

**PENERAPAN TRANSFER LEARNING MENGGUNAKAN
ARSITEKTUR DEEP CNN RESNET-50 UNTUK
KLASIFIKASI JENIS SAMPAH**



SKRIPSI

Diajukan untuk salah satu syarat kelulusan Program Sarjana (S1)

ADISAPUTRA MARBUN

NIM : 15210083

Program Studi Informatika

Fakultas Teknik dan Informatika

Universitas Bina Sarana Informatika

Jakarta

2025

PERSEMBAHAN

“Serahkanlah perbuatan mu kepada Tuhan, maka terlaksanalah segala rencanamu”

(Amsal 16:3)

Segala puji bagi Allah SWT. yang maha menguasai semesta alam beserta isinya, dan skripsi ini saya persembahkan untuk :

1. Kepada Bapak dan Ibu tercinta, terima kasih atas segala doa, dukungan, kasih sayang, serta pengorbanan yang tiada henti sejak awal hingga akhir perjalanan ini. Semoga dengan selesainya skripsi ini dan kelulusan yang diraih, saya dapat segera memperoleh pekerjaan yang baik dan mampu memberikan kehidupan yang lebih layak dan membahagiakan bagi Bapak dan Ibu.
2. Kepada keluarga besar saya, terima kasih atas segala dukungan, nasihat, serta bantuan moral dan materi yang telah diberikan. Berkat kasih sayang dan semangat dari kalian semua, saya dapat bertahan dan berdiri teguh hingga akhirnya mampu menyelesaikan skripsi ini dengan baik.
3. Teman-teman seperjuangan yang telah memberikan bantuan dan dukungan selama proses penyusunan skripsi ini. Terutama kepada Tim Padepokan Rumah Bagas yang selalu memberikan arahan, motivasi, dan semangat dengan gaya khas mereka yang tegas namun tulus, yang justru menjadi penyemangat tersendiri bagi saya untuk terus maju dan menyelesaikan skripsi ini.
4. Bapak Budi dan Bapak Hasta selaku dosen pembimbing yang telah dengan sabar membimbing, memberikan arahan, motivasi, dan masukan yang sangat berarti dalam proses penyusunan skripsi ini. Ucapan terima kasih juga saya sampaikan kepada seluruh dosen Universitas Bina Sarana Informatika yang telah memberikan ilmu, wawasan, serta pengalaman berharga selama masa perkuliahan, yang menjadi bekal penting dalam menyelesaikan studi ini.
5. Untuk diriku sendiri, terima kasih atas perjuangan, kesabaran, dan keteguhan hati yang telah menemani sepanjang perjalanan ini. Terima kasih telah terus melangkah, meski tidak selalu mudah. Usahamu tidak sia-sia, dan hasilnya adalah buah dari kerja keras yang tak kenal lelah. Semoga ke depannya kamu senantiasa diberi kesehatan, kekuatan, dan menjadi pribadi yang semakin baik dalam sikap, pikiran, dan tindakan. Dengan penuh rasa syukur, izinkan aku mengucapkan: Terima kasih, telah bertahan sejauh ini.

*“Jika kamu mencari siapa yang akan bisa
mengubah hidupmu lihat pada sebuah cermin”*

**SURAT PERNYATAAN KEASLIAN SKRIPSI PADA
PROGRAM SARJANA**

Yang bertanda tangan dibawah ini :

Nama : Adisaputra Marbun
NIM : 15210083
Jenjang : Sarjana (S1)
Program Studi : Informatika
Fakultas : Teknik dan Informatika
Perguruan Tinggi : Universitas Bina Sarana Informatika

Dengan ini menyatakan bahwa Skripsi/Tugas Akhir yang telah saya buat dengan judul: **“Penerapan Transfer Learning Menggunakan Arsitektur Deep CNN ResNet-50 Untuk Klasifikasi Jenis Sampah”**, adalah asli (orsinil) atau tidak plagiat (menjiplak) dan belum pernah diterbitkan/dipublikasikan dimanapun dan dalam bentuk apapun.

Demikianlah surat pernyataan ini saya buat dengan sebenar-benarnya tanpa ada paksaan dari pihak manapun juga. Apabila di kemudian hari ternyata saya memberikan keterangan palsu dan atau ada pihak lain yang mengklaim bahwa Skripsi pada Program Sarjana yang telah saya buat adalah hasil karya milik seseorang atau badan tertentu, saya bersedia diproses baik secara pidana maupun perdata dan kelulusan saya dari **Universitas Bina Sarana Informatika** dicabut/dibatalkan.

Dibuat di : Jakarta
Pada tanggal : 30 Juni 2025
Yang menyatakan,



ADISAPUTRA MARBUN

SUR AT PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Yang bertanda tangan dibawah ini :

Nama : Adisaputra Marbun
NIM : 15210083
Jenjang : Sarjana (S1)
Program Studi : Informatika
Fakultas : Teknik dan Informatika
Perguruan Tinggi : Universitas Bina Sarana Informatika

Dengan ini menyatakan bahwa seluruh data, informasi, interpretasi serta pernyataan yang terdapat dalam karya ilmiah Penulis dengan judul “**Penerapan Transfer Learning Menggunakan Arsitektur Deep CNN ResNet-50 Untuk Klasifikasi Jenis Sampah**” ini, kecuali yang disebutkan sumbernya adalah hasil pengamatan, penelitian, pengelolaan, serta pemikiran saya. Demikian kesepakatan ini dibuat dengan sebenarnya.

Penulis menyetujui untuk memberikan ijin kepada pihak **Universitas Bina Sarana Informatika** untuk mendokumentasikan karya ilmiah saya tersebut secara internal dan terbatas, serta tidak untuk mengunggah karya ilmiah Penulis pada repository Universitas Bina Sarana Informatika.

Penulis bersedia untuk bertanggung jawab secara pribadi, tanpa melibatkan pihak **Universitas Bina Sarana Informatika**, atas materi/isi karya ilmiah tersebut, termasuk bertanggung jawab atas dampak atau kerugian yang timbul dalam bentuk akibat tindakan yang berkaitan dengan data, informasi, interpretasi serta pernyataan yang terdapat pada karya ilmiah saya ini.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di : Jakarta
Pada tanggal : 30 Juni 2025
Yang menyatakan,



ADISAPUTRA MARBUN

PERSETUJUAN DAN PENGESAHAN SKRIPSI

Skripsi ini diajukan oleh:

Nama : Adisaputra Marbun
NIM : 15210083
Jenjang : Sarjana (S1)
Program Studi : Informatika
Fakultas : Teknik dan Informatika
Perguruan Tinggi : Universitas Bina Sarana Informatika
Judul Skripsi : Penerapan Transfer Learning Menggunakan Arsitektur Deep CNN ResNet-50 Untuk Klasifikasi Jenis Sampah

Telah dipertahankan pada periode 2025-1 dihadapan penguji dan diterima sebagai bagian persyaratan yang diperlukan untuk memperoleh Sarjana Komputer (S.Kom) pada Program Sarjana (S1) Program Studi Informatika di Universitas Bina Sarana Informatika.

Jakarta, 14 Agustus 2025

PEMBIMBING SKRIPSI

Pembimbing I : Budi Sudrajat, M.Kom.



Ditandatangani Digital:
Budi Sudrajat
2025-08-19 15:10:44

Pembimbing II : Hasta Herlan Asymar, S.T., M.M.



Ditandatangani Digital:
Hasta Herlan Asymar
2025-08-20 16:24:06

DEWAN PENGUJI

Penguji I : Ade Surya Budiman, S.T., M.Kom.



Ditandatangani Digital:
Ade Surya Budiman
14-08-2025 17:00:24

Penguji II : Albert Riyandi, M.Kom.



Ditandatangani Digital:
Albert Riyandi
14-08-2025 19:04:02

PEDOMAN PENGGUNAAN HAK CIPTA

Skripsi sarjana yang berjudul “**Penerapan Transfer Learning Menggunakan Arsitektur Deep CNN ResNet-50 Untuk Klasifikasi Jenis Sampah**” adalah hasil karya tulis asli Adisaputra Marbun dan bukan hasil terbitan sehingga peredaran karya tulis hanya berlaku di lingkungan akademik saja, serta memiliki hak cipta. Oleh karena itu, dilarang keras untuk menggandakan baik sebagian maupun seluruhnya karya tulis ini, tanpa seizin penulis.

Referensi kepustakaan diperkenankan untuk dicatat tetapi pengutipan atau peringkasan isi tulisan hanya dapat dilakukan dengan seizin penulis dan disertai ketentuan pengutipan secara ilmiah dengan menyebutkan sumbernya.

Untuk keperluan perizinan pada pemilik dapat menghubungi informasi yang tertera di bawah ini:

Nama : Adisaputra Marbun
Alamat : Jl. Pasar Kemiri Basmol Raya
No. Telp : 081263503175
E-mail : adiamrbn8@gmail.com

UNIVERSITAS

KATA PENGANTAR

Dengan mengucapkan puji syukur kehadirat pada Tuhan yang Maha Esa, yang telah melimpahkan rahmat dan karunia-Nya, sehingga pada akhirnya penulis dapat menyelesaikan tugas ini dengan baik. Skripsi pada Program Sarjana ini penulis sajikan dalam bentuk buku yang sederhana. Adapun judul Skripsi, yang penulis ambil sebagai berikut, **“Penerapan Transfer Learning Menggunakan Arsitektur Deep CNN ResNet-50 Untuk Klasifikasi Jenis Sampah”**.

Tujuan penulisan Skripsi pada Program Sarjana ini dibuat sebagai salah satu syarat kelulusan Sarjana Universitas Bina Sarana Informatika. Sebagai bahan penulisan diambil berdasarkan hasil penelitian (eksperimen), observasi dan beberapa sumber literatur yang mendukung penulisan ini. Penulis menyadari bahwa tanpa bimbingan dan dorongan dari semua pihak, maka penulisan Skripsi ini tidak akan berjalan lancar. Oleh karena itu pada kesempatan ini, ijinilah penulis menyampaikan ucapan terima kasih kepada :

1. Bapak Prof. Dr. Ir. Mochamad Wahyudi, M.Kom, M.M, M.Pd, IPU, Asean Eng, selaku rektor Universitas Bina Sarana Informatika.
2. Bapak Rachmat Adi Purnama, M.Kom, selaku Dekan FTI.
3. Bapak Dr. Sumanto, M.Kom, selaku Kaprodi Informatika.
4. Budi Sudrajat, M.Kom selaku Dosen Pembimbing Skripsi.
5. Hasta Herlan Asymar, S.T.,M.M. selaku Asisten Pembimbing Skripsi.
6. Staff / karyawan / dosen di lingkungan Universitas Bina Sarana Informatika.
7. Orang tua tercinta yang telah memberikan dukungan moral maupun spiritual.
8. Rekan-rekan mahasiswa kelas 15.8A.25 tahun 2025

Serta semua pihak yang terlalu banyak untuk disebut satu persatu sehingga terwujudnya penulisan ini. Penulis menyadari bahwa penulisan Skripsi ini masih jauh sekali dari sempurna, untuk itu penulis mohon kritik dan saran yang bersifat membangun demi kesempurnaan penulisan di masa yang akan datang.

Akhir kata semoga Skripsi ini dapat berguna bagi penulis khususnya dan bagi para pembaca yang berminat pada umumnya.

Jakarta, 30 Juni 2025

Penulis



Adisaputra Marbun

ABSTRAK

Adisaputra Marbun (15210083), Penerapan Transfer Learning Menggunakan Arsitektur Deep CNN ResNet-50 untuk Klasifikasi Sampah

Pengelolaan sampah masih menjadi tantangan besar di Indonesia akibat tingginya timbulan sampah dan rendahnya tingkat daur ulang. Salah satu solusi inovatif yang dapat diterapkan adalah sistem klasifikasi sampah otomatis berbasis citra. Penelitian ini bertujuan membangun model klasifikasi jenis sampah menggunakan arsitektur *Deep Convolutional Neural Network ResNet-50* dengan pendekatan *transfer learning*. Dataset yang digunakan berasal dari Kaggle dan mencakup lima kelas: *cardboard*, *glass*, *metal*, *paper*, dan *plastic*. Data telah melalui tahap pra-pemrosesan, *augmentasi*, dan pembagian secara *stratifikasi*. Model dilatih selama 50 epoch menggunakan *optimizer AdamW* dan fungsi kehilangan *CrossEntropyLoss*. Hasil pelatihan menunjukkan akurasi validasi tertinggi sebesar 85%. Evaluasi dengan *confusion matrix* dan *classification report* menunjukkan model mampu melakukan klasifikasi secara akurat dan seimbang pada tiap kelas. Sistem ini juga dilengkapi antarmuka interaktif untuk prediksi gambar tunggal, memperlihatkan potensi penerapan nyata dalam pengelolaan sampah berbasis teknologi. Hasil penelitian membuktikan bahwa *transfer learning* dengan *ResNet-50* efektif untuk klasifikasi citra sampah dan berpotensi mendukung solusi lingkungan berbasis kecerdasan buatan.

Kata Kunci: *transfer learning*, *resnet-50*, klasifikasi sampah.



UNIVERSITAS

ABSTRACT

Adisaputra Marbun (15210083), Penerapan Transfer Learning Menggunakan Arsitektur Deep CNN ResNet-50 untuk Klasifikasi Sampah

Waste management remains a major challenge in Indonesia due to the high volume of waste generation and low recycling rates. One innovative solution that can be applied is an automated image-based waste classification system. This study aims to develop a waste classification model using the Deep Convolutional Neural Network architecture ResNet-50 with a transfer learning approach. The dataset used is sourced from Kaggle and consists of five classes: cardboard, glass, metal, paper, and plastic. The data underwent preprocessing, augmentation, and stratified splitting. The model was trained for 50 epochs using the AdamW optimizer and the CrossEntropyLoss function. Training results showed a highest validation accuracy of 85%. Evaluation using a confusion matrix and classification report indicated that the model was able to classify each class accurately and consistently. The system is also equipped with an interactive interface for single-image prediction, demonstrating its practical potential in technology-based waste management. The findings confirm that transfer learning with ResNet-50 is effective for waste image classification and holds promise for supporting AI-based environmental solutions.

Keywords: *transfer learning, resnet-50, waste classification*





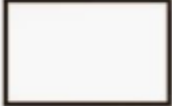
UNIVERSITAS

DAFTAR ISI

Lembar Judul Skripsi	i
Lembar Persembahan	ii
Lembar Surat Pernyataan Keaslian Skripsi Pada Program Sarjana	iii
Lembar Pernyataan Persetujuan Publikasi Karya Ilmiah.....	iv
Lembar Persetujuan dan Pengesahaan Skripsi	v
Lembar Pedoman Penggunaan Hak Cipta.....	vi
KATA PENGANTAR.....	vii
ABSTRAK	viii
ABSTRACT.....	ix
DAFTAR ISI	x
DAFTAR SIMBOL	xii
DAFTAR GAMBAR	xiii
DAFTAR TABEL.....	xiv
DAFTAR LAMPIRAN	xv
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah	2
1.3. Tujuan dan Manfaat	3
1.3.1 Tujuan.....	3
1.3.2. Manfaat	3
1.4. Hipotesis.....	4
1.5. Batasan Masalah.....	4
BAB II LANDASAN TEORI	5
2.1. Tinjauan Pustaka	5
2.1.1. Konsep Pengelolaan Sampah	5
2.1.2 <i>Deep Learning</i>	7
2.1.3 <i>Convolutional Neural Network (CNN)</i>	7
2.1.4 ResNet-50.....	11
2.1.5 <i>Transfer Learning</i>	12
2.1.6 <i>Tensor Flow</i>	13

2.1.7	<i>Data Augmentation</i>	14
2.1.8	<i>Confusion Matrix</i>	14
2.2.	Penelitian Terkait.....	15
BAB III METODOLOGI PENELITIAN.....		46
3.1.	Proses dan Langkah Penelitian.....	46
3.2.	Metode Pengolahan dan Analisis Data.....	48
3.2.1.	Pra-pemrosesan Data	48
3.2.2.	Pemetaan Label.....	49
3.2.3.	Pembagian Dataset	49
3.2.4.	Augmentasi Label.....	49
3.2.5.	Pembuatan Data Loader.....	49
BAB IV HASIL DAN PEMBAHASAN.....		52
4.1.	Hasil Penelitian.....	52
4.2.	Hasil Pengujian	56
BAB V PENUTUP.....		52
5.1.	Kesimpulan	52
5.2.	Saran.....	53
DAFTAR PUSTAKA		liv
DAFTAR RIWAYAT HIDUP.....		lvi
LEMBAR KONSULTASI.....		lvii
SURAT KETERANGAN RISET/ SURAT KEABSAHAN DATA.....		liv
LAMPIRAN.....		liv

DAFTAR SIMBOL

	<p>Connector</p> <p>Simbol keluar - masuk atau penyambungan proses dalam satu halaman yang sama</p>
	<p>Flow</p> <p>Simbol yang digunakan untuk menghubungkan antara simbol yang satu dengan yang lain.</p>
	<p>Process</p> <p>Simbol yang menunjukkan proses atau pengolahan yang dilakukan oleh komputer</p>

UNIVERSITAS

DAFTAR GAMBAR

Gambar II. 1 Deep Learning	7
Gambar II. 2 CNN.....	8
Gambar II. 3 Convolution Layer.....	9
Gambar II. 4 Jenis-jenis operasi pooling.....	10
Gambar II. 5 Jaringan Saraf Tiruan.....	11
Gambar II. 6 Arsitektur ResNet-50.....	12
Gambar II. 7 Visualisasi Transfer Learning	13
Gambar II. 8 Logo TensorFlow.....	13
Gambar II. 9 Visualisasi Data Augmentation.....	14
Gambar II. 10 Confusion Matrix.....	15
Gambar III. 1 Alur Penelitian.....	46
Gambar III. 2 Pengumpulan Dataset.....	47
Gambar IV. 1 Data Train dan Data Test	52
Gambar IV. 2 Visualisasi Data Latih.....	54
Gambar IV. 3 Epochs Accuracy	56
Gambar IV. 4 Confusion Matrix.....	57
Gambar IV. 5 Clasification Report Test	60
Gambar IV. 6 Prediksi Gambar Tunggal.....	61



UNIVERSITAS

DAFTAR TABEL

Tabel II. 1 Refrensi Penelitian.....	15
Tabel IV. 1 Train accuracy.....	53



DAFTAR LAMPIRAN

A1. Hasil Turnitin.....	liv
B1. Hasil Submit Jurnal.....	lx



BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Menurut (Nurmia et al., 2025) pengelolaan sampah merupakan salah satu tantangan utama di berbagai negara, termasuk Indonesia, yang menghasilkan jutaan ton sampah setiap tahunnya. Berdasarkan data terbaru dari Kementerian Lingkungan Hidup dan Kehutanan (KLHK), Indonesia menghasilkan sekitar 69,9 juta ton sampah pada tahun 2023. Namun, data yang tercatat dalam Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) hingga pertengahan 2024 hanya mencakup sebagian wilayah, dengan total timbunan sampah yang dilaporkan sebesar 38,6 juta ton dari 365 kabupaten/kota (Bustamin et al., 2023). Dari jumlah tersebut, hanya sekitar 11% yang berhasil didaur ulang secara efektif, sementara sisanya berakhir di tempat pembuangan akhir (TPA) atau bahkan mencemari lingkungan (KLHK, 2022). Kurangnya kesadaran masyarakat dalam memilah sampah serta terbatasnya sistem pengelolaan sampah otomatis semakin memperparah kondisi ini.

Saat ini, klasifikasi sampah masih banyak dilakukan secara manual, yang membutuhkan waktu lama, tenaga manusia yang besar, dan rentan terhadap kesalahan (*human error*). Oleh karena itu, di perlukan sebuah teknologi untuk mengoptimalkan proses pemilihan sampah secara efisien dan akurat. Perkembangan Kecerdasan Buatan (*Artificial Intelligence/AI*), khususnya dalam bidang pengolahan citra (*Computer Vision*), yang memberikan peluang besar untuk mengatasi masalah ini. Salah satu pendekatan yang menjajikan penggunaan *Deep Learning*, khususnya di bidang *Covolutional Neural Network* (CNN), yang telah terbukti dalam efektif dalam tugas klasifikasi gambar karena kemampuannya mengekstrak fitur secara *hierarkis* (Jihan Nuariputri, 2023).

Menurut (Li et al., 2025) di antara berbagai arsitektur CNN, *ResNet-50* (*Residual Network* dengan 50 lapisan) menonjol karena kemampuannya mengatasi masalah *vanishing gradient* melalui koneksi *skip connection*, sehingga mampu mencapai akurasi tinggi bahkan pada dataset yang kompleks. Teknik *transfer learning*, di mana model yang telah dilatih sebelumnya (*pre-trained*) pada dataset besar (seperti *ImageNet*) diadaptasi untuk tugas spesifik (klasifikasi sampah), menjadi solusi ideal untuk mengatasi keterbatasan data pelatihan. Pendekatan ini tidak hanya mempercepat proses pelatihan tetapi juga meningkatkan kinerja model (Wu & Lin, 2022).

Oleh karena itu, Penelitian hanya berfokus pada pengembangan model klasifikasi citra jenis sampah menggunakan arsitektur *ResNet-50* dengan pendekatan *transfer Learning*. Penelitian ini bertujuan untuk membangun sistem yang mampu mengenali dan mengklasifikasikan jenis sampah secara otomatis berdasarkan citra digital. Dengan demikian, penelitian ini hanya menguji kembali efektivitas *Resnet-50*, tetapi juga berupaya untuk memberikan hasil akhir berupa model klasifikasi yang dapat di jadikan acuan awal dalam mendukung pengelolaan sampah berbasis kecerdasan buatan di Indonesia.

1.2. Rumusan Masalah

Berdasarkan latar belakang di atas, permasalahan yang diangkat adalah:

1. Bagaimana mengimplementasikan *transfer learning* dengan arsitektur *ResNet-50* untuk mengklasifikasikan jenis sampah?
2. Bagaimana kinerja *model ResNet-50* dalam membedakan kategori sampah *Glass, Metal, Paper, Cardboard* dan *Plastik*.

1.3. Tujuan dan Manfaat

1.3.1 Tujuan

Penelitian ini bertujuan untuk:

1. Mengimplementasikan model klasifikasi jenis sampah menggunakan pendekatan *transfer learning* dengan *arsitektur ResNet-50*
2. Menganalisis kinerja model melalui metrik evaluasi seperti *confusion Matrix accuracy, precision, recall, dan F1-score*.

1.3.2. Manfaat

1. Bagi Object Penelitian
 - a. Memberikan solusi klasifikasi citra sampah yang lebih efisien dan akurat, yang dapat digunakan dalam sistem pemilahan sampah otomatis.
 - b. Mendukung upaya pengelolaan lingkungan yang berkelanjutan melalui teknologi berbasis kecerdasan buatan.
2. Bagi Penulis
 - a. Meningkatkan pemahaman dan keterampilan dalam bidang *machine learning*, khususnya dalam implementasi model *deep learning* dan *transfer learning* untuk klasifikasi citra.
 - b. Menjadi pengalaman praktis dalam membangun sistem klasifikasi berbasis CNN, serta melakukan analisis evaluasi model secara *komprensif*.
3. Bagi Pembaca
 - a. Menjadi referensi teoritis dan praktis dalam pengembangan penelitian serupa, khususnya dalam topik klasifikasi citra dengan pendekatan *transfer learning*.
 - b. Memberikan wawasan mengenai potensi penerapan *deep learning* dalam permasalahan lingkungan, khususnya dalam konteks daur ulang dan pengelolaan sampah modern.

- c. Mendorong pengembangan solusi berbasis teknologi dalam skala industri maupun masyarakat umum untuk mendukung program daur ulang dan ekonomi sirkular.

1.4. Hipotesis

1. Hipotesis nol (H_0) :

Model ResNet-50 tidak mampu mengklasifikasikan jenis sampah berdasarkan citra digital dengan akurasi dibawah 80%.

2. Hipotesis alternatif (H_1) :

Model ResNet-50 mampu mengklasifikasikan jenis sampah berdasarkan citra digital dengan akurasi yang tinggi dan memenuhi ambang performa yang ditetapkan dengan akurasi diatas 80%.

1.5. Batasan Masalah

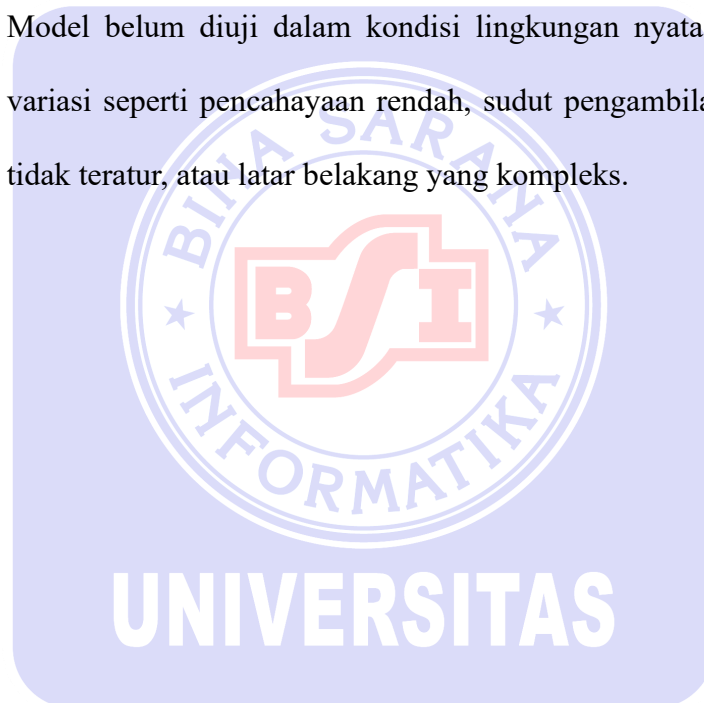
Agar penelitian lebih terfokus dan terarah, maka penelitian ini memiliki beberapa batasan masalah sebagai berikut :

1. Jenis dan Kategori Sampah

- a. Penelitian ini hanya difokuskan pada klasifikasi gambar sampah dalam kategori utama sampah anorganik, yang terdiri dari lima kelas: karton (*cardboard*), kaca (*glass*), logam (*metal*), kertas (*paper*), dan plastik (*plastic*).
- b. Penelitian tidak mencakup sub-klasifikasi yang lebih rinci, seperti membedakan jenis plastik berdasarkan warna atau bentuk, serta tidak mencakup kategori sampah organik atau B3.

2. Implementasi Sistem

- a. Penelitian ini hanya berfokus pada pengembangan dan evaluasi model klasifikasi citra menggunakan arsitektur *ResNet-50*, dan belum mencakup implementasi sistem dalam skala real-time.
3. Kondisi Lingkungan:
- a. Pengembangan dan pelatihan model dilakukan dengan menggunakan citra digital dalam kondisi ideal, yaitu gambar dengan resolusi jelas, pencahayaan cukup, serta latar belakang yang relatif bersih dan terkontrol.
 - b. Model belum diuji dalam kondisi lingkungan nyata yang memiliki variasi seperti pencahayaan rendah, sudut pengambilan gambar yang tidak teratur, atau latar belakang yang kompleks.



BAB II

LANDASAN TEORI

2.1. Tinjauan Pusataka

2.1.1. Konsep Pengelolaan Sampah

1. Definisi

Menurut (BPK (Badan Pemeriksaan Keuangan, 2021) sampah merupakan salah satu permasalahan lingkungan yang tak terhindarkan sebagai konsekuensi dari aktivitas manusia. Berdasarkan peraturan pemerintah Republik Indonesia Nomor 27 Tahun 2020 tentang pengelolaan sampah spesifik. Sampah didefinisikan sebagai sisa kegiatan sehari-hari manusia dan diproses oleh alam yang berbentuk padat (Pasal 1 ayat 1). Definisi ini menekankan bahwa sampah adalah hasil yang tidak lagi dibutuhkan dari suatu proses kehidupan atau alamiah yang berpotensi mengganggu keseimbangan lingkungan apabila tidak dikelola dengan baik (Naufal et al., 2023).

Dalam perspektif ekonomi sirkular, sampah dipandang tidak sekadar sebagai limbah, tetapi sebagai sumber daya yang memiliki nilai jika dikelola secara tepat. Menurut (Purwanti et al., 2021) dalam model ekonomi sirkular, sampah dapat diproses dan didaur ulang menjadi produk baru atau menjadi bahan baku *alternatif*, sehingga mengurangi tekanan terhadap sumber daya alam dan meminimalisir dampak negatif terhadap lingkungan (Malihah et al., 2024).

Menurut (Utari et al., 2022) kebiasaan konsumsi merupakan pola perilaku konsumsi yang dilakukan seseorang secara berulang untuk memenuhi kebutuhannya, yang berkontribusi langsung terhadap kuantitas sampah domestik yang dihasilkan. Kuantitas sampah ini dipengaruhi oleh berbagai faktor seperti gaya hidup, tempat tinggal, pengetahuan, dan kesadaran terhadap pengelolaan sampah. Mahasiswa dengan

kebiasaan konsumsi yang kurang baik, seperti sering membeli produk berkemasan sekali pakai, cenderung menghasilkan lebih banyak sampah, terutama sampah anorganik.

Menurut (Asri Farida Sihalo, 2020) dari sudut pandang lingkungan, sampah adalah limbah padat yang terdiri dari bahan organik dan anorganik yang dianggap tidak berguna lagi dan harus dikelola agar tidak membahayakan lingkungan dan melindungi investasi pembangunan SNI 19-2454-2002.

Berdasarkan berbagai pandangan tersebut, dapat disimpulkan bahwa sampah adalah sisa atau residu dari kegiatan manusia maupun alam yang tidak diinginkan, tidak berguna, atau tidak memiliki nilai ekonomis langsung, namun berpotensi menimbulkan pencemaran jika tidak dikelola secara tepat. Dalam konteks pembangunan berkelanjutan dan ekonomi sirkular, sampah harus dilihat sebagai entitas yang dapat dimanfaatkan kembali melalui proses pemilahan, pengolahan, dan daur ulang.


2. Klasifikasi

Menurut (Fajar Natsir, 2024) Sampah secara umum dapat diklasifikasikan ke dalam beberapa kategori berdasarkan karakteristik fisik maupun asalnya, yaitu sampah organik, anorganik, dan bahan berbahaya. Sampah organik merupakan limbah yang berasal dari sisa makhluk hidup, seperti sisa makanan, dedaunan, dan kayu, yang bersifat mudah terurai secara alami. Sebaliknya, sampah anorganik adalah limbah *non-biodegradable* yang terdiri atas bahan-bahan seperti plastik, logam, kaca, dan kertas, yang sulit terurai dan membutuhkan penanganan khusus. Sementara itu, sampah berbahaya mengandung zat kimia beracun yang dapat membahayakan kesehatan dan lingkungan, contohnya adalah baterai bekas, limbah medis, dan bahan kimia industri.

Klasifikasi ini memiliki peranan penting dalam mendukung proses daur ulang serta mewujudkan sistem pengelolaan sampah yang lebih efektif, efisien, dan berkelanjutan.

2.1.2 Deep Learning

Deep learning merupakan salah satu cabang dari *machine learning* yang terinspirasi dari cara kerja otak manusia. Pendekatan ini menggunakan struktur yang disebut *artificial neural networks* (jaringan saraf tiruan), yang terdiri atas banyak lapisan (*layers*). Teknologi ini memungkinkan sistem komputer untuk mempelajari informasi dari data dalam jumlah besar serta mampu mengenali pola-pola kompleks, seperti pada gambar, teks, dan suara (Raup et al., 2022). Salah satu algoritma yang umum digunakan dalam deep learning untuk melatih data berskala besar dengan jutaan parameter adalah *Convolutional Neural Network* (CNN). CNN dirancang secara khusus untuk mengolah data visual, seperti gambar dan video, dengan cara mengenali pola serta fitur-fitur visual yang terkandung di dalamnya (Ananto et al., 2023)




Sumber: (*ScienceDirect.com*)

Gambar II. 1
Deep Learning

2.1.3 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu jenis algoritma *deep learning* yang sangat efektif dalam melakukan pengenalan dan deteksi objek dalam

gambar. CNN terdiri dari beberapa lapisan utama seperti *convolutional layer*, *pooling layer*, dan *fully connected layer* (Luthfi Bangun Permadi & Restu, 2024).



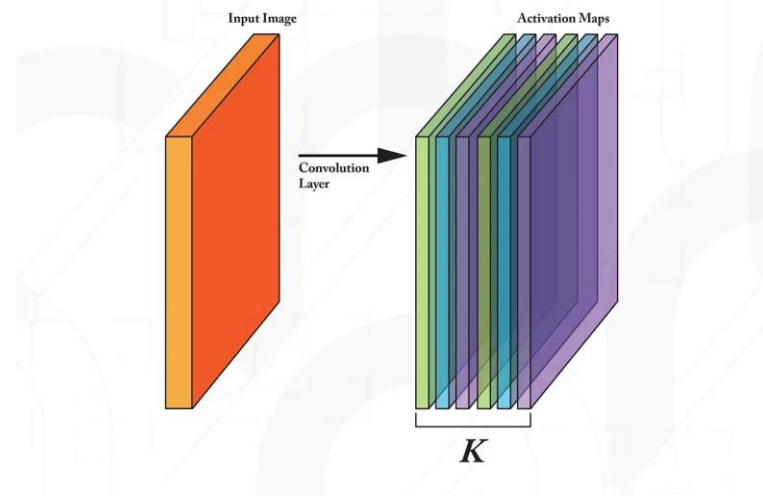
Convolutional Neural Network (CNN)

Sumber: (Trivusi.web.id)

Gambar II. 2
CNN

1. *Convolutional Layer*

Lapisan konvolusi (*convolutional layer*) merupakan komponen utama dalam arsitektur *Convolutional Neural Network* (CNN). Lapisan ini berfungsi untuk mengekstraksi ciri-ciri (fitur) dari data input, seperti gambar, audio, teks, dan *time series*. Melalui penerapan sejumlah *filter* atau *kernel*, lapisan konvolusi menghasilkan *feature map* yang menyoroti karakteristik penting dalam data tersebut. *Feature map* ini selanjutnya menjadi representasi yang lebih bermakna untuk diproses pada lapisan-lapisan berikutnya. Prinsip kerja dari lapisan konvolusi melibatkan operasi konvolusi antara filter dengan data input, yang memungkinkan sistem untuk menangkap pola-pola spasial, seperti tepi (*edges*), sudut (*corners*), dan tekstur dalam citra digital (Zhao & Zhang, 2024).



Sumber: (Richard Dharmadi)

Gambar II. 3
Convolution Layer

$$f(x) = \begin{cases} x, & \text{if } x \geq 0 \\ 0, & \text{if } x \leq 0 \end{cases}$$

f = nama fungsi.

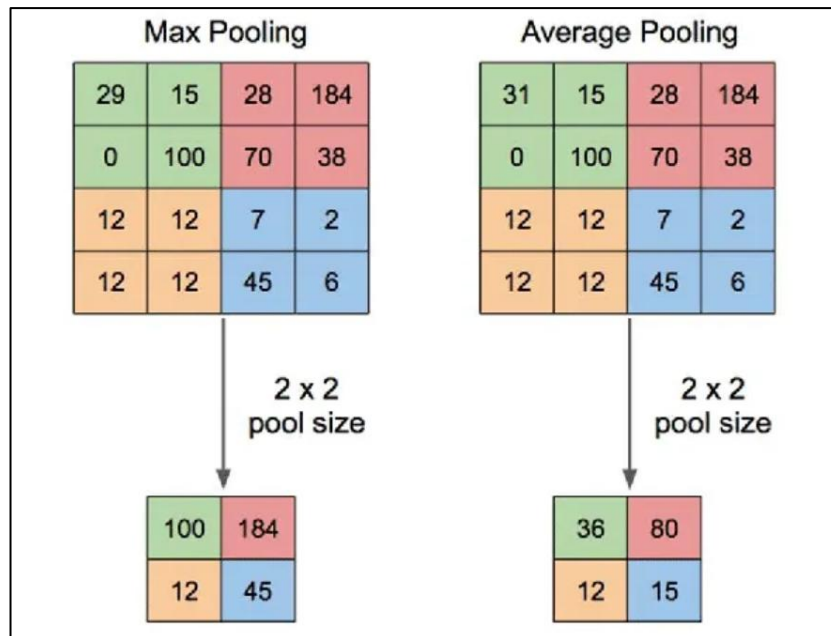
x = input dari fungsi (bisa berupa angka, vektor, hasil operasi, dll).

$f(x)$ = hasil/output dari fungsi setelah menerima input x .

2. Pooling Layer

Pooling layer merupakan salah satu komponen penting dalam arsitektur *Convolutional Neural Network* (CNN) yang umumnya ditempatkan setelah *convolutional layer*. Fungsi utama dari pooling layer adalah untuk mengurangi dimensi spasial dari *feature map* yang dihasilkan oleh *convolutional layer*. Proses ini bertujuan untuk menekan jumlah parameter dan komputasi yang dibutuhkan pada lapisan-lapisan berikutnya, serta berkontribusi dalam mengurangi risiko terjadinya *overfitting* pada model (Zhao & Zhang, 2024). Proses ini dikenal juga

dengan istilah *downsampling* atau *subsampling*. Terdapat beberapa jenis *pooling* yang umum digunakan dalam CNN, di antaranya adalah *max pooling* dan *average pooling*.



Sumber: (Richard Dharmadi)


Gambar II. 4
Jenis-jenis operasi *pooling*

Dengan penerapan *pooling layer*, jaringan CNN menjadi lebih efisien dan mampu mempertahankan informasi penting dari input citra sambil mengurangi kompleksitas data secara keseluruhan.

3. *Fully Connected Layer*

Fully connected layer (Basha et al., 2020) merupakan lapisan dalam arsitektur jaringan saraf tiruan yang berfungsi untuk melakukan transformasi terhadap data hasil ekstraksi fitur dari lapisan-lapisan sebelumnya agar dapat diklasifikasikan secara *linear*. Pada lapisan ini, setiap *neuron* terhubung secara penuh (*fully connected*) dengan seluruh neuron di lapisan sebelumnya, sehingga memungkinkan jaringan untuk mempelajari kombinasi kompleks dari fitur yang

telah diekstraksi oleh *convolutional dan pooling layer*. Output dari *fully connected layer* berupa vektor satu dimensi yang mengandung informasi *representatif* dari citra input. Nilai-nilai pada vektor ini akan diproses lebih lanjut untuk menghasilkan output akhir dalam bentuk prediksi kelas atau probabilitas dari setiap kategori objek. Dengan demikian, *fully connected layer* memiliki peran penting dalam tahap akhir



Sumber (Samuel Sena)


Gambar II. 5
Jaringan Saraf Tiruan

klasifikasi pada model CNN, yaitu mengubah representasi fitur menjadi keputusan klasifikasi (Magdalena et al., 2022).

2.1.4 ResNet-50

Arsitektur ResNet-50 terdiri dari beberapa blok *residual* yang masing-masing memiliki *shortcut connection* atau *skip connection* yang memungkinkan informasi dari lapisan sebelumnya dapat diteruskan ke lapisan yang lebih dalam tanpa mengalami perubahan. Mekanisme ini terbukti efektif dalam meningkatkan akurasi dan mempercepat proses pelatihan, karena model dapat belajar lebih dalam tanpa kehilangan informasi penting (Demmesse et al., 2024). Dalam penelitian ini, *ResNet-*

50 digunakan sebagai base model untuk melakukan klasifikasi citra jenis-jenis sampah (Jihan Nuariputri et al., 2023).



Sumber: (Suvaditya Mukherjee)

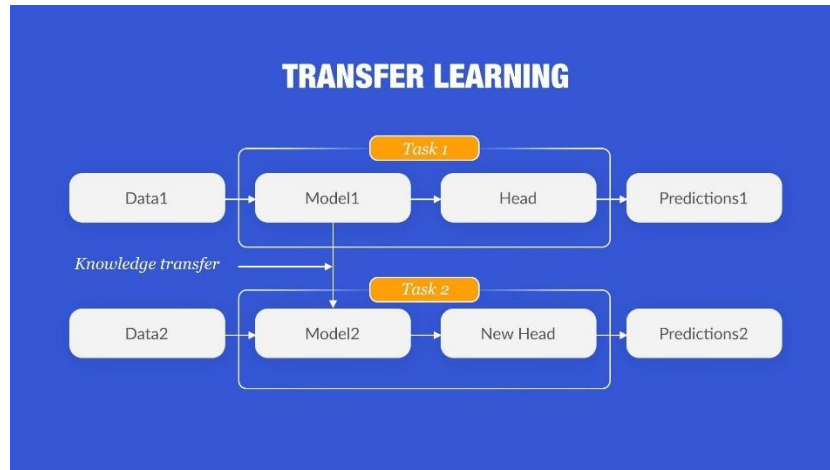
Gambar II. 6

Arsitektur ResNet-50

Keunggulan *ResNet-50* terletak pada kemampuannya dalam mengatasi *degradasi* akurasi pada jaringan dalam dan efisiensi dalam proses pelatihan, sehingga model ini menjadi pilihan populer untuk berbagai tugas klasifikasi citra, baik dalam bidang pengenalan objek, deteksi penyakit tanaman, hingga pengelompokan jenis sampah.

2.1.5 *Transfer Learning*

Transfer learning adalah pendekatan dalam *machine learning* di mana model yang sudah dilatih pada suatu tugas dengan dataset besar (misalnya *ImageNet*) digunakan kembali untuk tugas yang berbeda namun terkait. Pendekatan ini sangat berguna ketika dataset target berukuran kecil. Dengan memanfaatkan fitur yang telah dipelajari oleh model awal, proses pelatihan menjadi lebih cepat dan efisien, serta dapat menghasilkan performa yang baik meskipun dengan data terbatas (Wildan, 2024)



Sumber: (towardsdatascience.com)

Gambar II. 7
Visualisasi Transfer Learning

2.1.6 Tensor Flow

TensorFlow adalah *framework open-source* yang dikembangkan oleh Google untuk membangun, melatih, dan menerapkan model *machine learning* dan *deep learning*. *Framework* ini memungkinkan pengembang dan peneliti untuk membuat model-model AI yang kompleks dengan efisien, menggunakan konsep grafik komputasi di mana operasi matematika direpresentasikan sebagai node dan data multidimensi yang disebut tensor mengalir melalui *edges* dalam grafik tersebut.

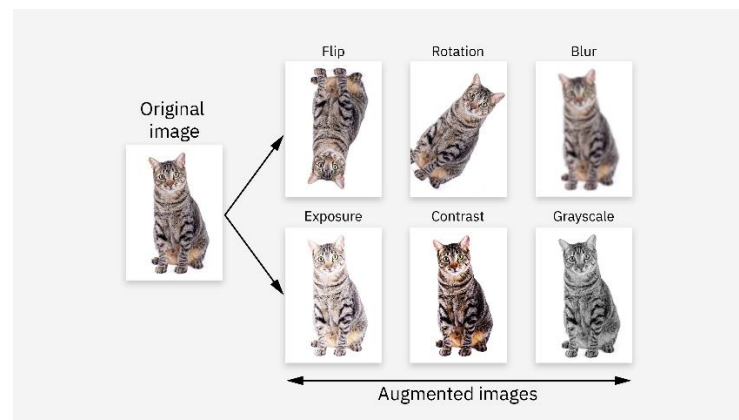


Sumber: (Tensorflow.org)

Gambar II. 8
Logo TensorFlow

2.1.7 Data Augmentation

Data augmentation adalah proses menghasilkan data baru dari data yang sudah ada dengan melakukan modifikasi atau transformasi kecil, seperti memutar, membalik, memperbesar, memotong, atau mengubah warna pada gambar, serta mengganti sinonim atau parafrasa pada teks. Tujuannya adalah untuk memperkaya dan memperbesar dataset agar model machine learning dapat belajar dari variasi data yang lebih beragam tanpa perlu mengumpulkan data baru (Permana et al., 2022).



Sumber: (IBM.Com)

Gambar II. 9

Visualisasi Data Augmentation

UNIVERSITAS

2.1.8 Confusion Matrix

Confusion matrix adalah sebuah tabel yang digunakan untuk mengevaluasi kinerja model klasifikasi. Matriks ini membandingkan hasil prediksi model dengan label sebenarnya dari data uji. Dengan *confusion matrix*, kita bisa mengetahui seberapa baik model memprediksi kelas-kelas tertentu (Permana et al., 2022)

		Predicted Values	
		Positive	Negative
Actual Values	Positive	70	30 Type 2 Error
	Negative	20 Type 1 Error	180

Sumber: (Blog train in Data.com)

Gambar II. 10
Confusion Matrix

2.2. Penelitian Terkait

Penelitian ini dilakukan melalui studi pustaka dan penelusuran literatur, di mana penulis mencari berbagai referensi yang berkaitan dengan topik penelitian. Referensi tersebut dicari secara daring melalui internet. Literatur yang ditemukan, seperti skripsi, jurnal, dan produk serupa, kemudian dianalisis untuk mendukung penelitian ini. Analisis tersebut bertujuan untuk memperluas cakupan terkait pada bidang penerapan transfer learning menggunakan arsitektur *deep cnn ResNet-50* untuk klasifikasi jenis sampah. Berikut adalah beberapa penelitian terkait dengan penelitian ini:

Tabel II. 1
Refrensi Penelitian

Penulis	Tahun	Metode	Hasil

<p>Jihan Nuariputri, Maimunah dan Pristi Sukmasetya</p>	<p>2023</p>	<p>Convolution Neural Network (CNN) dengan Arsitektur ResNet-50 dan fine-tuning</p>	<p>Akurasi validasi mencapai 98.70% pada epoch ke-9 dan 10. Setelah fine-tuning, akurasi validasi mencapai 100% dan akurasi pelatihan 98.73% pada epoch ke-18.</p>
<p>Ahmed Khan H, Naqvi s, Alharbi A, Alotaibi s, Alkathami M</p>	<p>2024</p>	<p>Deep Learning berbasis CNN (10 model), termasuk ResNeXt-101, ResNet, MobileNet, GoogLeNet + Federated Learning</p>	<p>Model ResNeXt-101 memperoleh akurasi 89.62% dan F1 score 89.66% (tertinggi). Disusul ResNeXt-50. Penelitian juga mengusulkan framework federated learning untuk menggabungkan 4 model unggulan demi akurasi optimal di sistem terdistribusi.</p>
<p>Wu F, Lin H</p>	<p>2022</p>	<p>Deep Learning menggunakan CNN (VGGNet-16 & ResNet-50), dengan dan tanpa Transfer Learning</p>	<p>ResNet-50 dengan Transfer Learning menunjukkan hasil terbaik: akurasi 96.6%, F1 score 97.8% untuk sampah organik, serta 93.0% untuk sampah residu. Transfer learning mempercepat</p>

			pelatihan dan meningkatkan akurasi dibanding model tanpa TL.
Anugrayani Bustamin, Baizul Zaman , Fadhil Khusnul Hakim	2023	CNN dengan arsitektur ResNet-50 + Transfer Learning, optimizer Adam, LR = 0.00005	Model mencapai akurasi 97,73% pada epoch ke-5 hanya dalam 8 epoch pelatihan. Model mampu mengklasifikasi jenis sampah anorganik secara efektif dan diuji dengan gambar di luar dataset, menunjukkan performa yang konsisten dan akurat.
Cristin E Nainggolan, Muhammad Nasir, Fatoni dan Udariansyah	2024	Penelitian ini menggunakan metode eksperimen dengan membandingkan dua arsitektur CNN, yaitu ResNet18 dan ResNet50, untuk klasifikasi gambar sampah. Data diproses melalui tahapan resize, augmentasi, normalisasi, dan konversi ke tensor. Model dibangun menggunakan Python dengan Keras dan TensorFlow di Google Colab. Evaluasi dilakukan menggunakan metrik akurasi, precision, recall, F1-score, dan confusion matrix.	Model ResNet18 mencapai akurasi 98.69% dengan waktu pelatihan 22 menit, sedangkan ResNet50 mencapai 99.41% dalam 34 menit. Keduanya menunjukkan precision dan recall sekitar 99%. ResNet50 unggul dalam akurasi, namun ResNet18 lebih efisien dalam waktu. Kedua model dinilai sangat baik

			dalam klasifikasi citra sampah.
--	--	--	------------------------------------

Sumber: (Hasil Penelitian, 2025)

Perbedaan penelitian ini dengan penelitian-penelitian sebelumnya terletak pada domain aplikasi serta dataset yang digunakan. Penelitian ini secara khusus menerapkan ResNet-50 untuk klasifikasi jenis sampah berdasarkan citra digital, suatu bidang yang masih relatif jarang dieksplorasi secara mendalam, khususnya dengan konteks data sampah di Indonesia. Selain itu, penelitian ini menekankan pada optimalisasi preprocessing citra dan evaluasi performa model dengan *metrik akurasi, presisi, recall*, dan *F1-score* sehingga dapat memberikan gambaran lebih *komprehensif* mengenai kemampuan model. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi baru sekaligus memperkuat literatur dalam bidang penerapan *deep learning* untuk pengelolaan lingkungan.

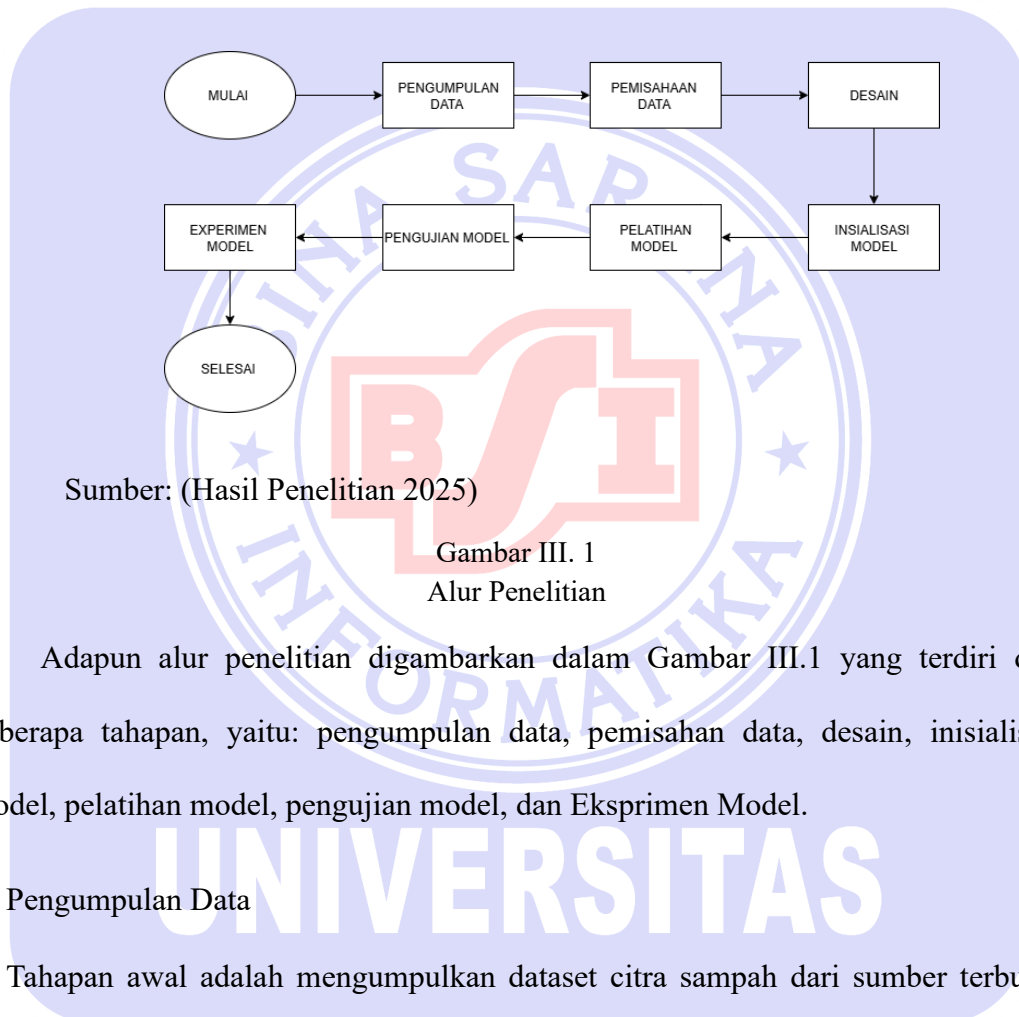


UNIVERSITAS

BAB III METODOLOGI PENELITIAN

3.1. Proses dan Langkah Penelitian

Penelitian ini bersifat eksperimental yang bertujuan untuk mengembangkan model klasifikasi citra jenis sampah menggunakan arsitektur *deep learning ResNet50* dengan pendekatan *transfer learning*



Sumber: (Hasil Penelitian 2025)

Gambar III. 1
Alur Penelitian

Adapun alur penelitian digambarkan dalam Gambar III.1 yang terdiri dari beberapa tahapan, yaitu: pengumpulan data, pemisahan data, desain, inisialisasi model, pelatihan model, pengujian model, dan Eksprimen Model.

1. Pengumpulan Data

Tahapan awal adalah mengumpulkan dataset citra sampah dari sumber terbuka. Dataset yang digunakan adalah *Trash Images* dari platform Kaggle, yang terdiri dari lima kelas utama: *cardboard*, *glass*, *metal*, *paper*, dan *plastic*. Data dikumpulkan lalu di periksa apakah data sesuai dengan yang sesuai kebutuhan dan disusun kedalam struktur folder berdasarkan label kelas masing-masing.

```
[ ] 1 !kaggle datasets download susandanesmand/trash-images
Dataset URL: https://www.kaggle.com/datasets/susandanesmand/trash-images
License(s): apache-2.0
trash-images.zip: Skipping, found more recently modified local copy (use --force to force download)
```

Sumber: (Peneliti 2025)

Gambar III. 2
Pengumpulan Dataset

2. Pemisahan Data

Setelah data terkumpul dan terstruktur, dilakukan pemisahan data menjadi dua subset, yaitu data pelatihan (*training set*) dan data pengujian (*testing set*). Pembagian dilakukan secara stratifikasi agar proporsi jumlah data pada tiap kelas tetap seimbang.

3. Desain

Tahapan ini mencakup perancangan sistem klasifikasi citra, termasuk pemetaan *label numerik*, pembuatan data *pipeline*, dan pra-pemrosesan citra. Data juga diproses dengan *augmentasi* seperti rotasi, zoom, dan *flipping* untuk meningkatkan variasi data dan mencegah *overfitting*.

4. Inisialisasi Model

Pada tahap ini dilakukan pemanggilan model *ResNet-50* yang telah dilatih sebelumnya (*pre-trained*) pada *dataset ImageNet*. *Layer* awal dibekukan, sementara *layer* klasifikasi terakhir (*fully connected*) diubah agar sesuai dengan jumlah kelas dataset penelitian.

5. Pelatihan Model

Proses pelatihan dilakukan selama 50 *epoch* menggunakan *optimizer AdamW* dan fungsi kehilangan *CrossEntropyLoss*. Data dimuat melalui *PyTorch Data Loader* secara bertahap (*batch*) untuk efisiensi memori dan waktu pelatihan. Model dievaluasi setiap *epoch* untuk mencatat *loss* dan *accuracy* pada data pelatihan dan validasi.

6. Pengujian Model

Setelah pelatihan selesai, model diuji menggunakan data pengujian untuk mengukur performa sebenarnya. Evaluasi dilakukan dengan menghitung metrik seperti *accuracy*, *precision*, *recall*, *f1-score* dan *Support* pada masing-masing kelas, serta menampilkan *confusion matrix* untuk test data.

7. Eksprimen Model

Tujuan dari eksperimen dalam klasifikasi citra jenis sampah menggunakan arsitektur *ResNet-50* adalah untuk mengevaluasi efektivitas pendekatan *transfer learning* dalam mengenali berbagai kategori sampah berdasarkan gambar.

3.2. Metode Pengolahan dan Analisis Data

Metode pengolahan dan analisis data dalam penelitian ini bertujuan untuk membangun dan mengevaluasi model klasifikasi citra jenis sampah menggunakan pendekatan *deep learning* berbasis arsitektur *ResNet50*. Pada penelitian ini, proses pengolahan data mencakup serangkaian tahapan yang dimulai dari penyiapan data, transformasi, hingga pembuatan struktur data untuk pelatihan dan pengujian. Sementara itu, analisis data mencakup evaluasi performa model berdasarkan *metrik evaluasi* yang digunakan.

3.2.1. Pra-pemrosesan Data

Dataset *Trash Images* dari Kaggle diunduh dan diekstrak, lalu disusun berdasarkan label kelas ke dalam struktur direktori yang terpisah. Setiap gambar diubah ukurannya menjadi 224×224 piksel agar sesuai dengan input model *ResNet-50*. Kemudian, dilakukan *normalisasi piksel* dan proses *denoising* menggunakan fungsi OpenCV untuk meningkatkan kualitas gambar dan mempercepat *konvergensi model*.

3.2.2. Pemetaan Label

Label kelas yang awalnya berbentuk teks seperti *cardboard*, *glass*, *metal* dikonversi ke format numerik melalui struktur *dictionary* atau *label map*. Pemetaan ini penting agar label dapat digunakan dalam fungsi loss seperti *Cross Entropy Loss*, yang memerlukan input berupa *indeks numerik*.

3.2.3. Pembagian Dataset

Data dibagi menjadi dua bagian, yaitu data pelatihan (70%) dan data pengujian (30%) dengan menggunakan metode *stratifikasi* agar proporsi jumlah kelas tetap seimbang. Pembagian ini dilakukan menggunakan fungsi *train test split* dari *Scikit learn* dengan parameter *stratify* berdasarkan label.

3.2.4. Augmentasi Label

Untuk meningkatkan variasi data dan kemampuan generalisasi model, dilakukan augmentasi pada data pelatihan. *Augmentasi* menggunakan *Image Data Generator* dengan transformasi seperti rotasi acak, zoom, *flipping horizontal*, dan pergeseran posisi gambar.

3.2.5. Pembuatan Data Loader

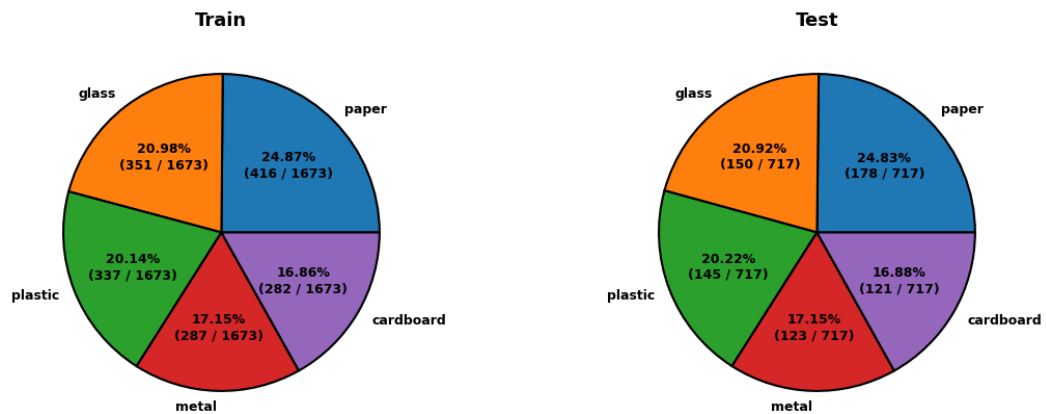
Data yang telah diproses dimasukkan ke dalam *Custom Dataset* dan dimuat dengan *Data Loader* dari *PyTorch*. Penggunaan *Data Loader* memungkinkan pemuatan data secara efisien dalam *batch*, dengan pengacakan data *shuffle* dan *paralelisasi multi-worker* untuk meningkatkan efisiensi pelatihan.

BAB IV

HASIL DAN PEMBAHASAN

4.1. Hasil Penelitian

1. Hasil Pelatihan Model



Sumber: (Peneliti 2025)

Gambar IV. 1
Data Train dan Data Test

Proses pelatihan dilakukan terhadap model klasifikasi citra jenis sampah menggunakan arsitektur *ResNet-50* yang diimplementasikan melalui pendekatan *transfer learning*. Dataset telah dibagi ke dalam dua bagian, yaitu data latih (*train*) sebanyak 1.673 gambar dan data uji (*test*) sebanyak 717 gambar. Pembagian data dilakukan secara stratifikasi untuk memastikan bahwa proporsi jumlah data pada masing-masing kelas tetap seimbang, sebagaimana terlihat pada gambar diagram pie di atas.

Pada data latih, kelas *paper* memiliki porsi terbesar yaitu 24,87% (416/1673), diikuti oleh *glass* sebesar 20,98%, *plastic* sebesar 20,14%, *metal* sebesar 17,15%, dan *cardboard* sebesar 16,86%. Pola distribusi yang hampir identik juga diterapkan pada data uji, dengan kelas *paper* tetap dominan sebesar 24,83% (178/717), dan diikuti

secara proporsional oleh kelas lainnya. Hal ini penting agar model tidak mengalami bias terhadap kelas mayoritas saat proses pelatihan.

Model kemudian dilatih selama beberapa *epoch* dengan menggunakan fungsi *loss* dan *optimizer* yang telah disesuaikan. Selama proses pelatihan berlangsung, dilakukan pencatatan terhadap nilai *loss* dan *accuracy* baik pada data latih maupun validasi. Nilai-nilai tersebut disimpan dalam sebuah struktur data (*dictionary*) untuk kemudian dianalisis lebih lanjut guna mengevaluasi performa model. Dengan distribusi data yang seimbang serta pelatihan yang optimal, model diharapkan mampu mengenali dan membedakan jenis sampah berdasarkan citra dengan akurasi tinggi dan generalisasi yang baik.

2. Hasil *Skore Epoch Validation*

Setiap *epoch* yang dijalankan memberikan hasil berupa metrik evaluasi seperti *train loss*, *train accuracy*, *validation loss*, dan *validation accuracy*. Berdasarkan grafik yang dihasilkan dari proses pelatihan, terlihat bahwa nilai *training accuracy* menunjukkan tren peningkatan dari *epoch* ke *epoch*, sedangkan nilai *validation loss* mengalami penurunan yang stabil, menandakan bahwa model mampu mempelajari data dengan baik. Nilai akurasi validasi tertinggi yang dicapai adalah sekitar 85%, yang sudah memenuhi ambang batas performa minimum yang ditetapkan dalam penelitian ini ($\geq 80\%$).

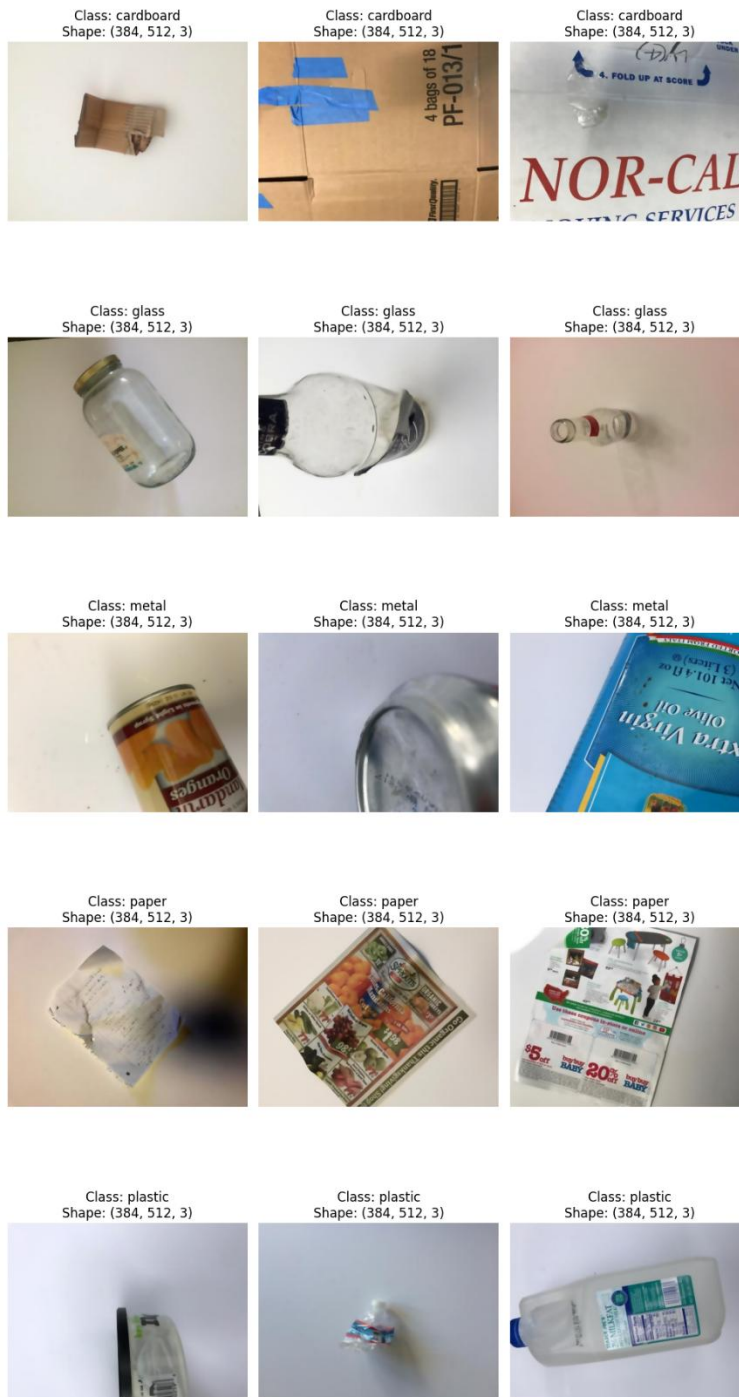
Tabel IV. 1
Train accuracy

Epoch	Train Loss	Train Accuracy	Test Loss	Test Accuracy
36	0.6570	0.7568	0.5226	0.8640
47	0.6195	0.7755	0.4541	0.8502

50	0.6011	0.7922	0.4776	0.8384
----	--------	--------	--------	--------

Sumber: (Peneliti 2025)

3. Training



Gambar IV.2

Visualisasi Data Latih

Sumber: (Peneliti 2025)

Gambar di atas menunjukkan beberapa contoh data latih dari masing-masing kelas yang terdapat dalam dataset *Trash Images*. Setiap citra memiliki resolusi standar sebesar 384×512 piksel dengan tiga saluran warna (RGB), sebagaimana ditunjukkan oleh keterangan "*Shape: (384, 512, 3)*" pada masing-masing gambar.

Terdapat lima kelas utama dalam dataset ini, yaitu:

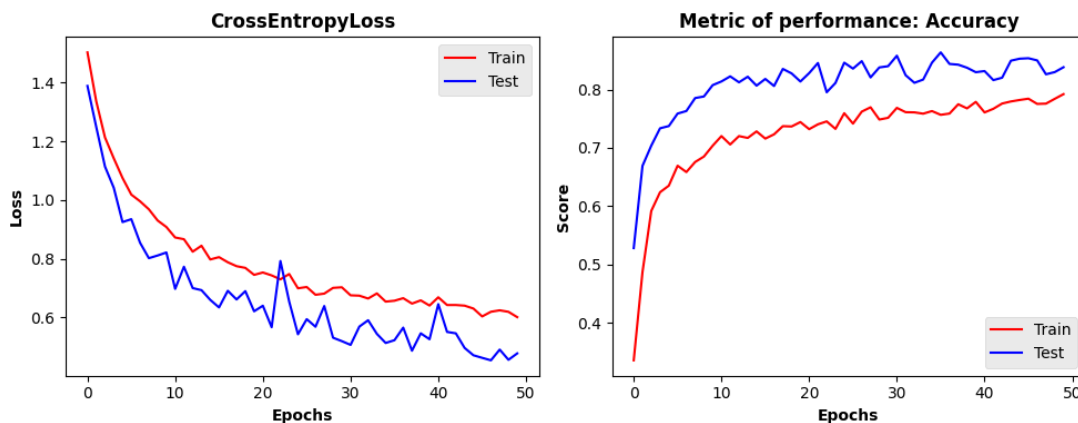
- a. *Cardboard*: Menampilkan gambar kardus bekas dalam berbagai bentuk dan warna, termasuk permukaan polos, sisi lipatan, dan permukaan dengan cetakan teks.
- b. *Glass*: Berisi gambar botol dan wadah kaca dalam posisi yang bervariasi, baik berdiri tegak maupun terbaring.
- c. *Metal*: Menampilkan gambar kaleng minuman, tutup botol, dan wadah logam lainnya dengan pencahayaan yang berbeda.
- d. *Paper*: Memuat gambar kertas dalam bentuk selebaran, brosur, dan kertas lipat yang umumnya memiliki teks atau gambar cetak.
- e. *Plastic*: Berisi gambar botol plastik, plastik bening pembungkus, dan komponen plastik lainnya.

Visualisasi ini sangat penting untuk memahami karakteristik visual dari masing-masing kelas, sekaligus memastikan bahwa data pelatihan mencakup keragaman bentuk, warna, sudut pengambilan gambar, dan kondisi objek (misalnya rata atau kusut). Variasi ini akan membantu model dalam mengenali pola-pola umum pada citra dan meningkatkan kemampuan generalisasi saat dihadapkan pada data uji baru. Dengan dataset yang representatif dan beragam seperti ini, proses pelatihan model *ResNet-50* dapat berjalan secara optimal, karena model memiliki cukup

informasi visual untuk belajar membedakan antar kelas sampah dengan akurasi yang tinggi.

4.2. Hasil Pengujian

1. Model Results



Sumber: (Peneliti 2025)

Gambar IV. 2
Epochs Accuracy

a. Grafik Kiri – *CrossEntropyLoss*

Grafik ini menunjukkan penurunan nilai *loss* selama proses pelatihan model menggunakan fungsi *CrossEntropyLoss*. Nilai *loss* menggambarkan seberapa besar kesalahan model dalam melakukan prediksi. Garis merah menunjukkan *loss* pada data pelatihan, sementara garis biru menunjukkan *loss* pada data pengujian. Dari grafik terlihat bahwa kedua garis mengalami penurunan secara bertahap dari *epoch* ke-0 hingga *epoch* ke-50. Penurunan ini menunjukkan bahwa model berhasil belajar dan memperbaiki prediksinya seiring bertambahnya *epoch*. Selain itu, nilai *loss* pada data pengujian cenderung lebih rendah daripada data pelatihan, yang menandakan bahwa model tidak mengalami *overfitting* secara signifikan dan tetap mampu mempertahankan performa yang baik pada data yang belum pernah dilihat sebelumnya.

b. Grafik Kanan – *Metric of Performance: Accuracy*

Grafik ini menampilkan nilai akurasi model selama proses pelatihan. Akurasi menggambarkan seberapa tepat model dalam mengklasifikasikan gambar ke dalam kelas yang benar. Garis merah menunjukkan akurasi pada data pelatihan, sedangkan garis biru menunjukkan akurasi pada data pengujian. Pada awal pelatihan, akurasi model masih rendah, namun grafik menunjukkan peningkatan yang signifikan dalam beberapa epoch pertama, lalu meningkat secara perlahan dan stabil hingga akhir pelatihan. Di akhir epoch, akurasi pengujian mencapai sekitar 85%, lebih tinggi daripada akurasi pelatihan. Hal ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan dapat melakukan prediksi yang cukup akurat terhadap data baru.

2. *Confusion Matrix*

Confusion Matrix - Test Data

True Labels	cardboard	100	0	1	20	0
	glass	0	133	5	2	10
	metal	2	2	115	1	3
	paper	5	0	6	165	2
	plastic	2	24	15	6	98
			cardboard	glass	metal	paper
		Predicted Labels				

Sumber: (Peneliti 2025)

Gambar IV. 3
Confusion Matrix

a. *Cardboard*

Kelas *cardboard* menunjukkan hasil klasifikasi yang cukup baik dengan total 121 gambar pada data uji. Dari jumlah tersebut, model berhasil mengklasifikasikan dengan benar sebanyak 100 gambar, sementara sisanya mengalami kesalahan klasifikasi. Tercatat sebanyak 1 gambar *cardboard* diklasifikasikan sebagai *metal* dan 20 gambar sebagai *paper*, sedangkan tidak ada yang salah diklasifikasikan sebagai *glass* atau *plastic*. Berdasarkan hasil ini, diperoleh akurasi kelas *cardboard* sebesar 82,64%, yang menunjukkan bahwa model cukup mampu mengenali karakteristik visual dari sampah jenis *cardboard*, meskipun masih terdapat kebingungan dengan kelas *paper* yang secara visual cukup mirip.

b. *Glass*

Kelas *glass* terdiri dari 150 gambar pada data uji. Model mampu mengklasifikasikan sebanyak 133 gambar dengan benar sebagai *glass*, sedangkan sisanya salah diklasifikasikan ke kelas lain, yaitu 5 gambar dikira *metal*, 2 sebagai *paper*, dan 10 sebagai *plastic*. Tidak ada gambar *glass* yang diklasifikasikan sebagai *cardboard*. Dengan demikian, diperoleh akurasi untuk kelas *glass* sebesar 88,67%, yang menunjukkan performa model yang cukup tinggi, meskipun masih terdapat tantangan dalam membedakan antara kaca dan plastik atau logam karena kemiripan bentuk dan permukaan reflektif.

c. *Metal*

Sebanyak 123 gambar pada data uji termasuk dalam kelas *metal*. Dari jumlah tersebut, model berhasil memprediksi dengan benar sebanyak 115 gambar. Kesalahan klasifikasi meliputi 2 gambar dikira *cardboard*, 2 dikira *glass*, 1 sebagai *paper*, dan 3 sebagai *plastic*. Dengan akurasi sebesar 93,50%, model menunjukkan performa yang

sangat baik dalam mengenali karakteristik visual sampah berbahan logam, dengan kesalahan minor yang bisa disebabkan oleh kemiripan bentuk atau warna dengan plastik dan kaca.

d. Paper

Kelas *paper* memiliki total 178 gambar pada data uji, dengan 165 di antaranya berhasil diklasifikasikan dengan benar oleh model. Kesalahan klasifikasi melibatkan 5 gambar yang dikira *cardboard*, 6 sebagai *metal*, dan 2 sebagai *plastic*. Akurasi klasifikasi untuk kelas ini mencapai 92,70%, menjadikan *paper* sebagai salah satu kelas dengan performa terbaik. Hal ini menunjukkan bahwa model cukup akurat dalam mengenali tekstur dan karakteristik unik dari kertas.

e. Plastic

Kelas *plastic* merupakan kelas yang paling banyak mengalami kesalahan klasifikasi. Dari 145 gambar, hanya 98 yang berhasil diklasifikasikan dengan benar. Sisanya tersebar ke beberapa kelas lain: 24 gambar dikira *glass*, 15 sebagai *metal*, 6 sebagai *paper*, dan 2 sebagai *cardboard*. Dengan akurasi hanya sebesar 67,59%, kelas *plastic* menunjukkan tantangan terbesar bagi model, kemungkinan disebabkan oleh kemiripan bentuk botol plastik dengan kaca atau logam, serta variasi warna dan tekstur yang lebih tinggi dibandingkan kelas lainnya.

3. *Clasification Report Test*

```

=====
Classification Report Test
=====
              precision    recall  f1-score   support

 cardboard      0.92      0.83      0.87      121
   glass         0.84      0.89      0.86      150
   metal         0.81      0.93      0.87      123
   paper         0.85      0.93      0.89      178
   plastic       0.87      0.68      0.76      145

 accuracy              0.85      717
 macro avg           0.86      0.85      0.85      717
 weighted avg        0.86      0.85      0.85      717

```

Sumber: (Peneliti 2025)

Gambar IV. 4
Classification Report Test

Evaluasi kinerja model dilakukan menggunakan *metrik precision, recall, dan f1-score* terhadap masing-masing kelas. Hasil evaluasi ini ditampilkan pada Classification Report sebagaimana terlihat pada Gambar IV. 5. Berdasarkan hasil tersebut, kelas *cardboard* memiliki *precision* sebesar 0.92, yang berarti bahwa dari semua prediksi sebagai *cardboard*, 92% di antaranya benar. *Recall* kelas ini sebesar 0.83 menunjukkan bahwa dari total 121 gambar *cardboard* dalam data uji, sebanyak 83% berhasil dikenali dengan benar. Nilai *f1-score* sebesar 0.87 menunjukkan keseimbangan antara *precision* dan *recall* yang cukup baik.

Untuk kelas *glass*, *precision* sebesar 0.84 dan *recall* sebesar 0.89 menunjukkan bahwa model cukup mampu mengenali gambar *glass* dengan akurat, dengan nilai *f1-score* mencapai 0.86. Sementara itu, pada kelas *metal*, *precision* berada pada angka 0.81 dan *recall* mencapai 0.93, yang berarti sebagian besar gambar metal berhasil diklasifikasikan dengan benar, meskipun terdapat sejumlah prediksi yang salah. Nilai *f1-score* pada kelas *metal* adalah 0.87, mencerminkan performa yang stabil.

Kelas *paper* menjadi salah satu kelas dengan performa tertinggi, dengan *precision* sebesar 0.85 dan *recall* sebesar 0.93. Hal ini menunjukkan bahwa model sangat baik

dalam mengenali gambar kelas ini, yang juga didukung oleh nilai *f1-score* tertinggi yaitu 0.89. Sebaliknya, performa terendah ditemukan pada kelas *plastic* dengan *recall* sebesar 0.68. Hal ini menunjukkan bahwa masih banyak gambar *plastic* yang salah diklasifikasikan ke dalam kelas lain. Meskipun *precision*-nya cukup tinggi sebesar 0.87, nilai *f1-score* yang hanya mencapai 0.76 menunjukkan ketidakseimbangan antara kemampuan model mengenali *plastic* dan kesalahan prediksinya.

Secara keseluruhan, model mencapai akurasi sebesar 0.85, yang menunjukkan bahwa 85% dari total 717 gambar uji diklasifikasikan dengan benar. Nilai *macro average* untuk *precision*, *recall*, dan *f1-score* masing-masing adalah 0.86, 0.85, dan 0.85, yang menunjukkan performa rata-rata antar kelas secara merata. Sedangkan *weighted average*, yang mempertimbangkan jumlah sampel tiap kelas, juga menunjukkan hasil yang konsisten dengan nilai masing-masing sebesar 0.86, 0.85, dan 0.85. Hasil ini menunjukkan bahwa model yang dibangun memiliki performa yang cukup baik dalam mengklasifikasikan lima jenis sampah, meskipun masih perlu dilakukan perbaikan terutama pada kelas *plastic*.

4. Prediksi Gambar Tunggal

Predicted Class: cardboard



Gambar IV. 5
Prediksi Gambar Tunggal

Gambar di atas menunjukkan hasil prediksi model terhadap satu citra uji yang berasal dari kelas sampah anorganik. Berdasarkan hasil pengolahan citra oleh model, kelas yang diprediksi adalah *cardboard*. Citra tersebut menampilkan potongan kardus dengan ciri khas berupa warna cokelat alami, tekstur bergelombang, serta tepi yang tidak beraturan, yang umum ditemukan pada material kardus bekas. Model berhasil mengidentifikasi objek ini secara akurat sesuai dengan label sebenarnya, yaitu kardus *cardboard*.

Proses prediksi ini merupakan bagian dari evaluasi performa model pada gambar *individual*. Pada tahap ini, model menerima input berupa satu gambar tunggal yang telah melalui tahapan *preprocessing*, seperti *resizing* ke ukuran 224×224 piksel, konversi ke bentuk *tensor*, dan normalisasi nilai *piksel*. Setelah itu, model mengolah citra tersebut dengan menerapkan parameter bobot yang telah dipelajari selama proses pelatihan, dan menghasilkan prediksi kelas yang sesuai. Keakuratan model dalam mengklasifikasikan citra ini menunjukkan bahwa model memiliki kemampuan dalam mengenali fitur visual utama dari material kardus. Ciri-ciri seperti warna dominan, permukaan bertekstur khas, serta pola kerusakan pada sisi-sisi kardus dapat dikenali dan dibedakan dari jenis sampah lainnya. Keberhasilan ini sejalan dengan hasil evaluasi kuantitatif sebelumnya, di mana kelas *cardboard* memperoleh nilai *precision* sebesar 0.92 dan *f1-score* sebesar 0.87, yang mencerminkan kinerja klasifikasi yang baik pada kategori ini.

BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan hasil penelitian dan pembahasan yang telah diuraikan pada bab sebelumnya, maka dapat disimpulkan beberapa hal penting sebagai berikut:

1. Penelitian ini berhasil mengembangkan sistem klasifikasi citra jenis sampah berbasis *deep learning* menggunakan *arsitektur ResNet-50* dengan pendekatan *transfer learning*. Model dilatih menggunakan dataset *Trash Images* dari platform kaggle dan telah melalui proses prapemrosesan data, pemetaan label ke format numerik, augmentasi citra untuk meningkatkan variasi data, serta pembagian dataset secara stratifikasi agar proporsi tiap kelas tetap seimbang. Hasil evaluasi menunjukkan bahwa model mencapai akurasi validasi sebesar 85%, melebihi ambang batas minimal kinerja sebesar 80% sebagaimana ditetapkan dalam hipotesis. Selain itu, nilai *precision*, *recall*, dan *f1-score* pada masing-masing kelas juga menunjukkan performa yang baik dan seimbang, membuktikan bahwa model mampu mengenali dan membedakan jenis sampah secara akurat berdasarkan citra digital. Dengan demikian, hipotesis alternatif (H_1) dapat diterima bahwa *arsitektur ResNet-50* mampu memberikan hasil klasifikasi yang akurat dan memenuhi standar performa yang ditetapkan dalam penelitian ini
2. Model menunjukkan performa klasifikasi yang sangat baik, dengan akurasi validasi tertinggi mencapai 85% pada data pengujian. Hal ini menunjukkan bahwa model mampu mengenali dan membedakan citra sampah berdasarkan lima kelas utama, yaitu *cardboard*, *glass*, *metal*, *paper*, dan *plastic* secara akurat.

3. Evaluasi model menggunakan *confusion matrix* dan *classification report* menunjukkan bahwa sebagian besar kelas memiliki nilai *precision*, *recall*, dan *f1-score* yang tinggi dan seimbang, yang mengindikasikan kemampuan model dalam melakukan klasifikasi secara konsisten dan stabil pada semua kelas.
4. Sistem juga berhasil diimplementasikan dengan fitur prediksi gambar tunggal melalui antarmuka *interaktif* menggunakan komponen FileUpload. Fitur ini memungkinkan pengguna untuk menguji model secara langsung terhadap gambar baru yang tidak termasuk dalam data pelatihan, dan hasilnya menunjukkan bahwa model mampu melakukan prediksi dengan akurasi yang baik, bahkan pada citra yang belum pernah dilihat sebelumnya.

5.2. Saran

Adapun beberapa saran yang dapat diberikan berdasarkan pelaksanaan dan hasil penelitian ini adalah:

1. Perluasan Dataset

Menambahkan jumlah dan variasi gambar pada setiap kelas akan membantu model mengenali karakteristik visual dengan lebih baik, khususnya pada kelas yang memiliki kemiripan visual seperti *glass* dan *metal*.

2. Penambahan Kategori Sampah

Untuk meningkatkan kegunaan sistem dalam aplikasi nyata, jumlah kategori dapat diperluas (misalnya: organik basah, elektronik, tekstil) agar mencerminkan klasifikasi sampah yang lebih kompleks di lingkungan nyata.

3. Optimasi Hyperparameter

Penelitian lanjutan dapat melakukan tuning lebih lanjut terhadap *hyperparameter* seperti *learning rate*, *batch size*, dan jumlah *epoch* untuk memperoleh hasil yang lebih optimal.

4. Konversi Model untuk *Deployment*

Model yang telah dilatih dapat dikonversi ke format seperti ONNX atau *TensorFlow Lite* agar dapat digunakan pada perangkat mobile atau sistem *embedded*, sehingga lebih praktis untuk diimplementasikan di lapangan.



DAFTAR PUSTAKA

- Ananto, D. T., Duta Mahardewantoro, D., Mustafa, F., Ardianto, M. G., Rafi, M. M., Zein, R. A., Saputra, O. E., Mujiastuti, R., Rosanti, N., & Adharani, Y. (2023). *Prosiding Seminar Nasional LPPM UMJ Website: <http://jurnal.umj.ac.id/index.php/semnaskat> E-ISSN: 2714-6286 Edukasi dan Pelatihan Pengenalan Machine Learning dan Computer Vision Untuk Mengeksplorasi Potensi Visual.* <http://jurnal.umj.ac.id/index.php/semnaskat>
- Asri Farida Sihaloho. (2020). *Sampah dari sudut pandang BSN SNI 19-2454-2002.*
- Basha, S. H. S., Dubey, S. R., Pulabaigari, V., & Mukherjee, S. (2020). Impact of fully connected layers on performance of convolutional neural networks for image classification. *Neurocomputing*, 378, 112–119. <https://doi.org/10.1016/j.neucom.2019.10.008>
- BPK (Badan Pemeriksaan Keuangan). (2021). *BPK (Badan Pemeriksaan Keuangan), sampah merupakan .*
- Bustamin, A., Zaman, B., Khusnul Hakim, F., Teknik Gowa, K., Poros Malino, J. K., Bontomarannu, K., Kharisma Makassar, S., Baji Ateka No, J., Mappakasunggu, B., Mamajang, K., & Makassar, K. (2023). *SISTEM MULTI KLASIFIKASI SAMPAH ANORGANIK DENGAN MENGGUNAKAN TRANSFER LEARNING INORGANIC WASTE MULTI CLASSIFICATION SYSTEM USING TRANSFER LEARNING* (Vol. 8, Issue 1). <http://journal.uinalauddin.ac.id/index.php/insypro>
- Demmese, F. A., Shajarian, S., & Khorsandroo, S. (2024). Transfer learning with ResNet50 for malicious domains classification using image visualization. *Discover Artificial Intelligence*, 4(1). <https://doi.org/10.1007/s44163-024-00154-z>
- Fajar Natsir. (2024). *Jenis Sampah Organik dan Anorganik Serta Cara Pengelolaannya.* 2024.
- Jihan Nuariputri. (2023). Klasifikasi Jenis Sampah Menggunakan Base ResNet-50. *Jurnal Ilmiah Komputasi*, 22(3). <https://doi.org/10.32409/jikstik.22.3.3380>
- Jihan Nuariputri, Maimunah, & Pristi. (2023). Klasifikasi Jenis Sampah Menggunakan Base ResNet-50. *Jurnal Ilmiah Komputasi*, 22(3). <https://doi.org/10.32409/jikstik.22.3.3380>
- Li, L., Wang, R., Zou, M., Guo, F., & Ren, Y. (2025). Enhanced ResNet-50 for garbage classification: Feature fusion and depth-separable convolutions. *PLoS ONE*, 20(1 January). <https://doi.org/10.1371/journal.pone.0317999>
- Luthfi Bangun Permadi, & Restu. (2024). *PENERAPAN ALGORITMA CNN (CONVOLUTIONAL NEURAL NETWORK) UNTUK DETEKSI DAN KLASIFIKASI TARGET MILITER BERDASARKAN CITRA SATELIT.*

- Malihah, L., Nazairin, A., & Martapura Kalimantan Selatan, D. (2024). YUME : Journal of Management Sampah Plastik Sachet Dalam Perspektif Pembangunan Berkelanjutan. In *YUME : Journal of Management* (Vol. 7, Issue 1).
- Naufal, M., Kasuma, A.-H., Fadhila, A., & Aini, N. (2023). *Kepastian Hukum Kebijakan Extended Producer Responsibility Bagi Produsen Penghasil Sampah*. <https://sipsn.menlhk.go.id/sipsn/>,
- Nurmia, L. Z., Andriyatno, A., Fitriani, F., & Munandar, R. (2025). Optimalisasi Pengelolaan Sampah Dan Daur Ulang Untuk Mengurangi Emisi Gas Rumah Kaca Di Perkotaan. *Lambda Jurnal Ilmiah Pendidikan MIPA Dan Aplikasinya*, 5(1), 1–8. <https://doi.org/10.58218/lambda.v5i1.1104>
- Permana, R., Saldu, H., & Maulana, D. I. (2022). OPTIMASI IMAGE CLASSIFICATION PADA JENIS SAMPAH DENGAN DATA AUGMENTATION DAN CONVOLUTIONAL NEURAL NETWORK. *Jurnal Sistem Informasi Dan Informatika (Simika)*, 5.
- Purwanti, I., Syariah, J. E., Ekonomi, F., Islam, B., & Pekalongan, I. (2021). *AmaNU: Jurnal Manajemen dan Ekonomi KONSEP DAN IMPLEMENTASI EKONOMI SIRKULAR DALAM PROGRAM BANK SAMPAH (STUDI KASUS: KEBERLANJUTAN BANK SAMPAH TANJUNG)* (Vol. 4, Issue 1).
- Raup, A., Ridwan, W., Khoeriyah, Y., Yuliati Zaqiah, Q., & Islam Negeri Sunan Gunung Djati Bandung, U. (2022). *Deep Learning dan Penerapannya dalam Pembelajaran*. <http://Jiip.stkipyapisdampu.ac.id>
- Utari, E., Pramudita, W. P., & Pratiwi, Z. (2022). *Jurnal Ekologi, Masyarakat dan Sains Analisis Hubungan Kebiasaan Konsumsi Dengan Kuantitas Sampah Domestik (Studi Pada Mahasiswa Pendidikan Biologi Untirta Angkatan 2020)*. <https://doi.org/10.55448/ems>
- Wildan, N. C. D. (2024). *8352-Article Text-26606-1-10-20241213*.
- Wu, F., & Lin, H. (2022). Effect of transfer learning on the performance of VGGNet-16 and ResNet-50 for the classification of organic and residual waste. *Frontiers in Environmental Science*, 10. <https://doi.org/10.3389/fenvs.2022.1043843>
- Zhao, L., & Zhang, Z. (2024). A improved pooling method for convolutional neural networks. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-51258-6>

DAFTAR RIWAYAT HIDUP

I. Biodata Mahasiswa

NIM : 15210083
Nama Lengkap : Adisaputra Marbun
Tempat / Tanggal Lahir : Sibongkare, 21 December 2001
Alamat lengkap : Jl. Kamal Raya, Cengkareng Tim., Kecamatan Cengkareng, Kota Jakarta Barat, Daerah Khusus Ibukota Jakarta

II. Pendidikan

a. Formal

1. SD Negeri 173499 Sibongkare, lulus tahun 2014
2. SMP Negeri 4 Pakkat, lulus tahun 2017
3. SMK Neg 2 Pakkat, lulus tahun 2020
4. Universitas Bina Sarana Informatika, belum lulus

b. Tidak Formal

1. Study Independen Bersertifikat Batch 6 Pembuatan Game Design Develoment 2D
2. LaskarAI

III. Riwayat Pengalaman berorganisasi / perkerjaan

1. Magang di Kementerian dan Energi Sumber Daya Mineral



Jakarta, 17 Agustus 2025










UNIVERSITAS

Adisaputra Marbun

LEMBAR KONSULTASI

	LEMBAR KONSULTASI SKRIPSI
	UNIVERSITAS BINA SARANA INFORMATIKA

NIM : 15210083
Nama Lengkap : Adisaputra Marbun
Dosen Pembimbing I : Budi Sudrajat, M.Kom
Judul Skripsi : Penerapan Transfer Learning Menggunakan Arsitektur Deep CNN RestNet-50 Untuk Klasifikasi Sampah

NO	Tanggal Bimbingan	Pokok Pembahasan	Paraf Dosen Pembimbing I
1.	17 April 2025	Bimbingan Perdana	
2.	16 Mei 2025	Bimbingan BAB I	
3.	30 Mei 2025	Bimbingan BAB II	
4.	13 Juni 2025	Bimbingan BAB III	
5.	19 Juni 2025	Bimbingan BAB IV	
6.	20 Juni 2025	Bimbingan BAB V	
7.	23 Juni 2025	Revisi BAB V dan Cek Turnitin	
8.	30 Juni 2025	ACC Keseluruhan	
9.	02 Oktober 2025	Revisi Jurnal	

Catatan untuk Dosen Pembimbing Bimbingan Skripsi

Dimulai Tanggal : 17 April 2025
Diakhiri Pada Tanggal : 30 Juni 2025
Jumlah Pertemuan : 8 Kali

Disetujui oleh,
Dosen Pembimbing I













Manda signan Digital:
budi.sudrajat@bsi.ac.id
2025-10-19 11:27:07

(Budi Sudrajat, M.Kom)

	LEMBAR KONSULTASI SKRIPSI
	UNIVERSITAS BINA SARANA INFORMATIKA

NIM : 15210083
 Nama Lengkap : Adisaputra Marbun
 Dosen Pembimbing II : Hasta Herlan Asymar, S.T., M.M
 Judul Skripsi : Penerapan Transfer Learning Menggunakan Arsitektur Deep CNN ResNet-50 Untuk Klasifikasi Jenis Sampah

NO	Tanggal Bimbingan	Pokok Pembahasan	Paraf Dosen Pembimbing II
1.	17 April 2025	Bimbingan Perdana	
2.	20 April 2025	Pengajuan BAB I	
3.	30 April 2025	Pengajuan BAB II	
4.	28 Mei 2025	Pengajuan BAB III	
5.	4 Juni 2025	Pengajuan BAB IV	
6.	10 Juni 2025	Pengajuan BAB V	
7.	16 Juni 2025	Cek Turnitin	
8.	30 Juni 2025	Acc Keseluruhan	
9.	10 Oktober 2025	Revisi	

Catatan untuk Dosen Pembimbing Bimbingan Skripsi
 Dimulai Tanggal : 17 April 2025
 Diakhiri Pada Tanggal : 30 Juni 2025
 Jumlah Pertemuan : 9

Disetujui oleh,
Dosen Pembimbing II




Ditandatangani Digital:
 Hasta Herlan Asymar
 2025-10-20 17:57:40

(Hasta Herlan Asymar, M.Kom)

SURAT KETERANGAN RISET/ SURAT KEABSAHAN DATA



LAMPIRAN

A1. Hasil Turnitin

 Page 2 of 51 - Integrity Overview Submission ID: 113286096200


17% Overall Similarity
The combined total of all matches, including overlapping sources, for each database.

Top Sources

- 14%  Internet sources
- 9%  Publications
- 7%  Submitted works (Student Papers)

 Page 2 of 51 - Integrity Overview Submission ID: 113286096200

Top Sources

14%  Internet sources
9%  Publications
7%  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	
	ejournal.jak-stik.ac.id	<1%
2	Internet	
	ejournal.itenas.ac.id	<1%
3	Internet	
	docplayer.info	<1%
4	Publication	
	Enggar Utari, Wida Putri Pramudita, Zulia Pratiwi. "Analisis Hubungan Kebiasaan ...	<1%
5	Student papers	
	Universitas Muslim Indonesia	<1%
6	Internet	
	es.scribd.com	<1%
7	Student papers	
	STT PLN	<1%
8	Student papers	
	Universitas Sumatera Utara	<1%
9	Internet	
	repositori.unsil.ac.id	<1%
10	Student papers	
	Universitas Jember	<1%
11	Internet	
	medium.com	<1%

12	Internet	www.mdpi.com	<1%
13	Student papers	Badan PPSDM Kesehatan Kementerian Kesehatan	<1%
14	Publication	Galih Hermawan. "Klasifikasi Pengemudi Terganggu Berdasarkan Citra Menggun...	<1%
15	Internet	ejurnal.seminar-id.com	<1%
16	Internet	etheses.uin-malang.ac.id	<1%
17	Internet	jurnal.umt.ac.id	<1%
18	Internet	www.chandra-asri.com	<1%
19	Internet	www.coursehero.com	<1%
20	Publication	Ni Putu Irene Pasca Nurahdika, Joko Sutopo. "Analisa Performa Convolution Neur...	<1%
21	Internet	docslib.org	<1%
22	Internet	digilib.unila.ac.id	<1%
23	Student papers	Forum Perpustakaan Perguruan Tinggi Indonesia Jawa Tengah	<1%
24	Internet	ojs.smkmerahputih.com	<1%
25	Internet	repository.unsri.ac.id	<1%

26	Publication	RakhimatuFitria Mekacahyani, Badie'ah Badie'ah, Imam Much Ibnu Subroto, "Cla...	<1%
27	Student papers	iGroup	<1%
28	Internet	123dok.com	<1%
29	Student papers	Universitas Maritim Raja Ali Haji	<1%
30	Internet	adoc.pub	<1%
31	Internet	informatika.stei.itb.ac.id	<1%
32	Internet	repo.unikadelasalle.ac.id	<1%
33	Publication	Ahmad Sihabillah, Abu Tholib, Iliyiah Ibnul Basit. "OPTIMASI MODEL RESNET50 U...	<1%
34	Internet	eprints.ums.ac.id	<1%
35	Internet	journal.mediapublikasIid	<1%
36	Internet	repository.ibs.ac.id	<1%
37	Publication	Eggi Chandra, Yus Sholva, Hafiz Muhardi. "Perancangan Sistem Pemantau Keting...	<1%
38	Internet	ojs.unud.ac.id	<1%
39	Internet	openlibrarypublications.telkomuniversity.ac.id	<1%

40	Internet	www.researchgate.net	<1%
41	Internet	www.slideshare.net	<1%
42	Internet	repo-mhs.ulm.ac.id	<1%
43	Internet	repository.teknokrat.ac.id	<1%
44	Internet	repository.unja.ac.id	<1%
45	Internet	www.perumpertoindo.co.id	<1%
46	Publication	Abdul Jalil Rozaqi, Muhammad Rudyanto Arief, Andi Sunyoto. "Implementation of...	<1%
47	Publication	J.L. Loeppky, D. Bingham, R.R. Sitter. "Constructing non-regular robust parameter...	<1%
48	Publication	Yudisman Ferdinan Bilik, Tundo, Nandang Sutisna, Atsilah Daini Putri, Dita Tri Yuli...	<1%
49	Internet	daysindelft.wordpress.com	<1%
50	Internet	ejournal.unhasy.ac.id	<1%
51	Internet	io.traffine.com	<1%
52	Internet	journal.ipb.ac.id	<1%
53	Internet	ojs.amikomsolo.ac.id	<1%



54	Internet	publikasiilmiah.ums.ac.id	<1%
55	Internet	fajarhidayat513.wordpress.com	<1%
56	Internet	library.universitaspertamina.ac.id	<1%
57	Publication	Afriani Afriani, Herry Sujaini, Niken Candraningrum. "Analisis Perbandingan Met...	<1%
58	Publication	Fifin Fitriana, Nurzaidah Putri Dalimunthe, Fitri Apriani, Sujadi Priyansah, Maulan...	<1%
59	Internet	jurnal.unprimdn.ac.id	<1%

lix

lix

B1. Hasil Submit Jurnal

The screenshot shows the website for Jurnal Ilmu Teknik dan Komputer. The browser address bar displays the URL: publikasi.mercubuana.ac.id/index.php/jitkom/author/saveSubmit/5. The page title is "Jurnal Ilmu Teknik dan Komputer" with the URL https://publikasi.mercubuana.ac.id/index.php/jitkom. The navigation menu includes HOME, ABOUT, USER HOME, SEARCH, CURRENT, ARCHIVES, and ANNOUNCEMENTS. The main content area is titled "Active Submissions" and shows a message: "Submission complete. Thank you for your interest in publishing with Jurnal Ilmu Teknik dan Komputer." Below this message, there is a list of "Active Submissions" (currently empty). The page also includes a "JURNAL MENU" sidebar with links like Editorial Team, Peer Review Process, and Author Guidelines. A "SUBMIT A MANUSCRIPT" button is visible. The footer contains contact information for Jurnal Ilmu Teknik dan Komputer, including the address at Universitas Mercu Buana Jakarta, phone numbers, fax, homepage, email, P-ISSN (2548-740X), and E-ISSN (2621-1491). It also features a Creative Commons Attribution-NonCommercial 4.0 International License logo and the DOI 10.322. On the right side, there is a "TOOLS" section with logos for Journal Template, Turnitin, Grammarly, Mendeley, Zotero, and EndNote.

