

KLASIFIKASI SAMPAH NON-ORGANIK MENGGUNAKAN ARSITEKTUR VGG-16, RESNET50 DAN DENSENET121

Anak Agung Candra Widyarningsih^{*1}, Ni Wayan Yulya Wiani², I Nyoman Saputra Wahyu Wijaya³

¹ Teknologi Informasi, Fakultas Pertanian dan Teknik, Universitas Panji Sakti

² Sistem dan Teknologi Informasi, Institut Teknologi dan Kesehatan Bali

³ Ilmu Komputer, Fakultas Teknik dan Kejuruan, Universitas Pendidikan Ganesha

Email: agung.candra@unipas.ac.id, yulyawiani23@gmail.com, wahyu.wijaya@undiksha.ac.id

*Penulis Korespondensi

(Naskah masuk: 26 April 2026, diterima untuk diterbitkan: 30 April 2026)

Abstrak

Pertumbuhan populasi global memicu lonjakan produksi sampah padat, termasuk di Indonesia di mana sebagian besar sampah berakhir di Tempat Pembuangan Akhir (TPA) tanpa melalui proses pemilahan yang memadai. Kurangnya pemahaman dan kesadaran masyarakat terkait klasifikasi sampah, khususnya sampah non-organik, mengakibatkan pengelolaan yang tidak optimal serta memicu dampak negatif terhadap lingkungan dan kesehatan masyarakat. Seiring dengan kemajuan teknologi kecerdasan buatan, penelitian ini mengusulkan solusi klasifikasi sampah otomatis melalui sistem deteksi cerdas berantarmuka visual berbasis *Deep Learning*. Penelitian ini membandingkan kinerja tiga arsitektur *Convolutional Neural Network* (CNN), yaitu VGG-16, ResNet50, dan DenseNet121, dengan mengimplementasikan teknik *fine-tuning* guna menghasilkan model klasifikasi sampah non-organik yang paling optimal. Hasil penelitian menunjukkan bahwa arsitektur DenseNet121 merupakan model yang paling unggul dengan tingkat akurasi validasi mencapai 93%. Keterbatasan kuantitas dan variasi dataset teridentifikasi sebagai faktor yang membuat arsitektur lainnya menjadi kurang optimal. Implementasi sistem ini diharapkan dapat diaplikasikan pada tempat sampah umum maupun fasilitas industri guna meningkatkan akurasi pemilahan sampah, menekan biaya operasional, serta mendukung pembangunan berkelanjutan.

Kata kunci: Klasifikasi Sampah, Convolutional Neural Network (CNN), VGG-16, ResNet50, DenseNet121.

CLASSIFICATION OF NON-ORGANIC WASTE USING VGG-16, RESNET50, AND DENSENET121 ARCHITECTURES

Abstract

Global population growth has triggered a surge in solid waste production, including in Indonesia, where the majority of waste ends up in landfills without proper sorting. The lack of public understanding and awareness regarding waste classification, particularly non-organic waste, results in suboptimal management and provokes negative impacts on the environment and public health. Along with the advancement of artificial intelligence technology, this study proposes an automated waste classification solution through a smart detection system with a visual interface based on *Deep Learning*. This study compares the performance of three *Convolutional Neural Network* (CNN) architectures, namely VGG-16, ResNet50, and DenseNet121, by implementing *fine-tuning* techniques to produce the most optimal non-organic waste classification model. The results show that the DenseNet121 architecture is the superior model, achieving a validation accuracy of 93%. The limitations in dataset quantity and variety were identified as factors contributing to the suboptimal performance of the other architectures. The implementation of this system is expected to be applied to public waste bins and industrial facilities to improve waste sorting accuracy, reduce operational costs, and support sustainable development.

Keywords: Waste Classification, Convolutional Neural Network (CNN), VGG-16, ResNet50, DenseNet121.

1. PENDAHULUAN

Pertumbuhan populasi dunia yang signifikan, merupakan salah satu tantangan global yang dihadapi. Dimana pada tahun 2030 pertumbuhan populasi dunia diperkirakan akan mencapai 8,6 miliar (Calicioglu *et al.*, 2019). Dampak yang ditimbulkan

bukan hanya pada masalah ketersediaan pangan, melainkan pada penipisan sumber daya yang tidak dapat diperbarui serta memburuknya lingkungan ekologis (Wang *et al.*, 2024).

Masalah lain yang ditimbulkan akibat dari bertambahnya populasi yakni produksi sampah yang

meningkat pesat pula. Produksi sampah padat global diperkirakan mencapai 1,3 miliar ton per tahun. Dimana pada tahun 2030, produksi sampah diperkirakan akan meningkat sekitar 2,2 miliar ton per tahun (Al-Dailami *et al.*, 2025). Indonesia adalah negara dengan penduduk terbanyak ke-4 di dunia yang menghasilkan sampah sekitar 35,31 juta ton per tahun (*Sistem Informasi Kinerja Pengelolaan Sampah Nasional*, 2026). Sebagian besar sampah yang dihasilkan di kota/kabupaten langsung dibuang ke TPA tanpa melalui proses pemilahan terlebih dahulu. Sebanyak 75% sampah atau sekitar 109.092 ton per hari yang belum terkelola.

Dengan adanya berbagai peraturan terkait pengelolaan sampah berbasis sumber, masyarakat didorong untuk melakukan pemilahan sampah secara mandiri ke dalam beberapa kategori sebelum dibuang ke TPA. Namun, kurangnya pengetahuan masyarakat mengenai klasifikasi sampah serta standar klasifikasi yang kompleks merupakan suatu kondisi yang harus mendapatkan perhatian penting. Banyak masyarakat yang belum memahami perbedaan antara sampah organik, anorganik, residu maupun sampah berbahaya, sehingga sampah sering dibuang secara bercampur tanpa melalui proses pemilahan terlebih dahulu.

Kurangnya kesadaran masyarakat terkait pemilahan sampah, khususnya sampah non-organik menyebabkan proses pengelolaan sampah menjadi kurang optimal serta meningkatkan volume sampah yang harus ditampung di TPA. Tidak jarang beberapa TPA memilih untuk melakukan pembakaran sampah, khususnya sampah non-organik yang sangat beragam. Dampak yang ditimbulkan akibat pembakaran sampah tidak hanya terhadap lingkungan tetapi juga berdampak pada kesehatan. Oleh karena itu, perlu dilakukan klasifikasi yang efektif khususnya pada sampah non-organik, yang juga bermanfaat bagi pembangunan berkelanjutan antara ekonomi dan lingkungan (Soni *et al.*, 2022).

Dengan perkembangan teknologi yang sangat pesat, khususnya pada bidang kecerdasan buatan dan peningkatan kemampuan komputasi komputer, teknologi pengenalan gambar mengalami kemajuan yang signifikan sehingga membuka peluang baru dalam proses pengklasifikasian objek secara otomatis dan lebih akurat.

Klasifikasi gambar merupakan salah satu bidang dalam *computer vision* yang mengalami perkembangan pesat seiring dengan kemajuan teknologi *Deep Learning* (DL) dan peningkatan kemampuan komputasi modern. *Convolutional Neural Network* (CNN) merupakan salah satu teknik *deep learning* yang banyak digunakan untuk memproses data berupa gambar (Yann and Yoshua, 1995). Banyak metode yang berbeda disajikan untuk meningkatkan akurasi dan efektivitas klasifikasi gambar.


Pesatnya perkembangan *deep learning*, khususnya arsitektur *Convolutional Neural Network*

(CNN), telah memicu berbagai penelitian klasifikasi citra sampah menggunakan beragam algoritma. Artikel ini membandingkan tiga arsitektur utama, yaitu VGG-16, ResNet50, dan DenseNet121, dengan menerapkan beberapa teknik *fine-tuning* untuk menghasilkan model yang optimal dalam mengklasifikasikan sampah non-organik. Ketiga arsitektur tersebut dipilih karena kinerjanya yang unggul dalam pengenalan citra (Risniyati and Luthfiarta, 2021; Susanti, Soleh and Sartono, 2023; Zahra *et al.*, 2025), sehingga diharapkan dapat menjadi solusi efektif untuk mendeteksi dan mengklasifikasikan sampah non-organik.

Dengan menggabungkan model *deep learning* dan antarmuka visual, diharapkan bisa menciptakan sistem deteksi sampah yang cerdas. Sistem ini sangat fleksibel untuk dipasang langsung di tempat sampah umum maupun di pusat pengolahan sampah industri. Keunggulannya, biaya operasional jadi jauh lebih murah dan pemilahan sampah menjadi lebih akurat, yang tentunya berdampak positif bagi kebersihan lingkungan.

2. METODE

Metodologi yang digunakan dalam penelitian ini secara lebih detail dapat dilihat pada Gambar 1. Dimana penelitian ini dimulai dari pengumpulan dataset, *preprocessing data*, pembuatan model, pelatihan dan pengujian serta evaluasi model.



Gambar 1. Alur Penelitian

Dimana di awal penelitian dilakukan pengumpulan data yang akan digunakan dalam penelitian ini. Untuk dataset yang digunakan bersumber dari TrashNet. Dimana TrashNet merupakan dataset publik di bidang klasifikasi sampah yang dibuat oleh (Yang and Thung, 2016) yang berasal dari Stanford University pada tahun 2016.

Tahap selanjutnya adalah *preprocessing data* yang diawali dengan *resize* agar ukuran citra menjadi seragam dan sesuai dengan *input size* yang direkomendasikan untuk ketiga arsitektur yang akan digunakan. Setelah proses *resize*, selanjutnya dilakukan teknik augmentasi untuk memperbanyak

data citra serta membuat data pada masing – masing kelas menjadi jumlah yang sama. Untuk teknik augmentasi yang dilakukan yakni rotasi, penggeseran gambar secara vertikal dan horizontal, zoom, dan pembalikan serta menerapkan *fill mode* untuk mengisi kekosongan pixel yang muncul setelah gambar dimanipulasi. Teknik augmentasi bertujuan untuk meningkatkan jumlah dataset. Tahap terakhir dari *preprocessing* adalah pembagian data, dimana dataset dibagi menjadi dua bagian yakni 70% data pelatihan dan 30% data validasi.

Tahapan selanjutnya yakni membangun model dimana pada penelitian ini menggunakan pendekatan pembelajaran mendalam *Convolutional Neural Network* (CNN), dengan tiga arsitektur yang berbeda diantaranya arsitektur VGG-16, ResNet-50, dan DenseNet121. Ketiga arsitektur diatas dilakukan penyesuaian *hyperparameter* untuk mengontrol proses *training* model. *Hyperparameter* yang diatur diantaranya *epoch*, *batch size*, *optimizer* dan *learning rate*. Selain itu lapisan tambahan diberikan jumlah neuron dan fungsi aktivasi sesuai dengan kebutuhan klasifikasi data dalam proses *training*.

Proses *training* dan *testing* dilakukan dilakukan dengan data yang sudah dipisahkan sebelumnya. Dimana proses *training* data dilakukan dengan menggunakan tiga arsitektur dan menghasilkan data yang selanjutnya digunakan untuk perhitungan akurasi dan *loss* yang nantinya akan menghasilkan model yang paling optimal pada tiap arsitektur. Selanjutnya model yang paling optimal pada tiap arsitektur akan dilakukan *testing* dengan data *testing* dengan tujuan untuk mengetahui kemampuan model pada tiap arsitektur terhadap data baru yang tidak pernah dilihat sebelumnya.

Tahap terakhir pada penelitian ini adalah evaluasi model. Tujuan dilakukannya evaluasi model pada penelitian ini adalah untuk menilai kinerja tiap model pada ketiga arsitektur dalam melakukan klasifikasi sampah non-organik. Pengujian dilakukan menggunakan *confusion matrix* sebagai salah satu metode untuk memperoleh nilai akurasi dari proses klasifikasi yang dilakukan pada dataset. Sebuah matriks dari hasil prediksi akan dibandingkan dengan kelas sebenarnya. Ilustrasi dari *confusion matrix* multikelas dan rumus *metrics* yang digunakan adalah sebagai berikut (Grandini, Bagli and Visani, 2008).

		Predicted Number			
		Class 1	Class 2	...	Class <i>n</i>
Actual Number	Class 1	x_{11}	x_{12}	...	x_{1n}
	Class 2	x_{21}	x_{22}	...	x_{2n}
	.	.	.	.	.
	.	.	.	.	.
	Class <i>n</i>	x_{n1}	x_{n2}	...	x_{nn}

Gambar 2. *Confusion Matrix* Multikelas

Gambar 2, menampilkan contoh dari *confusion matrix* yang digunakan untuk melakukan klasifikasi multikelas. Dimana *confusion matrix* digunakan

untuk memvisualisasikan kesalahan klasifikasi secara lebih spesifik. Selain itu untuk menilai kinerja model digunakan juga metrik akurasi yang merupakan metrik dasar untuk mengukur seberapa sering model memprediksi kelas yang benar (Eli *et al.*, 2025). Persamaan 1 merupakan persamaan yang digunakan dalam menentukan akurasi adalah sebagai berikut :

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Keterangan :

TP (*True Positive*) = prediksi yang benar sebagai kelas positif.

TN (*True Negative*) = prediksi yang benar sebagai kelas negatif.

FP (*False Positive*) = prediksi yang salah sebagai kelas positif.

FN (*False Negative*) = prediksi yang salah sebagai kelas negatif.

Selanjutnya digunakan juga *precision* dan *recall* untuk evaluasi model. Dimana *precision* digunakan untuk mengukur kemampuan model dalam melakukan prediksi data yang benar dari seluruh prediksi yang dilakukan. Sedangkan *recall* digunakan untuk mengukur kemampuan model dalam menentukan kelas data prediksi yang sebenarnya. Untuk perhitungan keduanya menggunakan persamaan 2 dan 3 berikut :

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

Untuk memberikan gambaran yang lebih seimbang mengenai kinerja model, digunakan *F1-Score*. Dimana *F1-Score* menggabungkan nilai dari *precision* dan *recall* menjadi nilai tunggal. Untuk perhitungan *F1-Score* menggunakan persamaan 4 berikut :

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision+Recall} \quad (4)$$

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Dataset yang digunakan dalam penelitian ini adalah dataset dari TrashNet diperoleh dari situs *Kaggle.com*, yang dapat diakses melalui <https://www.kaggle.com/datasets/feyzazkefe/trashnet/data>. Dataset tersebut merupakan dataset yang belum melalui proses pengolahan. Berikut adalah

beberapa contoh gambar mentah yang diperoleh dari dataset TrashNet :



Gambar 3. Sampel Citra Dataset

3.2 Preprocessing Data

Dataset yang sudah dikumpulkan kemudian dilakukan penyesuaian ukuran, dimana sebelumnya gambar berukuran 512 x 385 pixel disesuaikan ke dalam ukuran 224 x 224 pixel. Hal ini bertujuan untuk menyesuaikan ukuran input yang dimiliki oleh arsitektur CNN yang akan digunakan. Selain itu, penyesuaian ukuran dilakukan agar semua gambar yang akan diproses memiliki dimensi yang konsisten.

Setelah semua gambar memiliki ukuran input yang sama, dilakukan *augmentasi* dengan tujuan untuk memperbanyak variasi data pelatihan tanpa harus menambah jumlah data secara langsung. Pada penelitian ini menggunakan empat teknik transformasi geometris, meliputi rotasi acak hingga ± 30 derajat, translasi secara horizontal dan vertikal masing – masing 20% dari dimensi citra, pembesaran atau pengecilan hingga 20%, serta pembalikan citra secara horizontal. Selain itu digunakan juga metode nearest-neighbor untuk mengisi area kosong yang dihasilkan dari transformasi. Proses *augmentasi* ini meningkatkan jumlah dataset menjadi 1000 gambar per kelas. Sehingga jumlah data keseluruhan yang digunakan dalam penelitian ini sebanyak 500 data. Dimana dari data tersebut akan dilakukan pembagian data dengan rasio 70% data latih, dan 30% untuk data validasi. Sedangkan untuk data uji akan digunakan data yang berbeda, namun masih bersumber dari dataset yang sama. Untuk detail pembagian data serta jumlah kelas dapat dilihat pada tabel berikut.

Tabel 1. Detail Kelas dan Jumlah Data

	Data Training (70%)	Data Validasi (30%)
Cardboard	700	300
Glass	700	300
Metal	700	300
Paper	700	300
Plastic	700	300

3.3 Pembangunan Model

Pada penelitian ini menggunakan tiga model *pre-train* VGG-16, ResNet-50 dan DenseNet121 yang sudah dilatih sebelumnya menggunakan *weight* dari dataset *ImageNet* atau yang disebut dengan teknik *Transfer Learning*. Sebelum ketiga model dilatih dilakukan *fine-tuning* atau penyesuaian parameter agar dapat meningkatkan kinerja dan akurasi dari ketiga model. Berikut merupakan *model summary* dari ketiga arsitektur usulan yang digunakan pada penelitian ini.

Blok / Lapisan	Komponen Lapisan	Dimensi Keluaran	Jumlah Parameter
Input	Input Layer	224 × 224 × 3	0
Block 1	2 × Conv2D, 1 × MaxPooling	112 × 112 × 64	38.720
Block 2	2 × Conv2D, 1 × MaxPooling	56 × 56 × 128	221.440
Block 3	3 × Conv2D, 1 × MaxPooling	28 × 28 × 256	1.475.328
Block 4	3 × Conv2D, 1 × MaxPooling	14 × 14 × 512	5.899.776
Block 5	3 × Conv2D, 1 × MaxPooling	7 × 7 × 512	7.079.424
Flatten	Flatten Layer	25.088	0
Classifier 1	Dense (256 neuron) + Dropout	256	6.422.784
Output	Dense (5 neuron)	5	1.285
Total Parameter			21.138.757

Gambar 4. Summary Model VGG-16

Gambar 4 merupakan arsitektur pada model VGG16. Model ini bekerja secara bertahap untuk mengekstraksi gambar. Input yang digunakan berupa gambar berukuran 224×224 piksel dengan 3 saluran warna (RGB). Model ini memiliki 5 blok konvolusi, di mana jumlah *filter* terus meningkat di setiap blok untuk menangkap detail gambar. Setiap akhir blok menggunakan lapisan *max pooling* untuk memperkecil ukuran data secara spasial. Setelah melewati semua blok ekstraksi, data gambar yang berbentuk matriks diratakan (*flatten*) menjadi satu baris vektor. Data tersebut kemudian disalurkan ke lapisan *fully connected* yang dilengkapi dengan *dropout*, sebelum akhirnya ditentukan hasilnya ke dalam 5 kelas tujuan.

Blok / Stage	Operasi Utama	Dimensi Keluaran	Jumlah Parameter
Input	Input Layer	224 × 224 × 3	0
Conv1	Conv2D + BatchNorm	112 × 112 × 64	9.728
Conv2_x	3 Residual Blocks	56 × 56 × 256	215.808
Conv3_x	4 Residual Blocks	28 × 28 × 512	1.216.512
Conv4_x	6 Residual Blocks	14 × 14 × 1024	7.082.496
Conv5_x	3 Residual Blocks	7 × 7 × 2048	6.131.840
Global Avg Pool	GlobalAveragePooling2D	2.048	0
Classifier	Dense (256) + Dropout	256	524.544
Output	Dense (5)	5	1.285
Total Parameter			24.113.541

Gambar 5. Summary Model ResNet-50

Gambar 5 merupakan struktur model ResNet50. ResNet50 memiliki blok residual yang dilengkapi dengan *shortcut connections*. *Shortcut connections* ini berfungsi mengirimkan informasi dari lapisan awal langsung ke lapisan akhir untuk mencegah hilangnya informasi penting (*vanishing gradient*) akibat jaringan yang terlalu dalam. Proses dimulai dengan memasukkan gambar berukuran 224×224 piksel (RGB) melalui lapisan konvolusi awal dan *max pooling*. Selanjutnya, model terbagi menjadi 4 tahap blok utama dengan ukuran penyaring yang semakin besar. Di akhir jaringan, model menggunakan *global average pooling* untuk merangkum seluruh fitur

gambar menjadi vektor ringkas, lalu diteruskan ke lapisan klasifikasi dengan 256 neuron dan *dropout*.

Tahap / Bagian	Komponen Utama	Dimensi Keluaran	Jumlah Parameter
Input	Input Layer	$224 \times 224 \times 3$	0
Awal (Conv1)	Conv2D (7×7) + Pool	$56 \times 56 \times 64$	9.664
Dense Block 1	6 × Lapisan Bottleneck	$56 \times 56 \times 256$	~158.000
Transition 1	Conv2D (1×1) + AvgPool	$28 \times 28 \times 128$	33.792
Dense Block 2	12 × Lapisan Bottleneck	$28 \times 28 \times 512$	~600.000
Transition 2	Conv2D (1×1) + AvgPool	$14 \times 14 \times 256$	133.120
Dense Block 3	24 × Lapisan Bottleneck	$14 \times 14 \times 1.024$	~2.500.000
Transition 3	Conv2D (1×1) + AvgPool	$7 \times 7 \times 512$	528.384
Dense Block 4	16 × Lapisan Bottleneck	$7 \times 7 \times 1.024$	~3.000.000
Pooling Akhir	BatchNorm + Global Avg Pool	1.024	4.096
Classifier	Dense (256 neuron) + Dropout	256	262.400
Output	Dense (5 neuron)	5	1.285
Total Parameter			7.301.189


Gambar 6. Summary Model DenseNet121

Gambar 6 merupakan struktur model DenseNet-121. Keunggulan model ini terletak pada efisiensinya karena menggunakan sistem koneksi padat (*Dense Blocks*). Melalui lapisan penggabungan (*Concatenate*), setiap lapisan dalam blok ini saling berbagi informasi dan menerima masukan dari semua lapisan sebelumnya secara akumulatif. Setelah melewati lapisan awal dengan input citra 224×224 piksel (RGB), model masuk ke dalam 4 tingkatan *Dense Blocks*. Di antara blok-blok tersebut, terdapat lapisan transisi (*Transition Layers*) untuk mengontrol dan mengecilkan ukuran data. Fitur yang terkumpul di akhir jaringan dirangkum menggunakan *global average pooling*, lalu diproses oleh 256 neuron dengan *dropout* untuk klasifikasi pada 5 kelas.

3.4. Training dan Testing Model


Pelatihan pada ketiga model dikompilasi dengan *optimizer* Adam, fungsi *loss*, dan metrik akurasi. Proses pelatihan dilakukan pada 16 *batch* selama 30 *epoch* menggunakan data pelatihan dan pengujian. Untuk menentukan model optimal dari tiap arsitektur, digunakan nilai *loss* pada validation sebagai indikatornya. Penggunaan nilai validation *loss* sebagai indikator utama dalam menentukan arsitektur model optimal, karena mencerminkan kemampuan generalisasi model terhadap data baru. Titik konvergensi yang paling optimal ditunjukkan pada *epoch* dimana nilai validation *loss* paling minimum, yang menunjukkan model telah mencapai batas maksimum dalam memperlajari fitur – fitur dalam citra. Hasil yang diperoleh untuk masing – masing model adalah sebagai berikut.

Model VGG-16 memperoleh akurasi validasi hingga 78% dengan nilai *loss* 0,6639. Detail grafik akurasi dan *loss* dapat dilihat pada gambar 7 berikut.




Gambar 7. Grafik Akurasi dan Loss VGG-16

Model ResNet-50 memperoleh akurasi validasi sebesar 44% dengan nilai *loss* 1,2826. Detail grafik akurasi dan *loss* dapat dilihat pada gambar 8 berikut.



Gambar 8. Grafik Akurasi dan Loss ResNet-50

Model DenseNet121 memperoleh akurasi validasi mencapai 93% dengan nilai *loss* 0,2944. Detail grafik akurasi dan *loss* dapat dilihat pada gambar 9 berikut.




Gambar 9. Grafik Akurasi dan Loss DenseNet121

Tabel 2. Ringkasan Kinerja Model pada Tahap Pelatihan dan Validasi

Model	Akurasi Validasi	Loss Validasi
VGG-16	78%	0,6639
ResNet-50	44%	1,2826
DenseNet121	93%	0,2944

Setelah dilakukan proses pelatihan, pada masing – masing arsitektur diperoleh model yang paling optimal yang kemudian disimpan dalam format h5. Selanjutnya model tersebut digunakan kembali pada tahap pengujian. Dimana data yang diuji merupakan data yang belum pernah digunakan pada data pelatihan maupun validasi. Berikut hasil pengujian yang diperoleh pada masing – masing model.




Gambar 10. Hasil Pengujian Ketiga Model

Berdasarkan gambar diatas dapat dilihat bahwa, ketiga model dapat memprediksi gambar dengan tepat, dengan *confidence score* yang beragam. Pada gambar kedua yang memiliki latar belakang natural dan objek bertekstur tipis, sebuah gambar yang berbeda dari data pelatihan yang diberikan. Pada pengujian citra ini, tingkat keyakinan *confidence score* tertinggi diperoleh pada model DenseNet-121, sementara ResNet50 memperoleh *confidence score* terendah. Hasil ini menunjukkan bahwa ResNet50 kesulitan dalam mengekstrak detail objek yang kurang tajam. Di sisi lain, DenseNet-121 berhasil mengatasi tantangan kelengkapan fitur tersebut karena mengimplementasikan koneksi *feature concatenation* yang mengalirkan informasi dari lapisan paling awal hingga akhir.

3.5. Evaluasi Model

Berikut pada gambar 11 dibawah ini merupakan hasil analisis dari *confusion matrix* model optimal pada model VGG-16.



Gambar 11. *Confusion Matrix* VGG-16

Berdasarkan gambar 11, dari total 350 data gambar yang diinput, model berhasil mengklasifikasikan dengan cukup baik. Hasil prediksi menunjukkan bahwa:


1. Pada kelas “cardboard” dari total 350 data berhasil mengklasifikasikan 228 dengan benar, dan 122 data yang salah klasifikasi.
2. Pada kelas “glass” dari total 350 data berhasil mengklasifikasikan 234 dengan benar, dan 116 data yang salah klasifikasi.
3. Pada kelas “metal” dari total 350 data berhasil mengklasifikasikan 202 dengan benar, dan 148 data yang salah klasifikasi.
4. Pada kelas “paper” dari total 350 data berhasil mengklasifikasikan 271 dengan benar, dan 79 data yang salah klasifikasi.
5. Pada kelas “plastic” dari total 350 data berhasil mengklasifikasikan 237 dengan benar, dan 113 data yang salah klasifikasi

Berdasarkan *confusion matrix* tersebut diperoleh nilai *classification report* berikut.

	precision	recall	f1-score	support
cardboard	0.95	0.76	0.85	300
glass	0.70	0.78	0.74	300
metal	0.85	0.67	0.75	300
paper	0.74	0.90	0.82	300
plastic	0.73	0.79	0.76	300
accuracy			0.78	1500
macro avg	0.80	0.78	0.78	1500
weighted avg	0.80	0.78	0.78	1500

Gambar 12. *Classification Report* VGG-16

Berikut pada gambar 13 dibawah ini merupakan hasil analisis dari *confusion matrix* model optimal pada model ResNet50.



Gambar 13. *Confusion Matrix* ResNet50

Berdasarkan gambar 13, dari total 350 data gambar yang diinput, model berhasil mengklasifikasikan dengan cukup baik. Hasil prediksi menunjukkan bahwa:


1. Pada kelas “cardboard” dari total 350 data berhasil mengklasifikasikan 150 dengan benar, dan 200 data yang salah klasifikasi.
2. Pada kelas “glass” dari total 350 data berhasil mengklasifikasikan 183 dengan benar, dan 167 data yang salah klasifikasi.
3. Pada kelas “metal” dari total 350 data berhasil mengklasifikasikan 82 dengan benar, dan 268 data yang salah klasifikasi.
4. Pada kelas “paper” dari total 350 data berhasil mengklasifikasikan 252 dengan benar, dan 98 data yang salah klasifikasi.
5. Pada kelas “plastic” dari total 350 data berhasil mengklasifikasikan 0 dengan benar, dan 350 data yang salah klasifikasi

Berdasarkan *confusion matrix* tersebut diperoleh nilai *classification report* berikut.

	precision	recall	f1-score	support
cardboard	0.84	0.50	0.63	300
glass	0.32	0.61	0.42	300
metal	0.66	0.27	0.39	300
paper	0.40	0.84	0.54	300
plastic	0.00	0.00	0.00	300
accuracy			0.44	1500
macro avg	0.44	0.44	0.40	1500
weighted avg	0.44	0.44	0.40	1500

Gambar 14. Classification Report ResNet50

Berikut pada gambar 15 dibawah ini merupakan hasil analisis dari *confusion matrix* model optimal pada model DenseNet121.



Gambar 15. Confusion Matrix DenseNet121

Berdasarkan gambar 15, dari total 350 data gambar yang diinput, model berhasil mengklasifikasikan dengan cukup baik. Hasil prediksi menunjukkan bahwa:

1. Pada kelas “cardboard” dari total 350 data berhasil mengklasifikasikan 286 dengan benar, dan 64 data yang salah klasifikasi.
2. Pada kelas “glass” dari total 350 data berhasil mengklasifikasikan 252 dengan benar, dan 98 data yang salah klasifikasi.
3. Pada kelas “metal” dari total 350 data berhasil mengklasifikasikan 288 dengan benar, dan 62 data yang salah klasifikasi.
4. Pada kelas “paper” dari total 350 data berhasil mengklasifikasikan 285 dengan benar, dan 65 data yang salah klasifikasi.
5. Pada kelas “plastic” dari total 350 data berhasil mengklasifikasikan 281 dengan benar, dan 69 data yang salah klasifikasi.

Berdasarkan *confusion matrix* tersebut diperoleh nilai *classification report* seperti terlihat pada Gambar 16 berikut.

	precision	recall	f1-score	support
cardboard	0.97	0.95	0.96	300
glass	0.93	0.84	0.88	300
metal	0.92	0.96	0.94	300
paper	0.96	0.95	0.95	300
plastic	0.87	0.94	0.90	300
accuracy			0.93	1500
macro avg	0.93	0.93	0.93	1500
weighted avg	0.93	0.93	0.93	1500

Gambar 16. Classification Report DenseNet121

4. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, dapat disimpulkan bahwa model dengan kinerja yang paling optimal dalam melakukan klasifikasi terhadap sampah non-organik adalah model pada arsitektur DenseNet121 dengan akurasi validasi mencapai 93%. Hal ini menunjukkan bahwa setiap arsitektur memiliki ciri khas yang harus disesuaikan dengan karakteristik gambar yang akan diolah. Namun, tidak menutup kemungkinan untuk dilakukan *fine-tuning* dan penyesuaian *hyperparameter* pada tiap arsitektur agar dapat menyesuaikan diri dengan gambar yang akan dilatih. Selain itu, dataset yang terbatas serta variasi data yang kurang beragam juga membuat arsitektur lain kurang optimal dalam melakukan pembelajaran terhadap data.

Saran untuk penelitian selanjutnya, diharapkan dapat menambah jumlah *epoch*, serta penggunaan *batch size* yang lebih besar. Dataset yang digunakan juga diperluas baik dari jumlah data maupun variasi data. Sehingga model dapat lebih optimal dalam mempelajari dataset khususnya dalam melakukan klasifikasi terhadap sampah non-organik. Diharapkan juga melakukan perbandingan terhadap arsitektur lain selain ketiga model yang digunakan dalam penelitian ini.

5. DAFTAR PUSTAKA

- AL-DAILAMI, A. *ET AL.* (2025) ‘Sustainable solid waste management in Yemen: environmental, social aspects, and challenges’, *Biomass Conversion and Biorefinery* [Preprint]. Available at: <https://doi.org/https://doi.org/10.1007/s13399-022-02871-w>.
- CALICIOGLU, O. *ET AL.* (2019) ‘The future challenges of food and agriculture: An integrated analysis of trends and solutions’, *Sustainability (Switzerland)*, 11(1). Available at: <https://doi.org/10.3390/su11010222>.
- ELÍ, E. *ET AL.* (2025) ‘Stratified Sampling Algorithms for Machine Learning Methods in Solving Two-scale Partial Differential Equations’, *Journal of Scientific Computing*, 104(3), pp. 1–40. Available at: <https://doi.org/10.1007/s10915-025-03024-7>.

- GRANDINI, M., BAGLI, E. AND VISANI, G. (2008) 'Metrics For Multi-Class Classification: An Overview'. Available at: <https://doi.org/10.48550>.
- RISMIYATI, R. AND LUTHFIARTA, A. (2021) 'VGG16 Transfer Learning Architecture for Salak Fruit Quality Classification', *Telematika*, 18(1), p. 37. Available at: <https://doi.org/10.31315/telematika.v18i1.4025>.
- SISTEM INFORMASI KINERJA PENGELOLAAN SAMPAH NASIONAL (2026). Available at: <https://sampahnasional.kemenlh.go.id/>.
- SONI, A. ET AL. (2022) 'Challenges and opportunities of utilizing municipal solid waste as alternative building materials for sustainable development goals: A review', *Sustainable Chemistry and Pharmacy*, 27. Available at: <https://doi.org/https://doi.org/10.1016/j.scp.2022.100706>.
- SUSANTI, L.A., SOLEH, A.M. AND SARTONO, B. (2023) 'Deep Learning Image Classification Rontgen Dada pada Kasus Covid-19 Menggunakan Algoritma Convolutional Neural Network', *Jurnal Teknologi Informasi dan Ilmu Komputer*, 10(5), pp. 973–982. Available at: <https://doi.org/10.25126/jtiik.20231057142>.
- WANG, A. ET AL. (2024) 'The key to sustainability: In-depth investigation of environmental quality in G20 countries through the lens of renewable energy, economic complexity and geopolitical risk resilience', *Journal of Environmental Management*, Volume 352(120045). Available at: <https://doi.org/https://doi.org/10.1016/j.jenvman.2024.120045>.
- YANG, M. AND THUNG, G. (2016) 'Classification of Trash for Recyclability Status', pp. 1–6.
- YANN, L. AND YOSHUA, B. (1995) 'Convolutional Networks for Images, Speech, and Time-Series', *The handbook of brain theory and neural networks*, pp. 255–258. Available at: https://www.researchgate.net/profile/Yann_Lecun/publication/2453996_Convolutional_Networks_for_Images_Speech_and_Time_Series/links/0deec519dfa2325502000000.pdf?0Ahttps://www.researchgate.net/profile/Yann_Lecun/publication/2453996_Convolutional_Networks_fo.
- ZAHRA, A.L. ET AL. (2025) 'Implementasi Arsitektur CNN DenseNet-121 untuk Identifikasi Autoimun Kulit dengan Augmentasi Data', 5.