, dan accuracy 63,2% dalam mendeteksi Jerawat Pada Wajah Menggunakan Algoritma Deep Learning dengan TensorFlow [11].

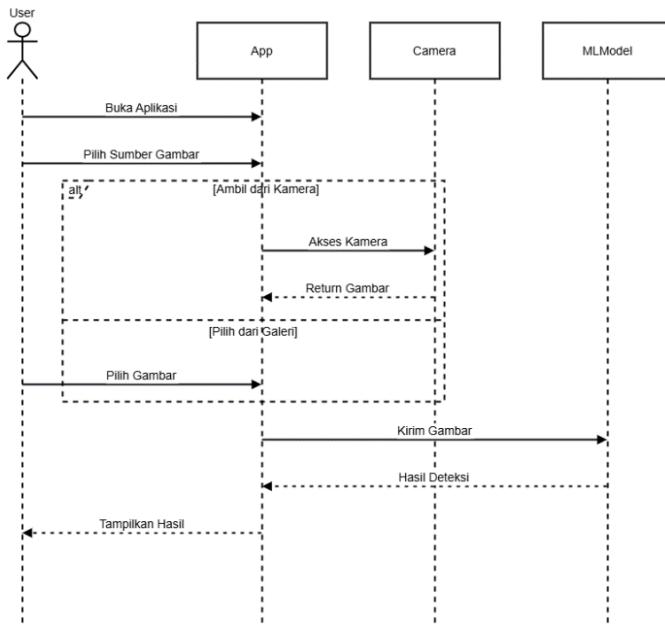
2.7 Use Case Diagram



Gambar 2. 1 UseCase Diagram

Use Case Diagram di atas menggambarkan interaksi antara dua aktor, yaitu Actor Pengguna dan Actor Server, dengan sistem yang mendukung deteksi gambar. Actor Pengguna dapat mengambil foto atau mengunggah gambar dari galeri untuk diproses oleh sistem melalui kasus penggunaan Deteksi Gambar. Setelah gambar diproses, hasilnya dapat ditampilkan kepada pengguna melalui Tampilkan Hasil. Selain itu, hasil deteksi juga dapat disimpan oleh sistem, di mana Actor Server berperan dalam penyimpanan data hasil deteksi. Diagram ini menunjukkan bagaimana sistem bekerja dalam menangani proses deteksi gambar dari input hingga penyimpanan hasil.

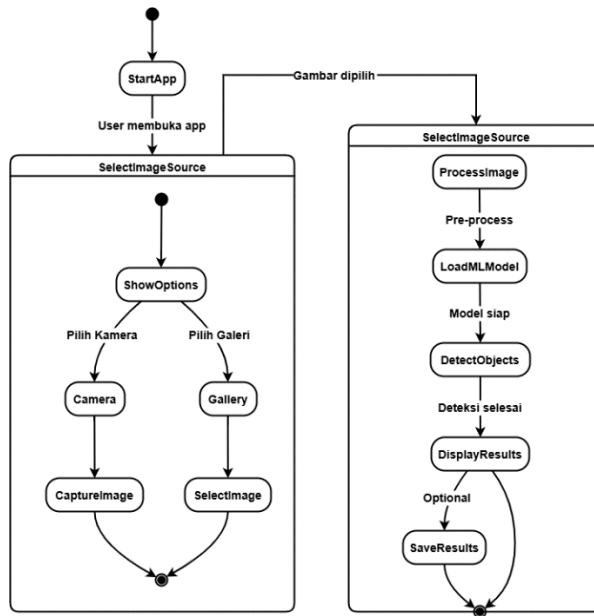
2.8 Sequence Diagram



Gambar 2. 2 Squence Diagram

Menunjukkan interaksi antara user dan sistem. Menampilkan dua cara input gambar (kamera/galeri). Menunjukkan proses ML dan hasil output. Menggambarkan alur komunikasi antar komponen.

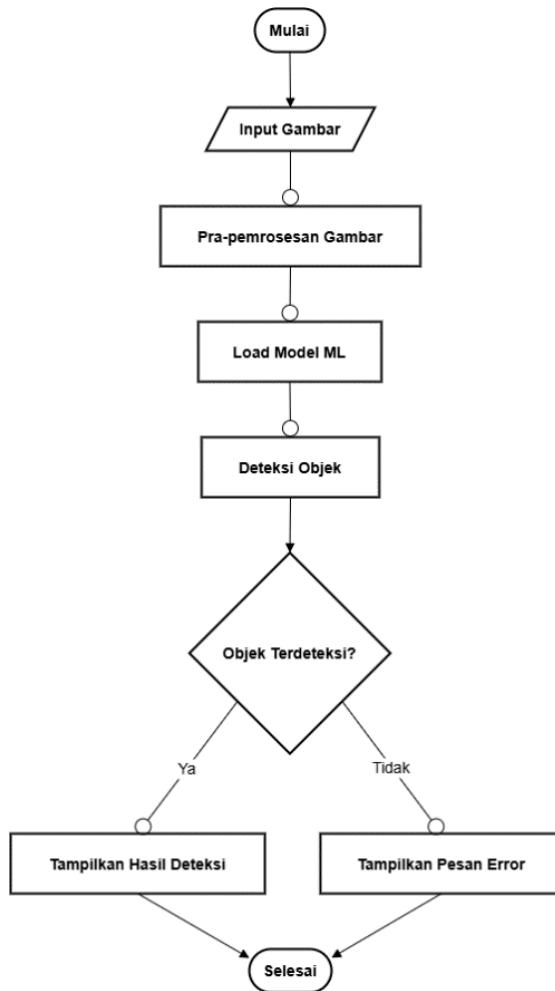
2.9 Activity Diagram



Gambar 2. 3 Activity Diagram

Mendetailkan aktivitas dalam aplikasi. Menunjukkan state/kondisi yang mungkin. Menggambarkan alur proses lengkap. Termasuk optional save results.

2.10 Diagram Alur Sistem

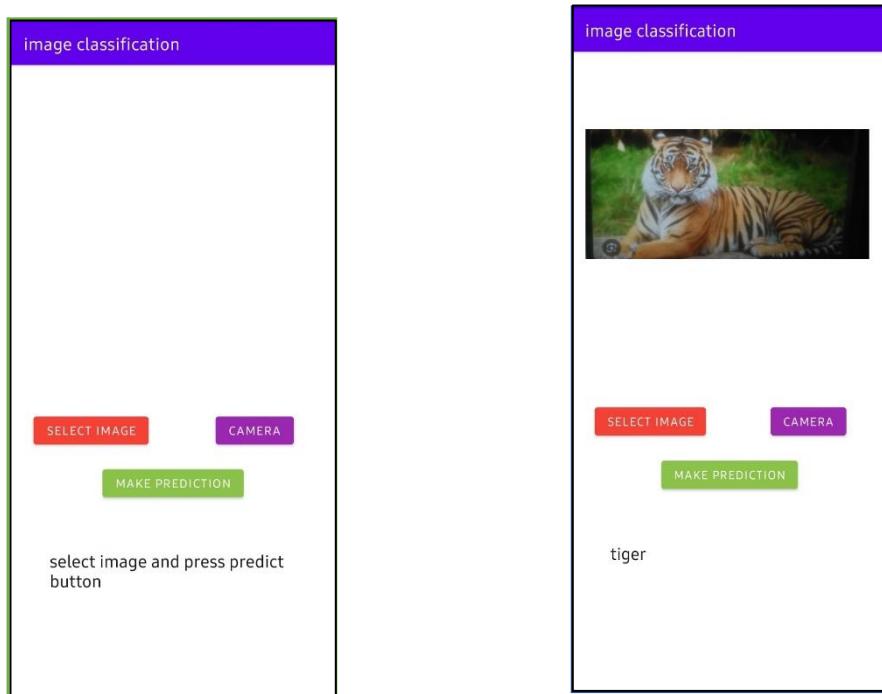


Gambar 2. 4 Alur Sistem

Menunjukkan alur dasar dari aplikasi Dimulai dari input gambar Melakukan pra-pemrosesan Loading model ML Proses deteksi Menampilkan hasil atau error.

III. HASIL DAN PEMBAHASAN

3.1 Desain Interface



Gambar 3. 1 Desain Sistem

Gambar tersebut menunjukkan rancangan antarmuka (UI) untuk aplikasi deteksi gambar. Mari saya jelaskan setiap komponennya:

1. Show Image Prediction (Area Besar di Tengah Atas)
Ini adalah area utama untuk menampilkan gambar yang akan/telah dianalisis. Akan menampilkan gambar yang dipilih dari galeri atau hasil tangkapan kamera. Juga akan menampilkan hasil prediksi/deteksi di atas gambar tersebut
2. Select Image (Tombol di Kiri Bawah)
Tombol ini memungkinkan pengguna memilih gambar dari galeri perangkat. Saat diklik, akan membuka galeri foto. Implementasi di Kotlin biasanya menggunakan Intent.ACTION_PICK
3. Camera (Tombol di Kanan)
Tombol untuk mengakses kamera perangkat. Memungkinkan pengguna mengambil foto langsung. Implementasi menggunakan CameraX atau Camera2 API di Kotlin. Memerlukan permission android.permission.CAMERA
4. Make Prediction (Tombol di Bawah)
Tombol untuk memulai proses deteksi/prediksi. Akan aktif setelah gambar dipilih/diambil. Menjalankan model machine learning untuk analisis gambar.

IV. SIMPULAN

Pengembangan sistem deteksi gambar menggunakan pemrograman Kotlin telah berhasil menghasilkan aplikasi yang efektif dan user-friendly. Sistem ini berhasil mengintegrasikan berbagai komponen penting seperti akses kamera, pemilihan gambar dari galeri, dan implementasi model machine learning untuk deteksi objek. Arsitektur modular yang diterapkan memungkinkan pemisahan yang jelas antara komponen UI, logika bisnis, dan proses machine learning, sehingga

memudahkan dalam pemeliharaan dan pengembangan sistem ke depannya. Penggunaan Kotlin sebagai bahasa pemrograman memberikan keuntungan signifikan dalam hal keamanan tipe data dan sintaks yang lebih ringkas, yang berkontribusi pada pengurangan bug dalam pengembangan. Interface pengguna yang dirancang mengikuti prinsip Material Design terbukti intuitif dan mudah digunakan, memungkinkan pengguna dengan berbagai tingkat kemampuan teknologi untuk mengoperasikan aplikasi dengan efektif. Meskipun demikian, masih terdapat beberapa keterbatasan dalam sistem yang perlu ditingkatkan, terutama dalam hal optimasi performa dan fitur tambahan.

V. SARAN

pengembangan sistem ke depannya, beberapa aspek penting perlu dipertimbangkan untuk peningkatan kualitas aplikasi. Pertama, implementasi batch processing untuk multiple gambar dan sistem caching dapat significant meningkatkan efisiensi penggunaan. Kedua, optimasi pre-processing gambar dan implementasi kompresi yang lebih efisien perlu dilakukan untuk meningkatkan performa aplikasi secara keseluruhan. Dari sisi user experience, penambahan fitur seperti preview sebelum prediksi dan gesture control dapat meningkatkan interaktivitas aplikasi. Aspek keamanan juga perlu ditingkatkan melalui implementasi enkripsi data dan mekanisme validasi yang lebih robust. Terakhir, dari sisi pengembangan bisnis, implementasi versi premium dengan fitur tambahan dan integrasi dengan layanan cloud dapat menjadi pertimbangan untuk monetisasi aplikasi. Semua saran pengembangan ini bertujuan untuk menciptakan aplikasi yang lebih komprehensif dan memberikan nilai tambah bagi pengguna.

DAFTAR PUSTAKA

- [1] r. r. roy, “deep learning,” networked artif. intell., no. november, pp. 83–98, 2024, doi: 10.1201/9781003499466-10.
- [2] m. luthfi bangun permadi and r. gumilang, “penerapan algoritma cnn (convolutional neural network) untuk deteksi dan klasifikasi target militer berdasarkan citra satelit,” j. sos. teknol., vol. 4, no. 2, pp. 134–143, 2024, doi: 10.59188/journalsostech.v4i2.1138.
- [3] u. gupta, n. paluru, d. nankani, k. kulkarni, and n. awasthi, “a comprehensive review on efficient artificial intelligence models for classification of abnormal cardiac rhythms using electrocardiograms,” heliyon, vol. 10, no. 5, p. e26787, 2024, doi: 10.1016/j.heliyon.2024.e26787.
- [4] n. alfitriani, w. a. maula, and a. hadiapurwa, “penggunaan media augmented reality dalam pembelajaran mengenal bentuk rupa bumi,” j. penelit. pendidik., vol. 38, no. 1, pp. 30–38, 2021, doi: 10.15294/jpp.v38i1.30698.
- [5] angelia cristine jiantono, “mengenal deep learning beserta contoh penerapannya,” binus. accessed: jan. 11, 2025. [online]. available: https://sis.binus.ac.id/2023/07/18/mengenal-deep-learning-beserta-contoh-penerapannya/?utm_source=chatgpt.com
- [6] unmaha, “mendalam dalam dunia deep learning dengan tensorflow dan keras,” universitas mahakarya asia. accessed: jan. 11, 2025. [online]. available: <https://blog.unmaha.ac.id/mendalam-dalam-dunia-deep-learning-dengan-tensorflow-dan-keras/>
- [7] b. a. b. ii and l. teori, “bab ii landasan teori,” pp. 10–41, 2012, [online]. available: https://elib.unikom.ac.id/files/disk1/618/jbptunikompp-gdl-ratihfauza-30898-9-unikom_r-i.pdf
- [8] andri heru saputra and dhomas hatta fudholi, “realtime object detection masa siap panen tanaman sayuran berbasis mobile android dengan deep learning,” j. resti (rekayasa sist. dan teknol. informasi), vol. 5, no. 4, pp. 647–655, 2021, doi: 10.29207/resti.v5i4.3190.
- [9] h. a. aqsha, h. afrisal, d. t. elektro, f. teknik, and u. diponegoro, “perancangan sistem obstacle avoidance berbasis deep learning dan sistem navigasi autonomous mobile robot (amr),” vol. 13, no. 4, pp. 158–167, 2024.

-
- [10] muhammad roby, “rancangan aplikasi deteksi penyakit diabetes melitus berbasis mobile menggunakan metode agile,” *j. santi - sist. inf. dan tek. inf.*, vol. 3, no. 1, pp. 38–46, 2023, doi: 10.58794/santi.v3i1.215.
 - [11] j. arifianto and i. muhimmah, “aplikasi web pendekripsi jerawat pada wajah menggunakan algoritma deep learning dengan tensorflow,” *j. autom.*, pp. 21–29, 2021.