



Metode *Systematic Literature Review* Arsitektur *Convolutional Neural Network* untuk Klasifikasi Sampah Berbasis Citra

Bambang Setia Budi^{1*}, Yulia Fatma²

^{1,2}Program Studi Teknik Informatika, Universitas Muhammadiyah Riau, Pekanbaru, Indonesia

Email: 220401043@student.umri.ac.id¹, yuliafatma@umri.ac.id²

*Penulis Korespondensi: 220401043@student.umri.ac.id

Abstract. Waste management is becoming increasingly complex as the volume and variety of waste types increase, making manual sorting processes inefficient and error-prone. In recent years, image-based waste classification using Deep Learning (DL), particularly Convolutional Neural Networks (CNN), has been widely developed as an automated waste sorting solution. This study aims to conduct a Systematic Literature Review (SLR) to analyze the performance, trends, and utilization of CNN architectures in image-based waste classification. The SLR method is carried out systematically through the stages of planning, literature search, study selection, data extraction, and result synthesis. A total of 15 scientific articles published between 2020 and 2025 were analyzed with a focus on CNN architecture, preprocessing techniques, dataset characteristics, number of classes, and evaluation metrics such as accuracy, precision, recall, and F1-score. The results of the study show that CNNs are capable of providing high classification performance in various scenarios. Standard CNNs are effective on small datasets with a limited number of classes, while transfer learning approaches such as MobileNetV2, ResNet50, VGG16, and EfficientNet show more stable performance in multi-class classification. Overall, CNN proved to be an effective and adaptive approach to support computer vision-based automated waste sorting systems.

Keywords: CNN; Computer Vision; DL; Systematic Literature Review; Waste Classification.

Abstrak. Pengelolaan sampah semakin kompleks seiring meningkatnya volume dan variasi jenis sampah, sehingga proses pemilahan manual menjadi tidak efisien dan rentan kesalahan. Dalam beberapa tahun terakhir, klasifikasi sampah berbasis citra menggunakan Deep Learning (DL), khususnya Convolutional Neural Network (CNN), banyak dikembangkan sebagai solusi pemilahan sampah otomatis. Penelitian ini bertujuan melakukan Systematic Literature Review (SLR) untuk menganalisis kinerja, tren, dan pemanfaatan arsitektur CNN dalam klasifikasi sampah berbasis citra. Metode SLR dilakukan secara sistematis melalui tahapan perencanaan, pencarian literatur, seleksi studi, ekstraksi data, dan sintesis hasil. Sebanyak 15 artikel ilmiah yang dipublikasikan pada rentang tahun 2020–2025 dianalisis dengan fokus pada arsitektur CNN, teknik preprocessing, karakteristik dataset, jumlah kelas, serta metrik evaluasi seperti akurasi, presisi, recall, dan F1-score. Hasil kajian menunjukkan bahwa CNN mampu memberikan performa klasifikasi yang tinggi pada berbagai skenario. CNN standar efektif pada dataset kecil dengan jumlah kelas terbatas, sedangkan pendekatan transfer learning seperti MobileNetV2, ResNet50, VGG16, dan EfficientNet menunjukkan performa yang lebih stabil pada klasifikasi multi-kelas. Secara keseluruhan, CNN terbukti sebagai pendekatan yang efektif dan adaptif untuk mendukung sistem pemilahan sampah otomatis berbasis visi komputer.

Kata Kunci: CNN; Deep Learning; Klasifikasi Limbah; Tinjauan Pustaka Sistematis; Visi Komputer.

1. LATAR BELAKANG

Permasalahan pengelolaan sampah menjadi isu global yang semakin kompleks seiring meningkatnya pertumbuhan populasi, urbanisasi, dan aktivitas industri. Volume sampah yang terus meningkat disertai dengan keragaman jenis material seperti plastik, kertas, logam, organik, dan elektronik membuat proses pemilahan secara manual semakin tidak efisien. Metode pemilahan tradisional tidak hanya memakan waktu dan tenaga, tetapi juga memiliki tingkat akurasi yang rendah serta berpotensi menimbulkan risiko kesehatan bagi petugas yang terlibat. Kondisi ini menekankan perlunya solusi modern yang lebih cepat, konsisten, dan terukur untuk mendukung program daur ulang dan keberlanjutan lingkungan.

Dalam beberapa tahun terakhir, teknologi pengolahan citra berbasis kecerdasan buatan, khususnya deep learning, mulai banyak diterapkan untuk mengatasi tantangan tersebut. Salah satu arsitektur yang terbukti unggul dalam tugas klasifikasi citra adalah Convolutional Neural Network (CNN). CNN mampu mengekstraksi fitur visual secara otomatis melalui lapisan konvolusi yang tersusun hierarkis, sehingga model dapat mengenali pola visual kompleks seperti tekstur, bentuk, tepi, maupun warna dari objek sampah. Beberapa penelitian melaporkan bahwa penggunaan sejumlah lapisan konvolusi yang dikombinasikan dengan teknik regularisasi—misalnya dropout—dapat meningkatkan akurasi model secara signifikan dan mengurangi risiko overfitting (Chhabra et al., 2022).

Selain penggunaan arsitektur CNN dasar, sejumlah studi telah mengadopsi arsitektur modern seperti Visual Geometry Group (VGG) 16 dan DenseNet untuk pemilahan sampah. Model-model ini dirancang untuk memperdalam representasi fitur dan meminimalkan masalah seperti hilangnya gradien, sehingga jaringan mampu belajar pola visual yang lebih kompleks dan stabil. Penerapan arsitektur tersebut pada citra sampah terbukti menghasilkan performa klasifikasi yang tinggi pada berbagai jenis material sampah yang memiliki variasi pencahayaan, bentuk, dan latar belakang (Dhande, 2022).

Kemajuan lainnya muncul dari pemanfaatan data augmentation dan strategi transfer learning menggunakan model pretrained seperti MobileNetV2 dan EfficientNet. Pendekatan ini membantu meningkatkan generalisasi model, terutama ketika dataset berukuran relatif kecil atau tidak seimbang. Berbagai penelitian menunjukkan bahwa transfer learning mampu mempercepat proses pelatihan, mengurangi kebutuhan dataset besar, serta mencapai akurasi tinggi pada klasifikasi sampah baik dalam skenario multi-kelas maupun biner (Nasir & Aziz Al-Talib, 2023).

Dengan semakin banyaknya penelitian menggunakan berbagai arsitektur CNN, teknik praproses, dan pendekatan optimasi yang berbeda, maka diperlukan sebuah kajian literatur sistematis (Systematic Literature Review) untuk memetakan perkembangan teknologi tersebut. SLR ini bertujuan untuk merangkum tren penelitian, mengidentifikasi pendekatan yang paling efektif, membandingkan performa model, serta mengungkap celah penelitian (research gap) yang dapat menjadi dasar dalam pengembangan sistem klasifikasi sampah berbasis citra yang lebih akurat, efisien, dan aplikatif pada implementasi dunia nyata.

2. KAJIAN TEORITIS

Klasifikasi sampah berbasis citra merupakan salah satu penerapan teknologi visi komputer yang bertujuan untuk mengidentifikasi dan mengelompokkan jenis sampah secara otomatis berdasarkan karakteristik visual yang terdapat pada citra digital. Teknologi ini dikembangkan untuk mengatasi keterbatasan proses pemilahan sampah secara manual yang cenderung memerlukan waktu lebih lama, rentan terhadap kesalahan, dan memiliki risiko kesehatan bagi petugas. Dengan memanfaatkan citra sebagai sumber informasi, sistem klasifikasi mampu mengenali perbedaan bentuk, warna, tekstur, dan pola objek sampah sehingga proses pemilahan dapat dilakukan secara lebih cepat, konsisten, dan efisien. Perkembangan teknologi kecerdasan buatan telah mendorong penggunaan metode pembelajaran mendalam (Deep Learning) sebagai pendekatan utama dalam menyelesaikan permasalahan klasifikasi citra, termasuk pada bidang pengelolaan sampah.


Salah satu metode Deep Learning yang paling banyak digunakan dalam klasifikasi citra adalah Convolutional Neural Network (CNN). CNN merupakan arsitektur jaringan saraf tiruan yang dirancang untuk mengekstraksi fitur visual secara otomatis melalui serangkaian lapisan konvolusi, fungsi aktivasi, dan pooling. Berbeda dengan metode konvensional yang memerlukan ekstraksi fitur secara manual, CNN mampu mempelajari representasi fitur secara hierarkis mulai dari fitur sederhana seperti tepi dan tekstur hingga fitur kompleks berupa bentuk objek. Kemampuan tersebut menjadikan CNN sangat efektif dalam berbagai tugas pengenalan citra, termasuk klasifikasi sampah yang memiliki karakteristik visual yang beragam. Berbagai penelitian menunjukkan bahwa CNN mampu menghasilkan performa klasifikasi yang tinggi dan stabil pada berbagai jenis dataset citra sampah.

Seiring perkembangan penelitian, berbagai arsitektur CNN modern telah dikembangkan untuk meningkatkan performa klasifikasi citra. Arsitektur seperti VGG16, ResNet50, MobileNetV2, dan EfficientNet menjadi model yang banyak digunakan karena mampu memberikan keseimbangan antara akurasi dan efisiensi komputasi. ResNet50 memanfaatkan mekanisme skip connection untuk mengatasi permasalahan vanishing gradient pada jaringan yang dalam, sedangkan MobileNetV2 dirancang agar lebih ringan dan efisien untuk perangkat dengan sumber daya terbatas. EfficientNet menawarkan optimasi skala jaringan yang lebih baik melalui pendekatan compound scaling. Berdasarkan hasil kajian literatur, model-model tersebut menunjukkan performa yang lebih stabil dibandingkan CNN standar, terutama pada klasifikasi sampah multi-kelas yang memiliki tingkat kompleksitas visual yang tinggi.

Selain pemilihan arsitektur, performa CNN juga dipengaruhi oleh teknik pendukung seperti data augmentation, transfer learning, dan fine-tuning. Data augmentation digunakan untuk meningkatkan variasi data pelatihan melalui transformasi citra seperti rotasi, flipping, dan zooming sehingga dapat mengurangi risiko overfitting. Sementara itu, transfer learning memungkinkan model memanfaatkan pengetahuan yang telah dipelajari dari dataset besar seperti ImageNet, sehingga proses pelatihan menjadi lebih cepat dan efektif meskipun jumlah data terbatas. Hasil sintesis berbagai penelitian menunjukkan bahwa kombinasi transfer learning, fine-tuning, dan data augmentation merupakan pendekatan yang paling efektif untuk meningkatkan akurasi serta kemampuan generalisasi model CNN dalam klasifikasi sampah berbasis citra.

3. METODE PENELITIAN

Penelitian ini menggunakan metode Systematic Literature Review (SLR) sebagai pendekatan utama untuk mengkaji penelitian terkait arsitektur CNN dalam klasifikasi sampah berbasis citra. Proses SLR dilakukan secara sistematis melalui tiga tahapan utama, sebagaimana ditunjukkan pada Gambar 1, yaitu perencanaan dan identifikasi topik, pencarian serta seleksi literatur, dan sintesis temuan serta penyusunan kesimpulan.



Gambar 1. Metodologi Penelitian.

Tahap perencanaan dan identifikasi topik bertujuan untuk merumuskan fokus penelitian dan ruang lingkup kajian. Selanjutnya, dilakukan pencarian dan seleksi literatur dari berbagai sumber ilmiah yang relevan berdasarkan kriteria inklusi dan eksklusi yang telah ditetapkan. Tahap akhir berupa sintesis temuan dilakukan dengan menganalisis dan mengintegrasikan hasil-hasil penelitian terpilih guna memperoleh gambaran komprehensif mengenai perkembangan model CNN, karakteristik dataset, serta capaian akurasi dalam klasifikasi sampah berbasis citra.

Perencanaan dan Identifikasi Topik

Tahap perencanaan dan identifikasi topik dilakukan untuk menentukan fokus kajian serta merumuskan ruang lingkup penelitian secara sistematis.

Pada tahap ini dilakukan analisis tren metode deep learning dan perumusan pertanyaan penelitian sebagai dasar pelaksanaan Systematic Literature Review sebagai berikut :

Analisis Tren Metode Deep Learning

Tahap awal penelitian diawali dengan perumusan pertanyaan penelitian yang berfokus pada identifikasi arsitektur CNN yang digunakan dalam klasifikasi sampah berbasis citra, teknik praproses dan augmentasi data yang diterapkan, serta performa model berdasarkan metrik evaluasi yang dilaporkan pada penelitian sebelumnya. Pada tahap ini juga ditentukan ruang lingkup penelitian, rentang tahun publikasi, serta kata kunci yang digunakan dalam proses penelusuran literatur.

Sebagai bagian dari proses perencanaan, dilakukan penelusuran awal literatur menggunakan Google Scholar dengan beberapa kata kunci metode Deep Learning utama, seperti CNN, RNN, LSTM, GAN, Autoencoder, dan MLP. Penelusuran awal ini bertujuan untuk memetakan tren penggunaan metode Deep Learning dalam publikasi ilmiah dan menjadi dasar dalam menentukan fokus penelitian. Hasil pemetaan awal menunjukkan bahwa CNN merupakan metode yang paling dominan digunakan dalam penelitian Deep Learning, khususnya pada bidang pengolahan citra, dibandingkan metode lainnya. Ringkasan hasil penelusuran awal tersebut disajikan dalam Tabel 1.

Tabel 1. Metode Deep Learning.

No	Metode Deep Learning	Jumlah Hasil Pencarian (Google Scholar)
1	Convolutional Neural Network (CNN)	1.290.000
2	Generative Adversarial Network (GAN)	1.160.000
3	Long Short-Term Memory (LSTM)	588.000
4	Multilayer Perceptron (MLP)	112.000
5	Recurrent Neural Network (RNN)	110.000
6	Autoencoder	105.000

Berdasarkan hasil pemetaan tersebut, penelitian ini memfokuskan kajian pada pengembangan dan evaluasi arsitektur CNN modern, seperti VGG, ResNet, MobileNet, dan EfficientNet, yang secara luas digunakan dalam penelitian klasifikasi sampah berbasis citra. Tujuan utama dari tahap perencanaan ini adalah memperoleh pemahaman yang komprehensif mengenai perkembangan teknologi klasifikasi sampah serta memastikan bahwa topik yang dipilih relevan, aktual, dan didukung oleh tren penelitian terkini.

Perumusan Research Questions

Berdasarkan latar belakang dan hasil pemetaan awal literatur, penelitian ini merumuskan empat pertanyaan penelitian (Research Questions/RQ) sebagai dasar dalam proses Systematic Literature Review.

Pertanyaan-pertanyaan ini dirancang untuk mengidentifikasi tren arsitektur, faktor yang memengaruhi performa model, serta pendekatan yang paling efektif dalam klasifikasi sampah berbasis citra menggunakan Convolutional Neural Network (CNN).

Adapun Research Questions dalam penelitian ini, yaitu: RQ1: Arsitektur CNN apa yang paling banyak digunakan dalam klasifikasi sampah berbasis citra?, RQ2 : Bagaimana pengaruh jumlah kelas terhadap akurasi model CNN pada klasifikasi sampah?, RQ3: Seberapa besar pengaruh ukuran dataset terhadap performa klasifikasi sampah berbasis CNN?, RQ4: Pendekatan apa yang paling efektif untuk meningkatkan performa CNN pada klasifikasi sampah multi- kelas?.

Pencarian dan Seleksi Literatur

Pencarian literatur dilakukan pada beberapa database akademik kredibel seperti Google Scholar, IEEE Xplore, Garuda, ResearchGate, Sinta . Pencarian difokuskan pada artikel yang dipublikasikan antara 2020 hingga 2025, menggunakan kata kunci seperti “*waste classification*”, “*transfer learning*”, “*CNN architecture*”, “*deep learning*”, “*trash dataset*”, dan “*image classification*”. Kriteria inklusi meliputi: 1) artikel jurnal atau prosiding yang membahas klasifikasi sampah berbasis citra, 2) menggunakan arsitektur CNN atau model Deep Learning terkait, 3) menyediakan informasi mengenai dataset, metode, dan hasil evaluasi.

Sementara itu, kriteria eksklusi mencakup artikel yang tidak menggunakan CNN, tidak menyediakan hasil eksperimen, tidak relevan dengan topik, atau hanya berupa abstrak tanpa akses penuh. Dari pencarian awal, diperoleh lebih dari 74 artikel yang sesuai dengan kata kunci. Setelah melalui proses seleksi berdasarkan relevansi, kelengkapan isi, dan kesesuaian topik, hanya 15 artikel yang dianggap relevan dan digunakan sebagai bahan utama dalam studi ini.

Sintesis Temuan dan Penyusunan Kesimpulan

Tahap akhir adalah melakukan sintesis terhadap hasil ekstraksi data dari setiap artikel terpilih. Pada tahap ini, seluruh penelitian dibandingkan berdasarkan arsitektur CNN yang digunakan, teknik augmentasi, metode praproses citra, dataset yang digunakan, serta performa model seperti akurasi, precision, recall, dan F1-score. Analisis ini memberikan gambaran umum mengenai tren arsitektur CNN yang paling banyak digunakan, efektivitas teknik praproses, serta tantangan-tantangan yang masih ditemui dalam klasifikasi sampah berbasis citra, seperti variasi kondisi lingkungan dan keterbatasan data.

Melalui sintesis ini, penelitian diharapkan dapat memberikan pemahaman yang lebih mendalam mengenai perkembangan model CNN untuk klasifikasi sampah serta memberikan wawasan mengenai arah penelitian lanjutan, termasuk potensi peningkatan akurasi melalui arsitektur modern dan teknik praproses yang lebih adaptif.

4. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil kajian terhadap 15 artikel terpilih yang telah melalui proses seleksi berdasarkan kriteria inklusi dan eksklusi. Pembahasan dibagi menjadi dua bagian utama, yaitu deskripsi karakteristik studi yang ditinjau serta analisis sintesis berdasarkan pertanyaan penelitian (Research Question). Pemisahan ini bertujuan untuk memberikan gambaran deskriptif terlebih dahulu sebelum dilakukan analisis komparatif secara sistematis.

Subbagian ini memaparkan karakteristik masing-masing penelitian yang dianalisis, meliputi arsitektur model, jumlah dataset, jumlah kelas, teknik praproses, serta capaian akurasi. Informasi tersebut dirangkum dalam tabel 2 perbandingan dan diuraikan secara singkat untuk memberikan konteks terhadap variasi pendekatan yang digunakan dalam klasifikasi sampah berbasis citra.

Tabel 2. Perbandingan *Literatur Riview*.

No	Judul Artikel	Arsitektur Model	Akurasi	Jumlah Dataset	Jumlah Kelas
1	Klasifikasi Sampah Berbasis Convolutional Neural Networks (CNN) untuk Peningkatan Efisiensi Pengelolaan Sampah (Kadyanan et al., 2024)	Convolutional Neural Network (CNN)	88%	25.000	2 Kelas
2	Klasifikasi Sampah Organik dan Anorganik Menggunakan Algoritma CNN (Purba et al., 2025)	CNN custom (5 layer)	94,88%	1.000	2 Kelas
3	Klasifikasi Sampah Rumah Tangga Menggunakan Metode Convolutional Neural Network (Sadida Aulia et al., 2024)	MobileNet (CNN)	86%	7.441	3 Kelas
4	Klasifikasi Jenis Sampah Menggunakan Metode Transfer Learning Pada Convolutional Neural Network (Wahyu & Ketut, 2024)	Transfer learning CNN (EffecienNet-B0)	88,53%	12.412	12 Kelas
5	Perbaikan Klasifikasi Sampah Menggunakan Pretrained CNN (Zayd et al., 2022)	AlexNet ResNet-18 ResNet-50	81,66% 87,99% 91,16%	2.532	6 Kelas
6	Penerapan Model Arsitektur VGG16 Untuk Klasifikasi Jenis Sampah (Sutanty et al., 2023)	VGG 16 (CNN)	82,89%	8.136	10 Kelas
7	Optimasi Model Resnet50 Untuk Klasifikasi Sampah (Sihabillah et al., 2025)	ResNet50 (CNN)	81%	22.564	2 Kelas
8	Pendeteksian dan Klasifikasi Sampah pada Bank Sampah Berbasis Web Menggunakan YOLOv11 (Nabila et al., 2025)	YOLOv11	91,7%	26.959	9 Kelas
9	Klasifikasi Jenis Sampah Menggunakan Metode Convolutional Neural Network (Hajid et al., 2025)	Convolutional Neural Network	98%	300	3 Kelas
10	Klasifikasi Jenis Sampah Menggunakan Base ResNet-50 (Nuariputri & Sukmasetya, 2023)	CNN ResNet-50 (fine-tuned)	98,70%	2751	7 Kelas
11	Klasifikasi Sampah Daur Ulang Menggunakan Convolutional Neural	Hybrid CNN + GLCM (fitur tekstur + deep feature)	83,30%	2527	6 Kelas

	Network Dan Gray Level Co-Occurrence Matrix (Abdan & Akbar, 2025)				
12	Identifikasi Pemilahan Sampah Berbasis Algoritma Transfer Learning CNN Menggunakan MobileNetV2 dan EfficientNetB0 (Thio & Susilo, 2025)	MobileNetV2	87,31%	2527	6 Kelas
13	Klasifikasi Sampah Organik dan Anorganik Menggunakan Transfer Learning MobileNetV2 pada Citra Digital (Syarif et al., 2025)	MobileNetV2	87%	2.990	2 Kelas
14	Klasifikasi Sampah Organik Dan Non Organik Menggunakan Transfer Learning (Julu & Nurdiah, 2025)	VGG16	88,10%		
		MobileNetV2	90,13%	26.478	2 Kelas
		ResNet50V2	88,30%		
15	Penerapan Convolutional Neural Network (CNN) untuk Klasifikasi Sampah dan Optimalisasi Sistem Penukaran Sampah (Anggraeni, 2024)	CNN	93%	312	3 Kelas

Klasifikasi Sampah Berbasis *Convolutional Neural Networks* (CNN) untuk Peningkatan Efisiensi Pengelolaan Sampah

Penelitian ini (Kadyanan et al., 2024) mengembangkan model CNN untuk klasifikasi sampah organik dan daur ulang menggunakan Water Classification Dataset dari Kaggle yang berisi sekitar 25.000 citra dengan distribusi kelas relatif seimbang. Seluruh citra dipreproses melalui resize dan normalisasi piksel, kemudian dibagi menggunakan `train_test_split` dengan `test_size` sebesar 0,2, sehingga 80% data digunakan untuk pelatihan dan 20% untuk pengujian. Arsitektur CNN terdiri dari beberapa blok `Conv2D` dan `MaxPooling2D` dengan jumlah filter bertingkat dari 32 hingga 256, diikuti oleh lapisan `Flatten`, `Dense`, dan `Dropout` sebesar 0,3 untuk mengurangi overfitting. Model dikompilasi menggunakan optimizer Adam dan fungsi `loss sparse_categorical_crossentropy`, serta dilatih selama 25 epoch dengan batch size 128 dan validation split 20%.

Hasil pelatihan menunjukkan peningkatan akurasi dan penurunan loss yang stabil pada data training dan validasi. Evaluasi pada data uji memperlihatkan bahwa model mampu mencapai akurasi yang baik dengan nilai precision, recall, dan F1-score yang seimbang pada kedua kelas. Temuan ini menunjukkan bahwa arsitektur CNN standar dengan preprocessing yang tepat sudah efektif untuk klasifikasi sampah skala besar. Model akhir disimpan dalam format .h5 dan berpotensi diterapkan pada sistem pemilahan sampah otomatis untuk meningkatkan efisiensi pengelolaan sampah.

Klasifikasi Sampah Organik dan Anorganik menggunakan Algoritma CNN

Penelitian ini (Purba et al., 2025) mengusulkan model CNN untuk klasifikasi sampah ke dalam enam kategori dengan jumlah citra per kelas berkisar antara 200–500 gambar. Seluruh citra dipreproses melalui resize dan data augmentation berupa rotasi dan flipping untuk meningkatkan variasi data dan mengurangi overfitting.

Arsitektur CNN terdiri dari tiga blok Conv2D–MaxPooling2D beraktivasi ReLU, yang diikuti oleh lapisan Flatten, Dense, dan Dropout sebesar 0,5. Lapisan output menggunakan Softmax untuk klasifikasi multi-kelas. Model dioptimasi menggunakan optimizer Adam dan fungsi loss categorical_crossentropy, serta dilatih selama 50 epoch.

Hasil evaluasi menunjukkan bahwa model mencapai akurasi yang tinggi dan stabil pada data uji. Confusion matrix memperlihatkan bahwa sebagian besar kelas dapat dibedakan dengan baik, meskipun masih terdapat kesalahan klasifikasi pada kelas dengan kemiripan visual seperti kertas dan kardus. Secara keseluruhan, penelitian ini menunjukkan bahwa CNN dasar dengan data augmentation sudah efektif untuk klasifikasi sampah multi-kelas skala menengah dan berpotensi diterapkan pada sistem pemilahan otomatis atau perangkat edge dengan keterbatasan sumber daya.

Klasifikasi Sampah Rumah Tangga menggunakan MobileNet (CNN – *Transfer Learning*)

Penelitian ini (Sadida Aulia et al., 2024) menerapkan metode CNN dengan pendekatan transfer learning menggunakan arsitektur MobileNet untuk mengklasifikasikan sampah rumah tangga ke dalam tiga kategori, yaitu organik, anorganik, dan B3. Dataset yang digunakan berjumlah 7.441 citra hasil gabungan dataset Kaggle dan citra lokal Indonesia, yang dibagi dengan rasio 80% data latih dan 20% data uji. Seluruh citra dipreproses dengan resize menjadi 224×224 piksel. Model MobileNet digunakan tanpa lapisan top bawaan dan ditambahkan satu dense layer berisi 900 neuron. Pelatihan dilakukan menggunakan optimizer Adam dengan learning rate 0,001, batch size 64, dan 25 epoch, dengan tujuan memperoleh efisiensi komputasi melalui mekanisme depthwise separable convolution. Hasil pelatihan menunjukkan peningkatan akurasi yang stabil, dengan akurasi training mencapai 98,71% dan akurasi validasi sebesar 95,70%. Evaluasi pada data uji menghasilkan akurasi 84,42%, dengan nilai presisi dan recall rata-rata pada kisaran 85–86%.

Perbandingan dengan VGG16 dan MobileNetV2 menunjukkan bahwa MobileNet memberikan performa terbaik, sehingga dapat disimpulkan bahwa arsitektur ini efektif dan efisien untuk klasifikasi sampah rumah tangga serta berpotensi diterapkan pada sistem pemilahan sampah otomatis berbasis visi komputer.

Klasifikasi Jenis Sampah menggunakan EfficientNetB0 dengan Metode *Transfer Learning*

Penelitian ini (Wahyu & Ketut, 2024) menerapkan arsitektur EfficientNetB0 sebagai model transfer learning pada CNN untuk mengklasifikasikan sampah ke dalam dua belas kategori. Dataset yang digunakan berasal dari Kaggle dan terdiri dari 12.412 citra dengan distribusi kelas yang tidak merata.

Data dibagi menjadi data pelatihan dan pengujian masing-masing sebanyak 7.557 dan 1.940 citra. EfficientNetB0 digunakan sebagai base model dengan parameter `include_top` dinonaktifkan dan seluruh lapisan dibekukan untuk mempertahankan bobot prelatih ImageNet. Lapisan tambahan berupa Flatten dan Dense beraktivasi ReLU ditambahkan, sedangkan lapisan output menggunakan Softmax. Model dikompilasi menggunakan optimizer Adam dan fungsi loss categorical crossentropy.

Hasil evaluasi menunjukkan bahwa model mencapai validation accuracy sebesar 92,97% dan akurasi pengujian sebesar 88,53%, yang menandakan kemampuan generalisasi yang cukup baik. Peneliti mencatat adanya selisih performa antara data latih dan validasi akibat porsi data pelatihan yang relatif kecil, sehingga model masih menunjukkan kecenderungan memorisasi. Analisis per kelas memperlihatkan performa tinggi pada kategori dengan jumlah data besar, sementara kelas dengan data terbatas memiliki akurasi lebih rendah. Secara keseluruhan, EfficientNetB0 terbukti efektif untuk klasifikasi sampah multi-kelas, dengan potensi peningkatan performa melalui perbaikan distribusi data dan penerapan augmentasi yang lebih beragam.

Peningkatan Klasifikasi Sampah menggunakan *Pretrained Convolutional Neural Network*

Penelitian ini (Zayd et al., 2022) berfokus pada peningkatan akurasi klasifikasi sampah dengan memanfaatkan beberapa arsitektur CNN, yaitu AlexNet, ResNet-18, dan ResNet-50, yang masing-masing diuji dalam kondisi pretrained dan tanpa pretrained. Studi ini merupakan pengembangan dari penelitian sebelumnya yang menggunakan AlexNet dan Support Vector Machine (SVM) untuk mengklasifikasikan enam jenis sampah, di mana SVM hanya mencapai akurasi 63% dan AlexNet sebesar 20%. Dataset yang digunakan bersumber dari Kaggle dan terdiri dari 2.532 citra dengan distribusi kelas yang tidak seimbang. Seluruh citra diproses melalui tahapan preprocessing berupa resize dari 512×384 menjadi 256×256 piksel, center crop ke ukuran 224×224, serta normalisasi berdasarkan nilai mean dan standar deviasi citra. Proses pelatihan dilakukan menggunakan enam konfigurasi model CNN dengan optimizer SGD, learning rate 0.001, fungsi loss categorical cross entropy, dan jumlah epoch sebanyak 50, serta dijalankan pada platform Google Colab dengan dukungan GPU.

Hasil penelitian menunjukkan peningkatan performa yang signifikan dibandingkan studi sebelumnya. AlexNet tanpa pretrained mencapai akurasi 58,58%, sedangkan versi pretrained meningkat menjadi 81,66% dengan konvergensi lebih cepat. ResNet-18 memberikan hasil yang lebih baik dengan akurasi 70,05% tanpa pretrained dan 87,99% dengan pretrained.

Performa terbaik dicapai oleh ResNet-50 pretrained dengan akurasi tertinggi sebesar 91,16% dan konvergensi pada epoch ke-14, jauh melampaui versi tanpa pretrained yang hanya mencapai 63,06%. Keunggulan ResNet terutama didukung oleh mekanisme skip connection yang menjaga aliran gradien pada jaringan yang dalam. Secara keseluruhan, penelitian ini menegaskan bahwa penggunaan pretrained CNN secara signifikan meningkatkan akurasi, stabilitas pelatihan, dan kecepatan konvergensi, serta membuktikan bahwa rendahnya performa pada studi sebelumnya lebih disebabkan oleh konfigurasi model dan parameter pelatihan yang kurang optimal dibandingkan keterbatasan metode CNN itu sendiri.

Klasifikasi Jenis Sampah menggunakan Arsitektur Vgg16

Penelitian ini (Sutanty et al., 2023) mengimplementasikan arsitektur VGG16 sebagai metode transfer learning untuk klasifikasi citra sampah menggunakan dataset Garbage Classification yang terdiri dari 8.134 gambar dengan sepuluh kategori. VGG16 digunakan sebagai fitur dasar dan dimodifikasi dengan penambahan GlobalAveragePooling2D serta dense layer beraktivasi ReLU dan softmax agar sesuai dengan karakteristik dataset. Data diproses melalui augmentasi seperti rotasi, flipping, zoom, dan shifting untuk meningkatkan variasi fitur, kemudian dibagi dengan rasio 70% data latih, 15% data validasi, dan 15% data uji. Pelatihan dilakukan hingga 40 epoch dengan mekanisme early stopping dan penyesuaian learning rate. Hasil pelatihan menunjukkan performa yang stabil dengan proses berhenti pada epoch ke-29. Model mencapai akurasi pelatihan sebesar 82,89%, akurasi validasi tertinggi 84,62%, dan akurasi pengujian sebesar 82,52%.

Evaluasi menggunakan confusion matrix serta metrik precision, recall, dan f1-score menunjukkan bahwa beberapa kelas memiliki performa sangat baik, sementara kelas lain masih mengalami kesalahan akibat kemiripan visual. Secara keseluruhan, penelitian ini membuktikan bahwa VGG16 cukup andal untuk klasifikasi sampah multikategori, meskipun peningkatan distribusi data dan penggunaan arsitektur yang lebih modern masih berpotensi meningkatkan performa pada penelitian selanjutnya.

Optimasi Model Resnet50 untuk Klasifikasi Sampah Organik dan Anorganik

Penelitian ini (Sihabillah et al., 2025) mengevaluasi penggunaan arsitektur ResNet50 untuk meningkatkan akurasi klasifikasi sampah organik dan anorganik menggunakan dataset berskala besar yang terdiri dari 22.564 citra, dengan 12.565 gambar sampah organik dan 9.999 gambar sampah anorganik. Dataset dibagi menggunakan metode stratifikasi dengan proporsi 80% data latih sebanyak 18.051 citra dan 20% data uji sebanyak 4.513 citra, sehingga distribusi kelas tetap seimbang pada kedua subset.

Seluruh data diproses melalui preprocessing berupa penyesuaian ukuran citra menjadi 384×384 piksel, normalisasi piksel, serta penerapan data augmentasi untuk meningkatkan variasi data dan ketahanan model terhadap perubahan orientasi, pencahayaan, dan posisi objek. ResNet50 dipilih karena mekanisme skip connection yang mampu menjaga stabilitas pelatihan pada jaringan dalam saat mengekstraksi fitur visual yang kompleks.

Pelatihan dilakukan selama lima epoch menggunakan optimizer Adam dan fungsi loss categorical crossentropy. Hasil pelatihan menunjukkan peningkatan akurasi yang konsisten, dengan akurasi pelatihan mencapai 84,07% dan akurasi validasi tertinggi sebesar 80,15%. Evaluasi lanjutan menunjukkan bahwa kelas organik memiliki recall yang sangat tinggi sebesar 91% dengan f1-score 84%, sementara kelas anorganik memiliki precision 85% namun recall lebih rendah sebesar 67%. Secara keseluruhan, penelitian ini membuktikan bahwa ResNet50 efektif untuk klasifikasi sampah biner dengan performa yang cukup seimbang, meskipun peningkatan jumlah data, strategi augmentasi, dan optimasi hyperparameter masih diperlukan untuk meningkatkan performa pada kelas anorganik, khususnya untuk penerapan pada sistem pemilahan sampah otomatis di lingkungan nyata.

Pendeteksian dan Klasifikasi Sampah menggunakan YOLOv11 pada Sistem Bank Sampah Berbasis Web

Penelitian ini (Nabila et al., 2025) mengembangkan sistem pendeteksian dan klasifikasi sampah berbasis web menggunakan algoritma YOLOv11, khususnya varian YOLOv11n (nano) yang dirancang untuk kecepatan tinggi dan efisiensi komputasi. Dataset yang digunakan merupakan gabungan dari Roboflow Universe, hasil scraping internet, dan pemotretan manual dengan total 27.400 citra yang mencakup sembilan kelas sampah. Data melalui proses verifikasi anotasi dan pembersihan, kemudian dibagi dengan rasio 78% data latih, 14% data validasi, dan 8% data uji. Pemodelan dilakukan menggunakan transfer learning dengan bobot prelatih YOLOv11n serta konfigurasi hyperparameter berupa batch size 32, ukuran citra 640×640 piksel, optimizer AdamW, dan variasi epoch antara 10 hingga 30. Hasil evaluasi menunjukkan bahwa pelatihan pada epoch ke-30 menghasilkan performa terbaik dengan nilai precision 91,7%, recall 89%, mAP50 93,2%, dan mAP50–95 sebesar 75,8%. Penurunan konsisten pada training loss, class loss, dan box loss menandakan proses pembelajaran berjalan stabil. Analisis per kelas memperlihatkan bahwa sebagian besar kategori memiliki performa tinggi, meskipun kelas dengan kemiripan visual seperti plastic, cardboard, dan paper menunjukkan nilai mAP lebih rendah.

Secara keseluruhan, penelitian ini membuktikan bahwa YOLOv11n efektif dan efisien untuk deteksi sampah multi-kelas serta layak diimplementasikan pada sistem berbasis web, dengan potensi peningkatan performa melalui perluasan dataset dan penggunaan varian YOLO yang lebih besar pada penelitian selanjutnya.

Klasifikasi Jenis Sampah menggunakan *Convolutional Neural Network* (CNN)

Penelitian ini (Hajid et al., 2025) mengimplementasikan algoritma CNN untuk mengklasifikasikan sampah ke dalam tiga kategori, yaitu organik, anorganik, dan B3, sebagai solusi terhadap permasalahan pemilahan sampah yang masih dilakukan secara manual. Dataset yang digunakan terdiri dari 300 citra dengan distribusi seimbang, masing-masing 100 gambar per kelas, yang dibagi menggunakan rasio 60% data latih, 20% data validasi, dan 20% data uji. Tahapan penelitian meliputi preprocessing data, perancangan arsitektur CNN, serta proses pelatihan selama 9 epoch dengan mekanisme early stopping untuk mencegah overfitting. Evaluasi performa dilakukan menggunakan metrik accuracy, precision, recall, dan f1-score.

Hasil evaluasi menunjukkan bahwa model mencapai akurasi keseluruhan sebesar 98%, dengan performa yang sangat baik pada seluruh kelas. Kelas sampah B3 dan organik memperoleh nilai precision dan recall sempurna sebesar 1,00, sementara kelas anorganik mencatat precision 0,95 dan recall 1,00. Nilai f1-score untuk seluruh kelas berada pada rentang 0,97–1,00, yang menunjukkan konsistensi model dalam mengenali jenis sampah.

Secara keseluruhan, penelitian ini membuktikan bahwa CNN mampu memberikan performa tinggi meskipun menggunakan dataset berskala kecil, namun perluasan jumlah dan variasi data tetap diperlukan agar model lebih robust ketika diterapkan pada kondisi nyata.

Optimalisasi Resnet50 untuk Klasifikasi Tujuh Jenis Sampah

Penelitian ini (Nuariputri & Sukmasetya, 2023) mengevaluasi performa arsitektur ResNet50 yang dimodifikasi untuk melakukan klasifikasi tujuh jenis sampah—cardboard, glass, metal, paper, plastic, trash, dan compost—menggunakan dataset TrashClassification berjumlah 2.751 citra. Dataset bersifat multi-class dan memiliki variasi karakter visual yang cukup tinggi antar kelas.

Tahapan preprocessing dilakukan melalui augmentasi (shearing, zooming, shifting) serta split validation untuk meningkatkan keragaman data dan mencegah overfitting. Model ResNet50 digunakan sebagai base model, kemudian ditambahkan beberapa fully connected layer (512 dan 128 neuron dengan ReLU, dropout 0.2) dan layer softmax pada output. Selain itu, penelitian menerapkan fine-tuning pada seluruh layer ResNet50 agar model mampu belajar fitur visual lebih mendalam. Proses pelatihan dilakukan selama 18 epoch, menggunakan optimizer Adam, batch size 16, serta learning rate 0.0001.

Hasil pengujian menunjukkan performa yang sangat tinggi, dimana model mencapai akurasi validasi 98,70%, dan setelah fine-tuning bahkan memperoleh akurasi validasi mencapai 100% pada epoch ke-17. Evaluasi menunjukkan penurunan loss yang stabil pada training maupun validation, meskipun grafik validation tampak lebih fluktuatif. Visualisasi hasil prediksi menunjukkan model mampu mengklasifikasikan 15 dari 16 sampel secara benar, memperlihatkan kemampuan generalisasi yang baik pada data multi-kelas. Secara keseluruhan, penelitian ini membuktikan bahwa ResNet50 yang dimodifikasi dan di-fine-tune sangat efektif untuk tugas klasifikasi sampah multi-kelas, dengan akurasi mendekati sempurna pada dataset berukuran menengah. Namun, fluktuasi pada loss validation menunjukkan bahwa peningkatan stabilitas model dan penambahan data real-world masih diperlukan untuk memastikan performa tetap konsisten ketika diterapkan pada sistem pemilahan sampah otomatis di lingkungan nyata.

Klasifikasi Sampah Daur Ulang menggunakan CNN dan GLCM

Penelitian ini (Abdan & Akbar, 2025) mengusulkan pendekatan multi-input yang menggabungkan CNN dan fitur tekstur Gray Level Co-occurrence Matrix (GLCM) untuk mengklasifikasi enam kategori sampah: kardus, kaca, logam, kertas, plastik, dan sampah umum. Integrasi kedua jenis fitur ini dilakukan untuk mengatasi tantangan utama dalam klasifikasi sampah, yaitu kemiripan visual antar material serta variasi tekstur yang tidak dapat ditangkap secara optimal oleh CNN saja.

Dataset yang digunakan mencakup 2527 citra, yang dibagi dengan rasio 80:20 untuk pelatihan dan pengujian. Tahap preprocessing meliputi normalisasi piksel, standarisasi ukuran gambar menjadi 224×224 piksel, serta penerapan class weight dan Focal Loss untuk mengatasi ketidakseimbangan kelas. Fitur tekstur diekstraksi menggunakan GLCM pada empat sudut (0°, 45°, 90°, 135°), menghasilkan 24 fitur tekstur per gambar yang kemudian diintegrasikan bersama representasi visual CNN melalui arsitektur multi-input.

Hasil pelatihan menunjukkan bahwa model multi-input CNN–GLCM mampu bekerja secara stabil tanpa indikasi overfitting, dengan akurasi pengujian sebesar 83,30%, macro F1-score 0,8144, dan weighted F1-score 0,8307. Performa terbaik dicapai pada kelas cardboard dan plastic, sementara kelas glass dan trash menunjukkan akurasi lebih rendah akibat variasi visual yang tinggi. Dibandingkan dengan model CNN tanpa fitur tekstur, pendekatan ini memberikan peningkatan akurasi sebesar 2,19%, menegaskan bahwa integrasi fitur GLCM membantu meningkatkan kemampuan diskriminasi material yang sulit dibedakan.

Meskipun belum menyamai performa model pretrained modern, hasil ini menunjukkan potensi pendekatan multi-input untuk klasifikasi sampah multi-kelas dan dapat ditingkatkan lebih lanjut melalui pengayaan dataset dan penggunaan arsitektur yang lebih canggih.

Perbandingan Mobilenetv2 dan Efficientnetb0 untuk Identifikasi Sampah Berbasis *Transfer Learning*

Penelitian ini (Thio & Susilo, 2025) menganalisis kinerja dua arsitektur transfer learning berbasis CNN, yaitu MobileNetV2 dan EfficientNetB0, untuk mengklasifikasi enam jenis sampah: plastik, kertas, kaca, karton, besi, dan sampah lainnya. Dataset gabungan berasal dari Kaggle dan pengambilan data mandiri, dengan total 2.527 gambar yang melalui tahap preprocessing, normalisasi piksel, resize ke 224×224 px, serta augmentasi (rotasi, flipping, zoom) untuk meningkatkan generalisasi model. Seluruh data dibagi menggunakan stratified split 60/20/20 sehingga proporsi antar kelas tetap seimbang. Kedua model dilatih selama 10 epoch menggunakan optimizer Adam dan fungsi loss categorical crossentropy. MobileNetV2 menggunakan Global Average Pooling, sedangkan EfficientNetB0 menggunakan flatten layer pada tahap klasifikasi. Pelatihan menunjukkan tren peningkatan akurasi dan penurunan loss pada kedua model, meskipun nilai loss masih tergolong tinggi, menandakan keterbatasan jumlah data untuk proses pembelajaran yang optimal. Hasil evaluasi menunjukkan bahwa MobileNetV2 memberikan performa yang lebih unggul, dengan akurasi training 87,31% dan akurasi validasi 91,57%, dibandingkan EfficientNetB0 yang menghasilkan akurasi training 82,46% dan validasi 88,29%.

Analisis confusion matrix memperkuat temuan ini, di mana MobileNetV2 menunjukkan rasio klasifikasi benar lebih tinggi pada seluruh kelas, terutama pada kategori karton, kertas, dan plastik. Perbandingan presisi, recall, dan f1-score juga memperlihatkan keunggulan MobileNetV2 pada hampir semua kelas, sedangkan EfficientNetB0 mengalami kesulitan terutama pada kelas kaca. Secara keseluruhan, penelitian ini menunjukkan bahwa MobileNetV2 lebih efisien dan akurat dibanding EfficientNetB0 untuk tugas klasifikasi sampah multi-kelas dengan dataset berukuran menengah.

Meskipun kedua model memberikan akurasi validasi yang cukup baik, tingginya nilai loss menunjukkan perlunya dataset yang lebih besar dan variatif untuk meningkatkan stabilitas prediksi. Ke depan, perluasan dataset dan eksplorasi arsitektur modern seperti EfficientNetV2 atau MobileNetV3 dapat meningkatkan performa sistem pemilahan sampah otomatis.

Klasifikasi Sampah Organik dan Anorganik Menggunakan Transfer Learning MobileNetV2 pada Citra Digital

Penelitian ini (Syarif et al., 2025) mengembangkan sistem klasifikasi sampah organik dan anorganik berbasis citra digital menggunakan pendekatan transfer learning dengan arsitektur MobileNetV2. Dataset diperoleh dari Kaggle dan lingkungan nyata dengan total 2.990 citra, yang dibagi menjadi 80% data latih dan 20% data validasi. Proses pemodelan dilakukan di Google Colab dengan tahapan preprocessing berupa normalisasi dan augmentasi data (rotasi, flip horizontal, zoom), serta penerapan class weighting untuk mengatasi ketidakseimbangan kelas. Model dilatih selama 15 epoch menggunakan optimizer Adam dan fungsi loss binary crossentropy, dengan arsitektur yang terdiri dari MobileNetV2, GlobalAveragePooling2D, dan layer output sigmoid.

Hasil pelatihan menunjukkan akurasi pelatihan di atas 98% dan akurasi validasi stabil pada kisaran 92–93%, dengan nilai loss yang menurun secara konsisten. Evaluasi model menghasilkan akurasi keseluruhan sebesar 87% dengan nilai precision 0,89 untuk kelas anorganik dan 0,85 untuk kelas organik, serta F1-score rata-rata 0,86. Pengujian pada 20 citra baru dari lingkungan nyata menunjukkan akurasi hingga 99%, meskipun beberapa citra dengan karakter visual ambigu memiliki confidence score di bawah 90%. Temuan ini menunjukkan bahwa MobileNetV2 mampu memberikan performa klasifikasi yang akurat dan efisien, namun masih memerlukan peningkatan dataset agar lebih robust terhadap variasi kondisi citra.

Klasifikasi Sampah Organik dan Non Organik menggunakan Transfer Learning

Penelitian ini (Julu & Nurdiah, 2025) menerapkan pendekatan transfer learning CNN untuk mengklasifikasikan sampah organik dan non-organik menggunakan tiga arsitektur pra-latih, yaitu VGG16, MobileNetV2, dan ResNet50V2. Dataset yang digunakan berasal dari Kaggle Waste Classification Data dengan total 26.478 citra, yang dibagi ke dalam data pelatihan, validasi, dan pengujian. Tahapan pemrosesan data meliputi resize citra menjadi 224×224 piksel, normalisasi nilai piksel, serta augmentasi seperti rotasi, flipping, dan zoom untuk meningkatkan variasi data. Ketiga model dilatih menggunakan konfigurasi yang sama, yakni optimizer Adam, batch size 32, learning rate 0,0001, dan penerapan early stopping guna mencegah overfitting. Hasil evaluasi menunjukkan bahwa MobileNetV2 memberikan performa terbaik dibandingkan VGG16 dan ResNet50V2, dengan akurasi 90,13%, presisi 96,25%, recall 80,25%, dan F1-score 88,78%, serta waktu inferensi tercepat. VGG16 dan ResNet50V2 memiliki akurasi yang relatif mendekati, namun menunjukkan efisiensi komputasi yang lebih rendah.

Temuan ini mengindikasikan bahwa arsitektur CNN yang ringan berbasis transfer learning mampu menghasilkan keseimbangan optimal antara akurasi dan kecepatan, sehingga lebih sesuai untuk diterapkan pada sistem pemilahan sampah otomatis berbasis perangkat mobile atau lingkungan terbatas sumber daya..

Penerapan *Convolutional Neural Network* (CNN) untuk Klasifikasi Sampah dan Optimalisasi Sistem Penukaran Sampah

Penelitian ini (Anggraeni, 2024) menerapkan CNN untuk mengklasifikasikan sampah sekaligus mengoptimalkan sistem penukaran sampah berbasis web. Dataset yang digunakan terdiri dari 312 citra sampah yang terbagi ke dalam tiga kelas, yaitu organik, plastik, dan kertas, dengan sumber data berasal dari Kaggle. Citra diproses melalui tahap preprocessing berupa penyesuaian ukuran menjadi 150×150 piksel dan pelabelan data. Pelatihan model dilakukan dengan beberapa skenario pembagian data latih dan validasi, yaitu rasio 60:40, 70:30, dan 80:20, untuk mengevaluasi pengaruh komposisi data terhadap performa model. Setelah pelatihan, model terbaik diimplementasikan ke dalam sistem berbasis website untuk melakukan klasifikasi sampah secara otomatis dari citra yang diunggah pengguna. Hasil penelitian menunjukkan bahwa model CNN mampu mencapai akurasi sangat tinggi hingga 99%, menandakan kemampuan yang sangat baik dalam mengenali pola visual sampah pada ketiga kelas.

Evaluasi menggunakan confusion matrix dan classification report menunjukkan bahwa sebagian besar data diklasifikasikan dengan benar, dengan performa rata-rata yang konsisten pada seluruh kategori sampah. Implementasi model ke dalam sistem penukaran sampah memberikan manfaat praktis berupa peningkatan efisiensi pemilahan, pengurangan kesalahan manusia, serta mendorong partisipasi masyarakat dalam pengelolaan sampah. Temuan ini menegaskan bahwa CNN merupakan pendekatan yang efektif dan aplikatif untuk mendukung sistem pengelolaan sampah otomatis di lingkungan nyata.

Analisis Berdasarkan *Research Question* (RQ)

Setelah pemaparan deskriptif setiap studi, dilakukan analisis sintesis untuk menjawab pertanyaan penelitian yang telah dirumuskan pada tahap perencanaan. Analisis ini berfokus pada identifikasi tren arsitektur CNN yang dominan, pengaruh jumlah kelas dan ukuran dataset terhadap performa, serta pendekatan yang paling efektif dalam meningkatkan akurasi klasifikasi sampah berbasis citra dan diperoleh hasil analisis sebagai berikut:

Arsitektur CNN yang Paling Dominan Digunakan

Berdasarkan hasil sintesis terhadap 15 penelitian yang dianalisis, ResNet50 merupakan arsitektur CNN yang paling dominan digunakan dalam klasifikasi sampah berbasis citra.

Hal ini ditunjukkan dari frekuensi kemunculan ResNet50 yang paling konsisten dibandingkan arsitektur lainnya, baik sebagai model utama maupun sebagai bagian dari perbandingan eksperimen pada beberapa studi. Dominasi ResNet50 didukung oleh kemampuannya dalam menangani permasalahan vanishing gradient melalui mekanisme skip connection, sehingga memungkinkan pelatihan jaringan yang lebih dalam tanpa penurunan performa. Secara empiris, beberapa penelitian dalam kajian ini menunjukkan bahwa ResNet50 mampu mencapai akurasi tinggi, seperti 91,16% pada dataset multi-kelas (Zayd et al., 2022) dan hingga 98,70% setelah proses fine-tuning (Nuariputri & Sukmasetya, 2023).

Dibandingkan dengan arsitektur lain seperti VGG16 dan MobileNetV2, ResNet50 memiliki keunggulan dalam kedalaman jaringan dan stabilitas pelatihan, sehingga lebih mampu menangkap fitur kompleks pada citra sampah yang memiliki variasi tinggi dalam tekstur, bentuk, dan pencahayaan. Sementara itu, MobileNetV2 cenderung lebih unggul dalam efisiensi komputasi, dan VGG16 lebih sederhana namun kurang optimal pada dataset kompleks. Dengan demikian, dapat disimpulkan bahwa ResNet50 merupakan arsitektur yang paling banyak digunakan sekaligus paling konsisten memberikan performa tinggi, terutama pada klasifikasi sampah multi-kelas dengan kompleksitas visual yang tinggi.

Pengaruh Jumlah Kelas terhadap Akurasi Model

Hasil sintesis menunjukkan bahwa jumlah kelas memiliki pengaruh signifikan terhadap performa model CNN dalam klasifikasi sampah berbasis citra. Pada skenario klasifikasi sederhana dengan 2–3 kelas, sebagian besar penelitian melaporkan akurasi yang sangat tinggi, umumnya berada pada rentang 88% hingga 99%. Sebagai contoh, penelitian oleh (Purba et al., 2025) dengan 2 kelas mencapai akurasi 94,88%, sementara (Anggraeni, 2024) dan (Hajid et al., 2025) dengan 3 kelas masing-masing mencapai akurasi hingga 93% dan 98%. Tingginya performa ini disebabkan oleh perbedaan visual antar kelas yang lebih jelas serta kompleksitas klasifikasi yang relatif rendah.

Sebaliknya, pada klasifikasi dengan jumlah kelas yang lebih banyak (5–12 kelas), terjadi penurunan akurasi yang cukup konsisten, dengan nilai umumnya berada pada kisaran 80% hingga 91%. Misalnya, pada penelitian (Wahyu & Ketut, 2024) dengan 12 kelas, akurasi yang diperoleh sebesar 88,53%, sedangkan (Sutanty et al., 2023) dengan 10 kelas hanya mencapai sekitar 82,89%. Penurunan ini menunjukkan bahwa peningkatan jumlah kelas secara langsung meningkatkan kompleksitas ruang fitur (feature space), sehingga model kesulitan dalam membedakan kelas-kelas yang memiliki karakteristik visual yang mirip. Secara ilmiah, fenomena ini dapat dijelaskan melalui peningkatan intra-class similarity dan inter-class similarity.

Pada dataset multi-kelas, beberapa kategori sampah seperti plastik, kertas, dan kardus memiliki tekstur, warna, dan bentuk yang hampir serupa, sehingga memperkecil margin antar kelas (class separability). Hal ini menyebabkan model CNN membutuhkan representasi fitur yang lebih dalam dan diskriminatif untuk mempertahankan akurasi.

Selain itu, peningkatan jumlah kelas juga memperbesar kompleksitas fungsi klasifikasi pada layer output (softmax), sehingga meningkatkan risiko kesalahan prediksi dan overfitting, terutama jika tidak diimbangi dengan jumlah data yang memadai. Oleh karena itu, hubungan antara jumlah kelas dan akurasi bersifat berbanding terbalik, kecuali jika didukung oleh arsitektur yang lebih dalam (seperti ResNet atau EfficientNet), teknik augmentasi data, serta strategi pelatihan seperti fine-tuning. Dengan demikian, dapat disimpulkan bahwa jumlah kelas merupakan faktor krusial yang secara langsung memengaruhi performa model CNN. Semakin tinggi jumlah kelas, semakin besar tantangan klasifikasi yang dihadapi, sehingga diperlukan pendekatan model dan strategi optimasi yang lebih kompleks untuk mempertahankan akurasi.

Pengaruh Ukuran Dataset terhadap Performa Model

Ukuran dataset berkontribusi terhadap stabilitas. Dalam konteks klasifikasi citra menggunakan CNN, istilah ukuran dataset secara ilmiah merujuk pada jumlah sampel citra (jumlah data/gambar), bukan ukuran file dalam satuan byte atau megabyte. Meskipun resolusi atau ukuran file dapat memengaruhi kualitas fitur visual, faktor yang paling menentukan dalam pembelajaran model adalah banyaknya variasi data yang direpresentasikan oleh jumlah sampel. Berdasarkan hasil SLR terhadap 15 penelitian, ukuran dataset terbukti berkontribusi langsung terhadap stabilitas pelatihan (training stability) dan kemampuan generalisasi model (generalization ability). Dataset dengan jumlah besar memungkinkan model CNN mempelajari distribusi data yang lebih luas, sehingga mampu mengenali variasi bentuk, tekstur, dan pencahayaan sampah secara lebih robust.

Namun demikian, temuan dalam kajian ini menunjukkan bahwa dataset besar tidak selalu menghasilkan akurasi tertinggi, terutama jika tidak diimbangi dengan kualitas data dan strategi pelatihan yang tepat. Sebagai contoh, penelitian (Sihabillah et al., 2025) menggunakan dataset besar sebanyak 22.564 citra, namun hanya menghasilkan akurasi sekitar 81%. Sebaliknya, penelitian (Hajid et al., 2025) dengan dataset kecil sebanyak 300 citra mampu mencapai akurasi hingga 98%. Perbedaan ini menunjukkan bahwa ukuran dataset bukan satu-satunya faktor penentu performa. Secara ilmiah, fenomena ini dapat dijelaskan melalui beberapa aspek. Pertama, kualitas dan distribusi dataset lebih berpengaruh dibanding jumlah semata. Dataset yang tidak seimbang atau memiliki label yang kurang representatif dapat menyebabkan model mengalami bias terhadap kelas tertentu.

Kedua, dataset kecil yang dilatih pada skenario sederhana (misalnya jumlah kelas sedikit) cenderung menghasilkan akurasi tinggi, namun berisiko mengalami overfitting, yaitu model hanya menghafal data latih tanpa mampu melakukan generalisasi pada data baru.

Selain itu, ukuran dataset juga berkaitan erat dengan kebutuhan strategi optimasi. Pada dataset terbatas, pendekatan seperti data augmentation (rotasi, flipping, zoom) dan transfer learning sangat efektif untuk meningkatkan variasi data secara sintesis serta memanfaatkan pengetahuan dari model pretrained. Sebaliknya, pada dataset besar, performa model lebih bergantung pada pemilihan arsitektur yang tepat dan tuning hyperparameter.

Dengan demikian, hubungan antara ukuran dataset dan performa model bersifat tidak linear. Dataset yang lebih besar memang meningkatkan potensi generalisasi, tetapi performa optimal hanya dapat dicapai jika didukung oleh: 1) Distribusi data yang seimbang, 2) Kualitas label yang baik, 3) Teknik praproses dan augmentasi yang tepat, serta 4) Penggunaan arsitektur cnn yang sesuai.

Oleh karena itu, dapat disimpulkan bahwa kombinasi antara ukuran dataset, kualitas data, dan strategi pelatihan merupakan faktor kunci dalam menentukan keberhasilan model CNN pada klasifikasi sampah berbasis citra, bukan ukuran dataset semata.

Pendekatan Paling Efektif untuk Meningkatkan Performa CNN

Berdasarkan hasil sintesis, pendekatan paling efektif dalam meningkatkan performa CNN adalah transfer learning yang dikombinasikan dengan fine-tuning. Metode ini memanfaatkan bobot pretrained dari dataset besar sehingga model telah memiliki representasi fitur dasar, kemudian disesuaikan dengan karakteristik data sampah. Strategi ini terbukti mampu meningkatkan akurasi dan mempercepat proses pelatihan dibandingkan pelatihan dari awal. Hal ini didukung oleh beberapa studi, seperti (Nuariputri & Sukmasetya, 2023), di mana ResNet50 dengan fine-tuning mencapai akurasi hingga 98,70%, menunjukkan keunggulan pendekatan transfer learning terutama pada klasifikasi multi-kelas.

Selain itu, data augmentation berperan penting dalam meningkatkan variasi data dan mengurangi overfitting, khususnya pada dataset terbatas. Teknik regularisasi seperti dropout juga membantu meningkatkan kemampuan generalisasi model. Pendekatan hybrid seperti CNN–GLCM dapat meningkatkan diskriminasi fitur tekstur pada dataset kecil, namun secara umum performanya masih berada di bawah model transfer learning modern pada skenario yang lebih kompleks. Dengan demikian, kombinasi transfer learning, fine-tuning, dan data augmentation merupakan strategi paling efektif untuk menghasilkan model CNN yang akurat dan stabil.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil Systematic Literature Review terhadap 15 penelitian terkait klasifikasi sampah berbasis citra menggunakan Convolutional Neural Network (CNN), dapat disimpulkan bahwa arsitektur ResNet50 merupakan model yang paling dominan digunakan serta menunjukkan performa yang paling konsisten, khususnya pada klasifikasi multi-kelas dengan kompleksitas visual yang tinggi.

Hasil analisis juga menunjukkan bahwa jumlah kelas memiliki pengaruh signifikan terhadap akurasi model. Klasifikasi dengan jumlah kelas yang sedikit (2–3 kelas) cenderung menghasilkan akurasi yang tinggi, sedangkan peningkatan jumlah kelas (5–12 kelas) menyebabkan penurunan performa akibat meningkatnya kompleksitas fitur dan kemiripan antar kelas.

Selain itu, ukuran dataset berperan dalam meningkatkan stabilitas pelatihan dan kemampuan generalisasi model, namun tidak secara langsung menjamin akurasi yang lebih tinggi. Performa optimal lebih dipengaruhi oleh kualitas dataset, keseimbangan distribusi data, serta strategi pelatihan yang digunakan.

Pendekatan yang paling efektif untuk meningkatkan performa CNN adalah kombinasi transfer learning, fine-tuning, dan data augmentation, yang terbukti mampu meningkatkan akurasi, mempercepat proses pelatihan, serta menghasilkan model yang lebih robust terhadap variasi data. Secara keseluruhan, keberhasilan klasifikasi sampah berbasis CNN ditentukan oleh integrasi antara pemilihan arsitektur yang tepat, kompleksitas klasifikasi, kualitas dataset, serta strategi optimasi yang digunakan, sehingga diperlukan pendekatan yang komprehensif untuk mencapai performa yang optimal.

UCAPAN TERIMA KASIH

Peneliti mengucapkan rasa terimakasih yang sebesar-besarnya kepada dosen pembimbing dan penguji yang telah bersedia memberikan segenap ilmunya untuk mengarahkan kepada peneliti dalam penelitian ini. Peneliti juga berterimakasih kepada pihak-pihak yang membantu peneliti untuk menyelesaikan penelitian ini, sehingga penelitian ini dapat selesai sesuai dengan yang diharapkan.

DAFTAR REFERENSI

Abdan, M. R., & Akbar, M. (2025). KLASIFIKASI SAMPAH DAUR ULANG MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK DAN GRAY LEVEL CO-OCCURRENCE MATRIX. *Jurnal Informatika Teknologi Dan Sains (JINTEKS)*, 7(3), 1211–1220.

- Anggraeni, K. N. (2024). Penerapan Convolutional Neural Network (CNN) untuk Klasifikasi Sampah dan Optimalisasi Sistem Penukaran Sampah. *JIMU: Jurnal Ilmiah Multi Disiplin*, 02(03), 535–544.
- Chhabra, M., Sharan, B., Gupta, K., & Astya, R. (2022). Waste Classification Using Improved CNN Architecture. *SSRN Electronic Journal*, Aece, 354–360. <https://doi.org/10.2139/ssrn.4157549>
- Dhande, K. J. (2022). *Waste Classification system using Transfer Learning and Image Segmentation*. <https://norma.ncirl.ie/id/eprint/6108>
- Hajid, P., Ridwan, R., & Marti, S. (2025). KLASIFIKASI JENIS SAMPAH MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK. *Jurnal Riset Dan Aplikasi Mahasiswa Informatika (JRAMI)*, 06(04), 886–895.
- Julu, D. I. S. H., & Nurdiah, D. (2025). KLASIFIKASI SAMPAH ORGANIK DAN NON ORGANIK MENGGUNAKAN TRANSFER LEARNING. *Jurnal TRANSFORMATIKA*, 23(1), 12–29.
- Kadyanan, I. G. A. G. A., Artawan, I. N., & Juniawan, P. (2024). Klasifikasi Sampah Berbasis Convolutional Neural Networks (CNN) untuk Peningkatan Efisiensi Pengelolaan Sampah. *Jurnal Ilmu Komputer*, 17(2), 12. <https://ojs.unud.ac.id/index.php/jik/article/view/118560>
- Nabila, M. S., Herlawati, H., & Hidayat, A. (2025). Pendeteksian dan Klasifikasi Sampah pada Bank Sampah Berbasis Web Menggunakan YOLO v11. *Journal of Student' Rresearch in Computer Science*, 6(1), 99–112.
- Nasir, I., & Aziz Al-Talib, G. A. (2023). Waste Classification Using Artificial Intelligence Techniques:Literature Review. *Technium: Romanian Journal of Applied Sciences and Technology*, 5, 49–59. <https://doi.org/10.47577/technium.v5i.8345>
- Nuariputri, J., & Sukmasetya, P. (2023). Klasifikasi Jenis Sampah Menggunakan Base ResNet-50. *Jurnal Ilmiah KOMPUTAS*, 22(3), 379–386.
- Purba, M. E., Situmorang, A. Z., Br Ginting, G. L., Lubis, M. W. P., & Sinaga, F. M. (2025). Klasifikasi Sampah Organik dan Anorganik Menggunakan Algoritma CNN. *Jurnal Sifo Mikroskil*, 26(1), 37–54. <https://doi.org/10.55601/jsm.v26i1.1510>
- Sadida Aulia, D., Arwoko, H., & Asmawati, E. (2024). Klasifikasi Sampah Rumah Tangga Menggunakan Metode Convolutional Neural Network. *Metik Jurnal*, 8(2), 114–120. <https://doi.org/10.47002/metik.v8i2.956>
- Sihabillah, A., Tholib, A., & Basit, I. I. (2025). OPTIMASI MODEL RESNET50 UNTUK KLASIFIKASI SAMPAH. *Informatic and Computational Intelligent Journal*, 06(02), 102–111.
- Sutanty, E., Maukar, Handayani, & Astuti, D. K. (2023). PENERAPAN MODEL ARSITEKTUR VGG16 UNTUK KLASIFIKASI JENIS SAMPAH. *Jurnal Pendidikan Teknologi Informasi*, 3(2), 407–419.
- Syarif, M., Prasetyo, S., Oktaviana, E., Zahra, A., Kristiawan, Y. I., & Dwi, R. (2025). Klasifikasi Sampah Organik dan Anorganik Menggunakan Transfer Learning MobileNetV2 pada Citra Digital. *Seminar Nasional Teknologi Informasi Dan Bisnis (SENATIB)*, 1028–1033.

- Thio, S. E., & Susilo, J. (2025). *Identifikasi Pemilahan Sampah Berbasis Algoritma Transfer Learning CNN Menggunakan MobileNetV2 dan EfficientNetB0*. 8(1). <https://doi.org/10.32877/bt.v8i1.1900>
- Wahyu, V., & Ketut, G. S. (2024). Klasifikasi Jenis Sampah Menggunakan Metode Transfer Learning Pada Convolutional Neural Network (CNN). *Jurnal Elektronik Ilmu Komputer Udayana*, 12(3), 589–596.
- Zayd, M. H., Oktavian, M. W., Meranggi, D. G. T., & Javier, A. (2022). Perbaikan klasifikasi sampah menggunakan pretrained Convolutional Neural Network Improvement of garbage classification using pretrained Convolutional Neural Network. *Jurnal Ilmiah Sistem Informasi*, 12(1), 1–8.