

SURAT KETERANGAN BEBAS PLAGIARISME



Universitas Nusantara PGRI Kediri
UPT. PERPUSTAKAAN, PUBLIKASI DAN INOVASI
Alamat: Kampus 1, Jl. KH. Ahmad Dahlan No.76 Kota Kediri 64112
Telp. (0354) 771576, (0354) 771503, (0354) 771495, Fax. (0354) 771576
Website: <http://ppi.unpkediri.ac.id/> Email: perpustakaan@unpkediri.ac.id

SURAT KETERANGAN BEBAS SIMILARITY

Ketua UPT Perpustakaan, Publikasi dan Inovasi Universitas Nusantara PGRI Kediri menerangkan bahwa mahasiswa dengan identitas berikut:

Nama Mahasiswa : Mohammad Ubaidillah Ridlo
NPM : 2213020215
Program Studi : S1-Teknik Informatika

Judul Karya Ilmiah:

“IMPLEMENTASI MOBILENETV2 BERBASIS TRANSFER LEARNING UNTUK KLASIFIKASI SAMPAH ORGANIK DAN ANORGANIK PADA PLATFORM ANDROID”

Dinyatakan sudah memenuhi syarat batas maksimal 30% *similarity* sesuai dengan ketentuan yang berlaku pada setiap subbab naskah Laporan **Tugas Akhir/Skripsi/Tesis** yang disusun.

Demikian Surat Keterangan ini kami berikan untuk dapat dipergunakan seperlunya.



Kediri, 23 Juni 2026
Ka UPT PPI,



Dr. Abdul Aziz Hunaifi, M.A



PERSETUJUAN BAU :



**BERITA ACARA
KEMAJUAN PEMBIMBINGAN
PENULISAN KARYA TULIS ILMIAH**

1. NAMA MAHASISWA : MOHAMMAD UBAIDILLAH RIDLO
NPM : 2243020215
Fak/Jur/Prodi : Fakultas Teknik dan Ilmu Komputer
Alamat Rumah : Jl. Yos Sudarso 05 Tulungrejo Pare
Alamat email : Ubaidillahridlo57@gmail.com
No. Telp./HP : 0880 3235 010
2. DOSEN PEMBIMBING I : RESTY WULANNINGRUM, S.Kom, M.Kom
Alamat Rumah : Blabak Kandat
Alamat email : restyw@unpkdr.ac.id
No. Telp. / HP : 085640106769
3. DOSEN PEMBIMBING II : Dr. RISKY ASWI RAMADHANI, S.Kom, M.Kom
Alamat Rumah : Purwa Paur Desa Banjorejo
Alamat email : riskyaswiramadhani@gmail.com
No. Telp. / HP : 081231034110
4. JUDUL KTI :

IMPLEMENTASI MOBILE LTV2 BERBASIS TRANSFER LEARNING
UNTUK KLASIFIKASI SAMPAH ORGANIK DAN ANORGANIK PADA
PLATFORM ANDROID

Catatan :

1. Periode Bimbingan (Sesuai SK Rektor) : _____
2. Jadwal Bimbingan : _____

	Hari	Pukul	Tempat / Ruang
Pembimbing I	Senin	10.00 wib	Prodi TI
	Rabu	10.00 wib	Prodi TI
Pembimbing II	Senin	13.00 wib	Prodi TI
	Rabu	13.00 wib	Prodi TI

3. Kemajuan Bimbingan

Pembimbing I

NO.	TANGGAL	MATERI	MASALAH	TT. DOSEN
	10-4-26	Preview	Topik Penelitian	Rf.
	19-4-26	Lainnya	Dataset	Rf.
	22-4-26	BAB I	Latar Belakang Masalah	Rf.
	30-4-26	BAB I	BAB I	Rf.
	4-5-26	BAB II	Kajian Pustaka	Rf.
	6-5-26	BAB III	Metode Penelitian	Rf.
	11-5-26	BAB III	Perancangan Sistem	Rf.
	13-5-26	Lainnya	Preprocessing Data	Rf.
	18-5-26	BAB IV	Implementasi Sistem	Rf.
	20-5-26	BAB IV	Pengujian	Rf.
	29-5-26	BAB IV	Analisis Hasil	Rf.
	2-6-26	BAB IV	BAB IV	Rf.
	3-6-26	BAB V	BAB V	Rf.
	8-6-26	Lainnya	ACC fiday (minor revision)	Rf.
	10-6-26	Lainnya	Abstrak	Rf.
	15-6-26	Lainnya	ACC Fall paper.	Rf.
	17-6-26	Lainnya	ACC fiday	Rf.

Pembimbing II

NO.	TANGGAL	MATERI	MASALAH	TT. DOSEN
	10-4-26	Preview	Topik penelitian	
	20-4-26	Lainnya	Definisi	
	27-4-26	Lainnya	Data set diperoleh	
	4-5-26	Lainnya	Abstrak	
	13-5-26	Lainnya	Abstrak	
	25-5-26	BAB III	BAB 3	
	26-5-26	BAB I	BAB I	
	29-5-26	BAB I	Pendahuluan	
	2-6-26	BAB I	Pendahuluan	
	3-6-26	BAB I	Penyusunan Masalah	
	4-6-26	BAB III	Metode gr. penelitian	
	5-6-26	BAB IV	BAB 4	
	8-6-26	BAB V	BAB 5	
	10-6-26	BAB V	BAB 5	
	12-6-26	BAB III	flowchart	
	15-6-26	BAB IV	Pengujian	
	17-6-26	Lainnya	ACC	

Mengetahui,

Kaprodi

Risa Melilita, N.Kon
NIDN 0721058902

Kediri, 18 Juni 2026

Mahasiswa Ybs,

Mohammad Ubaidillah Ridlo
NPM 2213020215



Universitas Nusantara PGRI Kediri

Status Terakreditasi Baik Sekali

SK BAN-PT No.671/SK/BAN-PT/Akred/PT/VII/2021 Tanggal 21 Juli 2021

Lembaga Penelitian Dan Pengabdian Pada Masyarakat (LPPM)

Kampus I Jl. K.H. Achmad Dahlan 76 Kediri 64112 Telp. (0354)771576,771503 Kediri

Website: <https://lp2m.unpkediri.ac.id> email: lemit@unpkediri.ac.id

BERITA ACARA UJIAN SKRIPSI

Pada hari ini Kamis tanggal 16 Juli 2026 bertempat di Ruang UJIAN M12 Universitas Nusantara PGRI Kediri, telah dilaksanakan Ujian Skripsi Mahasiswa Universitas Nusantara PGRI Kediri :



Nama : Mohammad Ubaidillah Ridlo
NPM : 2213020215
Prodi : S1-Teknik Informatika
Semester/Tahun Akademik : Genap, 25/26
Judul : IMPLEMENTASI MOBILENETV2 BERBASIS TRANSFER
LEARNING UNTUK KLASIFIKASI SAMPAH ORGANIK DAN
ANORGANIK PADA PLATFORM ANDROID
Dengan Hasil : Revisi Naskah
Nilai : 84 (A-)

Ketua Penguji

✓ Valid

(RESTY WULANNINGRUM, S.Kom,
M.Kom)

Penguji 1

✓ Valid

(ARDI SANJAYA, S.Kom, M.Kom)

Penguji 2

✓ Valid

(Dr. RISKY ASWI RAMADHANI,
S.Kom, M.Kom)

NB:

- Input Nilai dilakukan oleh Ketua Penguji, Penguji 1, dan Penguji ke-n melalui siacad
- Nilai Final berasal dari gabungan seluruh dosen penguji
- Daftar Dosen yang telah mengisi nilai: Ardi Sanjaya, Risky Aswi Ramadhani, Resty Wulanningrum
- Pastikan semua penguji telah melakukan input nilai



Universitas Nusantara PGRI Kediri

Status Terakreditasi Baik Sekali

SK BAN-PT No.671/SK/BAN-PT/Akred/PT/VII/2021 Tanggal 21 Juli 2021

Lembaga Penelitian Dan Pengabdian Pada Masyarakat (LPPM)

Kampus I Jl. K.H. Achmad Dahlan 76 Kediri 64112 Telp.(0354)771576,771503 Kediri

Website: <https://lp2m.unpkediri.ac.id> email: lemlit@unpkediri.ac.id

LEMBAR REVISI UJIAN SKRIPSI



Nama : Mohammad Ubaidillah Ridlo
NPM : 2213020215
Prodi : S1-Teknik Informatika
Semester/Tahun Akademik : Genap, 25/26
Hari/Tanggal Ujian : Kamis / 16 Juli 2026
Judul : IMPLEMENTASI MOBILENETV2 BERBASIS TRANSFER
LEARNING UNTUK KLASIFIKASI SAMPAH ORGANIK DAN
ANORGANIK PADA PLATFORM ANDROID
Dengan Hasil : Revisi Naskah
Nilai : 84 (A-)

Catatan Revisi:

Lihat catatan pada naskah, -, Lihat coretan pada naskah, pastikan semua istilah asing di cetak miring

Ketua Penguji

(RESTY WULANNINGRUM, S.Kom,
M.Kom)

Penguji 1

(ARDI SANJAYA, S.Kom, M.Kom)

Penguji 2

(Dr. RISKY ASWI RAMADHANI,
S.Kom, M.Kom)

NB:

- Tanda Tangan revisi (Ketua Penguji, Penguji 1, dan Penguji ke-n) dilakukan secara manual
- Nilai berasal dari gabungan dari seluruh dosen penguji
- Daftar Dosen yang telah mengisi nilai: Ardi Sanjaya, Risky Aswi Ramadhani, Resty Wulanningrum

Turnitin LLCC

2213020215_Mohammad Ubaidillah Ridlo

 TI-18

Document Details

Submission ID

trn:oid::2945:394823577

Submission Date

Jun 23, 2026, 2:04 PM GMT+7

Download Date

Jun 23, 2026, 2:15 PM GMT+7

File Name

2213020215_Mohammad Ubaidillah Ridlo.pdf

File Size

2.2 MB

73 Pages

12,212 Words

81,794 Characters

23% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

Filtered from the Report

- Bibliography

Top Sources

- 13%  Internet sources
- 10%  Publications
- 20%  Submitted works (Student Papers)

Integrity Flags

0 Integrity Flags for Review

Our system's algorithms look deeply at a document for any inconsistencies that would set it apart from a normal submission. If we notice something strange, we flag it for you to review.

A Flag is not necessarily an indicator of a problem. However, we'd recommend you focus your attention there for further review.

Top Sources

- 13% Internet sources
- 10% Publications
- 20% Submitted works (Student Papers)

Top Sources

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

1	Internet	informatika.unpkediri.ac.id	<1%
2	Student papers	Universitas Pamulang on 2026-05-04	<1%
3	Internet	journals.usm.ac.id	<1%
4	Internet	docplayer.info	<1%
5	Student papers	Universitas Muhammadiyah Purwokerto on 2025-07-09	<1%
6	Student papers	UPN Veteran Yogyakarta on 2026-04-30	<1%
7	Student papers	UPN Veteran Yogyakarta on 2026-06-02	<1%
8	Student papers	Universitas Jember on 2026-04-06	<1%
9	Internet	jurnal.polbeng.ac.id	<1%
10	Publication	Nurzaenab Nurzaenab, Sulfahmi Sulfahmi, Agus Halid, Fitriana M. Sabir, Andi Su...	<1%
11	Student papers	UPN Veteran Yogyakarta on 2026-04-22	<1%

12	Internet	www.coursehero.com	<1%
13	Student papers	Universitas 17 Agustus 1945 Semarang on 2026-06-09	<1%
14	Student papers	Universitas Dinamika on 2026-06-11	<1%
15	Internet	ejurnal.seminar-id.com	<1%
16	Internet	jurnal.kdi.or.id	<1%
17	Student papers	Universitas Islam Riau on 2026-04-28	<1%
18	Student papers	Universitas Islam Indonesia on 2026-06-15	<1%
19	Student papers	Universitas Tarumanagara on 2025-12-19	<1%
20	Student papers	Universitas Islam Riau on 2026-06-10	<1%
21	Student papers	Universitas Putera Batam on 2026-02-02	<1%
22	Internet	123dok.com	<1%
23	Student papers	Tarumanagara University on 2026-06-22	<1%
24	Student papers	Telkom University on 2026-06-18	<1%
25	Student papers	UPN Veteran Yogyakarta on 2026-04-02	<1%

26	Internet	regional.kompas.com	<1%
27	Student papers	Universitas Muhammadiyah Sukabumi on 2026-01-19	<1%
28	Publication	Ananda Rizki Dani, Irma Handayani. "Classification of Yogyakarta Batik Motifs Usi...	<1%
29	Student papers	UIN Syarif Hidayatullah Jakarta on 2025-08-04	<1%
30	Student papers	Universitas Islam Riau on 2025-12-04	<1%
31	Student papers	Universitas Tarumanagara on 2025-12-24	<1%
32	Internet	repository.telkomuniversity.ac.id	<1%
33	Student papers	Universitas Islam Riau on 2026-06-15	<1%
34	Student papers	Universitas Pamulang on 2026-06-22	<1%
35	Internet	repository.uin-suska.ac.id	<1%
36	Publication	Muhammad Fadli Setiawan. "IMPLEMENTASI ALGORITMA CONVOLUTIONAL NEU...	<1%
37	Student papers	Universitas Islam Riau on 2025-07-17	<1%
38	Student papers	Universitas Islam Riau on 2026-05-13	<1%
39	Publication	Aprilian Gevindo, Syafri Arlis. "Smoker Detection Using the You Only Look Once (Y...	<1%

40	Student papers	Universitas Pamulang on 2026-05-18	<1%
41	Internet	journal.irpi.or.id	<1%
42	Internet	repositori.umrah.ac.id	<1%
43	Internet	repository.ub.ac.id	<1%
44	Student papers	STT PLN on 2023-08-10	<1%
45	Student papers	Universitas Kristen Duta Wacana on 2026-04-14	<1%
46	Publication	Zidan Indra Nugraha, Arnita, Kana Saputra S, Abi Setiawan, Raysa Maharani, Fir...	<1%
47	Internet	digilib.unila.ac.id	<1%
48	Internet	widuri.raharja.info	<1%
49	Internet	www.dekoruma.com	<1%
50	Student papers	Admin Turnitin UISI on 2025-07-31	<1%
51	Publication	Eko Fuji Pangestu -, Bambang Irawan -. "KLASIFIKASI PENYAKIT TANAMAN PADI ...	<1%
52	Student papers	Institut Teknologi Sumatera on 2026-06-17	<1%
53	Student papers	New College of the Humanities on 2026-03-27	<1%

54	Student papers	Universitas Islam Indonesia on 2026-04-20	<1%
55	Internet	jurusan.tik.pnj.ac.id	<1%
56	Internet	repository.nurulfikri.ac.id	<1%
57	Publication	I Gede Dhananjaya, Kadek Yota Ernanda Aryanto, I Gede Partha Sindu. "Pemanfa...	<1%
58	Student papers	Perpustakaan on 2025-08-06	<1%
59	Student papers	UPN Veteran Yogyakarta on 2026-05-04	<1%
60	Student papers	Telkom University on 2025-07-02	<1%
61	Student papers	Udayana University on 2026-06-04	<1%
62	Student papers	Universitas Gunadarma on 2025-12-08	<1%
63	Student papers	Universitas Maritim Raja Ali Haji on 2025-04-21	<1%
64	Internet	kc.umh.ac.id	<1%
65	Student papers	UPN Veteran Yogyakarta on 2026-05-29	<1%
66	Student papers	Universitas Brawijaya on 2020-12-30	<1%
67	Student papers	Universitas Islam Riau on 2026-04-30	<1%

68	Student papers	Universitas Islam Riau on 2026-04-30	<1%
69	Student papers	Universitas Islam Riau on 2025-11-27	<1%
70	Student papers	Universitas Sumatera Utara on 2025-05-23	<1%
71	Internet	repository.stiki.ac.id	<1%
72	Internet	repository.uinjkt.ac.id	<1%
73	Publication	Doly Ilham Saputra Huta Julu, Dewi Nurdiyah. "KLASIFIKASI SAMPAH ORGANIK D...	<1%
74	Publication	Melania Velisita Lau, Aryani Dwi Handayani, Miyosagusti Yudo Widodo, Rani Irma...	<1%
75	Student papers	Sriwijaya University on 2026-04-28	<1%
76	Student papers	Tarumanagara University on 2026-06-20	<1%
77	Student papers	UIN Raden Intan Lampung on 2025-11-25	<1%
78	Student papers	UPN Veteran Yogyakarta on 2026-05-29	<1%
79	Student papers	Universitas Jember on 2025-06-11	<1%
80	Student papers	Universitas Muria Kudus on 2017-09-07	<1%
81	Student papers	Universitas Muslim Indonesia on 2024-03-28	<1%

82	Student papers	Universitas Negeri Surabaya The State University of Surabaya on 2026-06-05	<1%
83	Student papers	Universitas Sumatera Utara on 2026-06-04	<1%
84	Internet	openjournal.unpam.ac.id	<1%
85	Student papers	Abdullah Gul University on 2025-11-20	<1%
86	Publication	Evita Evita. "IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK BERBASIS MOB...	<1%
87	Student papers	Tarumanagara University on 2026-06-21	<1%
88	Student papers	UIN Sunan Ampel Surabaya on 2020-10-09	<1%
89	Student papers	UM Surabaya on 2025-09-12	<1%
90	Student papers	UNIVERSITAS BUDI LUHUR on 2025-08-19	<1%
91	Student papers	Universitas Islam Riau on 2026-03-26	<1%
92	Student papers	Universitas Muhammadiyah Surakarta on 2014-02-16	<1%
93	Internet	adoc.pub	<1%
94	Internet	id.123dok.com	<1%
95	Internet	journal.ilmudata.co.id	<1%

96	Internet	repository.ulb.ac.id	<1%
97	Internet	repository.unissula.ac.id	<1%
98	Internet	repository.unmuhjember.ac.id	<1%
99	Publication	RIEFALDI DIOFANO SAPUTRA, DWI OKTA DJOAS, ADE IRGI FIRDAUS, INDRY ANG...	<1%
100	Student papers	STT PLN on 2024-08-06	<1%
101	Student papers	UPN Veteran Yogyakarta on 2026-03-31	<1%
102	Student papers	UPN Veteran Yogyakarta on 2026-06-02	<1%
103	Student papers	Universitas Brawijaya on 2021-06-17	<1%
104	Student papers	Universitas Muslim Indonesia on 2025-08-19	<1%
105	Student papers	Universitas Tarumanagara on 2025-12-11	<1%
106	Internet	ejournal.bsi.ac.id	<1%
107	Internet	ejournal.upi.edu	<1%
108	Internet	jurnal.univbinainsan.ac.id	<1%
109	Internet	www.researchgate.net	<1%

110	Student papers	Binus University International on 2026-03-17	<1%
111	Student papers	Boston University on 2026-05-13	<1%
112	Student papers	Chittagong University of Engineering and Technology on 2026-06-15	<1%
113	Publication	Indah Clara Sari. "INTEGRASI MODEL DEEP LEARNING EFFICIENTNET-B0 UNTUK D...	<1%
114	Publication	Riko Angga Bayu Kusuma -, Bambang Irawan -, Abdul Khamid -. "KLASIFIKASI PEN...	<1%
115	Publication	Rizkon Jajila, Nur Ariesanto Ramdhan, Puji Wahyuningsih, Bambang Irawan. "Opt...	<1%
116	Student papers	UPN Veteran Yogyakarta on 2026-06-04	<1%
117	Student papers	Universitas Islam Riau on 2025-09-23	<1%
118	Student papers	Universitas Islam Sumatera Utara on 2026-04-20	<1%
119	Student papers	Universitas Pelita Harapan on 2025-11-13	<1%
120	Student papers	Universitas Putera Batam on 2024-01-26	<1%
121	Internet	idoc.pub	<1%
122	Internet	ojs.amikom.ac.id	<1%
123	Internet	pdfcoffee.com	<1%

124	Internet	repository.upiypk.ac.id	<1%
125	Student papers	STT PLN on 2025-08-11	<1%
126	Student papers	Tarumanagara University on 2026-06-20	<1%
127	Student papers	UIN Maulana Malik Ibrahim Malang on 2026-06-17	<1%
128	Student papers	Universitas Brawijaya on 2018-07-18	<1%
129	Student papers	Universitas Budi Luhur on 2025-07-12	<1%
130	Student papers	Universitas Khairun on 2026-06-09	<1%
131	Student papers	Universitas Muhammadiyah Makassar on 2026-01-14	<1%
132	Student papers	Universitas Negeri Medan on 2026-06-17	<1%
133	Student papers	Universitas Negeri Surabaya on 2026-06-19	<1%
134	Internet	aktualkalsel.com	<1%
135	Internet	jurnal.stkipggritulungagung.ac.id	<1%
136	Internet	repositori.usu.ac.id	<1%
137	Internet	repository.umsu.ac.id	<1%

138	Internet	www.karyaerat.co.id	<1%
139	Student papers	College of Banking and Financial Studies on 2026-03-04	<1%
140	Publication	Micco Aureldo Micco Aureldo, Juanda Renaldi Juanda Renaldi, Riki Afriansyah Riki ...	<1%
141	Student papers	Mount Saint Dominic Academy on 2024-12-04	<1%
142	Publication	Muhammad Sholeh Bathin, Desi Ramayanti. "SOBATHUNI : Aplikasi Rumah Sewa ...	<1%
143	Student papers	Perpustakaan on 2025-08-06	<1%
144	Student papers	Sriwijaya University on 2023-01-19	<1%
145	Publication	Swelandiah Endah Pratiwi, Iqbal Nur Kholish, Dody Pernadi, Paranita Asnur. "Pen...	<1%
146	Student papers	UNIVERSITAS BUDI LUHUR on 2026-02-21	<1%
147	Student papers	Universitas Brawijaya on 2018-07-24	<1%
148	Student papers	Universitas Islam Riau on 2025-12-15	<1%
149	Student papers	Universitas Muslim Indonesia on 2024-12-03	<1%
150	Student papers	Universitas Muslim Indonesia on 2025-07-16	<1%
151	Student papers	Universitas Pamulang on 2026-06-06	<1%

152	Student papers	Universitas Tarumanagara on 2025-12-23	<1%
153	Internet	eprints.walisongo.ac.id	<1%
154	Internet	journals.upi-yai.ac.id	<1%
155	Internet	jurnalmahasiswa.stiesia.ac.id	<1%
156	Internet	melekit-if.uwks.ac.id	<1%
157	Internet	repo.iain-tulungagung.ac.id	<1%
158	Internet	repository.trisakti.ac.id	<1%
159	Internet	repository.untag-sby.ac.id	<1%
160	Internet	text-id.123dok.com	<1%
161	Publication	Ferry Khusnil Arief, Nurul Kholidiah, Rifki Mistahul Munir, Rahma Yunita. "Compa...	<1%
162	Publication	Kadek Agus Tamayasa, Luh Joni Erawati Dewi. "ANALISIS PERBANDINGAN MODEL...	<1%
163	Publication	Muhammad Syaifur Rohman, Afrinaldi Afrinaldi, Ahmad Syauqani, Maya Safira. "...	<1%
164	Student papers	Politeknik Kesehatan Kemenkes Padang on 2026-04-21	<1%
165	Student papers	Fakultas Teknik on 2025-07-23	<1%

166	Publication	Husain Rahmani, Dadang Iskandar Mulyana. "Analisis Nutrisi Makanan Berbasis ..."	<1%
167	Publication	Sean Edbert Thio, Joko Susilo. "Identifikasi Pemilahan Sampah Berbasis Algoritma..."	<1%
168	Student papers	Sriwijaya University on 2023-06-20	<1%
169	Student papers	Telkom University on 2025-07-08	<1%
170	Student papers	UPN Veteran Yogyakarta on 2026-05-25	<1%
171	Student papers	Universitas Islam Riau on 2026-04-06	<1%
172	Student papers	Universitas Muria Kudus on 2024-06-14	<1%
173	Internet	doku.pub	<1%

BAB I

PENDAHULUAN

A. Latar Belakang

Objek penelitian ini berfokus pada pengelolaan sampah, yang telah menjadi tantangan lingkungan mendesak seiring peningkatan pertumbuhan penduduk. Di Indonesia, situasi ini sangat kritis; data menunjukkan jutaan ton sampah tingkat kewilayahan belum terkelola dengan baik (Julu & Nurdiyah, 2025). Kajian Lingkungan Hidup Strategis bahkan memproyeksikan Tempat Pemrosesan Akhir (TPA) nasional akan penuh pada tahun 2030 (Kementerian PPN/Bappenas, 2023). Kondisi ini menuntut adanya solusi pengelolaan di sumbernya yang lebih efektif dan berkelanjutan.

Permasalahan fundamental terletak pada proses pemilahan sampah manual di tingkat rumah tangga yang tidak efisien dan rentan terhadap kelalaian manusia. Akibatnya, fasilitas pengolahan limbah lokal, seperti Tempat Pengelolaan Sampah *Reduce, Reuse, Recycle* (TPS 3R), kerap kewalahan menanggung beban pemilahan awal. Keterbatasan teknologi otomatisasi menjadi hambatan utama dalam mendukung program daur ulang (Nugraha et al., 2025). Kesalahan pemilahan dari sumber ini menghambat proses pengolahan kompos dan memperparah penumpukan limbah di TPA.

Sebagai respons terhadap persoalan mendesak tersebut, penelitian ini mengajukan inovasi berupa sistem pemilahan sampah otomatis dengan pendekatan *deep learning*. Pendekatan ini mengandalkan *Convolutional Neural Network* (CNN), yaitu salah satu metode *Deep Learning* yang banyak digunakan dalam bidang pengenalan citra karena kemampuannya dalam mempelajari fitur visual secara otomatis untuk mendeteksi dan mengenali berbagai objek (Purba et al., 2025). Pada praktiknya, riset ini mengaplikasikan model MobileNetV2 melalui teknik *Transfer Learning*. Penggunaan arsitektur ini didasarkan pada orientasinya terhadap efisiensi komputasi, menjadikannya sangat kompatibel untuk dieksekusi secara *real-time* pada gawai atau perangkat

mobile yang memiliki spesifikasi *perangkat keras* terbatas (Rumayar et al., 2025).

Rekam jejak keandalan model ini juga telah divalidasi oleh berbagai studi sebelumnya. Misalnya, riset Julu & Nurdiah (2025) yang sukses mencetak akurasi hingga 90,13% dalam pemilahan sampah menggunakan *Transfer Learning* MobileNetV2. Lebih lanjut, komparasi oleh Thio & Susilo (2025) memperlihatkan bahwa MobileNetV2 dengan akurasi 87,31% menunjukkan performa yang lebih baik dibandingkan EfficientNetB0 yang hanya menyentuh 82,21%. Kesuksesan serupa juga dilaporkan oleh Nugraha et al. (2025) yang mampu melampaui akurasi 84% saat membangun pengklasifikasi sampah *real-time* berbasis CNN. Bahkan, penelitian terbaru oleh Wahid et al. (2026) pada Prosiding Seminar Nasional UNP Kediri berhasil mengimplementasikan MobileNetV2 berbasis Android dengan tingkat akurasi mencapai 91%.

Meskipun penerapan MobileNetV2 berbasis *Transfer Learning* pada platform mobile telah terbukti sukses pada penelitian-penelitian tersebut, terdapat kesenjangan penelitian (*research gap*). Pada riset yang dilakukan oleh Wahid et al. (2026) misalnya, pengujian model masih bergantung sepenuhnya pada *dataset* sekunder yang diperoleh dari repositori publik (Kaggle) dengan karakteristik data yang berbeda dibandingkan data hasil pengumpulan langsung di lingkungan lokal. Efektivitas model tersebut ketika diterapkan pada *dataset* primer hasil pengumpulan mandiri yang merepresentasikan kondisi lingkungan lokal masih belum dievaluasi secara mendalam. Hal ini penting karena perbedaan karakteristik citra, seperti variasi pencahayaan, latar belakang, sudut pengambilan, dan kualitas kamera, berpotensi memengaruhi kemampuan generalisasi model dalam melakukan klasifikasi. Selain itu, riset terdahulu umumnya baru sebatas memberikan kesimpulan responsivitas aplikasi secara kualitatif tanpa mengukur metrik waktu inferensi (*inference time*) secara kuantitatif dalam satuan milidetik.

Oleh karena itu, penelitian ini menggunakan *dataset* primer hasil pengumpulan mandiri yang terdiri atas 400 citra sampah organik dan anorganik

yang diperoleh dari lingkungan lokal. Selain mengevaluasi performa model berdasarkan nilai akurasi, presisi, *recall*, dan *F1-score*, penelitian ini juga mengukur *inference time* untuk mengetahui kinerja implementasi MobileNetV2 berbasis *Transfer Learning* pada perangkat Android. Pemilihan platform Android sendiri didasarkan pada tingginya tingkat penggunaan gawai tersebut di masyarakat, sehingga mampu menyediakan akses teknologi yang lebih praktis, cepat, dan fleksibel dibandingkan perangkat komputasi konvensional (Nugraha et al., 2025).

Berdasarkan urgensi permasalahan pemilahan limbah domestik serta masih terbatasnya kajian yang mengevaluasi performa pada data lapangan, penelitian ini mengusulkan sistem klasifikasi sampah organik dan anorganik berbasis Android native menggunakan arsitektur MobileNetV2 dengan pendekatan *Transfer Learning*. Melalui pemanfaatan pustaka CameraX API untuk penangkapan citra dan implementasi model TensorFlow Lite (.tflite), sistem yang dirancang mampu melakukan klasifikasi secara *real-time* dan *offline* pada perangkat Android. Dengan demikian, penelitian ini diharapkan mampu memberikan evaluasi objektif mengenai efektivitas performa MobileNetV2 ketika diterapkan pada *dataset* primer berukuran terbatas yang merepresentasikan kondisi lingkungan lokal secara nyata.

B. Identifikasi Masalah

Berdasarkan uraian pada bagian latar belakang, beberapa permasalahan yang menjadi fokus penelitian dapat diidentifikasi sebagai berikut:

1. Proses pemilahan sampah di tingkat rumah tangga masih dilakukan secara manual sehingga rentan terhadap kesalahan manusia dan kurang efisien.
2. Masih terbatasnya penelitian yang mengevaluasi performa sistem klasifikasi sampah berbasis mobile menggunakan *dataset* primer hasil pengumpulan mandiri yang merepresentasikan kondisi lingkungan lokal.

C. Rumusan Masalah

Permasalahan utama dalam penelitian ini dirumuskan dalam bentuk pertanyaan ilmiah sebagai berikut:

1. Bagaimana implementasi MobileNetV2 berbasis *Transfer Learning* untuk klasifikasi sampah organik dan anorganik pada platform Android?
2. Bagaimana performa model MobileNetV2 berbasis *Transfer Learning* berdasarkan nilai akurasi, presisi, *recall*, *F1-score*, dan *inference time*?

D. Batasan Masalah

Guna membatasi ruang lingkup pembahasan agar tetap berfokus pada tujuan utama, maka batasan masalah dalam penelitian ini ditetapkan sebagai berikut:

1. Sistem hanya mengklasifikasikan citra ke dalam dua kategori, yaitu sampah organik dan sampah anorganik.
2. *Dataset* penelitian terdiri atas 400 citra digital primer (.jpg/.png) yang terdiri atas 200 citra sampah organik (difokuskan pada jenis dedaunan dan sisa makanan/buah) dan 200 citra sampah anorganik (difokuskan pada botol dan kemasan plastik) yang diperoleh melalui pengumpulan mandiri oleh peneliti di kawasan hunian penduduk warga Desa Tulungrejo, Kecamatan Pare, Kabupaten Kediri, Jawa Timur.
3. Proses klasifikasi menerapkan metode *Transfer Learning* berbasis arsitektur MobileNetV2 dengan bobot awal ImageNet, di mana tahapan pengembangan dan kompilasi model memanfaatkan *framework* TensorFlow/Keras sebelum ditranslasikan ke format .tflite.
4. Sistem akhir diimplementasikan ke dalam wujud aplikasi *native* berbasis Android yang menjalankan proses inferensi (*predict*) secara *real-time* dan sepenuhnya berjalan di memori internal gawai (*offline*) tanpa memerlukan interaksi dengan *server* ataupun layanan *cloud*.
5. Penyusunan komponen antarmuka dan penangkapan gambar pada aplikasi Android memanfaatkan bahasa pemrograman Kotlin/Java yang diintegrasikan dengan pustaka CameraX API.

6. Metrik pengujian performa model dibatasi pada analisis kuantitatif menggunakan Confusion Matrix (mencakup tingkat Akurasi, Presisi, Recall, dan *F1-Score*) serta perhitungan kecepatan respons (*Inference Time*), tanpa melakukan analisis komparatif antara model yang menggunakan augmentasi dan model tanpa augmentasi.

E. Tujuan Penelitian

Sejalan dengan rumusan masalah yang telah ditetapkan, tujuan penelitian ini adalah:

1. Mengimplementasikan MobileNetV2 berbasis *Transfer Learning* untuk klasifikasi sampah organik dan anorganik pada platform Android.
2. Menganalisis performa model MobileNetV2 berbasis *Transfer Learning* berdasarkan nilai akurasi, presisi, recall, *F1-score*, dan *inference time*.

F. Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan kontribusi signifikan, baik secara teoritis maupun praktis:

1. Manfaat Teoritis

Secara teoritis, penelitian ini diharapkan dapat memberikan gambaran empiris mengenai performa MobileNetV2 berbasis *Transfer Learning* pada *dataset* primer berukuran terbatas yang diperoleh dari lingkungan lokal serta implementasinya pada perangkat Android.

2. Manfaat Praktis

Secara praktis, penelitian ini bermanfaat untuk masyarakat rumah tangga sebagai alat bantu berbasis sistem cerdas yang membantu masyarakat dalam mengidentifikasi jenis sampah organik dan anorganik secara lebih cepat melalui perangkat *smartphone*.

BAB II

TINJAUAN PUSTAKA

Bab ini membahas teori-teori fundamental yang menjadi dasar penelitian, mengkaji penelitian terdahulu yang relevan untuk menunjukkan posisi dan kebaruan penelitian ini, serta menyajikan kerangka berpikir yang sistematis.

A. Teori dan Penelitian Terdahulu

1. Landasan Teori

a. Permasalahan Sampah dan Pengelolaannya

Di wilayah perkotaan, manajemen pembuangan dan pengelolaan limbah telah menjadi pilar krusial dalam agenda pembangunan yang berkelanjutan (Sosunova & Porras, 2022). Kendati demikian, lonjakan volume sampah sebagai dampak dari urbanisasi terus menjadi kendala utama, sehingga menuntut adanya transisi dari metode konvensional menuju adopsi teknologi modern (Alfaidi et al., 2026). Di tingkat akar rumput, minimnya edukasi serta terbatasnya waktu luang membuat masyarakat kerap kali kebingungan saat harus mengidentifikasi kategori limbah yang berpotensi untuk didaur ulang (Fitriani et al., 2025). Berdasarkan kondisi tersebut, pemilahan yang masih mengandalkan tenaga manusia (manual) merupakan pemicu utama terjadinya penumpukan limbah. Oleh sebab itu, teknologi otomatisasi dapat menjadi salah satu alternatif solusi untuk mendukung proses pemilahan sampah secara lebih efektif sejak dari sumbernya.



Gambar 2. 1 Tumpukan sampah plastik

Sumber: Apriliani (2022)

b. Klasifikasi Sampah dan Pentingnya Daur Ulang

Sampah organik adalah sampah yang dapat terurai secara alami (sisa makanan/daun), sedangkan anorganik adalah sampah yang sulit terurai seperti plastik dan logam (Thio & Susilo, 2025). Fitriani et al. (2025) menjelaskan bahwa daur ulang merupakan proses pemanfaatan kembali material untuk mengurangi eksploitasi alam. Namun, rendahnya pemahaman masyarakat menyebabkan banyak sampah daur ulang bercampur dengan residu (Nugraha et al., 2025). Berdasarkan kajian tersebut, pemilahan antara sampah organik dan anorganik merupakan tahapan penting dalam mendukung proses daur ulang yang lebih efektif.

c. Pengolahan Citra Digital dan *Preprocessing*

Menurut Dijaya (2023), pengolahan citra digital adalah pemrosesan representasi gambar menggunakan komputer untuk meningkatkan kualitas atau mempersiapkan data mentah sebelum dianalisis lebih lanjut. Dalam implementasi *deep learning* untuk

19 pengenalan objek visual, tahap *preprocessing* mutlak diperlukan untuk menstandarisasi format matriks data agar sesuai dengan spesifikasi *input* arsitektur jaringan (Faris et al., 2023). Standardisasi ini krusial agar fitur-fitur penting pada citra dapat diekstraksi secara maksimal oleh algoritma tanpa terganggu oleh variasi dimensi maupun pencahayaan asal (Dijaya, 2023). Proses *preprocessing* yang diterapkan dalam penelitian ini meliputi:

66 1) Dimensi Citra Digital

Citra digital secara matematis didefinisikan sebagai fungsi dua dimensi $f(x, y)$, di mana nilai x dan y merupakan koordinat spasial, dan nilai amplitudo f pada titik tersebut menyatakan tingkat intensitas atau keabuan (*gray level*) dari citra (Gonzalez & Woods, 2018). Di dalam memori komputer, citra berwarna (RGB) direpresentasikan sebagai susunan matriks tiga dimensi yang terdiri dari komponen baris (*Width / W*), kolom (*Height / H*), dan jumlah kanal warna (*Channel / C*). Untuk menghitung total elemen piksel data *input* (N_{pixels}) yang dialokasikan ke dalam memori, digunakan persamaan berikut (Gonzalez & Woods, 2018):

143
$$N_{\text{pixels}} = W \times H \times C \dots \dots \dots (2.1)$$

2) *Resize* (Penskalaan)

Resize merupakan proses pengubahan resolusi dimensi spasial dari citra asli menjadi dimensi target yang baru untuk menstandarisasi data (Dijaya, 2023). Dalam penelitian ini, seluruh citra sampah rumah tangga diseragamkan ukurannya menjadi dimensi 224×224 piksel. Penyesuaian skala ini wajib dilakukan secara konstan karena ukuran spasial tersebut merupakan standar default resolusi *input* yang dibutuhkan oleh lapisan konvolusi awal (*input layer*) pada arsitektur MobileNetV2 agar proses ekstraksi fitur visual berjalan optimal (Sandler et al., 2018).

3) Normalisasi

Normalisasi bertujuan untuk mentransformasikan rentang nilai intensitas warna piksel asli yang awalnya bertipe integer skala biner 0–255 menjadi rentang nilai pecahan (*floating point*) baru antara 0–1 (Chollet, 2021). Tahapan skalar ini diterapkan dalam rekayasa citra untuk menjaga stabilitas sebaran data matriks serta mempercepat proses konvergensi gradien nilai kesalahan (*loss*) selama iterasi pelatihan model berlangsung (Faris et al., 2023). Formulasi matematis untuk operasi normalisasi piksel didefinisikan melalui persamaan berikut (Chollet, 2021):

$$x' = \frac{x}{255} \dots \dots \dots (2.2)$$

Keterangan Variabel:

- a) x = nilai intensitas piksel asli sebelum diproses (rentang skala biner 0–255).
- b) x' = nilai matriks piksel baru yang telah ternormalisasi (rentang pecahan *floating point* 0–1).


Dimana x merupakan nilai intensitas piksel asal sebelum diproses dan x' bertindak sebagai nilai matriks piksel baru yang telah ternormalisasi. Berdasarkan landasan teori tersebut, tahap *preprocessing* berperan penting dalam menyiapkan data citra agar sesuai dengan kebutuhan model sehingga proses pelatihan dapat berjalan lebih efektif.

d. Kecerdasan Buatan dan *Deep Learning*

Kecerdasan buatan (*Artificial Intelligence*) merupakan bidang ilmu yang mengalami perkembangan pesat dan secara signifikan telah memajukan teknologi *computer vision*, khususnya dalam kemampuan analisis serta pemahaman citra visual secara otomatis (Wu et al., 2025).

10

Sebagai bagian dari ekosistem tersebut, penerapan teknologi *Deep Learning* dan *computer vision* membuka peluang besar bagi pengembangan sistem otomatisasi cerdas yang mampu meniru kemampuan kognitif manusia dalam mengenali pola visual yang kompleks (Raisul Islam et al., 2024). Lebih lanjut, teknik *Deep Learning* telah terbukti sangat tangguh dalam menangani tugas klasifikasi citra karena keunggulannya dalam mengekstraksi fitur-fitur penting dari suatu *dataset* objek secara otomatis dan hierarkis (Sarkar et al., 2025). Berdasarkan karakteristik tersebut, *Deep Learning* merupakan salah satu pendekatan yang banyak digunakan dalam permasalahan klasifikasi citra karena kemampuannya dalam mempelajari pola visual secara otomatis.




Gambar 2. 2 Ilustrasi konsep Deep Learning pada klasifikasi citra

e. *Convolutional Neural Network (CNN)*

Secara mekanis, *Convolutional Neural Network (CNN)* bagian dari *deep learning* yang beroperasi dengan menerapkan tahap konvolusi guna menarik fitur gambar, lalu menyusutkan dimensi spasialnya

melalui mekanisme *pooling*, sebelum akhirnya diklasifikasikan oleh *fully-connected layer* (Haliza Ramadhanti et al., 2025). Dalam praktiknya, arsitektur CNN juga sering diintegrasikan dengan teknik regularisasi *Dropout* untuk menonaktifkan sebagian neuron secara acak selama pelatihan guna mencegah *overfitting*, serta menggunakan fungsi aktivasi *Softmax* pada lapisan keluaran (*output layer*) untuk mengonversi nilai perhitungan matematis jaringan menjadi probabilitas persentase kelas klasifikasi (Chollet, 2021). Untuk mengevaluasi tingkat kesalahan prediksi selama pelatihan, model menggunakan fungsi kehilangan (*loss function*) seperti *Crossentropy*, yang dioptimalkan kinerjanya menggunakan algoritma pembaruan bobot seperti *Optimizer Adam* guna mempercepat proses konvergensi (Chollet, 2021). Efektivitas algoritma ini tidak lepas dari kemampuannya untuk menguraikan fitur citra menjadi pola-pola yang mudah dikenali, ditambah lagi, kapasitasnya untuk belajar mandiri langsung dari data visual mampu memangkas beban pemrograman secara drastis (Purba et al., 2025). Khusus untuk arsitektur CNN jenis *MobileNetV2*, performanya dinilai sangat andal dan konsisten saat diterapkan pada platform Android, terutama dalam mengakomodasi fungsi pemindaian (*scan*) atau identifikasi objek secara *real-time* (Rumayar et al., 2025).



Gambar 2. 3 Mekanisme kerja *Convolutional Neural Network (CNN)*

f. **Arsitektur MobileNetV2 dan** Beban Komputasi

MobileNetV2 adalah **arsitektur CNN yang dirancang untuk efisiensi tinggi pada perangkat bergerak (*mobile*)**. Arsitektur ini tetap mempertahankan mekanisme efisiensi ini dari pendahulunya (MobileNetV1), yaitu *Depthwise Separable Convolution* (Haganta Barus et al., 2025). **Berbeda dengan konvolusi standar yang memproses fitur spasial dan saluran warna secara bersamaan, *Depthwise Separable Convolution* memecah operasi tersebut menjadi dua tahap terpisah, yaitu *Depthwise Convolution* dan *Pointwise Convolution*** (Howard et al., 2017). Pemisahan operasi konvolusi ini secara matematis mampu memangkas beban kerja prosesor *smartphone* secara drastis, sehingga ideal untuk proses identifikasi objek secara *real-time* (Thio & Susilo, 2025).

Mengacu pada pengembangan spesifik MobileNetV2 oleh Sandler et al. (2018), keunggulan utama model ini dibandingkan versi pendahulunya terletak pada introduksi blok struktur baru yang memuat dua fitur anatomi internal, yaitu:

1) *Inverted Residual Block* dengan *Expansion Layer*

Berbeda dengan blok residual tradisional yang langsung memperkecil dimensi di awal, MobileNetV2 menerapkan prinsip terbalik (*inverted*). Blok ini menggunakan lapisan *Pointwise Convolution* di bagian awal untuk memperlebar jumlah saluran fitur sebelum masuk ke tahap *Depthwise Convolution*. Mekanisme ini berfungsi menjaga kapasitas sirkulasi informasi agar karakteristik visual sampah rumah tangga yang bervariasi tidak mengalami kehilangan informasi esensial (*information loss*).

2) *Linear Bottleneck*

Pada arsitektur konvensional, **setiap lapisan konvolusi diikuti oleh fungsi aktivasi non-linear seperti ReLU**. Namun, sifat ReLU


dapat merusak informasi jika dipaksakan berjalan pada ruang fitur berdimensi rendah di ujung blok. MobileNetV2 menyelesaikan masalah ini dengan membuang fungsi ReLU pada lapisan *bottleneck* akhir dan menggantinya dengan fungsi linear biasa guna memastikan representasi ciri visual yang membedakan limbah organik dan anorganik tetap utuh.

Berdasarkan rasio efisiensi matematis dan kajian literatur (Thio & Susilo, 2025), operasi Depthwise dan *Pointwise Convolution* mampu mengurangi beban komputasi dibandingkan konvolusi standar. Oleh karena itu, MobileNetV2 dipilih dalam penelitian ini karena memiliki efisiensi komputasi yang baik sehingga sesuai untuk implementasi pada perangkat Android dengan sumber daya terbatas.

g. *Transfer Learning*

Transfer Learning memanfaatkan model pra-latih (*pretrained*) untuk mempercepat pelatihan pada *dataset* baru dengan kebutuhan data yang lebih sedikit (Thio & Susilo, 2025). Metode ini memecahkan masalah identifikasi dengan melakukan proses *fine-tuning* pada arsitektur dasar guna meningkatkan variasi dan akurasi pelatihan (Putri et al., 2025). Penggunaan model pra-latih seperti MobileNetV2 yang telah belajar dari jutaan gambar di ImageNet secara efektif dapat beradaptasi dengan cepat karena menggabungkan kekuatan dari arsitektur dasar yang sudah ada (Sandler et al., 2018).

Berdasarkan karakteristik tersebut, *Transfer Learning* dapat membantu mempercepat proses pelatihan model dan meningkatkan kemampuan adaptasi model pada *dataset* dengan jumlah data yang terbatas. Ilustrasi mekanisme pemindahan pengetahuan ini ditunjukkan pada Gambar 2.4.



Gambar 2. 4 Ilustrasi konsep Transfer Learning


Sumber: Chouhan (2026)

Berdasarkan konsep *Transfer Learning*, model MobileNetV2 yang telah dilatih pada *dataset* ImageNet digunakan sebagai dasar ekstraksi fitur, sedangkan *dataset* sampah yang digunakan dalam penelitian ini berperan sebagai data baru untuk melatih lapisan klasifikasi. Pendekatan ini memungkinkan proses pelatihan berjalan lebih efisien meskipun menggunakan jumlah data yang relatif terbatas (Thio & Susilo, 2025).

h. Augmentasi Data

Augmentasi data adalah teknik yang digunakan untuk memperkaya variasi *dataset* latih dan mengurangi risiko *overfitting* pada model machine learning (Rahina et al., 2024). Teknik ini dilakukan dengan memanipulasi citra secara sintesis tanpa mengubah informasi utama objek sehingga model dapat belajar dari berbagai variasi kondisi visual (Fitriani et al., 2025). Dalam penelitian ini, augmentasi diterapkan secara otomatis selama proses pelatihan menggunakan *ImageDataGenerator* yang meliputi rotasi (*rotation*), pergeseran posisi (*width* dan *height shift*), pergeseran kemiringan (*shear*), perbesaran (*zoom*), dan pembalikan citra secara horizontal (*flip*) (Haliza Ramadhanti et al., 2025). Teknik tersebut digunakan untuk


meningkatkan keragaman data latih sehingga kemampuan generalisasi model dapat ditingkatkan.



Gambar 2. 5 Ilustrasi teknik augmentasi data pada citra

i. Implementasi TFLite

Untuk dapat dijalankan pada perangkat dengan sumber daya komputasi terbatas seperti *smartphone* Android, penelitian ini menggunakan arsitektur MobileNetV2 yang dirancang agar memiliki ukuran model kecil dan kebutuhan komputasi yang rendah (Howard et al., 2017). Menurut Moroney (2018), model yang telah dilatih kemudian dikonversi ke dalam format TensorFlow Lite (.tflite) agar dapat dijalankan secara efisien pada platform Android. Penggunaan pustaka TFLite memungkinkan implementasi sistem deteksi yang efisien untuk perangkat *embedded*, serta terbukti sangat stabil untuk dikembangkan ke arah deteksi waktu nyata (*real-time detection*) secara langsung menggunakan aliran kamera dari perangkat pengguna (Justam et al., 2024).



Gambar 2. 6 Arsitektur TensorFlow Lite pada Android

Sumber: Moroney (2018)

Berdasarkan landasan teknis tersebut, konversi model ke format TensorFlow Lite memungkinkan model *deep learning* dijalankan secara lebih efisien pada perangkat Android dengan sumber daya yang terbatas.

j. Evaluasi Kinerja Model

Evaluasi kinerja model merupakan tahapan kritis untuk mengukur tingkat keberhasilan algoritma klasifikasi dan kecepatan respons sistem. Berdasarkan penelitian (Julu & Nurdiah, 2025), metrik evaluasi standar seperti Akurasi, Presisi, *Recall*, dan *F1-Score* secara luas diandalkan untuk memvalidasi performa ketepatan model pengenalan citra. Sementara itu, untuk sistem yang ditargetkan beroperasi secara *real-time* langsung dari kamera, pengukuran rata-rata

latensi (waktu inferensi) menjadi parameter tambahan yang umum digunakan untuk mengevaluasi performa sistem *real-time* (Faris et al., 2023). Metrik evaluasi berbasis matriks kontingensi (*Confusion Matrix*) untuk klasifikasi biner tersebut secara matematis dihitung menggunakan persamaan standar sebagai berikut (Chicco & Jurman, 2020):

1) Akurasi (*Accuracy*)

Rasio total prediksi benar (baik positif maupun negatif) terhadap keseluruhan total data pengujian yang tersedia di dalam *dataset*.

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots (2.3)$$

2) Presisi (*Precision*)

Tingkat ketepatan atau akurasi model dalam memprediksi kelas positif dari keseluruhan sampel yang diidentifikasi sebagai kelas positif oleh sistem.

$$\text{Presisi} = \frac{TP}{TP+FP} \dots\dots\dots (2.4)$$

3) Recall (Sensitivitas)

Kemampuan model dalam menemukan kembali dan mengklasifikasikan data positif secara benar dari keseluruhan total riil data positif yang ada di lapangan.

$$\text{Recall} = \frac{TP}{TP+FN} \dots\dots\dots (2.5)$$

4) F1-Score

Nilai rata-rata harmonik (*harmonic mean*) antara tingkat ketepatan prediksi (*presisi*) dan tingkat sensitivitas (*recall*) untuk menunjukkan keseimbangan performa model pada kondisi klasifikasi dua kelas.

$$F1 - \text{Score} = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \dots\dots\dots (2.6)$$

Dimana komponen parameter penyusun rumus di atas didefinisikan secara spesifik sebagai berikut (Chicco & Jurman, 2020):

- a) *TP (True Positive)*: Jumlah data organik yang berhasil diprediksi secara benar sebagai sampah organik oleh sistem.
- b) *TN (True Negative)*: Jumlah data anorganik yang berhasil diprediksi secara benar sebagai sampah anorganik oleh sistem.
- c) *FP (False Positive)*: Jumlah data anorganik yang salah diprediksi menjadi sampah organik oleh sistem.
- d) *FN (False Negative)*: Jumlah data organik yang salah diprediksi menjadi sampah anorganik oleh sistem.

5) Rata-rata Latensi (Waktu Inferensi)

Untuk mengevaluasi kinerja *real-time* dari model saat diimplementasikan pada perangkat Android, penelitian ini mengukur rata-rata latensi atau waktu inferensi. Pengukuran dilakukan secara langsung pada level kode dengan memantau selisih waktu komputasi per *frame* gambar. Rata-rata latensi diperoleh dengan menjumlahkan total waktu komputasi dari keseluruhan *frame* yang diuji, lalu membaginya dengan jumlah total percobaan. Hasil dari kalkulasi ini direpresentasikan dalam satuan milidetik (ms).

Oleh karena itu, penelitian ini menggunakan metrik Akurasi, Presisi, *Recall*, *F1-Score*, dan Latensi untuk memperoleh gambaran performa model secara lebih komprehensif.

k. Bahasa Pemrograman dan *Framework*

Python merupakan bahasa pemrograman yang banyak digunakan dalam pengembangan *Deep Learning* karena didukung berbagai *framework* seperti TensorFlow dan Keras (Chollet, 2021). Dalam penelitian ini, Python digunakan untuk proses pelatihan model

MobileNetV2, sedangkan Kotlin/Java digunakan untuk pengembangan aplikasi Android (Google, 2025). TensorFlow dan Keras menyediakan berbagai fasilitas pengembangan model, termasuk mekanisme *callbacks* seperti *Early Stopping* dan *Model Checkpoint* untuk membantu mengoptimalkan proses pelatihan model.

1. Android CameraX API

CameraX adalah pustaka (*library*) bawaan dari Android Jetpack yang dirancang untuk mempermudah integrasi dan pengembangan fitur kamera pada aplikasi Android. Menurut dokumentasi resmi pengembang (Google, 2025), CameraX menyediakan antarmuka (API) yang konsisten di berbagai perangkat dengan kapabilitas pengelolaan *lifecycle* yang berjalan otomatis. Dalam konteks sistem *Computer Vision*, aplikasi harus mampu memproses tangkapan layar secara instan dan responsif (Faris et al., 2023).

Oleh karena itu, CameraX dipilih karena mendukung proses ekstraksi *frame* secara *real-time* pada aplikasi Android, yang mana *frame* tersebut langsung dikonversi menjadi matriks data untuk diproses oleh TensorFlow Lite (Justam et al., 2024). Berdasarkan kemampuan tersebut, CameraX API dipilih untuk mendukung proses pengambilan *frame* gambar secara *real-time* pada aplikasi Android.

2. Kajian Pustaka

Berikut adalah tinjauan penelitian terdahulu yang relevan dengan penelitian ini:

- a. Fitriani, Evanita, dan Riadi (2025) melakukan penelitian berjudul "*Implementation of Convolutional Neural Network Algorithm in Recyclable Waste Recognition to Support Environmental Management*". Penelitian ini mengatasi permasalahan klasifikasi sampah dengan membangun sistem berbasis website interaktif yang berfokus pada pengenalan 6 kategori sampah (kaca, kertas, logam,

plastik, organik, dan residu) dengan capaian akurasi sebesar 90%. Perbedaannya dengan penelitian ini terletak pada platform *deployment* yang digunakan (Website vs Native Android) dan tingkat kompleksitas kelas yang diurai. Penelitian ini difokuskan pada platform Android bergerak dengan klasifikasi biner, yaitu kategori sampah organik dan anorganik.

- b. Thio dan Susilo (2025) memanfaatkan metode *Transfer Learning* pada penelitian berjudul "*Identifikasi Pemilahan Sampah Berbasis Algoritma Transfer Learning CNN Menggunakan MobileNetV2 dan EfficientNetB0*". Mereka bertujuan membandingkan dua model untuk menemukan arsitektur yang paling efisien dalam mengklasifikasikan 6 kategori sampah. Hasil pengujian membuktikan bahwa arsitektur MobileNetV2 lebih unggul dengan akurasi 87,31% dan waktu pelatihan selama 406 detik dibandingkan EfficientNetB0. Perbedaannya dengan penelitian ini adalah penelitian terdahulu tersebut digunakan oleh peneliti sebagai justifikasi teknis kuat dalam pemilihan arsitektur MobileNetV2. Selanjutnya, pada penelitian ini model diimplementasikan secara langsung pada aplikasi *mobile native* berbasis *real-time*, bukan sekadar perbandingan komparatif eksperimental di Python.
- c. Rasidi et al. (2022) dalam penelitiannya yang berjudul '*Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network*' membangun sistem pemilahan sampah otomatis menggunakan metode CNN standar. Dengan menggunakan total *dataset* sekunder sebanyak 25.077 gambar dari platform Kaggle, hasil pengujian akhir menunjukkan tingkat akurasi sebesar 96% untuk kategori sampah anorganik dan 62% untuk sampah organik. Kelemahan deteksi pada kelas organik tersebut diidentifikasi terjadi karena tingginya variasi bentuk, warna, dan pola pembusukan objek sampah organik di lapangan. Perbedaannya dengan penelitian ini


terletak pada pendekatan model dan implementasi sistem. Penelitian terdahulu menggunakan CNN konvensional dengan *dataset* sekunder berukuran besar, sedangkan penelitian ini memanfaatkan arsitektur MobileNetV2 berbasis *Transfer Learning* yang diimplementasikan pada perangkat Android menggunakan TensorFlow Lite untuk mendukung klasifikasi secara *real-time*.

- d. Julu dan Nurdiah (2025) melakukan penelitian berjudul "Klasifikasi Sampah Organik dan Non Organik Menggunakan *Transfer Learning*". Penelitian ini bertujuan membandingkan kinerja tiga arsitektur CNN pra-latih (VGG16, MobileNetV2, dan ResNet50V2) menggunakan *dataset* sekunder sebanyak 2.528 gambar. Hasil eksperimen menunjukkan bahwa MobileNetV2 menunjukkan performa terbaik berdasarkan hasil penelitian tersebut dengan tingkat akurasi sebesar 90,13%, presisi 96,25%, dan waktu inferensi sebesar 127,76 ms. Perbedaannya dengan penelitian ini terletak pada sumber *dataset*, teknik pengolahan data, dan implementasi sistem. Penelitian terdahulu menggunakan *dataset* sekunder dan pemisahan *dataset* konvensional, sedangkan penelitian ini menggunakan *dataset* primer hasil pengumpulan mandiri serta menerapkan teknik *online data augmentation* selama proses pelatihan. Selain itu, model pada penelitian ini diimplementasikan ke dalam aplikasi Android berbasis TensorFlow Lite yang mampu melakukan klasifikasi secara *real-time* dan *offline*.
- e. Wahid et al. (2026) dalam risetnya yang berjudul "Implementasi Arsitektur MobileNetV2 untuk Klasifikasi Sampah Organik dan Anorganik Berbasis Android" merancang aplikasi pemilahan sampah portabel yang berjalan secara *on device*. Model MobileNetV2 dilatih selama 10 *epoch* menggunakan 25.077 citra dari Kaggle dan dikonversi ke format TensorFlow Lite dengan ukuran file akhir yang sangat ringan sebesar 8,8 MB. Hasil pengujian

141 sistem menghasilkan akurasi keseluruhan sebesar 91%, dengan presisi kelas organik 96% dan *recall* kelas anorganik 97%. Perbedaannya dengan penelitian ini terletak pada karakteristik sumber *dataset* dan pendekatan pengembangan model yang digunakan. Penelitian terdahulu menggunakan *dataset* sekunder skala besar yang diperoleh dari Kaggle, sedangkan penelitian ini menggunakan *dataset* primer hasil pengumpulan mandiri dari lingkungan lokal. Selain itu, penelitian ini juga mengevaluasi performa model menggunakan *dataset* primer hasil pengumpulan mandiri serta mengukur *inference time* secara kuantitatif pada perangkat Android.

- 169 f. Wulanningrum, Handayani, dan Wibawa (2024) melakukan penelitian berjudul "*Perbandingan Instance Segmentation Image Pada Yolo8*" untuk menganalisis performa kompleksitas dan kecepatan model *Deep Learning* dalam deteksi objek secara *real-time*. Penelitian tersebut menekankan bahwa pengujian performa kecepatan komputasi model di lapangan merupakan tahapan krusial untuk menjamin keandalan sistem. Perbedaannya dengan penelitian ini terletak pada jenis arsitektur model yang diuji (YOLOv8 vs MobileNetV2) dan objek pengesanan. Jurnal ini diadopsi sebagai dasar metodologi bagi peneliti untuk melakukan analisis performa kecepatan inferensi model (*inference time*) secara transparan pada aplikasi Android.

B. Kerangka Berpikir



Gambar 2. 7 Kerangka Berpikir

Kerangka berpikir penelitian ini diawali dari permasalahan utama dalam pengelolaan sampah, yaitu proses pemilahan yang masih dilakukan secara manual sehingga sering menimbulkan kesalahan dan inefisiensi. Pemilahan manual menyebabkan sampah organik dan anorganik tercampur sehingga proses daur ulang menjadi kurang optimal (Thio & Susilo, 2025). Oleh karena

itu, diperlukan suatu sistem otomatis yang mampu membantu proses identifikasi sampah secara lebih akurat dan konsisten.

Untuk menjawab permasalahan tersebut, penelitian ini mendasarkan diri pada landasan teori mengenai pemrosesan citra digital, kecerdasan buatan, serta arsitektur *deep learning*. CNN dipilih sebagai metode utama karena memiliki kemampuan unggul dalam mengekstraksi fitur visual (Novantara et al., 2025). Arsitektur MobileNetV2 digunakan sebagai model inti karena dirancang agar ringan dan efisien pada perangkat pintar (Faris et al., 2023).

Secara sistematis, usulan proses pemecahan masalah dalam sistem ini dideskripsikan melalui tiga tahapan utama, yaitu Data *Input*, Proses, dan *Output*. Pada tahap Data *Input*, sistem menerima aliran citra visual (*stream frame*) secara *real-time* yang ditangkap melalui lensa kamera *smartphone* pengguna. Selanjutnya, pada tahap Proses, citra yang masuk akan dinormalisasi dan direduksi resolusinya (*resize*) agar sesuai dengan standar arsitektur algoritma. Data tersebut kemudian diteruskan ke dalam model MobileNetV2 berformat TensorFlow Lite yang telah dilatih menggunakan metode *Transfer Learning* untuk melakukan ekstraksi fitur dan klasifikasi.

Terakhir, pada tahap *Output*, sistem memproyeksikan hasil identifikasi ke antarmuka layar *smartphone* dalam wujud teks label kategori ("Organik" atau "Anorganik") beserta persentase tingkat keyakinan model (*Confidence Score*).

Berdasarkan landasan teori dan penelitian terdahulu, penelitian ini mengimplementasikan model klasifikasi sampah organik dan anorganik menggunakan MobileNetV2 berbasis *Transfer Learning*. Model tersebut kemudian dioptimalkan dan dikonversi ke TensorFlow Lite sehingga mampu berjalan secara *real-time* pada perangkat Android. Luaran dari penelitian ini adalah model yang akurat, efisien, dan siap diintegrasikan ke dalam aplikasi pemilahan sampah sebagai solusi pendukung pengelolaan lingkungan yang lebih baik.

BAB III

METODOLOGI PENELITIAN

Bab ini menguraikan secara rinci langkah-langkah metodologis yang dilaksanakan dalam penelitian, mulai dari desain penelitian, instrumen yang digunakan, lokasi dan jadwal, objek penelitian, prosedur sistematis, hingga teknik analisis data untuk membangun dan mengevaluasi sistem klasifikasi sampah berbasis Android.

A. Desain Penelitian

Desain penelitian dirancang untuk memastikan bahwa penelitian ini dapat dilakukan secara terarah dan sistematis untuk menghasilkan kesimpulan yang valid.

1. Jenis Penelitian

Jenis penelitian yang digunakan adalah Penelitian Pengembangan atau *Research and Development (R&D)*. Sesuai dengan fokusnya, penelitian ini masuk dalam kategori Pengembangan Perangkat Lunak (*Software Development*). Penelitian ini berfokus pada pengembangan dan pengujian sebuah produk perangkat lunak baru, yaitu aplikasi *mobile* Android untuk klasifikasi sampah organik dan anorganik.

Model pengembangan yang digunakan dalam penelitian ini adalah Model Prototyping. Menurut Sommerville et al. (2011), pendekatan ini merupakan proses pengembangan perangkat lunak yang bersifat iteratif (berulang), di mana prototipe awal dibangun secara cepat untuk kemudian dievaluasi dan disempurnakan. Pendekatan ini dipilih karena memungkinkan prototipe aplikasi dievaluasi dan direvisi secara internal selama fase pengembangan hingga mencapai versi prototipe final yang memenuhi standar kriteria fungsional dan non-fungsional.

Evaluasi kinerja produk akhir dilakukan menggunakan pendekatan kuantitatif yang mencakup dua aspek, yaitu pengukuran metrik performa klasifikasi model menggunakan *Confusion Matrix* serta pengukuran kinerja komputasi aplikasi secara *real-time* berdasarkan latensi waktu inferensi.

2. Variabel Penelitian

Penelitian ini melibatkan tiga jenis variabel utama, di mana masing-masing variabel ditetapkan dan diukur dengan spesifikasi sebagai berikut:

a. Variabel Independen (Bebas/*Prediktor*)

Variabel independen adalah variabel yang dimanipulasi atau diterapkan oleh peneliti untuk menyelesaikan masalah. Variabel independen dalam penelitian ini adalah *Dataset* citra sampah yang digunakan sebagai *input* model MobileNetV2. Variasi karakteristik citra, seperti bentuk objek, sudut pengambilan gambar, kondisi pencahayaan, dan latar belakang, menjadi faktor yang memengaruhi kemampuan model dalam mengenali dan mengklasifikasikan sampah organik maupun anorganik.

b. Variabel Dependen (Terikat/*Respon*)

Variabel dependen adalah variabel yang diukur dan diamati sebagai akibat dari penerapan variabel independen. Variabel ini mencakup dua aspek kinerja, yaitu:

- 1) Metrik Kinerja Klasifikasi: Diukur secara kuantitatif dalam bentuk persentase (%) menggunakan instrumen *Confusion Matrix*. Nilai ini dihitung dari hasil evaluasi eksekusi model pada Data Uji (*Test Set*), dengan membandingkan ketepatan antara label hasil prediksi yang dikeluarkan model dengan label kelas aktual pada citra (mencakup Akurasi, Presisi, *Recall*, dan *F1-Score*).

- 2) Latensi Waktu Inferensi (*Inference Time*): Diukur secara kuantitatif dalam satuan milidetik (ms) untuk mengamati kecepatan komputasi *real-time* sistem di perangkat Android. Pengukuran dilakukan menggunakan fungsi pencatatan waktu internal sistem pada bahasa pemrograman Kotlin/Java. Waktu inferensi dihitung dari saat proses inferensi TensorFlow Lite mulai dijalankan hingga proses inferensi selesai, kemudian dikonversi ke satuan milidetik.

c. Variabel Kontrol (Pengendali)

Variabel kontrol adalah parameter yang dipertahankan konstan selama penelitian untuk memastikan validitas internal pengujian, sehingga hasil dari variabel dependen murni dipengaruhi oleh variabel independen tanpa adanya faktor luar. Variabel yang dikendalikan mencakup:

- 1) Spesifikasi Perangkat Keras Pengujian: Pengukuran performa komputasi dan latensi dikunci hanya menggunakan satu jenis *smartphone* yang sama dari awal hingga akhir, yaitu Infinix Note 40 (RAM 8GB, OS Android 15).
- 2) Dimensi *Input* Citra: Seluruh data citra, baik pada saat pelatihan maupun inferensi, diubah ukurannya (*resize*) secara konstan menjadi resolusi 224×224 piksel.
- 3) Parameter Pelatihan (*Hyperparameters*): Konfigurasi algoritma ditetapkan secara konstan menggunakan *Optimizer Adam*, *Learning Rate* bernilai 0.0001, ukuran *batch* (*batch size*) 16, dan iterasi maksimal sebanyak 20 *epoch*.
- 4) Distribusi *Dataset*: Rasio pembagian *dataset* primer dikunci pada proporsi yang konstan, yaitu 70% untuk Data Latih (*Training Set*), 20% untuk Data Validasi (*Validation Set*), dan 10% untuk Data Uji (*Test Set*). Proporsi pembagian ini diterapkan berdasarkan kaidah rasio optimal pemisahan data (Joseph, 2022)

guna memastikan algoritma memiliki asupan data latih yang memadai untuk mengenali pola, sekaligus menyisakan data uji independen untuk validasi kinerja yang objektif.

- 5) Arsitektur dan Metode Sistem: Penggunaan arsitektur dasar MobileNetV2 berbasis *Transfer Learning* (termasuk pembekuan bobot ImageNet dan penambahan *GlobalAveragePooling2D*, *Dropout* 0.3, serta *Dense* 2 neuron) dikunci sebagai perlakuan komputasi tunggal tanpa adanya komparasi dengan algoritma lain.

B. Instrumen Penelitian

Instrumen adalah alat atau prosedur yang digunakan untuk mengukur atau mengumpulkan data dalam penelitian ini. Instrumen yang digunakan terbagi menjadi beberapa komponen utama:

1. Perangkat Keras (*Hardware*)

a. Lingkungan Pelatihan (*Training Environment*)

Seluruh proses pengolahan data, perancangan, dan pelatihan model dilakukan secara lokal menggunakan perangkat keras (laptop/PC) dengan spesifikasi: Prosesor AMD Ryzen 7, RAM 16GB, dan GPU RTX 2050 untuk mengeksekusi komputasi model *Deep Learning*.

b. Lingkungan Implementasi (*Deployment Environment*)

Proses implementasi dan pengujian prototipe aplikasi Android dilakukan menggunakan *smartphone* Android *Infinix Note 40* dengan RAM 8GB dan OS Android 15 untuk mengukur kinerja *real-time*.

2. Perangkat Lunak (*Software*)

- a. Sistem Operasi: Windows 11 (digunakan pada lingkungan komputasi lokal) dan Android 15 (digunakan pada lingkungan implementasi *smartphone*).

- b. **Bahasa Pemrograman:** Python (untuk pelatihan *model*) dan Java/Kotlin (untuk pengembangan aplikasi Android).
- c. **Platform Pengembangan:** *Visual Studio Code* (VS Code) untuk pelatihan model dan Android Studio untuk membangun aplikasi native Android.
- d. **Framework & Library yang digunakan**
- 1) TensorFlow & Keras: *Framework* utama untuk membangun, melatih, dan mengevaluasi model *deep learning*.
 - 2) TensorFlow Lite (TFLite): *Library* untuk mengonversi dan menjalankan *model* yang telah dioptimalkan pada perangkat Android.
 - 3) Scikit-learn: Untuk evaluasi model, khususnya dalam pembuatan *classification report* dan *confusion matrix*.
 - 4) Pandas & NumPy: Untuk manipulasi dan persiapan data.
 - 5) Matplotlib & Seaborn: Untuk visualisasi data dan hasil penelitian.
 - 6) CameraX API: *Library* Android yang digunakan untuk mengakses *stream* kamera secara *real-time* dan efisien.

3. Dataset

a. **Sumber Data**

Data yang digunakan adalah data primer yang dikumpulkan melalui proses akuisisi data langsung di lingkungan pemukiman warga Desa Tulungrejo, Kecamatan Pare, Kabupaten Kediri, Jawa Timur, agar model mampu mengenali objek sampah dengan karakteristik nyata skala rumah tangga.

Proses pengambilan citra dilakukan dengan memperhatikan variasi sudut pengambilan (angle), pencahayaan, serta latar belakang (*background*) untuk meningkatkan keberagaman karakteristik data. Dokumentasi proses akuisisi data ditunjukkan pada Gambar 3.1.



Gambar 3. 1 Dokumentasi Proses Akuisisi **Data** Primer

Keterangan: Pengambilan citra sampah organik (kiri) dan sampah anorganik (kanan) menggunakan kamera *smartphone*.

b. Karakteristik Data

Citra diambil menggunakan perangkat bergerak (*smartphone*) dengan variasi sudut pengambilan (*angle*), pencahayaan, dan latar belakang (*background*) yang beragam. Format citra adalah .jpg/.png yang kemudian diubah ukurannya (*resize*) menjadi dimensi *input* standar model (224×224 piksel). Contoh citra sampah organik dan anorganik yang digunakan dalam penelitian ditunjukkan pada Gambar 3.2.

**Organik****Anorganik**

Gambar 3. 2 Contoh Data Input Citra Sampah Organik dan Anorganik

c. Kuantitas Data

Pengumpulan data ditetapkan sebanyak 200 citra per kategori (Organik dan Anorganik) dengan total keseluruhan 400 citra. Kategori organik terdiri atas objek dedaunan dan sisa makanan/buah, sedangkan kategori anorganik terdiri atas botol dan kemasan plastik. Meskipun kuantitas data primer ini relatif terbatas untuk skala pemodelan *deep learning* konvensional, validitas dan keandalan pelatihan tetap terjaga melalui penerapan metode *Transfer Learning* menggunakan *pre-trained weights* ImageNet serta integrasi teknik *online data augmentation* (rotasi, *flip* dan *zoom*). Strategi kombinasi ini secara teoretis efektif memperkaya variasi karakteristik data latih secara dinamis pada setiap *epoch*, meminimalkan risiko *overfitting*, serta mengoptimalkan kemampuan generalisasi model saat mengeksekusi proses inferensi secara *real-time* pada platform Android.

d. Pembagian Data

Dataset primer yang terkumpul terlebih dahulu diacak (shuffle) menggunakan bilangan acak dengan seed bernilai 42 untuk mengurangi potensi bias akibat urutan pengambilan citra. Selanjutnya, pembagian data dilakukan secara proporsional pada masing-masing kelas sehingga distribusi data organik dan anorganik tetap seimbang pada data *training*, *validation*, dan *testing*. Pembagian dilakukan secara proporsional menjadi tiga subset sebagai berikut:

- 1) Data Latih (70%): Berjumlah 280 citra untuk melatih model MobileNetV2
- 2) Data Validasi (20%): Berjumlah 80 citra untuk memantau kinerja model selama pelatihan dan memicu mekanisme *Early Stopping*.
- 3) Data Uji (10%): Berjumlah 40 citra baru sebagai instrumen evaluasi akhir yang objektif.

4. Analisis Hasil (Alat Ukur Evaluasi)

a. Pengujian Fungsional (*Black Box*)

Dilakukan untuk memvalidasi fungsionalitas inti aplikasi tanpa melihat struktur kode program dengan menjalankan skenario manual: (1) Membuka aplikasi, (2) Mengarahkan kamera ke objek sampah, (3) Memverifikasi secara visual bahwa aplikasi menampilkan label prediksi yang benar tanpa *crash*.

b. Pengujian Non-Fungsional (Kinerja):

1) Alat Ukur 1

confusion matrix (dan metrik turunan):

Digunakan untuk mengukur kinerja klasifikasi model secara kuantitatif berdasarkan nilai *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN) dengan persamaan sebagai berikut:

$$1) \text{ Akurasi: } \frac{TP + TN}{Total} \dots\dots\dots(3.1)$$

$$2) \text{ Presisi: } \frac{TP}{TP + FP} \dots\dots\dots(3.2)$$

$$3) \text{ Recall: } \frac{TP}{TP + FN} \dots \dots \dots (3.3)$$

$$4) \text{ F1-Score: } 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \dots \dots \dots (3.4)$$

2) Alat Ukur 2

Pengukuran Latensi (*Inference Time*):

Digunakan untuk mengukur kinerja *real-time* model di perangkat Android dalam satuan milidetik (ms). Pengukuran dilakukan di dalam kode aplikasi dengan memantau selisih waktu sebelum *frame* kamera dikirim ke TFLite Interpreter dan sesudah hasil prediksi divisualisasikan ke layar.

C. Tempat dan Jadwal Penelitian

1. Tempat Penelitian

Akuisisi data primer berupa pengambilan citra sampah dilakukan secara langsung di lingkungan permukiman warga Desa Tulungrejo, Kecamatan Pare, Kabupaten Kediri, Jawa Timur. Lokasi tersebut dipilih karena menyediakan objek penelitian yang sesuai dengan kebutuhan penelitian, yaitu sampah domestik organik dan anorganik yang dihasilkan dari aktivitas sehari-hari masyarakat. Sementara itu, seluruh proses komputasi, pengembangan aplikasi, serta pelatihan model dilaksanakan menggunakan perangkat pribadi milik peneliti.

2. Jadwal Penelitian

Penelitian ini dilaksanakan dalam kurun waktu 6 (enam) bulan, dimulai dari Januari 2026 hingga Juni 2026. Jadwal pelaksanaan kegiatan penelitian dirinci dalam bentuk *Gantt Chart* pada Tabel 3.1, yang mencakup alokasi waktu per minggu untuk setiap tahapan kegiatannya yang selaras dengan prosedur penulisan model *prototyping*.

Tabel 3. 1 Jadwal Penelitian

Kegiatan	Bulan ke-1	Bulan ke-2	Bulan ke-3	Bulan ke-4	Bulan ke-5	Bulan ke-6
Studi Literatur & Analisis						
Pengumpulan & Persiapan Data						
Perancangan & Pelatihan Model						
Pengembangan Aplikasi Android						
Pengujian & Evaluasi						
Penyusunan Laporan						

D. Objek Penelitian / Subjek Penelitian

1. Analisis Kebutuhan Sistem

a. Kebutuhan Fungsional

- 1) Sistem harus dapat mengakses kamera perangkat Android secara *real-time*.
- 2) Sistem harus dapat menangkap *stream* video dari kamera secara terus-menerus.
- 3) Sistem harus mampu memproses setiap *frame* video menggunakan model TFLite.
- 4) Sistem harus menampilkan hasil klasifikasi (label 'Organik' atau 'Anorganik') sebagai *overlay* teks di layar.
- 5) Sistem harus menampilkan skor probabilitas (*confidence score*) prediksi.

b. Kebutuhan Non-Fungsional

- 1) Kinerja (*Latensi*): Sistem harus dapat memberikan prediksi secara *real-time* dengan waktu inferensi yang responsif agar terasa instan bagi pengguna tanpa jeda (*lag*).

- 2) Kinerja (*Akurasi*): Sistem harus mampu mencapai tingkat akurasi klasifikasi yang memadai dan stabil dalam mengenali jenis sampah.
- 3) Kegunaan (*Usability*): Aplikasi harus mudah digunakan, di mana pengguna hanya perlu mengarahkan kamera tanpa interaksi tombol yang rumit.

c. Kebutuhan Pengguna

Pengguna menginginkan alat bantu yang mampu mengidentifikasi jenis sampah dengan cepat dan instan tanpa perlu menyentuh fisik objek sampah secara langsung.

d. Kebutuhan Data

Jenis data berupa data non-struktural spesifik citra digital berformat .jpg atau .png berjumlah 400 citra (200 organik dan 200 anorganik), yang kemudian diperkaya melalui teknik augmentasi.

2. Objek Penelitian


Objek yang diteliti dan dianalisis dalam penelitian ini adalah:

a. Objek Utama: Model Machine Learning (Model Klasifikasi Citra)

1) Arsitektur Model MobileNetV2 Berbasis Transfer Learning:

Model yang digunakan dalam penelitian ini adalah MobileNetV2 berbasis *Transfer Learning* dengan bobot awal (*pre-trained weights*) ImageNet. Lapisan dasar MobileNetV2 digunakan sebagai *feature extractor* dengan parameter *trainable=False* sehingga bobot hasil pelatihan ImageNet tidak diperbarui kembali selama proses pelatihan. Selanjutnya ditambahkan lapisan *GlobalAveragePooling2D*, *Dropout* sebesar 0,3, dan *Dense Output Layer* dengan 2 neuron menggunakan fungsi aktivasi *Softmax* untuk menghasilkan klasifikasi sampah Organik dan Anorganik. Penggunaan MobileNetV2 dalam penelitian ini mengacu pada karakteristik arsitektur yang telah dibahas pada Bab II, yaitu memanfaatkan mekanisme *Depthwise*

Separable Convolution, *Inverted Residual Block*, dan *Linear Bottleneck* untuk menghasilkan model yang efisien pada perangkat bergerak. Arsitektur model yang digunakan dalam penelitian ini ditunjukkan pada Gambar 3.3.



Gambar 3.3 Arsitektur Model MobileNetV2 Berbasis Transfer Learning

Gambar 3.3 menunjukkan susunan lapisan model yang terdiri atas MobileNetV2 sebagai *feature extractor*, *GlobalAveragePooling 2D*, *Dropout*, dan *Dense Output Layer* dengan fungsi aktivasi Softmax. Arsitektur ini memungkinkan proses klasifikasi dijalankan secara *offline* pada perangkat Android melalui TensorFlow Lite tanpa memerlukan koneksi internet maupun server eksternal.

- 2) Alasan & Relevansi: MobileNetV2 dipilih karena arsitekturnya dirancang khusus (ringan dan efisien) untuk komputasi perangkat *mobile* yang memiliki memori terbatas, sehingga sangat relevan dengan tujuan penelitian untuk klasifikasi *real-time* di *smartphone*
- 3) Data yang Digunakan

Model dilatih menggunakan *Dataset* primer dengan distribusi yang telah dijelaskan pada Tabel 3.2.

Tabel 3. 2 Distribusi Dataset Sampah

Set Data	Persentase	Jumlah Sampel
----------	------------	---------------

Data Latih (Training)	70%	280
Data Validasi (Validation)	20%	80
Data Uji (Test)	10%	40
Total	100%	400

Keterangan: Jumlah di atas merupakan alokasi pembagian data primer sebelum proses augmentasi.

b. **Objek Sekunder: Sistem/Aplikasi Perangkat Lunak**

- 1) Detail: Prototipe aplikasi *native* berbasis Android (Aplikasi Klasifikasi Sampah *Real-time*).
- 2) Alasan & Relevansi: Dipilih sebagai wadah implementasi akhir (*deployment*) dari model MobileNetV2. Aplikasi ini relevan dengan masalah penelitian karena berfungsi sebagai antarmuka (*interface*) utama yang memungkinkan pengguna rumah tangga untuk langsung memanfaatkan teknologi AI melalui kamera *smartphone*.

3. Subjek Penelitian


Pihak atau sumber yang memberikan data untuk dianalisis dalam penelitian ini bukanlah subjek manusia (pengguna). Mengingat fokus penelitian adalah analisis teknis eksperimental perangkat lunak, maka Subjek penelitian ini adalah *dataset* citra sampah organik dan anorganik yang digunakan sebagai sumber data dalam proses pelatihan, validasi, dan pengujian model MobileNetV2. *Dataset* terdiri atas 400 citra primer yang diperoleh melalui proses akuisisi data secara langsung di lingkungan pemukiman warga wilayah Kediri, dengan rincian 200 citra sampah organik dan 200 citra sampah anorganik.

Data tersebut digunakan untuk melatih model, mengevaluasi kemampuan klasifikasi, serta mengukur performa model berdasarkan nilai akurasi, presisi, *recall*, dan *F1-score*.

E. Prosedur Penelitian

Penelitian ini dilaksanakan menggunakan pendekatan Model *Prototyping*. Metode ini dipilih karena sangat sesuai untuk pengembangan aplikasi yang berfokus pada penyempurnaan fungsionalitas inti, yaitu klasifikasi *real-time* berbasis pemrosesan data multimedia (citra dan *stream* video). Model ini bersifat iteratif (berulang), di mana peneliti membangun versi awal sistem, mengevaluasinya secara teknis, dan kemudian "mundur" (*backward*) untuk memperbaiki dan menyempurnakan sistem berdasarkan hasil evaluasi tersebut sebelum ditetapkan sebagai produk akhir.

Alur penelitian ini diilustrasikan pada Gambar 3.4.



Gambar 3. 4 Alur Penelitian Menggunakan Pendekatan Model Prototyping

Siklus utama dalam prosedur penelitian ini adalah sebagai berikut:

1. Analisis Kebutuhan dan Pengumpulan Data

Tahap awal untuk mengidentifikasi kebutuhan fungsional (aplikasi Android *real-time*) dan spesifikasi data. Pada tahap ini, *dataset* citra sampah primer di lapangan dikumpulkan dan diberikan pelabelan kelas (*labeling*) sesuai dengan ketentuan distribusi data.

2. Desain Cepat dan Bangun Prototipe Awal v1

- a. Melakukan prapemrosesan (*preprocessing*) dan augmentasi data dasar.
- b. Merancang arsitektur MobileNetV2 (*Transfer Learning*) dan melakukan pelatihan Prototipe Model v1 secara komputasi lokal menggunakan perangkat keras yang telah ditetapkan pada instrumen penelitian.
- c. Membangun antarmuka (*User Interface*) aplikasi Android mendasar yang mengintegrasikan CameraX API untuk menjalankan model.

3. Evaluasi Prototipe (Pengujiian)

Model v1 dievaluasi kinerjanya menggunakan *test set* melalui instrumen *Confusion Matrix* untuk mengukur ketepatan klasifikasi. Selanjutnya, model dikonversi ke format *.tflite* dan ditanamkan ke dalam aplikasi *smartphone* untuk menguji stabilitas fungsionalitas kamera serta merekam rata-rata kecepatan *inference time*.

4. Identifikasi Kekurangan dan Perbaikan

- a. Umpan Balik (*Feedback*): Hasil pengujian prototipe awal dianalisis secara internal untuk mendeteksi celah kekurangan, seperti tingkat akurasi yang belum optimal atau adanya gejala *lag* pada kamera.
- b. Perbaikan (*Refine*): Berdasarkan umpan balik tersebut, dilakukan modifikasi teknis secara langsung, baik melalui penyesuaian nilai *hyperparameter* pelatihan model (seperti *learning rate* dan kapasitas *epoch*) maupun optimasi baris kode pemrograman aplikasi. Prototipe

disempurnakan hingga mencapai standar fungsionalitas yang stabil dan ditetapkan sebagai versi prototipe final.

5. Produk Final dan Penyusunan Laporan

Setelah prototipe final disetujui dan dipastikan berjalan dengan baik secara fungsional maupun non-fungsional, sistem dianggap selesai. Hasil pengujian dari prototipe final inilah yang kemudian diekstraksi datanya untuk dianalisis dan disusun ke dalam laporan penelitian secara utuh.

F. Teknik Analisis Data

Bagian ini merinci teknik-teknik pengolahan, perancangan, dan interpretasi data matematis yang digunakan untuk menyelesaikan masalah penelitian.

1. Desain Sistem


Desain Sistem adalah proses merancang arsitektur, komponen, antarmuka, dan data untuk sistem perangkat lunak yang dibangun. Bagian ini dibagi menjadi tiga, yaitu:

a. Arsitektur Sistem (*System Architecture*)

Metodologi perancangan arsitektur yang digunakan adalah Analisis dan Desain Berorientasi Objek atau *Object-Oriented Analysis and Design* (OOAD). Pendekatan ini dipilih karena paradigma pemrograman yang diterapkan pada tahap implementasi adalah *Object Oriented Programming* (OOP), yaitu pengembangan aplikasi *native* Android menggunakan bahasa Java/Kotlin di mana data dan perilaku dibungkus secara terstruktur menjadi satu unit kelas dan objek.

Arsitektur sistem menggambarkan alur pemrosesan data pada aplikasi klasifikasi sampah berbasis Android, mulai dari proses pengambilan citra menggunakan CameraX API, tahap *preprocessing*, proses inferensi menggunakan model MobileNetV2 berbasis TensorFlow Lite, hingga penampilan hasil klasifikasi pada antarmuka

aplikasi. Arsitektur sistem yang digunakan dalam penelitian ini ditunjukkan pada Gambar 3.5.




Gambar 3.5 Arsitektur Sistem Klasifikasi Sampah Berbasis Android

Berdasarkan Gambar 3.5, pengguna mengarahkan kamera perangkat Android ke objek sampah yang akan diidentifikasi. Citra yang diperoleh diproses melalui tahap *preprocessing* sebelum diklasifikasikan menggunakan model MobileNetV2 TensorFlow Lite. Hasil inferensi berupa label kelas dan *confidence score* kemudian ditampilkan secara *real-time* pada antarmuka aplikasi Android. Arsitektur ini memungkinkan seluruh proses klasifikasi berjalan secara *offline* pada perangkat tanpa memerlukan koneksi internet maupun server eksternal.

Diagram UML (*Unified Modelling Language*) yang digunakan untuk memodelkan sistem adalah sebagai berikut:


1) Use Case Diagram



Gambar 3. 6 Use Case Diagram

Gambar 3.6 menunjukkan interaksi fungsional utama sistem. Terdapat satu Aktor yaitu "Pengguna" yang dapat melakukan *use case* utama "Melakukan Klasifikasi Sampah". *Use case* ini mewajibkan (<<include>>) dua *use case* lainnya agar dapat berjalan: "Mengakses Kamera" (sebagai *Input*) dan "Melihat Hasil Klasifikasi" (sebagai *Output*).


2) Activity Diagram



Gambar 3. 7 Activity Diagram

Gambar 3.7 merinci alur kerja (*workflow*) *real-time* sistem. Alur dimulai saat "Pengguna" "Buka Aplikasi". "Sistem Klasifikasi" kemudian melakukan "Inisialisasi Kamera". Sistem akan "Cek Kamera"; jika error, sistem "Tampilkan Error". Jika kamera tersedia, sistem "Tampilkan Preview Kamera" (*viewfinder*). Dari sini, sistem masuk ke dalam loop paralel: "Pengguna" menyediakan "Tangkap Citra / Realtime Input" yang terus-menerus diterima oleh sistem, yang kemudian melakukan "Preprocessing Gambar", "Klasifikasi CNN", dan "Tampilkan Hasil ke Pengguna", sebelum loop kembali untuk memproses *frame* berikutnya.

3) **Sequence Diagram**




Gambar 3. 8 Sequence Diagram

Gambar 3.8 menunjukkan alur interaksi objek dimulai saat Pengguna membuka aplikasi. Objek Kamera mengirimkan data citra melalui *captureImage()* ke SystemController, yang kemudian diproses lewat *preprocess()*. Citra diklasifikasikan oleh CNN Model menggunakan *predict()*, yang mengembalikan objek Result. Hasil ini diformat oleh SystemController dengan *formatResult()* dan ditampilkan ke Pengguna melalui objek Output menggunakan *showResult()*.

b. Desain Database (*Database Design / Struktur Kelas*)

Sistem klasifikasi *real-time* ini tidak menyimpan citra secara persisten ke dalam *Database Management System* (DBMS), melainkan memproses *stream* citra digital secara lokal di memori perangkat. Sesuai dengan pendekatan OOAD untuk data yang tidak disimpan di DBMS, struktur penyimpanan variabel dan objek direpresentasikan menggunakan *Class Diagram*:

45




Gambar 3. 9 Class Diagram

Gambar 3.9 mendefinisikan struktur kelas OOP.

- 1) **Camera**: Memiliki metode *startPreview()* dan *captureImage()* untuk mengambil data aliran (*stream*) piksel langsung dari perangkat keras kamera.
- 2) **SystemController**: Bertindak sebagai pengontrol memori utama yang mengeksekusi alur data melalui metode *preprocess()*, *classify()*, dan *sendResult()*.
- 3) **CNNModel**: Membungkus logika model dengan atribut lokasi *modelPath* untuk memuat file model dan variabel *inferenceTime* untuk mencatat waktu komputasi, serta metode *loadModel()* dan *predict()*.
- 4) **Result**: Objek data (*data class*) yang ditugaskan khusus untuk menampung *value* label klasifikasi dan skor probabilitasnya (*confidence*).
- 5) **Output**: Objek *UI* untuk me *render* hasil prediksi secara langsung ke layar gawai menggunakan metode *showResult()*.

c. Desain Antarmuka (UI/UX)

- 1) Menu *Home*



Gambar 3. 10 Desain Menu Home

Gambar 3. 10 menunjukkan rancangan layar pembuka (*form input/landing page*) aplikasi. Ditampilkan judul “Pengenalan Sampah” dan ikon kamera sebagai representasi fungsi pemindaian. Tersedia satu tombol aksi “Mulai” untuk memicu proses inisialisasi kamera dan membawa pengguna menuju halaman klasifikasi utama.

2) Menu Klasifikasi *Real-time*

Pengenalan Sampah



Terdeteksi: Sampah Anorganik

Gambar 3. 11 Desain Menu **Klasifikasi**

Gambar 3. 11 menampilkan **rancangan layar** (*form output*) saat proses identifikasi berjalan. Memuat antarmuka *viewfinder* kamera dengan teks *overlay* dinamis di bagian bawah. Teks ini bertugas menampilkan hasil pemrosesan data (misal: “Terdeteksi: Sampah Anorganik”) secara *real-time* tanpa interaksi tambahan dari pengguna.

2. Simulasi Proses Penyelesaian Masalah

Tahapan ini menyimulasikan perhitungan manual dan alur algoritma MobileNetV2 yang digunakan untuk menyelesaikan masalah klasifikasi.

a. Data Input dan Preprocessing Data

- 1) Deskripsi Data *Input*: *Dataset* yang diproses adalah citra sampah organik dan anorganik berformat JPG/PNG dengan dimensi bervariasi, yang dikumpulkan melalui proses akuisisi data primer.
- 2) *Preprocessing Data*

- a) *Resize*

Ukuran citra diubah menjadi dimensi *input* standar MobileNetV2 yaitu 224×224 piksel.

Berdasarkan persamaan (2.1), total elemen piksel yang diproses sebagai *input* adalah:

$$224 \times 224 \times 3 = 150.528 \text{ elemen}$$

- b) Normalisasi

Rentang nilai intensitas piksel diubah dari rentang asal (0-255) menjadi (0-1) sesuai dengan persamaan (2.2). Tahapan ini dilakukan untuk mempercepat proses konvergensi gradien pada model selama pelatihan berlangsung:

- c) *Augmentasi Data*

Untuk memperkaya variasi data latih dan mencegah terjadinya *overfitting* pada model (Barus et al., 2025), diterapkan teknik manipulasi citra secara *online* menggunakan *ImageDataGenerator* yang mencakup rotasi (maksimal 10°), pergeseran posisi (*width & height shift* 0.1), pergeseran kemiringan (*shear* 0.05), perbesaran (*zoom* 0.1), dan pembalikan citra secara horizontal.

- d) *Pembagian Data*

Dataset yang telah melalui tahap *preprocessing* kemudian dibagi secara proporsional untuk kebutuhan pelatihan dan evaluasi model, dengan rasio pembagian sebagai berikut:

- 1) Data Latih (*Training Set*): 70%
- 2) Data Validasi (*Validation Set*): 20%
- 3) Data Uji (*Test Set*): 10%

b. **Proses Pengolahan Data**

Proses pengolahan data dilakukan menggunakan model MobileNetV2 berbasis *Transfer Learning* yang arsitekturnya telah dijelaskan pada bagian Objek Penelitian. Model dilatih menggunakan dataset yang telah melalui tahap *preprocessing* dan augmentasi untuk mempelajari karakteristik citra sampah organik dan anorganik.

Sesuai dengan alur pemrosesan algoritma *Deep Learning*, model dilatih melalui tahapan berikut:

- 1) Inisialisasi Parameter Awal: Model diinisialisasi menggunakan *Optimizer Adam* dengan *learning rate* 0.0001, fungsi *loss Sparse Categorical Crossentropy*, dan ukuran *batch (batch size)* sebesar 16. Penggunaan *batch size* sebesar 16 ditetapkan untuk memberikan pembaruan bobot (*weight updates*) yang lebih adaptif pada setiap iterasi, sehingga model mampu mencapai konvergensi yang lebih stabil serta terhindar dari kondisi di mana model berhenti meningkatkan akurasi akibat terjebak pada karakteristik fitur yang terbatas selama proses pelatihan.
- 2) Iterasi (*Epoch*): Selama proses iterasi berlangsung, kumpulan data citra dimasukkan (*forward pass*) ke dalam jaringan. Algoritma mengekstraksi fitur spasial, menghitung nilai kesalahan (*loss*) dari prediksi klasifikasi, kemudian memperbarui bobot pada lapisan keluaran melalui *backward pass* agar pengenalan pola sampah Organik dan Anorganik menjadi semakin presisi pada iterasi berikutnya.
- 3) Kriteria Berhenti (Konvergensi): Proses iterasi (*epoch*) diatur maksimal sebanyak 20 *epoch*. Untuk menghentikan algoritma secara optimal dan mencegah *overfitting*, diterapkan fungsi

50

callbacks berupa *Early Stopping* yang akan menghentikan pelatihan secara otomatis jika tidak ada perbaikan nilai *validation loss* (*val_loss*) selama 5 *epoch* berturut-turut (*patience* = 5, *min_delta* = 0.001). Jika pelatihan berhenti, sistem akan secara otomatis memulihkan bobot model terbaik (*restore_best_weights*). Selain itu, diterapkan *Model Checkpoint* untuk menyimpan model terbaik secara otomatis ke dalam format .keras berdasarkan evaluasi nilai *validation loss* terendah selama proses pelatihan berlangsung.

c. Data Output dan Evaluasi

1) Data Output

Keluaran (*output*) utama yang dihasilkan oleh algoritma MobileNetV2 dalam sistem ini berupa hasil klasifikasi citra sampah. Secara spesifik, *output* direpresentasikan dalam dua bentuk, yaitu:

- Label Prediksi: Kategori kelas sampah yang terdeteksi, yaitu "Organik" atau "Anorganik".
- Skor Probabilitas (*Confidence Score*): Nilai keyakinan model (dalam persentase 0% - 100%) terhadap hasil klasifikasi tersebut yang dihitung melalui fungsi aktivasi Softmax.

2) Evaluasi

Evaluasi dilakukan untuk mengukur kinerja luaran dari model yang telah dilatih dan diimplementasikan.

a) Metrik Evaluasi Non-Fungsional

Matrik evaluasi yang digunakan untuk mengukur kinerja algoritma dalam penelitian ini terbagi menjadi dua aspek:

- Metrik Kinerja Klasifikasi: Menggunakan *Confusion Matrix* yang terdiri dari metrik Akurasi, Presisi, *Recall*, dan *F1-Score*.

- 2) Metrik Kinerja **Sistem** (*Real-time*): Menggunakan pengukuran Latensi waktu inferensi (*Inference Time*) dalam satuan milidetik (ms).

b) Simulasi Perhitungan Metrik Evaluasi

Sebagai contoh simulasi (*dummy*) perhitungan sebelum sistem diuji secara aktual di Bab IV, diasumsikan model diuji pada 40 sampel citra (20 Organik, 20 Anorganik). Distribusi hasil evaluasi prediksi tersebut direpresentasikan ke dalam bentuk *Confusion Matrix* seperti pada Tabel 3.3 berikut:

Tabel 3. 3 Simulasi *Confusion Matrix*

Kategori Aktual	Prediksi: Organik	Prediksi: Anorganik
Aktual: Organik	True Positive (TP) = 18	False Negative (FN) = 2
Aktual: Anorganik	False Positive (FP) = 1	True Negative (TN) = 19

Catatan Metodologi: Mengingat penelitian ini menggunakan klasifikasi biner (dua kelas), maka simulasi perhitungan metrik spesifik di bawah ini ditinjau dari Kelas Organik sebagai kelas positif target utama sistem.

1) Akurasi (*Accuracy*)

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} = \frac{18+19}{18+19+1+2} = \frac{37}{40} = 0,925 \text{ (92,5\%).}$$

Interpretasi: Secara keseluruhan, algoritma mampu mengklasifikasikan jenis sampah dengan tepat sebanyak 92,5% dari total pengujian.

2) Presisi (*Precision*)

$$\text{Presisi} = \frac{TP}{TP+FP} = \frac{18}{18+1} = \frac{18}{19} = 0,947 \text{ (94,7\%).}$$

Interpretasi: Dari seluruh sampah yang diprediksi

sebagai Organik oleh sistem, 94,7% di antaranya benar-benar sampah Organik.

3) *Recall (Sensitivitas)*

$$Recall = \frac{TP}{TP+FN} = \frac{18}{18+2} = \frac{18}{20} = 0,90 \text{ (90\%).}$$

Interpretasi: Dari keseluruhan aktual sampah Organik yang ada, sistem mampu mendeteksi dan mengenalinya kembali sebesar 90%.

4) *F1-Score*

$$F1-Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} = 2 \times \frac{0,947 \times 0,90}{0,947 + 0,90} = 2 \times \frac{0,8523}{1,847} = 0,923 \text{ (92,3\%).}$$

Interpretasi: Keseimbangan harmonik antara tingkat ketepatan (presisi) dan tingkat sensitivitas (*recall*) model berada di angka 92,3%.

5) *Latensi Inferensi (Inference Time)*

Latensi Inferensi = 5145,0 ms (waktu selesai) - 5000,0 ms (waktu mulai) = 145,0 ms.

Interpretasi: Kecepatan pemrosesan satu citra dari *input* hingga *output* memakan waktu 145,0 milidetik.

c) Analisis Performa

Berdasarkan simulasi perhitungan, model menunjukkan indikasi performa yang baik. Nilai Presisi (94,7%) yang lebih tinggi dibandingkan *Recall* (90%) mengindikasikan bahwa model memiliki ketepatan yang kuat dalam memprediksi sampah Organik (minim *False Positive*), meskipun terdapat sedikit kelemahan di mana model terkadang masih melewatkan objek sampah Organik sebagai Anorganik (*False Negative*). Berdasarkan simulasi, latensi 145 ms menunjukkan bahwa model berpotensi memenuhi kebutuhan aplikasi *real-time* karena berada di bawah batas waktu ideal gawai Android.

BAB IV

HASIL DAN PEMBAHASAN

A. Hasil Penelitian

1. Implementasi Desain Sistem

a. Implementasi Lembar Kerja

Halaman *home* aplikasi klasifikasi sampah berbasis Android digunakan sebagai tampilan awal ketika aplikasi dijalankan. Halaman ini berfungsi untuk mempermudah pengguna dalam mengakses fitur klasifikasi sampah. Implementasi halaman *home* aplikasi ditunjukkan pada Gambar 4.1.



Gambar 4.1 Halaman Home Aplikasi

Halaman klasifikasi digunakan untuk melakukan proses identifikasi sampah secara *real-time* menggunakan kamera *smartphone*. Implementasi halaman klasifikasi dan hasil prediksi ditunjukkan pada Gambar 4.2.



Gambar 4. 2 Halaman Klasifikasi dan Hasil Prediksi

Sistem akan memproses citra menggunakan model MobileNetV2 yang telah dikonversi ke format TensorFlow Lite. TensorFlow Lite digunakan karena mampu mengoptimalkan model *deep learning* agar dapat berjalan lebih ringan dan responsif pada perangkat mobile. Hasil klasifikasi ditampilkan secara langsung pada halaman yang sama

berupa kategori sampah organik atau anorganik beserta *confidence score* dari hasil prediksi model.

b. Keterkaitan Antar Lembar Kerja

Keterkaitan antarmuka halaman pada aplikasi klasifikasi sampah organik dan anorganik dirancang secara sistematis agar seluruh alur operasi dapat berjalan terstruktur. Siklus penggunaan aplikasi dimulai dari halaman *home (landing page)* sebagai menu awal bagi pengguna. Melalui halaman ini, sistem akan menginisialisasi pustaka internal sebelum mengarahkan pengguna menuju halaman klasifikasi utama untuk memulai proses identifikasi sampah secara *real-time* memanfaatkan lensa kamera *smartphone*.

Pada halaman klasifikasi, aliran bingkai gambar (*stream frame*) yang diperoleh dari penangkapan kamera akan dieksekusi secara langsung oleh model MobileNetV2 berformat TensorFlow Lite yang telah tertanam di dalam memori lokal Android. Hasil dari kalkulasi fungsi aktivasi Softmax tersebut kemudian diproyeksikan secara instan pada halaman yang sama berupa teks *overlay* yang memuat label kategori sampah ("Organik" atau "Anorganik") beserta persentase skor tingkat keyakinannya (*confidence score*).

Integrasi keterkaitan antar komponen antarmuka ini memastikan seluruh proses komputasi berjalan secara berurutan, dinamis, dan responsif, mulai dari fase inisialisasi perangkat keras kamera (*input*), ekstraksi fitur matriks citra (proses), hingga visualisasi hasil prediksi (*output*). Alur satu halaman (*single-page execution*) yang sederhana ini dirancang untuk memangkas latensi sistem sehingga memudahkan masyarakat dalam memilah sampah domestik secara cepat, praktis, dan efisien.

2. Pengujian Fungsional

Pengujian fungsional dilakukan untuk memastikan seluruh fitur pada aplikasi klasifikasi sampah organik dan anorganik dapat berjalan sesuai dengan fungsi yang telah dirancang. Pengujian dilakukan menggunakan metode black box testing dengan menguji fitur utama pada aplikasi Android.

Tabel 4. 1 Pengujian Fungsional

No	Nama Fitur	Skenario Pengujian	Hasil yang Diharapkan	Hasil
1	Halaman Home	Membuka aplikasi	Halaman utama aplikasi tampil	Berhasil
2	Akses Kamera	Menekan tombol klasifikasi	Kamera <i>smartphone</i> dapat diakses	Berhasil
3	Klasifikasi Sampah	Mengarahkan kamera ke objek sampah	Sistem dapat melakukan klasifikasi sampah	Berhasil
4	Hasil Prediksi	Proses klasifikasi selesai dilakukan	Sistem menampilkan kategori dan <i>confidence score</i>	Berhasil

Berdasarkan hasil pengujian fungsional pada Tabel 4.1, seluruh fitur utama aplikasi berhasil berjalan sesuai dengan fungsi yang telah dirancang. Hal tersebut menunjukkan bahwa aplikasi mampu melakukan proses klasifikasi sampah dengan baik pada perangkat Android.

3. Pengujian Non-Fungsional

a. Dataset dan Preprocessing

Sebelum dilakukan proses pelatihan model, dataset terlebih dahulu melalui tahap preprocessing. Dataset yang digunakan pada penelitian ini terdiri dari dua kategori sampah, yaitu sampah organik dan sampah anorganik. Pengambilan dataset dilakukan menggunakan

kamera *smartphone* dengan variasi sudut pengambilan gambar, pencahayaan, dan latar belakang objek.

Pada tahap *preprocessing* dilakukan proses *resize* citra menjadi ukuran 224×224 piksel serta normalisasi nilai piksel agar sesuai dengan kebutuhan input model MobileNetV2.

Selain itu, penelitian ini menerapkan metode *online augmentation* selama proses pelatihan berlangsung. Teknik augmentasi dilakukan secara *real-time* untuk meningkatkan variasi data pelatihan sehingga model dapat mengenali objek dengan lebih baik.



Gambar 4. 3 Dataset Sampah Organik dan Anorganik

Tabel 4. 2 Distribusi Dataset

Kategori Sampah	Jumlah Data
Organik	200
Anorganik	200
Total	400

Dataset kemudian dibagi menjadi data *training*, *validation*, dan *testing* menggunakan rasio 70:20:10. Pembagian dataset dilakukan untuk proses pelatihan dan evaluasi model.

Tabel 4. 3 Pembagian Dataset

Dataset	Jumlah
Training	280
Validation	80
Testing	40

Berdasarkan pembagian *dataset* pada Tabel 4.3, sebagian besar data digunakan pada proses pelatihan model agar model mampu mempelajari pola data dengan baik, sedangkan data *validation* dan *testing* digunakan untuk mengevaluasi performa model.

b. Pelatihan dan Evaluasi Model


Proses pelatihan model dilakukan menggunakan arsitektur MobileNetV2 berbasis *Transfer Learning* dengan *framework* TensorFlow dan Keras. Model dilatih menggunakan data hasil *preprocessing* dan *online augmentation* yang diterapkan untuk menghasilkan variasi data latih selama proses pelatihan.

Pada implementasinya, lapisan dasar MobileNetV2 yang telah dilatih menggunakan *dataset* ImageNet digunakan sebagai *feature extractor* dengan parameter *trainable* = *False*. Selanjutnya ditambahkan lapisan *GlobalAveragePooling2D*, *Dropout* sebesar 0,3, dan *Dense Output Layer* dengan 2 neuron menggunakan fungsi aktivasi *Softmax* untuk menghasilkan klasifikasi sampah organik dan anorganik. Arsitektur tersebut kemudian dikonversi ke format TensorFlow Lite agar dapat dijalankan secara efisien pada perangkat Android.

Pada proses pelatihan digunakan *optimizer* Adam dengan fungsi aktivasi *Softmax* pada lapisan keluaran (*output layer*) untuk melakukan klasifikasi dua kategori sampah, yaitu organik dan anorganik.

Model dilatih menggunakan *batch size* 16 selama 20 *epoch*. Penggunaan *optimizer* Adam membantu mempercepat proses konvergensi model sehingga pelatihan dapat berjalan lebih efektif.

Grafik *accuracy* dan *loss* digunakan untuk melihat performa model selama proses *training* dan *validation*. Grafik hasil pelatihan model ditunjukkan pada Gambar 4.4.



Gambar 4. 4 Grafik Accuracy dan Loss


Berdasarkan hasil pelatihan, model menunjukkan peningkatan *accuracy* dan penurunan *loss* yang stabil selama proses *training* dan *validation*. Hal tersebut menunjukkan bahwa model mampu mempelajari pola data dengan baik serta tidak mengalami penurunan performa yang signifikan selama proses pelatihan.

Perbedaan nilai *accuracy* pada data *training* dan *validation* yang tidak terlalu jauh menunjukkan bahwa model tidak mengalami *overfitting* yang signifikan selama proses pelatihan.

Penerapan *online augmentation* digunakan untuk meningkatkan variasi data pelatihan sehingga berpotensi membantu kemampuan generalisasi model terhadap variasi objek sampah yang berbeda.

Evaluasi model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* untuk mengetahui performa model dalam melakukan klasifikasi sampah.

Sebelum dilakukan perhitungan metrik evaluasi berupa *precision*, *recall*, dan *f1-score*, performa model terlebih dahulu dianalisis menggunakan *confusion matrix*. *Confusion matrix* digunakan untuk melihat detail perbandingan antara kelas aktual objek sampah dengan hasil prediksi yang dilakukan oleh model MobileNetV2. Berdasarkan total data *testing* sebanyak 40 sampel yang terbagi rata ke dalam kelas organik dan anorganik, visualisasi *confusion matrix* hasil pengujian ditunjukkan pada Gambar 4.5.



Gambar 4. 5 *Confusion Matrix* Klasifikasi Sampah

Berdasarkan Gambar 4.5, model menunjukkan kemampuan pemisahan fitur yang sangat baik. Dari total 20 data aktual sampah anorganik, model berhasil memprediksi seluruhnya secara tepat sebagai anorganik tanpa adanya kesalahan klasifikasi. Sementara itu, dari 20 data aktual sampah organik, model berhasil memprediksi 19 sampel dengan benar sebagai organik, dan terdapat 1 sampel yang mengalami salah klasifikasi menjadi sampah anorganik. Kesalahan

prediksi yang minor pada 1 sampel kelas organik ini menghasilkan nilai akurasi akhir model sebesar 97.5%. Berdasarkan matriks tersebut, nilai evaluasi model secara detail per kelas serta performa rata-ratanya dapat dijabarkan pada Tabel 4.4 berikut.

Tabel 4. 4 Hasil Evaluasi Klasifikasi Model MobileNetV2

Kelas / Metrik	Precision	Recall	F1-Score	Support
Anorganik	0.952	1.000	0.976	20
Organik	1.000	0.950	0.974	20
Accuracy			0.975	40
Macro Avg	0.976	0.975	0.975	40
Weighted Avg	0.976	0.975	0.975	40

Berdasarkan hasil evaluasi rincian *Classification Report* pada Tabel 4.4, model MobileNetV2 yang diintegrasikan dengan metode *online augmentation* mampu menghasilkan performa klasifikasi yang sangat tinggi dengan nilai akurasi global (*Accuracy*) mencapai 0.975 atau 97.5%. Tingginya nilai akurasi ini menunjukkan bahwa model MobileNetV2 mampu melakukan klasifikasi sampah organik dan anorganik dengan baik pada data pengujian yang digunakan. Selama proses pelatihan, penelitian juga menerapkan teknik *online augmentation* untuk menambah variasi data latih.

Meskipun demikian, hasil evaluasi tersebut perlu diinterpretasikan secara hati-hati mengingat jumlah data uji yang digunakan relatif terbatas, yaitu sebanyak 40 citra. Dengan ukuran data uji yang kecil, perubahan hasil klasifikasi pada beberapa sampel dapat memberikan pengaruh yang cukup besar terhadap nilai akurasi keseluruhan. Oleh karena itu, pengujian menggunakan *dataset* yang lebih besar dan lebih beragam diperlukan pada penelitian selanjutnya untuk memperoleh gambaran performa model yang lebih representatif.

Analisis performa mendalam pada masing-masing kelas objek sampah dipaparkan sebagai berikut:

- 1) Kelas Sampah Anorganik: Model mencetak nilai *Recall* sempurna sebesar 1.000 (100%), yang mengindikasikan bahwa seluruh data aktual sampah anorganik di dalam data uji (20 sampel) berhasil ditangkap dan dikenali tanpa ada satu pun yang terlewat. Adapun nilai *Precision* sebesar 0.952 disebabkan karena adanya 1 sampel dari kelas organik yang salah diprediksi oleh model masuk ke dalam kategori anorganik (*False Positive*).
- 2) Kelas Sampah Organik: Model menghasilkan nilai *Precision* sempurna sebesar 1.000 (100%), yang menunjukkan bahwa setiap objek yang diprediksi sebagai organik oleh sistem dipastikan sepenuhnya valid merupakan sampah organik asli tanpa ada *error* salah tebak. Sementara itu, nilai *Recall* sebesar 0.950 merupakan representasi dari adanya 1 sampel organik yang gagal dikenali dan terklasifikasi sebagai anorganik (*False Negative*).

Adapun satu sampel aktual dari kelas organik yang mengalami kesalahan klasifikasi (*False Negative*) dan terdeteksi sebagai anorganik ini memerlukan analisis visual lebih lanjut. Kesalahan prediksi secara teknis dapat terjadi akibat tingkat kemiripan tekstur atau warna objek organik yang sudah mengalami dekomposisi atau mengering (misalnya daun kering berwarna cokelat pucat) yang menyerupai karakteristik visual sampah anorganik tertentu, seperti kertas kusam atau potongan kardus. Kondisi ini menunjukkan bahwa meskipun model MobileNetV2 memiliki kemampuan pemisahan fitur yang tangguh, variasi degradasi fisik pada sampah organik di lapangan masih menjadi tantangan komputasional tersendiri.

Secara keseluruhan, baik nilai *Macro Average* maupun *Weighted Average* dari ketiga metrik utama (*Precision, Recall, F1-Score*) berada

konstan pada angka 0.976 dan 0.975. Konsistensi nilai rata-rata yang sangat tinggi ini menegaskan bahwa penggunaan arsitektur MobileNetV2 berbasis *Transfer Learning* menunjukkan performa yang baik dalam mengekstrak fitur visual secara seimbang (*robust*), meskipun dilatih pada kapasitas *dataset* lokal yang relatif terbatas.

c. **Pengujian Aplikasi Android**

Pengujian aplikasi Android dilakukan untuk memastikan sistem klasifikasi sampah organik dan anorganik dapat berjalan dengan baik pada perangkat *mobile*. Pengujian dilakukan menggunakan kamera *smartphone* untuk melakukan proses klasifikasi sampah secara *real-time*. Pada proses pengujian, sistem akan mendeteksi objek sampah melalui kamera kemudian menampilkan hasil klasifikasi secara langsung pada aplikasi Android.



Gambar 4. 6 Pengujian Aplikasi Android

Tabel 4. 5 Hasil Pengujian Klasifikasi Sampah

No	Objek Sampah	Gambar	Hasil Prediksi	Confidence Score
1	Botol Plastik		Anorganik	91%
2	Kulit Buah		Organik	92%
3	Daun Kering		Organik	93%
4	Plastik Kresek		Anorganik	92%
5	Plastik Kemasan (Cleo)		Anorganik	95%

Berdasarkan hasil pengujian pada Tabel 4.5, aplikasi Android mampu melakukan proses klasifikasi sampah secara *real-time* dengan hasil prediksi yang sesuai terhadap objek yang diuji.

Pengujian ini juga bertujuan untuk memvalidasi bahwa model MobileNetV2 yang telah dikonversi ke format TensorFlow Lite tetap mampu menghasilkan prediksi yang sesuai setelah diimplementasikan pada perangkat Android. Hasil pengujian menunjukkan bahwa proses *deployment* tidak menyebabkan gangguan terhadap fungsi klasifikasi model, sehingga sistem dapat digunakan secara langsung pada *smartphone* untuk melakukan identifikasi sampah secara *real-time*.

Perlu ditekankan bahwa kelima objek sampah yang digunakan dalam pengujian fungsional langsung pada perangkat ini merupakan data baru (*unseen data*) yang diambil secara acak di lingkungan pemukiman warga wilayah Kediri yang menjadi area sekitar tempat tinggal peneliti.

Objek uji tersebut tidak termasuk ke dalam bagian 400 *dataset* awal yang digunakan pada proses pelatihan maupun pengujian model sebelumnya. Hal tersebut mengindikasikan bahwa model menunjukkan kemampuan generalisasi yang cukup baik pada sampel data baru yang diuji, meskipun pengujian lebih luas masih diperlukan untuk memastikan konsistensi performa pada kondisi lingkungan yang lebih beragam dalam mengenali objek baru di lapangan secara langsung.

Namun, kemampuan generalisasi tersebut masih terbatas pada karakteristik objek yang memiliki kemiripan dengan data yang digunakan selama pelatihan. Kondisi ini wajar mengingat model hanya dilatih menggunakan 400 citra primer yang merepresentasikan beberapa jenis sampah tertentu, yaitu dedaunan, sisa makanan atau buah, botol plastik, dan kemasan plastik. Akibatnya, representasi fitur

Guna memvalidasi kecepatan respons dan kinerja komputasi *on device* secara lebih transparan pada level sistem, peneliti melakukan ekstraksi data *log* melalui fitur *Logcat* pada Android Studio selama aplikasi dijalankan. Rekaman aktivitas TFLite Interpreter pada paket aplikasi `com.example.skripsi` ditunjukkan pada Gambar 4.7.

[illegible]

Berdasarkan visualisasi data *stream log* pada Gambar 4.7, terdapat lima parameter metrik komputasi utama yang diekstrak secara otomatis oleh sistem di setiap *frame* gambar yang ditangkap oleh lensa kamera, dengan rincian analisis sebagai berikut:

- Submission ID trn:oid::2945:394823577

arsitektur MobileNetV2 pada dimensi *input* $224 \times 224 \times 3$ piksel. Berdasarkan data log yang diperoleh selama proses pengujian aplikasi, waktu inferensi model MobileNetV2 umumnya berada pada rentang 21,79 ms hingga 26,27 ms. Namun, pada beberapa kondisi tertentu ditemukan lonjakan waktu inferensi hingga mencapai 95,23 ms yang diduga dipengaruhi oleh proses pengolahan *frame* kamera, aktivitas sistem operasi Android, dan beban komputasi perangkat saat pengujian berlangsung. Secara umum, waktu inferensi tetap berada pada kategori responsif untuk kebutuhan klasifikasi *real-time* pada perangkat Android.

Hasil pengamatan menunjukkan bahwa sebagian besar *frame* diproses dalam waktu kurang dari 30 ms. Dengan waktu pemrosesan tersebut, sistem masih mampu menghasilkan tampilan prediksi secara *real-time* tanpa gangguan yang signifikan terhadap pengalaman pengguna. Meskipun terdapat beberapa lonjakan latensi pada kondisi tertentu, sistem tetap mampu mempertahankan performa klasifikasi secara stabil selama proses pengujian.

- 4) *TotalTime*: Akumulasi waktu total yang dibutuhkan sistem mulai dari proses konversi data *bitmap* citra mentah dari kamera melalui CameraX API, pengeksekusian tahap *preprocessing* (penskalaan dan normalisasi), proses inferensi model TFLite, hingga penyiapan komponen teks *overlay* ke layar gawai. Nilai *TotalTime* terpantau stabil berada pada rentang 26,40 ms hingga 77,80 ms.
- 5) *FPS (Frames Per Second)*: Jumlah bingkai gambar yang sanggup diproses oleh sistem dalam satu detik untuk mewujudkan interaksi yang responsif. Nilai FPS berjalan secara fluktuatif pada rentang 12,85 FPS hingga 37,88 FPS, di mana performa tertinggi

dicapai pada objek dengan tingkat kompleksitas latar belakang (*background*) yang minimal.

Jika dibandingkan dengan kebutuhan umum aplikasi *real-time* pada perangkat *mobile*, waktu inferensi yang berada pada rentang 21,79 ms hingga 26,27 ms menunjukkan bahwa model mampu menghasilkan prediksi dalam waktu kurang dari 0,03 detik untuk sebagian besar *frame* yang diproses. Hasil tersebut mengindikasikan bahwa arsitektur MobileNetV2 memiliki efisiensi komputasi yang baik dan sesuai untuk implementasi klasifikasi citra secara langsung pada perangkat Android.

Dengan demikian, hasil analisis data *log* pada Gambar 4.7 memberikan bukti empiris bahwa penggunaan model MobileNetV2 berbasis *Transfer Learning* yang dikonversi ke format TensorFlow Lite memungkinkan seluruh proses klasifikasi berjalan dengan sangat ringan, stabil, dan responsif langsung di dalam memori internal perangkat tanpa mengalami gejala penundaan gambar (*lag*) ataupun ketergantungan terhadap koneksi internet.

B. Pembahasan

Berdasarkan hasil pengujian fungsional dan non-fungsional, seluruh fitur utama aplikasi berhasil berjalan sesuai rancangan, termasuk akses kamera secara *real-time* dan penampilan *confidence score*. Evaluasi model MobileNetV2 menunjukkan performa klasifikasi yang sangat baik dengan nilai *accuracy* sebesar 97,5%, *precision* sebesar 97,6%, *recall* sebesar 97,5%, dan *F1-score* sebesar 97,5%. Hasil tersebut menunjukkan bahwa model mampu melakukan klasifikasi sampah organik dan anorganik secara konsisten pada data pengujian yang digunakan.

Performa tersebut menunjukkan bahwa MobileNetV2 berbasis *Transfer Learning* mampu melakukan klasifikasi dengan baik pada dataset primer yang digunakan. Pemanfaatan *pre-trained weights* dari MobileNetV2 membantu

model mengenali karakteristik sampah organik dan anorganik meskipun menggunakan *dataset* primer yang relatif terbatas. Grafik pelatihan menunjukkan bahwa nilai *training accuracy* dan *validation accuracy* terus meningkat hingga mendekati kondisi konvergen pada *epoch* ke 20. Di sisi lain, nilai *training loss* dan *validation loss* mengalami penurunan secara konsisten selama proses pelatihan. Pola tersebut mengindikasikan bahwa model mampu mempelajari karakteristik data secara efektif, serta tidak menunjukkan indikasi *overfitting* yang signifikan karena kurva pelatihan dan validasi menunjukkan pola yang relatif sejalan. Selain itu, konversi model ke format TensorFlow Lite (TFLite) memungkinkan proses inferensi berjalan cepat, responsif, dan sepenuhnya bersifat *on device* pada perangkat Android tanpa bergantung pada koneksi internet, sehingga sesuai untuk implementasi klasifikasi secara *real-time*.

Hasil akurasi sebesar 97,5% menunjukkan performa yang baik dibandingkan beberapa penelitian terdahulu. Sebagai pembanding pertama, penelitian oleh Thio & Susilo (2025) yang menerapkan metode *Transfer Learning* dengan model MobileNetV2 untuk klasifikasi enam jenis sampah menggunakan 2.527 citra menghasilkan akurasi *training* sebesar 87,31% dan akurasi *validation* sebesar 91,57%. Selanjutnya, penelitian oleh Rasidi et al. (2022) yang membangun arsitektur *Convolutional Neural Network* (CNN) standar untuk klasifikasi sampah organik dan anorganik menggunakan *dataset* sekunder sebanyak 25.077 citra menghasilkan akurasi pengujian sebesar 96% pada kategori anorganik, namun memiliki akurasi yang rendah pada kategori organik yaitu sebesar 62%. Sementara itu, untuk platform *deployment mobile* yang sejenis, riset dari Wahid et al. (2026) yang mengimplementasikan MobileNetV2 berbasis Android mencatat tingkat akurasi sebesar 91% dengan ukuran model TensorFlow Lite yang sangat ringkas sebesar 8,8 MB. Perbedaan hasil tersebut menunjukkan bahwa performa model tidak hanya dipengaruhi oleh jumlah *dataset*, tetapi juga oleh pemilihan arsitektur, strategi *Transfer Learning*, proses augmentasi data, serta karakteristik *dataset* yang digunakan selama pelatihan dan pengujian.

Keunggulan nilai akurasi pada sistem yang diusulkan dalam penelitian ini (97,5% secara seimbang per kelas) jika dibandingkan dengan ketimpangan hasil klasifikasi organik pada riset Rasidi et al. (2022) mengindikasikan bahwa pemanfaatan strategi *Feature Extraction* MobileNetV2 yang dipadukan dengan teknik online data *augmentation* berkontribusi dalam meningkatkan performa model meskipun menggunakan *dataset* primer sebanyak 400 citra. Pendekatan tersebut dinilai mampu menghasilkan model yang dinilai lebih *robust* dalam mengenali karakteristik sampah domestik di lingkungan pemukiman warga wilayah Kediri sehingga mampu mempertahankan performa klasifikasi yang relatif seimbang pada kedua kelas. Selain itu, model tetap beroperasi secara responsif dengan waktu inferensi yang umumnya berada pada rentang 21,79 ms hingga 26,27 ms, meskipun pada kondisi tertentu ditemukan lonjakan hingga 95,23 ms saat dieksekusi langsung pada perangkat *smartphone* tanpa memerlukan koneksi internet maupun komputasi *cloud*. Lonjakan tersebut diduga dipengaruhi oleh proses *autofocus* kamera, perubahan kondisi pencahayaan, maupun aktivitas sistem operasi Android yang menggunakan sumber daya perangkat secara bersamaan.

Meskipun menunjukkan performa yang baik, sistem yang dikembangkan dalam penelitian ini masih memiliki keterbatasan teknis pada ruang lingkup pemisahan fitur objek. Penggunaan fungsi Softmax menyebabkan model selalu menghasilkan prediksi ke salah satu dari dua kelas yang tersedia sehingga belum mampu menangani objek di luar kategori sampah (*out-of-distribution data*). Jika pengguna mengarahkan kamera aplikasi pada objek non-sampah, model tetap akan memberikan prediksi ke salah satu kelas yang tersedia meskipun objek tersebut berada di luar *domain* data pelatihan.

Dengan demikian, sistem belum memiliki mekanisme penolakan (*rejection mechanism*) terhadap objek yang berada di luar kategori sampah organik dan anorganik sehingga seluruh objek masukan akan tetap dipetakan ke salah satu kelas yang tersedia.

Oleh karena itu, pengkondisian jarak sensor, stabilitas pencahayaan alami, dan fokus visual pengguna secara langsung bertindak sebagai variabel luar yang memengaruhi validitas operasional inferensi aplikasi secara riil di lapangan.

Selain keterbatasan pada pemisahan fitur tersebut, ruang lingkup penelitian ini baru mencakup dua kategori sampah domestik dengan jumlah *dataset* primer yang relatif terbatas, yaitu sebanyak 400 citra. Keterbatasan jumlah data tersebut berpotensi membatasi kemampuan model dalam merepresentasikan variasi karakteristik sampah yang lebih luas pada kondisi lingkungan nyata. Oleh karena itu, meskipun model menghasilkan akurasi yang tinggi pada data pengujian, hasil tersebut masih perlu diinterpretasikan secara hati-hati dan belum dapat digeneralisasikan untuk seluruh jenis sampah yang dijumpai di lapangan. Selain itu, representasi objek pada masing-masing kategori masih terbatas pada beberapa jenis sampah tertentu, sehingga belum sepenuhnya merepresentasikan seluruh variasi sampah organik maupun anorganik yang dijumpai di lingkungan nyata. Stabilitas hasil prediksi model juga masih dapat dipengaruhi oleh faktor eksternal seperti kondisi pencahayaan, kualitas kamera perangkat, sudut pengambilan citra, dan variasi latar belakang objek.

Untuk penelitian selanjutnya, kuantitas *dataset* dapat diperbanyak dengan variasi objek yang lebih beragam serta menambahkan kategori kelas sampah lainnya guna meningkatkan jangkauan generalisasi sistem. Secara keseluruhan, penelitian ini berhasil mengimplementasikan MobileNetV2 berbasis *Transfer Learning* pada aplikasi Android untuk melakukan klasifikasi sampah organik dan anorganik secara *real-time* dengan akurasi 97,5% dan waktu inferensi yang relatif cepat.

BAB V

PENUTUP

A. Kesimpulan

Setelah melalui seluruh tahapan perancangan, implementasi, serta pengujian sistem klasifikasi sampah organik dan anorganik dengan arsitektur MobileNetV2 pada platform Android, diperoleh kesimpulan sebagai berikut:

1. Implementasi MobileNetV2 berbasis *Transfer Learning* berhasil diterapkan pada aplikasi Android melalui konversi model ke format TensorFlow Lite (.tflite). Integrasi dengan CameraX API memungkinkan sistem melakukan klasifikasi citra sampah organik dan anorganik secara *real-time* pada perangkat Android. Hasil pengujian menunjukkan aplikasi dapat berjalan dengan stabil selama proses penggunaan.
2. Model MobileNetV2 berbasis *Transfer Learning* menunjukkan performa yang baik dalam mengklasifikasikan sampah organik dan anorganik pada *dataset* primer yang digunakan. Model memperoleh akurasi sebesar 97,5% dengan nilai *precision*, *recall*, dan *F1-score* yang tinggi pada kedua kelas. Selain itu, rata-rata waktu inferensi sebesar 21,79 ms hingga 26,27 ms per *frame* menunjukkan bahwa model mampu mendukung proses klasifikasi secara *real-time* pada perangkat Android.

B. Saran

Meskipun sistem telah menunjukkan performa yang baik berdasarkan hasil pengujian, masih terdapat beberapa aspek yang dapat dikembangkan pada penelitian selanjutnya, yaitu:

1. Mengembangkan fungsionalitas antarmuka aplikasi dengan menambahkan fitur *Dual Mode Input*, yaitu pilihan klasifikasi melalui pemindaian kamera secara langsung maupun melalui gambar statis yang diambil terlebih dahulu. Fitur ini diharapkan dapat memberikan

fleksibilitas penggunaan serta memperluas skenario pemanfaatan aplikasi sesuai kebutuhan pengguna.

2. Melakukan pengujian pada berbagai kondisi lingkungan, seperti variasi pencahayaan, sudut pengambilan gambar, dan latar belakang objek yang berbeda untuk mengetahui tingkat ketahanan (*robustness*) model dalam kondisi penggunaan nyata.
3. Menambah jumlah dan variasi *dataset* yang digunakan, serta memperluas kategori sampah yang diklasifikasikan agar kemampuan generalisasi model terhadap kondisi lingkungan nyata dapat ditingkatkan.