



Komparatif Metode Convolutional Neural Network, GoogleNet & Transfer Learning pada Klasifikasi Sampah

Ariza Ikhlas, Yuhandri, Agung Ramadhanu*

Fakultas Ilmu Komputer, Magister Teknik Informatika, Universitas Putra Indonesia YPTK Padang, Padang, Indonesia

Jl.Raya Lubuk Begalung, Padang, Indonesia

Email: ¹arizaikhla01@gmail.com, ²yuyu@yptk.ac.id, ³*agung@yptk.ac.id

Email Penulis Korespondensi: agung@yptk.ac.id

Submitted: 31/01/2026; Accepted: 30/04/2026; Published: 30/04/2026

Abstrak—Permasalahan sampah merupakan isu global yang sangat kompleks, terutama di Indonesia. Volume sampah yang terus meningkat setiap tahun menjadi tantangan besar bagi lingkungan, Kesehatan dan perekonomian. sehingga perlu dilakukannya penelitian terkait *smart waste management* yaitu suatu konsep pemanfaatan kecerdasan buatan dalam pengelolaan sampah dengan mengadopsi teknik pengelolaan citra. Berdasarkan hal tersebut dalam penelitian ini bertujuan untuk melakukan perbandingan terhadap pemodelan Convolutional Neural Network (CNN), GoogleNet dan Transfer Learning. Metode yang digunakan dalam penelitian ini CNN, GoogleNet, dan Transfer Learning dengan memanfaatkan data augmentasi, dan fungsi aktivasi dan transfer learning mampu mengatasi permasalahan data terbatas dan mengurangi atau menghindari permasalahan overfitting pada pemodelan. Datasets yang digunakan dalam penelitian ini bersumber dari datasets yang dibangun oleh peneliti sendiri dan datasets Kaggle() dengan jumlah 300 sampel yang terdiri dari 6 kelas *Cardboard, Glass, Plastic, Metal, Paper, and Other/Trash*. hasil tersebut menyajikan metode transfer learning unggul dari pada metode lainnya dengan akurasi, presisi, recall, dan f1-score 100%. Kontribusi penelitian ini yaitu untuk memperkaya literatur dalam bidang machine learning dan *computer vision*, mengembangkan model yang lebih efisien untuk datasets terbatas, dan menjadi referensi bagi peneliti selanjutnya yang ingin mengembangkan sistem yang serupa.

Kata Kunci: Pengelolaan Sampah Cerdas; Deep Learning; CNN; GoogleNet; Transfer Learning

Abstract—The waste problem is a very complex global issue, especially in Indonesia. The volume of waste that continues to increase every year is a major challenge for the environment, health, and the economy. so it is necessary to conduct research related to smart waste management, namely, a concept of utilizing artificial intelligence in waste management by adopting image management techniques. Based on this, this study aims to compare the modeling of Convolutional Neural Network (CNN), GoogleNet, and Transfer Learning. The methods used in this study, CNN, GoogleNet, and Transfer Learning by utilizing data augmentation, activation functions, and transfer learning, are able to overcome the problem of limited data and reduce or avoid overfitting problems in modeling. The datasets used in this study are sourced from datasets built by the researcher himself and Kaggle datasets with a total of 300 samples consisting of 6 classes: Cardboard, Glass, Plastic, Metal, Paper, and Other/Trash. The results present that the transfer learning method is superior to other methods with accuracy, precision, recall, and f1-score, 100%. The contribution of this research is to enrich the literature in the field of machine learning and computer vision, develop more efficient models for limited datasets, and become a reference for future researchers who want to develop similar systems.

Keywords: Smart Waste Management; Deep Learning; CNN; GoogleNet; Transfer Learning

1. PENDAHULUAN

Permasalahan sampah merupakan isu global yang sangat kompleks, terutama di Indonesia. Volume sampah yang terus meingkat setiap tahunnya menjadi tantangan besar bagi lingkungan, Kesehatan dan perekonomian. Akar masalah sampah tidak hanya disebabkan oleh satu faktor melainkan terdiri dari beberapa hal seperti pola konsumsi berlebihan pertumbuhan populasi dan urbanisasi [1], kurangnya kesadaran Masyarakat [2], sistem pengelolaan sampah yang belum optimal [3]. Penelitian berkaitan dengan inovasi dan teknologi dalam pengelolaan sampah dengan judul teknologi insinerasi sebagai Solusi pengelolaan sampah perkotaan dan pemulihan energi yang dilakukan oleh dalam pengelolaan sampah dengan judul Teknologi Insinerasi sebagai Solusi Pengelolaan Sampah Perkotaan dan Pemulihan Energi metode yang digunakan dalam penelitian ini adalah review, hasil yang diperoleh insinerasi dapat mengurangi volume sampah sehingga lebih dari 90% dan menghasilkan energi panas yang dapat dikonversi menjadi Listrik. Abu sisa pembakaran dapat digunakan sebagai bahan konstruksi [4]

Beberapa konsep yang dilakukan dalam pengelolaan sampah yaitu Pengelolaan Sampah Kota Terintegrasi Menuju *Zero Waste* dalam pengelolaan sampah perkotaan. Konsep ini melibatkan pencegahan sampah dari awal, pengurangan penggunaan Kembali d, daur ulang dan pengelolaan sisa sampah yang minimal penelitian ini menyoroti pentingnya strategi *Zero Waste* untuk mengatasi permasalahan pengelolaan sampah perkotaan meskipun banyak kota di dunia telah berhasil menerapkan strategi ini, masih ada tantangan di Indonesia yang memerlukan inisiatif baru seperti melibatkan lebih banyak pemangku kepentingan dan memperkuat peran pemerintah dalam regulasi yang mendukung pengelolaan sampah yang berkelanjutan [5]. Berikutnya penggunaan konsep yang berbeda dalam pengelolaan sampah yaitu dengan judul pengelolaan sampah terpadu dengan konsep *Waste to Energy* di *Smart City* IKN. Konsep penelitian ini menggunakan pendekatan *Waste to Energy (WtE)* mengolah sampah padat menjadi energi listrik dan panas melalui proses pembakaran termal yang terkontrol konsep ini bertujuan untuk mendukung visi IKN sebagai kota pintar dan ramah lingkungan. Hasil dari pengamatan selama 15



hari pengolahan termal hanya menghasilkan residu 2,97% dengan asumsi pengoperasian satu unit insinerator, sampah dapat diubah menjadi energi Listrik sebesar 195.169 watt. Pengeoperasian dua unit incinerator dapat menghasilkan output energi dua kali lipat menjadi 390.338 watt[6]. Konsep *Smart Waste Management* konsep ini menggunakan pemanfaatan kecerdasan buatan dalam pengelolaan sampah pemanfaatan kecerdasan buatan berpotensi merevolusi pengelolaan sampah kota dengan meningkatkan efektivitas pengumpulan, pemrosesan dan klasifikasi sampah teknologi berbasis kecerdasan buatan dalam pengelolaan sampah kota dengan meningkatkan efektivitas pengumpulan, pemrosesan dan klasifikasi sampah. Teknologi berbasis kecerdasan buatan seperti tempat sampah pintar, robot klasifikasi model prediktif dan deteksi nirkabel yang memungkinkan pemantauan tempat sampah memprediksi pengumpulan dan mengoptimalkan kinerja fasilitas pengelolaan sampah [7].

Penelitian dengan judul literature review: studi komparatif klasifikasi sampah menggunakan algoritma deep learning berdasarkan studi literatur ini peneliti melakukan literatur review terhadap berbagai pemodelan CNN, berdasarkan studi literatur ini melakukan sistematika literatur review terhadap berbagai pemodelan CNN, berdasarkan hasil penelitian CNN dasar memperoleh tingkat akurasi 100% terhadap 150 sampel data dan 2 kelas. Selain itu Resnet dengan jumlah data 2527 dengan jumlah 6 kelas memperoleh akurasi 99.41%. Kombinasi Resnet50, KNN+NCA dengan total sampel 13.089 dengan jumlah kelas 1672 kelas memperoleh 99.35%. CNN (CapSA Ecoc + ANN) dengan data 1.515 dengan 12 kelas menghasilkan 99%. CNN dengan total sampel 2.800 dengan jumlah 2 kelas akurasi memperoleh 99%[8].

Penelitian terkait Smart Waste Management yang berjudul *Collection of Plastic packaging of various Types : Sorting of Fraction of plastic waste using Both Automated and Manual modes* metode pemilihan sampah plastic secara otomatis dan manual. Mode otomatis menggunakan sistem konveyor dan sensor optic untuk memisahkan jenis plastik, sementara model manual dilakukan oleh operator. Hasil dari penelitian ini pemilahan otomatis menunjukkan efisiensi yang lebih tinggi dalam memisahkan jenis – jenis tertentu, tetapi pemilahan manual masih diperlukan untuk material yang sulit di deteksi. Kualitas fraksi plastic yang dihasilkan dari pemilahan otomatis lebih murni [9]. Penelitian terdahulu dengan judul *Waste Material Clasisfication Using Performance Evaluation of Deep learning Models*. Metode yang di evaluasi adalah arsitektur *deep learning* seperti (GoogleNet, InceptionV3, dan Xception). Data yang digunakan adalah berbagai jenis sampah. Hasil yang diperoleh InceptionV3 menunjukkan performa luar biasa dengan akurasi presisi, recall dan F1-score 100% [10].

Penelitian dengan judul *Deep learning – Based Automated Garbage Image Classification Using Light – Weight Model*. Metode yang digunakan dalam penelitian ini dengan pendekatan *transfer learning* menggunakan pemodelan ringan seperti (MobileNetV3, ShuffleNet, Efficient Netb2, SqueezeNet, GoogleNet dan ViT). Data yang digunakan datasets yang terdiri dari sampah 5 jenis kelas kaca, plastic, baterai, kertas, logam. Hasil yang diperoleh performa tertinggi pada EfficientNetb2 datasets dengan akurasi 97% [11]. Penelitian dengan judul *Optimization of an automated garbage recognition model based on ResNet-50 and weakly supervised CNN for sustainable urban development*. Metode yang digunakan dalam penelitian ini yaitu *Resnet-50, YoloV5, Weakly Supervised CNN*, datasets yang digunakan empat datasets publik. Hasil metode yang diusulkan mengungguli algoritma tradisional dalam akurasi, efisiensi, dan stabilitas; mengurangi waktu inferensi lebih dari 48.6% Flops lebih dari 46.5%, dan MAPE lebih dari 41% pada datasets HGI-30 meningkatkan akurasi dan kekokohan klasifikasi citra sampah [12].

Penelitian ini berfokus pada aplikasi visi citra dan *deeplearning* dalam lengan robot penyortir sampah otomatis. Penelitian yang berjudul *Comparative study of Machine Learning Algorithm for Garbage Classification*. Metode yang digunakan dalam penelitian ini yaitu MobileNetV2, Inception, ResNet. Tujuan penelitian ini membandingkan kinerja *MobileNetV2, InceptionV3* dan ResNet untuk klasifikasi sampah guna menemukan algoritma yang optimal. Kelemahan pada penelitian ini tidak mengusulkan metode baru, ruang lingkup terbatas pada model tertentu, ketergantungan pada datasets tertentu [13]. Penelitian berjudul *Garbage classification detection system based on the YoloV8 algorithm* metode yang digunakan dalam penelitian ini YoloV8 Datasets yang digunakan adalah *datasets public* yang digabungkan dengan data yang dikumpulkan sendiri (15.000 Citra) tujuan penelitian ini adalah mengembangkan klasifikasi sampah dengan model terlatih mencapai ~35 f/s dan akurasi pengenalan 90% [14]. Penelitian berjudul *Garbage Classification from Visual Footprints: Using Transfer Learning Strategy*. Metode yang digunakan dalam penelitian ini adalah CNN dan *transfer learning* model pre-trained seperti ConvNeXtBase, EfficientNetV2L. 6531 gambar sampah rumah tangga dibagi menjadi 8 Kategori Hasil yang diperoleh dalam penelitian ini ConvNeXtBase mencapai akurasi 99% EfficientNetV2L mencapai akurasi 98%.[15] Penelitian berjudul *Garbage Image Classification based on Deep Learning* metode yang digunakan dalam penelitian ini adalah ResNet50 *transfer learning*, InceptionV3, dan kombinasi ResNet dan SENet (ResNeXt) hasil yang diperoleh ResNet50 + *transfer learning* efisiensi pelatihan lebih baik InceptionV3: mengurangi *misclassification, robust*, generalisasi tinggi; ResNet + SENet: menghindari overfitting, konvergensi cepat tingkat pengenalan lebih tinggi; ResNeXt: error rate lebih rendah dari ResNet dan Inception-ResNet-V2 [16]. Penelitian berjudul *Garbage Classification Algorithm Based on Improved MobileNetV3*. Metode yang digunakan dalam penelitian ini menggunakan MobileNetV3 (GMC-MobileNetV3) dengan mekanisme perhatian CBAM fungsi aktivasi, dan Global Average Pooling. Datasets yang digunakan datasets yang dibuat sendiri 4152 gambar dalam 4 kategori *kitchen waste, recyclable waste, hazardous waste* dan sebagainya. Hasil yang diperoleh dalam penelitian ini adalah akurasi pengenalan 96.55% pada datasets buatan sendiri (3.6% lebih tinggi dari model asli), jumlah parameter model 0.64M(56.6% lebih rendah), waktu pengenalan gambar tunggal 26.4ms [17].

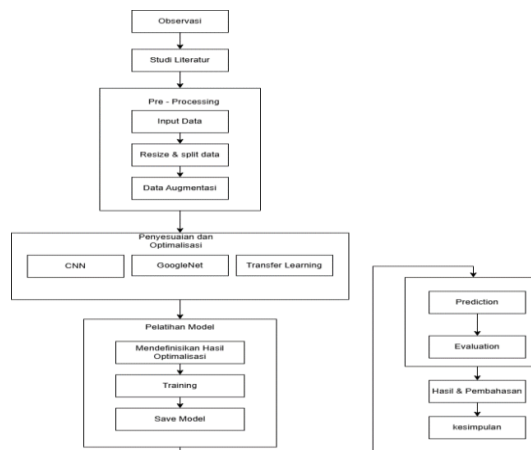
Penelitian berjudul *Application research of image classification algorithm based on deep learning in household garbage sorting*. Metode yang digunakan dalam penelitian ini dengan CNN, Capuchin Search Algorithm (CapSA) untuk optimasi *hyperparameter* CNN, *Error-Correcting Output Codes* (ECOC) dan Artificial Neural Networks (ANN) untuk klasifikasi [18]. Penelitian berjudul *Classification of Organic and Recyclable Waste Based on Feature Extraction and Machine Learning*. metode yang digunakan dalam penelitian ini adalah *Feature Extraction (InceptionV3)*, *Machine Learning Algorithms* (SVM, Decision Tree, KNN). Data yang digunakan sebanyak 24.705 gambar sampah rumah tangga (13.880 organik,10.825 daur ulang) [19]. Penelitian berjudul *RepVGG-MEM: a lightweight Model for Garbage Classification Achieving a Balance Between Accuracy and Speed*. metode yang digunakan dalam penelitian ini RepVGG-MEM, yang berasal dari arsitektur Rep VGG, dilengkapi dengan *Convolution Block Attention Module* dengan *multi-scala*, dan teknik pemangkasan juga digunakan., datasets digunakan dengan citra sampah, hasil yang diperoleh Model RepVGG-MEM mencapai akurasi 93,26% dengan jumlah parameter 7,2 juta Flops 1,41 Miliar versi yang dipangkas (RepVGG-MEM5) mengurangi parameter menjadi 1,2 juta dan FLOPS menjadi 0,55 miliar dengan penurunan akurasi 1,17% [20]. Penelitian berjudul *Garbage Content Estimation Using Internet of Things and Machine Learning*.. Metode yang digunakan dalam penelitian ini sistem tempat sampah pintar (SGBS) yang tertanam dengan sensor (suhu, kelembaban, gas) dan model *machine learning* yang dilatih menggunakan pembacaan sensor gabungan harian. Data yang digunakan dalam penelitian ini pembacaan sensor dari SGBS yang diinstal di lima rumah tangga selama satu bulan, dikombinasikan dengan anotasi rinci isi sampah rumah tangga, Hasil yang diperoleh 91% akurasi pada 5 isi sampah dapur,89% pada 5 isi kertas/kotak, dan 85% pada 8 kategori sampah untuk tugas klasifikasi [21]. Penelitian berjudul *GFN: A Garbage Classification Fusion Network Incorporating Multiple Attention Mechanism* metode yang digunakan dalam penelitian menggunakan *framework deep learning inovatif Garbage FusionNet*(GFN) yang mengintegrasikan ResNet dan *Vision Transformer (ViT)*, Serta modul *Pyramid Pooling Module (PPM)* dan *Convolution Block Attention Module* [22]. Penggunaan kecerdasan buatan dan visi komputer juga telah dilakukan juga telah dilakukan oleh peneliti sebelumnya dengan judul *Detection FROM Highly Cluttered Waste Scenes Using Computer Vision*.penelitian menggunakan model Computer Vision dengan model faster R-CNN , Cascade - RCNN, Retinanet , Yolov8 – x mencapai Mean Average Precision (MAP) sebesar 0.395 tanpa *transfer learning* dan meningkat menjadi 90,463 dengan *transfer learning* [23].

Berdasarkan uraian tersebut, penelitian ini dilakukan untuk melakukan perbandingan dan evaluasi model terkait pemanfaatan data augmentasi dan tanpa data augmentasi. Melakukan optimalisasi untuk mengoptimalkan pemanfaatan model serta menentukan pencarian *hyperparameter* terbaik untuk klasifikasi citra sampah dengan jumlah data yang relatif kecil. Melakukan perbandingan dan analisis setiap pemodelan untuk pengujian pemodelan yang efektif untuk digunakan dalam klasifikasi citra sampah. Kontribusi penelitian ini yaitu untuk memperkaya literatur dalam bidang *machine learning* dan *computer vision*, mengembangkan model yang lebih efisien untuk datasets terbatas. Menjadi referensi bagi peneliti selanjutnya yang ingin mengembangkan sistem yang serupa.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Kerangka penelitian adalah kumpulan tahapan yang disusun untuk merancang menjalankan dan mengevaluasi suatu penelitian kerangka ini berfungsi sebagai panduan alur kerja yang membantu peneliti dalam mengatur serta mengarahkan seluruh aktivitas penelitian secara terstruktur dan sistematis. Gambar 1 menunjukkan tahapan yang dilakukan dalam penelitian. Dalam penelitian ini peneliti menggunakan eksperimen yaitu melakukan uji coba terhadap arsitektur *CNN*, *GoogleNet* dan *Transfer learning* untuk kasus dalam penelitian ini membangun model untuk klasifikasi sampah.



Gambar 1. Metodologi Penelitian

Tahapan proses penelitian ini dilakukan secara sistematis melalui beberapa langkah utama, yaitu observasi, studi literatur, preprocessing data, penyesuaian dan optimasi model, pelatihan model, serta evaluasi hasil dan pembahasan. Pada tahap awal, observasi dan studi literatur dilakukan untuk memahami permasalahan mengkaji penelitian terdahulu serta menentukan metode yang paling relevan untuk digunakan. Selanjutnya data diproses melalui tahap preprocessing dan optimasi sebelum dilakukan pelatihan model, kemudian kinerja model dievaluasi untuk dianalisis dan pembahasan guna memperoleh Kesimpulan penelitian.

2.2 Observasi


Pada tahap ini, peneliti melakukan observasi langsung di lapangan untuk menidentifikasi berbagai permasalahan yang sedang terjadi. Proses observasi dilengkapi dengan kegiatan wawancara kepada pihak terkait yang memiliki informasi relevan, sehingga peneliti dapat menggali data secara lebih mendalam mengenai faktor penyebab, konteks dan dampak dari permasalahan tersebut. Hasil observasi dan wawancara kemudian dianalisis secara sistematis untuk memastikan bahwa masalah penelitian yang dirumuskan benar sesuai dengan kondisi empiris di lapangan dan memiliki relasi kuat sebagai dasar penyusunan penelitian.

2.3 Studi Literature

Tahap studi literatur dilakukan untuk mengumpulkan, meninjau dan menganalisis berbagai sumber teori yang relevan dengan topik penelitian. Proses ini peneliti mempelajari jurnal, buku, laporan penelitian maupun publikasi ilmiah lainnya untuk memahami perkembangan konsep metode serta temuan – temuan terdahulu melalui studi literatur. Peneliti dapat mengidentifikasi celah penelitian Menyusun kerangka teori dan menentukan pendekatan yang tepat untuk penelitian yang akan dilakukan. Tahap ini juga memastikan bahwa penelitian yang dirancang memiliki landasan ilmiah yang kuat dan tidak mengulang pekerjaan sebelumnya.

2.4 Preprocessing

Tahap persiapan data yaitu mempersiapkan data untuk penelitian. Tahap ini yaitu mengumpulkan data sampel citra sampah. Citra sampah yang dikumpulkan terdiri dari 6 kategori seperti *cardboard*, *trash*, *glass*, *paper*, *plastic* dan *metal*. Setiap kelas terdiri dari masing – masing 50 sampel pada setiap kelas dengan total sampel 300. Adapun penggunaan datasets sekunder yaitu pada kelas kaca / *glass* yang diambil dari datasets Trashnet.



Gambar 2. Sampel data pelatihan

Gambar 2 menunjukkan sejumlah sampel data yang diambil secara acak dari datasets penelitian. Sampel tersebut merepresentasikan beberapa kategori jenis sampah, yaitu paper, plastic, glass, cardboard, metal, serta trash / other. Keberagaman kategori ini bertujuan untuk memastikan bahwa model klasifikasi dapat mengenali dan membedakan setiap jenis sampah secara akurat berdasarkan karakteristik visualnya.

2.5 Arsitektur Convolutional Neural Network

Implementasi *Convolutional Neural Network (CNN)* pada penelitian ini dilakukan melalui beberapa tahapan yang saling berkaitan untuk menghasilkan model klasifikasi citra yang optimal. CNN dipilih karena kemampuannya dalam melakukan ekstraksi fitur secara otomatis tanpa memerlukan proses *feature engineering manual* seperti pada metode tradisional. Arsitektur CNN yang digunakan terdiri dari beberapa blok utama yaitu *Convolutional layer*, *Pooling layer*, *Flatten layer* dan *Fully Connected layer*.

Gambar tersebut menunjukkan arsitektur Convolutional Neural Network (CNN) yang terdiri dari beberapa lapisan Conv2D dan MaxPooling 2D untuk mengekstraksi serta mereduksi fitur dari citra berukuran $224 \times 224 \times 4$. Proses ekstraksi fitur dilakukan secara bertahap dengan peningkatan jumlah filter dari 32, 64, hingga 128 untuk menangkap pola yang semakin kompleks. Setelah melalui proses flatten, fitur yang dihasilkan diklasifikasikan menggunakan lapisan Dense dan Dropout untuk mengurangi overfitting sebelum menghasilkan output akhir sebanyak 6 kelas. Arsitektur ini dirancang untuk mengoptimalkan proses pembelajaran fitur spasial dan meningkatkan akurasi klasifikasi citra.

2.6 GoogleNet

Implementasi Arsitektur GoogleNet pada penelitian ini dilakukan sebagai tahapan utama dalam proses pengujian model klasifikasi citra sampah. GoogleNet, yang dikenal juga sebagai InceptionV1, merupakan salah satu arsitektur Convolutional Neural Network (CNN) yang memiliki kemampuan tinggi dalam mengekstraksi fitur visual secara efisien melalui kombinasi beberapa jenis filter konvolusi pada setiap modul Inception. Arsitektur GoogleNet menampilkan arsitektur jaringan yang kompleks dengan berbagai lapisan Convolutional, Maxpooling, dan Concatenate yang tersusun dalam beberapa blok parallel dengan modul Inception. Setiap blok dirancang untuk mengekstraksi fitur pada berbagai skala secara simultan, sehingga mampu menangkap informasi spasial yang lebih kaya dan mendalam. Dimensi fitur diperkecil secara bertahap melalui proses pooling hingga mencapai tahap Global average Pooling sebelum masuk ke lapisan klasifikasi akhir. Secara keseluruhan arsitektur ini bertujuan meningkatkan kemampuan model dalam mengenali pola yang kompleks serta menghasilkan performa klasifikasi yang lebih optimal dan stabil.


2.7 InceptionV3 Transfer learning

Implementasi *Transfer Learning* pada penelitian ini dilakukan dengan memanfaatkan arsitektur InceptionV3 yang sebelumnya telah dilatih pada datasets berskala besar, yaitu ImageNet. Penggunaan model prelatih bertujuan untuk memanfaatkan kemampuan ekstraksi fitur mendalam yang telah dimiliki InceptionV3 sehingga proses pelatihan menjadi lebih efisien dan mampu memberikan performa yang lebih baik meskipun menggunakan datasets yang relatif terbatas. *Deep learning* berbasis *transfer learning* untuk klasifikasi enam kelas, dimulai dari *Input Layer* yang menerima citra berukuran $224 \times 224 \times 3$, kemudian melewati blok pra – pemrosesan (sequential dan lambda) sebelumnya diekstraksi fiturnya oleh model *backbone* (functional) yang menghasilkan fitur map berukuran (5,5,2048). Fitur map ini dipadatkan menggunakan *GlobalAveragePooling2D* menjadi vektor berdimensi 2048, lalu masuk ke lapisan dense berisi 256 neuron yang berfungsi sebagai fully connected layer untuk membentuk representasi fitur tingkat tinggi. Selanjutnya vektor 256 dimensi tersebut kembali melalui *dropout* dan diakhiri dengan lapisan *dense* berisi 6 neuron dengan aktivasi softmax yang menghasilkan probabilitas untuk masing – masing dari enam kelas target pada tugas klasifikasi citra yang dirancang.

3. HASIL DAN PEMBAHASAN

Model yang diusulkan berhasil dilatih menggunakan datasets citra berukuran 224×224 piksel dengan enam kelas target. Proses pelatihan menunjukkan konvergensi yang stabil, ditandai dengan penurunan nilai loss pada data latih dan validasi hingga mencapai titik jenuh, sementara akurasi terus meningkat. Pada akhir pelatihan, setiap model memperoleh akurasi pelatihan yang tinggi dengan selisih yang relatif kecil terhadap akurasi validasi, sehingga indikasi overfitting dapat dikatakan minimal. Hal menghasilkan model yang cukup baik dalam mengenali pola visual pada masing masing kelas.

3.1 Hasil Preprocessing



Gambar 3. Hasil Data Augmentasi

Gambar 3 menunjukkan contoh hasil data augmentation pada objek kaleng, dimana setiap citra mengalami variasi transformasi seperti rotasi, perubahan pencahayaan, flip, serta zoom. Variasi ini bertujuan memperkaya keragaman dataset sehingga model CNN dapat belajar mengenali objek dalam berbagai kondisi nyata yang lebih kompleks. Dengan Data augmentasi tersebut, performa model diharapkan menjadi lebih *robust* dan mampu melakukan generalisasi lebih baik terhadap citra baru.

3.2 Hasil Training

Pada tahap ini menyajikan hasil pelatihan model yang telah dilakukan pada tahap sebelumnya. Proses pelatihan bertujuan untuk mengoptimalkan parameter model agar mampu mengenali pola pada data latih secara efektif. Evaluasi hasil pelatihan dianalisis berdasarkan nilai akurasi loss, serta metrik kinerja lainnya untuk mengetahui tingkat konvergensi dan performa model secara keseluruhan.





Tabel 1. Hasil Training CNN, GoogleNet, dan Transfer learning



Model	Epoch	Acc	Val Acc	Loss	Val loss	Data augmentasi
CNN	50	100%	95%	0.00%	98%	Tidak
CNN	53	67%	80%	90%	80%	Ya
GoogleNet	96	97%	100%	4%	5%	Tidak
GoogleNet	69	98%	96%	5%	12%	Ya
Transfer Learning	7	94%	100%	23%	4%	Tidak
Transfer Learning	55	100%	100%	47%	8%	Ya

3.3 Hasil Prediksi

Tahap prediksi yang krusial dilakukan dengan melibatkan enam model terlatih yang berbeda, dimana setiap model dievaluasi kemampuannya untuk mengklasifikasi atau memproses 6 citra baru yang belum pernah dilihat sebelumnya. Dalam proses ini, setiap citra akan dilewatkan melalui keenam model secara berurutan atau paralel untuk mendapatkan *output* prediksi (misalnya, label, probabilitas) sehingga menghasilkan 72 hasil prediksi. Hasil prediksi dari keragaman model ini kemudian dapat dianalisis secara komparatif untuk menilai performa generalisasi dan *robustness* masing – masing model menentukan model terbaik untuk deployment produksi.

Tabel 2. Hasil Prediksi CNN, GoogleNet, dan Transfer Learning

Gambar	Model	Confidence	Predict	value
	CNN	25%	Paper	Salah
	CNN(DA)	26%	Trash	Salah
	GoogleNet	30%	Paper	Salah
	GoogleNet(DA)	25%	Metal	Salah
	Transfer Learning	35%	Glass	Salah
	Transfer Learning(DA)	34%	Glass	Salah
	CNN	34%	Glass	Benar
	CNN(DA)	27%	Trash	Salah
	GoogleNet	28%	Glass	Benar
	GoogleNet(DA)	32%	Metal	Salah
	Transfer Learning	31%	Glass	Benar
	Transfer Learning(DA)	31%	Glass	Benar
	CNN	35%	Cardboard	Benar
	CNN(DA)	18%	Cardboard	Benar
	GoogleNet	33%	Cardboard	Benar
	GoogleNet(DA)	35%	Cardboard	Benar
	Transfer Learning	35%	Cardboard	Benar
	Transfer Learning(DA)	34%	Cardboard	Benar
	CNN	35%	Trash	Salah
	CNN(DA)	34%	Trash	Salah
	GoogleNet	35%	Trash	Salah
	GoogleNet(DA)	34%	Trash	Salah
	Transfer Learning	35%	Plastic	Salah
	Transfer Learning(DA)	26%	Metal	Benar
	CNN	35%	Trash	Benar
	CNN(DA)	35%	Trash	Benar
	GoogleNet	35%	Trash	Benar

Gambar	Model	Confidence	Predict	value
	GoogleNet(DA)	32%	Trash	Benar
	Transfer Learning	22%	Paper	
	Transfer Learning(DA)	25%	Trash	Benar
	CNN	35%	Metal	Salah
	CNN(DA)	34%	Trash	Salah
	GoogleNet	24%	Plastic	Salah
	GoogleNet(DA)	26%	Plastic	Salah
	Transfer Learning	35%	Paper	Benar
	Transfer Learning(DA)	34%	Paper	Benar

3.4 Evaluasi

Tabel 3 Evaluasi Model CNN tanpa data augmentasi

	Precision	Recall	F1-Score	Support
Cardboard	0.8462	1.0000	0.9167	11
Glass	0.7778	0.8750	0.8235	8
Metal	0.8182	1.0000	0.9000	9
Paper	1.0000	1.0000	1.0000	14
Plastic	1.0000	0.7143	0.8333	7
Trash	1.0000	0.7273	0.8421	11
accuracy			0.9000	60
Macro avg	0.9070	0.8861	0.8859	60
weighted avg	0.9149	0.9000	0.8978	60

Berdasarkan hasil evaluasi, model klasifikasi citra sampah memperoleh akurasi sebesar 90% dari 60 data uji, yang menunjukkan kinerja klasifikasi yang sangat baik. Kelas *paper* memiliki performa terbaik dengan nilai *precision*, *recall*, *recall* dan *f1-score* sebesar 100%, sedangkan kelas *Cardboard* dan *Metal* juga menunjukkan kinerja tinggi dengan *recall* mencapai 100%. Pada kelas *plastic* dan *trash*, nilai *precision* tetap tinggi namun *recall* relatif relative lebih rendah, yang mengindikasikan masih terdapat beberapa data yang belum terdeteksi dengan baik. secara keseluruhan, nilai macro average F1 – Score sebesar 88% dan weighted average f1 – score sebesar 89% menunjukkan bahwa model memiliki performa yang cukup seimbang dan konsisten dalam mengklaisifikasikan berbagai jenis sampah.

Tabel 4 Evaluasi Model CNN dengan data augmentasi

	Precision	Recall	F1-Score	Support
Cardboard	1.0000	0.6364	0.7778	11
Glass	0.6000	0.7500	0.6667	8
Metal	0.6000	1.0000	0.7500	9
Paper	0.7692	0.7143	0.7407	14
Plastic	1.0000	0.5714	0.7273	7
Trash	0.7273	0.7273	0.7273	11
accuracy			0.7333	60
Macro avg	0.7828	0.7332	0.7316	60
weighted avg	0.7828	0.7333	0.735	60

Berdasarkan hasil evaluasi, model CNN dengan data augmetasi untuk klasifikasi citra sampah memperoleh akurasi sebesar 73.33% dari 60 data uji, yang menunjukkan performa klasifikasi pada kategori cukup baik. Nilai *precision*, *recall* dan *F1 – Score* pada tiap kelas menunjukkan variasi kinerja yang cukup signifikan. Kelas *Cardboard* dan *Plastic* memiliki nilai *precision* sebesar 100%, namun nilai *recall* relatif rendah, yang mengindikasikan bahwa meskipun prediksi pada kelas tersebut sangat tepat, masih terdapat sejumlah data aktual yang belum berhasil terdeteksi oleh model. Kelas *Metal* menunjukkan *recall* sempurna 100%, namun dengan *precision* yang lebih rendah, menandakan adanya kesalahan prediksi positif pada kelas tersebut. Sementara itu, kelas *Glass*, *Paper* dan *Trash* menunjukkan performa yang relative seimbang antara *precision* dan *recall*, dengan nilai *F1-Score* berada pada kisaran 0.66 – 074. Secara keseluruhan, nilai macro average F1 – score sebesar 73.16% dan weighted average F1 – score sebesar 73.5% menunjukkan bahwa model memiliki kinerja yang cukup konsisten antar kelas, meskipun masih terdapat ruang untuk peningkatan terutama dalam meningkatkan kemampuan deteksi *recall* pada beberapa kelas tertentu.

Tabel 5 Evaluasi Model GoogleNet Tanpa data augmentasi

	Precision	Recall	F1-Score	Support
Cardboard	0.7857	1.0000	0.8800	11
Glass	0.8889	1.0000	0.9412	8
Metal	1.0000	1.0000	1.0000	9
Paper	0.9231	0.8571	0.8889	14
Plastic	1.0000	1.0000	1.0000	7
Trash	1.0000	0.7273	0.8421	11
accuracy			0.9167	60
Macro avg	0.9329	0.9307	0.9254	60
weighted avg	0.9280	0.9167	0.9153	60

Berdasarkan hasil evaluasi model klasifikasi citra sampah, diperoleh nilai akurasi sebesar 91,67% dari 60 data uji, yang menunjukkan bahwa model mampu melakukan prediksi dengan tingkat ketepatan yang sangat baik. Secara per kelas, model menunjukkan kinerja sangat baik pada kelas *Metal* dan *Plastic* dengan nilai *precision*, *recall* dan *F1-score* mencapai 100%, menandakan seluruh data pada kelas tersebut berhasil diklasifikasikan dengan benar. Kelas *Cardboard* dan *Glass* memiliki nilai *recall* sempurna 100%, meskipun *precision* pada kelas *Cardboard* sedikit lebih rendah, yang mengindikasikan adanya prediksi positif yang salah. Kinerja pada kelas *Paper* juga tergolong baik dengan *F1-score* sebesar 88%, meskipun *recall* tidak maksimal. Sementara itu kelas *Trash* menunjukkan nilai *recall* terendah 72%, yang mengindikasikan masih terdapat data pada kelas ini yang salah diklasifikasikan ke kelas lain. Secara keseluruhan, nilai *macro average F1 – score* sebesar 92.54% dan *weighted average F1-score* sebesar 91.53% menegaskan bahwa model memiliki performa yang stabil dan seimbang di seluruh kelas, meskipun masih diperlukan peningkatan khususnya pada kelas *Trash* untuk meningkatkan sensitivitas model.

Tabel 6 Hasil Evaluasi GoogleNet dengan data augmentasi

	Precision	Recall	F1-Score	Support
Cardboard	0.7143	0.9091	0.8000	11
Glass	1.0000	1.0000	1.0000	8
Metal	0.6000	1.0000	0.7500	9
Paper	1.0000	0.7143	0.8333	14
Plastic	1.0000	0.7143	0.8333	7
Trash	1.0000	0.7273	0.8421	11
accuracy			0.8333	60
Macro avg	0.8857	0.8442	0.8431	60
weighted avg	0.8876	0.8333	0.8386	60

Tabel 6 Merupakan laporan klasifikasi terhadap pemodelan GoogleNet dengan data augmentasi. Hasil menunjukkan bahwa tingkat akurasi yang diperoleh masih tergolong baik yaitu 83.33%. Pada kelas *Glass* dapat indikasikan bahwa pemodelan memiliki kemampuan prediksi yang sempurna yang memiliki *precision*, *recall*, dan *f1 – score* 100%. Sementara pada kelas *metal* memiliki *recall* 100% dan memiliki *precision* yang lebih rendah 60% ini mengindikasikan bahwa pemodelan masih memiliki kesalahan dalam memprediksi kelas metal. Pada kelas *Paper*, *Plastic* dan *Trash* memiliki nilai *precision* 100% dan memiliki *recall* yang lebih rendah artinya bahwa pada kelas tersebut masih ada belum berhasil dalam memprediksi kelas tersebut. Secara keseluruhan, nilai *macro average f1-score* sebesar 84.31% dan *weighted average f1-score* sebesar 83.86% menunjukkan bahwa kinerja model baik dan stabil diseluruh kelas, namun masih diperlukan peningkatan terutama untuk meningkatkan *recall* ada beberapa kelas agar performa model menjadi optimal.

Tabel 7 Hasil Evaluasi transfer learning tanpa data augmentasi

	Precision	Recall	F1-Score	Support
Cardboard	1.0000	1.0000	1.0000	11
Glass	1.0000	1.0000	1.0000	8
Metal	1.0000	1.0000	1.0000	9
Paper	1.0000	1.0000	1.0000	14
Plastic	1.0000	1.0000	1.0000	7
Trash	1.0000	1.0000	1.0000	11
accuracy			1.0000	60
Macro avg	1.0000	1.0000	1.0000	60
Weighted avg	1.0000	1.0000	1.0000	60

Berdasarkan hasil evaluasi, model menunjukkan performa yang sangat baik dengan nilai *precision*, *recall*, dan *F1-score* sebesar 100% pada seluruh kelas sampah, yaitu *Cardboard*, *Glass*, *Metal*, *Paper*, *Plastic* dan *Trash*.



Nilai akurasi kelseuruhan juga mencapai 100% pada 60 data uji, yang menandakan bahwa seluruh sampel berhasil diklasifikasikan dengan benar. Selain itu, nilai *macro average* dan *weighted average* yang sama – sama bernilai 100% menunjukkan konsistensi performa model pada seluruh kelas. Hasil ini mengindikasikan bahwa model mampu melakukan klasifikasi citra sampah dengan sangat baik, meskipun diperlukan analisis untuk memastikan tidak terjadinya overfitting.

Tabel 8 Hasil Evaluasi Transfer learning dengan data augmentasi

	Precision	Recall	F1-Score	Support
Cardboard	1.0000	1.0000	1.0000	11
Glass	1.0000	1.0000	1.0000	8
Metal	1.0000	1.0000	1.0000	9
Paper	1.0000	1.0000	1.0000	14
Plastic	1.0000	1.0000	1.0000	7
Trash	1.0000	1.0000	1.0000	11
accuracy			1.0000	60
Macro avg	1.0000	1.0000	1.0000	60
weighted avg	1.0000	1.0000	1.0000	60

Berdasarkan hasil evaluasi, model menunjukkan performa yang sangat baik dengan nilai precision, recall, dan F1-score sebesar 100% pada seluruh kelas sampah, yaitu *Cardboard*, *Glass*, *Metal*, *Paper*, *Plastic* dan *Trash*. Nilai akurasi kelseuruhan juga mencapai 100% pada 60 data uji, yang menandakan bahwa seluruh sampel berhasil diklasifikasikan dengan benar. Selain itu, nilai *macro average* dan *weighted average* yang sama – sama bernilai 100% menunjukkan konsistensi performa model pada seluruh kelas. Hasil ini mengindikasikan bahwa model mampu melakukan klasifikasi citra sampah dengan sangat baik, meskipun diperlukan analisis untuk memastikan tidak terjadinya overfitting.

4. KESIMPULAN

Berdasarkan hasil penelitian dan pembahasan yang telah diuraikan pada bab sebelumnya, dapat disimpulkan bahwa seluruh rumusan masalah yang diajukan dalam penelitian ini telah terjawab. Jawaban atas rumusan masalah akan disusun secara sistematis sesuai dengan urutan permasalahan yang telah dirumuskan. Dengan demikian, Kesimpulan yang disajikan mencerminkan pencapaian tujuan penelitian secara menyeluruh berdasarkan hasil analisis yang telah dilakukan. Berdasarkan hasil penelitian ini bahwa hasil menggunakan data augmentasi bisa menurunkan performa model kelemahan pada penelitian ini peneliti hanya menggunakan beberapa teknik data augmentasi ketidak cocokkan dalam memilih data augmentasi berakibat pemodelan tidak akan mampu mempelajari data dengan baik sehingga kesalahan dalam memilih data augmentasi berpotensi mengurangi performace model. Terkait optimalisasi penggunaan fungsi aktivasi leaky_relu sangat baik digunakan untuk penggunaan data terbatas, sehingga penggunaan fungsi aktivasi ini sangat baik digunakan untuk pemanfaatan data terbatas. Dapat disimpulkan bahwa berdasarkan hasil eksperimen ini bahwa transfer learning lebih unggul dari pada pemodelan lain yang memiliki tingkat akurasi, presisi, recall dan f1-score 100% dan tetap konsisten dengan menggunakan model yang telah di optimalisasi. Saran dalam penelitian ini masih banyak ditemukan kelemahan perlunya pengkajian ulang terkait transfer learning atau pemanfaatan ViT untuk menemukan hasil prediksi yang lebih baik dan lebih robust dan mampu memprediksi objek dalam berbagai kondisi seperti perbedaan pencahayaan, background atau jenis sampah yang belum pernah diajarkan dalam pemodelan ini. Serta perlunya peningkatan jumlah data sekitar 300 – 5.000 per kelas agar pemodelan layak digunakan untuk skala industri.

REFERENCES

- [1] I. Tasya Jadidah, N. Anisah, A. Nabila Zakiyah, E. Kumala Sari, M. Dewi, and S. Panca Putri, “Pengaruh Pola Konsumsi Masyarakat Urban Dan Dampaknya Terhadap Lingkungan,” *SIGNIFICANT: Journal Of Research And Multidisciplinary*, vol. 2, no. 02, pp. 242–251, Dec. 2023, doi: 10.62668/significant.v2i02.876.
- [2] N. Junus, Z. Mamu, and O. ,Sri Suaib, “View of Peningkatan Kesadaran Masyarakat Dalam Menjaga Kelestarian Wilayah Pesisir Pantai,” Jan. 2024.
- [3] Z. Zainuddin and U. Kusnaedi, “Manajemen Sampah dalam Pemanfaatan Potensi Sampah Secara Optimal (Studi Kasus Kota Bogor),” *KALBISOCIO*, vol. 11, no. 1, 2024, doi: 10.53008/kalbisocio.v11i1.3296.
- [4] M. Idris, M. Setyawan, and Z. Mufrodi, “Teknologi Insinerasi Sebagai Solusi Pengolahan Sampah Perkotaan dan Pemulihan Energi: A Review,” Jakarta, Apr. 2024.
- [5] M. A. R. Sutisna, “Strategi pengelolaan sampah kota terintegrasi menuju zero waste,” *Waste Handling and Environmental Monitoring*, vol. 1, no. 1, Feb. 2024, doi: 10.61511/whem.v1i1.2024.631.
- [6] U. Rose, L. Kusumawati, E. Kurniyaningrum, D. Pontan, and T. Widiarso, “Pengolahan Sampah Terpadu Dengan Konsep Waste To Energy Di Smart City IKN,” Jun. 2025.
- [7] B. Fang et al., “Artificial intelligence for waste management in smart cities: a review,” Aug. 01, 2023, *Springer Science and Business Media Deutschland GmbH*. doi: 10.1007/s10311-023-01604-3.



- [8] A. Ikhlas and B. Hendrik, “Sistemasi: Jurnal Sistem Informasi Literature Review: Studi Komparasi Klasifikasi Sampah menggunakan Algoritma Deep Learning Literature Review: A Comparative Study of Waste Classification using Deep Learning Algorithms,” 2025. [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [9] R. Prochazka *et al.*, “Collection of Plastic Packaging of Various Types: Sorting of Fractions of Plastic Waste Using Both Automated and Manual Modes,” *IEEE Access*, vol. 12, pp. 44244–44261, 2024, doi: 10.1109/ACCESS.2024.3376230.
- [10] I. B. Al-Mashhadani, “Waste material classification using performance evaluation of deep learning models,” *Journal of Intelligent Systems*, vol. 32, no. 1, Jan. 2023, doi: 10.1515/jisys-2023-0064.
- [11] G. Yolcu Oztel, “Deep learning-based automated garbage image classification using light-weight models,” *Journal of Scientific Reports-A*, vol. 062, pp. 171–181, 2025, [Online]. Available: <https://dergipark.org.tr/pub/jsr-a>
- [12] Y. Zhou *et al.*, “Optimization of automated garbage recognition model based on ResNet-50 and weakly supervised CNN for sustainable urban development,” *Alexandria Engineering Journal*, vol. 108, pp. 415–427, Dec. 2024, doi: 10.1016/j.aej.2024.07.066.
- [13] S. J. Buchade and S. Bhoite, “Comparative Study of ML Algorithms for Garbage Classification,” Jan. 30, 2024. doi: 10.21203/rs.3.rs-3903806/v1.
- [14] Y. Zhou, L. Lin, and T. Wang, “Garbage classification detection system based on the YOLOv8 algorithm,” *AIP Adv.*, vol. 14, no. 12, Dec. 2024, doi: 10.1063/5.0244795.
- [15] Z. Xu and N. Hajari, “Garbage Classification from Visual Footprints: Using Transfer Learning Strategy,” in *Proceedings of the International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications*, Science and Technology Publications, Lda, 2025, pp. 403–409. doi: 10.5220/0013151200003912.
- [16] W. Wang, “Garbage Image Classification based on Deep Learning,” 2024, pp. 400–410. doi: 10.2991/978-94-6463-370-2_42.
- [17] X. Tian, L. Shi, Y. Luo, and X. Zhang, “Garbage Classification Algorithm Based on Improved MobileNetV3,” *IEEE Access*, vol. 12, pp. 44799–44807, 2024, doi: 10.1109/ACCESS.2024.3381533.
- [18] J. Wang, “Application research of image classification algorithm based on deep learning in household garbage sorting,” *Heliyon*, vol. 10, no. 9, May 2024, doi: 10.1016/j.heliyon.2024.e29966.
- [19] E. T. Yasin, M. Koklu, and E. Tahsin Yasin, *Classification of Organic and Recyclable Waste based on Feature Extraction and Machine Learning Algorithms*. 2023. [Online]. Available: <https://www.researchgate.net/publication/370600046>
- [20] Q. Si and S. Ik Han, “RepVGG-MEM: A Lightweight Model for Garbage Classification Achieving a Balance Between Accuracy and Speed,” *IEEE Access*, vol. 13, pp. 36451–36469, 2025, doi: 10.1109/ACCESS.2025.3544631.
- [21] E. Likotiko, Y. Matsuda, and K. Yasumoto, “Garbage Content Estimation Using Internet of Things and Machine Learning,” *IEEE Access*, vol. 11, pp. 13000–13012, 2023, doi: 10.1109/ACCESS.2023.3242547.
- [22] Z. Wang, W. Zhou, and Y. Li, “GFN: A Garbage Classification Fusion Network Incorporating Multiple Attention Mechanisms,” *Electronics (Switzerland)*, vol. 14, no. 1, Jan. 2025, doi: 10.3390/electronics14010075.
- [23] D. Mewada *et al.*, “Contamination Detection From Highly Cluttered Waste Scenes Using Computer Vision,” *IEEE Access*, vol. 12, pp. 129434–129446, 2024, doi: 10.1109/ACCESS.2024.3456469.