

KLASIFIKASI SAMPAH MENGGUNAKAN CNN DENGAN ARSITEKTUR MOBILENETV4 DAN TRANSFER LEARNING

Patrisius Satria Hendrawan, Dedy Hermanto

Informatika, Universitas Multi Data Palembang

Jalan Rajawali No.14 Palembang Indonesia

patriussatriahendrawan_2226250033@mhs.mdp.ac.id

ABSTRAK

Pengelolaan sampah yang efektif menjadi tantangan utama di Indonesia, mengingat volume timbunan sampah nasional terus meningkat setiap tahunnya. Proses pemilahan sampah yang masih dilakukan secara manual dinilai kurang efisien dan rentan terhadap kesalahan klasifikasi. Penelitian ini bertujuan mengembangkan sistem klasifikasi sampah otomatis berbasis citra digital yang efisien dan akurat menggunakan arsitektur MobileNetV4 dengan pendekatan *Transfer Learning*. Model dievaluasi menggunakan tiga varian arsitektur, yaitu *Small*, *Medium*, dan *Large*. Dataset publik dari Kaggle yang terdiri dari 10 kategori dan 20.218 citra diproses melalui pra-pemrosesan, augmentasi data, serta penerapan *class weighting* untuk menangani ketidakseimbangan data antar kelas. Kinerja model diukur menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*. Hasil pengujian menunjukkan bahwa varian MobileNetV4-*Small* dan *Medium* berhasil mencapai tingkat akurasi tertinggi yang setara, yaitu 81%, sedangkan varian *Large* mengalami penurunan performa menjadi 74% akibat *overfitting*. Berdasarkan hasil tersebut, MobileNetV4-*Small* disimpulkan sebagai model paling optimal karena mampu mempertahankan performa klasifikasi yang baik dengan kapasitas parameter yang lebih sedikit, sehingga sangat efisien untuk diterapkan pada sistem sortasi sampah bersumber daya komputasi terbatas.

Kata kunci : Sampah, MobileNetV4, Transfer Learning

1. PENDAHULUAN

Indonesia merupakan salah satu negara dengan volume produksi sampah rumah tangga yang cukup besar di Asia Tenggara. Berdasarkan data dari Sistem Informasi Pengelolaan Sampah Nasional (SIPSN), volume timbunan sampah nasional pada tahun 2024 mencapai lebih dari 33,7 juta ton, dengan mayoritas berasal dari rumah tangga dan kawasan komersial [1]. Dalam menghadapi tantangan pengelolaan sampah, klasifikasi dan pemilahan sampah sejak dini menjadi langkah penting untuk mendukung daur ulang dan ekonomi sirkular. Proses sortir sampah masih dilakukan secara manual dan subjektif, yang tidak efisien serta berpotensi terjadi kesalahan klasifikasi (Rizki et al., 2023). Kondisi ini mendorong kebutuhan akan sistem klasifikasi sampah yang otomatis, akurat, dan dapat diandalkan.

Di era industri 4.0, pendekatan *computer vision* dan *machine learning* telah mendorong pemanfaatan metode *Convolutional Neural Network* (CNN) untuk otomatisasi klasifikasi sampah berbasis citra digital. Meskipun mampu menghasilkan akurasi tinggi, CNN konvensional masih menghadapi tantangan berupa kebutuhan komputasi yang besar dan risiko *overfitting* pada dataset terbatas. Untuk mengatasi hal tersebut, arsitektur *lightweight CNN* seperti MobileNetV4 dikembangkan untuk mencapai keseimbangan antara akurasi dan efisiensi komputasi [2]. Selain itu, pendekatan *Transfer Learning* terbukti efektif dalam kondisi data pelatihan terbatas dengan memanfaatkan fitur yang telah dipelajari dari dataset berskala besar seperti ImageNet, sekaligus mempercepat konvergensi dan mengurangi risiko *overfitting* [3].

Berdasarkan uraian tersebut, penelitian ini bertujuan menganalisis performa arsitektur MobileNetV4 dalam tugas klasifikasi sampah berbasis citra melalui pendekatan *Transfer Learning*, serta menentukan varian arsitektur yang paling optimal dari sisi akurasi maupun efisiensi komputasi. Dataset yang digunakan merupakan dataset publik Kaggle “*Garbage Dataset: A Comprehensive Image Dataset for Garbage Classification and Recycling*” yang terdiri dari 20.218 citra dengan 10 kelas, yaitu *Metal*, *Glass*, *Biological*, *Paper*, *Battery*, *Trash*, *Cardboard*, *Shoes*, *Clothes*, dan *Plastic*. Penelitian menggunakan tiga varian model MobileNetV4, yaitu MobileNetV4-*Small*, MobileNetV4-*Medium*, dan MobileNetV4-*Large* dengan bobot awal (*pretrained weights*) dari ImageNet. Untuk meningkatkan kemampuan generalisasi model, diterapkan teknik augmentasi data berupa rotasi, *flipping*, *zoom*, dan *brightness adjustment*, serta penerapan *class weighting* untuk menangani ketidakseimbangan data antar kelas. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Hasil penelitian diharapkan dapat berkontribusi pada pengembangan sistem sortasi sampah otomatis yang efisien dan menjadi referensi bagi penelitian selanjutnya di bidang pengelolaan sampah berbasis kecerdasan buatan.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Penelitian klasifikasi sampah berbasis citra banyak memanfaatkan pendekatan *Transfer Learning* untuk meningkatkan performa model pada dataset yang terbatas. Penelitian dari [3] menunjukkan bahwa

Transfer Learning mampu menghasilkan performa yang kompetitif dibandingkan pelatihan dari awal (*training from scratch*), sekaligus mempercepat konvergensi dan mengurangi risiko *overfitting*.

Di sisi lain, penelitian [4] memperkenalkan MobileNetV4 sebagai arsitektur *lightweight CNN* yang menggunakan pendekatan *Neural Architecture Search* (NAS) dengan blok *Universal Inverted Bottleneck* (UIB) dan *Mobile Multi-Query Attention* (MQA) untuk mencapai keseimbangan antara akurasi dan efisiensi komputasi. Efektivitas MobileNetV4 juga dibuktikan oleh penelitian [2] pada klasifikasi penyakit daun jagung dengan akurasi tinggi dan kebutuhan komputasi yang lebih rendah dibandingkan arsitektur CNN yang lebih kompleks.

Berdasarkan penelitian terdahulu tersebut, MobileNetV4 dan *Transfer Learning* memiliki potensi yang baik untuk diterapkan pada klasifikasi sampah berbasis citra. Oleh karena itu, penelitian ini mengimplementasikan kedua pendekatan tersebut untuk memperoleh model yang efisien dan akurat.

2.2. Sampah

Menurut Kementerian Lingkungan Hidup dan Kehutanan (KLHK), sampah merupakan material sisa yang sudah tidak digunakan lagi dan harus dikelola secara terpadu mulai dari pengurangan, pemanfaatan kembali, hingga pengolahan akhir. Pengelolaan sampah yang tidak optimal menyebabkan penurunan kualitas lingkungan hidup dan meningkatkan risiko gangguan kesehatan masyarakat [1].

2.3. Convolutional Neural Network

Convolutional Neural Network (CNN) adalah algoritma deep learning yang digunakan untuk memproses data gambar, menentukan objek dalam gambar dan berfungsi untuk membedakan satu objek dengan objek lainnya [5]. CNN digunakan untuk mengolah data berupa citra maupun audio. Model ini berfokus pada proses klasifikasi data berlabel dengan menerapkan pendekatan supervised Learning, di mana proses pelatihan dilakukan menggunakan data yang memiliki target. Tujuan utama dari metode ini adalah mengelompokkan data ke dalam kelas atau kategori tertentu [6].


2.4. MobileNetV4

MobileNetV4 merupakan pengembangan terbaru dari keluarga MobileNet yang dirancang menggunakan pendekatan *Hybrid Neural Architecture Search* (NAS) untuk mencapai efisiensi komputasi dan latensi yang sangat rendah pada perangkat mobile, sekaligus mempertahankan tingkat akurasi yang kompetitif [4].

MobileNetV4 mengintegrasikan dua komponen utama yang berperan penting dalam meningkatkan performa klasifikasi sampah, yaitu *Universal Inverted Bottleneck* (UIB) dan *Attention Mechanism internal*. UIB berfungsi sebagai blok utama untuk ekstraksi fitur melalui kombinasi ekspansi channel, *depthwise*

convolution, dan proyeksi channel. Struktur ini memungkinkan model menangkap informasi visual secara efisien dengan jumlah parameter dan kebutuhan komputasi yang lebih rendah dibandingkan CNN konvensional.

Selain itu, MobileNetV4 memanfaatkan *attention mechanism* pada beberapa layer untuk meningkatkan kualitas representasi fitur. Mekanisme ini membantu model memfokuskan perhatian pada fitur yang paling relevan serta mengurangi pengaruh informasi yang kurang penting, sehingga meningkatkan kemampuan klasifikasi pada objek yang memiliki kemiripan visual [4].



Gambar 1. Model Arsitektur MobileNetV4

Arsitektur MobileNetV4 tersedia dalam tiga varian, yaitu MobileNetV4-Small, MobileNetV4-Medium, dan MobileNetV4-Large. Ketiga varian tersebut memiliki kompleksitas dan jumlah parameter yang berbeda sehingga dapat dipilih sesuai kebutuhan antara efisiensi komputasi dan performa klasifikasi.

2.5. Transfer Learning

Transfer Learning adalah teknik pembelajaran yang memanfaatkan model yang telah dilatih sebelumnya menggunakan dataset berskala besar sebagai sumber pengetahuan. Pengetahuan yang telah diperoleh tersebut kemudian ditransfer untuk membantu menyelesaikan tugas baru yang memiliki karakteristik serupa. Pengetahuan yang telah diperoleh tersebut kemudian ditransfer untuk membantu

menyelesaikan tugas baru yang memiliki karakteristik serupa.[13]

2.6. Augmentasi Data

Augmentasi data adalah strategi untuk meningkatkan keragaman data pelatihan secara signifikan tanpa harus mengumpulkan data baru, dengan cara menerapkan berbagai transformasi pada data yang sudah ada, seperti *rotation*, *flipping*, *zoom*, dan *brightness adjustment* sehingga model pembelajaran mendalam dapat belajar lebih efektif dan mengurangi risiko overfitting [7].

2.7. Class Weight

Ketidakseimbangan jumlah data antar kelas (*class imbalance*) merupakan permasalahan yang sering ditemui dalam klasifikasi *machine learning*, di mana jumlah sampel pada satu kelas jauh lebih dominan dibandingkan kelas lainnya. Kondisi ini menyebabkan model cenderung bias terhadap kelas mayoritas dan gagal mempelajari pola dari kelas minoritas secara optimal, sehingga kinerja klasifikasi pada kelas dengan jumlah data lebih sedikit menjadi rendah [12].

Salah satu pendekatan yang umum digunakan untuk mengatasi permasalahan *class imbalance* adalah penerapan *class weighting* pada fungsi loss selama proses pelatihan model. Metode ini memberikan penalti kesalahan yang lebih besar pada kelas minoritas dan penalti yang lebih kecil pada kelas mayoritas, sehingga model terdorong untuk mempelajari karakteristik seluruh kelas secara lebih seimbang tanpa harus mengubah distribusi data secara langsung[8]. Skema pembobotan berdasarkan kebalikan akar jumlah sampel tiap kelas (*Inverse Square Root Number of Samples* atau ISRS) mampu memberikan penalti yang lebih proporsional dan menghasilkan performa yang lebih stabil pada dataset dengan distribusi kelas yang tidak seimbang.[12]

$$W = 10 \times \frac{1}{\sqrt{\text{Number Sample of Class}}} \quad (1)$$

3. METODE PENELITIAN



Gambar 2. Tahapan Metodologi

Dalam pelaksanaan penelitian ini, diterapkan perancangan metode terlebih dahulu untuk meminimalisir kesalahan dalam proses penelitian. Tahapan metodologi penelitian dapat dilihat pada gambar 2.

3.1. Studi Literatur

Tahapan ini dimulai dengan melakukan pembelajaran literatur berupa jurnal dan buku terkait topik penelitian ini, yaitu klasifikasi sampah menggunakan CNN dengan arsitektur MobileNetV4 dan *Transfer Learning*.

3.2. Pengumpulan Data

Pada tahap ini, dilakukan proses pengumpulan dataset berupa dataset klasifikasi sampah yang berasal dari website Kaggle <https://www.kaggle.com/datasets/sumn2u/garbage-classification-v2> yang berjudul “*Garbage Dataset : A Comprehensive Image Dataset for Garbage Classification and Recycling*.”. Terdiri dari 20.218 gambar dan 10 kelas yang berbeda.

3.3. Perancangan


Pada tahap ini dirancang sistem klasifikasi citra sampah berbasis *deep learning* menggunakan arsitektur MobileNetV4. Tahapan ini diawali dengan proses *preprocessing data* untuk menyiapkan dataset agar sesuai dengan kebutuhan pelatihan model. Setiap citra dilakukan penyesuaian ukuran dan normalisasi nilai piksel (224 x 224) untuk memastikan keseragaman distribusi input, sehingga proses pelatihan jaringan saraf dapat berlangsung secara stabil dan efisien.

Untuk meningkatkan kemampuan generalisasi model, diterapkan teknik data augmentation pada data latih berupa rotasi, *zoom*, *brightness adjustment* dan *horizontal flipping*. Strategi ini bertujuan memperkaya variasi data tanpa mengubah label kelas sehingga model menjadi lebih *robust* terhadap perubahan orientasi objek dan membantu mengurangi *overfitting* [9].

Model yang digunakan adalah MobileNetV4 dengan pendekatan *Transfer Learning* menggunakan bobot awal (*pretrained weights*) dari ImageNet. Selanjutnya, dilakukan fine-tuning pada layer klasifikasi agar model dapat menyesuaikan dengan karakteristik dataset sampah yang digunakan. Pendekatan *Transfer Learning* dipilih karena mampu meningkatkan performa dan mempercepat proses konvergensi model pada dataset dengan jumlah data terbatas [10].

Fitur hasil ekstraksi dari MobileNetV4 selanjutnya diteruskan ke *classification head* berupa lapisan *fully connected* untuk menghasilkan 43 prediksi kelas sampah. Mengingat dataset yang digunakan memiliki distribusi jumlah data yang tidak seimbang antar kelas, proses pelatihan model mempertimbangkan kondisi *class imbalance* dengan menyesuaikan proses optimasi, sehingga model tidak

bias terhadap kelas mayoritas dan tetap mampu mengenali kelas dengan jumlah data yang lebih sedikit. Skema perancangan dapat dilihat pada Gambar 3.



Gambar 3. Skema Perancangan Model

3.4. Implementasi

Pada tahapan ini dilakukan implementasi dari sistem yang telah dirancang sebelumnya agar sistem dapat mengenali dan melakukan klasifikasi terhadap data training yang telah diolah sebelumnya.

3.5. Pengujian

Pada tahapan ini, sistem yang telah dibuat sebelumnya akan melakukan uji coba terhadap data uji. Setelah tahapan uji coba, hasil pengujian dihitung untuk mendapatkan tingkat keberhasilan metode yang digunakan dengan *Confusion Matrix* dalam menghitung nilai *precision*, *recall*, *f1-score* dan *accuracy* yang dapat dilihat pada Persamaan (2), (3), (4) dan (5).

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

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

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (5)$$

4. HASIL DAN PEMBAHASAN

4.1. Data Collection

Penelitian ini menggunakan dataset publik yang diperoleh dari platform Kaggle dengan judul "*Garbage Dataset: A Comprehensive Image Dataset for Garbage Classification and Recycling*". Dataset tersebut dapat diakses melalui situs Kaggle dan terdiri dari 20.218 citra yang terbagi ke dalam 10 kelas, yaitu *Metal*, *Glass*, *Biological*, *Paper*, *Battery*, *Trash*, *Cardboard*, *Shoes*, *Clothes*, dan *Plastic*.

Dataset ini dipilih karena memiliki variasi jenis sampah yang cukup beragam sehingga sesuai untuk mengevaluasi performa model MobileNetV4 dalam tugas klasifikasi citra sampah berbasis *Transfer Learning*.

4.2. Pre-Processing Data

Tahap *pre-processing* dilakukan untuk menyiapkan dataset sebelum digunakan pada proses pelatihan model. Seluruh citra terlebih dahulu diubah ukurannya (*resize*) menjadi 224×224 piksel agar sesuai dengan ukuran masukan (*input size*) yang digunakan oleh arsitektur MobileNetV4. Selanjutnya, citra dikonversi menjadi tensor, sehingga nilai piksel yang semula berada pada rentang 0–255 dinormalisasi menjadi 0–1. Proses ini bertujuan untuk menghasilkan distribusi input yang seragam sehingga pelatihan model dapat berlangsung lebih stabil dan efisien.

Untuk meningkatkan kemampuan generalisasi model, diterapkan teknik *data augmentation* pada data latih berupa rotasi acak hingga 20° , zoom dengan skala 0,8–1,2, horizontal flipping, serta penyesuaian tingkat brightness sebesar 0,2. Sementara itu, data validasi dan data uji hanya melalui proses *resize* dan konversi ke tensor tanpa augmentasi agar proses evaluasi dilakukan menggunakan data asli.

4.3. Pembuatan Model

Pada penelitian ini, model klasifikasi dibangun menggunakan MobileNetV4-Small, Medium dan Large dengan pendekatan *Transfer Learning*. Model diinisialisasi menggunakan *pretrained weights* dari ImageNet sehingga dapat memanfaatkan representasi fitur yang telah dipelajari sebelumnya. Selanjutnya, seluruh parameter pada *backbone* dibekukan (*freeze*), sedangkan lapisan *classifier* dibuka (*unfreeze*) untuk dilakukan proses *fine-tuning* sesuai dengan karakteristik dataset klasifikasi sampah.

Sebelum proses pelatihan, dataset dibagi menjadi 80% data latih, 10% data validasi, dan 10% data uji. Berdasarkan pembagian tersebut diperoleh sebanyak 9.808 data latih, 1.226 data validasi, dan 1.226 data uji.

Mengingat distribusi jumlah data antar kelas tidak seimbang, penelitian ini menerapkan metode *Class Weight* dengan skema *Inverse Square Root Number of Samples* (ISNS) pada fungsi *Cross Entropy Loss*. Pendekatan ini bertujuan untuk memberikan bobot yang lebih besar pada kelas minoritas sehingga model tidak bias terhadap kelas mayoritas selama proses pelatihan.


Optimasi model dilakukan menggunakan algoritma Adam dengan *learning rate* sebesar 0,001, sedangkan proses pelatihan dilakukan selama 20 epoch dengan batch size 32. Seluruh proses pelatihan memanfaatkan data latih, sementara data validasi digunakan untuk memantau performa model pada setiap epoch sebelum dilakukan evaluasi akhir menggunakan data uji.

4.4. Hasil Pengujian MobileNetV4-Small

Pengujian pada varian MobileNetV4-Small menggunakan 1.226 citra uji menghasilkan tingkat akurasi sebesar 81%. Model menunjukkan kinerja terbaik pada kelas *Clothes* dengan metrik *Precision* 0.98, *Recall* 0.94, dan *F1-Score* 0.96. Kinerja yang solid juga terlihat pada kelas *Biological* dan *Shoes* dengan *F1-Score* masing-masing sebesar 0.91. Di sisi lain, kelas *Trash* memperoleh hasil terendah dengan *F1-Score* 0.59, yang mengindikasikan kesulitan model dalam mengekstraksi fitur visual sampah yang sangat acak dan tidak berpola pada kelas tersebut.

Tabel 1. Hasil Evaluasi Model MobileNetV4-Small

Kelas	Precision	Recall	F1-Score	Jumlah Data
Battery	0.81	0.94	0.87	64
Biological	0.85	0.99	0.91	68
Cardboard	0.76	0.82	0.79	140
Clothes	0.98	0.94	0.96	181
Glass	0.84	0.76	0.80	189
Metal	0.65	0.76	0.70	109
Paper	0.81	0.66	0.72	126
Plastic	0.77	0.69	0.73	146
Shoes	0.91	0.91	0.91	162
Trash	0.53	0.66	0.59	41



Gambar 4. Hasil Confusion Matrix Model MobileNetV4-Small

Berdasarkan analisis *Confusion Matrix*, model mengalami klasifikasi yang kurang akurat pada beberapa kelas dengan fitur visual yang tumpang tindih. Terdapat 22 citra *Paper* yang keliru diprediksi sebagai *Cardboard* akibat kemiripan tekstur dan warna. Model juga mengalami kebingungan pada

material reflektif, di mana 18 citra *Glass* diklasifikasikan sebagai *Plastic*, karena pantulan cahaya pada permukaan kedua material tersebut.


4.5. Hasil Pengujian MobileNetV4-Medium

Sejalan dengan varian *Small*, arsitektur MobileNetV4-Medium berhasil mencapai tingkat akurasi keseluruhan sebesar 81%. Kinerja optimal tetap dipegang oleh kelas *Clothes* dengan *F1-Score* 0.96, *Recall* 0.93 dan *Precision* 0.99, dan terdapat sedikit peningkatan pada kelas *Shoes* yang mencapai *F1-Score* 0.93, *Recall* 0.91 dan *Precision* 0.95. Namun, performa untuk kelas *Trash* mengalami sedikit penurunan dengan *F1-Score* 0.58.

Tabel 2. Hasil Evaluasi Model MobileNetV4-Medium

Kelas	Precision	Recall	F1-Score	Jumlah Data
Battery	0.80	0.86	0.83	64
Biological	0.93	0.91	0.92	68
Cardboard	0.79	0.76	0.77	140
Clothes	0.99	0.93	0.96	181
Glass	0.85	0.75	0.80	189
Metal	0.69	0.79	0.74	109
Paper	0.71	0.71	0.71	126
Plastic	0.73	0.75	0.74	146
Shoes	0.95	0.91	0.93	162
Trash	0.48	0.76	0.58	41

Hasil *Confusion Matrix* pada varian *Medium* memperlihatkan pola kebingungan yang serupa. Sebanyak 16 citra *Paper* masih terdeteksi sebagai *Cardboard*. Masalah pada varian *small* juga masih ada untuk material yang reflektif, varian *medium* salah mengklasifikasikan 22 citra *Glass* menjadi *Plastic*. Hal ini menunjukkan bahwa penambahan kapasitas lapisan ekstraksi pada blok varian *Medium* belum mampu sepenuhnya memisahkan kemiripan visual pada objek reflektif.



Gambar 5. Hasil Confusion Matrix Model MobileNetV4-Medium


4.6. Hasil Pengujian MobileNetV4-Large

Pengujian menggunakan arsitektur MobileNetV4-Large menghasilkan tingkat akurasi sebesar 74%. Penurunan akurasi ini dibandingkan varian yang lebih kecil merupakan indikasi terjadinya *overfitting*, di mana kapasitas parameter model yang terlalu besar justru menangkap *noise* berlebih pada dataset latih dan gagal melakukan klasifikasi pada data uji. Kinerja tertinggi masih didapatkan pada kelas *Clothes* dengan *F1-Score* 0.92, *Recall* 0.91, *Precision* 0.93, sementara kelas *Trash* menurun secara drastis dengan *F1-Score* menjadi 0.47, *Recall* 0.45, dan *Precision* 0.50.

Tabel 3. Hasil Evaluasi Model MobileNetV4-Large

Kelas	Precision	Recall	F1-Score	Jumlah Data
Battery	0.56	0.81	0.66	64
Biological	0.56	0.93	0.70	68
Cardboard	0.83	0.55	0.66	140
Clothes	0.93	0.91	0.92	181
Glass	0.71	0.79	0.75	189
Metal	0.65	0.73	0.69	109
Paper	0.68	0.57	0.62	126
Plastic	0.70	0.66	0.68	146
Shoes	0.98	0.82	0.89	165
Trash	0.50	0.45	0.47	40

Pada evaluasi *Confusion Matrix*, tingkat misklasifikasi menyebar dengan frekuensi yang lebih tinggi. Kesalahan prediksi antara *Paper* dan *Cardboard* semakin terlihat, di mana 21 citra *Cardboard* justru diprediksi keliru sebagai *Paper*. Begitu pula dengan kelas *Glass*, di mana 23 citra salah diprediksi sebagai *Plastic*, yang mempertegas kesulitan model dalam mengklasifikasi data citra dengan kemiripan tekstur pada jumlah dataset yang terbatas.



Gambar 6. Hasil Confusion Matrix MobileNetV4-Large

4.7. Perbandingan Kinerja MobileNetV4

Untuk menentukan arsitektur klasifikasi sampah yang paling optimal, dilakukan perbandingan kinerja

secara menyeluruh antara varian MobileNetV4-Small, Medium, dan Large. Pada tahap komparasi ini, parameter evaluasi untuk masing-masing kelas difokuskan pada penggunaan metrik *F1-Score*.

Pemilihan *F1-Score* sebagai metrik utama didasarkan pada karakteristik dataset penelitian yang memiliki tingkat ketidakseimbangan jumlah data yang tinggi antar kelas (*class imbalance*). *F1-Score* digunakan untuk harmonisasi antara presisi dan Recall, yang berguna pada data multikelas tidak seimbang [11]. Ringkasan perbandingan metrik *F1-Score* serta tingkat akurasi akhir untuk ketiga varian dapat dilihat pada Tabel 4.

Tabel 4. Perbandingan Kinerja Varian MobileNetV4

Kelas	F1-Score		
	Small	Medium	Large
Battery	0.87	0.83	0.66
Biological	0.91	0.92	0.70
Cardboard	0.79	0.77	0.66
Clothes	0.96	0.96	0.92
Glass	0.80	0.80	0.75
Metal	0.70	0.74	0.69
Paper	0.72	0.71	0.62
Plastic	0.73	0.74	0.68
Shoes	0.91	0.93	0.89
Trash	0.59	0.58	0.47
Accuracy	81%	81%	74%

Berdasarkan komparasi pada Tabel 4, varian MobileNetV4-Small dan Medium menunjukkan performa prediksi yang setara dengan akurasi tertinggi sebesar 81%. Di sisi lain, varian Large menunjukkan performa terendah (74%) di seluruh kelas target. Hal ini mengonfirmasi bahwa penambahan kompleksitas parameter pada arsitektur model saat menggunakan dataset dengan jumlah terbatas justru memicu *overfitting* dan menurunkan kemampuan klasifikasi model terhadap data baru.

Meskipun varian Medium memiliki sedikit keunggulan dalam mengenali kelas *Shoes* (*F1-Score* 0.93 berbanding 0.91), varian MobileNetV4-Small dinilai sebagai model yang paling unggul dan direkomendasikan dalam penelitian ini. Arsitektur Small mampu mempertahankan tingkat akurasi dan kinerja klasifikasi yang stabil dengan kapasitas parameter yang jauh lebih sedikit. Keunggulan tersebut menjadikan varian Small lebih efisien dari segi komputasi dan memori tanpa harus mengorbankan kualitas prediksi, sehingga sangat ideal untuk diimplementasikan pada perangkat sistem pemilahan sampah cerdas yang umumnya memiliki sumber daya terbatas.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian klasifikasi sampah menggunakan arsitektur MobileNetV4 dan *Transfer Learning*, dapat disimpulkan bahwa varian MobileNetV4-Small merupakan model yang paling unggul dan direkomendasikan. Varian *Small* dan *Medium* berhasil mencapai tingkat akurasi tertinggi

yang setara, yaitu sebesar 81%. Performa ini mengalahkan varian *Large* (74%) yang mengalami *overfitting* akibat tingginya kompleksitas parameter saat dilatih menggunakan dataset yang terbatas. Arsitektur *Small* terbukti mampu mempertahankan stabilitas kinerja klasifikasi dengan kapasitas parameter yang jauh lebih sedikit, sehingga lebih efisien secara komputasi untuk diimplementasikan pada sistem cerdas dengan sumber daya terbatas. Meskipun evaluasi menunjukkan hasil yang solid, model masih mengalami kendala dalam mengklasifikasikan kelas *Trash* yang memperoleh *F1-Score* terendah (0.59), serta rentan mengalami misklasifikasi pada material dengan tekstur serupa (*Paper* dan *Cardboard*) maupun objek reflektif (*Glass* dan *Plastic*). Oleh karena itu, saran untuk penelitian selanjutnya adalah melakukan penambahan kuantitas dataset secara lebih merata pada kelas minoritas, serta menerapkan teknik pra-pemrosesan citra tingkat lanjut atau mengeksplorasi mekanisme *attention* tambahan untuk menajamkan ekstraksi fitur pada objek-objek yang bersifat transparan dan memantulkan cahaya

DAFTAR PUSTAKA

- [1] KLHK/SIPSN, "Data timbulan sampah nasional 2024," Kementerian Lingkungan Hidup dan Kehutanan Republik Indonesia.
- [2] M. N. Anugrah and N. Rachmat, "Klasifikasi Penyakit Daun Tanaman Jagung Menggunakan Pendekatan Transfer Learning Arsitektur MobileNetV4," vol. 4, no. 4, pp. 2174–2182, 2025.
- [3] Z. A. Amin, K. N. Sami, and R. Hassan, "An Approach of Classifying Waste Using Transfer Learning Method," *Int. J. Perceptive Cogn. Comput.*, vol. 7, no. 1, pp. 41–52, 2021.
- [4] D. Qin *et al.*, "MobileNetV4: Universal Models for the Mobile Ecosystem," 2024.
- [5] K. Azmi and S. Defit, "Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat," vol. 16, no. 1, pp. 2580–2582, 2023.
- [6] A. R. Fachrurroji, M. Y. Wijaya, and F. Irma, "Implementasi algoritma cnn mobilenet untuk klasifikasi gambar sampah di bank sampah," *J. Pengemb. Obs. Sist. Komput.*, vol. 11, no. 1, 2024.
- [7] J. Sanjaya and M. Ayub, "Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan Random Crop , Rotate , dan Mixup," *J. Tek. Inform. dan Sist. Inf.*, vol. 6, pp. 311–323, 2020.
- [8] Z. Yu, X. Li, X. Niu, J. Shi, and G. Zhao, "Face Anti-Spoofing with Human Material Perception," *Eur. Conf. Comput. Vis.*, 2020.
- [9] S. Poudel, *Classification of Waste Materials using CNN Based on Transfer Learning*, vol. 1, no. 1. Association for Computing Machinery, 2022. doi: 10.1145/3574318.3574345.
- [10] B. Huo, W. Qi, D. Li, H. Ren, and C. Hou, "Intelligent Waste Classification System Design and Implementation Based on Deep Learning," *2025 4th Int. Conf. Cyber Secur. Artif. Intell. Digit. Econ. (CSAIDE 2025)*, March 0709, 2025, Kuala Lumpur, Malaysia, vol. 1, no. 1, pp. 441–448, 2025, doi: 10.1145/3729706.3729776.
- [11] S. Helmiyah, R. Pramestiawan, and R. Lampung, "Analisis Komparatif Algoritma Machine Learning dengan Metrik Akurasi , Presisi , Recall , dan F1-Score pada Dataset Kacang Kering," *J. Ilmu Komput. Dan Teknol.*, vol. 6, no. 3, pp. 152–159, 2025.
- [12] S. Ağırıklandırma, T. Kullanımı, M. Araştırma, and B. Bakırarar, "Class Weighting Technique to Deal with Imbalanced Class Problem in Machine Learning : Methodological Research Makine Öğrenmesinde Dengesiz Sınıf Problemiyle Başa Çıkmak İçin," pp. 19–29, 2023, doi: 10.5336/biostatic.2022-93961.
- [13] D. Made, S. Amanda, G. K. Gandhiadi, and I. G. N. Lanang, "Kajian Metode Transfer Learning untuk Identifikasi Tumbuhan Herbal Berbasis Lontar Usada Taru Pramana," *J. Sains dan Teknol.*, vol. 14, no. 1, pp. 77–89, 2025.