

EFISIENSI PEMILAHAN SAMPAH DAUR ULANG BERBASIS ANDROID MENGGUNAKAN MODEL CNN SSD-MOBILENET V2

Ari Asmawati¹, Yusuf Kurniawan^{*2}, Rizki Nur Fadilah³

¹Program Studi Sains Data, Fakultas Sains dan Teknologi, Universitas Raharja

^{2,3}Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Raharja

E-mail: ariasmawati@raharja.info¹, yusuf.kurniawan@raharja.info^{*2},

rizki.nur@raharja.info³

Abstrak

Kurangnya kesadaran masyarakat dalam memilah sampah merupakan salah satu kendala utama dalam pengelolaan sampah yang berkelanjutan. Sampah yang seharusnya dapat didaur ulang sering kali tercampur di Tempat Pembuangan Akhir (TPA), sehingga mengurangi nilai ekonomis dan memperburuk pencemaran lingkungan. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi sampah otomatis berbasis teknologi deteksi objek menggunakan arsitektur SSD-MobileNet V2 yang efisien dan ringan, sehingga dapat berjalan optimal pada perangkat Android. Model dilatih menggunakan 2.536 gambar sampah daur ulang yang telah dianotasi serta diperkuat melalui teknik augmentasi data. Evaluasi dilakukan dengan menggunakan metrik mean Average Precision (mAP) dan akurasi per kategori. Hasil pelatihan menunjukkan bahwa sistem mampu mengenali berbagai jenis sampah daur ulang dengan akurasi tertinggi sebesar 99% pada tutup botol plastik, dan akurasi terendah sebesar 86% pada kaleng logam. Nilai mAP keseluruhan yang dicapai adalah 87,62%. Model ini juga telah dioptimalkan dalam format TensorFlow Lite untuk mendukung deteksi real-time pada aplikasi Android. Hasil ini menunjukkan bahwa pendekatan yang diusulkan berpotensi menjadi solusi praktis dalam mendukung proses pemilahan sampah secara cerdas dan berkelanjutan.

Kata Kunci—SSD, MobileNet V2, Deteksi Objek, Pemilahan Sampah, Deep Learning

Abstract

The lack of public awareness in sorting waste remains one of the primary obstacles in achieving sustainable waste management. Recyclable waste is often mixed at the Final Disposal Site (TPA), reducing its economic value and worsening environmental pollution. This study aims to develop an automatic waste classification system based on object detection technology using the efficient and lightweight SSD-MobileNet V2 architecture, optimized for Android devices. The model was trained on 2,536 annotated images of recyclable waste and enhanced using data augmentation techniques. Evaluation was conducted using the mean Average Precision (mAP) metric and per-category accuracy. The training results show that the system can accurately recognize various types of recyclable waste, achieving the highest accuracy of 99% on plastic bottle caps and the lowest accuracy of 86% on metal cans. The overall mAP achieved was 87.62%. The model was also optimized in TensorFlow Lite format to support real-time detection within an Android application. These results indicate that the proposed approach has strong potential as a practical solution to support intelligent and sustainable waste sorting practices.

Keywords—Single Shot Detector (SSD), MobileNet V2, Object Detection, Waste Classification, Deep Learning

1. PENDAHULUAN

Permasalahan sampah merupakan isu lingkungan yang semakin mendesak di berbagai negara, termasuk Indonesia. Berdasarkan data dari Kementerian Lingkungan Hidup dan Kehutanan Republik Indonesia, timbulan sampah nasional pada tahun 2024 mencapai sekitar 34 juta ton, dengan komposisi utama terdiri dari 20% sampah plastik dan 11% sampah kertas atau karton [1]. Peningkatan volume sampah setiap tahunnya belum diimbangi oleh sistem pengelolaan yang efektif, sehingga berdampak pada pencemaran tanah, air, dan udara. Selain itu, pengelolaan sampah yang tidak optimal turut berkontribusi terhadap penurunan kualitas hidup masyarakat serta meningkatnya risiko kesehatan publik. Di sisi lain, masih banyak potensi sumber daya yang terbuang karena sampah yang seharusnya dapat didaur ulang justru tidak terkelola dengan baik.

Salah satu faktor utama yang menghambat pengelolaan sampah adalah rendahnya kesadaran dan pemahaman masyarakat dalam melakukan pemilahan sampah. Sampah yang masih memiliki nilai guna kerap bercampur di Tempat Pembuangan Akhir (TPA), sehingga menurunkan potensi daur ulang dan memperparah dampak ekologis. Oleh karena itu, diperlukan pendekatan yang adaptif dan berbasis teknologi yang dapat diterapkan secara langsung oleh masyarakat luas.

Penelitian yang dilakukan oleh Fahrurroji et al. mengemukakan bahwa permasalahan sampah merupakan isu global yang memerlukan solusi pengelolaan yang efektif, khususnya di negara berkembang seperti Indonesia. Salah satu solusi yang diusulkan adalah melalui implementasi bank sampah, yang menuntut adanya sistem pendataan real-time yang bersifat transparan. Teknologi berbasis *Convolutional Neural Network* (CNN), khususnya arsitektur MobileNet, memungkinkan prediksi citra sampah dengan tingkat akurasi yang tinggi pada perangkat bergerak, yaitu mencapai 96% untuk kategori sampah logam dan 72% untuk plastik. Meskipun demikian, *model* ini masih menghadapi kendala dalam mengenali objek dengan bentuk yang serupa maupun pada citra yang kompleks [2].

Studi yang dilakukan oleh Astuti et al. menunjukkan bahwa *model* deteksi objek berbasis SSD-MobileNet memiliki kinerja yang baik dalam mendeteksi daun semanggi secara real-time melalui kamera webcam. Metode yang digunakan memanfaatkan TensorFlow Object Detection serta arsitektur *CNN-SSD* untuk proses ekstraksi fitur dan klasifikasi citra. Prosedur penelitian mencakup tahapan akuisisi data, preprocessing, pelatihan dan pembentukan *model*, serta pengujian. Hasil terbaik diperoleh pada pembagian data latih dan uji dengan rasio 80:20, yang menghasilkan nilai precision sebesar 80%, recall 100%, dan akurasi sebesar 86,6% [3].

Penelitian yang dilakukan oleh Holiyanti et al. membuktikan bahwa metode *Convolutional Neural Network* (CNN) mampu menjalankan tugas deteksi objek secara efektif dalam mengidentifikasi jenis sampah seperti kardus, kaca, dan logam. Sistem yang dikembangkan memanfaatkan dataset citra dan berhasil mencapai tingkat akurasi hingga 96% dalam klasifikasi sampah logam. Pendekatan ini mendukung proses klasifikasi otomatis dan telah berhasil diimplementasikan melalui platform berbasis web [4].

Nugraha et al. menyatakan bahwa peningkatan efisiensi dalam proses pemilahan sampah merupakan aspek penting dalam upaya pelestarian lingkungan. Penelitian tersebut menawarkan solusi berupa sistem klasifikasi sampah yang berbasis algoritma *Convolutional Neural Network* (CNN) dan terintegrasi dengan platform web. Sistem ini dilengkapi dengan fitur unggah gambar serta kemampuan klasifikasi secara real-time melalui kamera, yang memungkinkan pengguna mengenali jenis sampah dengan tingkat akurasi mencapai 84,46%. Pendekatan ini tidak hanya mendorong praktik pemilahan yang lebih cerdas dan efisien, tetapi juga membuka peluang untuk pengembangan sistem ke dalam kategori sampah yang lebih beragam di masa mendatang [5].

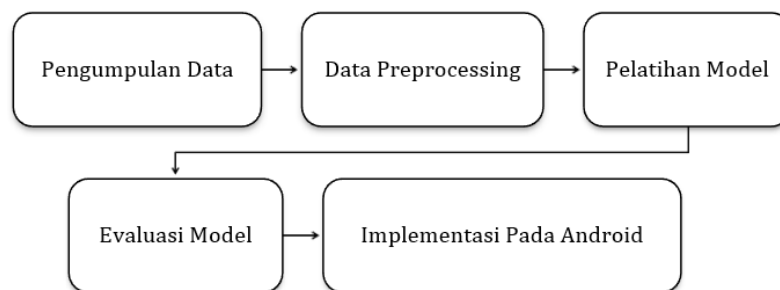
Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan sistem klasifikasi sampah daur ulang berbasis Android menggunakan *model* CNN SSD-MobileNet V2. Sistem ini dioptimalkan dalam format TensorFlow Lite agar dapat berjalan secara efisien di perangkat Android dengan sumber daya terbatas. Diharapkan, sistem ini

mampu mendukung proses pemilahan sampah secara otomatis, akurat, dan real-time serta dapat diimplementasikan secara luas oleh masyarakat.

Tujuan utama dari penelitian ini adalah mengembangkan dan menerapkan solusi pemilahan sampah berbasis teknologi ringan dan responsif, yang dapat meningkatkan efektivitas daur ulang dan mendukung edukasi masyarakat terhadap pentingnya pengelolaan sampah berkelanjutan.

2. METODE PENELITIAN

Penelitian ini bertujuan untuk merancang dan mengembangkan sistem pemilahan sampah otomatis berbasis *model* deteksi objek SSD-MobileNet V2 yang efisien dan kompatibel dengan perangkat berbasis Android. Proses penelitian dilaksanakan melalui beberapa tahapan utama, yaitu pengumpulan data, data preprocessing, pelatihan *model*, evaluasi hasil, serta implementasi pada Android. Tahapan sistematis dari keseluruhan proses tersebut disajikan secara visual dalam Diagram Alur pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

Pengumpulan Data

Data yang digunakan dalam penelitian ini terdiri dari 2.536 gambar sampah daur ulang yang telah dianotasi secara manual dengan *bounding box* dan label kelas objek, mencakup kategori seperti botol plastik, gelas plastik, kaleng aluminium, kaleng logam, kardus rongsok, kardus, kaca bening, kaca berwarna, dan tutup botol.

Untuk meningkatkan performa *model* dalam mengenali objek secara akurat, dilakukan proses augmentasi gambar menggunakan berbagai teknik seperti rotasi, pembalikan horizontal, penyesuaian pencahayaan, dan *zooming*. Penggabungan berbagai sumber dataset yang beragam bertujuan untuk memperluas cakupan data pelatihan, meningkatkan generalisasi *model* terhadap variasi objek di dunia nyata, serta mendukung upaya pemerintah dalam pengelolaan dan klasifikasi sampah secara cerdas [6].

Data Preprocessing

Proses preprocessing data dilakukan dengan membagi *dataset* menjadi tiga bagian menggunakan metode stratifikasi, yaitu teknik pembagian data yang mempertahankan proporsi jumlah data pada setiap kelas agar tetap seimbang dalam masing-masing subset. Keberhasilan penerapan *deep learning* sangat bergantung pada ketersediaan dan jumlah data yang digunakan dalam proses pelatihan jaringan saraf. Dataset, dalam hal ini, merupakan sekumpulan data terstruktur yang digunakan sebagai dasar pelatihan model *deep learning* untuk membentuk kemampuan prediktif yang akurat [7]. *Dataset* tersebut dibagi dengan komposisi 70% untuk data pelatihan (*training*), 15% untuk data validasi (*validation*), dan 15% untuk data pengujian (*testing*).

Pendekatan ini diterapkan guna memastikan bahwa *model* memperoleh distribusi data yang representatif selama proses pelatihan, serta mampu diuji secara objektif pada data yang tidak pernah dilihat sebelumnya. Dengan demikian, *model* diharapkan dapat menghasilkan performa yang lebih general dan reliabel dalam melakukan klasifikasi sampah daur ulang.

Pelatihan Model

Model yang diimplementasikan dalam penelitian ini adalah *Single Shot Multibox Detector-MobileNet V2* (SSD-MobileNet V2), sebuah arsitektur *object detection* yang dikenal karena karakteristiknya yang ringan dan memiliki kecepatan inferensi tinggi. Model ini dirancang untuk dapat berjalan secara optimal pada perangkat dengan keterbatasan sumber daya, seperti smartphone. MobileNet sendiri merupakan bagian dari keluarga *Convolutional Neural Network (CNN)* yang telah terintegrasi secara langsung dalam *TensorFlow Object Detection API*, sehingga mempermudah pengembang dalam membangun sistem deteksi objek yang efisien dan mudah diimplementasikan [8].

Proses pelatihan dilakukan menggunakan platform Google Colaboratory (Google Colab), yaitu lingkungan pemrograman berbasis cloud yang menyerupai Jupyter Notebook. Platform ini memungkinkan pengguna menjalankan skrip *Python* tanpa memerlukan instalasi lokal, serta menyediakan akses ke GPU/TPU secara gratis, yang sangat mendukung pelatihan *model deep learning* berskala besar [9]. Dalam penelitian ini, pelatihan *model* dilakukan menggunakan parameter utama berupa jumlah langkah (*training steps*) sebanyak 40.000 dan ukuran *batch* sebesar 16 gambar per iterasi.

Evaluasi Model

Evaluasi kinerja model dilakukan dengan menggunakan metrik *mean Average Precision (mAP)*, yang berfungsi untuk mengukur tingkat ketepatan prediksi terhadap objek dalam citra. *Mean Average Precision* mencerminkan seberapa akurat *model* dalam memprediksi posisi dan kelas objek melalui *bounding box*, jika dibandingkan dengan *ground truth* atau anotasi referensi yang sebenarnya [10].

Proses evaluasi dilakukan terhadap data validasi dan data pengujian dengan berbagai nilai ambang batas *Intersection over Union (IoU)*. *Intersection over Union (IoU)* merupakan fungsi loss yang umum digunakan dalam analisis batas objek, karena mampu mengukur tingkat tumpang tindih antara kotak prediksi dengan kotak acuan (*ground truth*) dalam tugas deteksi objek [11]. Penggunaan IoU memungkinkan evaluasi menyeluruh terhadap tingkat kesalahan prediksi model. Untuk memperoleh nilai *mean Average Precision (mAP)*, langkah pertama yang dilakukan adalah menghitung nilai *Average Precision (AP)* untuk masing-masing kelas yang berhasil terdeteksi. Selanjutnya, nilai *mAP* diperoleh dari rata-rata semua nilai *Average Precision (AP)* yang telah dihitung.

Adapun rumus umum untuk menghitung *mAP* adalah sebagai berikut:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (1)$$

di mana:

N adalah jumlah total kelas objek,

AP_i adalah nilai *Average Precision* pada kelas ke- i .

Implementasi Pada Android

Setelah proses pelatihan dan evaluasi *model* selesai dilakukan, langkah selanjutnya adalah melakukan optimasi *model* agar dapat dijalankan secara efisien pada perangkat berbasis Android. Tahap optimasi ini mencakup konversi *model* ke dalam format *TensorFlow Lite*, yang dirancang khusus untuk aplikasi *machine learning* di perangkat dengan sumber daya terbatas. Penggunaan *TensorFlow Lite* memungkinkan proses konversi model klasifikasi citra agar dapat dijalankan secara efisien pada perangkat Android, dengan waktu inferensi yang singkat dan konsumsi sumber daya yang minimal, sehingga mendukung implementasi sistem klasifikasi secara real-time [12]. Proses ini bertujuan untuk mengurangi ukuran *model* dan mempercepat waktu inferensi tanpa mengorbankan akurasi secara signifikan.

Setelah model dikonversi ke *TensorFlow Lite*, metadata ditambahkan untuk menyimpan informasi penting seperti label kelas dan ukuran input. Metadata ini memudahkan integrasi dengan aplikasi Android agar model dapat digunakan untuk deteksi dan klasifikasi gambar

secara real-time langsung dari perangkat [13]. Penambahan *metadata* ini bertujuan agar *model* dapat dikenali dan digunakan secara optimal oleh aplikasi Android, termasuk dalam proses pemetaan hasil prediksi ke label yang sesuai.

Model yang telah dioptimalkan dan dilengkapi dengan *metadata* kemudian diintegrasikan ke dalam aplikasi Android, sehingga mampu mendukung proses klasifikasi sampah secara otomatis dan *real-time*.

3. HASIL DAN PEMBAHASAN

Penelitian ini menghasilkan sistem klasifikasi citra untuk pemilahan sampah daur ulang dengan menggunakan *model* SSD-MobileNet V2. Proses pengembangan dilakukan melalui tahapan pengumpulan data, data preprocessing, pelatihan *model*, evaluasi *model*, serta implementasi pada Android. Setiap tahapan berkontribusi terhadap peningkatan akurasi dan efisiensi sistem. Hasil akhir menunjukkan performa klasifikasi yang tinggi dan mendukung deteksi secara real-time.

Pengumpulan Data

Proses pengumpulan data telah berhasil dilakukan dengan memperoleh total sebanyak 2.536 gambar, di mana setiap gambar telah dianotasi menggunakan *bounding box* dan dilengkapi dengan label kelas masing-masing. Gambar-gambar tersebut mencakup beragam jenis sampah daur ulang, antara lain botol plastik, gelas plastik, kaleng aluminium, kaleng logam, kardus rongsok, kardus, kaca bening, kaca berwarna, dan tutup botol.

Untuk memperkaya keragaman data dan meningkatkan kemampuan generalisasi *model*, dilakukan penerapan berbagai teknik *augmentasi*, seperti rotasi, pembalikan horizontal (*horizontal flipping*), perbesaran (*zoom*), serta penyesuaian intensitas pencahayaan. Teknik *augmentasi* ini terbukti efektif dalam memperluas distribusi visual objek pada *dataset*, sehingga memungkinkan *model* untuk lebih adaptif terhadap variasi posisi dan kondisi pencahayaan pada saat proses pengujian.

Data Preprocessing

Tahap *data preprocessing* dilakukan dengan membagi dataset menggunakan metode *stratified split*, guna menjaga proporsi kelas yang seimbang dalam setiap subset. Metode *stratified split* memastikan bahwa setiap kelas terwakili secara proporsional dalam dataset pelatihan, meskipun tidak menjamin jumlah sampel yang sama untuk setiap kelas kecuali tidak terdapat ketidakseimbangan data [14].

Adapun komposisi data yang dihasilkan dari proses ini adalah sebagai berikut:

- 1.770 gambar (70%) untuk data pelatihan,
- 381 gambar (15%) untuk data validasi,
- 384 gambar (15%) untuk data pengujian.


Distribusi kelas yang merata pada setiap bagian dataset sangat penting untuk menghindari bias pada *model* terhadap kelas tertentu. Dengan demikian, *model* diharapkan mampu melakukan generalisasi secara lebih optimal ketika dihadapkan pada data baru yang belum pernah dilihat sebelumnya.

Hasil Pelatihan Model

Model yang digunakan dalam proses pelatihan ini adalah *Single Shot Multibox Detector* (SSD) dengan *backbone* *MobileNet V2*. *Dataset* pelatihan terdiri dari 1.775 gambar yang telah dianotasi, mencakup sembilan kategori sampah daur ulang, yaitu: botol plastik, gelas plastik, kaleng aluminium, kaleng logam, kardus rongsok, kardus, kaca bening, kaca berwarna, dan tutup botol.

Proses pelatihan dilakukan selama 40.000 langkah (*step*) dengan *batch size* sebanyak 16 gambar per iterasi. Selama pelatihan, *model* secara bertahap belajar mengenali pola dan fitur visual dari setiap kelas objek melalui optimasi parameter jaringan.

Hasil pelatihan divisualisasikan dalam bentuk grafik sebagai berikut:



(a)

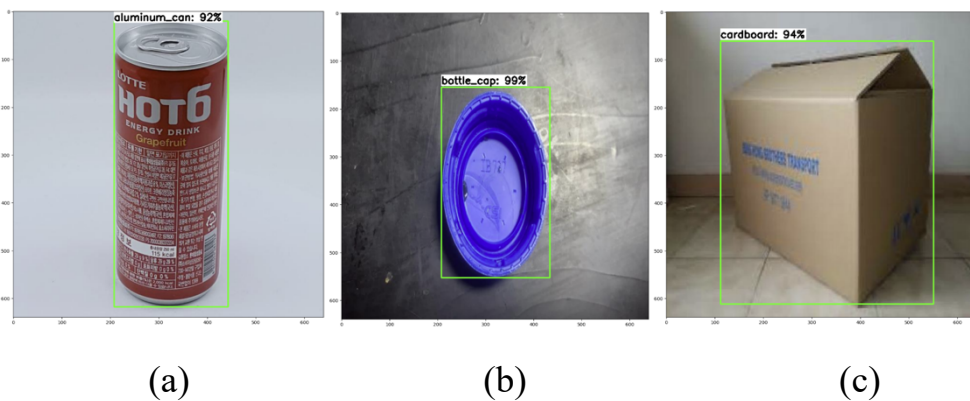
(b)

Gambar 2. Grafik a) *learning rate* dan b) *total loss* selama proses *training*

Pada grafik *total loss* dan *learning rate* selama proses pelatihan, ditunjukkan adanya hubungan erat antara keduanya dalam memengaruhi performa *model*. *Learning rate* merupakan parameter penting yang mengatur sejauh mana *model* melakukan penyesuaian terhadap bobot selama proses pelatihan [15]. Pada tahap awal pelatihan, penggunaan *learning rate* yang relatif tinggi menyebabkan *total loss* menurun dengan cepat, meskipun cenderung fluktuatif. Hal ini mencerminkan proses pembelajaran awal yang agresif dan eksploratif.

Seiring bertambahnya jumlah *training step*, *learning rate* secara bertahap diturunkan melalui mekanisme *scheduler*. Penurunan ini membuat proses pembelajaran menjadi lebih stabil dan terarah. Setelah melewati sekitar 10.000 *step*, *learning rate* yang semakin kecil memungkinkan *model* melakukan penyesuaian bobot secara lebih hati-hati. Hal ini ditunjukkan dengan penurunan *total loss* yang semakin stabil dan mendekati konvergensi dinilai rendah, tanpa indikasi *overfitting* yang signifikan. *Overfitting* terjadi ketika sebuah *model* memiliki kapasitas yang terlalu besar sehingga mampu menghafal data pelatihan secara menyeluruh termasuk terhadap *noise* atau anomali, sehingga mengurangi kemampuannya dalam melakukan generalisasi terhadap data baru [16].

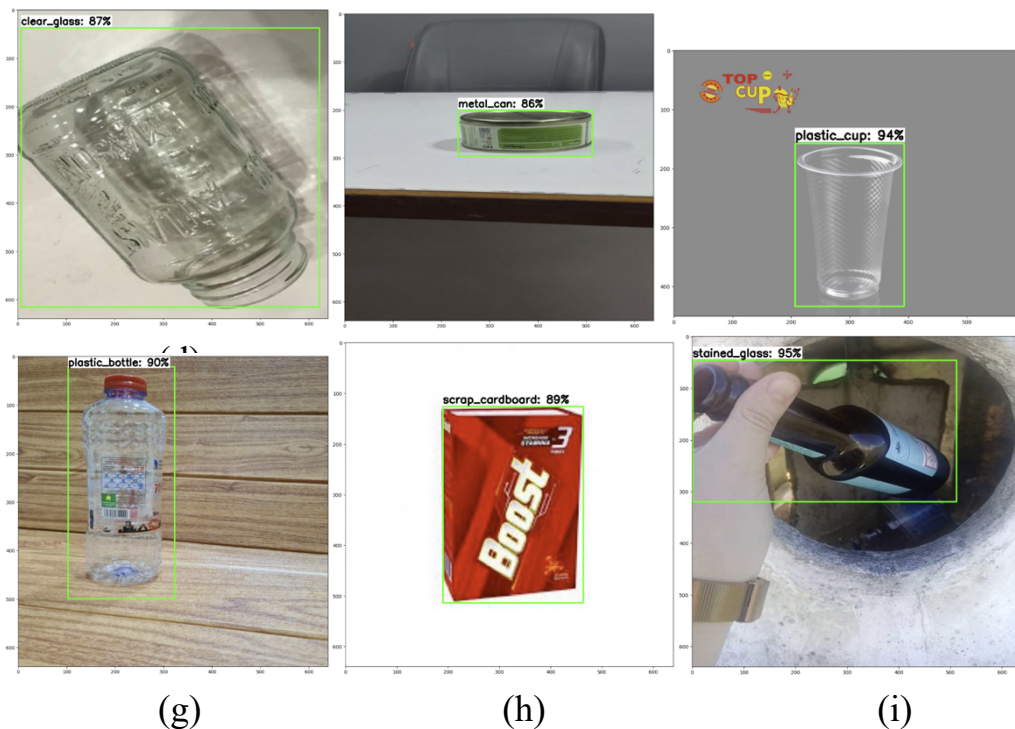
Kombinasi antara penurunan *learning rate* secara bertahap dan stabilitas *total loss* menunjukkan bahwa strategi pengaturan *learning rate* berperan penting dalam meningkatkan efektivitas dan kestabilan pelatihan *model* secara keseluruhan. Selanjutnya, Gambar 2 menampilkan hasil akurasi klasifikasi untuk masing-masing kategori sampah daur ulang.



(a)

(b)

(c)



Gambar 3. Gambar dari berbagai macam sampah daur ulang a) *aluminum_can*, b) *bottle_cap*, c) *cardboard*, d) *clear_glass*, e) *metal_can*, f) *plastic_cup*, g) *plastic_bottle*, h) *scrap_cardboard*, i) *stained_glass*.

Berdasarkan gambar di atas, sistem berhasil mengenali berbagai jenis sampah daur ulang dengan tingkat akurasi yang tinggi. Kaleng aluminium terdeteksi sebagai *aluminum_can* dengan akurasi 92%, tutup botol plastik sebagai *bottle_cap* (99%), kardus sebagai *cardboard* (94%), dan toples kaca bening sebagai *clear_glass* (87%). Selain itu, kaleng logam dikenali sebagai *metal_can* (86%), gelas plastik sebagai *plastic_cup* (94%), dan botol plastik sebagai *plastic_bottle* (90%). Potongan kardus bekas diklasifikasikan sebagai *scrap_cardboard* dengan akurasi (89%), sedangkan botol kaca berwarna terdeteksi sebagai *stained_glass* dengan akurasi (95%). Hasil ini menunjukkan bahwa *model* deteksi objek yang digunakan mampu mengidentifikasi berbagai jenis sampah daur ulang dengan cukup akurat, sehingga dapat mendukung proses pemilahan sampah secara otomatis dan *real-time* pada aplikasi Android.


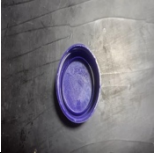



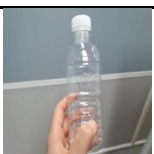



Secara keseluruhan, *model* menunjukkan performa yang memuaskan dalam proses klasifikasi gambar sampah daur ulang. Meski demikian, performa *model* masih dapat ditingkatkan lebih lanjut, misalnya dengan menambah jumlah data pelatihan atau menyesuaikan parameter pelatihan untuk memperoleh hasil yang lebih optimal.

Evaluasi Model

Evaluasi performa *model* dilakukan menggunakan metrik *mean Average Precision (mAP)*, yang merupakan ukuran utama dalam menilai akurasi deteksi objek berdasarkan ketepatan posisi dan klasifikasi objek. *mAP* dihitung dari rata-rata nilai *Average Precision (AP)* untuk setiap kelas objek, berdasarkan hasil prediksi terhadap *bounding box* yang dibandingkan dengan *ground truth*.

Model ini menunjukkan perbedaan performa akurasi pada pengujian awal dengan nilai *Intersection over Union (IoU)* yang lebih rendah, di mana nilai akurasi terlihat tinggi namun tidak merepresentasikan ketepatan posisi yang akurat. Oleh karena itu, dilakukan evaluasi lebih lanjut dengan ambang *Intersection over Union (IoU)* yang lebih tinggi untuk mendapatkan gambaran yang lebih objektif terhadap kemampuan deteksi spasial *model*.

Tabel 1. Hasil *Intersection over Union (IoU)* untuk setiap *class* dan total *mAP* nya

Class	Gambar	IoU 0.5
aluminum_can		84.99%
bottle_cap		100.00%
cardboard		83.79%
clear_glass		72.78%
metal_can		81.10%
plastic_bottle		95.53%
plastic_cup		92.50%
scrap_cardboard		77.89%
stained_glass		100.00%
Total mAP		87.62%

Hasil evaluasi menunjukkan bahwa model mencapai nilai *mean Average Precision (mAP)* sebesar 87,62%, yang mengindikasikan kemampuan deteksi dan klasifikasi objek dengan tingkat presisi dan akurasi yang tinggi. *Model* memberikan performa optimal pada objek berukuran sedang, seperti botol plastik dan kaleng logam.

Namun demikian, meskipun *model* menunjukkan performa tinggi pada beberapa kelas seperti *bottle_cap* dan *stained_glass* dengan akurasi mencapai 100%, terdapat penurunan akurasi pada objek seperti *clear_glass* (72,78%) dan *scrap_cardboard* (77,89%). Penurunan ini diduga disebabkan oleh karakteristik visual yang kompleks, seperti kemiripan warna atau tekstur antara objek dan latar belakangnya, yang dapat mempersulit proses ekstraksi fitur secara tepat oleh *model*.

Implementasi Pada Android


Setelah proses pelatihan dan evaluasi diselesaikan, *model* deteksi objek kemudian dioptimalkan menggunakan *TensorFlow Lite* untuk memastikan efisiensi dalam penggunaannya pada perangkat Android. Optimasi ini berhasil menurunkan ukuran *model* secara signifikan tanpa mengorbankan performa akurasi secara berarti.

Sebagai bagian dari proses optimasi, metadata ditambahkan ke dalam *model* menggunakan *TensorFlow Lite Metadata Writer*. Informasi metadata yang dimasukkan mencakup nama *model*, versi, deskripsi fungsi, serta label dari setiap kelas objek yang dikenali. Penambahan metadata ini bertujuan untuk meningkatkan keterbacaan, kompatibilitas, dan interoperabilitas *model* ketika diintegrasikan ke dalam sistem aplikasi Android, sehingga memudahkan pengembangan dan pemeliharaan sistem di masa mendatang.

Model yang telah dioptimalkan tersebut selanjutnya diintegrasikan ke dalam aplikasi Android untuk mendukung proses pemilahan sampah secara otomatis dan *real-time*. Pengujian dilakukan menggunakan perangkat *Xiaomi 11T*, yang memiliki spesifikasi prosesor tinggi dan dukungan GPU yang baik. Hasil pengujian menunjukkan bahwa *model* mampu melakukan proses inferensi dengan kecepatan rata-rata 50–150 milidetik per gambar, serta secara akurat mendeteksi beberapa objek daur ulang dalam satu *frame*. Hal ini menunjukkan bahwa sistem dapat berjalan dengan responsif dan efisien pada perangkat Android kelas menengah ke atas.



Gambar 4. Tampilan aplikasi Android saat menjalankan proses deteksi objek secara langsung melalui kamera perangkat



Gambar 5. Tampilan aplikasi Android saat menjalankan proses deteksi objek dari foto yang diambil melalui galeri perangkat

Aplikasi ini menyediakan dua fitur utama untuk deteksi objek. Pertama, pengguna dapat melakukan deteksi secara langsung melalui kamera perangkat, sebagaimana ditunjukkan pada Gambar 4. Fitur ini memungkinkan deteksi sampah secara real-time di lingkungan nyata. Kedua, aplikasi juga menyediakan opsi untuk melakukan deteksi objek dari gambar yang diambil dari galeri, sebagaimana ditampilkan pada Gambar 5. Fitur ini berguna bagi pengguna yang ingin menguji atau menganalisis gambar yang telah tersimpan sebelumnya.

Implementasi ini menunjukkan potensi kuat sistem dalam membantu proses pemilahan sampah secara praktis, baik di tingkat rumah tangga, komunitas, maupun sektor industri kecil yang bergerak dalam pengelolaan limbah.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem pemilahan sampah daur ulang berbasis Android menggunakan *model* SSD-MobileNet V2 dengan akurasi tertinggi sebesar 99% pada tutup botol plastik, dan akurasi terendah sebesar 86% pada kaleng logam. Nilai mAP keseluruhan yang dicapai adalah 87,62%. Pembagian data secara stratifikasi (70% pelatihan, 15% validasi, 15% pengujian) berhasil menjaga keseimbangan distribusi kelas, sementara optimasi *model* ke format TensorFlow Lite memungkinkan inferensi real-time 150-200 milidetik per gambar pada perangkat Android. Meskipun demikian, studi ini memiliki beberapa keterbatasan, antara lain: jumlah data pelatihan yang relatif terbatas (2.536 gambar) dengan variasi latar belakang dan pencahayaan belum optimal, ruang lingkup klasifikasi hanya mencakup 9 jenis sampah daur ulang tanpa memasukkan kategori organik atau B3, serta akurasi yang masih rendah pada kelas tertentu seperti gelas bening dengan akurasi 72,78% dan kardus rongsok dengan akurasi 77,89% akibat kemiripan visual. Untuk penelitian lanjutan, direkomendasikan ekspansi dataset dengan kondisi lebih kompleks, penambahan kelas sampah baru (*e-waste*, organik), pengujian arsitektur alternatif (*YOLO*, *EfficientDet*), dan optimasi untuk perangkat low-end guna meningkatkan aplikabilitas sistem di masyarakat luas.

5. SARAN

Penulis merekomendasikan agar pengembangan sistem ke depan difokuskan pada perluasan dataset pelatihan dengan jumlah minimal 5.000 gambar, disertai variasi latar belakang kompleks dan kondisi pencahayaan yang beragam, guna meningkatkan kemampuan generalisasi model terhadap kondisi nyata. Selain itu, penambahan kategori sampah baru seperti sampah elektronik (e-waste), sampah medis, dan sampah organik dinilai penting untuk memperluas cakupan klasifikasi dan menjawab kebutuhan pengelolaan limbah secara lebih menyeluruh. Penulis juga menyarankan untuk menguji arsitektur Convolutional Neural Network (CNN) alternatif, seperti YOLO atau EfficientDet, serta menerapkan teknik transfer learning guna mengoptimalkan akurasi pada kelas dengan performa rendah, seperti kaca bening dan kardus rongsok. Di samping itu, penggunaan teknik data augmentation spesifik, misalnya random occlusion, diharapkan dapat membantu meningkatkan kemampuan model dalam mengenali objek dengan kemiripan fitur visual yang tinggi. Uji coba langsung oleh masyarakat di berbagai lingkungan operasional juga dianggap penting, agar sistem dapat diuji secara kontekstual dan memperoleh masukan langsung dari pengguna. Penulis juga menekankan pentingnya edukasi dan sosialisasi kepada masyarakat terkait pentingnya pemilahan sampah serta cara penggunaan aplikasi yang tepat, khususnya di kalangan sekolah, komunitas, dan rumah tangga. Akhirnya, untuk memastikan keberlanjutan dan perluasan dampak dari sistem yang dikembangkan, penulis menyarankan adanya kolaborasi aktif dengan instansi pemerintah, Dinas Lingkungan Hidup, serta komunitas pengelola bank sampah lokal agar sistem dapat terintegrasi dengan program pengelolaan sampah resmi di tingkat daerah.

DAFTAR PUSTAKA

- [1] Kementerian Lingkungan Hidup dan Kehutanan Republik Indonesia, 2024, Sistem Informasi Pengelolaan Sampah Nasional (SIPSN), <https://sipsn.menlhk.go.id/sipsn/public/data/komposisi> diakses tgl 8 Juni 2025.
- [2] A. R. Fahrurroji, M. Y. Wijaya, and I. Fauziah, "Implementasi Algoritma CNN MobileNet untuk Klasifikasi Gambar Sampah di Bank Sampah," *PROSISKO: Jurnal Pengembangan Riset Dan Observasi Sistem Komputer*, vol. 11, no. 1, pp. 45–51, 2024. <https://doi.org/10.30656/prosisko.v11i1.8101>
- [3] I. Astuti, W. W. Ariestya, and B. Solehudin, "Deteksi Objek Daun Semanggi Secara Real Time Menggunakan CNN-Single Shot Multibox Detector (SSD)," *Jurnal Ilmiah FIFO*, vol. 14, no. 1, pp. 47, 2022. <https://doi.org/10.22441/fifo.2022.v14i1.005>
- [4] R. Holiyanti, S. Wati, I. Fahmi, and C. Rozikin, "Pendeteksi Sampah Metal untuk Daur Ulang Menggunakan Metode Convolutional Neural Network," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 8, no. 1, 2022. <https://doi.org/10.28932/jutisi.v8i1.4492>
- [5] Z. I. Nugraha, A. Arnita, S. Kana Saputra, A. Setiawan, R. Maharani, and F. Zaharani, "Implementasi Algoritma CNN dalam Pengembangan Website untuk Klasifikasi Sampah Organik, dan Non-Organik," *Jurnal Manajemen Informatika dan Sistem Informasi*, vol. 8, no. 1, pp. 90–101, 2025. <https://doi.org/10.36595/misi.v8i1.1355>
- [6] M. I. B. Ahmed, R. B. Alotaibi, R. A. Al-Qahtani, R. S. Al-Qahtani, S. S. Al-Hetela, K. A. Al-Matar, N. K. Al-Saqer, A. Rahman, L. Saraireh, M. Youldash, and G. Krishnasamy, "Deep Learning Approach to Recyclable Products Classification: Towards Sustainable Waste Management," *Sustainability*, vol. 15, no. 14, pp. 11138, 2023. <https://doi.org/10.3390/su151411138>
- [7] Alzubaidi, L., Bai, J., Al-Sabaawi, A., Santamaría, J., Albahri, A. S., Al-dabbagh, B. S. N., Fadhel, M. A., Manoufali, M., Zhang, J., Al-Timemy, A. H., Duan, Y., Abdullah, A., Farhan, L., Lu, Y., Gupta, A., Albu, F., Abbosh, A., & Gu, Y., "A survey on deep learning tools dealing with data scarcity: Definitions, challenges, solutions, tips, and applications," *Journal of Big Data*, vol. 10, no. 1, pp. 46, 2023. <https://doi.org/10.1186/s40537-023-00727-2>

- [8] M. R. D. Ulhaq, M. A. Zaidan, and D. Firdaus, "Pengenalan Ekspresi Wajah Secara Real-Time Menggunakan Metode SSD Mobilenet Berbasis Android," *Journal of Technology and Informatics (JoTI)*, vol. 5, no. 1, pp. 48–52, 2023. <https://doi.org/10.37802/joti.v5i1.387>
- [9] Paper, D., 2021, *State-of-the-Art Deep Learning Models in TensorFlow: Modern Machine Learning in the Google Colab Ecosystem*, Apress, New York.
- [10] L. S. Riva and J. Jayanta, "Deteksi Penyakit Tanaman Cabai Menggunakan Algoritma YOLOv5 Dengan Variasi Pembagian Data," *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 8, no. 3, pp. 248–254, 2023. <https://doi.org/10.30591/jpit.v8i3.5679>
- [11] Mohammed, S. A. K., Razak, M. Z. A., Rahman, A. H. A., & Bakar, M. A., "An Efficient Intersection Over Union Algorithm for 3D Object Detection," *IEEE Access*, vol. 12, pp. 169768–169786, 2024. <https://doi.org/10.1109/ACCESS.2024.3495761>
- [12] Qusnur Aulia, S. N., "Image Classification untuk Telur Ayam Menggunakan Smartphone Android dengan Convolutional Neural Networks (CNN)," *BERNAS: Jurnal Pengabdian Kepada Masyarakat*, vol. 5, no. 2, pp. 1278–1285, 2024. <https://doi.org/10.31949/jb.v5i2.8187>
- [13] Suharjito, Elwirehardja, G. N., & Prayoga, J. S., "Oil palm fresh fruit bunch ripeness classification on mobile devices using deep learning approaches," *Computers and Electronics in Agriculture*, vol. 188, pp. 106359, 2021. <https://doi.org/10.1016/j.compag.2021.106359>
- [14] A. A. Khan, "Balanced Split: A New Train-Test Data Splitting Strategy for Imbalanced Datasets (Version 1)," *arXiv*, 2022. <https://doi.org/10.48550/ARXIV.2212.11116>
- [15] Y. Rayhan and A. P. Rifai, "Multi-class Waste Classification Using Convolutional Neural Network," *Applied Environmental Research*, 2024. <https://doi.org/10.35762/AER.2024021>
- [16] W. A. Firmansyach, U. Hayati, and Y. A. Wijaya, "Analisa Terjadinya Overfitting dan Underfitting pada Algoritma Naive Bayes dan Decision Tree dengan Teknik Cross Validation," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 1, pp. 262–269, 2023. <https://doi.org/10.36040/jati.v7i1.6329>