Cyberspace: Jurnal Pendidikan Teknologi informasi
Volume 10, Nomor 2, Oktober 2026, hal. 81 – 97
ISSN 2598-2079 (print) | ISSN 2597-9671 (online)

KLASIFIKASI JENIS SAMPAH DI ACEH MENGGUNAKAN *COMPUTER VISION*

Nisa Rianti[1], Zulfan[2], Kikye Martiwi Sukiakhy[3*], Junidar[4], Sri Azizah Nazhifah[5]

[1,2,3,4,5]Departmen Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Syiah Kuala, Banda Aceh, Indonesia
E-mail: [1]nisaanti@mhs.usk.ac.id, [2]zulfan.abdullah@usk.ac.id,
[3]kikye.martiwi.sukiakhy@usk.ac.id, [4]junidar678@usk.ac.id. [5]sriazizah07@usk.ac.id
Corresponding Author: kikye.martiwi.sukiakhy@usk.ac.id

Abstract

This study aims to classify waste types in Aceh using a deep learning-based computer vision approach with the ResNet50V2 architecture. The dataset used is a combination of data from the internet and direct image capture results with a total of 8,184 images for training and validation and 3,468 images as testing data. The data is classified into three categories: organic, inorganic, and electronic waste. The pre-processing stage includes data cleaning, adjusting the image size to 224 × 224 pixels, converting to RGB format, and normalization using the preprocess input function. The model was trained using a transfer learning approach, data augmentation, and a fine-tuning strategy at the final layer of the network to improve classification performance. Test results show that the model achieved an accuracy of 83.91%, a precision of 84.86%, and a recall of 82.73%. The model was then implemented in a Flask-based web application prototype that allows users to upload waste images and obtain classification results automatically. The results of this study demonstrate that a deep learning approach using ResNet50V2 is capable of classifying waste types and supporting a technology-based waste management system in Aceh.

Keywords: *computer vision, waste classification, ResNet50V2, deep learning.*

Abstrak

Penelitian ini bertujuan untuk mengklasifikasikan jenis sampah di Aceh menggunakan pendekatan *computer vision* berbasis *deep learning* dengan arsitektur ResNet50V2. Dataset yang digunakan merupakan kombinasi data dari internet dan hasil pengambilan gambar secara langsung dengan total 8.184 gambar untuk pelatihan dan validasi serta 3.468 gambar sebagai data pengujian. Data diklasifikasikan ke dalam tiga kategori, yaitu sampah organik, anorganik, dan elektronik. Tahap pra-pemrosesan meliputi pembersihan data, penyesuaian ukuran citra menjadi 224×224 piksel, konversi ke format RGB, serta normalisasi menggunakan fungsi `preprocess_input`. Model dilatih menggunakan pendekatan *transfer learning*, augmentasi data, serta strategi *fine-tuning* pada lapisan akhir jaringan untuk meningkatkan performa klasifikasi. Hasil pengujian menunjukkan bahwa model mencapai *accuracy* sebesar 83,91%, *precision* sebesar 84,86%, dan *recall* sebesar 82,73%. Model kemudian diimplementasikan dalam prototipe aplikasi web berbasis Flask yang memungkinkan pengguna mengunggah gambar sampah dan memperoleh hasil klasifikasi secara otomatis. Hasil penelitian ini menunjukkan bahwa pendekatan *deep learning* menggunakan ResNet50V2 mampu mengklasifikasikan jenis sampah dengan mendukung sistem pengelolaan sampah berbasis teknologi di Aceh.

Kata Kunci: *computer vision,* klasifikasi sampah*,* ResNet50V2*, deep learning.*

1. Pendahuluan

Permasalahan pengelolaan sampah menjadi isu lingkungan yang mendesak baik secara global maupun nasional. Pertumbuhan penduduk, urbanisasi, serta perubahan pola konsumsi Masyarakat berkontribusi signifikan terhadap peningkatan timbulan sampah setiap tahunnya. Menurut data Kementerian Lingkungan Hidup dan Kehutanan (KLHK), Indonesia menghasilkan sekitar 69,7 juta ton sampah per tahun, dengan mayoritas berasal dari aktivitas rumah tangga dan Kawasan perkotaan [1]. Timbunan sampah dalam jumlah besar yang tidak terkelola dengan baik berpotensi menimbulkan pencemaran tanah, air, dan udara, serta berdampak langsung pada Kesehatan Masyarakat dan berkelanjutan lingkungan.

Di provinsi Aceh, persoalan serupa juga terjadi. Walaupun data total timbulan sampah untuk keseluruhan provinsi belum dipublikasikan secara rinci, laporan dari beberapa kabupaten/kota memberikan Gambaran besarnya permasalahan. Misalnya, Kota Banda Aceh menghasilkan rata-rata sekitar 255-258 ton sampah per hari, dengan total tahunan mencapai 93.258 ton pada tahun 2024, meningkat dari tahun sebelumnya yang sebesar 92.624 ton [2]. Di Kabupaten Aceh Besar, volume sampah mencapai sekitar 90 ton per hari selama bulan Ramadhan akibat meningkatnya aktivitas konsumsi masyarakat [3]. Sementara itu, di Kabupaten Aceh Timur, produksi sampah harian rata-rata sekitar 70 ton, dan naik hingga 90 ton per hari pada bulan Ramadhan [4]. Data ini menunjukkan bahwa persoalan persampahan merupakan isu serius di berbagai daerah di Aceh dan tidak terbatas pada Kawasan perkotaan besar. Permasalahan semakin kompleks dan membutuhkan solusi yang tidak hanya efektif tetapi juga berkelanjutan. Sampah yang tidak terkelola ini berpotensi mencemari lingkungan, mengancam Kesehatan Masyarakat, dan menghambat upaya daur ulang yang berkelanjutan. Ini terutama penting jika kita tidak memisahkan antara sampah organik, anorganik dan elektronik dari awal. Sampah organik, seperti sisa-sisa makanan, daun kering, Kulit buah dan sayur, bisa cepat terurai dengan sendirinya [5]. sampah anorganik, seperti botol plastik, kaca, logam dan kaleng minuman yang butuh waktu lama untuk bisa hancur. sampah elektronik seperti ponsel, komputer, TV, dan peralatan rumah tangga yang mengandung bahan berbahaya seperti logam berat dan zat kimia beracun, sehingga tidak boleh dibuang sembarangan. Proses pemisahan sampah hingga saat ini banyak dilakukan secara manual, yang tidak hanya membutuhkan waktu dan tenaga, tetapi juga berisiko mengalami kesalahan. Selain itu, membedakan jenis sampah sering kali sulit dilakukan hanya dengan melihat karena bentuk, warna, dan keadaan fisik sampah itu sangat berbeda-beda. Oleh karena itu, diperlukan sistem pemisahan sampah yang menggunakan teknologi penglihatan komputer untuk membantu mengidentifikasi dan memberikan petunjuk penanganan sampah kepada masyarakat. Penerapan teknologi seperti *Convolutional Neural Network* (CNN) telah terbukti efektif dalam klasifikasi gambar sampah .

Seiring dengan pesatnya perkembangan teknologi di era digital, computer vision semakin popular dan menjadi salah satu istilah kunci dalam bidang pengolahan citra. Kemajuan pesat dalam *deep learning* telah mendorong perkembangan signifikan dalam *computer vision*, khususnya melalui penggunaan CNN sebagai arsitektur utama. CNN merupakan jaringan saraf berlapis yang mampu melakukan *end-to-end learning* untuk mengekstraksi fitur penting dari citra tanpa memerlukan *feature engineering* manual. Sejak keberhasilan AlexNet pada kompetisi ImageNet pada tahun 2012, berbagai arsitektur CNN seperti VGG, GoogLeNet, dan ResNet terus berkembang untuk meningkatkan akurasi dan efisiensi. Meskipun demikian, tantangan seperti *overfitting*, kebutuhan komputasi tinggi, dan interpretabilitas model masih menjadi fokus penelitian.

CNN umumnya terdiri dari lapisan *convolution, pooling,* dan *fully connected* yang dipadukan dengan fungsi aktivitas serta teknik regulasi seperti *batch normalization* dan *dropout* untuk meningkatkan performa. Sebelum pelatihan, data citra biasanya melalui tahap pra-pemrosesan seperti normalisasi dan reduksi dimensi untuk menghasilkan representasi fitur yang optimal [6].

Penelitian sebelumnya oleh Pieters (2025) berhasil mengembangkan sistem klasifikasi sampah otomatis berbasis CNN yang mampu meningkatkan efisiensi pengelolaan sampah untuk mendukung implementasi *Smart Waste Management* (SWM). Hasil penelitian tersebut memperkuat bahwa pendekatan deep learning memiliki potensi signifikan dalam meningkatkan akurasi dan kecepatan pemilahan sampah di lingkungan perkotaan. Penelitian ini dapat menjadi acuan dalam pengembangan sistem serupa di Aceh yang saat ini masih mengandalkan proses pemilahan secara manual [7].

Penelitian sebelumnya yang mengembangkan sistem klasifikasi sampah otomatis menggunakan CNN telah menunjukkan hasil yang menjanjikan, dengan akurasi mencapai 94,86% pada dataset pelatihan. Meskipun demikian, performa model masih menunjukkan keterbatasan, terutama dalam mengklasifikasikan sampah organik dengan presisi 45,7% dan *recall* 38,8% [7]. Kondisi ini menunjukkan perlunya arsitektur jaringan yang lebih kuat dan mampu mengekstrak fitur visual dengan tingkat detail lebih tinggi.

Untuk mengatasi masalah tersebut, penelitian ini menggunakan ResNet50V2, varian CNN yang menggunakan *residual connection* untuk menjaga aliran gradien tetap stabil pada jaringan yang lebih mendalam. ResNet50V2 merupakan pengembangan dari ResNet50 yang menggunakan *residual connection* atau *skip connections*. Metode ini memungkinkan informasi dapat melewati satu atau lebih lapisan dalam jaringan neural, sehingga aliran gradient tetap terjaga pada jaringan yang sangat dalam [8]. Penelitian ini difokuskan pada pengembangan evaluasi model klasifikasi sampah berbasis ResNet50V2 dengan menggunakan dataset publik dan data yang dikumpulkan secara langsung dari Aceh (manual), untuk menghasilkan klasifikasi yang akurat untuk kategori organik, anorganik dan elektronik.

ResNet50V2 dipilih karena kemampuannya dalam mengatasi vanishing gradient melalui *residual connection* serta mengoptimalkan performa jaringan yang lebih dalam. Pendekatan ini memungkinkan model mengekstrak fitur penting dari gambar sampah dengan tingkat detail tinggi, sehingga meningkatkan akurasi klasifikasi [8].

Berdasarkan penelitian sebelumnya, ResNet50V2 telah terbukti efektif dalam berbagai klasifikasi citra. Penelitian oleh Hastari et al. (2024) menggunakan ResNet50V2 untuk identifikasi penyakit tanaman padi dengan akurasi 0,9992 [6]. Kemudian, penelitian dari Mustaqim et al. (2025) menunjukkan model ini menawarkan kombinasi seimbang antara akurasi tinggi dan efisiensi komputasi pada klasifikasi citra monkeypox [9]. Selanjutnya, penelitian oleh Molchanova et al. (2025) berhasil menggunakan ResNet50V2 dalam klasifikasi limbah konstruksi dengan akurasi 97,8% menggunakan sistem hibrida YOLO11 + ResNet50V2 [10]. Temuan ini mendukung pemilihan ResNet50V2 dalam penelitian ini, karena model mampu mengekstrak fitur citra kompleks secara akurat sekaligus efisien secara komputasi, sehingga sesuai untuk pengembangan sistem pemilahan sampah berbasis web.

Penelitian ini diharapkan dapat berguna bagi masyarakat dalam memudahkan proses pemilahan sampah, tetapi juga bermanfaat bagi pemerintah daerah dan instansi terkait dalam mendukung kebijakan pengelolaan sampah, bagi pelaku usaha daur ulang dalam meningkatkan efisiensi, serta bagi sektor Pendidikan sebagai media pembelajaran dan peningkatan kesadaran lingkungan

2. Metode

Metode penelitian yang akan dilakukan terdiri dari beberapa tahapan penelitian. Skema dari alur tersebut dapat dilihat pada gambar 1.

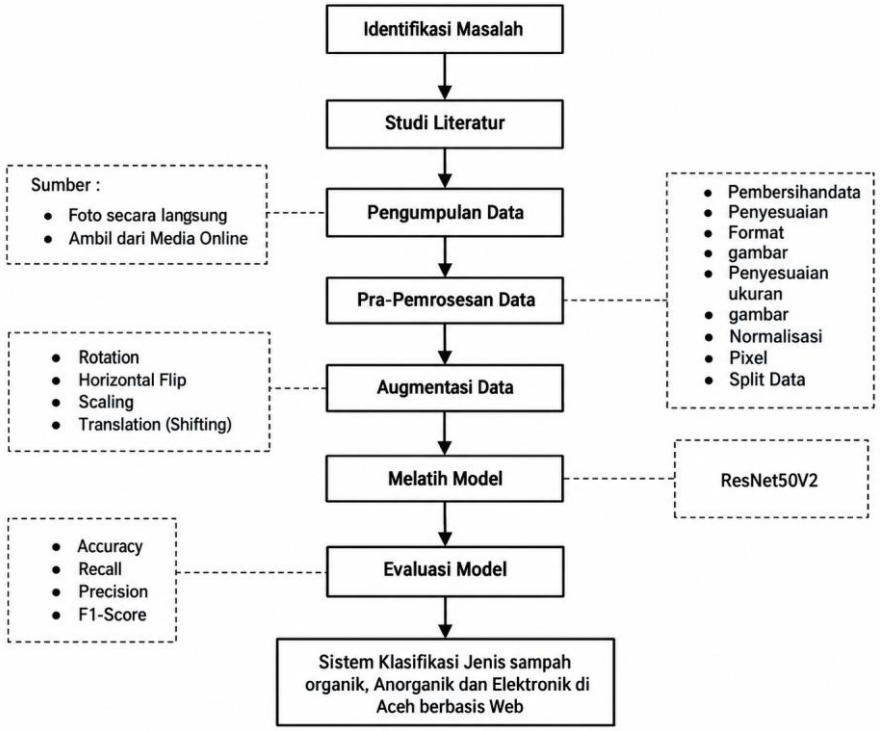

Gambar 1. Diagram alur penelitian

2.1 Identifikasi Masalah

Penelitian ini diawali dengan identifikasi permasalahan utama dalam klasifikasi jenis sampah di Aceh menggunakan pendekatan *computer vision*. Pengelolaan sampah menjadi salah satu tantangan penting dalam menjaga kebersihan lingkungan, termasuk di Provinsi Aceh. Salah satu upaya yang dapat dilakukan untuk mendukung pengelolaan sampah yang lebih efisien adalah melalui penerapan teknologi computer vision dalam proses klasifikasi sampah. Teknologi ini memungkinkan sistem untuk mengenali dan mengelompokkan sampah organik, anorganik serta elektronik secara otomatis berdasarkan citra.

Namun, penerapan *computer vision* dalam konteks klasifikasi sampah di Aceh masih terbatas. Belum ada model yang secara khusus dikembangkan untuk menangani karakteristik citra sampah yang bervariasi dalam hal bentuk, warna, latar, dan kondisi pencahayaan. Selain itu, Tingkat efektivitas model *deep learning*, khususnya arsitektur ResNet50V2, dalam mengklasifikasi jenis sampah di Aceh juga belum pernah dievaluasi secara sistematis.

Kondisi tersebut menunjukkan adanya kebutuhan untuk melakukan penelitian yang tidak hanya mengembangkan model klasifikasi berbasis *computer vision*, tetapi juga menguji performa model tersebut dalam mengenali jenis sampah organik, anorganik, dan elektronik secara akurat.

2.2 Studi Literatur

Studi literatur merupakan tahap awal yang sangat penting dalam penelitian ini untuk

memahami perkembangan penelitian terdahulu, mengidentifikasi celah dalam penelitian, serta memilih strategi yang tepat untuk menangani isu yang diangkat. Langkah pertama dalam kajian literatur adalah mengumpulkan sumber referensi yang relevan dengan topik penelitian. Sumber referensi diperoleh dari artikel ilmiah, buku, dan sumber yang dapat dipercaya lainnya melalui database akademik seperti Mendeley, Springer, dan Google Scholar. Penelusuran dilakukan dengan menggunakan kata kunci seperti "klasifikasi sampah menggunakan ResNet50", "penerapan *computer vision*", "klasifikasi sampah menggunakan *deep learning*" untuk mendapatkan informasi yang relevan dengan penelitian ini.

Setelah referensi terkumpul, Langkah berikutnya adalah menganalisis metode dan pendekatan yang pernah diterapkan dalam penelitian sebelumnya, terutama yang berkaitan dengan penggunaan CNN dalam klasifikasi sampah. Beberapa aspek penting yang dikaji meliputi jenis arsitektur CNN yang digunakan, serta cara evaluasi model yang diterapkan dalam penelitian sebelumnya.

2.3 Pengumpulan Data

Tahapan pengumpulan data dalam penelitian ini dilakukan secara sistematis untuk memastikan bahwa dataset yang digunakan bersifat representatif untuk proses pelatihan dan pengujian model klasifikasi [11]. Dataset yang digunakan terdiri dari tiga kategori utama sampah, yaitu sampah organik, sampah anorganik, dan sampah elektronik. Sampah organik meliputi material yang mudah terurai secara alami seperti sisa makanan, daun kering, kertas, kulit buah dan sayuran. Sampah anorganik terdiri dari material yang sulit untuk terurai seperti plastik, kaca, dan logam. Sementara itu, sampah elektronik terdiri dari kabel, mesin cuci dan televisi yang tidak lagi digunakan. Dataset publik dikumpulkan dari beberapa sumber terpercaya seperti Mendeley Data dan Kaggle, antara lain:

Tabel 1. Daftar dataset publik yang digunakan dalam penelitian

Sumber Platform	**Nama Dataset**
Mendeley Data	*Waste Classification Dataset*
Kaggle	*Custom Waste Classification Dataset*
Kaggle	*Recyclable and Household Waste Classification*
Kaggle	*Waste Images Dataset*
Kaggle	*Food Waste*
Kaggle	*E-Waste Image Dataset*

Pengumpulan dari berbagai sumber tersebut menghasilkan total 4.716 citra yang telah terklasifikasi ke dalam tiga kategori. Untuk menambah keberagaman visual dan memastikan relevansi dataset terhadap kondisi nyata di Aceh, dilakukan pula proses pengambilan gambar secara manual di beberapa Lokasi, seperti area perumahan, pasar tradisional, dan tempat pembuangan sementara (TPS). Melalui metode ini diperoleh 3.468 citra untuk semua kategori. Seluruh citra manual diambil dengan variasi objek, latar belakang, sudut pengambilan dan kondisi pencahayaan yang berbeda. Dengan demikian, total dataset yang digunakan dalam penelitian ini berjumlah 8.184 citra, dengan distribusi yang tetap proporsional pada ketiga kategori. Variasi objek, latar belakang, dan pencahayaan. Berikut contoh gambar dari kategori tersebut ditunjukkan pada gambar 2 dan 3.



Gambar 2. Sampel data yang dikumpulkan dari publik



Gambar 3. Sampel data yang dikumpulkan secara manual

2.4 Pra-pemrosesan Data

Pra-pemrosesan data merupakan tahap penting dalam menyiapkan dataset sebelum digunakan pada proses pelatihan model *deep learning*. Pada penelitian ini, pra-pemrosesan dilakukan untuk memastikan bahwa seluruh citra sampah memiliki kualitas dan format yang sesuai dengan kebutuhan model, sehingga mampu mendukung proses pembelajaran secara optimal [12]. Tahap pertama yang dilakukan adalah pembersihan data, yaitu menghapus citra yang kabur, tidak relevan dengan kategori sampah, atau terdapat duplikasi.

Setelah proses pembersihan, seluruh citra diubah ke ukuran 224 × 224 piksel sesuai dengan ukuran input pada arsitektur ResNet50V2. Proses ini dilakukan tanpa mengubah rasio aspek objek agar karakteristik visual seperti bentuk, kontur, warna, dan tekstur tetap terjaga. Selanjutnya dilakukan normalisasi nilai piksel dengan mengubah rentang 0–255 menjadi -1 hingga 1 menggunakan transformasi $(x/127.5) - 1$, sesuai dengan kebutuhan arsitektur ResNet50V2.

Tahap berikutnya adalah pembagian dataset secara stratified menjadi tiga bagian utama. Data hasil pengambilan manual sebanyak 3.468 citra digunakan sepenuhnya sebagai data uji untuk mengevaluasi performa model pada kondisi nyata. Sementara itu, 4.716 citra dari sumber online dibagi menjadi 70% data latih dan 30% data validasi untuk proses pelatihan dan pemantauan model.

2.5 Augmentasi data

Dalam proses augmentasi data untuk klasifikasi sampah, baik organik, anorganik, maupun elektronik, berbagai teknik diterapkan untuk meningkatkan variasi dalam dataset

serta memperkuat kemampuan model untuk menggeneralisasi. Teknik augmentasi ini dirancang agar model mampu mengidentifikasi pola dari data yang terbatas dan dapat beradaptasi dengan berbagai situasi dalam kehidupan nyata [13]. Salah satu teknik yang digunakan adalah rotasi, di mana gambar diputar dalam sudut tertentu, seperti antara -15° hingga 15°, supaya model dapat mengenali objek sampah dari berbagai perspektif. Di samping itu, juga dilakukan flip atau pembalikan gambar secara horizontal untuk memastikan bahwa model tidak berfokus pada satu orientasi saja saat mengenali objek. Selanjutnya, diterapkan teknik *scaling* (*zoom-in* dan *zoom-out*) yang melibatkan perubahan ukuran gambar baik dengan memperbesar maupun memperkecil, tanpa mengubah aspek rasio. Pendekatan ini memungkinkan model untuk mengenali sampah dalam berbagai ukuran serta jarak pemotretan. Sehingga model dapat belajar dari berbagai posisi objek dalam gambar. Meskipun objek terlihat lebih besar atau lebih kecil, ukuran akhir gambar tetap dikonversi kembali ke 224×224 agar sesuai dengan input ResNet50V2.

2.6 Melatih model

Dalam penelitian ini. Model yang digunakan adalah ResNet50V2, yang merupakan salah satu arsitektur CNN yang dikenal dengan kemampuannya dalam ekstraksi fitur yang kuat dan efisien dalam mengenali pola visual yang kompleks pada gambar. Pendekatan transfer learning digunakan dalam pelatihan model ini, dengan memanfaatkan bobot awal (*pre-trained weights*) dari dataset ImageNet. Dengan cara ini, model tidak perlu dilatih dari awal, sehingga proses pelatihan menjadi lebih efisien dan membutuhkan sumber daya komputasi yang lebih rendah [14]. Lapisan akhir dari model ResNet50V2 kemudian disesuaikan dengan jumlah kelas yang digunakan dalam penelitian ini, yaitu tiga kelas organik anorganik dan elektronik.

Setelah pelatihan selesai, model terbaik disimpan menggunakan metode ModelCheckpoint, yang secara otomatis menyimpan model dengan kinerja validasi terbaik. Model ini kemudian diuji menggunakan data uji untuk menilai kinerjanya secara objektif [15]. Evaluasi dilakukan dengan menggunakan beberapa matrik seperti *accuracy*, *precision, recall*, dan F1-*score*, untuk menilai sejauh mana model dapat mengenali dan membedakan citra sampah organik, anorganik dan elektronik dengan benar.

2.7 Evaluasi model

Evaluasi terhadap model dalam studi ini dilakukan dengan menggunakan beberapa matrik penting, yaitu *accuracy, precision, recall*, dan F1-*score*, untuk menilai efektifitas ResNet50V2 dalam mengklasifikasikan gambar sampah organik, anorganik dan elektronik.

Matrik *precision* digunakan untuk mengevaluasi seberapa tepat model dalam menghasilkan prediksi positif yang akurat, sedangkan *recall* berfungsi untuk menilai seberapa baik model dalam mengidentifikasi semua sampel dari sebuah kelas dengan benar [16]. Untuk mencapai keseimbangan antara kedua matrik tersebut, digunakan F1-*score*, yang merupakan rata-rata harmonis dari *precision* dan *recall*. Nilai F1-*score* yang tinggi menunjukkan bahwa model memiliki keseimbangan yang baik dalam mendeteksi dan membedakan setiap jenis limbah [15].

2.8 Sistem klasifikasi jenis Sampah di Aceh menggunakan Flask

Untuk dukungan tujuan penelitian dalam mengimplementasikan model klasifikasi ke dalam prototipe web sederhana, sistem melakukan tahapan pra-pemrosesan

menggunakan library OpenCV dan Pillow, termasuk resize gambar ke ukuran 224x224 piksel dan normalisasi nilai piksel agar sesuai kebutuhan input model [18]. Setelah itu, proses klasifikasi dilakukan menggunakan model deep learning ResNet50V2 yang telah dilatih dengan dataset tiga kategori sampah. Model menghasilkan label prediksi dengan *confidence score* tertinggi. Jika Tingkat kepercayaan kurang dari 40%, sistem akan memberikan informasi bahwa gambar tidak dapat dikenali sebagai bentuk validasi sederhana demi mengurangi kesalahan prediksi.

3. Hasil dan Pembahasan

3.1 Pengumpulan Data

Penelitian ini menggunakan dataset yang telah dikumpulkan dari beberapa sumber dan secara manual. Proses pengumpulan citra dilakukan melalui dua metode utama, yaitu:

1. Pengambilan citra secara langsung menggunakan kamera ponsel di lingkungan sekitar untuk mendokumentasikan gambar sampah secara nyata, sebanyak 368 jenis citra.
2. Pencarian citra secara daring dilakukan melalui mesin pencarian Google dengan memilih gambar dari berbagai situs yang menyediakan visual sampah anorganik, organik, dan elektronik. Gambar yang di peroleh sebanyak 4.716 gambar.

Tabel 2. Kombinasi ketentuan pengambilan citra secara umum

Aspek Variasi	Jenis Variasi	Jumlah
Latar belakang	Di tanah/ tempat asal	1
	Di atas permukaan datar dengan latar belakang polos dan bersih	1
Total latar belakang		**2**
Sudut pengambilan	Depan	1
	Atas	1
	Samping	1
Total sudut		**3**
Kondisi pencahayaan	Terang	1
	Agak gelap	1
Total pencahayaan		**2**
Jumlah kombinasi per jenis sampah	**(2 x 3 x 2)**	**12**

Tabel 3. Kombinasi ketentuan pengambilan citra jenis sampah tertentu

Aspek Variasi	Jenis Variasi	Jumlah
Latar belakang	Di tanah/ tempat asal	1
Total latar belakang		**1**
Sudut pengambilan	Depan	1
	Atas	1
	Samping	1
Total sudut		**3**
Kondisi pencahayaan	Terang	1
	Agak gelap	1
Total pencahayaan		**2**

Jumlah kombinasi per jenis sampah	(1 x 3 x 2)	**6**

Tabel 4. Distribusi data uji manual berdasarkan kategori dan jenis sampah Kategori Sampah Jenis Sampah Jumlah Variasi citra yang di ambil

Kategori Sampah	**Jenis Sampah**	**Jumlah Variasi citra yang di ambil**
Organik	Daun kering	42
	Kertas	42
	Kulit buah dan Sayur	42
Total variasi citra Organik		**126**
Anorganik	Kaca	42
	Logam	42
	Plastik	42
Total variasi citra Anorganik		**126**
Elektronik	Mesin cuci	44
	Televisi	44
	kabel	28
	Total variasi citra elektronik	**116**
Total Keseluruhan		**368**

Dengan demikian, dari proses pengambilan gambar secara manual diperoleh 368 citra asli yang terdiri dari berbagai jenis sampah pada tiga kategori. Berdasarkan kombinasi variasi pengambilan citra yang telah ditetapkan, dataset pengujian yang digunakan dalam penelitian ini berjumlah 3.468 gambar. Seluruh gambar dikumpulkan dalam masing-masing folder berdasarkan kelas. Jadi total dataset yang digunakan dalam penelitian ini terdiri dari 8.184 gambar yang digunakan sebagai data pelatihan dan validasi, yang terbagi ke dalam tiga kelas utama yaitu sampah organik, anorganik, dan elektronik. Distribusi tersebut dapat dilihat pada tabel 5 serta gambar 3 dan 4.

Tabel 5. Distribusi jumlah gambar per kelas

Kategori	**Jenis**	**Data Sekunder**	**Data Primer**
Anorganik	Total	2.003	1.512
	Kaca	665	504
	Logam	636	504
	Plastik	702	504
Elektronik	Total	835	696
	Kabel	228	168
	Mesin cuci	256	264
	Televisi	351	264
Organik	Total	1.858	1.260
	Daun kering	436	504

Kertas	720	504
Kulit buah dan sayur	702	252

Dataset disimpan di Google Drive dalam satu folder utama yang didalamnya terdapat 3 subfolder, masing-masing merepresentasikan 3 jenis sampah. Setiap subfolder dinamai sesuai dengan kelas yang ditetapkan berdasarkan studi literatur. Seluruh gambar disimpan dalam format .jpg dan .png, dengan penamaan file menggunakan urutan huruf dan angka (misalnya : gambar1.jpg, gambar2.png, dan seterusnya) untuk setiap kelas. Penamaan ini bertujuan untuk memudahkan proses perhitungan jumlah data dan pemanggilan data saat proses pelatihan model di lakukan.

3.2 Pra-Pemrosesan Data

Tahap pra-pemrosesan data dilakukan untuk memastikan seluruh citra yang digunakan dalam penelitian memiliki kualitas, format, dan ukuran yang seragam sebelum digunakan pada proses pelatihan model. Proses ini penting karena dataset yang diperoleh berasal dari berbagai sumber, yaitu data sekunder yang digunakan untuk pelatihan model dan data primer yang digunakan untuk pengujian model. Perbedaan sumber data dapat menyebabkan varian dalam format file, ukuran gambar, maupun kualitas citra, sehingga diperlakukan proses pra-pemrosesan untuk menyiapkan dataset agar sesuai dengan kebutuhan model klasifikasi berbasis deep learning.

Tahap pertama yang dilakukan adalah pembersihan data. Pembersihan data dilakukan untuk memastikan bahwa seluruh gambar yang digunakan dalam penelitian berada dalam kondisi yang valid dan dapat diproses oleh sistem. Pada tahap ini dilakukan pemeriksaan terhadap seluruh file gambar dalam dataset untuk memastikan hanya file dengan ekstensi yang didukung yang digunakan. Ekstensi gambar yang diterima dalam penelitian ini meliputi .jpg, .jpeg, .png, .bmp, dan .gif. proses ini dilakukan secara terprogram menggunakan Python dengan melakukan pengecekan terhadap struktur direktori dataset serta jumlah gambar pada setiap kelas. Pembersihan data bertujuan untuk menghindari kesalahan saat proses pembacaan gambar dan pelatihan model.

Setelah proses pembersihan data, tahap selanjutnya adalah penyesuaian format gambar agar sesuai dengan kebutuhan model deep learning yang digunakan. Pada penelitian ini, setiap gambar dipastikan memiliki tiga channel warna (RGB). Jika terdapat gambar yang memiliki satu channel (grayscale), maka gambar tersebut secara otomatis dikonversi menjadi tiga channel menggunakan fungsi pemrosesan citra pada TensorFlow. Selain itu, tipe data gambar juga diubah menjadi float32 sesuai dengan kebutuhan pipeline pemrosesan data dan kompatibel dengan proses komputasi pada model deep learning. Kemudian dilakukan penyesuaian ukuran gambar. Gambar dalam dataset memiliki ukuran yang bervariasi sehingga dilakukan penyeragaman dimensi sebelum digunakan dalam proses pelatihan model. Pada penelitian ini seluruh gambar diubah ukurannya menjadi 224 x 224 piksel, yang merupakan ukuran input yang sesuai dengan arsitektur model ResNet50V2. Proses penyesuaian ukuran ini dilakukan secara otomatis saat dataset dimuat menggunakan fungsi image_dataset_from_directory pada TensorFlow. Penyeragaman ukuran gambar bertujuan agar seluruh data memiliki dimensi yang konsisten sehingga dapat diproses secara optimal oleh model.

Tahap berikutnya adalah normalisasi nilai piksel gambar untuk menyesuaikan dengan kebutuhan model ResNet50V2. Normalisasi dilakukan menggunakan fungsi preprocess_input yang mengubah rentang nilai piksel dari 0 – 255 menjadi rentang -1 hingga 1. Proses ini bertujuan untuk meningkatkan stabilitas dan efisiensi proses

pelatihan model *deep learning*. Dengan melakukan normalisasi, distribusi nilai piksel menjadi lebih seimbang sehingga model dapat melakukan proses pembelajaran dengan lebih baik.

Setelah seluruh proses pra-pemrosesan selesai dilakukan, dataset kemudian dibagi menjadi beberapa bagian untuk keperluan pelatihan dan evaluasi model. Pada penelitian ini, data sekunder digunakan sebagai dataset pelatihan dan validasi dengan rasio pembagian 70% untuk training dan 30% untuk *validation*. Proses pembagian ini dilakukan secara otomatis dan acak menggunakan parameter *validation_split* pada TensorFlow, dengan ini *seed* tertentu agar pembagian data tetap konsisten setiap kali proses dijalankan. Sementara itu, primer digunakan sebagai dataset pengujian untuk mengevaluasi performa akhir model. Pembagian dataset ini bertujuan untuk memastikan bahwa model dilatih dan diuji menggunakan data yang berbeda sehingga hasil evaluasi yang diperoleh lebih objektif.

3.3 Augmentasi Data

Teknik augmentasi yang digunakan pada penelitian ini meliputi horizontal flip, rotation, zoom (*scaling*), dan translation (*shifting*). Setiap teknik memiliki tujuan tertentu untuk meningkatkan variasi data serta membantu model mengenali objek sampah dalam berbagai kondisi.

1. Flip Horizontal (pembalikan horizontal)
   Teknik horizontal flip dilakukan dengan membalik gambar secara horizontal atau dari kiri ke kanan. Implementasi teknik ini menggunakan lapisan RandomFlip ("horizontal") pada TensorFlow.
2. Rotasi (*Rotation Augmentation*)
   Teknik rotasi digunakan untuk memutar gambar dalam sudut tertentu agar model dapat mengenali objek sampah dari berbagai perspektif. Pada tahap implementasi, rotasi dilakukan pada rentang sekitar -15° hingga 15°, yang pada kode diimplementasikan menggunakan RandomRotation(0.04). Nilai 0.04 pada TensorFlow merepresentasikan sekitar 4% dari 360°.
3. *Scaling* (pembesaran dan pengecilan gambar)
   Teknik *scaling* atau zoom augmentation dilakukan untuk memberikan variasi ukuran objek dalam gambar. Pada penelitian ini teknik *scaling* diterapkan menggunakan lapisan RandomZoom (0.1). Nilai 0.1 menunjukkan bahwa gambar dapat mengalami perubahan ukuran hingga sekitar ±10% dari ukuran aslinya.
4. *Translation* (Perpindahan Posisi Gambar)
   Teknik *translation* digunakan untuk menggeser posisi objek dalam gambar ke arah kiri, kanan, atas, atau bawah. Teknik ini diimplementasikan menggunakan lapisan RandomTranslation (0.05, 0.05). Nilai 0.05 menunjukkan bahwa gambar dapat digeser hingga sekitar 5% dari dimensi gambar baik secara horizontal maupun vertikal.

3.4 Melatih Model

Proses pelatihan model klasifikasi citra dilakukan menggunakan arsitektur ResNet50V2 dengan pendekatan transfer learning untuk memanfaatkan representasi fitur visual yang telah dipelajari pada dataset ImageNet. Pendekatan ini memberikan keuntungan dalam meningkatkan efisiensi pelatihan dan stabilitas konvergensi model, terutama pada dataset penelitian yang memiliki jumlah data terbatas. Seluruh citra terlebih dahulu melalui tahap normalisasi menggunakan fungsi preprocess_input

ResNet50V2 yang mengubah rentang nilai piksel dari 0–255 menjadi rentang -1 hingga 1 agar sesuai dengan distribusi data pada model pretrained.

Pelatihan model dilakukan menggunakan dua tahap utama, yaitu tahap feature extraction dan fine-tuning. Pada tahap awal, seluruh lapisan pada ResNet50V2 dibekukan (freeze layer) untuk mempertahankan fitur umum yang telah dipelajari sebelumnya, sementara hanya lapisan klasifikasi tambahan yang dilatih. Arsitektur klasifikasi tambahan terdiri atas lapisan GlobalAveragePooling2D untuk mereduksi dimensi fitur spasial menjadi representasi global, diikuti oleh BatchNormalization untuk menstabilkan distribusi aktivasi jaringan, serta Dropout sebesar 0,5 sebagai mekanisme regularisasi untuk mengurangi risiko overfitting. Lapisan keluaran menggunakan fungsi aktivasi softmax untuk melakukan klasifikasi pada tiga kelas sampah yang digunakan dalam penelitian.

Proses pelatihan tahap pertama menggunakan optimizer Adam dengan learning rate sebesar 1e-4 dan fungsi loss Categorical Crossentropy dengan label smoothing sebesar 0,05. Penggunaan label smoothing bertujuan untuk menghindari kepercayaan prediksi yang terlalu tinggi pada satu kelas tertentu sehingga dapat meningkatkan kemampuan generalisasi model. Untuk mengatasi ketidakseimbangan distribusi data antar kelas, diterapkan teknik class weighting yang memberikan bobot lebih besar pada kelas dengan jumlah data yang lebih sedikit sehingga model dapat belajar secara lebih seimbang terhadap seluruh kelas. Selain itu, dilakukan penyesuaian tambahan pada bobot kelas tertentu yang memiliki kecenderungan kesalahan klasifikasi lebih tinggi, sehingga model dapat memberikan perhatian lebih pada kelas tersebut selama proses pelatihan.

Selain itu, proses pelatihan juga memanfaatkan beberapa mekanisme callback untuk meningkatkan stabilitas proses training. Callback yang digunakan meliputi ModelCheckpoint untuk menyimpan model terbaik berdasarkan nilai validation accuracy, EarlyStopping untuk menghentikan proses pelatihan secara otomatis apabila nilai validation loss tidak mengalami peningkatan dalam beberapa epoch, serta ReduceLROnPlateau yang berfungsi menurunkan learning rate ketika performa validasi mengalami stagnasi. Penggunaan callback ini membantu mempercepat konvergensi model sekaligus mencegah terjadinya overfitting selama proses pelatihan.

Proses training tahap pertama dilakukan hingga 20 epoch. Training accuracy meningkat dari 38.01% di epoch pertama hingga 90.0% di epoch terakhir, sedangkan validation accuracy meningkat dari 75.25% hingga 92.93%. Nilai loss menurun secara konsisten dari 1.9056 menjadi 0.3482. Precision dan recall pada validation set masing-masing mencapai 0.9331 dan 0.9272, menunjukkan model mampu memprediksi setiap kelas secara seimbang.

Tahap pelatihan kedua dilakukan menggunakan strategi fine-tuning parsial dengan membuka kembali beberapa lapisan pada model ResNet50V2. Pada tahap ini, 120 lapisan awal tetap dibekukan, sementara lapisan setelahnya diaktifkan untuk dilatih sehingga model dapat menyesuaikan bobot jaringan dengan karakteristik dataset penelitian. Lapisan Batch Normalization tetap dibekukan untuk menjaga stabilitas distribusi statistik selama proses pelatihan. Selain itu, digunakan *learning rate* yang lebih kecil yaitu 1e-5 agar proses penyesuaian bobot berlangsung lebih halus dan tidak merusak representasi fitur umum yang telah dipelajari dari dataset ImageNet. Strategi ini memungkinkan model mempelajari karakteristik spesifik dataset tanpa mengurangi kemampuan generalisasi dari model pretrained.

Hasil pelatihan tahap fine-tuning parsial dilakukan selama 15 epoch dengan *learning rate* 1e-5. *Validation accuracy* meningkat dari 92.93% pada tahap *feature extraction*

menjadi 97.17%, dan validation loss menurun dari 0.348 menjadi 0.274. Precision dan *recall* masing-masing meningkat menjadi 0.9723 dan 0.9689, menandakan model lebih sensitif dan tepat dalam klasifikasi tiga kelas sampah. Peningkatan ini menegaskan bahwa strategi fine-tuning parsial berhasil meningkatkan kemampuan model dalam mengekstraksi fitur spesifik dataset. *Learning curve* dapat dilihat pada gambar 5.

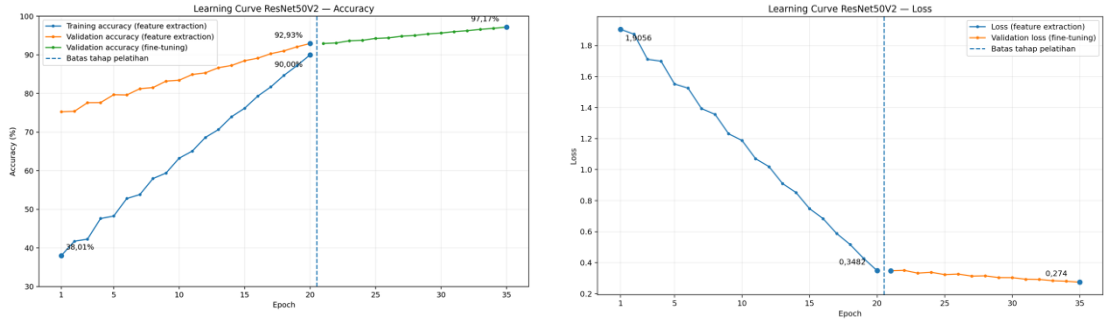

Gambar 5. *Learning curve* ResNet50V2 -*Accuracy & Lost*

3.5 Evaluasi Model

Berdasarkan hasil pengujian terhadap 3.468 citra, model memperoleh *accuracy* sebesar 83,91%, *precision* sebesar 84,86%, dan *recall* sebesar 82,73%. Hasil ini menunjukkan bahwa model mampu melakukan klasifikasi dengan cukup baik meskipun diuji menggunakan dataset yang berasal dari sumber yang berbeda dengan data pelatihan.

Berdasarkan *classification report*, kelas anorganik memiliki nilai F1-*score* tertinggi sebesar 0,86, sedangkan kelas elektronik dan organik masing-masing memperoleh F1-*score* sebesar 0,83. Nilai *precision* tertinggi terdapat pada kelas elektronik sebesar 0,94, namun nilai *recall* pada kelas tersebut lebih rendah yaitu 0,74, yang menunjukkan masih terdapat beberapa citra elektronik yang diklasifikasikan ke kelas lain.

Analisis *confusion matrix* menunjukkan bahwa sebagian besar prediksi berada pada diagonal utama. Sebagai contoh, 1.271 citra anorganik, 518 citra elektronik, dan 1.121 citra organik berhasil diklasifikasikan dengan benar oleh model. Visualisasi *confusion matrix* ditunjukkan pada gambar 6.

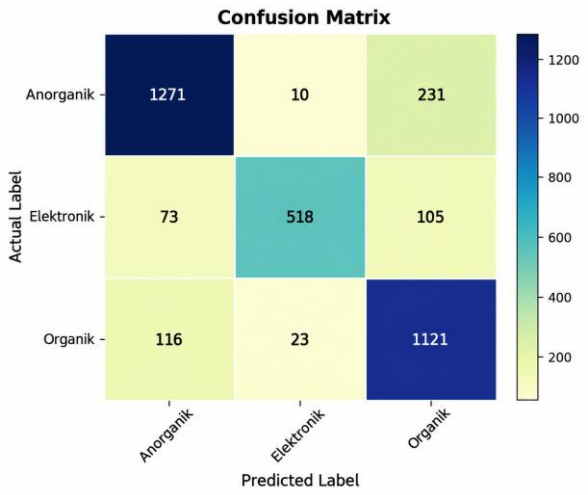

Gambar 6. *Confusion matrix*

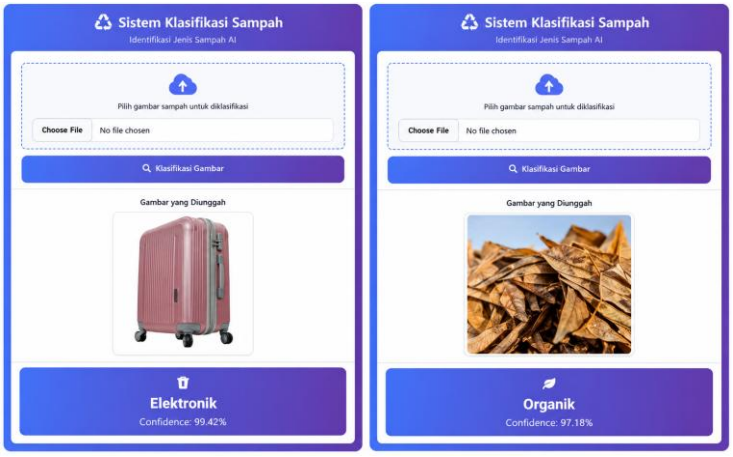

Gambar 7. Contoh prediksi pada citra di luar kategori pelatihan dengan *confidence* tinggi

Berdasarkan gambar 7, terlihat bahwa model tetap memberikan prediksi terhadap citra yang tidak termasuk dalam kategori pelatihan dengan nilai *confidence* yang relatif tinggi.



Gambar 8. variasi citra seperti citra grayscale dan citra biner

Hasil pengujian pada gambar 8 menunjukkan bahwa model mampu melakukan prediksi pada citra grayscale maupun biner. Secara keseluruhan, hasil evaluasi menunjukkan bahwa model ResNet50V2 mampu mengekstraksi fitur visual dengan baik pada data pengujian.

3.6 Implementasi Sistem Klasifikasi Jenis Sampah di Aceh Berbasis Web

Setelah diperoleh model klasifikasi terbaik menggunakan arsitektur ResNet50V2, tahap selanjutnya adalah mengimplementasikan model tersebut ke dalam sebuah prototipe aplikasi berbasis web. Implementasi sistem dilakukan secara lokal menggunakan framework Flask tanpa melakukan *deployment* ke server publik. Aplikasi ini dirancang untuk membantu proses identifikasi jenis sampah di Aceh, yaitu organik, anorganik, dan elektronik, melalui input berupa gambar. Tampilan pada system tersebut dapat dilihat pada gambar 9

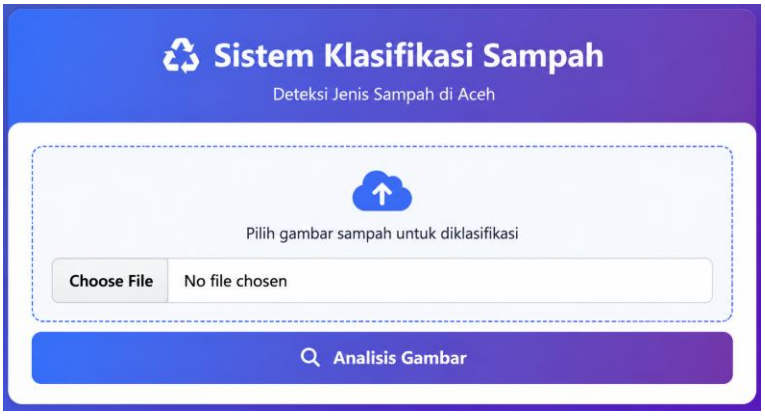

Gambar 9. Tampilan antarmuka implementasi sistem klasifikasi jenis sampah di Aceh berbasis web

4. Kesimpulan dan Saran

4.1 Kesimpulan

Berdasarkan hasil penelitian mengenai implementasi sistem klasifikasi jenis sampah di Aceh menggunakan model ResNet50V2 berbasis web, maka dapat diambil beberapa Kesimpulan sebagai berikut :

1. Penelitian ini telah menerapkan model klasifikasi citra menggunakan pendekatan computer vision untuk mengenali tiga jenis sampah, yaitu sampah organik, anorganik, dan elektronik. Model dibangun menggunakan arsitektur ResNet50V2 dengan pendekatan *transfer learning* serta didukung oleh proses pra-pemrosesan data dan augmentasi citra untuk meningkatkan variasi data pelatihan.
2. Berdasarkan hasil evaluasi model menggunakan dataset pengujian sebanyak 3.468 citra, model ResNet50V2 memperoleh nilai *accuracy* sebesar 83,91%, *precision* sebesar 84,86%, dan *recall* sebesar 82,73%. Hasil ini menunjukkan bahwa model memiliki kemampuan dalam mengklasifikasikan jenis sampah meskipun diuji menggunakan data yang berbeda dengan data pelatihan.
3. Model klasifikasi yang telah dikembangkan berhasil diimplementasikan kedalam sebuah *prototype* aplikasi berbasis web sederhana menggunakan *framework* Flask. Aplikasi ini memungkinkan pengguna untuk mengunggah gambar sampah melalui browser, kemudian sistem akan melakukan proses pra-pemrosesan citra dan menampilkan hasil klasifikasi secara otomatis sesuai dengan kategori sampah yang terdeteksi.

4.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran yang dapat dipertimbangkan untuk pengembangan penelitian selanjutnya, yaitu sebagai berikut:

1. Penelitian selanjutnya disarankan untuk menambah jumlah dataset serta memperluas variasi jenis sampah agar model dapat mempelajari lebih banyak karakteristik objek dan meningkatkan akurasi klasifikasi.
2. Penelitian berikutnya dapat membandingkan performa beberapa arsitektur *deep learning* lainnya, seperti MobileNet, EfficientNet, atau DenseNet, untuk mengetahui model yang paling optimal dalam melakukan klasifikasi jenis sampah.
3. Pengembangan sistem dapat dilakukan dengan melakukan *deployment* aplikasi ke server atau *platform cloud* sehingga sistem dapat diakses secara luas oleh masyarakat melalui internet.

4. Sistem juga dapat dikembangkan dengan menambahkan fitur deteksi objek secara langsung menggunakan kamera (*real-time detection*) sehingga proses identifikasi sampah dapat dilakukan secara lebih praktis.

Daftar Pustaka

[1] CNBC Indonesia, "RI Hasilkan 69,7 Juta Ton Sampah per Tahun, Ini Datanya.," hlm. https://www.cnbcindonesia.com/news/20240625131019-4-549127/ri-hasilkan-697-juta-ton-sampah-per-tahun-ini-datanya., 2024.

[2] The Aceh Post, "Sepanjang Tahun 2024 Produksi Sampah di Banda Aceh Capai 93.258 Ton," 2024. [Daring]. Tersedia pada: https://theacehpost.com/news/sepanjang-tahun-2024-produksi-sampah-di-banda-aceh-capai-93-258-ton.

[3] AJNN, "Produksi Sampah di Aceh Timur Meningkat Capai 90 Ton per Hari," 2024b. [Daring]. Tersedia pada: https://www.ajnn.net/news/produksi-sampah-di-aceh-timur-meningkat-capai-90-ton-per-hari.

[4] AJNN, "Aceh Besar Produksi 95 Ton Sampah per Hari Selama Ramadan," 2024a. [Daring]. Tersedia pada: https://www.ajnn.net/news/aceh-besar-produksi-95-ton-sampah-per-hari-selama-ramadan.

[5] Supiyandi Supiyandi dan Rafif Rasendriya, "Penggunaan Visi Komputer untuk Mengidentifiksi Jenis Buah dari Gambar," *Router J. Tek. Inform. Dan Terap.*, vol. 2, no. 4, hlm. 94–103, Nov 2024, doi: 10.62951/router.v2i4.287.

[6] D. Hastari, S. Winanda, A. R. Pratama, N. Nurhaliza, dan E. S. Ginting, "Application of Convolutional Neural Network ResNet-50 V2 on Image Classification of Rice Plant Disease," *Public Res. J. Eng. Data Technol. Comput. Sci.*, vol. 1, no. 2, Feb 2024, doi: 10.57152/predatecs.v1i2.865.

[7] Luntungan Stephen Pieters, "Development of Automatic Waste Classification System using CNN-Based Deep Learning to Support Smart Waste Management," *INOVTEK Polbeng - Seri Inform.*, vol. 10, no. 1, hlm. 214–224, Mar 2025, doi: 10.35314/wst8mh87.

[8] Doly Ilham Saputra Huta Julu dan Dewi Nurdiyah, "KLASIFIKASI SAMPAH ORGANIK DAN NON ORGANIK MENGGUNAKAN TRANSFER LEARNING," *J. Transform.*, vol. 23, no. 1, hlm. 12–29, Jul 2025, doi: 10.26623/transformatika.v23i1.12201.

[9] H. J. Mustaqim dan O. Suria, "Comparative Analysis of ResNet50V2, ResNet152V2, and MobileNetV2 Architectures in Monkeypox Classification," vol. 9, no. 4.

[10] M. Molchanova, V. Didur, O. Mazurets, dan O. Sobko, "Method for Construction and Demolition Waste Classification Using Two-Factor Neural Network Image Analysis ⋆".

[11] K. M. Sukiakhy, J. Junidar, dan S. A. Nazhifah, "PENGGUNAAN DATA PADA TWITTER DALAM KLASIFIKASI DAN VISUALISASI CYBERBULLYING DENGAN ALGORITMA SVM (SUPPORT VECTOR MACHINE)," *Cyberspace J. Pendidik. Teknol. Inf.*, vol. 7, no. 1, hlm. 1, Mar 2023, doi: 10.22373/cj.v7i1.17358.

[12] M. Mizanur Rahman *dkk.*, "Efficient brain cancer identification using ResNet50 and ResNet50 V2: a comparative study with a primary MRI dataset," *Bull. Electr. Eng. Inform.*, vol. 14, no. 4, hlm. 2849–2860, Agu 2025, doi: 10.11591/eei.v14i4.9142.

[13] J. Liang, "Image classification based on RESNET," *J. Phys. Conf. Ser.*, vol. 1634,

no. 1, hlm. 012110, Sep 2020, doi: 10.1088/1742-6596/1634/1/012110.

[14] P. A. Nugroho, I. Fenriana, R. Arijanto, dan M. Kom, "IMPLEMENTASI DEEP LEARNING MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) PADA EKSPRESI MANUSIA," vol. 2, no. 1, 2020.

[15] M. R. Alwanda, R. P. K. Ramadhan, dan D. Alamsyah, "Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle," *J. Algoritme*, vol. 1, no. 1, hlm. 45–56, Okt 2020, doi: 10.35957/algoritme.v1i1.434.

[16] A. A. A. Paliwang, M. R. D. Septian, dan M. Cahyanti, "KLASIFIKASI PENYAKIT TANAMAN APEL DARI CITRA DAUN DENGAN CONVOLUTIONAL NEURAL NETWORK".

[17] A. Ibnul Rasidi, Y. A. H. Pasaribu, A. Ziqri, dan F. D. Adhinata, "Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network," *J. Tek. Inform. Dan Sist. Inf.*, vol. 8, no. 1, Apr 2022, doi: 10.28932/jutisi.v8i1.4314.

[18] Z. Lin *dkk.*, "Protocol for performing deep learning-based fundus fluorescein angiography image analysis with classification and segmentation tasks," *STAR Protoc.*, vol. 5, no. 3, hlm. 103134, Sep 2024, doi: 10.1016/j.xpro.2024.103134.