

KLASIFIKASI SAMPAH BIODEGRADABLE DAN NON-BIODEGRADABLE MENGGUNAKAN ARSITEKTUR MOBILENET DAN XGBOOST

Enrico Giriyo Panaroma, Muhammad Ezar Al Rivan

Informatika, Universitas Multi Data Palembang
Jl. Rajawali 14, 30113 Palembang - Sumatera Selatan
enricogp888@gmail.com

ABSTRAK

Pengelolaan sampah merupakan tantangan utama dalam menjaga kelestarian lingkungan hidup secara global. Seiring meningkatnya volume sampah yang dihasilkan setiap tahun, proses pemilihan sampah secara manual menjadi kurang efisien dan rentan akan *human error*, maka dari itu klasifikasi sampah yang tepat, khususnya dalam membedakan antara sampah *biodegradable* dan *non-biodegradable*, sangat penting untuk mendukung proses daur ulang dan mengurangi dampak lingkungan. Penelitian ini bertujuan mengembangkan sistem klasifikasi sampah yang efisien dan akurat dengan menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2 dan MobileNetV3-Large sebagai ekstraksi fitur serta XGBoost untuk klasifikasi gambar, yang dibandingkan akan performa MobileNetV2, *hybrid* MobileNetV2 + XGBoost, dan MobileNetV3-Large. Metode penelitian meliputi pelatihan, validasi dan pengujian terhadap dataset *BDWaste* dengan pembagian data yang sesuai untuk mengoptimalkan performa. Evaluasi performa dilakukan menggunakan *accuracy*, *precision*, *recall*, dan *F1-score* untuk memastikan kemampuan model dalam membedakan kedua kategori secara konsisten. Hasil pengujian menunjukkan bahwa model *hybrid* memberikan performa yang paling unggul dengan tingkat akurasi sebesar 94,69% dengan komputasi yang ringan yaitu dengan ukuran model sebesar 150 KB dengan waktu pelatihan 127 detik.

Kata kunci : CNN; MobileNetV2; MobileNetV3; Sampah; XGBoost

1. PENDAHULUAN

Pengelolaan sampah masih menjadi salah satu tantangan lingkungan hidup paling krusial di era modern. Sampah yang tidak terkelola dengan baik tidak hanya memicu pencemaran lingkungan darat dan udara, tetapi juga memberikan dampak kerusakan yang fatal terhadap ekosistem akuatik. Dalam skala global, penelitian terbaru mengungkapkan bahwa lebih dari 1.000 sungai di seluruh dunia menyumbang sekitar 80% dari total emisi sampah plastik tahunan yang pada akhirnya mengalir dan mencemari lautan [1].

Di Indonesia, urgensi penanganan masalah lingkungan dan limbah ini direkam secara komprehensif oleh Badan Pusat Statistik (BPS) melalui publikasi Statistik Lingkungan Hidup Indonesia 2025. Laporan yang disusun dengan mengacu pada kerangka *Framework for the Development of Environment Statistics* (FDES) 2013 tersebut menegaskan kompleksitas kondisi lingkungan nasional yang membutuhkan penanganan secara fleksibel, komprehensif, dan integratif [2].

Seiring meningkatnya volume sampah yang terus dihasilkan setiap tahunnya, metode klasifikasi dan pemilihan sampah secara manual menjadi kurang efisien dan dinilai rentan terhadap *human error*. Oleh karena itu, klasifikasi sampah menjadi langkah awal yang sangat penting dalam sistem pengelolaan limbah, khususnya dalam membedakan antara sampah *biodegradable* (dapat terurai secara alami) dan *non-biodegradable* (tidak dapat terurai secara alami) yang memerlukan penanganan berbeda untuk mendukung proses daur ulang dan pengurangan limbah [3].

Perkembangan teknologi pengolahan citra dan kecerdasan buatan, khususnya *Convolutional Neural Networks* (CNN), telah memberikan kemajuan signifikan dalam klasifikasi gambar, termasuk pengenalan jenis-jenis sampah. CNN mampu mengekstraksi fitur visual yang kompleks secara otomatis dari gambar, sehingga sangat efektif untuk aplikasi klasifikasi citra [4].

MobileNet merupakan salah satu arsitektur CNN yang dirancang khusus untuk perangkat dengan sumber daya terbatas, seperti perangkat mobile, dengan tetap mempertahankan akurasi yang tinggi dan efisiensi komputasi [5].

Penggunaan optimasi Adam dalam pelatihan MobileNetV2 dapat mencapai total akurasi diatas 96% [6]. Evaluasi performa model klasifikasi menggunakan metrik seperti *precision*, *recall*, *F1-Score*, dan *accuracy* untuk melihat kemampuan model dalam mengklasifikasikan data [7].

MobileNetV2 adalah pengembangan dari MobileNet yang memperkenalkan konsep *inverted residuals* dan *linear bottlenecks*, sehingga meningkatkan performa jaringan dengan parameter yang lebih sedikit dan kecepatan inferensi yang lebih cepat [4].

MobileNetV2 telah banyak diaplikasikan dalam klasifikasi sampah karena kemampuannya dalam mengekstraksi fitur secara efisien dan efektif [6].

MobileNetV3 merupakan evolusi terbaru yang menggabungkan teknik *Neural Architecture Search* (NAS) dan optimasi manual untuk menghasilkan model yang lebih ringan dengan performa yang lebih baik dibandingkan versi sebelumnya [8].

MobileNetV3 hadir dalam dua varian utama, yaitu MobileNetV3-Large dan MobileNetV3-Small. MobileNetV3-Large dirancang untuk memberikan akurasi lebih tinggi dengan efisiensi komputasi yang terjaga [8].

Studi menunjukkan bahwa MobileNetV3-Large mampu menurunkan penggunaan memori hingga 15% dan mempercepat inferensi hingga 20% dibandingkan MobileNetV2, tanpa mengorbankan akurasi [8].

Dalam konteks klasifikasi sampah, model ini memberikan keseimbangan optimal antara kecepatan dan ketepatan, sangat cocok untuk implementasi pada perangkat mobile dengan keterbatasan sumber daya [9].

Untuk meningkatkan akurasi klasifikasi, metode *hybrid* digunakan dengan menggabungkan CNN sebagai ekstraksi fitur dan algoritma *machine learning* lain untuk klasifikasi gambar. Salah satu algoritma yang populer adalah XGBoost, sebuah sistem boosting pohon keputusan yang scalable dan memiliki kemampuan generalisasi yang baik serta mekanisme regularisasi yang memungkinkan penanganan data tidak seimbang dan *overfitting* [10].

Penggunaan XGBoost dalam klasifikasi sampah, baik secara mandiri maupun dikombinasikan dengan CNN seperti MobileNetV2, telah menunjukkan peningkatan akurasi hingga 5-10% dibandingkan model tunggal [11].

Dataset yang digunakan dalam penelitian ini diadaptasi dari BDWaste, yang merupakan kumpulan data citra sampah *biodegradable* dan *non-biodegradable* yang komprehensif dan representatif dari kondisi nyata di Bangladesh [6]. *Dataset* ini terdiri dari 10 kategori sampah *biodegradable / digestive* dan 10 kategori sampah *non-biodegradable / non-digestive*.

Penelitian ini bertujuan mengembangkan sistem klasifikasi sampah dengan menggunakan MobileNetV2 dengan MobileNetV3-Large sebagai ekstraksi fitur dengan XGBoost sebagai klasifikasi gambar untuk MobileNetV2, sehingga menemukan model mana yang lebih efektif untuk mengklasifikasi sampah, sehingga diharapkan dapat menghasilkan model yang efisien dan akurat dalam membedakan sampah *biodegradable* dan *non-biodegradable*. Pendekatan ini diharapkan dapat memberikan kontribusi dalam pengelolaan sampah yang lebih baik dan mendukung program daur ulang yang berkelanjutan.

2. TINJAUAN PUSTAKA

Tinjauan Pustaka ini membahas konsep dan penelitian terdahulu yang relevan dengan klasifikasi citra sampah secara otomatis dengan menggunakan pendekatan *deep learning* dan *machine learning*. Pembahasan mencakup arsitektur klasifikasi citra digital, arsitektur MobileNetV2 dan MobileNetV3-Large sebagai ekstraksi fitur yang ringan untuk sumber daya yang terbatas serta penggunaan XGBoost sebagai algoritma untuk klasifikasi gambar dalam skema

model *hybrid* yang bertujuan untuk meningkatkan efisiensi waktu pelatihan secara signifikan dengan memanfaatkan *decision tree* pada XGBoost. Bagian ini disusun sebagai landasan teoritis yang mendukung metode dan analisis hasil penelitian.

2.1. Penelitian Terdahulu

Klasifikasi sampah secara otomatis memerlukan arsitektur yang ringan namun tetap mempertahankan tingkat akurasi tinggi untuk implementasi pada perangkat dengan sumber daya terbatas. Penggunaan arsitektur MobileNetV2 telah terbukti efektif dalam mengenali kategori limbah secara akurat dengan beban komputasi yang efisien [12].

Optimalisasi sistem manajemen limbah juga terus dikembangkan melalui pendekatan klasifikasi sampah daur ulang menggunakan teknik transfer learning untuk mencapai performa yang lebih optimal [13].

Untuk mendapatkan hasil yang lebih stabil, integrasi model *hybrid* yang menggabungkan MobileNetV2 sebagai ekstraktor fitur dan *Extreme Gradient Boosting* (XGBoost) sebagai pengklasifikasi terbukti mampu memberikan performa yang lebih unggul dibandingkan penggunaan lapisan saraf konvensional saja [11].

Selain pemilihan arsitektur, aspek validasi model juga menjadi faktor krusial di mana penggunaan metrik evaluasi berbasis *confusion matrix* menjadi standar penting untuk memberikan penilaian performa klasifikasi yang menyeluruh dan mendalam [7]. Berdasarkan literatur tersebut, penelitian ini menggabungkan efisiensi ekstraksi fitur dari MobileNet dengan kecepatan pemrosesan XGBoost serta, membandingkan penggunaan MobileNetV2 dan MobileNetV3-Large untuk klasifikasi sampah *biodegradable* dan *non-biodegradable*.


2.2. MobileNetV2

MobileNetV2 merupakan arsitektur *Convolutional Neural Network* (CNN) efisien yang diperkenalkan sebagai penyempurnaan dari MobileNetV1 untuk mendukung aplikasi pada perangkat dengan keterbatasan sumber daya komputasi. Inovasi dari MobileNetV2 adalah pengenalan struktur *Inverted Residuals* dan *Linear Bottleneck* yang memungkinkan model memiliki jumlah parameter yang lebih sedikit namun tetap mempertahankan akurasi yang kompetitif [4].

MobileNetV2 sangat efektif digunakan dalam klasifikasi citra karena kemampuannya dalam mempertahankan akurasi dan ringan komputasi [12].


Berbeda dengan blok residual konvensional yang menggunakan pola “tebal-tipis-tebal”, *inverted residual* pada MobileNetV2 menerapkan pola “tipis-tebal-tipis”. Blok ini diawali dengan lapisan ekspansi 1×1 untuk meningkatkan dimensi kanal, diikuti oleh *depthwise convolution* 3×3 yang melakukan filtrasi spasial secara terpisah pada setiap kanal. Proses ini kemudian dilanjutkan dengan *pointwise convolution*

1×1 untuk menggabungkan informasi antar kanal. Pendekatan *depthwise separable convolution* ini secara signifikan mengurangi jumlah parameter dan operasi perkalian-akumulasi (MACs) dibandingkan konvolusi standar.



Gambar 1. Residual Block dan Inverted Residual Block

Pada tahap akhir blok, lapisan proyeksi 1×1 menggunakan *linear bottleneck* tanpa fungsi aktivasi non-linear. Strategi ini bertujuan untuk mempertahankan informasi penting pada representasi berdimensi rendah dan mencegah hilangnya informasi akibat aktivasi non-linear pada ruang fitur yang terkompresi [4].



Gambar 2. Separable Linear Bottleneck dan Bottleneck with Expansion Layer

Dalam penelitian ini, MobileNetV2 digunakan dalam dua kasus: pertama sebagai model klasifikasi mandiri dan yang kedua untuk ekstraksi fitur dan yang nantinya diproses oleh algoritma XGBoost dalam skema model *hybrid* untuk mengklasifikasi citra sampah.


2.3. MobileNetV3

MobileNetV3 merupakan generasi ketiga dari seri MobileNet yang dirancang untuk mengoptimalkan performa pada perangkat mobile melalui kombinasi teknik *Network Architecture Search* (NAS). Arsitektur ini tidak dirancang secara manual sepenuhnya, melainkan dicari secara otomatis untuk

menyeimbangkan latensi dan akurasi pada berbagai platform perangkat keras [8].

MobileNetV3 hadir dalam dua varian utama, yaitu MobileNetV3-Large dan MobileNetV3-Small. MobileNetV3-Large dirancang untuk perangkat dengan sumber daya yang lebih memadai dan fokus pada peningkatan akurasi, sedangkan MobileNetV3-Small dioptimalkan untuk perangkat dengan keterbatasan sumber daya yang lebih ketat, seperti perangkat IoT dan perangkat *mobile entry level* [8].

Inovasi utama yang membedakan MobileNetV3-Large dari generasi sebelumnya adalah menambahkan modul *Squeeze-and-Excitation* (SE) ke dalam struktur *inverted residual*. Modul SE memungkinkan jaringan untuk meningkatkan representasi fitur secara adaptif dengan memberikan bobot pada saluran fitur, sehingga meningkatkan kualitas ekstraksi fitur tanpa menambah beban komputasi yang signifikan. Selain itu, arsitektur ini menerapkan fungsi aktivasi *hard-swish* (h-swish) yang lebih efisien dibandingkan fungsi *swish* standar sehingga mengurangi beban komputasi [8].



Gambar 3. Struktur Blok Inverted Residual pada MobileNetV3-Large dengan Modul Squeeze-and-Excitation

2.4. XGBoost

Extreme Gradient Boosting (XGBoost) algoritma *ensemble learning* yang menggunakan metode *gradient boosting* untuk membangun model prediksi secara iteratif melalui penambahan pohon keputusan (*decision trees*) baru yang meminimalkan kesalahan residual [10].

XGBoost memanfaatkan teknik regularisasi L1 dan L2 yang berfungsi untuk menjaga stabilitas model dan mencegah terjadinya *overfitting* [13].

Dalam konteks klasifikasi citra, XGBoost dapat digunakan untuk mengklasifikasi gambar setelah tahap ekstraksi fitur oleh arsitektur *Convolutional Neural Network* (CNN). Fitur yang dihasilkan CNN diubah menjadi *vector* numerik dan digunakan sebagai masukan untuk XGBoost, yang digunakan untuk mempelajari hubungan antar fitur dan pola untuk melakukan klasifikasi [14].


Dalam penelitian ini, *vector* fitur dari lapisan yang dihasilkan MobileNetV2 akan digunakan sebagai input XGBoost untuk mengklasifikasi sampah *biodegradable* dan *non-biodegradable*.

2.5. Hybrid (MobileNetV2 + XGBoost)

Pendekatan *hybrid* pada penelitian ini menggabungkan MobileNetV2 sebagai ekstraksi fitur dan XGBoost untuk mengklasifikasi citra. Strategi ini

didasarkan pada kemampuan lapisan konvolusi CNN dalam menangkap hierarki fitur spasial dari citra, sementara model *boosting* digunakan untuk mempelajari hubungan antar fitur pada tahap klasifikasi.

Implementasi dilakukan dengan menggunakan MobileNetV2 hingga lapisan *Global Average Pooling* (GAP), sehingga vektor fitur ini digunakan sebagai input untuk XGBoost menggantikan *Fully Connected Layer* [11], [15].



Gambar 4. Mekanisme Ensemble Learning pada Lapisan Klasifikasi Hybrid MobileNetV2-XGBoost

Dengan pendekatan ini, proses pembelajaran pada tahap klasifikasi tidak lagi bergantung pada mekanisme seperti *backpropagation* seperti pada lapisan *Fully Connected* konvensional, melainkan memanfaatkan strategi *boosting* berbasis pohon keputusan yang membangun model secara bertahap melalui minimasi residual.

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimental dengan membandingkan tiga model yaitu: MobileNetV2, MobileNetV3-Large dan model *hybrid* (MobileNetV2 + XGBoost) untuk mengklasifikasi gambar sampah berdasarkan *biodegradable* dan *non-biodegradable*. Seluruh model menggunakan teknik *transfer learning* pada dataset. Dataset yang digunakan didapatkan dari “BDWaste: A comprehensive image dataset of digestible and indigestible waste in Bangladesh” [6] yang bersisi 2500 total gambar yang dibagi menjadi *digestive/non-biodegradable* = 1242 dan *digestive/biodegradable* = 1258, dengan label yang dipakai adalah 10 *digestive* dan 10 *indegstive*. Dataset *digestive* berisi *banana peel, egg shell, fish ash, lemon peel, mango peel, paper, potato peel, rice, shell of malta*, dan *sugarcane husk*. Lalu dataset *indigestive* berisi *bottle, can, chips packet, empty medicine packet, glass, gloves, mask, plastic, polythene*, dan *wire*. Dataset dibagi menjadi 80% data latihan, 10% data validasi, dan 10% data uji coba.

Proses penelitian dibagi menjadi empat tahap utama yaitu *pre-processing* dan augmentasi gambar agar citra menjadi format yang seragam, ekstraksi fitur dengan menerapkan strategi *transfer learning* yang berupa penggunaan *pre-trained model imageNet* yang digunakan pada lapisan konvolusi, serta melakukan *freezing* pada lapisan dasar model. Pelatihan model MobileNetV2, MobileNetV3-Large dan *hybrid*

(MobileNetV2+XGBoost), dan evaluasi serta komparasi model.

Implementasi model MobileNetV2 dan MobileNetV3-Large diawali dengan augmentasi citra berukuran 224 x 224 piksel dengan warna RGB dengan rotasi 20 derajat, pergeseran lebar dan tinggi, *sheer*, *zoom*, hingga pembalikan horizontal. Kedua arsitektur ini dibangun dengan menambahkan lapisan *Global Average Pooling* (GAP) setelah base model, diikuti lapisan *dense* dengan 1024 neuron menggunakan aktivasi ReLu, lapisan *dropout* sebesar 0,2 untuk mitigasi resiko *overfitting* dan lapisan output softmax untuk klasifikasi citra sampah. Parameter yang digunakan adalah dengan *epoch* 20 dengan *batch size* sebesar 32 serta *learning rate* 0,0001 dan penggunaan optimasi Adam. Khusus pada MobileNetV3-Large diterapkan *mixed precision* (float16) untuk mengoptimalkan efisiensi komputasi saat proses pelatihan berlangsung.

Pada skenario model *hybrid*, MobileNetV2 difungsikan sebagai pengekstraksi fitur statis yang dimana, fitur yang diekstraksi dari lapisan GAP MobileNetV2 menghasilkan vektor numerik yang dijadikan input oleh XGBoost. Model XGBoost dikonfigurasi dengan parameter *n_estimators* sebanyak 100 pohon keputusan dengan *learning rate* 0,1 menggunakan fungsi kerugian *multi-log loss*. Seluruh bobot model hasil penelitian disimpan dalam format file *.h5* untuk arsitektur berbasis *deep learning* dan model berbasis *gradient boosting* menggunakan format *.pkl*.

Tahap akhir penelitian difokuskan pada pengujian mendalam menggunakan data uji yang belum pernah dilihat sebelumnya oleh model untuk menjamin validitas hasil. Evaluasi dilakukan dengan menghasilkan *confusion matrix* guna menunjukkan frekuensi prediksi benar dan salah pada label sampah *biodegradable* dan *non-biodegradable*. Evaluasi model digunakan dengan 4 metrik utama yang diekstrak dari *confusion matrix*. *Accuracy* berguna untuk memberikan gambaran umum seberapa sering model menebak gambar secara keseluruhan. *Precision* berguna untuk mengukur keakuratan model dalam membedakan prediksi positif. *Recall* berguna untuk mengukur kemampuan model dalam menemukan kembali seluruh informasi kelas positif. *F1-Score* adalah rata-rata antara *presision* dan *recall* untuk memberikan gambaran performa yang seimbang, terutama pada dataset dengan kelas bervariasi [7].

Analisis mendalam terhadap perilaku model dilakukan dengan pembagian nilai pada *confusion matrix* guna memahami ketepatan identifikasi sampah *biodegradable* sebagai label negatif dan *non-biodegradable* sebagai label positif. Pembagian nilai berupa *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) menjadi parameter utama dalam menentukan reabilitas model pada kondisi nyata [7].

Selain aspek ketepatan, penelitian ini mengukur efisiensi model yang meliputi total durasi waktu

pelatihan, dan perbandingan file ukuran model akhir dalam satuan *KiloByte* (KB).

Seluruh eksperimen dijalankan pada komputasi lokal dengan spesifikasi perangkat keras berupa *GPU NVIDIA GeForce RTX 3050* dengan *3296 MB VRAM*, *CPU Intel® Core i5-10500H* dan *RAM sebesar 32GB*.


4. HASIL DAN PEMBAHASAN

Hasil eksperimen yang diperoleh dari proses pelatihan dan pengujian dengan menggunakan *MobileNetV2*, *MobileNetV3-Large* dan *hybrid* (*MobileNetV2* + *XGBoost*) dengan matriks evaluasi yang digunakan meliputi *accuracy*, *precision*, *recall*, dan *F1-Score* yang dihitung berdasarkan *confusion matrix*.

Tabel 1. Hasil Performa Klasifikasi Model


Model	A (%)	P (%)	R (%)	F1-Score (%)
MobileNetV2	93,88	89,13	100	94,25
MobileNetV3-Large	67,35	71,72	57,72	63,96
Hybrid (MobileNetV2 - XGBoost)	94,69	90,44	100	94,98

Tabel 1 menyajikan hasil evaluasi model matriks berdasarkan metrik *accuracy* (A), *precision* (P) dan *recall* (R). Tabel 1 juga menunjukkan bahwa model *MobileNetV2* memiliki sensitivitas penuh terhadap kelas *non-biodegradable* pada data uji (*recall* = 100%; *FN* = 0), tetapi masih menghasilkan 15 kasus *false positive* (*biodegradable* yang salah terklasifikasi sebagai *non-biodegradable*). *MobileNetV3-Large* menampilkan performa yang jauh lebih rendah pada konfigurasi dan *dataset* ini (*accuracy* = 67.35%, *recall* = 57.72%), yang mengindikasikan bahwa pada setup pelatihan dan *hyperparameter* yang digunakan, arsitektur tersebut kurang berhasil mempelajari pola yang relevan untuk kumpulan data *BDWaste*.




Gambar 5. Confusion Matrix MobileNetV2

Model *hybrid* (*MobileNetV2* + *XGBoost*) menunjukkan performa paling stabil di antara ketiganya, yang mempertahankan *recall* = 100% sambil menurunkan jumlah *false positive* menjadi 13 dan meningkatkan *TN* dari 107 menjadi 109, sehingga menghasilkan kenaikan metrik presisi dan *F1* secara kecil namun konsisten (*precision* = 90.44%, *F1-score* = 94.98%, *accuracy* = 94.69%). Perbaikan ini menunjukkan bahwa, pada representasi fitur yang sama, pengklasifikasi berbasis boosting cenderung memperbaiki diskriminasi lintas-kelas dibandingkan *classifier fully connected* pada eksperimen ini.



Gambar 6. Confusion Matrix MobileNetV3



Gambar 7. Confusion Matrix Hybrid (MobileNetV2 + XGBoost)

Tabel 2. Hasil Komputasi Model

Model	Model Size	Training Time
MobileNetV2	24.697 KB	2670 detik
MobileNetV3-Large	24.086 KB	2675 detik
Hybrid (MobileNetV2 - XGBoost)	150 KB	127 detik

Tabel 2 menunjukkan perbandingan ukuran model (*model size*) dan waktu pelatihan (*training time*) dari ketiga pendekatan yang telah diuji. Berdasarkan hasil pengukuran MobileNetV2 dan MobileNetV3-Large memiliki *model size* dan *training time* yang serupa, masing-masing sebesar 24.697 KB dan 24.086 KB untuk ukuran model, serta waktu pelatihan sebesar 2670 detik dan 2675 detik.

Sebaliknya, pendekatan *hybrid* (MobileNetV2 + XGBoost) menunjukkan perbedaan yang signifikan dari sisi komputasi dengan ukuran yang tercatat sebesar 150 KB dengan waktu pelatihan 127 detik. Dibandingkan dengan MobileNetV2, model *hybrid* memiliki ukuran model 99,39% lebih kecil serta waktu pelatihan 95,24% lebih cepat. Perbedaan ini menunjukkan bahwa optimisasi berbasis boosting memiliki kompleksitas pelatihan yang lebih rendah dibandingkan pendekatan berbasis jaringan saraf pada konfigurasi yang digunakan.

5. KESIMPULAN DAN SARAN

Penelitian ini membandingkan performa antar 3 skema model yaitu MobileNetV2, MobileNetV3, dan *hybrid* (MobileNetV2 + XGBoost) untuk mengklasifikasi gambar sampah secara mudah terurai (*biodegradable*) dan yang tidak mudah terurai (*non-biodegradable*). Hasil eksperimen menunjukkan bahwa skema model *hybrid* memberikan performa yang lebih baik dibandingkan skema yang lain dengan akurasi sebesar 94,69% dengan *model size* yang lebih kecil yaitu 150 KB dan *training time* sebesar 127 detik.

DAFTAR PUSTAKA

- [1] L. J. J. Meijer, T. Van Emmerik, R. Van Der Ent, C. Schmidt, and L. Lebreton, "More than 1000 rivers account for 80% of global riverine plastic emissions into the ocean," *Sci. Adv.*, vol. 7, no. 18, pp. 1–14, 2021, doi: 10.1126/sciadv.aaz5803.
- [2] Badan Pusat Statistik, "Statistik Lingkungan Hidup Indonesia 2025," 2025.
- [3] M. A. Latief, M. Rasikh, A. Riyyasy, F. Z. Ulya, L. Puspita, G. Claudia, and L. R. Nabila, "Klasifikasi bahan Biodegradable dan Non-Biodegradable menggunakan Convolutional Neural Network (CNN)," *Satuan Tulisan Ris. dan Inov. Teknol.*, vol. 8, no. 3, pp. 348–354, 2024, doi: 10.30998/string.v8i3.19314.
- [4] M. Sandler, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: inverted residuals and linear bottlenecks," *Int. Conf. Comput. Vis.*, pp. 4510–4520, 2018, doi: 10.1109/CVPR.2018.00474.
- [5] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Adreetto, and H. Adam, "MobileNets: efficient Convolutional Neural Networks for mobile vision applications," pp. 1–9, 2017, doi: 10.48550/arXiv.1704.04861.
- [6] W. Rahman, M. Akter, and N. Sultana, "BDWaste: A comprehensive image dataset of digestible and indigestible waste in," *Data Br.*, vol. 53, pp. 1–19, 2024, doi: 10.1016/j.dib.2024.110153.
- [7] S. Sathyanarayanan and B. R. Tantri, "Confusion matrix-based performance evaluation metrics," *African J. Biomed. Res.*, vol. 27, no. 4, 2024, doi: 10.53555/AJBR.v27i4S.4345.
- [8] A. Howard, W. Wang, G. Chu, L. Chen, B. Chen, M. Tan, W. Wang, Y. Zhu, R. Pang, V. Vasudevan, Q. V. Le, and H. Adam, "Searching for MobileNetV3," *Int. Conf. Comput. Vis.*, pp. 1314–1324, 2019, doi: 10.1109/ICCV.2019.00140.
- [9] Y. Zhao, H. Huang, Z. Li, H. Yiwang, and M. Lu, "Intelligent garbage classification system based on improve MobileNetV3-Large," *Conn. Sci.*, vol. 34, no. 1, pp. 1299–1321, 2022, doi: 10.1080/09540091.2022.2067127.
- [10] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System," *Assoc. Comput. Mach.*, pp. 785–794, 2016, doi: 10.1145/2939672.2939785.
- [11] M. N. Suryanooradja, A. D. Rahajoe, A. Junaidi, and K. Surabaya, "Hybrid MobileNetV2 dan Extreme Gradient Boosting untuk klasifikasi kerusakan bangunan," *J. Inform. dan Tek. Elektro Terap.*, vol. 13, no. 3, pp. 402–412, 2025, doi: 10.23960/jitet.v13i3.6858.
- [12] L. Yong, L. Ma, D. Sun, and L. Du Id, "Application of MobileNetV2 to waste classification," *PLoS One*, vol. 18, no. 3, pp. 1–16, 2023, doi: 10.1371/journal.pone.0282336.
- [13] I. N. Yulita, F. Ardiansyah, A. S. Prabuwo, M. R. Ramdhani, M. A. Wicaksono, A. Trisanto, and A. Sholahuddin, "Recyclable waste classification using SqueezeNet and XGBoost," *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 10, pp. 345–352, 2023, doi: 10.14569/IJACSA.2023.0141037.
- [14] W. Jiao, X. Hao, and C. Qin, "The image classification method with CNN-XGBoost model based on Adaptive Particle Swarm Optimization," *Information*, vol. 12, no. 4, pp. 1–22, 2021, doi: 10.3390/info12040156.
- [15] M. Zivkovic, N. Bacanin, M. Antonijevic, B. Nikolic, and G. Kvascev, "Hybrid CNN and XGBoost Model Tuned by Modified Arithmetic Optimization Algorithm for COVID-19 Early Diagnostics from X-ray Images," *Electronics*, vol. 11, no. 22, p. 30, 2022, doi: 10.3390/electronics11223798.