Implementasi *Convolutional Neural Network* (CNN) pada Aplikasi Android untuk Klasifikasi Jenis Sampah

W Windini[1], N B Nugraha[*2]

[1,2] Jurusan Teknik Informatika, Politeknik Negeri Indramayu

E-mail: windiniwindii@gmail.com[1], nurbudinugraha@polindra.ac.id[*2]

Abstrak. Permasalahan sampah yang terus meningkat menuntut adanya solusi cerdas dalam proses pemilahan dan pengelolaannya. Penelitian ini bertujuan untuk mengimplementasikan metode *Convolutional Neural Network* (CNN) menggunakan arsitektur MobileNetV2 pada aplikasi Android untuk mengklasifikasikan jenis sampah berbasis citra digital. Tahapan penelitian meliputi pengumpulan dan *screening* dataset, preprocessing citra, pelatihan model menggunakan *transfer learning, fine tuning,* serta konversi model ke format *TensorFlow Lite.* Aplikasi dikembangkan menggunakan *framework* Flutter dan mampu melakukan klasifikasi secara *on-device* melalui kamera maupun galeri perangkat. Model hasil pelatihan berhasil mencapai *validation accuracy* tertinggi sebesar 91,20% pada tahap *fine tuning.* Hasil evaluasi menunjukkan seluruh kelas memperoleh nilai *Area Under Curve* (AUC) di atas 0,97 yang menandakan kemampuan klasifikasi yang sangat baik. Model kemudian diimplementaskan pada perangkat Android menggunakan *TensorFlow Lite* dan mampu melakukan klasifikasi secara lokal tanpa koneksi internet dengan waktu pemrosesan rata-rata sekitar 5 detik. Hasil penelitian menunjukkan bahwa MobileNetV2 dapat diterapkan secara efektif pada aplikasi Android sebagai solusi praktis untuk membantu proses pemilahan sampah secara mandiri dan berpotensi mendukung edukasi serta proses identifikasi jenis sampah yang lebih berkelanjutan.

Kata kunci: MobileNetV2; *Convolutional Neural Network;* Klasifikasi Sampah; *TensorFlow Lite;* Android.

Abstract. *This research aims to implement a Convolutional Neural Network (CNN) method using the MobileNetV2 architecture in an Android application to classify types of waste based on digital images. The research stages included dataset collection and screening, image preprocessing, model training using transfer learning, fine-tuning, and model conversion to the TensorFlow Lite format. The application was developed using the Flutter framework and is capable of on-device classification via the device's camera or gallery. The trained model achieved a maximum validation accuracy of 91.20% during the fine-tuning stage. Evaluation results showed that all classes achieved an Area Under the Curve (AUC) value above 0.97, indicating excellent classification performance. The model was subsequently implemented on Android devices using TensorFlow Lite and is capable of performing classification locally without an internet connection, with an average processing time of approximately 5 seconds. The research results demonstrate that MobileNetV2 can be effectively applied in Android applications as a practical solution to assist with independent waste sorting and has the potential to support education and a more sustainable waste identification process.*

Keywords: MobileNetV2; *Convolutional Neural Network; Waste Classification; TensorFlow Lite;* Android.

1. Pendahuluan

Permasalahan sampah merupakan salah satu isu lingkungan yang terus meningkat seiring pertumbuhan jumlah penduduk dan aktivitas manusia. Semakin tinggi jumlah populasi, semakin besar pula volume sampah yang dihasilkan [1]. Peningkatan timbulan sampah yang tidak diimbangi dengan sistem pengelolaan yang efektif dapat menimbulkan berbagai dampak negatif terhadap lingkungan. Oleh karena itu, proses identifikasi dan pemilahan sampah menjadi salah satu langkah penting dalam mendukung pengelolaan sampah yang berkelanjutan [2].

Berdasarkan data Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) Kementerian Lingkungan Hidup dan Kehutanan (KLHK), persentase sampah yang belum terkelola di Indonesia masih mencapai sekitar 31,71% atau sekitar 10,1 juta ton [3]. Kondisi tersebut menunjukkan bahwa efektivitas pengelolaan sampah di tingkat operasional masih menghadapi berbagai tantangan sehingga diperlukan inovasi teknologi yang mampu meningkatkan efisiensi dan konsistensi proses pemilahan sampah [4].

Salah satu hambatan utama dalam pengelolaan sampah adalah proses pemilahan yang masih didominasi oleh metode manual. Metode tersebut sangat bergantung pada kesadaran, ketelitian, dan konsistensi manusia sehingga berpotensi menimbulkan kesalahan identifikasi dan menurunkan efektivitas pengelolaan sampah. Oleh karena itu, diperlukan sistem otomatis yang mampu melakukan identifikasi dan klasifikasi jenis sampah secara cepat, akurat, dan konsisten [5].

Perkembangan *Artificial Intelligence* (AI), khususnya pada bidang *Computer Vision* dan *Deep Learning*, memberikan peluang untuk mengotomatisasi proses identifikasi objek melalui citra digital. *Deep Learning* merupakan pengembangan dari *machine learning* yang memanfaatkan jaringan saraf tiruan berlapis untuk melakukan ekstraksi fitur secara otomatis dari data dalam jumlah besar [6]. Salah satu arsitektur yang paling banyak digunakan dalam pengolahan citra adalah *Convolutional Neural Network* (CNN), yang mampu mengenali pola visual seperti warna, tekstur, dan bentuk objek secara efektif [7].

Berbagai penelitian telah membuktikan efektivitas CNN dalam klasifikasi sampah berbasis citra. Thio dan Susilo mengembangkan sistem identifikasi sampah menggunakan pendekatan *transfer learning* dengan arsitektur MobileNetV2 dan EfficientNet-B0 yang menghasilkan performa klasifikasi yang baik [6]. Penelitian Yu dan Grammenos menerapkan *deep learning* untuk mendukung proses klasifikasi sampah pada sistem daur ulang cerdas dan menunjukkan pentingnya kualitas preprocessing citra terhadap performa model [1]. Muslihat et al., berhasil menerapkan CNN untuk klasifikasi sampah organik dan anorganik dengan tingkat akurasi yang tinggi [7]. Penelitian Purba et al., juga menunjukkan bahwa CNN mampu mengklasifikasikan sampah organik dan anorganik secara efektif menggunakan citra digital [8]. Selain itu, Hanif dan Arief membuktikan bahwa pendekatan *transfer learning* MobileNetV2 mampu mencapai performa yang lebih baik dibandingkan CNN yang dibangun dari awal [9].

Meskipun demikian, sebagian besar penelitian terdahulu masih berfokus pada evaluasi performa model secara langsung pada perangkat bergerak, khususnya Android, masih relatif terbatas. Selain itu, integrasi model *deep learning* ke dalam aplikasi yang mampu berjalan secara *real-time* dengan memanfaatkan *TensorFlow Lite* belum banyak dibahas secara komprehensif [11]. Kondisi tersebut menunjukkan adanya kesenjangan antara pengembangan model klasifikasi dan implementasi sistem yang siap digunakan oleh pengguna akhir [12].

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengimplementasikan algoritma *Convolutional Neural Network* menggunakan arsitektur MobileNetV2 pada aplikasi Android untuk mengklasifikasikan lima jenis sampah, yaitu kaca, kertas, logam, organik, dan plastik. Model yang telah dilatih dikonversi ke format *TensorFlow Lite* sehingga dapat dijalankan secara lokal pada perangkat

Android. Selain mengevaluasi performa model menggunakan metrik *accuracy, precision, recall, F1-score,* dan *Area Under Curve* (AUC) [13], penelitian ini juga menguji implementasi sistem pada perangkat Android melalui pengujian fungsional dan pengukuran waktu pemrosesan. Dengan adanya aplikasi ini diharapkan proses identifikasi dan pemilahan sampah dapat dilakukan secara lebih cepat, praktis, dan mudah diakses oleh masyarakat [14]. Kontribusi penelitian ini mencakup dua aspek utama, yaitu pengembangan model klasifikasi berbasis CNN dan implementasi (deployment) model tersebut ke aplikasi mobile menggunakan TensorFlow Lite, termasuk kajian trade-off antara akurasi dan efisiensi pada perangkat dengan sumber daya terbatas, sejalan dengan riset deployment CNN ringan berbasis edge terbaru [15][16][17].

2. Metode Penelitian

2.1 Tahapan Penelitian

Penelitian ini menggunakan metode pengembangan sistem berbasis *Deep Learning* untuk mengklasifikasikan jenis sampah menggunakan algoritma *Convolutional Neural Network* (CNN) pada perangkat Android. Tahapan penelitian meliputi pengumpulan dataset, preprocessing data, pelatihan model, evaluasi model, konversi model ke *TensorFlow Lite*, implementasi aplikasi Android, serta penguian sistem [18][19][20].

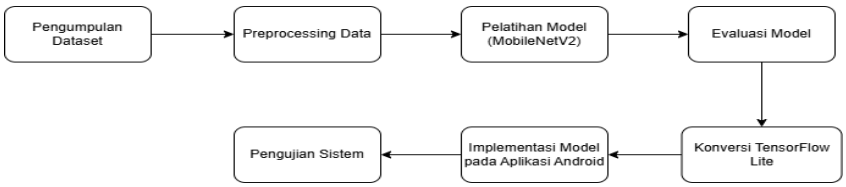

Gambar 1 Tahapan Penelitian

2.2 Dataset

Dataset yang digunakan berupa citra sampah yang terdiri dari lima kategori, yaitu kaca, kertas, logam, organik, dan plastik. Dataset diperoleh dari sumber dataset publik (Roboflow, Kaggle, dan lainnya) dan digunakan sebagai data pelatihan, validasi, serta pengujian model. Pembagian dataset dilakukan untuk memastikan model mampu melakukan proses pembelajaran dan evaluasi secara optimal terhadap data yang belum pernah dikenali sebelumnya. Dataset dibagi menggunakan rasio 80:10:10 untuk data latih, data validasi, dan data uji, menghasilkan total 17.500 citra dengan rincian per kelas disajikan pada Tabel 1. Dataset bersumber dari platform Kaggle dan Roboflow, yang merupakan repositori dataset citra publik yang umum digunakan pada penelitian klasifikasi sampah berbasis citra.

Tabel 1. Distribusi Dataset per Kelas

Kelas	Data Latih (Train)	Data Validasi	Data Uji (Test)	Total
Kaca	2800	350	350	3500
Kertas	2800	350	350	3500
Logam	2800	350	350	3500
Organik	2800	350	350	3500
Plastik	2800	350	350	3500
Total	14000	1750	1750	17500

2.3 Preprocessing Data

Tahap preprocessing dilakukan untuk menyesuaikan data dengan kebutuhan model MobileNetV2. Proses ini meliputi perubahan ukuran citra menjadi 224 × 224 piksel, normalisasi nilai piksel, serta

augmentasi data. Teknik augmentasi yang digunakan meliputi rotasi, *flipping, zoom,* dan translasi citra untuk meningkatkan variasi data dan menguragi risiko *overfitting* selama proses pelaithan model.

2.4 Pelatihan Model

Model klasifikasi dibangun menggunakan arsitektur MobileNetV2 dengan pretrained weights dari ImageNet. Arsitektur ini dipilih karena memiliki kompleksitas komputasi yang relatif rendah sehingga sesuai untuk implementasi pada perangkat bergerak. Proses pelatihan dilakukan menggunakan framework TensorFlow dengan dataset yang telah melalui tahap preprocessing. Kinerja model selama proses pelatihan dipantau berdasarkan nilai accuracy dan loss pada data pelatihan dan validasi.

Konfigurasi pelatihan menggunakan batch size sebesar 32 dan optimizer Adam dengan learning rate sebesar 0,0001 pada tahap awal fine-tuning, kemudian diturunkan menjadi 0,00001 pada tahap fine-tuning lanjutan. Pelatihan dilakukan selama 30–50 epoch dengan mekanisme early stopping menggunakan validation loss sebagai parameter pemantauan dan patience sebesar 5. Mekanisme tersebut digunakan untuk menghentikan proses pelatihan ketika tidak terjadi peningkatan kinerja validasi dan untuk memperoleh model dengan performa validasi terbaik.

Strategi fine-tuning dilakukan secara bertahap. Pada tahap awal, seluruh layer pada base model MobileNetV2 dibekukan (freeze) sehingga hanya classifier head yang dilatih. Setelah tahap awal selesai, sejumlah layer terakhir pada base model dibuka (unfreeze) untuk dilakukan fine-tuning. Tahapan ini bertujuan menyesuaikan fitur hasil pretraining ImageNet dengan karakteristik citra pada dataset penelitian, sekaligus mempertahankan efisiensi komputasi dari arsitektur MobileNetV2.

2.5 Evaluasi Model

Evaluasi model dilakukan menggunakan data uji yang tidak terlibat dalam proses pelatihan. Kinerja model diukur menggunakan *confusion matrix* serta metrik evaluasi berupa *accuracy, precision, recall, F1-score,* dan *Area Under Curve* (AUC). Penggunaan beberapa metrik evaluasi bertujuan untuk memberikan gambar yang lebih komprehensif mengenai kemampuan model dalam mengklasifikasikan setiap kategori sampah.

2.6 Implementasi Sistem

Model hasil pelatihan dikonversi ke format *TensorFlow Lite* agar dapat dijalankan secara lokal pada perangkat Android. Implementasi aplikasi dilakukan menggunakan *framework* Flutter. Pengguna dapat melakukan klasifikasi sampah melalui kamera maupun galeri perangkat. Hasil klasifikasi ditampilkan dalam bentuk kategori sampah dan nilai *confidence score,* sedangkan riwayat scan klasifikasi disimpan menggunakan *SQLite.*

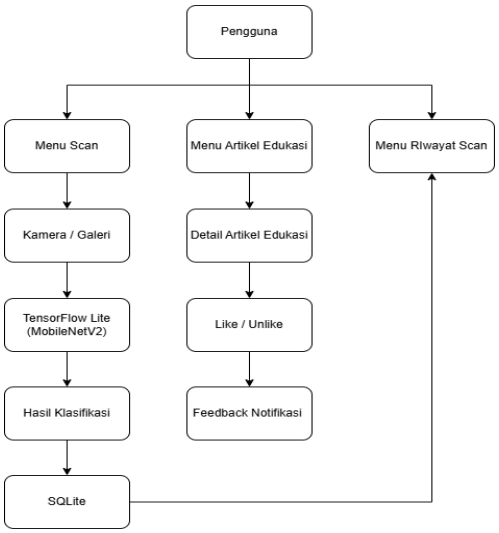

Gambar 2. Arsitektur Sistem

2.7 Pengujian Sistem

Pengujian sistem dilakukan untuk memastikan seluruh fungsi aplikasi berjalan sesuai dengan kebutuhan. Pengujian meliputi fungsional aplikasi, pengujian akurasi model, pengujian waktu inferensi pada perangkat Android, serta pengujian penyimpanan riwayat scan. Hasil pengujian digunakan untuk mengevaluasi keberhasilan implementasi model MobileNetV2 dalam mendukung proses klasifikasi sampah secara *on-device (near real-time)* pada perangkat Android.

3. Hasil dan Pembahasan

3.1 Hasil Evaluasi Model MobileNetV2

Model MobileNetV2 yang telah dilatih kemudian dievaluasi menggunakan data pengujian untuk mengetahui kemampuan model dalam mengklasifikasikan lima kategori jenis sampah, yaitu kaca, kertas, logam, organik, dan plastik. Evaluasi dilakukan menggunakan metrik *accuracy, precision, recall,* dan *f1-score.*

Tabel 2. Hasil Evaluasi Model

Metrik	Nilai (%)
Accuracy	90,63%
Precision	90,59%
Recall	90,63%
F1-Score	90,59%

Berdasarkan Tabel 2, model MobileNetV2 memperoleh akurasi sebesar 90,63% pada data pengujian. Nilai *precision, recall,* dan *F1-score* yang masing-masing berada di atas 90% menunjukkan bahwa model memiliki kemampuan yang baik dalam mengenali dan mengklasifikasikan lima kategori sampah yang digunakan dalam penelitian. Hasil tersebut mengindikasikan bahwa model mampu melakukan proses klasifikasi secara konsisten dan memiliki tingkat kesalahan yang relatif rendah.

Tabel 3. Hasil Evaluasi Model Per Kelas

Kelas	Precision	Recall	F1-Score
Kaca	89,68%	86,86%	88,24%
Kertas	90,38%	94,00	92,16%
Logam	90,86%	88,00%	89,40%
Organik	95,56%	98,29%	96,90%

Plastik	86,49%	86,00%	86,25%

Berdasarkan Tabel 3, kelas organik memperoleh performa terbaik dengan nilai *precision* sebesar 95,56%, *recall* sebesar 98,29%, dan *F1-score* sebesar 96,90%. Hal ini menunjukkan bahwa model mampu mengenali karakteristik visual sampah organik dengan sangat baik. Sebaliknya, kelas plastik memperleh nilai *F1-score* terendah sebesar 86,25%. Hasil tersebut menunjukkan masih terdapat beberapa kesalahan klasifikasi pada kelas plastik yang kemungkinan disebabkan oleh kemiripan warna, bentuk, atau tekstur dengan kategori sampah lainnya. Secara keseluruhan, seluruh kelas memperoleh nilai *F1-score* di atas 86%, yang menunjukkan bahwa model memiliki performa klasifikasi yang baik pada seluruh kategori jenis sampah.

Rendahnya performa kelas plastik kemungkinan besar disebabkan oleh kemiripan karakteristik visual dengan kelas kaca dan kertas. Berdasarkan confusion matrix pada Gambar 3, sebagian besar kesalahan klasifikasi kelas plastik terjadi karena tertukar dengan kelas kaca dan kelas kertas, yang diduga terjadi karena kemasan plastik yang transparan atau bening secara visual menyerupai tekstur kaca, sedangkan plastik kemasan berwarna putih atau permukaan doff dapat menyerupai tekstur kertas di bawah kondisi pencahayaan tertentu.

3.1.1 Confusion Matrix

Confusion matrix pada Gambar 3, sebagian besar data berhasil diklasifikasi dengan benar pada masing-masing kelas. Kelas organik menunjukkan performa terbaik dengan 344 prediksi benar dari 350 data uji, sedangkan kelas plastik memperoleh jumlah prediksi benar terendah yaitu 301 data. Beberapa kesalahan klasifikasi masih ditemukan pada kelas kaca, logam, dan plastik yang memiliki karakteristik visual yang relatif mirip. Secara keseluruhan, hasil *confusion* matrix menunjukkan bahwa model MobileNetV2 mampu melakukan klasifikasi lima kategori sampah dengan baik dan menghasilkan akurasi sebesar 90,63%.

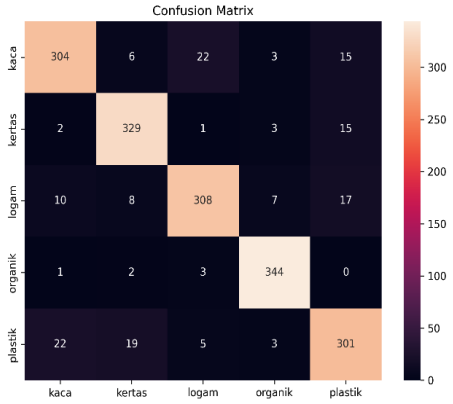

Gambar 3. *Confusion Matrix* Hasil Pengujian Model MobileNetV2

Pola kesalahan klasifikasi secara rinci dapat diamati sebagai berikut. Kelas kaca paling banyak salah diklasifikasikan sebagai logam (22 dari 350 citra) dan plastik (15 citra). Kelas kertas paling banyak tertukar dengan plastik (15 citra). Kelas logam paling banyak tertukar dengan plastik (17 citra) dan kaca (10 citra). Kelas organik menunjukkan kesalahan klasifikasi paling sedikit (6 dari 350 citra), sedangkan kelas plastik paling banyak tertukar dengan kaca (22 citra) dan kertas (19 citra). Pola ini menunjukkan adanya kesalahan klasifikasi dua arah (bidirectional) yang cukup menonjol antara plastik dan kaca (total 37 citra tertukar antar kedua kelas) serta antara plastik dan kertas (34 citra), yang mengindikasikan model masih kesulitan membedakan objek dengan tekstur transparan, mengkilap, atau berwarna netral.

Temuan ini menjadi dasar bahwa upaya perbaikan model ke depan dapat difokuskan pada penambahan variasi data untuk kelas plastik, terutama pada kondisi pencahayaan dan latar belakang yang beragam.

3.1.2 ROC Curve dan AUC

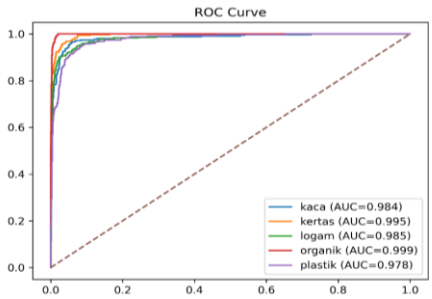

Gambar 4. ROC Curve dan Nilai AUC Model MobileNetV2

Berdasarkan ROC Curve pada Gambar 4, seluruh kelas memperoleh nila AUC di atas 0,97. Nilai tersebut menunjukkan bahwa model MobileNetV2 memiliki kemampuan diskriminasi yang sangat baik dalam membedakan lima kategori sampah yang digunakan pada penelitian. Kelas organik memperoleh nilai AUC tertinggi sebesar 0,999, sedangkan kelas plastik memperoleh nilai AUC terendah sebesar 0,978.

3.2 Implementasi Aplikasi Android

Model MobileNetV2 yang telah dilatih kemudian dikonversi ke format TensorFlow Lite (TFLite) dan diintegrasikan ke dalam aplikasi Android menggunakan framework Flutter. Implementasi ini memungkinkan proses klasifikasi dilakukan secara lokal pada perangkat tanpa memerlukan koneksi internet. Aplikasi yang dikembangkan terdiri atas beberapa halaman utama, yaitu halaman beranda, scan sampah, preview scan, hasil deteksi, riwayat scan, dan artikel edukasi.

Dari sisi performa perangkat, model yang dikonversi ke format TFLite memiliki ukuran file sekitar 12 MB, dengan rata-rata waktu inferensi murni (tanpa proses pengambilan gambar dan rendering UI) sekitar 250 ms. Pengujian dilakukan pada perangkat Android kelas menengah dengan RAM minimal 4 GB. Waktu pemrosesan sekitar 5 detik yang disebutkan pada bagian abstrak dihitung secara end-to-end, yaitu sejak kamera mengambil gambar hingga hasil klasifikasi ditampilkan pada layar, termasuk proses pengambilan gambar dan rendering antarmuka, bukan hanya waktu inferensi model saja. Mengingat waktu pemrosesan tersebut, istilah yang lebih tepat digunakan pada penelitian ini adalah on-device inference atau near-real-time classification, bukan real-time, agar ekspektasi pembaca terhadap performa sistem sesuai dengan kondisi aktual aplikasi.

3.2.1 Halaman Beranda

Halaman beranda merupakan halaman utama aplikasi yang berfungsi sebagai pusat navigasi pengguna. Pada halaman ini tersedia menu untuk mengakses fitur scan sampah, riwayat hasil klasifikasi, dan artikel edukasi.



Gambar 5. Halaman Beranda Aplikasi

3.2.2 Halaman Scan Sampah

Halaman scan sampah digunakan untuk memperoleh citra yang akan diklasifikasikan oleh sistem. Pengguna dapat mengambil gambar secara langsung menggunakan kamera perangkat atau memilih gambar yang tersimpan pada galeri.



Gambar 6. Scan via Kamera

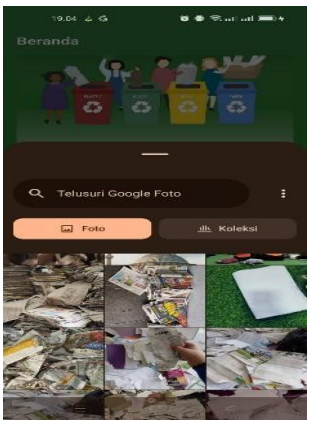

Gambar 7. Scan via Galeri

3.2.3 Halaman Preview Scan

Halaman *preview* scan menampilkan citra yang telah dipilih sebelum dilakukan proses klasifikasi. Fitur ini membantu pengguna untuk memastikan objek yang akn dianalisis sudah sesuai dan terlihat dengan jelas.

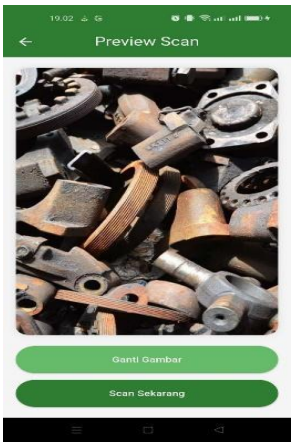

Gambar 8. Halaman Preview Scan

3.2.4 Halaman Hasil Deteksi

Halaman hasil deteksi menampilkan kategori sampah yang berhasil diprediksi oleh model MobileNetV2 beserta nilai *confidence score* sebagai tingkat keyakinan model terhadap hasil klasifikasi yang diberikan.

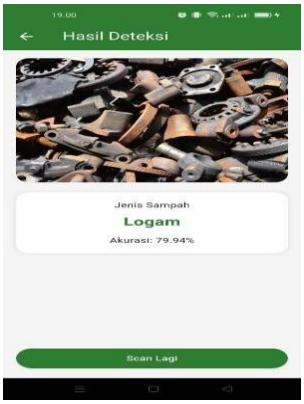

Gambar 9. Halaman Hasil Deteksi

3.2.5 Halaman Riwayat Scan

Halaman riwayat scan digunakan untuk menyimpan hasil klasifikasi yang telah dilakukan sebelumnya. Data riwayat disimpan secara lokal menggunakan *SQLite* sehingga dapat diakses kembali oleh pengguna kapan saja.

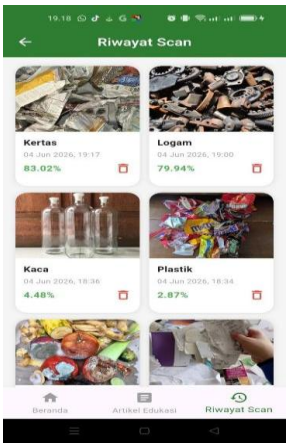

Gambar 10. Halaman Riwayat Scan

3.2.6 Halaman Artikel Edukasi

Halaman artikel edukasi menyediakan informasi mengenai jenis sampah, cara pemilahan, dan pengelolaan sampah yang baik. Pengguna juga dapat memberikan interaksi berupa *like* atau *unlike* pada artikel yang tersedia sebagai bentuk umpan balik terhadap konten yang disajikan. Fitur riwayat pemindaian dan artikel edukasi pada penelitian ini berfungsi sebagai media pendukung aplikasi, bukan sebagai kontribusi yang telah dievaluasi dampaknya. Karena belum dilakukan pengujian terhadap perubahan pemahaman atau perilaku pengguna, klaim penelitian dibatasi pada penyediaan media edukasi mengenai jenis dan pengelolaan sampah, dan tidak diklaim secara langsung meningkatkan kesadaran lingkungan pengguna.



Gambar 11. Halaman Artikel Edukasi



Gambar 12. Detail Artikel Edukasi



Gambar 13. *Like* Artikel Edukasi



Gambar 14. *Unlike* Artikel Edukasi

3.3 Pengujian Sistem

Pengujian sistem dilakukan menggunakan metode *black box testing* untuk memastikan seluruh fitur aplikasi dapat berjalan sesuai dengan kebutuhan fungsional yang telah dirancang. Pengujian dilakukan pada fitur utama aplikasi yang meliputi proses scan via kamera dan galeri, preview scan, klasifikasi sampah, penyimpanan riwayat scan, serta artikel edukasi.

Tabel 4. Pengujian Blackbox

No	Skenario Pengujian	Hasil yang Diharapkan	Hasil Pengujian	Status
1	Menjalankan aplikasi	Halaman *splash screen* berhasil ditampilkan.	Sesuai harapan	Berhasil
2	Mengambil gambar melalui kamera	Gambar berhasil ditampilkan pada halaman *preview scan.*	Sesuai harapan	Berhasil
3	Mengambil gambar melalui kamera	Gambar berhasil ditampilkan pada halaman *preview scan.*	Sesuai harapan	Berhasil

4	Menampilkan hasil klasifikasi scan	Hasil klasifikasi berhail ditampilkan.	Sesuai harapan	Berhasil
5	Menampilkan riwayat scan	Data riwayat scan berhasil ditampilkan.	Sesuai harapan	Berhasil
6	Membuka artikel edukasi	Artikel berhasil ditampilkan.	Sesuai harapan	Berhasil
7	*Like* dan *unlike* artikel	Status interaksi berhasil diperbarui.	Sesuai harapan	Berhasil

Berdasarkan hasil pengujian, seluruh fitur aplikasi dapat berjalan dengan baik dan menghasilkan keluaran sesuai dengan kebutuhan sistem. Tidak ditemukan kesalahan yang menghambat proses penggunaan aplikasi, sehingga sistem dinyatakan berhasil diimplementasikan pada perangkat Android. Pengujian black box pada penelitian ini mencakup 7 skenario fungsional yang seluruhnya merupakan skenario kondisi normal (positive scenario), yaitu menjalankan aplikasi, pengambilan gambar melalui kamera dan galeri, klasifikasi, riwayat scan, serta interaksi pada artikel edukasi. Skenario negatif atau kondisi error, seperti pengguna tidak memberikan gambar, berkas gambar rusak (corrupt), format gambar tidak didukung, izin (permission) kamera ditolak, atau model gagal melakukan prediksi, belum diuji pada penelitian ini dan menjadi salah satu batasan yang perlu ditindaklanjuti pada pengujian berikutnya.

3.4 Pembahasan

Hasil evaluasi menunjukkan bahwa model MobileNetV2 mampu mencapai akurasi sebesar 90,63% pada data pengujian, dengan nilai precision, recall, dan F1-score yang masing-masing berada di atas 90%. Selain itu, seluruh kelas memperoleh nilai AUC di atas 0,97 yang menunjukkan kemampuan model yang sangat baik dalam membedakan lima kategori sampah. Berdasarkan confusion matrix, sebagian besar data berhasil diklasifikasikan dengan benar, meskipun masih terdapat beberapa kesalahan klasifikasi pada kelas yang memiliki karakteristik visual serupa. Performa tersebut menunjukkan bahwa pemanfaatan transfer learning melalui pretrained model MobileNetV2 dan proses fine-tuning mampu menghasilkan representasi fitur yang cukup efektif untuk membedakan karakteristik visual pada dataset sampah yang digunakan.

Implementasi model menggunakan TensorFlow Lite memungkinkan proses klasifikasi dilakukan secara lokal pada perangkat Android tanpa memerlukan koneksi internet. Pendekatan on-device inference tersebut mendukung penggunaan aplikasi secara lebih praktis karena proses prediksi tidak bergantung pada komunikasi dengan server eksternal. Hasil pengujian fungsional juga menunjukkan bahwa fitur-fitur utama aplikasi dapat berjalan sesuai dengan kebutuhan sistem. Dengan demikian, MobileNetV2 tidak hanya memberikan performa klasifikasi yang baik pada tahap evaluasi model, tetapi juga dapat diintegrasikan ke dalam aplikasi Android untuk mendukung proses klasifikasi jenis sampah secara praktis.

Meskipun demikian, performa model pada data pengujian perlu dibedakan dari performa aplikasi pada kondisi penggunaan nyata. Nilai akurasi sebesar 90,63% diperoleh berdasarkan data pengujian yang digunakan dalam penelitian, sedangkan hasil klasifikasi ketika aplikasi digunakan melalui kamera perangkat dapat dipengaruhi oleh karakteristik citra yang berbeda dari dataset. Variasi pencahayaan, latar belakang, posisi dan ukuran objek, jarak serta sudut pengambilan gambar, maupun objek yang hanya terlihat sebagian dapat memengaruhi kualitas prediksi model.

Evaluasi model pada penelitian ini masih menggunakan data uji yang bersumber dari dataset publik sehingga belum sepenuhnya merepresentasikan keragaman kondisi citra pada penggunaan aplikasi di lingkungan nyata. Oleh karena itu, hasil akurasi 90,63% tidak dapat secara langsung digeneralisasikan sebagai tingkat akurasi aplikasi pada seluruh kondisi penggunaan. Pengujian lebih lanjut menggunakan citra yang diperoleh langsung melalui kamera perangkat dalam berbagai kondisi lingkungan diperlukan untuk mengevaluasi kemampuan generalisasi model secara lebih komprehensif.

Selain itu, pemilihan MobileNetV2 pada penelitian ini belum dibandingkan secara eksperimental dengan arsitektur ringan lainnya menggunakan dataset dan protokol pelatihan yang sama. Pengujian fungsional aplikasi juga masih berfokus pada skenario penggunaan normal dan belum mencakup seluruh kemungkinan kondisi kesalahan. Penelitian selanjutnya dapat memperluas evaluasi melalui pengujian pada data real-world, perbandingan dengan beberapa arsitektur ringan lainnya, serta penambahan skenario pengujian negatif untuk memperoleh evaluasi performa model dan sistem yang lebih komprehensif.

4. Kesimpulan

Penelitian ini berhasil mengimplementasikan metode Convolutional Neural Network (CNN) menggunakan arsitektur MobileNetV2 pada aplikasi Android untuk mengklasifikasikan lima jenis sampah, yaitu kaca, kertas, logam, organik, dan plastik. Hasil evaluasi pada data pengujian menunjukkan bahwa model memperoleh accuracy sebesar 90,63%, precision 90,59%, recall 90,63%, dan F1-score 90,59%. Seluruh kelas juga memperoleh nilai AUC di atas 0,97, yang menunjukkan kemampuan model yang sangat baik dalam membedakan kategori sampah.

Model berhasil dikonversi ke format TensorFlow Lite dan diintegrasikan ke dalam aplikasi Android menggunakan Flutter sehingga proses klasifikasi dapat dilakukan secara lokal tanpa koneksi internet. Model memiliki ukuran sekitar 12 MB dengan waktu inferensi rata-rata sekitar 250 ms pada perangkat Android, sedangkan waktu pemrosesan secara end-to-end sekitar 5 detik. Pengujian fungsional menunjukkan bahwa seluruh fitur utama aplikasi dapat berjalan sesuai dengan kebutuhan sistem. Dengan demikian, penelitian ini menunjukkan bahwa MobileNetV2 dapat menjadi pendekatan yang efektif untuk mengintegrasikan model CNN ringan ke dalam aplikasi Android sebagai media bantu klasifikasi sampah berbasis citra secara on-device.

5. Referensi

[1] Yu, Y., & Grammenos, R. (2021). Towards artificially intelligent recycling: Improving image processing for waste classification. arXiv preprint, arXiv:2108.06274. https://arxiv.org/abs/2108.06274

[2] Alden, S., & Sari, B. N. (2023). Implementasi Algoritma CNN Untuk Pemilahan Jenis Sampah Berbasis Android Dengan Metode CRISP-DM. Jurnal Informatika, 10(1), 62–71. https://doi.org/10.31294/inf.v10i1.14985

[3] Kementerian Lingkungan Hidup dan Kehutanan (KLHK). (2024). Sistem Informasi Pengelolaan Sampah Nasional (SIPSN): Capaian Kinerja Pengelolaan Sampah. Diakses dari https://sipsn.menlhk.go.id/sipsn/public/data/capaian

[4] Diponegoro, M., Kusumawardani, S., & Hidayah, I. (2021). Tinjauan Pustaka Sistematis: Implementasi Metode Deep Learning pada Prediksi Kinerja Murid. Jurnal Nasional Teknik Elektro dan Teknologi Informasi, 10(2), 131–138. https://doi.org/10.22146/jnteti.v10i2.1417

[5] Azmi, K., Defit, S., & Sumijan. (2023). Implementasi convolutional neural network (CNN) untuk klasifikasi batik tanah liat Sumatera Barat. Jurnal Unitek, 16(1), 28–40.

[6] Thio, S. E., & Susilo, J. (2025). Identifikasi Pemilahan Sampah Berbasis Algoritma Transfer Learning CNN menggunakan MobileNetV2 dan EfficientNetB0. bit-Tech (Binary Digital – Technology), 8(1), 25–32. https://doi.org/10.32877/bt.v8i1.1900

[7] Muslihati, M., Sahibu, S., & Taufik, I. (2024). Implementasi Algoritma Convolutional Neural Network untuk Klasifikasi Jenis Sampah Organik dan Non Organik. MALCOM: Indonesian Journal of Machine Learning and Computer Science, 4(3), 840–852. https://doi.org/10.57152/malcom.v7i2.1346

[8] Purba, M. E., Situmorang, A. Z., Ginting, G. L. B., Lubis, M. W. P., & Sinaga, F. M. (2025). Klasifikasi Sampah Organik dan Anorganik Menggunakan Algoritma CNN. Jurnal Sifo Mikroskil (JSM), 26(1), 37–54. https://doi.org/10.55601/jsm.v26i1.1510
[9] Hanif, M., & Arief, Z. S. (2025). Analisis Perbandingan Kinerja CNN Sekuensial dan Transfer Learning MobileNetV2 untuk Klasifikasi Sampah. Jurnal Aplikasi Informatika dan Multimedia, 1(1), 16–20.
[10] Kohsasih, K. L., Rizky, M. D. A., Fahriyani, T., Wijaya, V., & Rosnelly, R. (2022). Analisis Perbandingan Algoritma Convolutional Neural Network dan Algoritma Multi-Layer Perceptron Neural dalam Klasifikasi Citra Sampah. Jurnal TIMES, 10(2), 22–28. https://doi.org/10.51351/jtm.10.2.2021655
[11] Sandi, K., Yudha, A., Aryanto, N., & Farabi, M. (2022). Klasifikasi sampah menggunakan Convolutional Neural Network. Indonesian Journal of Data Science, 3(2), 72–81.
[12] Sihananto, A. N., Al Haromainy, M. M., & Sari, A. P. (2023). Pemilahan Jenis Sampah Menggunakan Algoritma CNN. SCAN: Jurnal Teknologi Informasi dan Komunikasi, 17(3). https://doi.org/10.33005/scan.v17i3.3523
[13] Dwiatmoko, F., Utami, D., & Sivi, N. A. (2024). Klasifikasi Citra Sampah Organik dan Non Organik Menggunakan Algoritma CNN (Convolutional Neural Network). Explore, 14(1), 1–5. https://doi.org/10.35200/ex.v14i1.103
[14] Nuariputri, J., Maimunah, & Sukmasetya, P. (2023). Klasifikasi Jenis Sampah Menggunakan Base ResNet-50. Jurnal Ilmiah Komputasi, 22(3). https://doi.org/10.32409/jikstik.22.3.3380
[15] Echchidmi, M., & Bouayad, A. (2026). Compact waste image classification with multi-student CNNs and edge-oriented model selection. Frontiers in Artificial Intelligence, 9, 1804734. https://doi.org/10.3389/frai.2026.1804734
[16] Rayhan, Y., & Rifai, A. P. (2024). Multi-class Waste Classification Using Convolutional Neural Network. Applied Environmental Research, 46(2). https://doi.org/10.35762/AER.2024021
[17] Abdulmahmood, M., & Grammenos, R. (2021). Improving the Deployment of Recycling Classification through Efficient Hyper-Parameter Analysis. arXiv preprint, arXiv:2110.11043. https://arxiv.org/abs/2110.11043
[18] Naufal, M. F., Siswantoro, J., & Wicaksono, M. G. K. (2023). Klasifikasi Tulisan Tangan pada Resep Obat Menggunakan Convolutional Neural Network. Techno.Com, 22(2), 508–526. https://doi.org/10.33633/tc.v22i2.8075
[19] Maulana, I., Khairunisa, N., & Mufidah, R. (2024). Deteksi Bentuk Wajah Menggunakan Convolutional Neural Network (CNN). JATI (Jurnal Mahasiswa Teknik Informatika), 7(6), 3348–3355. https://doi.org/10.36040/jati.v7i6.8171
[20] Li, X., & Grammenos, R. (2023). Evaluation of practical edge computing CNN-based solutions for intelligent recycling bins. IET Smart Cities, 5(3), 194–209. https://doi.org/10.1049/smc2.12057