

**PERBANDINGAN PERFORMA KLASIFIKASI GAMBAR SAMPAH
ANTARA *MOBILENETV2* DAN *DENSENET169***

SKRIPSI



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS BUDDHI DHARMA
TANGERANG
2024**

**PERBANDINGAN PERFORMA KLASIFIKASI GAMBAR SAMPAH
ANTARA *MOBILENETV2* DAN *DENSENET169***

SKRIPSI

**Diajukan sebagai salah satu syarat untuk kelengkapan gelar kesarjanaan pada
Program Studi Teknik Informatika
Jenjang Pendidikan Strata 1**



**NAZZUA AZZAHRA
20201000069**

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS BUDDHI DHARMA
TANGERANG
2024**

LEMBAR PERSEMBAHAN

“life is hard, but God sent me indah basudara”

Dengan mengucapkan puji syukur kepada Tuhan Yang Maha Esa, Skripsi ini kupersembahkan untuk:

1. Allah SWT, sebagai bentuk penghormatan dan ungkapan syukur atas segala rahmat-Nya yang tiada henti.
2. Diri sendiri yang telah berjuang dan bekerja keras sepanjang proses penelitian ini.
3. Bapak dan Ibu tercinta, yang telah membesarkan aku dan selalu membimbing, mendukung, memotivasi, memberi apa yang terbaik bagiku serta selalu mendoakan aku untuk meraih suksesku.
4. Keluarga Besar dari Bapak dan Ibu, yang telah memberikan dukungan moral, doa, dan cinta yang tak terhingga selama perjalanan ini.
5. Bapak Aditya Hermawan, yang telah membimbing dan memberikan masukan selama penulisan penelitian.
6. Sahabat-sahabat saya yang selalu memberikan semangat dan dukungan sepanjang proses penelitian ini.
7. Teman-teman Kelompok belajar “dunia terbalik”, yang telah menjadi sumber kekuatan dan keceriaan dalam setiap langkah perjalanan akademis ini.
8. Teman-teman Kelompok belajar “kita usahakan s.kom itu sambil makan mie ayam” yang telah setia bersama sejak awal semester, menemani dan mendukung dalam segala perjuangan.
9. Kakak tingkatku Lidya Lunardi, Sonya Eliesse Dameria, Cut Mita Sari Safitri, Margaretha Natalya, dan Aditya Gunawan yang telah memberikan inspirasi dan teladan dalam perjalanan akademis ini.
10. Indah Basudara yang kekocakannya selalu menghibur, telah menjadi sumber semangat saya dalam menyelesaikan skripsi ini.

UNIVERSITAS BUDDHI DHARMA
LEMBAR PERNYATAAN KEASLIAN SKRIPSI

Yang bertanda tangan di bawah ini.

NIM : 20201000069
Nama : Nazzua Azzahra
Jenjang Studi : Strata I
Program Studi : Teknik Informatika
Peminatan : Database Development

Dengan ini saya menyatakan bahwa :

1. Skripsi ini adalah asli dan belum pernah diajukan untuk mendapat gelar akademik Sarjana atau kelengkapan studi, baik di Universitas Buddhi Dharma maupun di Perguruan Tinggi lainnya.
2. Skripsi ini saya buat sendiri tanpa bantuan dari pihak lain, kecuali arahan dosen pembimbing.
3. Dalam Skripsi ini tidak terdapat karya atau pendapat yang telah ditulis atau dipublikasikan orang lain, kecuali secara tertulis dengan jelas dan dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan dicantumkan daftar pustaka.
4. Dalam Skripsi ini tidak terdapat pemalsuan (kebohongan), seperti buku, artikel, jurnal, data sekunder, pengolahan data, dan pemalsuan tanda tangan dosen atau Ketua Program Studi Universitas Buddhi Dharma yang dibuktikan dengan keasliannya.
5. Lembar pernyataan ini saya buat dengan sesungguhnya, tanpa paksaan dan apabila dikemudian hari atau pada waktu lainnya terdapat penyimpangan dan ketidak benaran dalam pernyataan ini, saya bersedia menerima sanksi akademik berupa pencabutan gelar akademik yang telah saya peroleh karena Skripsi ini serta sanksi lainnya sesuai dengan peraturan dan norma yang berlaku.

Tangerang, 30 Juli 2024
Yang membuat pernyataan,



Nazzua Azzahra
20201000069

UNIVERSITAS BUDDHI DHARMA
LEMBAR PERSETUJUAN PUBLIKASI KARYA ILMIAH

Yang bertanda tangan di bawah ini :

NIM : 20201000069
Nama : Nazzua Azzahra
Jenjang Studi : Strata 1
Program Studi : Teknik Informatika
Peminatan : Database Development

Dengan ini menyetujui untuk memberikan ijin kepada pihak Universitas Buddhi Dharma, Hak Bebas Royalti Non – Eksklusif (*Non-exclusive Royalty-Free Right*) atas karya ilmiah kami yang berjudul: “PERBANDINGAN PERFORMA KLASIFIKASI GAMBAR SAMPAH ANTARA *MOBILENETV2* DAN *DENSENET169*”, beserta alat yang diperlukan (apabila ada).

Dengan Hak Bebas Royalti Non – Eksklusif ini pihak Universitas Buddhi Dharma berhak menyimpan, mengalih-media atau format-kan, mengelolanya dalam pangkalan data (*database*), mendistribusikannya, dan menampilkan atau mempublikasikannya di *internet* atau media lain untuk kepentingan akademis tanpa perlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis atau pencipta karya ilmiah tersebut.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Universitas Buddhi Dharma, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini saya buat dengan sebenarnya.

Tangerang, 30 Juli 2024
Yang membuat pernyataan,



Nazzua Azzahra
20201000069

UNIVERSITAS BUDDHI DHARMA
LEMBAR PENGESAHAN PEMBIMBING

PERBANDINGAN PERFORMA KLASIFIKASI GAMBAR SAMPAH
ANTARA *MOBILENETV2* DAN *DENSENET169*

Dibuat Oleh :

NIM : 20201000069

Nama : Nazzua Azzahra

Telah disetujui untuk dipertahankan di hadapan Tim Penguji Ujian
Komprehensif

Program Studi Teknik Informatika
Perminatan Database Development
Tahun Akademik 2023/2024

Disahkan oleh,

Tangerang, 21 Juni 2024

Pembimbing,



Aditya Hermawan, M.Kom.
NIDN : 0406128801

UNIVERSITAS BUDDHI DHARMA
LEMBAR PENGESAHAN SKRIPSI

PERBANDINGAN PERFORMA KLASIFIKASI GAMBAR SAMPAH
ANTARA *MOBILENETV2* DAN *DENSENET169*

Dibuat Oleh :

NIM : 20201000069

Nama : Nazzua Azzahra

Telah disetujui untuk dipertahankan di hadapan Tim Penguji Ujian
Komprehensif

Program Studi Teknik Informatika
Perminatan Database Development

Tahun Akademik 2023/2024

Disahkan oleh,

Tangerang, 30 Juli 2024

Dekan,

Ketua Program Studi,



Dr. Yakub, M.Kom., M.M.
NIDN : 0304056901



Hartana Wijaya, M.Kom.
NIDN : 0412058102

LEMBAR PENGESAHAN TIM PENGUJI

Nama : Nazzua Azzahra
NIM : 20201000069
Fakultas : Sains dan Teknologi
Judul Skripsi : PERBANDINGAN PERFORMA KLASIFIKASI GAMBAR
SAMPAH ANTARA *MOBILENETV2* DAN *DENSENET169*

Dinyatakan LULUS setelah mempertahankan di depan Tim Penguji pada hari Selasa, 30 Juli 2024

Nama Penguji : Tanda Tangan :
Ketua Sidang : **Rudy Arijanto, M.Kom.**
NIDN : 0415077105
Penguji I : **Dr. Yakub, M.Kom., M.M.**
NIDN : 0304056901
Penguji II : **Aditiya Hermawan, M.Kom.**
NIDN : 0406128801

Mengetahui,
Dekan Fakultas Sains dan Teknologi

Dr. Yakub, M.Kom., M.M.

NIDN : 0304056901

KATA PENGANTAR

Dengan mengucapkan Puji Syukur kepada Tuhan Yang Maha Esa, yang telah memberikan Rahmat dan karunia-Nya kepada penulis sehingga dapat menyusun dan menyelesaikan Skripsi ini dengan judul **PERBANDINGAN PERFORMA KLASIFIKASI GAMBAR SAMPAH ANTARA *MOBILENETV2* DAN *DENSENET169***. Tujuan utama dari pembuatan Skripsi ini adalah sebagai salah satu syarat kelengkapan dalam menyelesaikan program pendidikan Strata 1 Program Studi Teknik Informatika di Universitas Buddhi Dharma. Dalam penyusunan Skripsi ini penulis banyak menerima bantuan dan dorongan baik moril maupun materiil dari berbagai pihak, maka pada kesempatan ini penulis menyampaikan rasa terima kasih yang sebesar-besarnya kepada :

1. Ibu Dr. Limajatini, S.E., M.M., B.K.P., sebagai Rektor Universitas Buddhi Dharma
2. Bapak Dr. Yakub, M.Kom., M.M., sebagai Dekan Fakultas Sains dan Teknologi
3. Bapak Rudy Arijanto, M.Kom., sebagai Wakil Dekan Fakultas Sains dan Teknologi
4. Bapak Hartana Wijaya, M.Kom., sebagai Ketua Program Studi Teknik Informatika
5. Bapak Aditiya Hermawan, M.Kom., sebagai pembimbing yang telah membantu dan memberikan dukungan serta harapan untuk menyelesaikan penulisan Skripsi ini.
6. Orang tua dan keluarga yang selalu memberikan dukungan baik moril dan materiil.
7. Teman-teman yang selalu membantu dan memberikan semangat.

Serta semua pihak yang terlalu banyak untuk disebutkan satu persatu sehingga terwujudnya penulisan ini. Penulis menyadari bahwa penulisan Skripsi ini masih belum 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 pembaca yang berminat pada umumnya.

Tangerang, 30 Juli 2024

Penulis

ABSTRAK

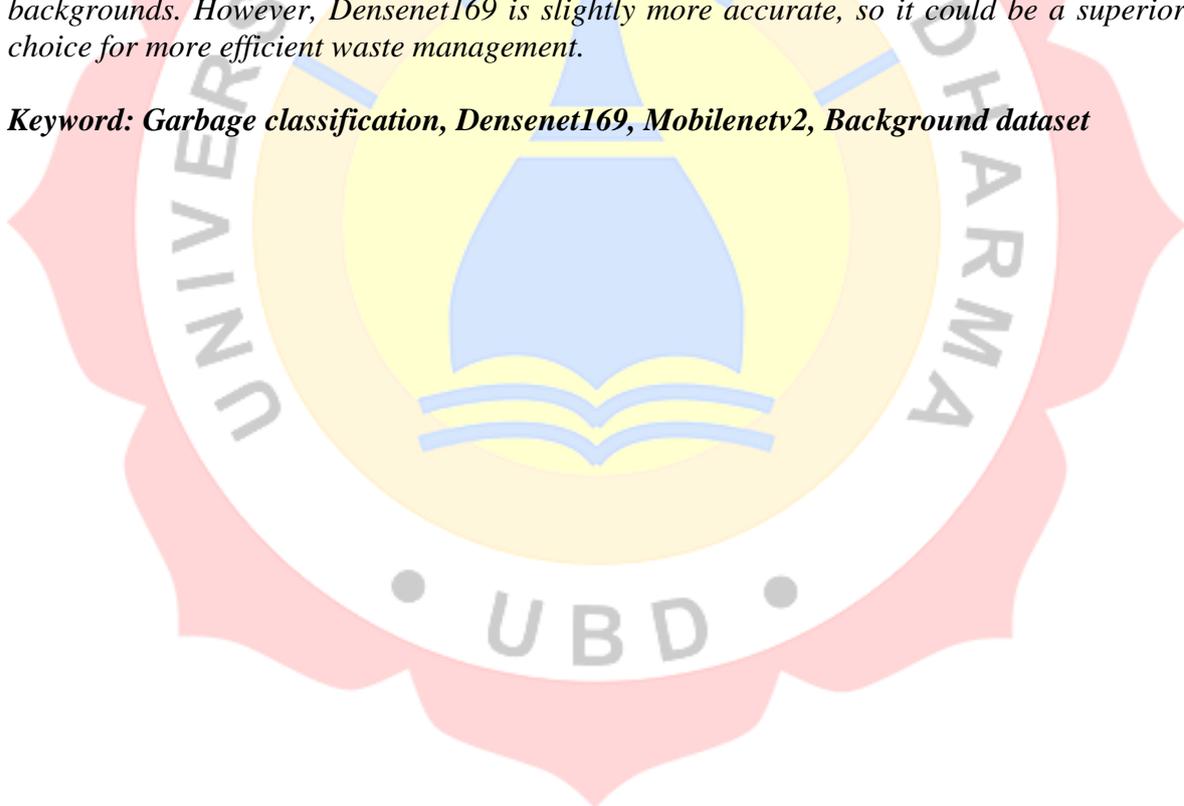
Pengelolaan sampah menjadi tantangan besar seiring dengan peningkatan populasi dan aktivitas manusia. Dalam upaya mengoptimalkan daur ulang dan pengelolaan sampah yang lebih efisien, solusi klasifikasi sampah otomatis menjadi kunci penting. Oleh karena itu, penelitian ini bertujuan untuk membandingkan kinerja dua arsitektur CNN, yaitu *Mobilenetv2* dan *Densenet169*, dalam mengklasifikasikan gambar sampah. Dua *dataset* berbeda, dengan dan tanpa *background*, digunakan untuk mengevaluasi pengaruh *background* pada akurasi klasifikasi. *Mobilenetv2* dipilih karena efisiensi dan ringannya, sedangkan *Densenet169* dipilih karena keseimbangan antara akurasi dan kecepatan. Kedua model dilatih dan dievaluasi pada *dataset* dengan enam kelas sampah: *plastic*, *metal*, *glass*, *cardboard*, *trash*, dan *paper*. Selanjutnya, *dataset* yang sudah dilabeli dibagi menjadi data *training*, validasi, dan *testing* dengan rasio 8:1:1. Proses pelatihan dilakukan dengan menggunakan teknik augmentasi data untuk meningkatkan variasi data *training* dan mencegah *overfitting*. Untuk mengevaluasi kinerja model, peneliti menggunakan *confusion matrix*, kurva ROC-AUC, dan metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-score*. Hasil penelitian menunjukkan bahwa model *Densenet169* dengan *dataset* mengandung *background* mencapai akurasi tertinggi, yaitu 88.33%, sedangkan *Mobilenetv2* dengan *dataset* yang sama juga mencapai akurasi tinggi, yaitu 84.05%. Hasil ini menunjukkan bahwa baik *Mobilenetv2* maupun *Densenet169* berhasil dengan baik dalam mengklasifikasikan gambar sampah dengan *background*. Namun, *Densenet169* sedikit lebih akurat, sehingga bisa menjadi pilihan yang lebih unggul untuk pengelolaan sampah yang lebih efisien.

Kata Kunci: Klasifikasi sampah, *Densenet169*, *Mobilenetv2*, *Background dataset*

ABSTRACT

Waste management is becoming a big challenge along with the increase in population and human activities. In an effort to optimize recycling and more efficient waste management, automatic waste classification solutions are an important key. Therefore, this research aims to compare the performance of two CNN architectures, namely Mobilenetv2 and Densenet169, in classifying trash images. Two different datasets, with and without background, are used to evaluate the influence of background on classification accuracy. Mobilenetv2 was chosen for its efficiency and lightness, while Densenet169 was chosen for its balance between accuracy and speed. Both models were trained and evaluated on a dataset with six waste classes: plastic, metal, glass, cardboard, trash, and paper. Next, the labeled dataset is divided into training, validation and testing data with a ratio of 8:1:1. The training process is carried out using data augmentation techniques to increase the variety of training data and prevent overfitting. To evaluate model performance, researchers used a confusion matrix, ROC AUC curve, and evaluation metrics such as accuracy, precision, recall, and F1-score. The research results show that the Densenet169 model with a dataset containing backgrounds achieved the highest accuracy, namely 88.33%, while Mobilenetv2 with the same dataset also achieved high accuracy, namely 84.05%. These results show that both Mobilenetv2 and Densenet169 succeeded well in classifying trash images with backgrounds. However, Densenet169 is slightly more accurate, so it could be a superior choice for more efficient waste management.

Keyword: Garbage classification, Densenet169, Mobilenetv2, Background dataset



DAFTAR ISI

LEMBAR JUDUL LUAR SKRIPSI

LEMBAR JUDUL DALAM SKRIPSI

LEMBAR PERSEMBAHAN

LEMBAR PERNYATAAN KEASLIAN SKRIPSI

LEMBAR PERSETUJUAN PUBLIKASI ILMIAH

LEMBAR PENGESAHAN PEMBIMBING

LEMBAR PENGESAHAN SKRIPSI

LEMBAR PENGESAHAN TIM PENGUJI

KATA PENGANTAR.....	i
ABSTRAK	ii
<i>ABSTRACT</i>	iii
DAFTAR ISI.....	iv
DAFTAR TABEL.....	viii
DAFTAR GAMBAR.....	ix
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang Masalah.....	1
1.2 Identifikasi Masalah	4
1.3 Ruang Lingkup	5
1.4 Tujuan dan Manfaat.....	5
1.4.1 Tujuan.....	5
1.4.2 Manfaat.....	5
1.5 Sistematika Penulisan.....	6
BAB II LANDASAN TEORI	8
2.1 Teori Umum	8
2.1.1 Data.....	8
2.1.2 <i>Website</i>	8
2.1.3 <i>Deep learning</i>	9
2.2 Teori Khusus	10
2.2.1 Convolutional Neural Network (CNN)	10
2.2.2 Sampah Anorganik	13
2.2.3 <i>Image Preprocessing</i>	14
2.2.4 <i>Mobilenetv2</i>	14

2.2.5	<i>Densenet169</i>	16
2.2.6	<i>Confusion matrix</i>	17
2.2.7	Kurva ROC-AUC	19
2.2.8	<i>Black box Testing</i>	20
2.3	Teori Rancangan.....	21
2.3.1	<i>Flowchart</i>	21
2.3.2	Python.....	22
2.3.3	HTML.....	23
2.3.4	<i>Scikit-learn</i>	24
2.3.5	<i>Tensorflow</i>	24
2.3.6	Keras.....	25
2.3.7	<i>Jupyter Notebook</i>	26
2.4	Tinjauan Studi	26
2.4.1	Penelitian oleh Abdul Fadlil, Rusydi Umar, Sunardi, Arief Setyo Nugroho.....	26
2.4.2	Penelitian oleh Sunardi, Anton Yudhana, Miftahuddin Fahmi	27
2.4.3	Penelitian oleh Cuiping Shi, Cong Tan, Tao Wang, dan Ligu Wang 27	
2.4.4	Penelitian oleh Mohammed Imran Basheer Ahmed, Raghad B. Alotaibi, Rahaf A. Al-Qahtani, Rahaf S. Al-Qahtani, Sara S. Al-Hetela, Khawla A. Al-Matar, Noura K. Al-Saqer, Atta Rahman, Linah Saraireh, Mustafa Youldash dan Gomathi Krishnasamy.....	28
2.4.5	Penelitian oleh Liying Yong, Le Ma, Dandan Sun, Liping Du.....	29
2.4.6	Penelitian oleh Ming Zeng, Xiangzhe Lu, Wenkang Xu, Tongxi Zhou, Yinbo Liu	29
2.4.7	Penelitian oleh Sujan Poudel dan Prakash Poudyal	30
2.4.8	Penelitian oleh Qiang Zhang, Qifan Yang, Xujuan Zhang, Qiang Bao, Jinqi Su, Xueyan Liu	31
2.4.9	Penelitian oleh Janusz Bobulski dan Mariusz Kubanek.....	32
2.4.10	Penelitian oleh Haris Imam Karim Fathurrahman, Ahmad Azhari, Tole Sutikno, Li-Yi Chin, Prasetya Murdaka Putra, Isro Dwian Yunandha, Gralo Yopa Rahmat Pratama, Beni Purnomo.....	32
2.4.11	Penelitian oleh Hua Zheng dan Yu Gu.....	33
2.4.12	Penelitian oleh Olugboja Adedeji dan Zenghui Wang	34

2.4.13 Penelitian oleh Kunsen Lin, Youcai Zhao, Lina Wang, Wenjie Shi, Feifei Cui, Tao Zhou	34
2.4.14 Penelitian oleh Sunardi, Anton Yudhana, Miftahuddin Fahmi	35
2.4.15 Penelitian oleh Leow Wei Qin, Muneer Ahmad, Ihsan Ali, Rafia Mumtaz, Syed Mohammad Hassan Zaidi, Sultan S. Alshamrani, Muhammad Ahsan Raza, dan Muhammad Tahir	36
2.4.16 Rangkuman Model Penelitian	37
2.5 Kerangka Pemikiran	61
BAB III METODELOGI PENELITIAN.....	62
3.1 Pengumpulan Data.....	62
3.1.1 <i>Flowchart</i> Perancangan <i>Dataset</i>	62
3.1.2 Data Sekunder dari <i>Kaggle</i>	63
3.1.3 Data Metode <i>Background Removal</i>	65
3.2 Pengolahan Data.....	68
3.2.1 Keterangan Data	68
3.2.2 Pelabelan Data	70
3.2.3 Pembagian Data.....	71
3.3 Pelatihan Model.....	73
3.3.1 <i>Flowchart</i> Pelatihan Model	73
3.3.2 Perangkat Keras.....	74
3.3.3 Lingkungan Pengembangan	75
3.3.4 Augmentasi Data	76
3.3.5 Konfigurasi Model dan <i>Optimazer</i>	77
3.3.6 Kompilasi Model	79
3.4 Metode Evaluasi	80
3.4.1 <i>Confusion matrix</i>	81
3.4.2 Akurasi Klasifikasi	81
3.4.3 Kurva ROC-AUC	82
BAB IV HASIL DAN PEMBAHASAN	83
4.1 Evaluasi Model.....	83
4.1.1 Evaluasi Model <i>Mobilenetv2 Dataset Background</i>	83
4.1.2 Evaluasi Model <i>Mobilenetv2 Dataset Background</i>	88
4.1.3 Evaluasi Model <i>Densenet169 Dataset Background</i>	93
4.1.4 Evaluasi Model <i>Densenet169 Dataset Non-background</i>	98

4.2	Komparasi Hasil Evaluasi Model	103
4.3	Implementasi	106
4.3.1	Halaman Beranda	106
4.3.2	Halaman Hasil	107
4.3.3	Halaman Deteksi Sampah.....	108
4.4	Pengujian Sistem dengan <i>Black box Testing</i>	110
4.5	Pembahasan	111
BAB V SIMPULAN DAN SARAN		115
5.1	Simpulan.....	115
5.2	Saran	115
DAFTAR PUSTAKA		116
LAMPIRAN		
DAFTAR RIWAYAT HIDUP		



DAFTAR TABEL

Tabel 2.1 <i>Confusion matrix</i>	18
Tabel 2.2 Tingkat akurasi kurva ROC-AUC	20
Tabel 2.3 Symbol <i>Flowchart</i>	21
Tabel 2.4 Rangkuman Model Penelitian	37
Tabel 3.1 Keterangan Variasi Sampah	68
Tabel 3.2 Konfigurasi Splitfolders	71
Tabel 3.3 Spesifikasi Perangkat Keras	75
Tabel 3.4 Ukuran <i>input</i> tiap model CNN	76
Tabel 3.5 Konfigurasi parameter model CNN	78
Tabel 3.6 Konfigurasi kompilasi model	79
Tabel 3.7 Perbandingan Akurasi Model <i>Dataset Background</i> dan <i>Non-background</i>	80
Tabel 4.1 Metrik Evaluasi <i>Mobilenetv2</i> pada <i>Dataset Background</i> per kelas.....	86
Tabel 4.2 Metrik Evaluasi <i>Mobilenetv2</i> pada <i>Dataset Non-background</i> per kelas	91
Tabel 4.3 Metrik Evaluasi <i>Densenet169</i> pada <i>Dataset Background</i> per kelas.....	96
Tabel 4.4 Metrik Evaluasi <i>Densenet169</i> pada <i>Dataset Non-background</i> per kelas	101
Tabel 4.5 Rangkuman Kurva ROC-AUC Model	105
Tabel 4.6 Blackbox <i>Testing</i> pada <i>Website</i> Deteksi Sampah.....	110
Tabel 4.7 Perbandingan hasil penelitian dengan penelitian sebelumnya	113

DAFTAR GAMBAR

Gambar 2.1 Perbedaan <i>Deep learning</i> dan <i>Machine learning</i> (Alzubaidi et al., 2023)	10
Gambar 2.2 Arsitektur CNN (Alzubaidi et al., 2021)	11
Gambar 2.3 Ilustrasi <i>Convolutional Layer</i>	11
Gambar 2.4 Ilustrasi <i>Pooling Layer</i>	12
Gambar 2.5 Ilustrasi <i>Fully Connected Layer</i>	13
Gambar 2.6 Struktur Jaringan <i>Mobilenetv2</i>	16
Gambar 2.7 Arsitektur <i>Densenet169</i>	17
Gambar 2.8 Struktur HTML	24
Gambar 2.9 <i>Flowchart</i> Kerangka Pemikiran.....	61
Gambar 3.1 <i>Flowchart</i> Perancangan <i>Dataset</i>	62
Gambar 3.2 <i>Cardboard Background</i>	63
Gambar 3.3 <i>Glass Background</i>	64
Gambar 3.4 <i>Metal Background</i>	64
Gambar 3.5 <i>Paper Background</i>	64
Gambar 3.6 <i>Trash Background</i>	65
Gambar 3.7 <i>Plastic Background</i>	65
Gambar 3.8 <i>Cardboard Non-background</i>	66
Gambar 3.9 <i>Glass Non-background</i>	66
Gambar 3.10 <i>Metal Non-background</i>	66
Gambar 3.11 <i>Paper Non-background</i>	67
Gambar 3.12 <i>Plastic Non-background</i>	67
Gambar 3.13 <i>Trash Non-background</i>	67
Gambar 3.14 Folder masing-masing variasi.....	70
Gambar 3.15 <i>Dataset Background</i>	70
Gambar 3.16 <i>Dataset Non-background</i>	71
Gambar 3.17 Hasil Splitfolders	72
Gambar 3.18 <i>Flowchart</i> Pelatihan Model	73
Gambar 3.19 Anaconda Navigator	76
Gambar 3.20 Contoh Augmentasi Label <i>Glass</i>	77
Gambar 3.21 Folder Notebook <i>Dataset Background</i>	78
Gambar 3.22 Folder Notebook <i>Dataset Non-background</i>	78
Gambar 4.1 Perbandingan Akurasi Pelatihan dan Validasi <i>Mobilenetv2</i> dengan <i>Dataset Background</i>	83

Gambar 4.2 Perbandingan <i>Loss</i> Pelatihan dan Validasi <i>Mobilenetv2</i> dengan <i>Dataset Background</i>	84
Gambar 4.3 Code Penyimpanan Model dan History Pelatihan <i>Mobilenetv2 Dataset Background</i>	84
Gambar 4.4 <i>Confusion matrix Mobilenetv2 Dataset Background</i>	85
Gambar 4.5 Kurva ROC-AUC <i>Mobilenetv2 Dataset Background</i>	87
Gambar 4.6 Perbandingan Akurasi Pelatihan dan Validasi <i>Mobilenetv2 Dataset Non-background</i>	88
Gambar 4.7 Perbandingan <i>Loss</i> Pelatihan dan Validasi <i>Mobilenetv2 Dataset Non-background</i>	89
Gambar 4.8 Code menyimpan Model dan History Pelatihan <i>Mobilenetv2 Dataset Non-background</i>	89
Gambar 4.9 <i>Confusion matrix Mobilenetv2 Dataset Non-background</i>	90
Gambar 4.10 Kurva ROC-AUC <i>Mobilenetv2 Dataset Non-background</i>	92
Gambar 4.11 Perbandingan Akurasi Pelatihan dan Validasi <i>Densenet169 Dataset Background</i>	93
Gambar 4.12 Perbandingan <i>Loss</i> Pelatihan dan Validasi <i>Densenet169</i> dengan <i>Dataset Background</i>	94
Gambar 4.13 Code menyimpan Model dan History Pelatihan <i>Densenet169 Dataset Background</i>	94
Gambar 4.14 <i>Confusion matrix Densenet169 Dataset Background</i>	95
Gambar 4.15 Kurva ROC-AUC <i>Densenet169</i> dengan <i>Dataset Background</i>	97
Gambar 4.16 Perbandingan Akurasi Pelatihan dan Validasi <i>Densenet169 Dataset Non-background</i>	98
Gambar 4.17 Perbandingan <i>Loss</i> Pelatihan dan Validasi <i>Densenet169 Dataset Non-background</i>	99
Gambar 4.18 Code menyimpan Model dan History Pelatihan <i>Densenet169 Dataset Non-background</i>	99
Gambar 4.19 <i>Confusion matrix Densenet169 Dataset Non-background</i>	100
Gambar 4.20 Kurva ROC-AUC <i>Densenet169 Dataset Non-background</i>	102
Gambar 4.21 Rangkuman <i>Confusion matrix</i> Model.....	104
Gambar 4.22 Tampilan Halaman Beranda	107
Gambar 4.23 Tampilan Halaman Info Sampah	108
Gambar 4.24 Tampilan Halaman Deteksi Sampah	109

Gambar 4.25 Tampilan Halaman Tidak Mengunggah Gambar 109
Gambar 4.26 Tampilan Hasil Deteksi Sampah 110
Gambar 4.27 Perbandingan Akurasi Tiap Model..... 112



BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Pengelolaan sampah merupakan masalah yang serius seiring meningkatnya pertumbuhan populasi dan aktivitas manusia. Menurut laporan terbaru dari International Lianhe Zaobao, volume sampah di seluruh dunia diprediksi akan meningkat sebanyak 70% pada tahun 2050, yang akan menambah kesulitan dalam tugas klasifikasi sampah (Kang et al., 2020). Menurut Kang et al., penting untuk melakukan klasifikasi sampah dengan tepat sebagai langkah *krusial* dalam pengelolaan sampah. Salah satu masalah utama dalam pengelolaan sampah adalah pengelompokan sampah berdasarkan jenisnya, yaitu organik dan anorganik (Sunardi et al., 2023b). Sampah organik dapat terurai secara alami melalui proses biologi, sedangkan sampah anorganik memerlukan waktu lebih lama, bahkan bertahun-tahun, untuk terurai (Hamami, 2023). Data ini menunjukkan bahwa pengelolaan limbah anorganik memerlukan penanganan lebih lanjut karena sebagian besar materi tersebut sulit terurai oleh alam.

Sebagaimana yang telah disebutkan, penting untuk memperhatikan pengelolaan sampah terutama pada sampah anorganik. Pengelolaan sampah yang masih mengandalkan metode manual dalam proses pemisahan limbah kurang efisien dan tidak ramah lingkungan (Wu & Lin, 2022). Di Indonesia, masyarakat masih mengalami kesulitan dalam mengklasifikasikan jenis sampah, sehingga seringkali mencampurkan sampah menjadi satu (Hamami, 2023). Pemilahan sampah menjadi langkah dasar yang diperlukan untuk memungkinkan daur ulang secara efisien dan hemat biaya (Lin et al., 2022). Daur ulang merupakan proses penting yang berkontribusi dalam mengurangi jumlah sampah yang berakhir di tempat

pembuangan sampah, laut, atau ekosistem lainnya (Ahmed et al., 2023). Sebagai contoh, implementasi sistem daur ulang di China telah membuktikan keberhasilannya dalam menanggulangi masalah sampah (Sevinç & Ozyurt, 2022). Dalam situasi ini, langkah penting yang harus diambil adalah meningkatkan efisiensi daur ulang melalui proses pemilahan otomatis (Wu & Lin, 2022).

Melanjutkan upaya meningkatkan efisiensi daur ulang melalui pemilahan otomatis, penerapan teknik pembelajaran mendalam sebagai bagian dari kecerdasan buatan memainkan peran penting dalam otomatisasi klasifikasi limbah (Mao et al., 2021; Vo et al., 2019). Salah satu arsitektur dalam klasifikasi otomatis yaitu *Convolutional Neural Network* (CNN). Dengan kemampuannya yang unik dalam mengenali dan mengklasifikasikan visual, CNN diakui sebagai salah satu pendekatan paling dominan dalam mengenali gambar dan menjadi pilihan utama dalam bidang ini (Mao et al., 2021). CNN adalah jenis jaringan saraf buatan yang secara khusus dirancang untuk tugas seperti klasifikasi gambar, klasifikasi audio, dan *Natural Language Processing* (NLP) (Oswald Campesato, 2020).

CNN sudah banyak digunakan dalam penelitian sebelumnya untuk mengklasifikasikan sampah, seperti dalam penelitian (Fadlil et al., 2022) yang menggunakan teknik CNN dan *Support Vector Machines* (SVM) untuk membedakan sampah botol plastik berdasarkan merknya. Hasilnya menunjukkan bahwa CNN memiliki akurasi 99%, lebih tinggi dibandingkan SVM. Penelitian lainnya oleh (Sunardi et al., 2023a) menggunakan CNN untuk membedakan jenis limbah menjadi organik dan anorganik, mencapai akurasi sebesar 98.92%. Selanjutnya, dalam penelitian yang dilakukan oleh (Shi et al., 2021), penggunaan metode CNN bersama dengan ekstraksi fitur *Multilayer Hybrid* untuk mengklasifikasikan limbah mencapai tingkat akurasi sebesar 92,6%.

CNN terus mengalami perkembangan dari waktu ke waktu, menyebabkan terjadinya kemajuan yang signifikan dalam bidang *deep learning* (L. Chen et al., 2021). Penerapan metode CNN ini ditingkatkan melalui pengembangan arsitektur dan jumlah lapisan yang digunakan dalam jaringannya (Nashrullah et al., 2020). Pemilihan arsitektur yang tepat sangat penting untuk melakukan klasifikasi gambar dengan baik dalam berbagai kategori (Sun et al., 2020). Algoritma CNN sendiri memiliki beragam arsitektur, diantaranya seperti *Mobilenetv2* dan *Densenet169*, yang dirancang dengan berbagai keperluan. *Mobilenetv2* adalah model jaringan neural yang efisien dan ringan, cocok untuk perangkat dengan keterbatasan memori dan komputasi (Yong et al., 2023). Dalam penelitian tersebut, *Mobilenetv2* mencapai tingkat akurasi sebesar 82,92% dalam mengklasifikasikan limbah domestik dengan empat kategori limbah. Hasil ini menunjukkan performa yang sangat baik dari model tersebut, yang mampu mengungguli model-model CNN lain yang digunakan dalam penelitian tersebut. Sementara itu, *Densenet169* adalah arsitektur jaringan saraf konvolusional yang setiap lapisan terhubung langsung dengan semua lapisan lainnya secara berurutan (Sai Susanth et al., 2021). Ini membuatnya bisa menggunakan kembali fitur-fitur, mengurangi jumlah aturan yang harus dipelajari, dan belajar dengan cepat (Zeng et al., 2020). *Densenet169* cocok untuk aplikasi yang membutuhkan pemahaman mendalam tentang fitur-fitur gambar (Ahmed et al., 2023). Sebuah studi yang melibatkan *Densenet169* yang dilakukan oleh (Zeng et al., 2020) meneliti beberapa model CNN, termasuk *DenseNet121*, *Densenet169*, *ResNet50*, *ResNet101*, *ResNeXt50*, *ResNeXt101*, *EfficientNet-B3*, dan *EfficientNet-B4*, dalam mengklasifikasikan sampah dengan 4 kategori utama sampah dan 10 subkategori sampah. Hasilnya menunjukkan bahwa model *EfficientNet-B4* memiliki akurasi tertinggi sebesar 96,76%, diikuti oleh *EfficientNet-B3* sebesar 96,47% dan

Densenet169 sebesar 96,35%. Meskipun akurasi *Densenet169* sedikit lebih rendah dibandingkan *EfficientNet-B3* dan *EfficientNet-B4*, waktu inferensinya lebih singkat (23,7 md). Oleh karena itu, berdasarkan pertimbangan akurasi dan kecepatan, penelitian ini memilih *Densenet169* sebagai *backbone* yang paling sesuai.

Berdasarkan latar belakang yang telah dijelaskan, maka peneliti akan melakukan penelitian dengan judul “**PERBANDINGAN PERFORMA KLASIFIKASI GAMBAR SAMPAH ANTARA *MOBILENETV2* DAN *DENSENET169***”. Penelitian ini akan membandingkan hasil kinerja arsitektur CNN yaitu *Mobilenetv2* dan *Densenet169*. Selain itu, penelitian ini juga akan membandingkan hasil performa kedua arsitektur tersebut pada dua *dataset* yang berbeda, yaitu *dataset* dengan *background* dan *dataset* tanpa *background*. Hal ini kemudian akan diimplementasikan ke dalam sebuah aplikasi *website* untuk membantu masyarakat dalam mengelola sampah, khususnya sampah anorganik, dengan lebih efisien.

1.2 Identifikasi Masalah

Berdasarkan latar belakang masalah di atas, dapat diidentifikasi masalah sebagai berikut:

- a. Pemilahan sampah secara manual oleh masyarakat sering membuat sampah menjadi tercampur, sehingga mengurangi efektivitas proses daur ulang.
- b. Pengaruh keberadaan *background* dalam dataset terhadap kinerja model CNN dalam klasifikasi sampah masih perlu diteliti lebih lanjut.
- c. Dibutuhkan aplikasi web yang bisa membantu masyarakat untuk mengenali jenis-jenis sampah dengan mudah.

1.3 Ruang Lingkup

Adapun yang menjadi ruang lingkup dalam penelitian ini meliputi hal – hal berikut:

- a. *Dataset* sekunder yang diperoleh dari *Kaggle* dengan judul "*Garbage Classification*" yang dikumpulkan oleh CCHANG (<https://www.kaggle.com/datasets/asdasdasdas/garbage-classification>);
- b. *Dataset* yang digunakan dalam penelitian ini terdiri dari 2527 sampel sampah;
- c. Pengembangan program berbasis *website*.

1.4 Tujuan dan Manfaat

1.4.1 Tujuan

Tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut:

- a. Mengimplementasikan model CNN, seperti *Mobilenetv2* atau *Densenet169* dalam mengklasifikasikan sampah;
- b. Mengetahui pengaruh keberadaan *background* pada dataset;
- c. Membuat aplikasi web yang dapat mengidentifikasi jenis sampah.

1.4.2 Manfaat

Manfaat yang dapat diperoleh dalam penelitian ini adalah sebagai berikut:

- a. Meningkatkan efisiensi dan akurasi pemilahan sampah menggunakan model CNN (*Mobilenetv2* dan *Densenet169*) dengan menerapkan dua *dataset* berbeda.
- b. Memberikan wawasan tentang pengaruh *background dataset* terhadap kinerja model dalam klasifikasi sampah.
- c. Mengembangkan sebuah aplikasi web yang mudah digunakan oleh masyarakat untuk mengidentifikasi jenis sampah, sehingga dapat mendukung pengelolaan sampah yang lebih baik.

1.5 Sistematika Penulisan

Sistematika penulisan bertujuan mempermudah pemahaman dan penelaahan penelitian. Dalam laporan ini, materi dikelompokkan menjadi beberapa sub bab yang dapat dijelaskan secara garis besar, sebagai berikut:

BAB I PENDAHULUAN

Bab ini memuat penjelasan mengenai latar belakang masalah, identifikasi masalah, ruang lingkup penelitian, tujuan dan manfaat penelitian, serta sistematika penulisan.

BAB II LANDASAN PEMIKIRAN TEORITIS

Bab ini berisi paparan mengenai teori-teori yang terkait dengan penelitian ini, yang terbagi menjadi tiga bagian, yaitu teori umum, teori khusus, dan teori rancangan. Selain itu, juga mencakup tinjauan studi dan kerangka pemikiran.

BAB III METODE PENELITIAN

Bab ini berisi uraian terkait pengumpulan data, metode yang digunakan, *flowchart* dan perancangan *interface*.

BAB IV HASIL DAN PEMBAHASAN

Bab ini berisi penjelasan mengenai evaluasi terhadap model yang telah dikembangkan, tampilan program yang dibuat, serta pengujian aplikasi yang dilakukan.

BAB V SIMPULAN DAN SARAN

Bab ini merangkum simpulan dari penelitian berdasarkan hasil pengujian dan implementasi yang telah dilakukan, serta memberikan saran-saran yang dapat dikembangkan untuk penelitian selanjutnya.



BAB II

LANDASAN TEORI

2.1 Teori Umum

2.1.1 Data

Data merupakan informasi dasar yang diperoleh melalui observasi objek atau peristiwa (Pane et al., 2020). Setelah melalui proses pengolahan, data akan menghasilkan informasi yang menggambarkan fakta baik secara kualitatif maupun kuantitatif (Gunadi & Widiyanto, 2020). Jenis data meliputi waktu, angka, teks, gambar, suara, dan video (Dalle et al., 2020). Berdasarkan pengertian data di atas, data memiliki fungsi penting sebagai berikut:

- a. Membantu dalam pengambilan keputusan untuk menyelesaikan masalah
- b. Menjadi dasar atau landasan untuk penelitian dan perencanaan;
- c. Berfungsi sebagai panduan dalam menyelesaikan tugas;
- d. Menjadi acuan untuk mengevaluasi kinerja (Pane et al., 2020).

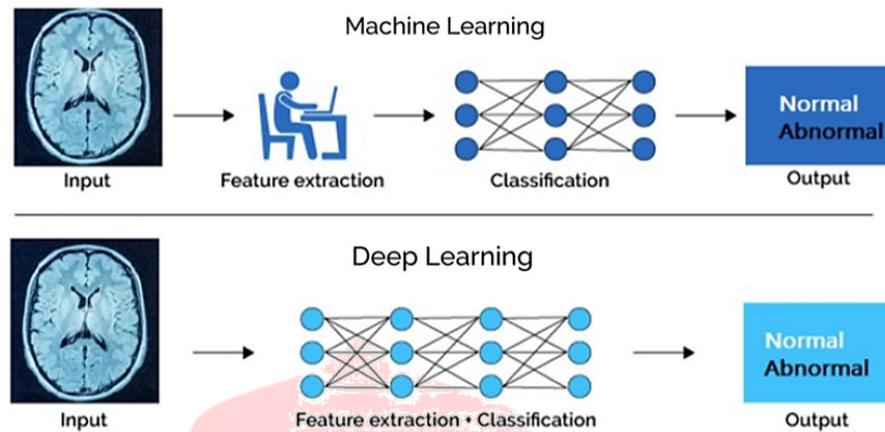
2.1.2 Website

Website adalah sekumpulan halaman informasi di internet yang berfokus pada topik tertentu dan diterbitkan oleh perseorangan atau organisasi (Pardede et al., 2019). Secara teknis, *website* terdiri dari serangkaian halaman web yang menggunakan HTML, disimpan di server, dan dapat diakses melalui *browser* dengan menggunakan URL dan koneksi internet (D. M. Widia & Asriningtias, 2021). Untuk mengaksesnya, pengguna dapat menggunakan protokol HTTP atau HTTPS, yang memberikan tingkat keamanan lebih tinggi melalui enkripsi data (Huzaeni et al., 2021). Sebuah *website* umumnya berisi berbagai jenis konten, seperti gambar, ilustrasi, video, dan teks, yang digunakan untuk berbagai keperluan.

Pada penelitian ini, *website* dijadikan alat implementasi untuk melakukan klasifikasi gambar sampah anorganik. Semua individu yang memiliki akses internet dan perangkat seperti *computer*, *smartphone*, atau *tablet*, dapat melakukan proses klasifikasi gambar tersebut.

2.1.3 *Deep learning*

Deep learning adalah cabang dari *machine learning* yang menggunakan jaringan saraf kompleks untuk memahami representasi data secara lebih abstrak dibandingkan konsep yang kurang abstrak (Alzubaidi et al., 2021). Teknologi ini telah merevolusi berbagai aplikasi, seperti klasifikasi gambar, pemrosesan video, dan pengenalan bahasa alami (Liu et al., 2020). Dalam analisis gambar, *deep learning* menggunakan jaringan saraf tiruan *deep feed-forward* dengan jaringan saraf konvolusi, yang meningkatkan kemampuan dalam menangani *dataset* besar (Alzubaidi et al., 2021) Selain itu, kelebihan *deep learning* terlihat dalam *Supervised Learning*, di mana model kompleks lebih efektif merepresentasikan data citra berlabel (Silaparasetty, 2020). *Deep learning* juga meminimalkan proses panjang *Machine learning* dengan pendekatan lebih otomatis, seperti terlihat pada Gambar 2.1.

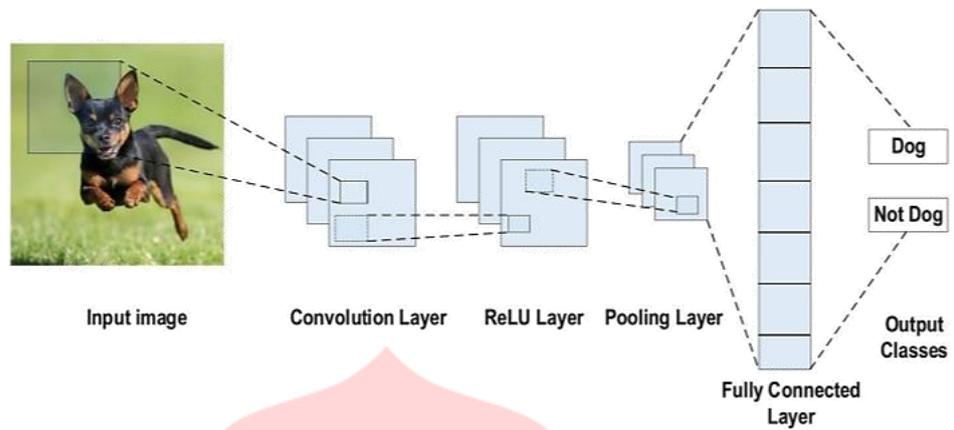


Gambar 2.1 Perbedaan *Deep learning* dan *Machine learning* (Alzubaidi et al., 2023)

2.2 Teori Khusus

2.2.1 Convolutional Neural Network (CNN)

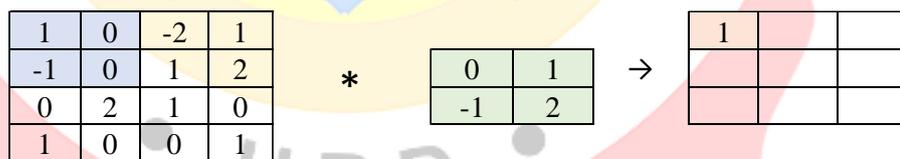
CNN merupakan salah satu jenis *deep learning* yang sedang dikembangkan dan dianggap sebagai salah satu metode *machine learning* paling canggih saat ini. CNN adalah metode *deep learning* terkini yang dianggap paling canggih dalam *machine learning* saat ini. CNN telah diterapkan secara luas dalam berbagai bidang, termasuk visi komputer (Fang et al., 2020), pemrosesan ucapan (Palaz et al., 2019), pengenalan wajah (Li et al., 2020), dan sebagainya. Struktur CNN meniru jaringan saraf konvensional pada otak manusia dan hewan. Secara lebih khusus, dalam otak kucing, urutan kompleks sel membentuk korteks visual; struktur ini disimulasikan oleh CNN (Alzubaidi et al., 2021). Arsitektur CNN terdiri dari tiga lapisan: *convolutional*, *pooling*, dan *fully connected* sebagaimana diperlihatkan pada Gambar 2.2.



Gambar 2.2 Arsitektur CNN (Alzubaidi et al., 2021)

a. *Convolutional Layer*

Salah satu komponen kunci dalam arsitektur CNN adalah lapisan konvolusi, dimana lapisan ini menggunakan filter konvolusi atau kernel untuk melakukan pemrosesan data (Taye, 2023). Filter ini digunakan untuk mengkonvolusikan gambar *input* dalam bentuk metrik N-dimensi, menghasilkan *output* berupa *feature map* (Bezdan & Baćanin Džakula, 2019; Taye, 2023). Representasi perhitungan lapisan konvolusi dapat dilihat pada Gambar 2.3.



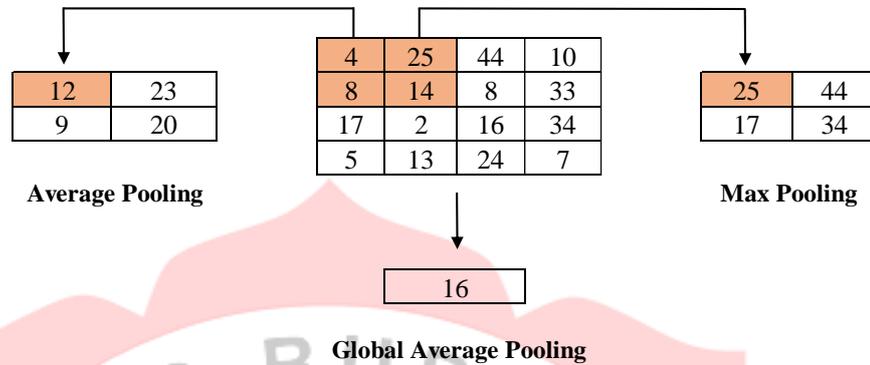
Gambar 2.3 Ilustrasi *Convolutional Layer*

b. *Pooling Layer*

Pendekatan yang digunakan untuk mereduksi ukuran *feature map* setelah proses konvolusi, tetapi tetap mempertahankan informasi penting (Alzubaidi et al., 2021). Sebelum operasi *pooling*, ukuran langkah dan kernel disesuaikan. Metode *pooling* yang umum digunakan meliputi *max*

pooling, *average pooling*, dan *GAP pooling* (Ramadhani et al., 2023).

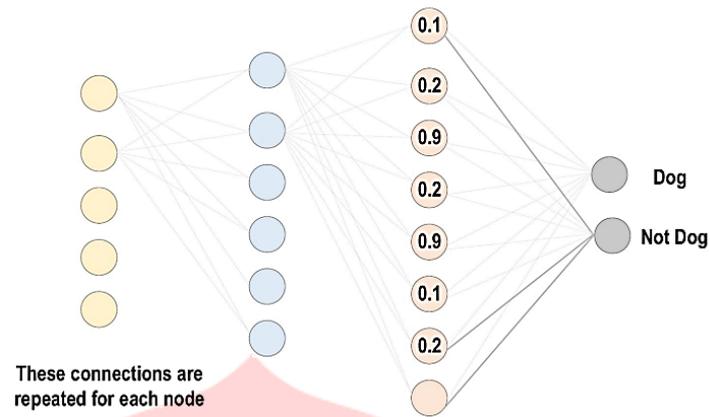
Representasi lapisan *pooling* dapat dilihat pada Gambar 2.4.



Gambar 2.4 Ilustrasi *Pooling Layer*

c. *Fully Connected Layer*

Lapisan di mana setiap neuron terhubung dengan semua neuron dari lapisan sebelumnya dalam jaringan, membentuk koneksi yang lengkap atau *fully connected* (Alzubaidi et al., 2021). *Output* dari lapisan ini adalah representasi akhir dari CNN, yang menggambarkan hasil klasifikasi atau prediksi yang dihasilkan oleh jaringan tersebut (Hanifah & Hermawan, 2023). Lapisan ini juga menggunakan fungsi aktivasi untuk menentukan aktivasi atau non-aktivasi neuron berdasarkan *input* yang diterima (Alzubaidi et al., 2021). Beberapa jenis fungsi aktivasi yang sering digunakan dalam lapisan *fully connected* antara lain *sigmoid*, *tanh*, dan ReLU (Taye, 2023). Representasi lapisan *fully connected* dapat dilihat pada Gambar 2.5.



Gambar 2.5 Ilustrasi *Fully Connected Layer*

2.2.2 Sampah Anorganik

Sampah anorganik adalah benda padat yang dibuang oleh suatu komunitas atau perseorangan karena dianggap tak berguna (Luis F. Diaz et al., 2020). Sampah anorganik sulit terurai oleh bakteri, sehingga perlu waktu lama untuk bisa hancur (hingga ratusan tahun) (Chazanah et al., 2022). Sampah ini tidak hanya memiliki variasi jenisnya, seperti kaca, logam, plastik, atau kertas, tetapi juga memiliki potensi bahaya, seperti dampak pada lingkungan, risiko kesehatan, pengaruh pada ekosistem, dan bahaya fisik (Awasthi et al., 2023).

Pentingnya pengelolaan sampah menekankan perlunya kita untuk melakukan pemilahan sampah sebelum membuangnya. Dengan melakukan pemilahan sampah, kita dapat mengurangi akumulasi sampah di sekitar kita. Sampah jenis non-organik umumnya dapat didaur ulang atau diproses menjadi produk baru (Sunardi et al., 2023b). Namun, di Indonesia, masyarakat masih mengalami kesulitan dalam mengklasifikasikan jenis sampah (Hamami, 2023). Dengan kemajuan teknologi sensor dan informasi elektronik, serta popularitas teknologi visi mesin di berbagai sektor (H. Chen,

2021; Zhu et al., 2019), penelitian ini bertujuan menerapkan teknologi visi mesin untuk identifikasi dan klasifikasi limbah padat yang akurat.

2.2.3 *Image Preprocessing*

Image preprocessing adalah langkah awal untuk mempersiapkan dan memperkuat citra sebelum dilakukan analisis atau klasifikasi lebih lanjut (Salvi et al., 2021; Yong et al., 2023). Dalam proses ini, citra dimodifikasi agar memiliki kualitas yang lebih baik, sehingga dapat dengan mudah dipahami oleh manusia atau mesin (Mark & Alberto, 2019). Ini berarti bahwa informasi yang terkandung dalam citra dapat diinterpretasikan secara berbeda tergantung pada kebutuhan pengguna (Stojnev & Stojnev Ilić, 2020). *Image preprocessing* melibatkan berbagai teknik, termasuk segmentasi citra, yang digunakan untuk membagi citra menjadi bagian-bagian berdasarkan ciri-ciri seperti warna, tekstur, atau intensitas (Orisa & Hidayat, 2019).

Dalam penelitian ini, kita akan menerapkan teknik segmentasi di mana latar belakang citra dihilangkan untuk meningkatkan fokus pada objek utama. Dengan cara ini, diharapkan model akan lebih fokus pada identifikasi objek sampah, sehingga dapat meningkatkan akurasi klasifikasi.

2.2.4 *Mobilenetv2*

Mobilenetv2 merupakan arsitektur jaringan saraf konvolusional yang dirancang agar efisien dan ringan untuk perangkat mobile (Ahmed et al., 2023). Arsitektur ini menggunakan operasi separable yang terdiri dari lapisan konvolusi *depthwise* dan *pointwise* (Pang et al., 2023). Dengan menggunakan operasi ini, jumlah parameter dapat dikurangi sehingga komputasi menjadi lebih efektif (Zheng & Gu, 2021). Untuk memperlihatkan bahwa konvolusi *depthwise separable* menghasilkan efek yang sama dengan lapisan konvolusi

standar, namun dengan biaya ruang dan waktu yang lebih rendah, dapat dijelaskan melalui rumus berikut ini (Pang et al., 2023):

$$\frac{Df \times Df \times Dk \times Dk \times M \times Df \times Df \times M \times N}{Df \times Df \times Dk \times Dk \times M \times N} = \frac{1}{N} + \frac{1}{Dk^2} \quad (1)$$

Keterangan :

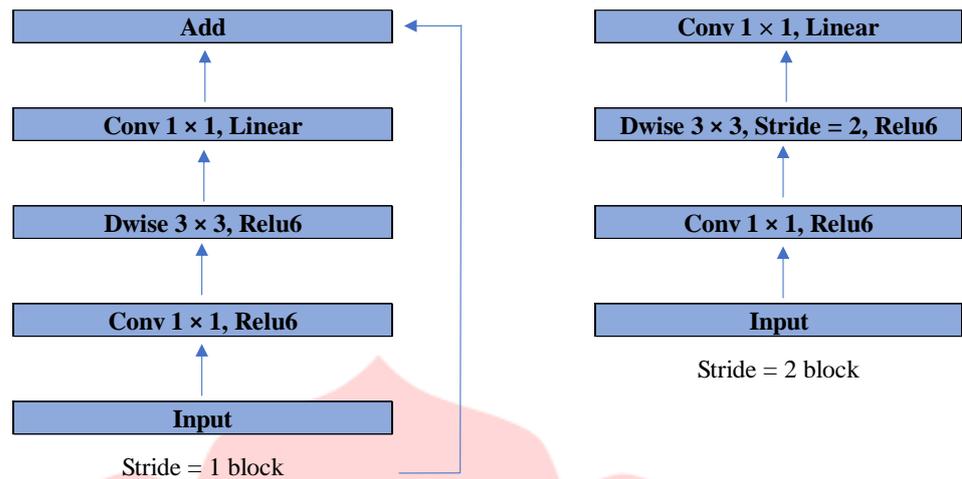
Df = Panjang sisi dari grafik karakteristik *input*

Dk = Panjang sisi kernel konvolusi

M = Jumlah *input channel*

N = Jumlah *output channel*

Arsitektur *Mobilenetv2* menggunakan pendekatan residual terbalik dan *bottleneck linear*, yang terdiri dari tiga lapisan pada setiap bloknnya (Ahmed et al., 2023; Pang et al., 2023; Zheng & Gu, 2021). Lapisan konvolusi 1×1 pertama digunakan untuk mengurangi jumlah saluran *input*, diikuti oleh lapisan konvolusi *depthwise* 3×3 untuk mengekstraksi fitur, dan diakhiri dengan lapisan konvolusi 1×1 untuk mengembalikan jumlah saluran ke ukuran semula (Ahmed et al., 2023). Pendekatan ini memberikan manfaat dalam manajemen memori yang lebih efisien pada unit dasar *Mobilenetv2* (Pang et al., 2023).

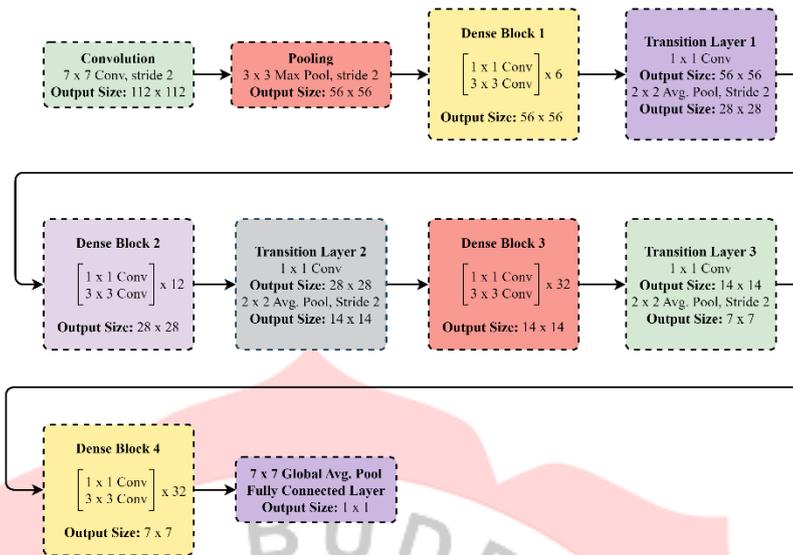


Gambar 2.6 Struktur Jaringan *Mobilenetv2*

2.2.5 *Densenet169*

Densenet169 adalah salah satu arsitektur CNN yang diusulkan oleh Huang et al. pada tahun 2017 (Ahmed et al., 2023). Model ini merupakan varian dari *DenseNet*, yang didasarkan pada ide utama untuk menghubungkan setiap lapisan secara langsung satu sama lain dalam suatu blok, bukan hanya dengan lapisan sebelumnya (Chauhan et al., 2021). Dengan demikian, *Densenet169* menghasilkan model yang lebih efisien dalam hal parameter dan komputasi dibandingkan dengan arsitektur tradisional lainnya (Al-rimy et al., 2023).

Densenet169 terdiri dari 169 lapisan yang terdiri dari *convolutional*, *maxpool*, *dense*, dan *transition layers* (Vulli et al., 2022; Zhang et al., 2021). Model ini menggunakan fungsi aktivasi ReLU di setiap bagian arsitektur dan aktivasi *Softmax* pada lapisan terakhir (Vulli et al., 2022). Gambar 2.7 memberikan tampilan detail mengenai arsitektur *Densenet169* (Narmadha et al., 2022).



Gambar 2.7 Arsitektur *Densenet169*

Dengan koneksi langsung dari setiap blok ke lapisan-lapisan berikutnya, *DenseNet-169* memungkinkan informasi dari lapisan sebelumnya diakses lebih mudah, sehingga mengurangi kehilangan informasi selama proses pelatihan (Al-rimy et al., 2023). Model ini telah diterapkan dalam berbagai aplikasi, seperti klasifikasi citra medis, analisis pemandangan alam, dan pengenalan objek (Yadav & Surendra Yadav, 2024). Dengan waktu inferensi yang cepat (Zeng et al., 2020) dan akurasi yang tinggi, *DenseNet-169* menjadi pilihan populer untuk banyak tugas visi komputer (Ahmed et al., 2023). Secara keseluruhan, *DenseNet-169* adalah arsitektur CNN yang kuat dan efisien, terbukti efektif untuk berbagai tugas.

2.2.6 Confusion matrix

Confusion matrix adalah metode evaluasi yang digunakan untuk membandingkan hasil prediksi dengan nilai sebenarnya dalam klasifikasi model (Zhang et al., 2021). *Matrix* ini mewakili kolom dan baris, dimana baris menggambarkan kelas aktual dari instansi dan kolom menggambarkan kelas yang diprediksi (Syiarul Amrullah & Fachri Pane, 2023). Untuk

memudahkan pemahaman mengenai empat istilah pada *confusion matrix*,

Tabel 2.1 merinci hasil evaluasi kinerja model (Rahmad et al., 2020):

Tabel 2.1 *Confusion matrix*

		True Values	
		True	False
Prediction	True	TP Correct result	FP Unexpected result
	False	FN Missing result	TN Correct absence of result

a. *True positive* (TP): hasil prediksi yang menyatakan positif dan hasil sebenarnya juga positif.

b. *True negative* (TN): hasil prediksi yang menyatakan negatif dan hasil sebenarnya juga negatif.

c. *False positive* (FP): hasil prediksi yang menyatakan positif, tetapi hasil sebenarnya negatif.

d. *False negative* (FN): hasil prediksi yang menyatakan negatif, tetapi hasil sebenarnya positif.

Dalam *Confusion matrix*, terdapat sejumlah metrik evaluasi yang digunakan untuk menilai kinerja model setelah proses pelatihan. Metrik-metrik ini juga dikenal sebagai *Classification Report* :

a. Akurasi

Akurasi adalah probabilitas model mengklasifikasikan sebuah unit dengan benar (Grandini et al., 2020). Cara menghitung akurasi adalah perbandingan antara jumlah prediksi benar dan total prediksi terhadap dokumen (Rahutomo et al., n.d.). Atau dengan fungsi

$$akurasi = \frac{(TP + TN)}{(TP + FP + TN + FN)} \quad (2)$$

b. Presisi

Presisi adalah perbandingan antara jumlah sampel yang berhasil diklasifikasikan dengan benar sebagai positif terhadap jumlah total sampel yang diklasifikasikan sebagai positif (Fahmy, 2022). Formula presisi dapat didefinisikan sebagai berikut.

$$presisi = \frac{TP}{(TP + FP)} \quad (3)$$

c. Recall

Recall adalah persentase dari semua sampel positif yang berhasil diprediksi sebagai positif, dan dapat dirumuskan sebagai berikut (Zhang et al., 2021).

$$recall = \frac{TP}{(TP + FN)} \quad (4)$$

d. F1-score

F1 score adalah nilai rata-rata yang menggabungkan presisi dan recall secara harmonis (Zhang et al., 2021). Rentang nilai F1 score adalah antara 0 hingga 1, di mana nilai 1 menunjukkan performa terbaik. Formula F1 Score dapat dijelaskan sebagai berikut.

$$f1 - score = 2 \times \frac{recall \times presisi}{recall + presisi} \quad (5)$$

2.2.7 Kurva ROC-AUC

Kurva ROC merupakan grafik yang menunjukkan kinerja model klasifikasi dalam membedakan antara prediksi *true positive* (TP) dan *false positive* (FP) pada berbagai ambang pemisahan data (Nahm, 2022). Melalui

kurva ROC, kita dapat mengevaluasi seberapa baik model dapat membedakan antara hasil positif dan negatif, serta melihat *trade-off* antara sensitivitas dan spesifisitas model (Zailani & Hanun, 2020). Kurva ROC digunakan untuk menghitung nilai AUC (Kevin et al., 2020). Kurva ROC memiliki tingkat nilai diagnosis atau klasifikasi yang bisa dilihat pada Tabel 2.2 (Prayogo et al., 2022).

Tabel 2.2 Tingkat akurasi kurva ROC-AUC

Akurasi	Tingkat Klasifikasi
0.90-1.00	Excellent classification
0.80-0.90	Good classification
0.70-0.80	Fair classification
0.60-0.70	Poor classification
0.50-0.60	Failure

2.2.8 *Black box Testing*

Black-box testing adalah metode pengujian perangkat lunak yang mengevaluasi fungsi sistem tanpa mempertimbangkan detail internalnya (Shadiq et al., 2021). Pengujian ini berfokus untuk memastikan apakah *input* yang diberikan menghasilkan *output* yang sesuai dengan spesifikasi yang telah ditentukan (Golian et al., 2022). Menurut (Rahadi & Vikasari, 2020) keuntungan menggunakan metode *black-box testing* antara lain: (1) Penguji tidak perlu mengetahui bahasa pemrograman tertentu; (2) Pengujian dilakukan dari sudut pandang pengguna, yang membantu mengungkap ambiguitas atau inkonsistensi dalam spesifikasi; (3) Programmer dan tester saling bergantung satu sama lain.

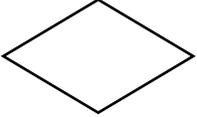
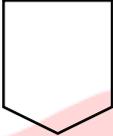
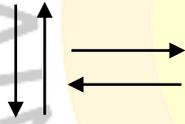
2.3 Teori Rancangan

2.3.1 Flowchart

Untuk mempermudah pemahaman algoritma oleh orang lain, terutama programmer yang bertanggung jawab untuk mengimplementasikan program, digunakan alat bantu berupa diagram alir atau *flowchart*. *Flowchart* merupakan representasi grafis yang menunjukkan urutan langkah atau proses dalam sistem atau program menggunakan simbol-simbol standar (Putri & Jarti, 2022). Setiap simbol dalam *flowchart* menggambarkan proses tertentu, dan hubungan antar proses digambarkan dengan garis penghubung. Dengan menggunakan *flowchart*, urutan proses kegiatan dapat lebih jelas dan mudah dipahami. Beberapa simbol standar yang digunakan dalam *flowchart* dapat dilihat pada Tabel 2.3.

Tabel 2.3 *Symbol Flowchart*

Simbol	Nama	Deskripsi
	<i>Start/End</i>	Mendefinisikan awal atau akhir dari sebuah <i>flowchart</i> .
	<i>Input/Output</i>	Mendefinisikan masukan dan keluaran proses.
	Proses	Digunakan untuk setiap proses yang dilakukan oleh komputer.
	<i>Predefined Processing</i>	Digunakan untuk menyatakan bagian dari program (subprogram).

	Keputusan	Digunakan untuk memutuskan proses lanjutan dari kondisi tertentu.
	Persiapan	Digunakan untuk memberi nilai awal pada suatu variabel.
	Penghubung halaman berbeda	Digunakan untuk menghubungkan <i>flowchart</i> pada halaman yang berbeda.
	Database	Digunakan untuk menyatakan database atau basis data.
	Penghubung halaman sama	Digunakan untuk menghubungkan <i>flowchart</i> pada halaman yang sama.
	Garis Aliran	Digunakan untuk menyambungkan setiap simbol.

2.3.2 Python

Python adalah bahasa pemrograman tingkat tinggi yang dianggap mudah dipelajari dan memiliki sintaks yang mirip dengan bahasa manusia. Dikembangkan oleh Guido van Rossum pada tahun 1990, *Python* terus diperbarui oleh *Python Software Foundation* (Silaparasetty, 2020). Keunggulan *Python* meliputi dukungan untuk berbagai sistem operasi, termasuk *Linux* yang secara umum menyertakan *Python* secara default. *Python* memiliki berbagai koleksi modul siap pakai seperti *Matplotlib*, *Numpy*, *Pandas*, *Scikit-learn*, dan sejumlah *library* lainnya yang menyokong berbagai keperluan pengembangan (Kurniawan, 2022).

Python memiliki sejumlah kegunaan yang meliputi kemampuannya untuk membuat aplikasi web, mengelola alur kerja, terhubung dengan basis data, membaca dan mengubah file, memproses data besar, melakukan operasi matematika, serta mempercepat pembuatan *prototype* dan pengembangan perangkat lunak yang sudah ada (Maarif, 2020).

2.3.3 HTML

HTML adalah bahasa pemrograman yang digunakan untuk membuat halaman web dengan tampilan grafis. Dalam HTML, terdapat fasilitas yang disebut "*Markup Language*" yang memungkinkan kita mengatur elemen-elemen seperti judul, paragraf, tabel, gambar, dan lainnya menggunakan tanda-tanda khusus dalam *script* HTML (McGrath, 2020). HTML dikeluarkan oleh W3C (*World Wide Web Consortium*) dan setiap perkembangan dalam HTML harus melewati proses evaluasi dan persetujuan dari W3C. Dalam pembuatannya, HTML menggunakan tag-tag spesifik untuk mengorganisir data dalam suatu situs (Kaban & Sembiring, 2021). Tag-tag HTML ditandai dengan tanda "<...>" dan ditutup dengan tanda "/" seperti "</...>". Meskipun telah mengalami berbagai perkembangan, HTML tetap menjadi dasar dalam pembuatan situs web modern seperti PHP, ASP, dan JSP. Sebagian besar situs web saat ini masih mengandalkan HTML sebagai bagian terpenting dari infrastruktur teknologinya. Untuk memahami lebih lanjut tentang struktur HTML, penelitian (Casabona, 2020) menjelaskan beberapa elemen penting yang diperlihatkan pada Gambar 2.8.

```
<!DOCTYPE html>
<html>
<head>
    <title>Judul Web</title>
</head>
<body>
    Konten website
</body>
</html>
```

Gambar 2.8 *Struktur HTML*

- a. Tag `<!DOCTYPE html>` mengidentifikasi dokumen sebagai dokumen HTML dan diletakkan di awal.
- b. Tag `<html>` menandai awal dan akhir dokumen HTML.
- c. Tag `<head>` menyimpan informasi terkait dokumen seperti deskripsi, pengaturan, dan tautan ke file eksternal.
- d. Tag `<title>` digunakan untuk judul yang ditampilkan pada *browser*.
- e. Tag `<body>` tempat untuk konten yang disajikan oleh *browser*, termasuk teks dan gambar.

2.3.4 *Scikit-learn*

Scikit-learn adalah sebuah pustaka (*library*) *Python* yang didesain untuk *machine learning*. Pustaka ini dikembangkan dengan memanfaatkan fitur-fitur yang tersedia di *SciPy*, sehingga memudahkan pengguna untuk menerapkan berbagai algoritma *machine learning* secara efisien (Raschka et al., 2020). *Scikit-learn* diciptakan oleh David Cournapeau pada tahun 2007 dan menjadi pintu masuk yang baik untuk mempelajari *machine learning* karena mudah digunakan (Géron, 2022).

2.3.5 *Tensorflow*

Tensorflow adalah sebuah perpustakaan sumber terbuka yang awalnya dikembangkan oleh tim Google Brain pada tahun 2015 dengan lisensi Apache

2.0 (Kapoor et al., 2022). Perpustakaan ini sangat membantu para pengembang dalam menciptakan berbagai model *Machine learning*, termasuk dalam domain *deep learning* yang sedang berkembang pesat, yang memungkinkan pembangunan jaringan saraf yang kompleks (Nugraha et al., 2020). Salah satu kelebihan *Tensorflow* adalah kemampuannya untuk berjalan pada berbagai platform. *Tensorflow* dapat dijalankan pada berbagai CPU dan GPU, sehingga memudahkan pengembang dalam mengembangkan model *deep learning* (Silaparasetty, 2020). Perpustakaan ini tersedia untuk perangkat *Linux*, *macOS*, *Windows*, serta perangkat *mobile* seperti Android dan iOS. Selain itu, *Tensorflow* juga dapat digunakan pada aplikasi *desktop*, *mobile*, server, maupun web.

2.3.6 Keras

Keras adalah antarmuka *library* yang dirancang untuk menyederhanakan implementasi algoritma *Deep learning* pada platform *High Performance Computing*, khususnya *Tensorflow*. Meskipun sering disalahpahami sebagai kumpulan algoritma *Deep learning*, Keras sebenarnya berfungsi sebagai antarmuka untuk menerapkan algoritma-algoritma tersebut di *Tensorflow*. *Library* ini menyediakan komponen-komponen esensial seperti tujuan, lapisan, pengoptimal, fungsi aktivasi, dan alat-alat untuk memudahkan pengkodean jaringan saraf, termasuk dukungan untuk data gambar dan teks. Keras dapat diakses di GitHub dan memiliki dukungan komunitas melalui forum masalah di GitHub serta saluran Slack (Harani & Hasanah, 2020).

2.3.7 *Jupyter Notebook*

Jupyter Notebook adalah dokumen interaktif yang berisi kode, persamaan, visualisasi, dan teks naratif (Wang et al., 2020). Nama "Jupyter" berasal dari tiga bahasa pemrograman utama yang didukungnya, yaitu Julia, *Python*, dan R (Silaparasetty, 2020). Fungsi utama *Jupyter Notebook* adalah memungkinkan penulisan dan eksekusi kode, serta menyertakan berbagai jenis media seperti gambar, video, dan widget interaktif yang menggunakan HTML dan *JavaScript* (Pimentel et al., 2021). File *Jupyter Notebook* memiliki ekstensi *.ipynb* yang merupakan singkatan dari "*IPython Notebook*" (Pajankar, 2020).

2.4 Tinjauan Studi

2.4.1 Penelitian oleh Abdul Fadlil, Rusydi Umar, Sunardi, Arief Setyo Nugroho

Penelitian berjudul "*Comparison of Machine learning Approach for Waste Bottle Classification*" (Fadlil et al., 2022) membahas tentang perbandingan antara pendekatan CNN dan *Support Vector Machine* untuk klasifikasi botol plastik limbah. Penelitian ini menggunakan *dataset* yang dikumpulkan secara manual dengan mengambil foto menggunakan kamera beresolusi 2352 x 4160 piksel. *Dataset* tersebut terdiri dari 10 merek botol, yaitu *Aqua*, *Ades*, *Coca-Cola*, *Fanta*, *Floridina*, *Freshtea*, *Fruittea*, *Ichiocha*, *Minute Maid*, dan *Sprite*. Kemudian, *dataset* dibagi menjadi data *training* dan *testing* dengan perbandingan 10:1. Selanjutnya, peneliti melibatkan langkah pengumpulan data, pelabelan *dataset*, *pre-processing*, pelatihan dan pengujian model, serta perbandingan kinerja model dengan evaluasi menggunakan *confusion matrix*. Hasil penelitian menunjukkan bahwa CNN

memiliki akurasi yang lebih tinggi, mencapai 99%, dibandingkan SVM yang hanya memiliki akurasi 74%.

2.4.2 Penelitian oleh Sunardi, Anton Yudhana, Miftahuddin Fahmi

Penelitian berjudul “*Improving Waste Classification Using CNNs: An Application of Machine learning for Effective Environmental Management*” (Sunardi et al., 2023a) membahas penerapan CNN dalam mengembangkan sistem klasifikasi sampah. Peneliti menggunakan *dataset* dari *Kaggle* yang terdiri dari dua kategori yaitu sampah organik dan anorganik. *Dataset* ini dibagi menjadi data *training* dan data *testing* dengan rasio 85:15. Penelitian ini mencakup tahap pengumpulan data, pra-pemrosesan, pembuatan model CNN, dan evaluasi model menggunakan metrik akurasi dan binary cross-entropy *loss* pada data *testing*. Hasil akhir dari penelitian ini menunjukkan bahwa model CNN yang dikembangkan berhasil mencapai akurasi sebesar 98,92% dan *loss* sebesar 4,03% saat diuji dengan data *testing*. Model ini memiliki potensi besar untuk meningkatkan efisiensi dalam klasifikasi sampah.

2.4.3 Penelitian oleh Cuiping Shi, Cong Tan, Tao Wang, dan Ligu Wang

Penelitian berjudul “*A Waste Classification Method Based on a Multilayer Hybrid Convolution Neural Network*” (Shi et al., 2021) membahas pengembangan metode klasifikasi sampah menggunakan jaringan saraf konvolusi hibrida berlapis (MLH-CNN). Peneliti menggunakan *dataset* yang dibuat oleh Mindy Yang dan Gary Thung yang terbagi dalam 6 kelas limbah yaitu *cardboard, paper, plastic, glass, metal, and trash*. *Dataset* ini dibagi menjadi data pelatihan dan pengujian dengan perbandingan 4:1. Selanjutnya, peneliti melakukan tahap pra-pemrosesan, merancang model, memilih

optimizer terbaik, melatih dan mengevaluasi model dengan mengukur presisi, *recall*, *F1-score*, serta menganalisis *confusion matrix*, heatmap, dan uji occlusion. Hasil akhir dari penelitian ini menunjukkan bahwa model MLH-CNN yang diusulkan berhasil mencapai akurasi klasifikasi sampah mencapai 92.6%, yang lebih tinggi dibandingkan dengan beberapa metode lain yang telah ada sebelumnya.

2.4.4 Penelitian oleh Mohammed Imran Basheer Ahmed, Raghad B. Alotaibi, Rahaf A. Al-Qahtani, Rahaf S. Al-Qahtani, Sara S. Al-Hetela, Khawla A. Al-Matar, Noura K. Al-Saquer, Atta Rahman, Linah Saraireh, Mustafa Youldash dan Gomathi Krishnasamy

Penelitian berjudul “*Deep learning Approach to Recyclable Products Classification: Towards Sustainable Waste Management*” (Ahmed et al., 2023) membahas pentingnya teknologi *computer vision*, terutama *deep learning*, untuk otomatisasi klasifikasi sampah dengan membandingkan kinerja algoritma seperti CNN, *Densenet169*, *Mobilenetv2*, dan *ResNet50v2*. Penelitian ini bertujuan untuk mengatasi keterbatasan metode manual yang tidak efisien. Dalam penelitian ini, peneliti menggunakan *dataset* yang dibuat oleh Yousefi yang terbagi dalam 5 kelas limbah yaitu *paper*, *plastic*, *glass*, *metal*, and *others*. *Dataset* tersebut dibagi menjadi data *training* dan *testing* dengan perbandingan 70:30. Selanjutnya, peneliti melakukan *preprocessing*, *confusion matrix*, hyperparameter optimal dengan teknik Randomized Search CV dengan CNN. Hasil penelitian menunjukkan bahwa penggunaan CNN, baik dengan maupun tanpa arsitektur tertentu, memiliki akurasi tinggi dalam pengenalan gambar, dengan hasil sebagai berikut: akurasi CNN sebesar 88,52%, *Densenet169* sebesar 94,4%, *Mobilenetv2* sebesar 97,6%, dan

ResNet50v2 sebesar 98,95%. Ini menunjukkan bahwa penerapan teknologi *deep learning* dan *computer vision* dapat meningkatkan efisiensi pengelolaan limbah untuk masa depan yang lebih berkelanjutan.

2.4.5 Penelitian oleh Liying Yong, Le Ma, Dandan Sun, Liping Du

Penelitian berjudul “*Application of Mobilenetv2 to waste classification*” (Yong et al., 2023) membahas penerapan teknologi *deep learning* menggunakan model *Mobilenetv2* pada aplikasi WeChat untuk mengatasi masalah pemilahan sampah di rumah. Penelitian ini menggunakan *dataset* yang dikumpulkan secara manual melalui teknologi web crawler *Python*, dan *dataset* tersebut terdiri dari 4 kategori sampah, yaitu *recyclable waste*, *kitchen waste*, *hazardous waste* dan *other waste*. *Dataset* tersebut kemudian dibagi menjadi data *training*, *validation*, dan *testing* dengan perbandingan 8:1:1. Selanjutnya, peneliti melakukan tahap *preprocessing*, mengembangkan WeChat Mini Program dengan mengintegrasikan model back-end API, melakukan visualisasi hasil dengan menggunakan *Matplotlib*, dan membandingkan performa dengan model CNN klasik menggunakan 20% *dataset* secara acak. Hasil penelitian menunjukkan bahwa model *Mobilenetv2* mencapai akurasi sebesar 82,92%, mengungguli model CNN sebesar 15,42%. Kelebihan model *Mobilenetv2* adalah arsitekturnya yang efisien dan ukurannya yang ringan sehingga dapat dijalankan di pada perangkat dengan sumber daya yang terbatas.

2.4.6 Penelitian oleh Ming Zeng, Xiangzhe Lu, Wenkang Xu, Tongxi Zhou, Yinbo Liu

Penelitian berjudul “*PublicGarbageNet : A Deep learning Framework for Public Garbage Classification*” (Zeng et al., 2020) membahas

mengembangkan sebuah kerangka kerja *Deep learning* untuk mengklasifikasikan sampah publik yang dikenal sebagai PublicGarbageNet. Penelitian ini menggunakan *dataset* baru yang dikembangkan oleh peneliti sendiri, mencakup empat kategori utama dan 10 sub-kategori sampah dengan total 10.624 gambar. Label *dataset* mencakup jenis sampah seperti *Kitchen Waste*, *Recyclable Plastics*, *Unrecyclable Plastics*, *Recyclable Paper*, *Unrecyclable Paper*, *Metal*, *Electronics*, *Glass*, *Textile*, dan *Hazardous Material*. *Dataset* ini dibagi menjadi data pelatihan dan pengujian dengan perbandingan 5:1. Selanjutnya, peneliti melakukan tahap multi-task learning, augmentasi data, optimisasi *learning rate*, dan label smoothing dalam pengembangan algoritma klasifikasi sampah. Eksperimen juga dilakukan menggunakan berbagai arsitektur CNN sebagai backbone, serta analisis ablasi untuk mengevaluasi pengaruh komponen jaringan dan teknik pelatihan. Hasil akhir dari penelitian menunjukkan bahwa PublicGarbageNet mencapai akurasi 96,35% pada *dataset* baru ini, dengan *Densenet169* dipilih sebagai backbone yang paling cocok berdasarkan pertimbangan akurasi dan kecepatan.

2.4.7 Penelitian oleh Sujan Poudel dan Prakash Poudyal

Penelitian berjudul “*Classification of Waste Materials using CNN Based on Transfer learning*” (Poudel & Poudyal, 2022) membahas tentang pentingnya pengelolaan limbah melalui pemanfaatan teknologi canggih dalam proses pemilahan limbah yaitu CNN. Penelitian ini menggunakan *dataset* dari Stanford *TrashNet* dan terdiri dari 7 kategori sampah, yaitu *cardboard*, *glass*, *metal*, *paper*, *plastic*, *trash*, dan *organic*. Kemudian, *dataset* dibagi menjadi data *training*, *validation*, dan *testing* dengan

perbandingan 70:18:12. Selanjutnya, peneliti melibatkan langkah *dataset preparation*, *transfer learning*, *image preprocessing*, *feature extraction*, *fine tuning*, dan perbandingan tujuh arsitektur model CNN, yaitu *InceptionV3*, *InceptionResNetV2*, *Xception*, *VGG19*, *MobileNet*, *ResNet50*, dan *DenseNet201*. Penelitian menunjukkan bahwa membedakan jenis limbah menjadi *biodegradable* dan *non-biodegradable* menggunakan teknik *transfer learning* pada CNN dapat mencapai tingkat akurasi sebesar 93,8% dengan model *DenseNet201*.

2.4.8 Penelitian oleh Qiang Zhang, Qifan Yang, Xujuan Zhang, Qiang Bao, Jinqi Su, Xueyan Liu

Penelitian berjudul “*Waste image classification based on transfer learning and CNN*” (Zhang et al., 2021) membahas tentang klasifikasi gambar limbah dengan menggunakan model CNN yaitu *Densenet169*. Penelitian ini menggunakan *dataset* yang dikumpulkan secara manual melalui teknologi web crawler *Python* dan fotografi manual. *Dataset* ini terdiri dari 5 kategori sampah, yaitu *glass*, *cloth*, *paper*, *plastic*, dan *metal*. Kemudian, *dataset* dibagi menjadi data *training* dan *testing* dengan perbandingan 7:3. Peneliti menggunakan tahap *preprocessing* data, *transfer learning*, optimisasi parameter, evaluasi model menggunakan *confusion matrix* serta kurva ROC dan AUC, dan melakukan perbandingan kinerja model *Densenet169* dengan model-model lainnya. Hasil penelitian menunjukkan bahwa model *Densenet169* mencapai tingkat akurasi sebesar 82,8% dalam klasifikasi limbah, mengungguli model-model sebanding seperti *AlexNet*, *GoogLeNet*, dan *VGG*.

2.4.9 Penelitian oleh Janusz Bobulski dan Mariusz Kubanek

Penelitian berjudul “*Deep learning for Plastic Waste Classification System*” (Bobulski & Kubanek, 2021) membahas penggunaan *deep learning* dan CNNs untuk mengklasifikasikan limbah plastik. *Dataset* yang digunakan adalah WaDaBa, yang terdiri dari empat kategori limbah plastik yaitu PET, PE-HD, PS, dan PP. *Dataset* ini dibagi menjadi data *training* dan data *testing* dengan rasio 9:1. Langkah-langkah penelitian meliputi pengumpulan *dataset*, pembagian data, *pre-processing*, pelatihan model, dan evaluasi dengan mengukur akurasi kinerja model menggunakan data *testing*. Hasil penelitian menunjukkan bahwa CNN dengan 15 layer dan gambar berukuran 120x120 piksel lebih efektif untuk mengklasifikasikan limbah plastik dengan akurasi 97,43%. Di antara beberapa model yang diuji, *Mobilenetv2* terbukti paling baik dengan akurasi 86%.

2.4.10 Penelitian oleh Haris Imam Karim Fathurrahman, Ahmad Azhari, Tole Sutikno, Li-Yi Chin, Prasetya Murdaka Putra, Isro Dwian Yunandha, Gralo Yopa Rahmat Pratama, Beni Purnomo

Penelitian berjudul “*Indonesian Waste Database: Smart Mechatronics System*” (Imam et al., 2023) membahas pengembangan sistem mechatronics yang menggunakan kecerdasan buatan untuk mengidentifikasi kategori sampah di Indonesia. Penelitian ini menggunakan *Indonesian Waste Database*, yang terdiri dari enam kategori sampah: *cardboard*, *metal*, *paper*, *plastic*, *medical* dan *organic*. *Dataset* dibagi menjadi data *training* dan *testing* dengan rasio 8:2. Langkah-langkah penelitian meliputi pembagian *dataset*, penggunaan DenseNet sebagai kecerdasan buatan dalam proses pembelajaran, penggunaan Jetson Nano sebagai CPU utama untuk

mentransmisikan data ke sistem robotik *mechatronics*, implementasi sistem deteksi menggunakan kamera pada robot, dan evaluasi sistem untuk meningkatkan efektivitas integrasi kecerdasan buatan dan *mechatronics*. Hasil penelitian ini adalah sistem mekatronik cerdas berbasis kecerdasan buatan yang menggunakan model *DenseNet201*, dengan akurasi 92,7%, untuk mengidentifikasi kategori sampah secara efektif.

2.4.11 Penelitian oleh Hua Zheng dan Yu Gu

Penelitian berjudul “*EnCNN-UPMWS: Waste Classification by a CNN Ensemble Using the UPM Weighting Strategy*” (Zheng & Gu, 2021) membahas tentang sistem klasifikasi limbah menggunakan teknologi CNN ensemble dan strategi pembobotan pengukuran presisi yang tidak setara (UPMWS). Penelitian ini memanfaatkan dua *dataset* yang berasal dari sumber web terbuka dan *dataset* dari penelitian sebelumnya. *Dataset FourTrash* terdiri dari 4 kategori sampah, yakni *recyclable*, *dry*, *wet*, dan *harmful*. Sementara itu, *dataset TrashNet* memiliki 6 kategori sampah, meliputi *glass*, *paper*, *cardboard*, *plastic*, *metal*, dan *trash*. Pengelompokan *dataset* dilakukan menjadi data *training* dan *testing* dengan rasio 70:30. Peneliti melibatkan langkah-langkah, seperti *preprocessing*, UPMWS dengan tiga model CNN, evaluasi *confusion matrix*, dan perbandingan hasil dengan model SOTA serta metode lain, termasuk CNN tunggal dan ansambel CNN. Hasil penelitian menunjukkan bahwa model EnCNN-UPMWS berhasil meningkatkan akurasi klasifikasi sampah menjadi 93,50%, dengan ansambel 3 model CNN dan strategi pembobotan UPMWS. Evaluasi pada *dataset FourTrash* dan *TrashNet* menunjukkan kinerja superior, berpotensi meningkatkan efisiensi pengelolaan limbah dan daur ulang.

2.4.12 Penelitian oleh Olugboja Adedeji dan Zenghui Wang

Penelitian berjudul “*Intelligent Waste Classification System Using Deep learning CNN*” (Adedeji & Wang, 2019) membahas pengembangan sistem klasifikasi sampah cerdas menggunakan kombinasi model CNN yaitu *ResNet-50* dan SVM. Penelitian ini menggunakan *dataset* dari GITHUB dengan 4 kelas sampah, seperti *glass*, *metal*, *paper*, dan *plastic*. Peneliti melibatkan *preprocessing*, *feature extraction ResNet-50*, *color augmentation* dan *batch normalization*, optimasi *ResNet-50* dengan momentum dan *weight decay*. Hasil penelitian menunjukkan bahwa sistem klasifikasi limbah otomatis CNN *ResNet-50* dan SVM mencapai akurasi 87%. Oleh karena itu, model hybrid tersebut mampu mempermudah pemisahan limbah, dan meningkatkan efisiensi.

2.4.13 Penelitian oleh Kunsen Lin, Youcai Zhao, Lina Wang, Wenjie Shi, Feifei Cui, Tao Zhou

Penelitian berjudul “*MSWNet: A visual deep machine learning method adopting transfer learning based upon ResNet 50 for municipal solid waste sorting*” (Lin et al., 2023) membahas tentang sistem klasifikasi limbah padat kota menggunakan *deep learning*, dengan model *ResNet 50 transfer learning*. Penelitian ini menggunakan *dataset* dari web terbuka dan terdiri dari 4 kategori sampah, yaitu *recyclable*, *organic*, *residual*, dan *hazardous*. Kemudian, *dataset* dibagi menjadi data *training*, *testing* dan validasi dengan perbandingan 8:1:2. Peneliti menggunakan serangkaian langkah dalam penelitiannya, termasuk pra-pemrosesan data, penerapan *transfer learning*, visualisasi dengan menggunakan jaringan dekonvolusi, PCA, dan t-SNE, serta penyesuaian *learning rate*. Hasil penelitian menunjukkan bahwa model

MSWNet (*ResNet50* dengan *transfer learning*) berhasil secara efisien mereduksi dimensi data dengan tingkat akurasi mencapai 93,50%. Meskipun demikian, penulis merekomendasikan penelitian lebih lanjut untuk mengatasi beberapa keterbatasannya menggunakan metode CAM dan Grad-CAM.

2.4.14 Penelitian oleh Sunardi, Anton Yudhana, Miftahuddin Fahmi

Penelitian berjudul “*SVM-CNN Hybrid Classification for Waste Image Using Morphology and HSV Color Model Image Processing*” (Sunardi et al., 2023b) mengkaji tentang pengelompokan sampah di Indonesia dengan menggunakan model klasifikasi hibrida yang menggabungkan SVM dan CNN. Tujuan penelitian ini adalah untuk memisahkan jenis sampah dengan menggunakan teknik pemrosesan gambar, seperti morfologi dan model warna HSV. Penelitian ini menggunakan *dataset* yang diperoleh dari *Kaggle* dengan 2 kelas sampah, yaitu organik dan anorganik. *Dataset* tersebut kemudian dibagi menjadi data *training* dan *testing* dengan perbandingan 85:15. Selanjutnya, peneliti melakukan tahap *preprocessing*, evaluasi model SVM-CNN pada data uji, dan melakukan perbandingan model SVM (SIFT-PCA) dan model klasifikasi lain tanpa HSV/morfologi. Hasil penelitian menunjukkan bahwa model SVM-CNN hybrid dengan pengolahan gambar (model warna HSV dan morfologi) mencapai akurasi 99,34%, tanpa *overfitting*. Penulis menyarankan penelitian lebih lanjut dengan CNN saja dan uji coba pada *dataset* berbeda.

2.4.15 Penelitian oleh Leow Wei Qin, Muneer Ahmad, Ihsan Ali, Rafia Mumtaz, Syed Mohammad Hassan Zaidi, Sultan S. Alshamrani, Muhammad Ahsan Raza, dan Muhammad Tahir

Penelitian berjudul “*Precision Measurement for Industry 4.0 Standards towards Solid Waste Classification through Enhanced Imaging Sensors and Deep learning Model*” (Qin et al., 2021) membahas pengukuran presisi untuk standar Industri 4.0 dalam klasifikasi limbah padat menggunakan sensor gambar yang ditingkatkan dan model *deep learning*. Penelitian ini menggunakan *dataset TrashNet* dari penelitian sebelumnya, yang terdiri dari enam kategori sampah: *cardboard, glass, metal, paper, plastic, dan trash*. *Dataset* dibagi menjadi data *training* dan *testing* dengan rasio 8:2. Langkah-langkah penelitian meliputi pembagian *dataset*, augmentasi data pada data *training*, penggunaan *Mobilenetv2* sebagai ekstraktor fitur, klasifikasi dengan *Softmax* dan SVM, validasi silang 10-fold, dan evaluasi model menggunakan data *testing*. Hasil penelitian menunjukkan bahwa meskipun akurasi *Mobilenetv2* dengan SVM mencapai 83,46% dan lebih rendah dibandingkan dengan VGG16 dengan SVM yang mencapai 97%, *Mobilenetv2* lebih praktis untuk diimplementasikan pada perangkat seluler karena arsitekturnya yang ringan dan dirancang khusus untuk aplikasi seluler.

2.4.16 Rangkuman Model Penelitian

Tabel 2.4 Rangkuman Model Penelitian

No	Peneliti	Nama Jurnal dan Tahun	Judul	Latar Belakang	Masalah (Research Question)	Metode	Hasil
1.	Abdul Fadlil, Rusydi Umar, Sunardi, Arief Setyo Nugroho	<i>Emerging Science Journal</i> 2022	<i>Comparison of Machine learning Approach for Waste Bottle Classification</i>	Masalah limbah plastik di Indonesia, terutama botol plastik, masih memiliki nilai ekonomi. Limbah botol plastik dapat didaur ulang menjadi berbagai produk seperti kerajinan, mainan, dan wadah tanaman. Namun, untuk menghasilkan	Bagaimana perbandingan efektivitas metode CNN dan <i>Support Vector Machine</i> dalam mengklasifikasikan botol plastik berdasarkan mereknya?	<i>Support Vector Machine</i> dan CNN	Hasil penelitian menunjukkan bahwa CNN mencapai akurasi 99% dalam mengklasifikasikan botol plastik, sedangkan SVM mencapai akurasi 74%. Hasil eksperimen menegaskan bahwa CNN lebih efektif daripada SVM dalam tugas ini.

				kerajinan berkualitas, perlu dilakukan klasifikasi botol plastik berdasarkan mereknya. Proses klasifikasi ini penting untuk pengelolaan limbah yang lebih efisien dan inovatif.			
2.	Sunardi, Anton Yudhana, Miftahuddin Fahmi	<i>Revue d'Intelligence Artificielle</i> 2023	<i>Improving Waste Classification Using CNNs: An Application of Machine learning for Effective Environmental Management</i>	Dengan bertambahnya volume sampah, dibutuhkan peningkatan efisiensi dalam proses sortir sampah. Proses ini menantang bagi manusia, sehingga	Bagaimana kinerja CNN dalam mengklasifikasikan sampah berdasarkan jenisnya, dibandingkan dengan pendekatan lain dalam	CNN	Hasil penelitian menunjukkan model CNN yang dikembangkan mencapai akurasi 98.92% dan tingkat kehilangan (<i>loss</i>) 4.03% pada set data uji. Hasil yang sangat baik ini

				<p>pengembangan sistem otomatis menggunakan teknik <i>machine learning</i> seperti CNN dianggap sebagai solusi potensial. Artikel ini bertujuan menerapkan CNN untuk mengembangkan sistem klasifikasi sampah yang efisien dan akurat dalam pengelolaan sampah.</p>	<p>penelitian sebelumnya?</p>		<p>menunjukkan bahwa penerapan teknik <i>machine learning</i>, khususnya CNN, efektif dalam menangani masalah klasifikasi sampah. Hal ini berpotensi mengurangi volume sampah yang dibuang ke tempat pembuangan akhir serta melindungi lingkungan.</p>
3.	<p>Cuiping Shi, Cong Tan, Tao Wang, dan Ligu Wang</p>	<p><i>Applied Sciences</i> 2021</p>	<p><i>A Waste Classification Method Based on a Multilayer Hybrid</i></p>	<p>Klasifikasi sampah cerdas sangat diperlukan untuk menghadapi</p>	<p>Bagaimana cara mengembangkan metode yang efektif untuk</p>	<p><i>MLH-CNN, ResNet50, VGG16, AlexNet</i></p>	<p>Hasil penelitian menunjukkan metode MLH-CNN, dengan</p>

			<p><i>Convolution Neural Network</i></p> <p>masalah meningkatnya limbah dan degradasi lingkungan. Penelitian sebelumnya menghadapi tantangan kompleksitas dan jumlah parameter yang besar. Oleh karena itu, penelitian ini bertujuan untuk mengusulkan pendekatan sederhana dengan sedikit parameter untuk meningkatkan</p>	<p>mengklasifikasikan sampah dengan menggunakan jaringan saraf konvolusi multilayer hybrid (MLH-CNN), terutama untuk <i>dataset TrashNet</i> yang memiliki sedikit sampel?</p>	<p>struktur sederhana dan sedikit parameter, unggul dalam eksperimen klasifikasi dengan mencapai akurasi hingga 92,6%. Ini melampaui beberapa metode terbaru lainnya, menunjukkan ekstraksi fitur yang baik dan hasil klasifikasi yang stabil.</p>
--	--	--	---	--	--

				efektivitas klasifikasi sampah.			
4.	Mohammed Imran Basheer Ahmed, Raghad B. Alotaibi, Rahaf A. Al- Qahtani, Rahaf S. Al- Qahtani, Sara S. Al-Hetela, Khawla A. Al- Matar, Noura K. Al-Saqer, Atta Rahman, Linah Saraireh, Mustafa Youldash dan	<i>Sustainability</i> 2023	<i>Deep learning Approach to Recyclable Products Classification: Towards Sustainable Waste Management</i>	Masalah pengelolaan sampah yang terus meningkat menjadi isu global. Arab Saudi, sebagai negara yang sedang berkembang, juga menghadapi tantangan dalam mengelola sampah. Metode tradisional penyortiran sampah secara manual dinilai tidak efisien dan rentan terhadap kesalahan. Oleh karena itu, penelitian ini	Bagaimana <i>deep learning</i> dapat digunakan untuk mengotomatisasi klasifikasi sampah dan meningkatkan efisiensi pengelolaan sampah, serta model <i>deep learning</i> mana yang paling efektif untuk tugas ini?	CNN, <i>Mobilenetv2</i> , <i>ResNet50v2</i> , dan <i>Densenet169</i>	Hasil penelitian menunjukkan bahwa model pre- trained <i>ResNet50v2</i> mencapai akurasi tertinggi 98.95%, diikuti oleh <i>Mobilenetv2</i> dengan 97.6%, <i>Densenet169</i> dengan 94.4%, dan model CNN sendiri dengan 88.52%. Ini membuktikan bahwa <i>deep learning</i> efektif untuk mengotomatisasi dan meningkatkan

	Gomathi Krishnasamy			bertujuan untuk mencari solusi yang lebih efektif dan efisien dalam mengelola sampah, khususnya dalam proses klasifikasi sampah.			efisiensi klasifikasi sampah.
5.	Liyong Yong, Le Ma, Dandan Sun, Liping Du	<i>Application of classification algorithms</i> 2023	<i>Application of Mobilenetv2 to waste classification</i>	Masalah utama dalam pembuangan sampah domestik adalah kurangnya pemilahan dan pembuangan yang tepat. Penelitian ini mengusulkan solusi dengan menerapkan <i>deep learning</i> menggunakan model <i>Mobilenetv2</i>	Bagaimana penerapan model <i>Mobilenetv2</i> dalam aplikasi WeChat dapat membantu dalam pemilahan sampah di rumah, dan seberapa jauh performa model ini bisa mengungguli model CNN tradisional dalam	<i>Mobilenetv2</i>	Hasil penelitian menunjukkan bahwa <i>Mobilenetv2</i> mencapai akurasi 82,92%, melebihi model CNN sebesar 15,42%. Keunggulan <i>Mobilenetv2</i> terletak pada ukuran yang ringan, memungkinkannya dijalankan pada

				<p>untuk mengklasifikasikan sampah domestik ke dalam empat kategori. Hal ini bertujuan untuk meningkatkan efisiensi dan mengurangi klasifikasi manual, menghemat waktu dan biaya.</p>	<p>mengklasifikasikan sampah?</p>		<p>perangkat mobile, sehingga dapat diakses dengan mudah oleh berbagai pengguna.</p>
6.	<p>Ming Zeng, Xiangzhe Lu, Wenkang Xu, Tongxi Zhou, Yinbo Liu</p>	<p><i>Proceedings of the 39th Chinese Control Conference 2020</i></p>	<p><i>PublicGarbageNet : A Deep learning Framework for Public Garbage Classification</i></p>	<p>Penumpukan sampah di sebagian besar kota besar di China berdampak besar pada ekonomi setiap tahunnya dan menekan infrastruktur pengelolaan</p>	<p>Bagaimana cara mengembangkan suatu kerangka kerja <i>deep learning</i> yang efektif untuk melakukan klasifikasi sampah publik, khususnya dalam</p>	<p><i>DenseNet121, Densenet169, ResNet50, ResNet101, ResNeXt50, ResNeXt101, EfficientNet-B3, dan EfficientNet-B4</i></p>	<p>Hasil akhir dari penelitian menunjukkan bahwa PublicGarbageNet mencapai akurasi 96,35% pada <i>dataset</i> baru ini, dengan</p>

			<p>sampah kota. Penelitian ini bertujuan untuk mengembangkan teknologi baru dalam pengelolaan sampah rumah tangga dengan menggunakan PublicGarbageNet, sebuah kerangka kerja <i>deep learning</i>. Metode ini memanfaatkan CNN untuk mengklasifikasikan sampah, mengenali empat kategori utama sampah domestik dan</p>	<p>mengidentifikasi jenis-jenis utama sampah rumah tangga, serta menerapkan berbagai teknik optimisasi untuk meningkatkan akurasi model?</p>	<p><i>Densenet169</i> dipilih sebagai backbone yang paling cocok berdasarkan pertimbangan akurasi dan kecepatan.</p>
--	--	--	--	--	--

				sepuluh subkelas yang berbeda.			
7.	Sujan Poudel dan Prakash Poudyal	<i>FIRE '22: Proceedings of the 14th Annual Meeting of the Forum for Information Retrieval Evaluation 2023</i>	<i>Classification of Waste Materials using CNN Based on Transfer learning</i>	Manajemen limbah sangat penting untuk kesehatan dan kebersihan lingkungan. Salah satu langkah utama dalam manajemen limbah yang efektif adalah memisahkan limbah berdasarkan jenisnya. Oleh karena itu, penelitian ini bertujuan untuk mengelompokkan gambar limbah menjadi tujuh kategori menggunakan	Apakah teknik <i>transfer learning</i> pada CNN dapat digunakan untuk mencapai akurasi tinggi dalam mengklasifikasikan gambar limbah menjadi tujuh kategori?	<i>InceptionV3, InceptionResNetV2, Xception, VGG19, MobileNet, ResNet50, dan DenseNet201</i>	Hasil penelitian ini menunjukkan bahwa menggunakan <i>transfer learning</i> pada CNN bisa sangat efektif untuk mengklasifikasikan gambar limbah ke tujuh kategori, dengan model <i>DenseNet201</i> mencapai akurasi validasi 95,05%. Penelitian juga menyoroti bahwa integrasi teknologi seperti IoT dan AI dapat

				CNN, dengan fokus pada penerapan <i>transfer learning</i> untuk meningkatkan akurasi klasifikasi limbah.			meningkatkan efisiensi dalam pengelolaan limbah secara berkelanjutan.
8.	Qiang Zhang, Qifan Yang, Xujuan Zhang, Qiang Bao, Jinqi Su, Xueyan Liu	<i>Waste Management</i> 2021	<i>Waste image classification based on transfer learning and CNN</i>	Untuk mengatasi masalah polusi limbah perkotaan yang signifikan, peneliti menggunakan teknik <i>transfer learning</i> dan arsitektur CNN dalam mengembangkan model klasifikasi gambar limbah. Mereka	Bagaimana kinerja model Deep-BP-ANN dibandingkan dengan metode <i>Machine learning</i> seperti XGBoost, Logistic Regression, Naïve Bayes, dan KNN dalam memprediksi customer churn	<i>Logistic Regression, Naïve Bayes, k-NN, XGBoost, Artificial Neural Network (ANN)</i>	Deep-BP-ANN mendapatkan akurasi 79.38% menggunakan metode evaluasi Holdout, 73.90% menggunakan metode evaluasi 10-Fold CV pada dataset Cell2Cell, 88.12% menggunakan metode evaluasi Holdout dan

			<p>menghadapi kendala <i>dataset</i> tidak seimbang dan beragam, sehingga membangun <i>dataset</i> NWNUTRASH untuk penelitian ini. Dengan model <i>Densenet169</i>, mereka meningkatkan efisiensi dan akurasi klasifikasi limbah. Pendekatan ini diharapkan memberikan solusi yang lebih efektif dalam mengelola permasalahan limbah perkotaan</p>		<p>86.57% menggunakan metode evaluasi 10-Fold CV pada dataset IBM Telco</p>
--	--	--	--	--	---

				melalui teknologi pengenalan citra berbasis <i>deep learning</i> .			
9.	Janusz Bobulski dan Mariusz Kubanek	<i>Applied Computational Intelligence and Soft Computing</i> 2021	<i>Deep learning for Plastic Waste Classification System</i>	Tantangan utama dalam pengelolaan limbah plastik global adalah proses pemilahan manual yang rumit dan mahal. Untuk meningkatkan efisiensi daur ulang, ilmuwan menggunakan teknologi pemrosesan gambar dan kecerdasan buatan, terutama <i>deep learning</i> , untuk otomatisasi	Seberapa efektif PCA, Autoencoders, LDA, T-SNE, dan Xgboost dalam mengurangi fitur untuk prediksi churn dalam industri yang diberikan?	<i>LightGBM, Decision Tree, Random Forest, Support Vector Machine, Logistic Regression, XGBoost, AdaBoost</i>	LightGBM mendapatkan akurasi terbaik yaitu 86.88% pada dataset Bank Customer, 80.48% pada dataset IBM Telco, dan 95.8% pada dataset Orange menggunakan Bayesian Optimization

				<p>pemisahan limbah seperti kertas, plastik, logam, dan kaca. Salah satu tantangan utama adalah memisahkan berbagai jenis material, seperti warna kaca atau jenis plastik yang berbeda, dalam satu kelompok. Solusi potensialnya adalah menggunakan jaringan saraf konvolusional dan <i>deep learning</i> untuk mengidentifikasi dan memisahkan limbah plastik ke</p>		
--	--	--	--	---	--	--

				dalam kategori PS, PP, PE-HD, dan PET secara otomatis, baik di pabrik daur ulang maupun di rumah tangga.			
10.	Haris Imam Karim Fathurrahman, Ahmad Azhari, Tole Sutikno, Li-Yi Chin, Prasetya Murdaka Putra, Isro Dwian Yunandha, Gralo Yopa Rahmat	<i>International Journal of Robotics and Control Systems</i> 2023	<i>Indonesian Waste Database: Smart Mechatronics System</i>	Meningkatnya masalah sampah di Indonesia memerlukan solusi efisien untuk pengelolaannya. Penelitian ini bertujuan mengembangkan Sistem Mechatronics Cerdas untuk Indonesian Waste Database guna	Bagaimana performa algoritma XGBoost dalam menganalisis churn pelanggan dibandingkan dengan model <i>machine learning</i> lainnya seperti Random Forest atau Logistic Regression?	<i>XGBoost</i>	Berdasarkan hasil pengujian, <i>XGBoost</i> mendapatkan akurasi tertinggi dengan nilai 82.1%

	Pratama, Beni Purnomo			<p>meningkatkan klasifikasi dan manajemen sampah. Sampah di Indonesia telah mencemari lingkungan, terutama wilayah pesisir dan laut. Dengan kecerdasan buatan dan teknologi mechatronics, diharapkan sistem ini dapat lebih akurat dalam mengidentifikasi kategori sampah, mendeteksi objek sampah, dan</p>			
--	--------------------------	--	--	---	--	--	--

				memprediksi pola sampah.			
11.	Hua Zheng dan Yu Gu	<i>Electronics</i> 2021	<i>EnCNN-UPMWS: Waste Classification by a CNN Ensemble Using the UPM Weighting Strategy</i>	Artikel ini menangani masalah manajemen sampah padat di China, yang menghasilkan volume besar setiap harinya. Dengan fokus pada sampah dari rumah tangga dan bisnis, penelitian menggunakan teknologi CNN ensemble dan strategi pembobotan UPM untuk meningkatkan akurasi dalam	Bagaimana dampak dari beberapa kombinasi hyperparameter terhadap performance model?	<i>Neural Network</i>	Berdasarkan hasil pengujian, kombinasi parameter ReLu untuk Hidden Layers dan Sigmoid untuk Output Layers mendapatkan akurasi tertinggi yaitu 86.8%, Batch Size dengan jumlah 7 mendapatkan akurasi terbaik yaitu 85.75%, dan RMSProp mendapatkan akurasi terbaik

			<p>mengklasifikasikan sampah. Dalam menghadapi kompleksitas tantangan pengelolaan sampah, artikel ini berusaha menyediakan solusi dengan mengembangkan metode klasifikasi sampah yang lebih presisi, dengan harapan dapat meningkatkan efektivitas pengelolaan sampah rumah tangga.</p>		<p>yaitu 86.45% sebagai optimizer</p>
--	--	--	---	--	---------------------------------------

12.	Olugboja Adedeji dan Zenghui Wang	<i>Procedia Manufacturing</i> 2019	<i>Intelligent Waste Classification System Using Deep learning CNN</i>	<p>Akumulasi sampah padat di perkotaan dapat mengakibatkan pencemaran lingkungan dan risiko kesehatan, dengan perkiraan peningkatan sebesar 70% pada tahun 2025. Saat ini, metode manual dalam pemisahan limbah terbukti tidak efisien. Penelitian ini menyarankan pengembangan sistem cerdas untuk klasifikasi limbah, menggabungkan</p>	<p>Bagaimana kinerja model prediksi churn pelanggan menggunakan metode klasifikasi CART dan ANN?</p>	<i>Classification and Regression Tree (CART), Artificial Neural Networks (ANN)</i>	<p>Berdasarkan hasil pengujian, ANN mendapatkan akurasi terbaik yaitu 93.88%</p>
-----	-----------------------------------	------------------------------------	--	---	--	--	--

				<p>model CNN <i>ResNet-50</i> yang telah terlatih sebelumnya dengan metode <i>Support Vector Machine</i> .</p>			
13.	<p>Kunsen Lin, Youcai Zhao, Lina Wang, Wenjie Shi, Feifei Cui, Tao Zhou</p>	<p><i>Frontiers in Environmental Science</i> 2023</p>	<p><i>MSWNet: A visual deep machine learning method adopting transfer learning based upon ResNet 50 for municipal solid waste sorting</i></p>	<p>Penelitian ini berupaya mengatasi tantangan semakin kompleksnya pengelolaan sampah padat kota (MSW) dengan menggunakan pendekatan <i>deep learning</i> menggunakan ResNet. Fokus utamanya adalah mengatasi masalah hilangnya gradien</p>	<p>Bagaimana kinerja model JIT-Homogeneous dan JIT-Heterogeneous ensemble model untuk CCP di sektor telekomunikasi?</p>	<p><i>Support Vector Machine, k-NN, Naïve Bayes, Neural Network</i></p>	<p>Berdasarkan hasil pengujian, model Heterogeneous Ensemble (Stacking) mendapatkan akurasi tertinggi yaitu 77.27%.</p>

				<p>dalam jaringan saraf yang dalam, dengan menerapkan pendekatan <i>transfer learning</i> untuk meningkatkan ketersediaan data dan performa model. Penelitian bertujuan menciptakan metode klasifikasi sampah yang akurat dan efisien untuk pengelolaan sampah padat di perkotaan.</p>			
14.	Sunardi, Anton Yudhana,	<i>IIETA</i> 2023	<i>SVM-CNN Hybrid Classification for Waste Image</i>	Masalah pengelolaan sampah di	Bagaimana penggunaan teknik <i>machine learning</i>	<i>k-NN, Support Vector Machine,</i>	Random Forest mendapatkan akurasi terbaik

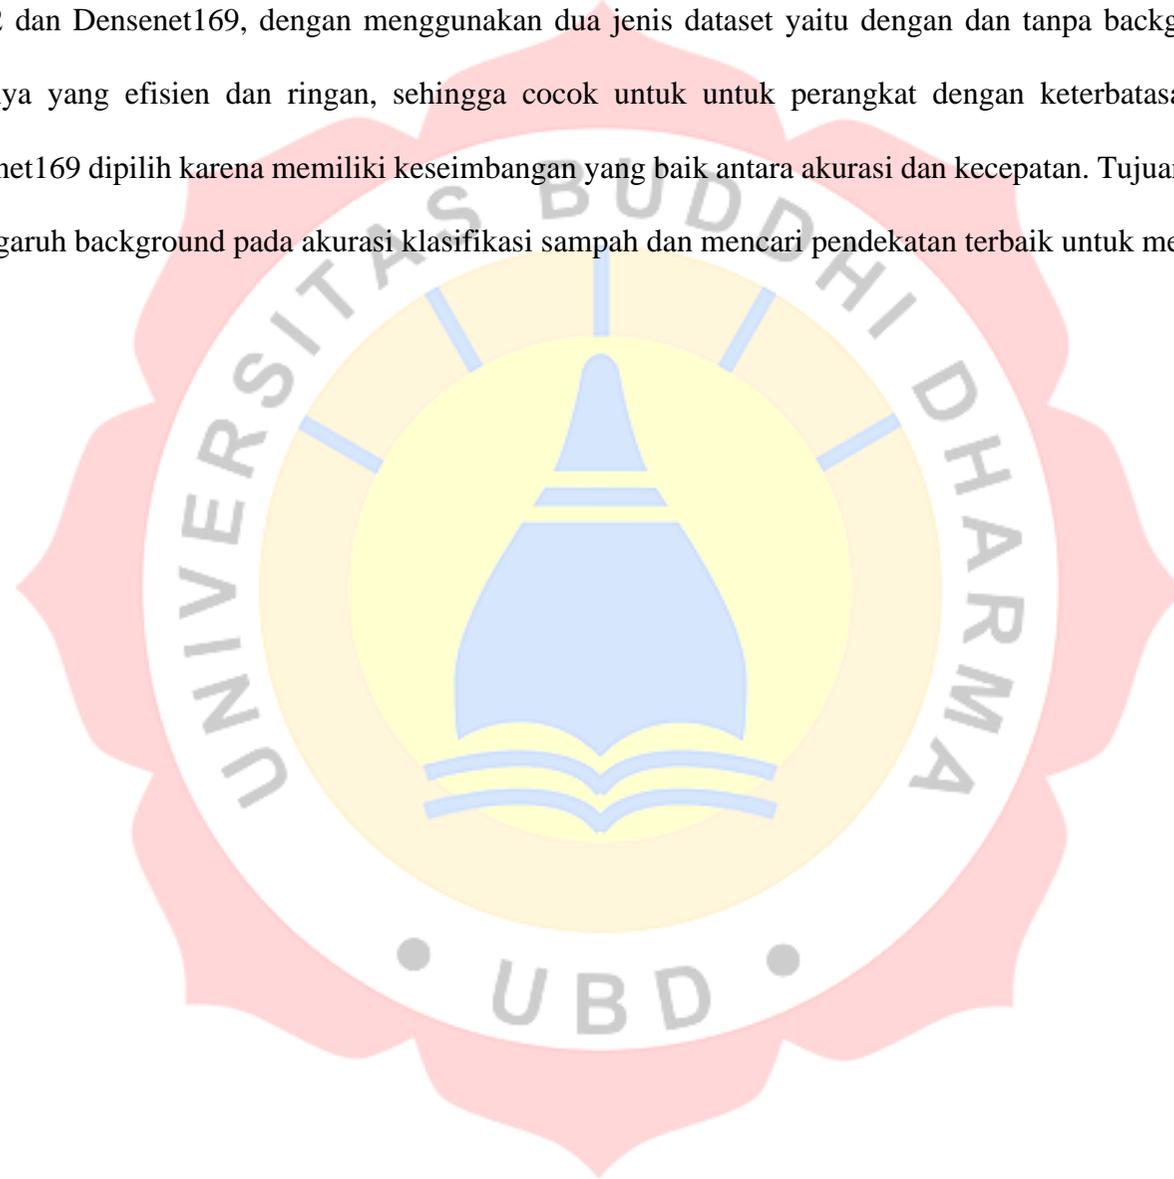
	Miftahuddin Fahmi		<i>Using Morphology and HSV Color Model Image Processing</i>	Indonesia mencerminkan fakta bahwa setiap penduduk rata-rata menghasilkan 0,7 kg sampah per hari, tetapi hanya 55,87% dari jumlah tersebut yang dikelola setiap tahun. Salah satu tantangan utama adalah pengelompokan sampah menjadi organik dan anorganik. Bau tidak sedap dari sampah organik sering kali menjadi keluhan karyawan	dapat membantu dalam memprediksi churn pelanggan di sektor perbankan?	<i>Decision Tree, Random Forest</i>	yaitu 85.18% tanpa Oversampling dan 95.74% menggunakan Oversampling pada pengujian yang dilakukan secara langsung (tanpa Feature Selection), k-NN mendapatkan akurasi terbaik yaitu 83.97% tanpa Oversampling dan Random Forest mendapatkan akurasi terbaik yaitu 92.95% menggunakan Oversampling pada pengujian yang dilakukan
--	----------------------	--	--	---	---	-------------------------------------	---

				<p>yang menghambat efisiensi dalam proses pengelompokan sampah. Penelitian ini bertujuan untuk menerapkan teknologi pembelajaran mesin guna memisahkan jenis sampah secara lebih efektif dan meningkatkan manajemen keseluruhan dalam pengelolaan sampah.</p>			<p>menggunakan mRMR, k-NN mendapatkan akurasi terbaik yaitu 82.15% tanpa Oversampling dan Random Forest mendapatkan akurasi terbaik yaitu 92.19% menggunakan Oversampling pada pengujian yang dilakukan menggunakan Relief-F</p>
15.	Leow Wei Qin, Muneer Ahmad, Ihsan	<i>Wireless Communications</i>	<i>Precision Measurement for Industry 4.0</i>	<p>Pengembangan model klasifikasi gambar yang</p>	<p>Bagaimana penggunaan berbagai fungsi</p>	<i>Artificial Neural Network (ANN)</i>	<p>Berdasarkan hasil pengujian, Fungsi Aktivasi Sigmoid</p>

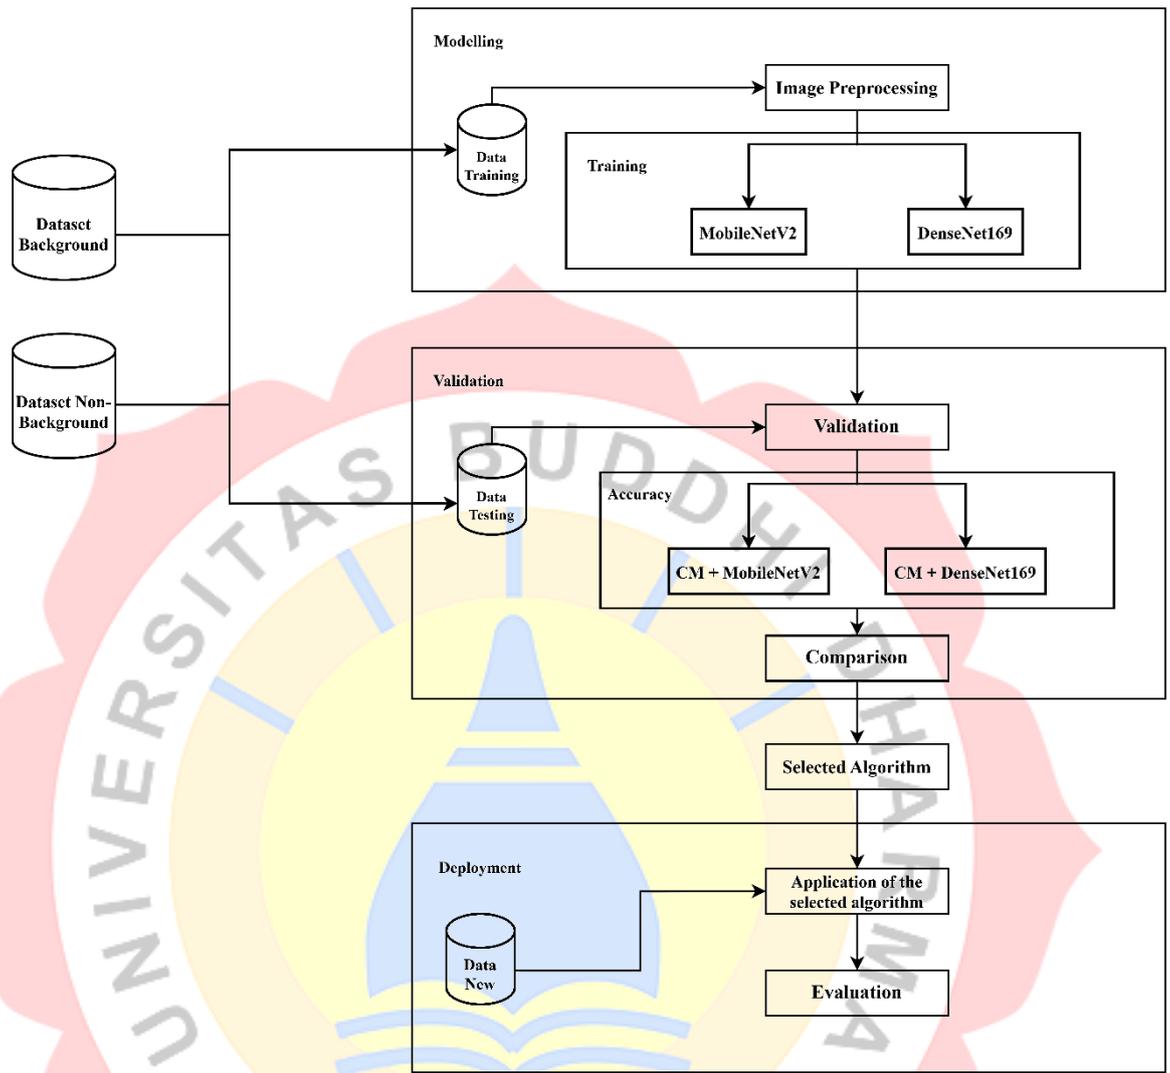
	Ali, Rafia Mumtaz, Syed Mohammad Hassan Zaidi, Sultan S. Alshamrani, Muhammad Ahsan Raza, dan Muhammad Tahir	<i>and Mobile Computing</i> 2021	<i>Standards towards Solid Waste Classification through Enhanced Imaging Sensors and Deep learning Model</i>	efisien dan akurat untuk mengelompokkan limbah padat berdasarkan materi limbahnya. Di era Industri 4.0, menggunakan sensor gambar yang canggih dan model pembelajaran seperti MobileNetV2 sangat penting untuk mengklasifikasikan limbah padat dengan tepat.	aktivasi dalam ANN mempengaruhi performa model?		dengan jumlah Batch Size 50, dan 2 Hidden Layers dengan Hidden Unit (Jumlah Neuron pada Hidden Layers) 75 dan 35 mendapatkan akurasi terbaik yaitu 93.14%.
--	--	-------------------------------------	--	--	---	--	--

Berdasarkan studi sebelumnya, berbagai algoritma seperti ResNet50, VGG16, AlexNet, Mobilenetv2, Densenet169, dan GoogLeNetV2 telah digunakan untuk mengklasifikasikan gambar sampah. Pada penelitian ini, peneliti akan membandingkan dua model,

yaitu Mobilenetv2 dan Densenet169, dengan menggunakan dua jenis dataset yaitu dengan dan tanpa background. Mobilenetv2 dipilih karena arsitekturnya yang efisien dan ringan, sehingga cocok untuk perangkat dengan keterbatasan memori dan komputasi. Sementara, Densenet169 dipilih karena memiliki keseimbangan yang baik antara akurasi dan kecepatan. Tujuan penelitian ini adalah untuk mengevaluasi pengaruh background pada akurasi klasifikasi sampah dan mencari pendekatan terbaik untuk meningkatkan akurasi.



2.5 Kerangka Pemikiran



Gambar 2.9 Kerangka Pemikiran

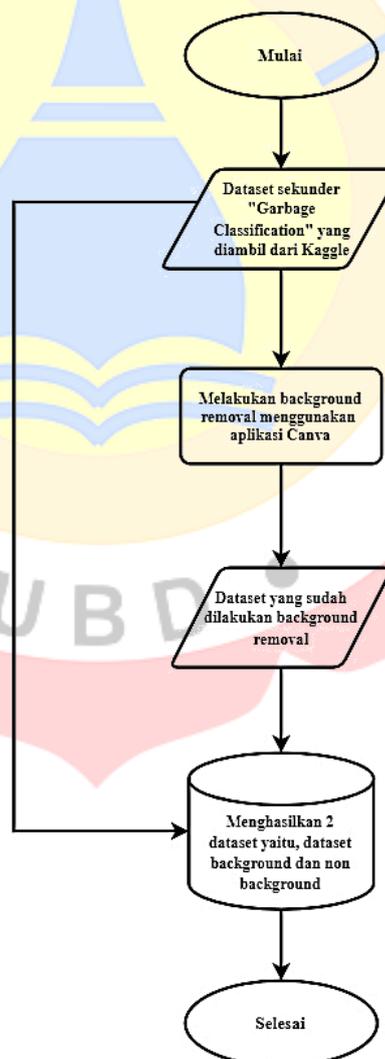
BAB III

METODELOGI PENELITIAN

3.1 Pengumpulan Data

Pada tahap ini, peneliti menggunakan dua dataset. *Dataset* pertama diperoleh dari repositori terbuka *Kaggle*, sedangkan dataset kedua melibatkan proses *background removal* menggunakan aplikasi *Canva*. Jumlah keseluruhan kedua *dataset* ini adalah 5.054 gambar. Informasi terperinci mengenai *dataset* sekunder ini dapat diakses melalui tautan berikut: <https://www.kaggle.com/datasets/asdasdasdasdas/garbage-classification>.

3.1.1 *Flowchart* Perancangan *Dataset*

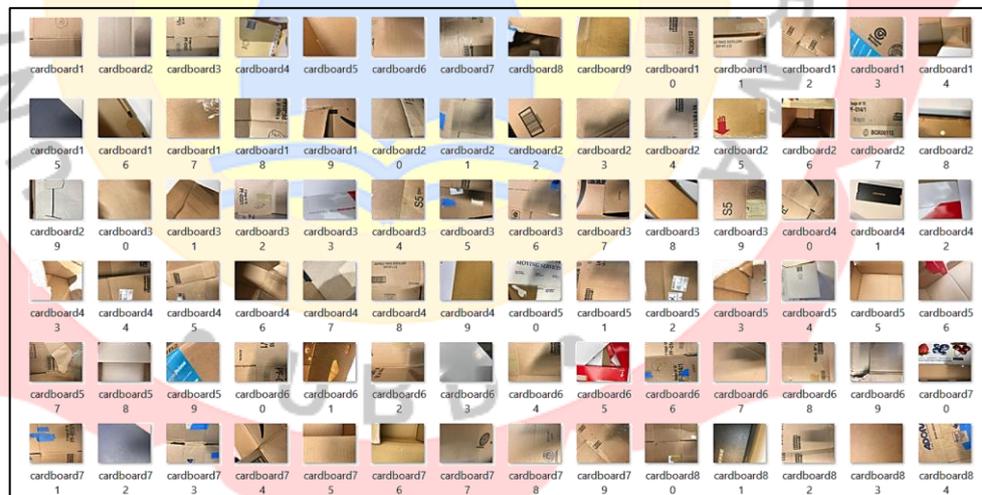


Gambar 3.1 *Flowchart* Perancangan *Dataset*

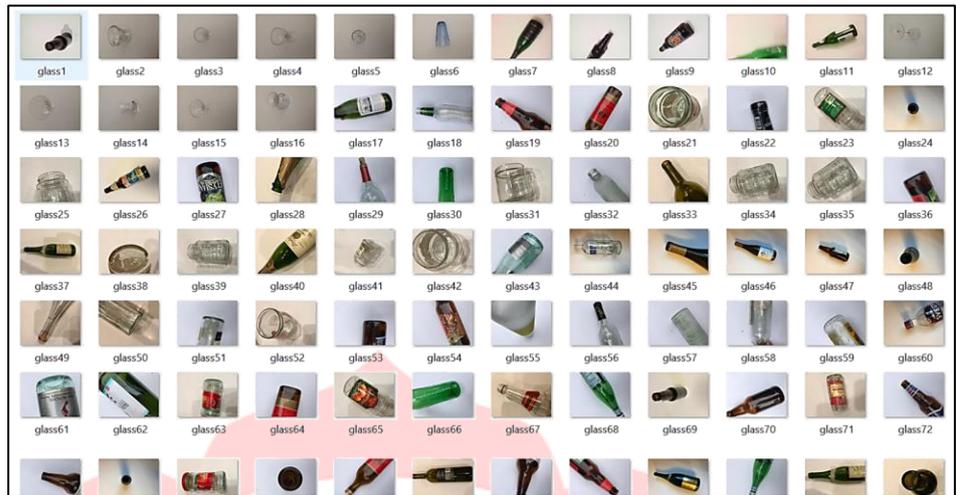
Gambar 3.1 di atas menggambarkan proses pembuatan *dataset* dengan menggunakan *dataset* sekunder "*Garbage Classification*" yang diunduh dari platform *Kaggle*. Langkah pertama adalah melakukan *background removal* pada *dataset* sekunder menggunakan aplikasi *Canva*. Setelah proses *background removal* selesai dilakukan, *dataset* yang telah diolah akan menghasilkan dua *dataset*, yaitu *dataset background* dan *dataset non-background*.

3.1.2 Data Sekunder dari *Kaggle*

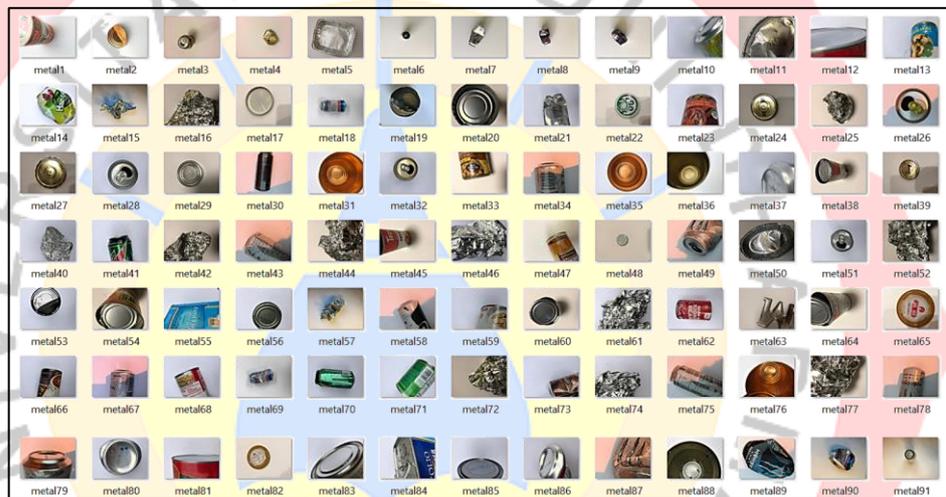
Sumber data awal diperoleh dari *Kaggle* dengan judul *dataset* "*Garbage Classification*" yang dibuat oleh CCHANG. *Dataset* ini terdiri dari 2527 gambar dan memiliki 6 atribut, yaitu *plastic*, *metal*, *glass*, *cardboard*, *trash*, dan *paper*. Gambaran lengkap dari *dataset* yang digunakan dapat dilihat pada Gambar 3.2 hingga 3.7.



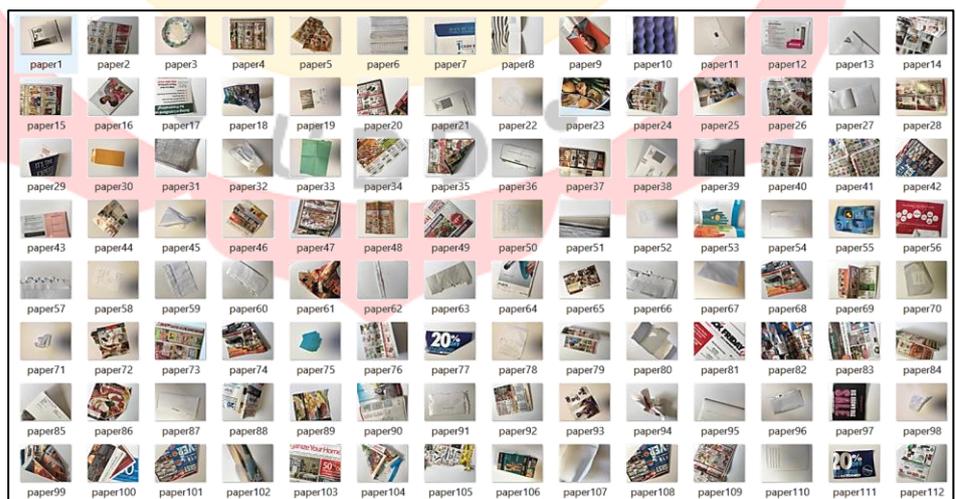
Gambar 3.2 *Cardboard Background*



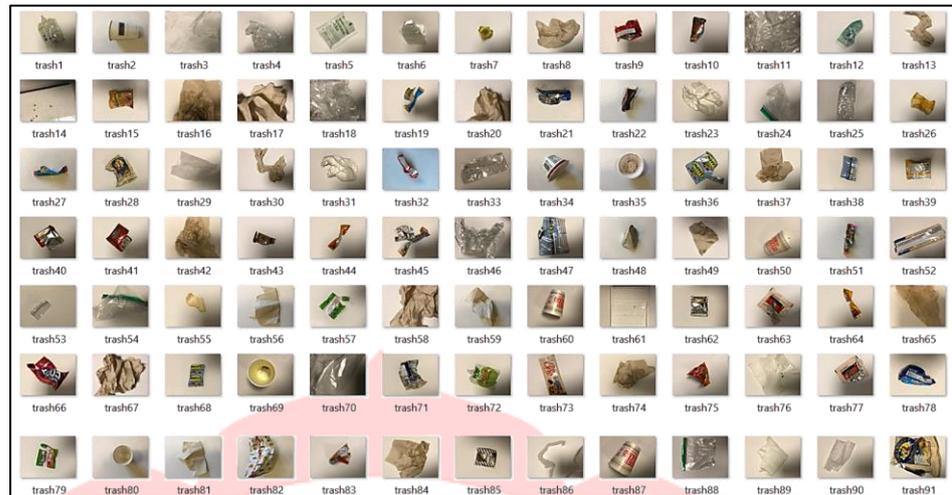
Gambar 3.3 Glass Background



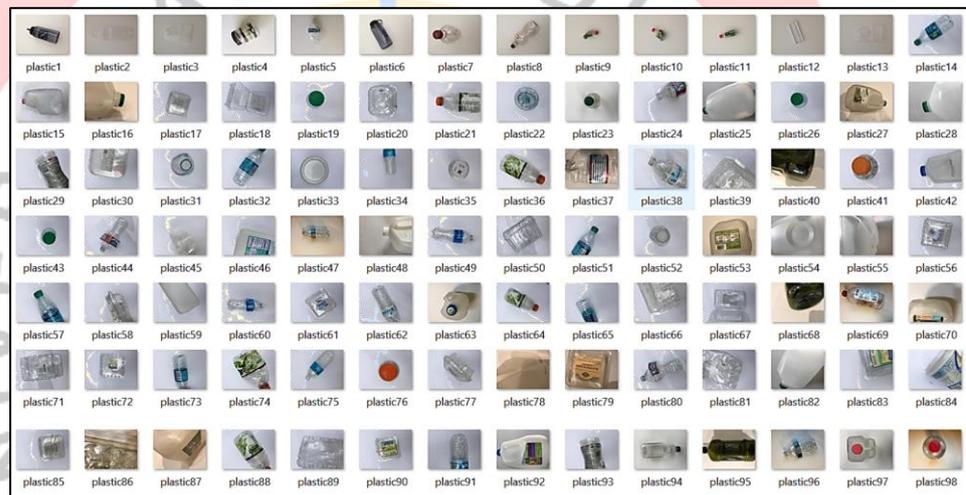
Gambar 3.4 Metal Background



Gambar 3.5 Paper Background



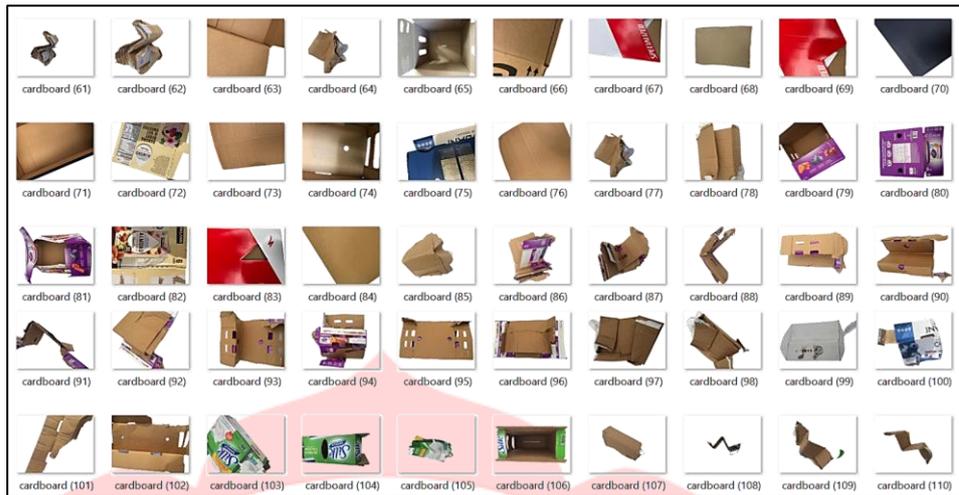
Gambar 3.6 *Trash Background*



Gambar 3.7 *Plastic Background*

3.1.3 Data Metode *Background Removal*

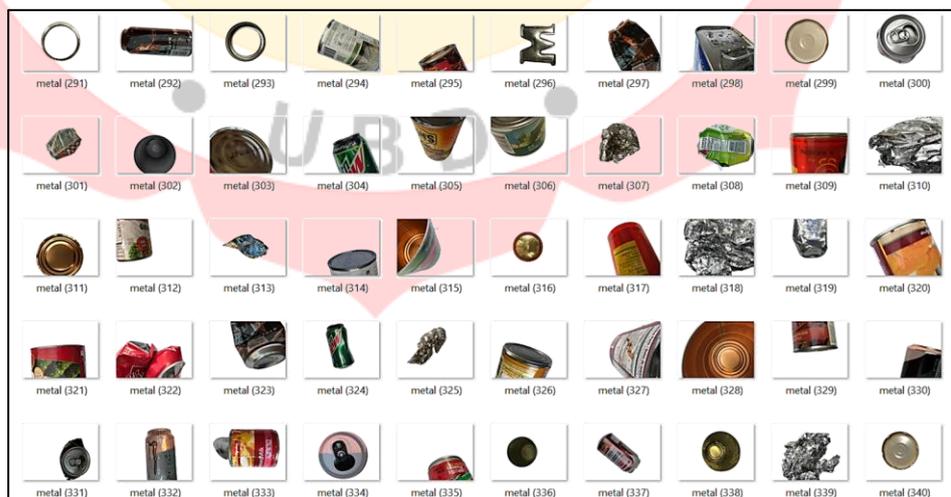
Dalam proses *background removal*, data diperoleh dari data utama yaitu *dataset* yang dimiliki oleh CCHANG dan terdiri dari 2527 gambar dengan 6 atribut. Proses *background removal* dilakukan menggunakan aplikasi Canva. Metode *background removal* ini berfokus untuk memperoleh gambar-gambar sampah dengan latar belakang yang telah dihapus, sehingga memungkinkan untuk memfokuskan analisis pada objek utama, yaitu sampah, tanpa adanya gangguan latar belakang. Gambaran *dataset* setelah proses ini dapat dilihat pada Gambar 3.8 hingga 3.13.



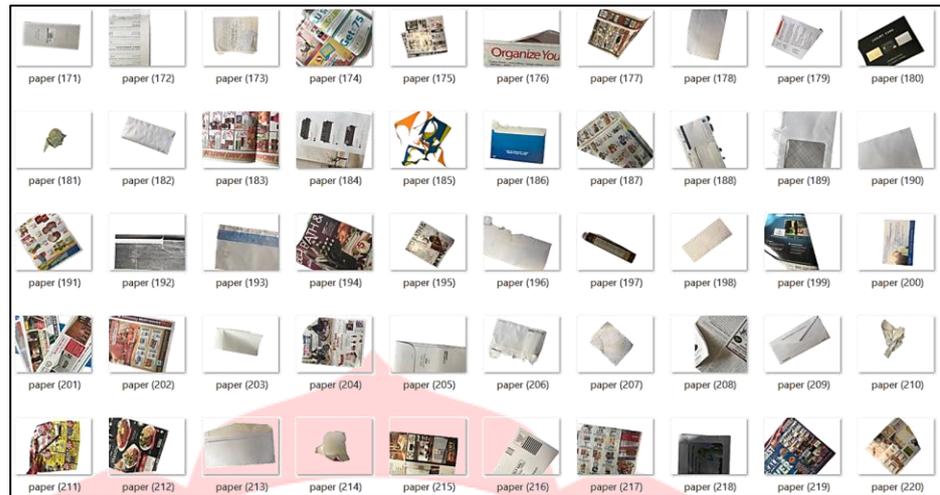
Gambar 3.8 *Cardboard Non-background*



Gambar 3.9 *Glass Non-background*



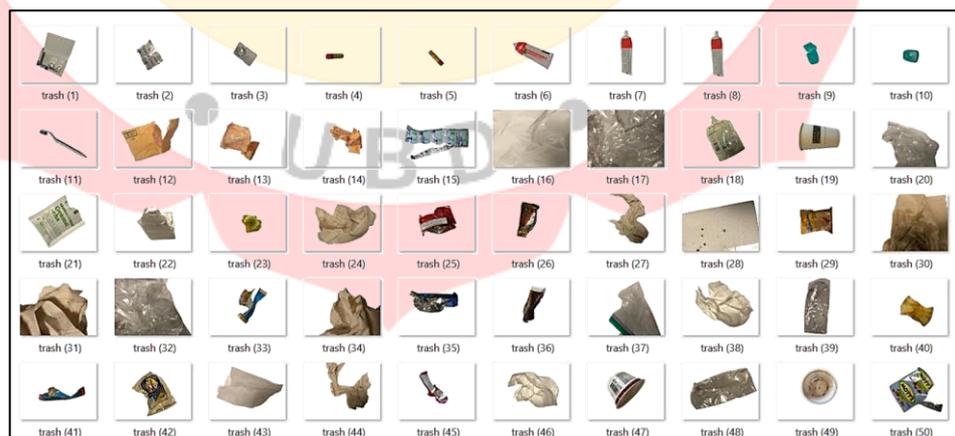
Gambar 3.10 *Metal Non-background*



Gambar 3.11 *Paper Non-background*



Gambar 3.12 *Plastic Non-background*



Gambar 3.13 *Trash Non-background*

3.2 Pengolahan Data

3.2.1 Keterangan Data

Data yang telah terkumpul terdiri dari gambar-gambar yang mewakili 6 variasi sampah yang berbeda. Setiap variasi memiliki ciri fisik yang identik. Model CNN akan mempelajari ciri fisik ini untuk mengenali dan mengklasifikasikan setiap variasi sampah. Tabel 3.1 menjelaskan variasi sampah yang digunakan dan jumlah data yang terdapat di setiap varian.

Tabel 3.1 Keterangan Variasi Sampah

Gambar	Nama Varian	Ciri	Jumlah Data
	<i>Cardboard</i>	Bentuknya dapat beragam, mulai dari kotak standar hingga bentuk khusus, dengan warna dominan coklat, namun ada juga yang berwarna hitam atau putih.	403 sampel
	<i>Glass</i>	Bentuknya seperti tabung, memiliki warna yang bervariasi namun dominan berwarna putih atau transparansi.	501 sampel
	<i>Metal</i>	Bentuknya sangat bervariasi, dengan warna dominan silver dan memiliki kilap alami.	410 sampel

	<p><i>Paper</i></p>	<p>Memiliki beragam bentuk, mulai dari lembaran atau gulungan hingga bentuk khusus, dan biasanya memiliki warna putih atau krem. Warna kertas dapat dipengaruhi oleh cetakan yang ada padanya.</p>	<p>594 sampel</p>
	<p><i>Plastic</i></p>	<p>Memiliki bentuk beragam, seperti botol, kemasan, atau wadah, dengan dominan berwarna putih atau tranparansi.</p>	<p>482 sampel</p>
	<p><i>Trash</i></p>	<p>Memiliki berbagai bentuk seperti kemasan, botol, kertas, atau benda-benda lainnya, dengan ukuran yang beragam. Warnanya juga sangat beragam, sesuai dengan jenis material yang digunakan.</p>	<p>137 sampel</p>

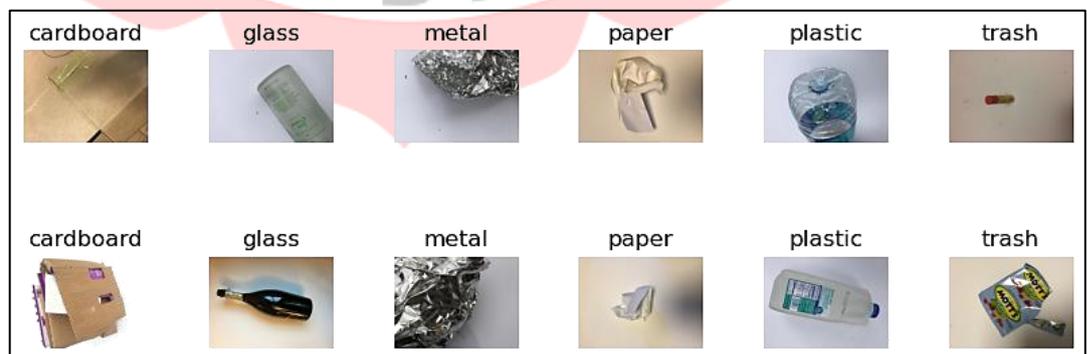
3.2.2 Pelabelan Data

Pada tahap ini, peneliti menggunakan *dataset* yang telah dilabelkan oleh CCHANG melalui repositori terbuka *Kaggle*. *Dataset* tersebut telah dikelompokkan ke dalam 6 folder yang mewakili label *dataset*, di mana masing-masing folder diberi nama sesuai dengan jenis sampah yang menjadi fokus penelitian, seperti *cardboard*, *glass*, *metal*, *paper*, *plastic*, dan *trash*. Dengan *dataset* yang telah dilabeli oleh CCHANG, peneliti dapat langsung memanfaatkannya tanpa perlu melakukan pelabelan ulang, sehingga mempercepat dan mempermudah proses penelitian. Gambar 3.14 memberikan penjelasan rinci mengenai folder-folder yang merepresentasikan setiap variasi sampah yang digunakan dalam penelitian.

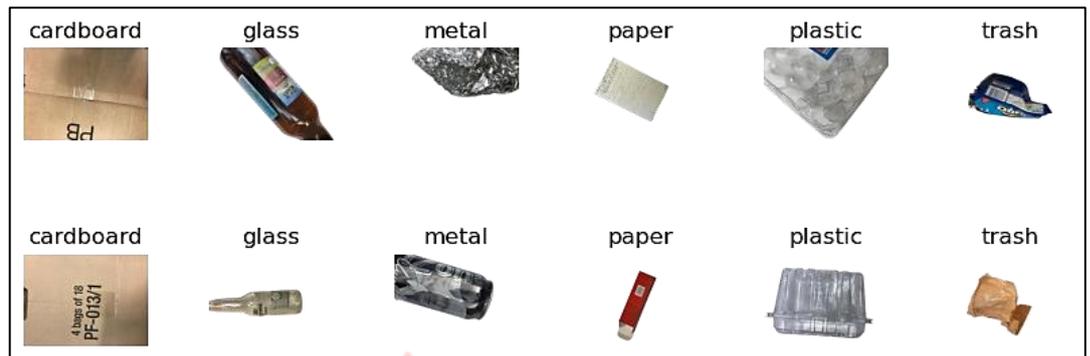
Name	Date modified	Type
cardboard	16/01/2024 20:55	File folder
glass	16/01/2024 20:55	File folder
metal	16/01/2024 20:55	File folder
paper	16/01/2024 20:55	File folder
plastic	16/01/2024 20:55	File folder
trash	16/01/2024 20:55	File folder

Gambar 3.14 Folder masing-masing variasi

Berikut adalah gambaran *dataset background* dan *nobackground* beserta labelnya, seperti yang terlihat pada Gambar 3.15 dan 3.16.



Gambar 3.15 *Dataset Background*



Gambar 3.16 *Dataset Non-background*

3.2.3 Pembagian Data

Selanjutnya *dataset* yang sudah memiliki label, akan dibagi *secara pseudo-random* menjadi data *training*, *validation* dan *testing*. Pada tahap *training*, data *training* akan digunakan untuk melatih model CNN. Data *validation* digunakan untuk memvalidasi hasil pelatihan model, sedangkan data *testing* digunakan untuk menguji kinerja model tersebut. Proses ini dilakukan menggunakan modul *split-folders* pada bahasa pemrograman *Python* dengan menggunakan *seed* tertentu (Filter, 2022) dan pembagian mengikuti rasio umum 8:1:1 (Brown et al., 2023). Selanjutnya, Tabel 3.2 memberikan informasi lengkap tentang pengaturan dalam pembagian *dataset* menggunakan modul *split-folders* dalam *Python*.

Tabel 3.2 *Konfigurasi Splitfolders*

Parameter	Nilai
Tipe Pembagian	Ratio
Seed	42
Rasio <i>Training</i>	.8
Rasio <i>Validation</i>	.1
Rasio <i>Testing</i>	.1

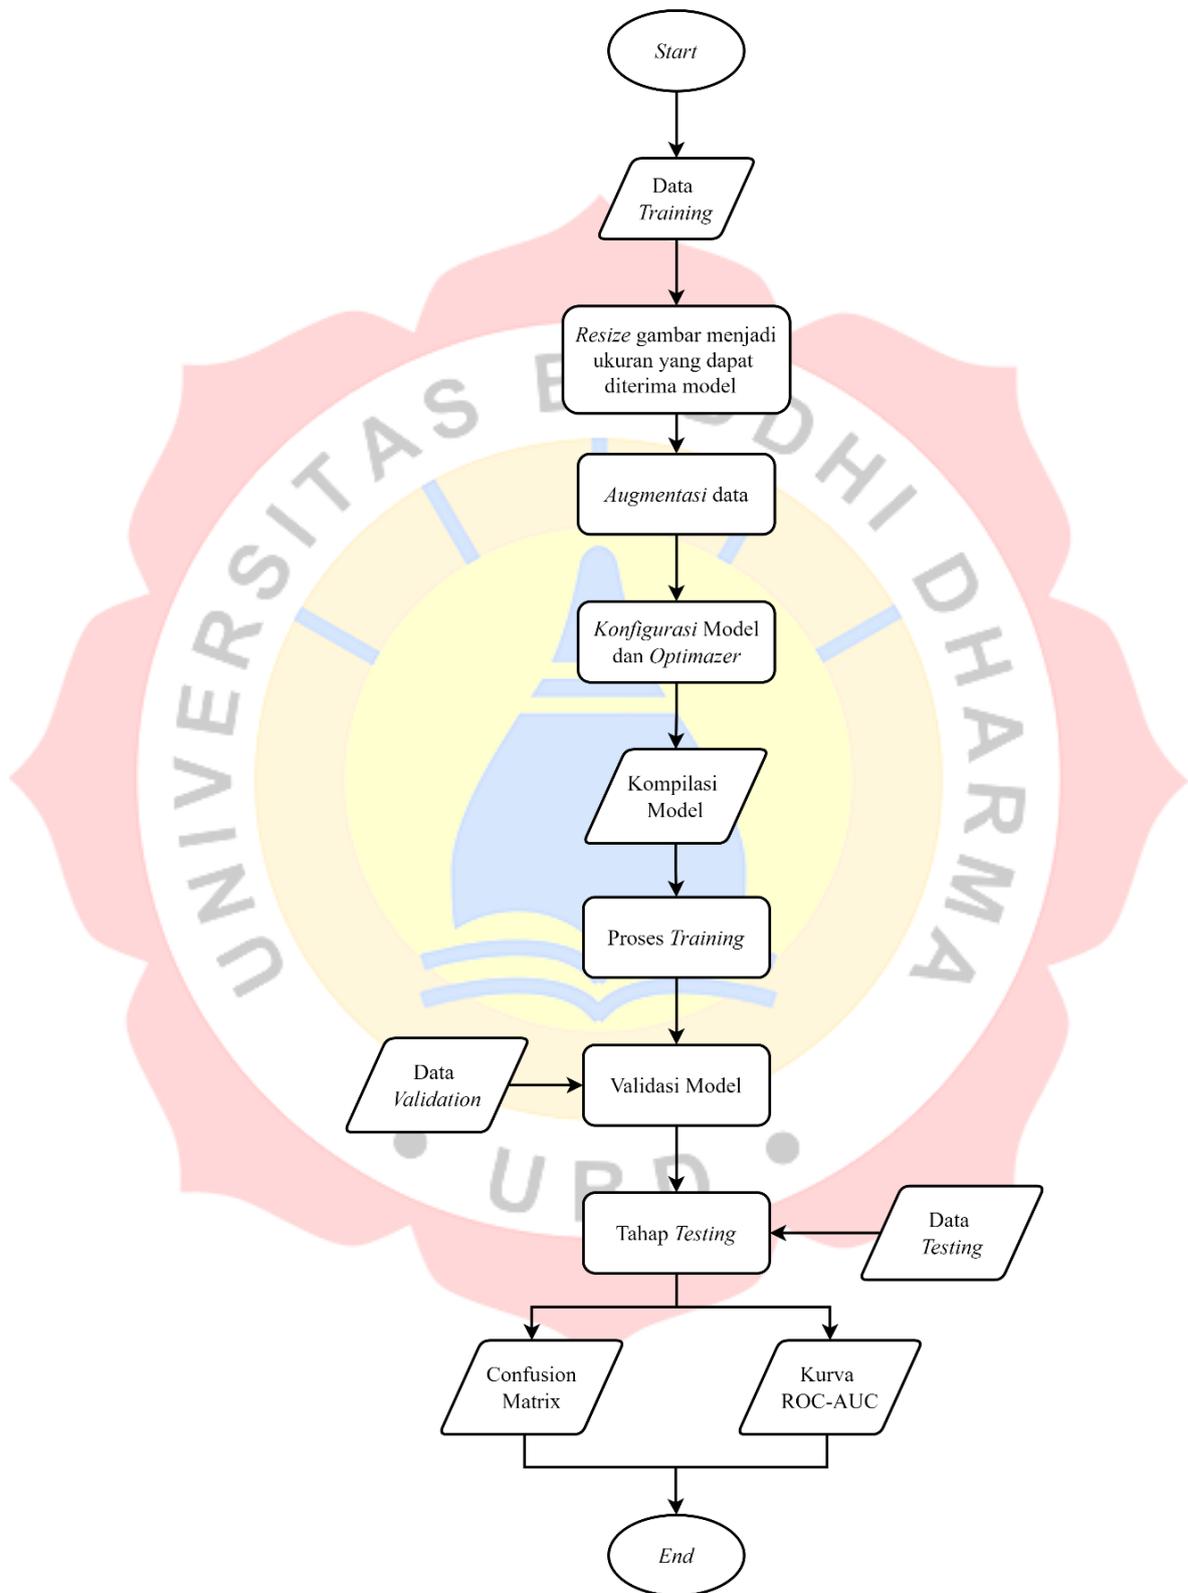
Setelah dilakukan operasi pembagian folder sesuai dengan konfigurasi pada tabel 3.2, hasilnya adalah tiga folder yang diberi nama train, val, dan test. Dalam folder train, terdapat total 2019 gambar data *training*, yang terdiri dari 322 gambar kardus, 400 gambar kaca, 328 gambar logam, 475 gambar kertas, 385 gambar plastik, dan 109 gambar sampah. Kemudian, di folder val, terdapat 251 gambar data validasi, yang terbagi menjadi 40 gambar kardus, 50 gambar kaca, 41 gambar logam, 59 gambar kertas, 48 gambar plastik, dan 13 gambar sampah. Terakhir, di folder test, terdapat 257 gambar data pengujian, dengan perincian 41 gambar kardus, 51 gambar kaca, 41 gambar logam, 60 gambar kertas, 49 gambar plastik, dan 15 gambar sampah. Pembagian ini dilakukan secara proporsional terhadap semua kelas variasi sampah. Selanjutnya, Gambar 3.17 yang terdapat di bawah ini menunjukkan hasil dari proses splitfolders yang terbagi ke dalam folder val, train, dan test.

test	16/01/2024 20:55	File folder
train	16/01/2024 20:55	File folder
val	16/01/2024 20:55	File folder

Gambar 3.17 Hasil *Splitfolders*

3.3 Pelatihan Model

3.3.1 Flowchart Pelatihan Model



Gambar 3.18 Flowchart Pelatihan Model

Dalam proses pelatihan model, seperti ditunjukkan pada Gambar 3.18 di atas, terdapat serangkaian langkah yang perlu dilakukan. Langkah pertama dalam pelatihan model ini adalah menyiapkan data pelatihan. Hal ini melibatkan proses *resizing* gambar menjadi ukuran 224 x 224 piksel, sesuai dengan spesifikasi input model CNN. Selanjutnya, dilakukan teknik augmentasi data seperti *shear*, *zoom*, *horizontal flip*, *rotation*, *height shift*, *width shift*, dan *brightness adjustment*. Tujuannya adalah untuk memperkaya dataset *training* dan meningkatkan keragaman sampel.

Setelah data siap, model kemudian dikonfigurasi sesuai dengan arsitektur yang telah ditentukan, seperti yang terlihat pada Tabel 3.5. Selanjutnya, model dikompilasi dengan parameter-parameter yang sesuai, sebagaimana ditunjukkan pada Tabel 3.6.

Proses pelatihan model pun dilakukan menggunakan data *training*. Untuk mengevaluasi performa model, dilakukan validasi dengan menggunakan data validasi. Dari proses validasi, dapat dinilai sejauh mana model mampu mengenali pola dalam data yang belum pernah dilihat sebelumnya.

Terakhir, model diuji menggunakan data *testing* untuk mengetahui performa akhirnya. Evaluasi lebih rinci dilakukan dengan menggunakan *confusion matrix* dan kurva ROC-AUC, guna mendapatkan pemahaman yang lebih komprehensif tentang kinerja model.

3.3.2 Perangkat Keras

Untuk melatih model CNN, diperlukan perangkat keras yang memadai. Kecepatan pelatihan model sangat dipengaruhi oleh spesifikasi perangkat keras yang digunakan. Semakin tinggi spesifikasi perangkat keras,

maka proses pelatihan model akan semakin cepat. Pada bidang *deep learning*, meskipun tidak wajib, penggunaan kartu grafis dapat mempercepat proses pelatihan karena kemampuannya dalam melakukan komputasi secara paralel. Detail perangkat keras yang digunakan untuk penelitian ini terdapat pada Tabel 3.3.

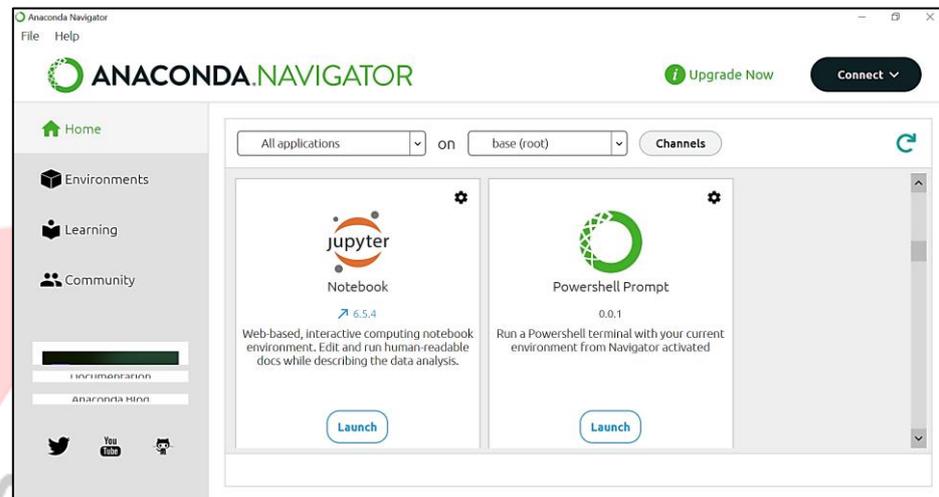
Tabel 3.3 Spesifikasi Perangkat Keras

Jenis Perangkat Keras	Nama Perangkat Keras
Processor	Intel core i5 - 8250U
RAM	16 GB DDR 4 1197MHz
Kartu Grafis	NVIDIA GeForce 920MX
Penyimpanan	SSD: 119 GB
Peripheral	Keyboard Mouse Monitor

3.3.3 Lingkungan Pengembangan

Pelatihan model CNN dilakukan menggunakan Anaconda Navigator. Anaconda Navigator memiliki fasilitas khusus yang memungkinkan pengaplikasian ilmiah, termasuk pelatihan model *machine learning*. *Python* 3.11.5 dipilih sebagai versi *Python* yang digunakan untuk memastikan keamanan, kinerja, dan fitur terbaru, sambil mempertahankan kompatibilitas penuh dengan pustaka yang digunakan. *Tensorflow* versi 2.15 digunakan karena versi tersebut merupakan versi terakhir yang mendukung penggunaan kartu grafis pada sistem operasi Windows. Model CNN diperoleh dari Keras yang telah terintegrasi secara default dengan *Tensorflow*. Proses

pengembangan model dilakukan menggunakan *Jupyter Notebook* karena antarmuka yang mudah digunakan dan integrasi yang langsung dengan Anaconda. Selanjutnya, Gambar 3.19 di bawah ini menampilkan antarmuka Anaconda Navigator.



Gambar 3.19 Anaconda Navigator

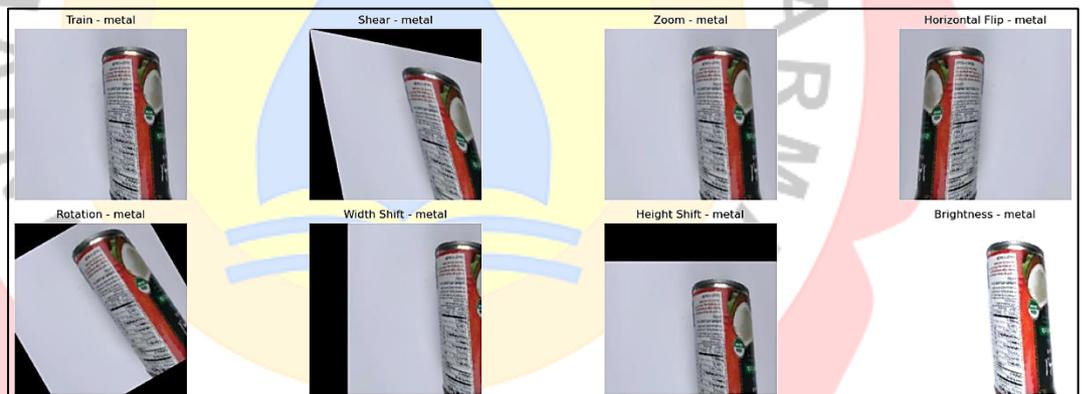
3.3.4 Augmentasi Data

Untuk meningkatkan kompleksitas *dataset* secara buatan, diperlukan augmentasi data dengan melakukan transformasi acak pada data pelatihan. Sebelum melakukan transformasi gambar, diterapkan fungsi *preprocessing* yang mengubah format gambar agar dapat diterima oleh model CNN. Salah satu tahap *preprocessing* ini adalah meresize gambar menjadi resolusi yang sesuai dengan setiap model CNN yang akan dilatih. Berikut adalah ukuran gambar *input* untuk setiap model CNN, sebagaimana tercantum pada Tabel 3.4 di bawah ini.

Tabel 3.4 Ukuran input tiap model CNN

Arsitektur	Resolusi <i>Input</i>
<i>Mobilenetv2</i>	224 × 224
<i>Densenet169</i>	224 × 224

Dalam proses transformasi *dataset*, terdapat beberapa teknik yang dapat diterapkan. Pertama, kita dapat menggunakan teknik *shear* untuk menggeser sudut pada gambar. Selanjutnya, kita dapat memanfaatkan teknik *zoom* untuk memperbesar atau memperkecil bagian tertentu dari gambar. Selain itu, kita juga dapat menggunakan teknik *horizontal flip* untuk mencerminkan gambar secara horizontal, serta teknik *rotation* untuk memberikan variasi orientasi. Selain itu, terdapat pula teknik *height shift* yang digunakan untuk menggeser gambar secara vertikal, serta teknik *width shift* yang digunakan untuk menggeser gambar secara horizontal. Terakhir, kita dapat menggunakan teknik *brightness adjustment* untuk mengatur tingkat kecerahan pada gambar. Contoh penerapan teknik augmentasi gambar dapat dilihat pada Gambar 3.20 di bawah ini.

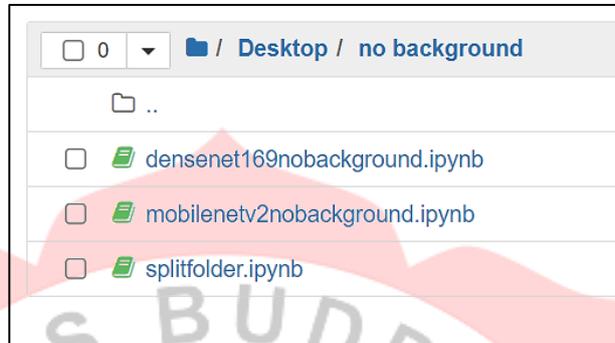


Gambar 3.20 Contoh Augmentasi *Label Glass*

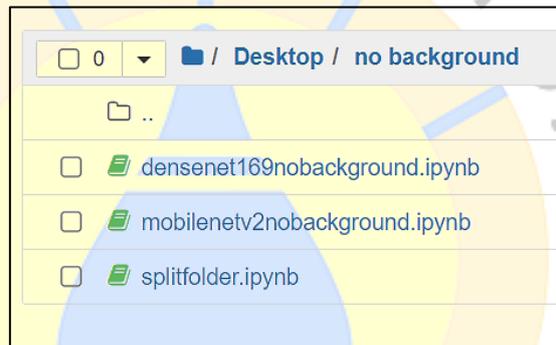
3.3.5 Konfigurasi Model dan *Optimizer*

Konfigurasi model dan *optimizer* dilakukan pada file *Jupyter Notebook* masing-masing model. Struktur folder disusun berdasarkan arsitektur CNN yang digunakan, yaitu *Mobilenetv2* dan *Densenet169*. Dalam folder tersebut, terdapat file *notebook* yang menangani proses pengolahan gambar dan non-pengolahan gambar. Penyusunan struktur folder ini

membantu menjaga kebersihan dan keteraturan file *notebook*, serta memudahkan akses untuk mengonfigurasi setiap model. Gambar 3.21 dan 3.22 menunjukkan struktur folder yang digunakan dalam penelitian ini.



Gambar 3.21 Folder *Notebook Dataset Background*



Gambar 3.22 Folder *Notebook Dataset Non-background*

Dalam penelitian ini, arsitektur CNN dideklarasikan dalam variabel `base_model`. Untuk melakukan *transfer learning*, bobot diatur sebagai 'imagenet' dan `layer.trainable` diatur sebagai `false`, sehingga lapisan CNN membeku dan informasi yang diperoleh dari *transfer learning* tetap terjaga. Berikut adalah konfigurasi keempat model yang digunakan dalam penelitian ini, seperti yang tercantum dalam Tabel 3.5 di bawah ini:

Tabel 3.5 Konfigurasi parameter model CNN

Parameter	<i>Mobilenetv2</i>	<i>DenseNet169</i>
Base model	<i>Mobilenetv2()</i>	<i>Densenet169()</i>
Include_top	False	False

Weights	Imagenet	Imagenet
Jumlah neuron	64	64
Aktivasi dense layer	Relu	Relu
Layer.trainable	False	False

Untuk melatih model, optimizer diterapkan saat melakukan kompilasi model. Setiap model dilatih selama 20 *epoch* (iterasi) karena jumlah data yang relatif kecil, serta memberikan perbandingan yang seimbang antara model-model saat tahap evaluasi. Pengukuran *loss* yang digunakan adalah categorical crossentropy, yang merupakan metode umum untuk mengukur kesalahan akurasi pada model klasifikasi dengan banyak kelas. Selanjutnya, informasi lengkap mengenai konfigurasi kompilasi model tercantum dalam Tabel 3.6.

Tabel 3.6 Konfigurasi kompilasi model

Parameter	ADAM
Optimizer	adam
Loss	Categorical_crossentropy
Metrics	Accuracy
Epochs	20

3.3.6 Kompilasi Model

Proses pelatihan model dilakukan sesuai dengan konfigurasi yang telah ditentukan untuk masing-masing model. Waktu pelatihan model bervariasi antara 1 jam hingga 2 jam, tergantung pada arsitektur CNN yang digunakan dan keterbatasan perangkat keras. Berikut adalah akurasi dua model CNN yang telah melalui berbagai proses pengolahan gambar dari awal hingga akhir pelatihan, sebagaimana tertera pada Tabel 3.7 di bawah ini.

Tabel 3.7 Perbandingan Akurasi Model *Dataset Background* dan *Non-background*

<i>Epoch</i>	MobileNetV Background	Densenet169 Background	Mobilenetv2 Non-background	Densenet169 Non- background
<i>Epoch 1</i>	0.6920	0.7321	0.7143	0.7098
<i>Epoch 2</i>	0.7768	0.7812	0.7232	0.7545
<i>Epoch 3</i>	0.8036	0.8036	0.7812	0.7946
<i>Epoch 4</i>	0.8304	0.7946	0.7723	0.8571
<i>Epoch 5</i>	0.7946	0.8259	0.7589	0.8259
<i>Epoch 6</i>	0.8304	0.8482	0.7991	0.8170
<i>Epoch 7</i>	0.8348	0.8259	0.7946	0.8125
<i>Epoch 8</i>	0.8259	0.8348	0.7991	0.8616
<i>Epoch 9</i>	0.8170	0.8438	0.8080	0.8482
<i>Epoch 10</i>	0.8259	0.8393	0.8348	0.8482
<i>Epoch 11</i>	0.8259	0.8482	0.8170	0.8393
<i>Epoch 12</i>	0.8304	0.8214	0.7946	0.8214
<i>Epoch 13</i>	0.8348	0.8482	0.7812	0.8393
<i>Epoch 14</i>	0.8393	0.8571	0.8125	0.8527
<i>Epoch 15</i>	0.8080	0.8571	0.8036	0.8304
<i>Epoch 16</i>	0.8304	0.8705	0.8348	0.8571
<i>Epoch 17</i>	0.8438	0.8482	0.8170	0.8304
<i>Epoch 18</i>	0.8482	0.8571	0.7991	0.8036
<i>Epoch 19</i>	0.8214	0.8482	0.8259	0.8571
<i>Epoch 20</i>	0.8348	0.8616	0.7857	0.8705

3.4 Metode Evaluasi

Mengevaluasi model *machine learning* untuk mengukur kinerjanya sangat penting sebagai indikator seberapa baik model tersebut. Dalam penelitian ini, akan digunakan dua metode evaluasi yang berbeda. Setiap metode memiliki perannya sendiri dalam mengukur kemampuan model CNN dari berbagai sudut pandang.

3.4.1 *Confusion matrix*

Confusion matrix merupakan matriks berukuran $N \times N$ yang digunakan untuk mengevaluasi kinerja model klasifikasi pada suatu *dataset*. Dalam penelitian ini, *Confusion matrix* diperoleh melalui pengujian model CNN menggunakan data *testing*. Sebelum pengujian dilakukan, *dataset* dibagi menjadi tiga bagian, yakni data *training* sebesar 80%, data *validation* sebesar 10%, dan data *testing* sebesar 10%. Setelah model dilatih dan diuji pada data *testing*, didapatkan nilai *true positive* (TP), *true negative* (TN), *false positive* (FP), serta *false negative* (FN) yang membentuk *Confusion matrix*. Matriks ini disusun dengan predicted class sebagai sumbu x (berisi prediksi model) dan actual class sebagai sumbu y (mencerminkan kelas asli sampel *testing*). Untuk memudahkan pemahaman, hasil *Confusion matrix* akan divisualisasikan menggunakan *library* matplotlib.

3.4.2 Akurasi Klasifikasi

Akurasi klasifikasi merupakan metode pengukuran yang sederhana namun sangat berguna dalam mengevaluasi performa model CNN. Dalam penghitungannya, akurasi klasifikasi menggunakan empat variabel penting. *True positive* dan *true negative* adalah jumlah klasifikasi yang benar dan akurat, sedangkan *false positive* dan *false negative* adalah jumlah klasifikasi yang salah oleh model. Dari variabel-variabel ini, terdapat empat tolak ukur untuk mengukur akurasi model, yaitu:

- a. Akurasi: Kemungkinan sebuah model untuk melakukan klasifikasi dengan benar pada suatu unit data.
- b. Presisi: Ukuran seberapa sering model tersebut mengklasifikasikan sesuatu sebagai "positif" dengan benar

- c. *Recall*: Mengukur sejauh mana model dapat mengklasifikasikan objek positif dengan benar.
- d. *F1-score*: Rata-rata harmonis antara presisi dan *recall*, yang memberikan bobot seimbang kepada keduanya. Rentang nilai F1 score adalah 0 hingga 1, di mana nilai 1 menunjukkan kinerja terbaik.

3.4.3 Kurva ROC-AUC

ROC-AUC adalah metrik evaluasi yang digunakan untuk mengukur seberapa baik model klasifikasi membedakan antara kelas positif dan negatif pada suatu *dataset*. Langkah pertama adalah melatih model klasifikasi pada data *training* dan menggunakan model tersebut untuk membuat prediksi pada data *testing*. Kurva ROC-AUC diperoleh dari perbandingan *false positive rate* (FPR) dan *true positive rate* (TPR). Proses ini melibatkan penggunaan fungsi *roc_curve* dari *library* sklearn, dengan parameter *y_true* (target kelas dari data *testing*) dan *y_score* (hasil prediksi probabilitas positif pada data *testing*). Nilai-nilai ini digunakan untuk menghitung FPR dan TPR pada berbagai *threshold*. Hasil perhitungan kemudian diplotkan ke dalam kurva, dengan TPR sebagai sumbu y dan FPR sebagai sumbu x.