

# Eksplorasi Data Augmentasi dan Optimasi pada Xception untuk Klasifikasi Sampah

## *Exploration of Data Augmentation in Xception for Waste Classification*

<sup>1</sup>Ariza Ikhlas\*, <sup>2</sup>Syafri Arlis

<sup>1,2</sup>Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Putra Indonesia YPTK Padang

<sup>1,2</sup>Jl. Raya Lubuk Begalung, Kecamatan Bungus Teluk Kabung, Kota Padang, Sumatera Barat

\*e-mail: [arizaikhlas01@gmail.com](mailto:arizaikhlas01@gmail.com)\*, [syafri\\_arlis@upiypk.ac.id](mailto:syafri_arlis@upiypk.ac.id)

(received: 16 August 2025, revised: 13 October 2025, accepted: 15 October 2025)

### Abstrak

Jumlah sampah yang terus meningkat diseluruh dunia menimbulkan masalah polusi, pengelolaan sampah dan daur ulang, yang membutuhkan solusi baru untuk meningkatkan ekosistem baru dalam pengelolaan sampah, seperti penggunaan *Smart Waste Management* yang merupakan pemanfaatan teknologi informasi dan *Artificial Intelligence* dalam pengelolaan sampah. Tujuan dari penelitian ini yaitu mengimplementasikan Xception CNN model untuk klasifikasi sampah, melakukan eksplorasi beberapa teknik augmentasi data, dan Optimasi Model yang sesuai untuk klasifikasi sampah. Metode yang digunakan dalam penelitian ini melalui beberapa tahap yaitu Persiapan Data, Membangun dan melatih model, menyesuaikan model untuk data dan membuat klasifikasi, evaluasi model, mengembangkan melalui melalui berbagai eksperimen, save dan reload model yang telah dilatih. Datasets yang digunakan dalam penelitian ini adalah Datasets Kaggle yang terdiri dari 2.527 yang terdiri dari beberapa kelas *Cardboard, Glass, Metal, Paper, Plastic, Trash*. Berdasarkan hasil optimasi maka diperoleh hyperparameter yang sesuai dengan datasets TrashNet yaitu batchsize = 32, Convfilters=64, Optimizer Adam(learning rate = 0.0001), dropout=0.25. Hasil pelatihan sebanyak 100 epoch maka diperoleh hasil terbaik akurasi 99%, loss 0.7%, validasi akurasi 87%, dan loss validasi 52%, pada hasil evaluasi yang diujikan dengan data uji diperoleh akurasi 76%, Precision 79%, Recall 75%, F1-Score 75%. Dengan menggunakan data augmentasi Scale, Translate, Color Space dapat meningkatkan terhadap Akurasi 13%, Precision 11%, Recall 13% dan F1-Score 12%. Kontribusi dalam penelitian ini mengimplementasikan Xception model terhadap datasets TrashNet untuk klasifikasi sampah. Dan mengusulkan beberapa metode data augmentasi yang menawarkan bukti empiris untuk menerima atau menolak teori. memberikan Solusi untuk pengembangan *Smart Waste Management*. Melakukan eksperimen untuk memperkaya literatur dengan hasil yang baru. Serta membandingkan berbagai metode data augmentasi yang sesuai dengan datasets TrashNet.

**Kata Kunci** : *artificial intelligence*, visi komputer, augmentasi data, xception, optimisasi, *smart waste management*

### Abstract

*The increasing volume of waste worldwide has led to significant challenges related to pollution, waste management, and recycling. These issues require innovative solutions to enhance the waste management ecosystem, such as the implementation of Smart Waste Management, which leverages information technology and artificial intelligence. This study aims to implement the Xception Convolutional Neural Network (CNN) model for waste classification, explore various data augmentation techniques, and identify optimal model configurations for this task. The research methodology consists of several stages, including data preparation, model building and training, model adaptation for classification tasks, model evaluation, iterative experimentation, and saving and reloading the trained model. The dataset used in this study is the TrashNet dataset obtained from Kaggle, consisting of 2,527 images across several classes: cardboard, glass, metal, paper, plastic, and trash. Based on the optimization process, the selected hyperparameters include a batch size of 32, 64*


convolutional filters, the Adam optimizer (learning rate = 0.0001), and a dropout rate of 0.25. After training for 100 epochs, the model achieved a training accuracy of 99% with a loss of 0.7%, and a validation accuracy of 87% with a validation loss of 52%. Evaluation on the test dataset yielded an accuracy of 76%, precision of 79%, recall of 75%, and an F1-score of 75%. The application of data augmentation techniques—such as scaling, translation, and color space transformation—resulted in performance improvements, increasing accuracy by 13%, precision by 11%, recall by 13%, and F1-score by 12%. This study contributes by implementing the Xception model on the TrashNet dataset for waste classification and proposing several data augmentation methods that provide empirical evidence to support or challenge existing approaches. The findings offer practical insights for the development of Smart Waste Management systems, enrich the literature through experimental results, and provide a comparative analysis of data augmentation techniques suitable for the TrashNet dataset.

**Keywords :** artificial intelligence, computer vision, data augmentation, optimization, smart waste management, xception

## 1 Pendahuluan

Sampah pada dasarnya adalah merupakan bahan padatan yang tersisa dari aktivitas manusia atau proses Alami. Secara umum negara maju memproduksi sampah lebih banyak dari pada dinegara berkembang.Indonesia dengan penduduk yang besar dengan tingkat pertumbuhan yang tinggi mengakibatkan terus bertambahnya volume timbulan sampah pertahunnya.

Komposisi sampah dunia juga sangat tergantung pada kondisi ekonomi suatu negara. Komposisi sampah di Indonesia juga mencerminkan kondisi perekonomian yaitu di level negara menengah.



Gambar 1 Komposisi sampah nasional [1]

Berdasarkan komposisi sampah di Indonesia pada tahun 2025 (Gambar 1) terdiri dari 39,36% sisa makanan, 12,63% Kayu dan ranting, 11,17% dari Kertas / Karton, 19,73% Plastik, 3,42% Logam, 2,55% Kain, 2,08% Karet / Kulit, 2,4% Kaca, 6,66% lainnya. Kemudian meningkatnya urbanisasi dan aglomerasi orang – orang di daerah perkotaan di Indonesia dalam banyak hal menyebabkan kondisi sanitasi kota semakin memburuk. Disamping itu, pola konsumsi masyarakat yang berubah dari masyarakat tradisional ke modern memberikan kontribusi pada perubahan komposisi sampah.

Sumber sampah di Indonesia berasal dari berbagai sumber utama yaitu 53,77% Rumah tangga, 3,97% Perkantoran, 10,48% Perniagaan, 14,47% Pasar, 3,78% Fasilitas Publik, 11,91% Kawasan, 1,62% lainnya[1]undang – undang Nomor 18 Tahun 2008 tentang Pengelolaan sampah sudah disahkan lebih dari satu dasawarsa.

**Tabel 1 dapat dilihat berbagai Perundang – undangan turunan dari UU 18 / 2008[2]**

Hal yang diatur	Peraturan
Pemberian Kompensasi oleh pemerintah daerah sebagai akibat dampak negatif yang ditimbulkan oleh kegiatan penanganan sampah di tempat pemrosesan akhir sampah	PP 81/2012, PP22/2012 dan Pemendagri 33 / 2010
Tata cara penyediaan fasilitas pemilahan sampah tata cara pelabelan atau penandaan dan kewajiban produsen untuk mengelola kemasan dan/atau barang yang diproduksinya yang tidak dapat / sulit terurai	PP 81 / 2012
Penanganan Sampah yang mengatur pemilahan pengumpulan, pengangkutan , pengelolaan, dan pemrosesan akhir sampah	PP 81 / 2012, PermenLH 13/2012, Permendagri 33/2010, PermenPU No.3 / 2013
Bentuk dan tata cara peran masyarakat dalam pengelolaan sampah oleh pemda dan / atau pemerintah.	PP 81 / 2012
Larangan memasukan sampah ke wilayah NKRI mencampur sampah dengan B3 dan Mengelola sampah yang menyebabkan pencemaran dan / atau perusakan lingkungan	Permendagri 31 / 2016

Pada Tabel 1 dapat dilihat beberapa kebijakan pemerintah dalam Hal penerapan peraturan perundang – undangan turunan dari UU 18/2008. Pemberian Kompensasi oleh pemerintah daerah sebagai akibat dampak negatif yang ditimbulkan oleh kegiatan penanganan sampah ditempat pemrosesan akhir sampah. Yang diatur pada PP 81/2012, PP22/2012 dan Pemendagri 33 / 2010. Kemudian Tata cara penyediaan fasilitas pemilahan sampah tata cara pelabelan atau penandaan dan kewajiban produsen untuk mengelola kemasan dan / atau barang yang diproduksinya yang tidak dapat . sulit terurai diatur pada PP 81 / 2012. Penanganan sampah yang mengatur pemilahan pengumpulan, pengangkutan , pengelolaan , dan perosessan akhir sampah diatur dalam PP 81 / 2012, PermenLH 13/2012, Permendagri 33 / 2010, PermenPU No.3 / 2013. Bentuk dan tata cara peran masyarakat dalam pengelolaan sampah oleh pemda dan / atau pemerintah Diatur dalam PP 81 / 2012. Larangan memasukan sampah ke wilayah NKRI mencampur sampah dengan B3 dan Mengelola sampah yang menyebabkan dan pencemaran atau perusakan lingkungan Permendagri 31 / 2016.

Selama ini sebagian besar masyarakat masih memandang sampah sebagai barang sisa tidak berguna bukan sebagai sumber daya yang bisa dimanfaatkan.Pengangkutan sampah dari sumbernya (cakupan pelayanan persampahan) menjadi masalah tersendiri yang masih sulit untuk diatas.beberapa faktor yang memengaruhi sampah antara lain Jumlah Penduduk, Keadaan Sosial Ekonomi, Kemajuan Teknologi, Tingkat Pendidikan.

Sampai saat ini sampah masih menjadi permasalahan lingkungan yang belum bisa terselesaikan. Tantangan kita dalam pengelolaan sampah di negara ini sangat besar.beberapa yang menonjol dari kondisi pengelolaan sampah adalah Kurangnya kesadaran masyarakat, Kemampuan pemerintah daerah terbatas, Parahnya kondisi di Tempat Pemrosesan Akhir (TPA), Iklim dan Aspek Sosial Budaya.

Sementara faktor sosial budaya dimaksudkan lebih pada kebiasaan dimasyarakat dalam pola konsumsinya. Kita cenderung membeli barang dalam jumlah kecil misalnya sampo atau sabun dalam kemasan saset. Tidak kalah banyak juga sampah bungkus minuman serbuk siap saji seperti kopi dan serbuk buah[2].

Jumlah sampah yang terus meningkat di seluruh dunia menimbulkan berbagai masalah dalam pengelolaan sampah yang membutuhkan strategi baru untuk meningkat ekosistem pengelolaan sampah yang lebih baik. Seperti penggunaan *smart waste management* yang melahirkan inovasi – inovasi terbaru dengan pemanfaatan teknologi kecerdasan buatan[3].

Berbagai inovasi yang dikembangkan seperti Analisis kimia, Bidang Penggunaan dan Aplikasi perkotaan untuk membangun.banyak Inovasi – inovasi yang dilahirkan pada bidang kimia analisis seperti teknologi Waste To Energy , Optimisasi Pirolisis, Identifikasi kandungan karbon biologis dan karbon fosil dalam sampah padat.

Berikut ini adalah penelitian terkait Waste to Energy dengan judul *A mini review on AI-driven thermal treatment of solid waste :Emission control and process optimization*. [4] tujuan penelitian ini adalah mengkaji penerapan algoritma kontrol yang dioptimalkan oleh AI dalam proses thermal seperti pirolisis , insinerasi, dan gassifikasi. Manfaat penelitian ini adalah Penerapan solusi berbasis AI memungkinkan optimasi efisiensi energi optimal dan meminimalkan emisi zat berbahaya termasuk CO, Nox, dan dioksin.

Berikutnya berjudul *A Comprehensive study of machine Learning for Waste to Energy*. [5] tujuan penelitian ini menyajikan studi komprehensif yang mengintegrasikan machine learning, penilaian siklus hidup (LCA) dan Optimasi heuristik untuk mencapai proses limbah medis menjadi bahan bakar yang rendah karbon. Model Machine learning mengungguli model proses rinci (DPM) dengan stabilitas komputasi yang lebih tinggi waktu optimasi juga berkurang dari jam menjadi detik.

Penelitian berikutnya berjudul *Waste to Energy Trends and Perspective* [6]. Tujuan penelitian ini meninjau berbagai limbah yang dapat digunakan dalam proses waste to energy dengan menggunakan proses termokimia, biokimia dan kimia, manfaat penelitian ini adalah proses waste to energy dapat menjadi cara untuk memulihkan energi dari limbah dan membantu akses ke energi dari limbah dan membantu akses ke energi terbarukan bagi populasi dunia.

Penelitian terkait pyrolisis juga telah dilakukan oleh peneliti sebelumnya yang berjudul *Optimizing pyrolysis and Co- Pyrolysis of plastic and Biomass using Artificial Intelligence* [7] Tujuan penelitian menyelidiki dampak komposisi bahan baku dan kondisi operasi dalam pirolisis dan ko – pirolisis. Mengembangkan model prediksi machine learning dan kerangka kerja optimasi. Manfaat penelitian pirolisis dan ko-pirolisis limbah biomassa dan plastik menawarkan cara yang menjanjikan untuk pengelolaan limbah berkelanjutan dan generasi energi terbarukan.

Penelitian terdahulu lainnya berjudul *Machine learning application in biomass pytolysis from biorefinery to end of life product management* [8]. Tujuan penelitian ini memberikan tinjauan komprehensif tentang penggunaan machine learning (ML) dalam pirolisis. Manfaat penelitian ini menyoroti keberhasilan ML dalam optimasi dan kontrol proses, memprediksi hasil produk , pemantauan waktu nyata, penilaian siklus hidup, dan analisis tekno – ekonomi selama pirolisis biomassa.

Penelitian lain berjudul *Machine learning Predictions of Oil Yields Obtained by Plastic Pyrolysis and Application to thermodynamic Analysis* [9]. tujuan penelitian ini mengembangkan model untuk memprediksi hasil dan konversi dari komposisi umpan dan kondisi reaksi. Manfaat penelitian ini adalah Model ini berpotensi menjadi alat untuk memprioritaskan sumber daya ke aliran plastik yang paling menjanjikan dan untuk mengevaluasi starategi pra – pemisahan untuk meningkatkan hasil.

Adapun penelitian terkait identifikasi karbon biologis dan karbon fosil dalam limbah padat. Adapun penelitian terdahulu *Improving the method for calculating carboon emission from waste incineration confirmed with carbon – 14 testing of flue gas*[10].penelitian ini bertujuan mengembangkan metode yang lebih baik untuk menghitung emisi karbon langsung dari pabrik insinerasi limbah padat kota. Manfaat menyediakan cara baru untuk secara akurat menghitung emisi karbon dari insinerasi limbah.

Peneliti berikutnya melakukan penelitian yang berjudul *Accelarator mass spectrometry for tracing fossil carbon ceontent of combusted* [11]. Tujuan penelitian ini menentukan inventarisasi emisi CO2 fosil dan pabrik insinerasi limbah untuk tujuan perdagangan emisi di masa depan.

*GreenHouse Gas Emissions from incineration of Municipal Solid Waste in Seoul South Korea* yang dilakukan oleh [12]. Tujuan penelitian ini adalah memperkirakan emisi gas rumah kaca (GRK) dari insinerasi limbah padat kota (MSW) di Seoul.

Penelitian terkait logistic dan transportasi peneliti terdahulu juga pernah melakukan penelitian yang berjudul *Optimizing waste managemnt in smart cities an IoT – Based approach using dynamic bald eagle search optimization algorithm (DBESO) and machine learning*. [13]Penelitian ini bertujuan untuk mengatasi tantangan dalam pengelolaan limbah seperti jadwal yang tidak teratur , rute yang tidak optimal, dan prediksi yang tidak akurat dalam jumlah limbah.

Berikutnya penelitian lain yang berjudul *Vehicle route optimizer for waste collection and routing optimization problem* [14]. tujuan penelitian ini memperkenalkan starategi optimasi rute kendaraan (VRO) untuk meningkatkan efisiensi dan keberlanjutan kota pintar.

*Research on optimization of waste sorting and transportation network in smart cities base on garbage volume prediction* [15]. Tujuan penelitian ini menyajikan model optimasi untuk rute

<http://sistemasi.ftik.unisi.ac.id>

kendaraan sampah kering dan basah yang bertujuan untuk meminimalkan biaya total, jejak karbon , dan polusi sekunder.

Penelitian lain membahas topik yang berbeda identifikasi tempat pembuang sampah illegal dengan judul *Revealing influencing factors on global waste distribution via deep – learning based dumpsite detection from satellite imagery*[16].Tujuan penelitian ini ialah mengembangkan metode yang efektif , efisien dan berbiaya rendah untuk mendeteksi tempat pembuangan sampah menggunakan citra satelit.

Selain itu penelitian asal indonesia melakukan yang berjudul *Identification of illegally dumped plastic waste in a highly polluted river in indonesia using sentinel – 2 satellite imagery*. [17] tujuan penelitian ini yaitu mengidentifikasi pembuangan sampah plastik ilegal disungai menggunakan citra satelit sentinel – 2.

Penelitian lain yang berjudul *Aerial waste dataset for landfill discovery in aerial and satellite images* [18]. Tujuan penelitian menyajikan dataset untuk deteksi tempat pembuangan sampah, yang dapat digunakan untuk membuat alat deteksi otomatis.Datasets ini dapat membantu penelitian kearah metode deteksi tempat pembuangan sampah yang terukur dan akurat.

Kemudian penelitian tentang aplikasi perkotaan seperti robotic, tong sampah pintar dan aplikasi prediksi berikut penelitian – penelitian terkait aplikasi prediksi dalam pengelolaan sampah. *Predicition of waste generation using machine learning :a Regional study in Korea*[19].Tujuan penelitian ini adalah untuk memprediksi volume sampah rumah tangga secara akurat menggunakan machine learning untuk perencanaan kota yang berkelanjutan dan pengembangan kebijakan lingkungan berbasis data.membantu para pengambil keputusan dalam merumuskan dan memperbaiki sistem pengelolaan sampah untuk mencapai tujuan keberlanjutan.

*A comparative analysis of forecasting algorithms for predicting municipal solid waste generation in Chittagong City*[20].Tujuan penelitian untuk memprediksi produksi sampah padat kota (MSW) di Kota Chitagong menggunakan algoritma Multilayer Perceptron (MLP), Support Vector Machine (SVM), dan Gaussian Algoritma (GA).Manfaat penelitian memberikan informasi yang akurat untuk membantu para pengambil keputusan memodifikasi dan memperbaiki sistem pengelolaan sampah untuk mencapai tujuan keberlanjutan.

*Construction and Demolition Waste Generation Prediction by Using Artificial Neural Networks and Metaheuristic Algorithm*[21].Tujuan penelitian ini untuk memprediksi timbulan sampah konstruksi dan pembongkaran (CDW) menggunakan jaringan saraf tiruan (ANN) dan Algoritma metaheuristik.Manfaat penelitian ini membantu dalam memecahkan masalah kompleks yang tidak dapat diselesaikan oleh metode konvensional, dan memberikan alat yang berguna untuk perencanaan dan pengelolaan CDW.

Penelitian tentang robotic yang berjudul *Optimizing waste Sorting for sustainability an AI – Powered Robotic Solution for Beverage Container Recycling*[22]. Tujuan penelitian ini mengembangkan solusi robotik bertenaga AI untuk daur ulang wadah minuman. Manfaat penelitian ini meningkatkan efisiensi pemilahan sampah, meningkatkan tingkat daur ulang, dan berkontribusi pada keberlanjutan.

Penelitian lain *Robotic waste sorting using deep learning* [23] tujuan penelitian ini menyajikan sistem pemilahan sampah otomatis yang menggunakan kamera stereoskopis dan manipulator robotik dengan Deep learning. Manfaat penelitian mengatasi inefisiensi dan biaya tinggi dari metode pemilhan manual, meningkatkan akurasi dan efisiensi proses daur ulang.

Penelitian lain yang berjudul *Versatile waste sorting in small batch and flexible manufacturing industries using deep learning techniques*(Vukicevic et al., 2025). Tujuan penelitian ini menilai kemampuan arsitektur segment Anyting model (SAM) untuk memisahkan objek yang sangat bervariasi dalam pemilahan sampah robotik. Manfaat Penelitian ini Mengeliminasi kebutuhan untuk mengembangkan algoritma deteksi dan segmentasi khusus, dan secara signifikan mengurangi waktu serta biaya untuk beradaptasi dengan kasus penggunaan yang berbeda.

Penelitian lain yaitu *Application of the vision – based deep learning technique for waste classification using robotic manipulation systems*[25]. Tujuan penelitian ini mengusulkan sistem klasifikasi sampah cerdas dan otomatis yang mengintegrasikan deep learning dengan kontrol kinematik robot. Manfaat penelitian ini adalah mengatasi tantangan pemilahan manual seperti ketidakakuratan dan resiko kesehatan, serta meningkatkan akurasi , kecepatan dan keandalan klasifikasi secara signifikan.

Penelitian yang berjudul *Optimized Operation Management With Prediction filling levels of the Litter Bins for a Fleet of Autonomous Urban Service Robots* [26] Tujuan penelitian ini Mengoptimalkan manajemen operasional armada robot layanan perkotaan otonom dengan memprediksi tingkat pengisian tempat sampah. Tujuan Penelitian ini memungkinkan transisi dari layanan padat karya ke layanan otonom mengurangi biaya operasional, dan Meningkatkan keberlanjutan.

Penelitian tentang tong sampah cerdas juga telah dilakukan oleh peneliti terdahulu seperti *A survey of smart dustbin system using the IoT and Deep Learning*[27]. Tujuan penelitian ini melakukan survei komprehensif terhadap sistem tempat sampah cerdas menggunakan IoT dan Pembelajaran mendalam. Manfaat Penelitian ini Meningkatkan Kondisi Sanitasi di Perkotaan padat penduduk, mengurangi biaya tenaga kerja, dan Memungkinkan pemantauan sampah secara real – time.

Penelitian lain tentang *Smart Trash Box technology of Computer Vision to Support Ecogreen Campus*[28]. Tujuan Penelitian Mengembangkan sistem tempat sampah cerdas yang dapat mengklasifikasikan sampah organik dan non-organik menggunakan teknik komputer vision untuk mendukung kampus hijau. Manfaat Penelitian membantu pengelolaan sampah di lingkungan kampus menjadi lebih terorganisir melestarikan sumber daya alam, dan lingkungan.

Penelitian tentang *Smart Waste bin monitoring using IoT for Sustainable biomedical waste management*[29] .Tujuan Penelitian ini Menerapkan solusi IoT untuk memantau dan mengelola sampah biomedis di fasilitas layanan kesehatan secara berkelanjutan. Meningkatkan pemantauan sampah di fasilitas kesehatan, memastikan pengumpulan tepat waktu dan menganalisis pola untuk efisiensi yang lebih baik.

Berdasarkan penelitian diatas dapat disimpulkan pemanfaat *Artificial Intelligence* banyak digunakan dalam pengembangan *Smart Waste Management* klasifikasi sampah sangat direkomendasikan untuk pengelolaan sampah padat kota, dan penggunaan robot dan tong sampah cerdas dapat secara substansial untuk meningkatkan efesiensi klasifikasi sampah. Namun robot membutuhkan keterampilan visual dan operasional yang canggih untuk berfungsi dilingkungan industri yang sangat heterogen, kompleks, dan tidak dapat di prediksi untuk klasifikasi sampah.

Beberapa teknologi yang dibutuhkan yaitu Deteksi visual menggunakan gambar hiperspektral untuk menemukan wilayah target yang diminati. Robot dapat mengatasi kondisi lapangan yang kompleks dengan menambahkan teknologi lokalisasi dan pemetaan secara simultan serta metode segmentasi instance. *Deeplearning* teknologi deeplearning seperti segmentasi instance, dapat secara akurat mendeteksi kontur semua objek dalam gambar, termasuk limbah konstruksi dan pembongkaran. Integrasi Sistem para peneliti saat ini menyelidiki metode integrasi robot pemilah sampah ke dalam sistem pengelolaan sampah yang ada, seperti memanfaatkan robot untuk memilah sampah sebelum dikirim ke tempat pembuangan akhir[3].

Dalam penelitian ini peneliti akan melakukan penelitian tentang Pemanfaatan Artificial Intelligence dengan menggunakan *Computer Vision* menggunakan Xception Model untuk pengklasifikasian sampah.Tujuan dari penelitian ini yaitu mengimplementasikan Xception CNN model untuk klasifikasi sampah, melakukan eksplorasi beberapa teknik augmentasi data, dan Optimasi Model yang sesuai untuk klasifikasi sampah.

## 2 Tinjauan Literatur

Penelitian tentang pemanfaatan *Computer Vision* untuk pengklasifikasian sampah oleh peneliti terdahulu oleh Pandey A et al[30] Penelitian yang berjudul *Deep Learning Enabled Garbage Classification and Detection by Visual Context for Aerial images*. Metode yang digunakan dalam penelitian ini dengan menggunakan *Transfer Learning* dengan *MobileNetV3 – Large , Fine Tuning + augmentasi , dataset KACHARA*. Hasil yang diperoleh dalam penelitian ini akurasi 94.37% , F1 – Score 94.22% . Dataset yang digunakan dalam penelitian ini adalah dataset baru (top – view aerial). Model lebih ringan 21.3 MB, cocok untuk deployment.kekurangan dalam penelitian ini adalah tidak mendukung multi object segmentation, keterbatasan generalisasi.

Penelitian lain yang berjudul *Mutli – layer Feature Fusion for high – accuracy Solid Waste Classification using Hybrid Deep learning Model* diteliti oleh Celik G[31]. Metode yang digunakan dalam penelitian ini adalah Hybrid model (EfficientNetB0 +InceptionV3 + HyperColumn)+

XGBClassifier. Hasil akurasi yang diperoleh dalam penelitian ini mencapai akurasi 99.87% pada datasets HGI-30, 99.40% pada TrashNet. Kelebihan penelitian memiliki tingkat akurasi yang sangat tinggi, fungsi multi – resolusi , kode tersedia open source. Kekurangan Perhitungan lebih kompleks, butuh resource tinggi , dataset terbatas.

Peneliti lain dengan memanfaatkan metode berbeda yang berjudul Real time intelligent garbage monitoring and efficient collection using Yolov8 dan Yolov5 deeplearning models for environmental sustainability di teliti oleh Mohammed et al[32]. Model yang digunakan yaitu Yolov5, Yolov8, EfficientNet, dengan pemanfaatan teknologi IoT (Raspberry Pi sensor).Hasil yang diperoleh pada Yolov5 & Yolov8 menunjukkan akurasi tinggi, kelas ‘Full-trash bin’ paling akurat, ‘wet trash’ paling rendah. Kelebihan Pemodelan ini ringan, bisa jalan di perangkat tanpa GPU, real – time Monitoring , bisa diintegrasikan IoT. Kekurangan Tantangan occlusion, Optimasi CPU / GPU masih perlu kelas tertentu akurasinya rendah.

Peneliti lain dengan menggunakan pemodelan Focus – RCNet yang berjudul *Focus – RCNet : Lightweight recyclable waste classsification algorithm based on focus and knowledge distillation* diteliti oleh Zheng D, et al[33].metode yang digunakan dalam penelitian menggunakan Focus – RCNet (MobileNetV2-inspired, SimAM attention, Knowledge Distillation). Hasil yang diperoleh akurasi mencapai 92% pada datasets TrashNet , Model ringan, Ringan, Cepat , bisa digunakan untuk IoT / Embedded.kekurangan akurasi menurun dibanding dengan model – model besar, terbatas hanya pada datasets TrashNet.

Penelitian lain dengan menggunakan Yolo dan menggunakan *Complex Multi – Scenes, yang berjudul Skip – Yolo: Domestic Garbage Detection Using Deep Learning Method in Complex Multi-scenes* diteliti oleh Lun Z et al[34]. Metode yang digunakan Skip-Yolo (Yolov3) + Dense Convolution Block + Multiscale feature fusion). Hasil akurasi meningkat 22.5% & 18.6% recall dibanding Yolov3, efektif di multi – scene. Kelebihan Deteksi lebih baik pada garbage mirip di kondisi kompleks, mengurangi overfitting., kekurangan dalam penelitian ini masih menggunakan Yolov3 (realatif lama),komputasi lebih berat dibanding lightweight model.

Penelitian lain yang berfokus pada sampah medis dengan judul Medical Waste sorting machine development with IoT and Yolo model utilization diteliti oleh Moktar H, M et al[35]. Metode yang digunakan dalam penelitian ini ialah Yolov5 – Yolov9 (Yolov8), IoT , Prototype mesin Sortir, hasil yang diperoleh mAP 98% , Precision 0.958, recal 0.9663; uji coba prototipe 93.75% kelebihan tingkat akurasi tinggi, protipe nyata , relevan dengan SDG2(Kesehatan).kekurangan hanya menggunakan datasets medis.

Penelitian lain menggunakan metode yang berbeda yang berjudul *Intelligent Waste Classification approach based on improved multi – layered convolutional neural network*. Diteliti oleh Chabra M et al[31]. Metode yang digunakan Improved DCNN + Transfer Learning (VGG16, VGG19, MobileNetV2, DenseNet121, EfficentNetB0). Hasil akurasi 93.28% lebih tinggi dari baseline CNN & Transfer Learning. Kelebihan Peningkatan signifikan dengan Fine-tuning, regularisasi (LeakyReLU, Dropout) Fokus kekurangna Fokus hanya pada datasets Binary (Organic vs Recyclable), datastes terbatas hanya 25k gambar.

Berdasarkan penelitian – penelitian terdahulu telah banyak dari mereka yang telah berhasil mengembangkan dan mengimplementasikan *Artificial Intelligence* dan *Computer Vision* untuk pengklasifikasian sampah. Dari pemanfaatan Transfer Learning dan Eksplorasi Data Augmentasi, menggunakan Focus-RCNet, Hybrid Model, penerapan IoT / Embeded Systems, penerapan pada mesin sortir prototipe, Yolov3, memanfaatkan DCNN pada Transfer learning VGG16,VGG19, MobileNetV2, DenseNet121, dan EfficientNetB0 yang memiliki tingkat akurasi yang baik dalam pengembangan metode mereka.

Dalam penelitian ini peneliti memilih Arsitektur Xception untuk pengklasifikasian sampah, kerena pemodelan ini termasuk dalam pemodelan besar maksudnya adalah pemodelan yang memiliki struktur / arsitektur yang kompleks. Penelitian ini juga bertujuan untuk melakukan Optimasi dan Eksplorasi data augmentasi dengan berbagai teknik data augmentasi untuk klasifikasi sampah yang sesuai atau cocok untuk pengklasifikasian sampah.

## 2.1 Artificial Intelligence (AI)

AI adalah sub bidang ilmu komputer yang berfokus pada pengembangan agen cerdas , atau sistem penalaran, pembelajaran, dan tindakan otonom. Metode efektif untuk menyelesaikan berbagai masalah, mulai dari bermain game hingga diagnosa medis , telah dikembangkan menggunakan AI. Bahkan , penciptaan algoritma ML & DL telah menjadi salah satu perkembangan paling signifikan dalam AI[36].

## 2.2 Deep Learning (DL)

*Deep Learning* (DL) merupakan cabang dari *Machine Learning* (ML) yang memproses informasi melalui serangkaian algoritma yang disusun secara hierarkis dalam beberapa lapisan. Setiap lapisan bertugas mengolah keluaran dari lapisan sebelumnya , sehingga membentuk suatu jaringan saraf tiruan (Artificial Neural Network) yang meniru proses pemrosesan informasi secara terdistribusi sebagaimana dilakukan oleh neuron dalam otak manusia.

Salah satu teknik yang termasuk dalam DL adalah Convolutional Neural Network (CNN). Dengan demikian , CNN merupakan bagian dari DL , namun tidak semua algoritma DL merupakan CNN , CNN secara umum banyak digunakan dalam bidang klasifikasi data visual dan computer vision, karena kemampuannya dalam mengekstraksi fitur dari citra dengan mengurai gambar menjadi piksel – piksel yang dilengkapi label atau tag. Hal ini memungkinkan model untuk memperoleh pemahaman visual terhadap data.

Proses utama dalam CNN adalah operasi konvolusi, yakni suatu transformasi matematis antara dua fungsi yang menghasilkan fungsi baru, yang menghasilkan interaksi atau pengaruh antara kedua fungsi tersebut.

## 2.3 CNN Convolution Neural Network

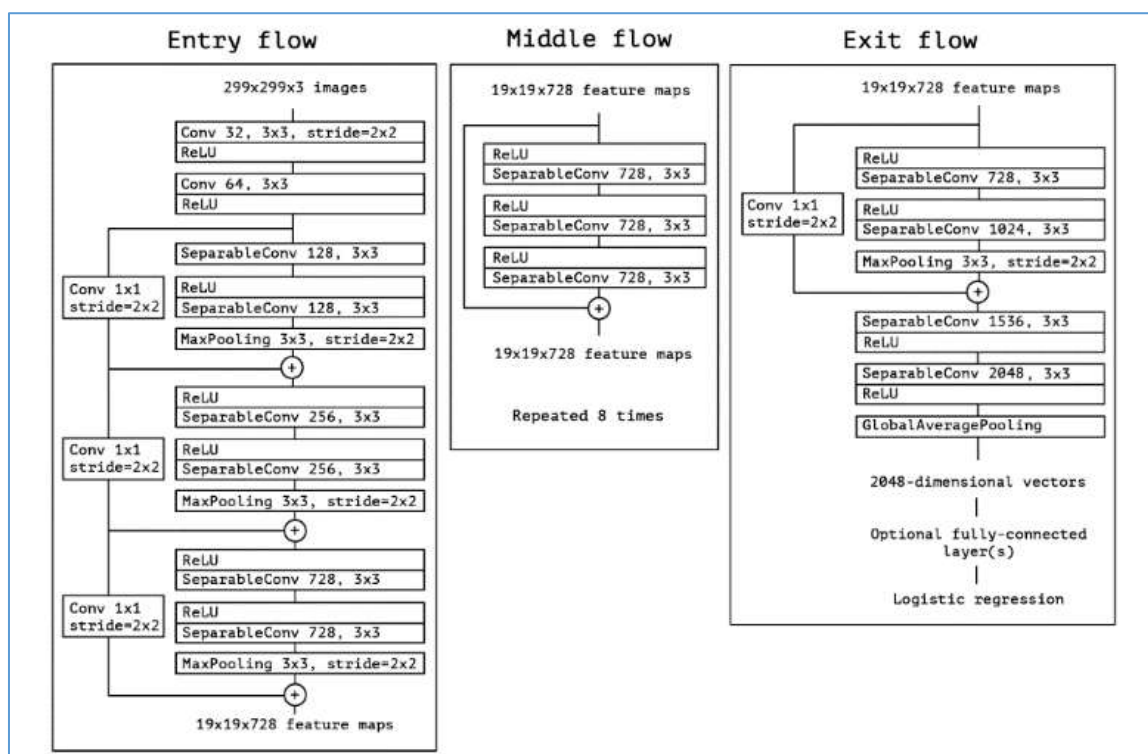
CNN merupakan model klasik dalam tugas pengenalan dan klasifikasi citra. Dalam pengenalan citra sampah, mengeksplorasi berbagai arsitektur CNN atau varian yang disempurnakan dapat meningkatkan kinerja klasifikasi. Misalnya struktur jaringan yang lebih dalam seperti ResNet, Inception, dan EfficientNet dapat dicoba untuk meningkatkan representasi dan kemampuan generalisasi model. CNN melakukan operasi konvolusi pada citra masukan dengan menerapkan serangkaian filter mengekstraksi fitur hierarkis dari citra asli dengan menumpuk lapisan konvolusional menggabungkan lapisan, dan lapisan fungsi aktivasi.

Pembelajaran fitur otomatis: CNN dapat secara otomatis mempelajari representasi fitur dalam gambar melalui algoritma backpropagation selama pelatihan. Berbagai parameter dan bidang reseptif local: CNN mengurangi jumlah parameter model dan mempertahankan kemampuan untuk memodelkan informasi local dalam gambar melalui berbagai parameter model dan mempertahankan kemampuan untuk memodelkan informasi lokal dalam gambar melalui berbagai parameter dan bidang reseptif local. Invariansi terhadap transformasi gambar : CNN menunjukkan Tingkat invariansi tertentu terhadap transformasi gambar seperti translasi penskalaan, dan rotasi melalui operasi konvolusi dan penggabungan.

Akan tetapi model CNN memiliki beberapa keterbatasan Pertama model ini membutuhkan jumlah data berlabel yang cukup. Model CNN biasanya memerlukan Kumpulan data yang besar untuk pelatihan guna menghindari overfitting dan meningkatkan kemampuan generalisasinya [37].

## 2.4 Arsitektur Xception

Arsitektur jaringan saraf konvolusional yang sepenuhnya didasarkan pada lapisan Konvolusional yang sepenuhnya didasarkan pada lapisan konvolusi yang dapat dipisahkan secara mendalam. Deskripsi lengkap mengenai spesifikasi jaringan ditunjukkan pada Gambar 2



Gambar 2 Xception arsitektur[38]

Dalam arsitektur Xception, data input diproses melalui tiga tahap utama : alur masuk (entry flow), alur Tengah (middle flow), dan alur keluar (exit flow). Pada tahap awal , data melewati beberapa lapisan konvolusi awal yang bertugas mengekstraksi fitur dasar. Setelah itu, data masuk ke bagian Tengah jaringan, yang merupakan inti dari arsitektur ini dan terdiri dari blok – blok yang sama diulang sebanyak delapan kali.

Setiap blok dalam alur Tengah terdiri dari lapisan Separable Convolution yang memisahkan proses konvolusi spasial dan kanal.Semua Lapisan Convolutional termasuk yang separable, selalu diikuti oleh proses normalisasi batch(batch normalization),meskipun tidak ditampilkan secara eksplisit dalam diagram arsitektur.

Pada bagian akhir (exit flow), data difinalisasi untuk proses klasifikasi dengan menggunakan beberapa lapisan konvolusi tambahan dan biasanya diakhiri dengan pooling dan lapisan klasifikasi. Seluruh lapisan separable Convolution dalam model ini menggunakan depth multiplier sebesar 1 yang berarti tidak ada peningkatan jumlah saluran fitur (channel) selama proses konvolusi [38].

## 2.5 Data Augmentasi

Image data augmentasi meningkatkan ukuran pada gambar atau datasets latih dengan menghasilkan beberapa contoh training dari gambar yang ada.Augment data dengan melakukan *flip*, *rotating* dan mengatur kecerahan secara acak.ini juga membantu model untuk lebih tangguh terhadap berbagai variasi didalam posisi, asli dan kondisi cahaya [18].

## 2.6 Confusion Matrix

Confusion Matrix Karl Pearson menemukan *Confusion Matrix* (Tabel 2) pada tahun 1904 saat pertama kali dikenal sebagai tabel Kontingensi.kemudian matriks klasifikasi dan kemudian disebut *Confusion Matrix*, dalam *Data Sciences* [40].

*Confusion Matrix* adalah matriks berukuran persegi berukuran N x N, dengan menunjukkan jumlah kelas keluaran. Setiap baris mewakili jumlah instansi kelas yang diprediksi dan setiap kolom mewakili jumlah kelas yang sebenarnya.ini memberikan rincian kelas per kelas dari jumlah prediksi akurat dan tidak akurat yang dibuat oleh pengklasifikasian untuk tugas klasifikasi. Kategorisasi dapat berupa biner atau multikelas[40].

Ada dua tipe prediksi :

True Positive (TP) : Kedua Nilai aktual dan perediksi bernilai positif

False Positive (FP) : melalui prediksi adalah positif nilai aktualnya adalah negatif. Ini disebut “Type 1 error”

True Negatif (TN) : nilai sebenarnya adalah negatif dan prediksi bernilai negatif.

False Negatif (FN) : melalui prediksi menjadi negatif dan sampel adalah positif ini juga disebut “Type Error II”.

**Table 2 Confusion matrix[40]**

	Actual Values	
	Positif	Negatif
Positif	True Positif (TP)	False Positif (FP/ Type 1 Error)
Negatif	False Negatif (FN/ Type II Error)	True Negative (TN)

## 2.7 Accuracy

Akurasi (1) adalah bagian kebenaran prediksi dari semua prediksi atau seberapa sering sebuah prediksi mendapatkan hasil yang benar.

$$Akurasi = \frac{(TP+TN)}{(TP+FP+TN+FN)} \dots\dots\dots(1)$$

Akurasi adalah bagian yang sangat berguna ketika class dalam dataset itu seimbang, yaitu , mereka memiliki jumlah instansi yang kira – kira sama untuk setiap kelas. Namun, akurasi klasifikasi memiliki keterbatasan, terutama ketika berhadapan dengan dataset yang tidak seimbang, dimana jumlah contoh dari satu kelas dapat secara signifikan melebihi jumlah contoh dari kelas lainnya. Dalam kasus seperti itu , model dapat mencapai akurasi yang tinggi hanya dengan memprediksi kelas mayoritas. Namun kinerjanya di kelas minoritas mungkin buruk[40].

## 2.8 Precision

Jika ada lebih dari dua keluaran kelas, klasifikasi akurasi tidak menyediakan informasi tentang kelas yang diprediksi secara akurat. dalam kasus seperti itu ukuran yang lebih tepat adalah presisi (2). Presisi adalah fraksi dari hasil positif yang diprediksi dengan benar[40].

$$Presisi = \frac{TP}{(TP+FP)} \dots\dots\dots(2)$$

Nilai presisi yang tinggi menunjukkan bahwa model memiliki tingkat False Positif yang rendah, artinya model tersebut menghasilkan prediksi positif yang akurat. Namun nilai presisi rendah menunjukkan tingginya jumlah False Positif, yang menunjukkan bahwa model tersebut lebih banyak prediksi positif yang salah.

Presisi tidak mengevaluasi kinerja dengan tepat terkait kasus negatif. Presisi juga tidak mempertimbangkan False Negatif (Error type II) yang merupakan kasus True Positif tetapi diprediksi secara keliru sebagai negatif. Ketika false negatif perlu diminimalkan atau ketika False Positif dan False Negatif sama pentingnya, metrik lain seperti recall (sensitivitas) atau F1 – Skor yang menyeimbangkan presisi dan recall dapat dipertimbangkan.

## 2.9 Recall

Recall (3) adalah mengukur proporsi positif aktual yang diprediksi dengan benar, atau seberapa akurat model memprediksi kasus positif. Peningkatan presisi akan mengurangi recall. Ini disebut kompromi presisi recall. Pilihan antara presisi dan recall bergantung pada aplikasi spesifik. Misalnya, jika suatu model dibangun untuk mendeteksi penipuan, model tersebut memprioritaskan presisi karena tidak perlu menandai terlalu banyak transaksi yang sah sebagai penipuan. Jika suatu model

dibangun untuk mendiagnosis suatu penyakit, recall lebih disukai, karena penting untuk mendeteksi kemungkinan penyakit tersebut [40].

$$Recall = \frac{TP}{(TP+FN)} \dots\dots\dots(3)$$

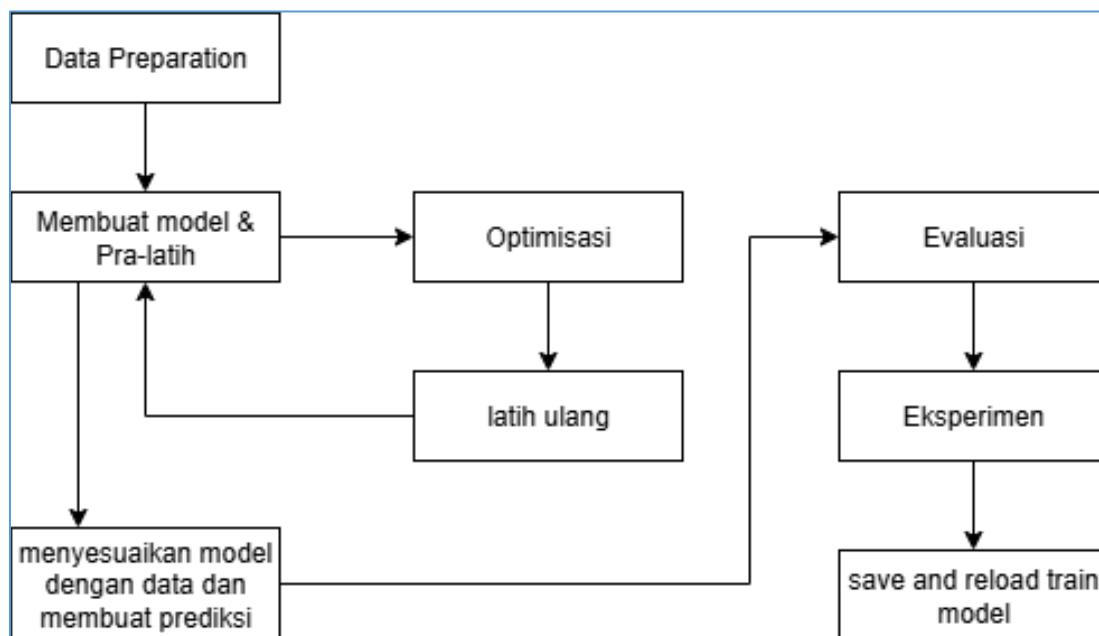
**2.10 F1- Score**

F1 – Score (4), mengkombinasikan Precision dan Recall, penting untuk model yang mana keduanya sama pentingnya. ini adalah rata – rata harmoni pada precision dan recall yang dilihat keduanya False negatif dan False Positif. Rata – rata harmonic di komputasikan dan dibagi dengan sejumlah nilai dalam data series dengan menjumlahkan membalikan nilai dalam deret data. Rata – rata harmonik selalu lebih kecil atau sama dengan rata – rata aritmatika dan rata – rata geometrik karena rata – rata harmonik memberikan bobot untuk nilai yang lebih kecil dalam deret data. Ketika precision dan recall sama. Rata- rata harmonik dirata – rata kan mendekati nilai terkecil [40].

$$F1 – SCORE = \frac{(2 \times Presisi \times Recall)}{(Presisi + Recall)} \dots\dots\dots(4)$$

**3. Metode Penelitian**

Pada Gambar 3 dibuatlah serangkaian tahapan – tahapan penelitian guna untuk mempermudah peneliti untuk melaksanakan penelitian. adapun tahap – tahap penelitian yaitu dimulai dengan persiapan data. setelah data disiapkan kemudian lanjut ketahap berikutnya yaitu membangun model Xception dan pra-latih pemodelan tanpa augmentasi data, pada tahap ini peneliti juga melakukan optimasi dan pelatihan sehingga memperoleh pemodelan yang baik. kemudian tahap berikutnya yaitu penyesuaian model terhadap data dan membangun prediksi. Tahap berikutnya ialah melakukan Evaluasi dengan menggunakan *confusion matrix*. kemudian peneliti melakukan eksplorasi teknik augmentasi data. Langkah terakhir adalah menyimpan dan menggunakan kembali pemodelan.



**Gambar 3 Metode penelitian**

**Persiapan Data** dalam penelitian ini peneliti menggunakan datasets trashnet yang terdiri 2577 file dengan format jpg. Yang terdiri dari 6 kelas yaitu Cardboard, Glass, Metal, Paper, Plastic dan Trash. Data dibagi menjadi dua yaitu 80% data train dan 20% data test. Dimana total data train menjadi 2062 sementara data test terdiri dari 515 file.

**Membangun Model & Pra-latih** Peneliti akan melakukan ujicoba dan Optimasi beberapa ukuran batch size dimulai ukuran 4,8,16,32. Batch size itu sendiri merupakan banyak gambar yang akan di proses dalam pra latih, besar atau kecilnya batchsize sangat berpengaruh terhadap model yang dibangun.setelah dilakukan pengujian beberapa batchsize dan dilakukan dengan optimasi maka diperoleh hasil terbaik pemodelan. Hyperparameter terbaik pada batchsize 32 Best Param Convfilters = 64, Learning rate = 0.0001, dropout = 0.25.

**Menyesuaikan pemodelan terhadap data dan membuat prediksi** pada tahap ini peneliti menyesuaikan pemodelan yang telah dilakukan optimasi dan menerapkannya kedalam pemodelan. Hyperparameter yang diterapkan yaitu dengan batchsize 32, parameter Convfilters=64, Optimizer = Adam(lr = 0.0001),dropout = 0.25.pemodelan akan kembali dilatih dengan menggunakan 100 epoch tanpa menggunakan data augmentasi. Berdasarkan hasil pra latih ini diperoleh pemodelan terbaik yaitu terdapat pada epoch 47 dengan akurasi = 99% , loss = 0.67%, validasi akurasi = 87%, dan validasi loss = 52%.

**Evaluasi** pada tahapan ini pemodelan diuji kembali dengan menggunakan *Confusion Matrix*, dan pengujian Accuracy, Precision , Recall, dan F1-Score. Pengujian ini dilakukan tanpa menggunakan augmentasi data. Hasil yang diperoleh berdasarkan *Confusion Matrix* seperti yang ditunjukkan pada Tabel 3 berikut.

**Tabel 3 Prediksi kebenaran dan kesalahan**

Kelas	True	False
Cardboard	78	1
Glass	79	19
Metal	44	43
Paper	104	23
Plastik	70	24
Trash	20	9

Berdasarkan pengujian menggunakan confusion matrik maka diperoleh hasil yaitu akurasi 76% pada precision 79%, recall 75% dan F1-Score 75%. Berdasarkan hasil yang diperoleh kemampuan klasifikasi ini cukup baik. Dengan demikian , performa ini dapat dijadikan landasan untuk penyempurnaan model pada tahap berikutnya.

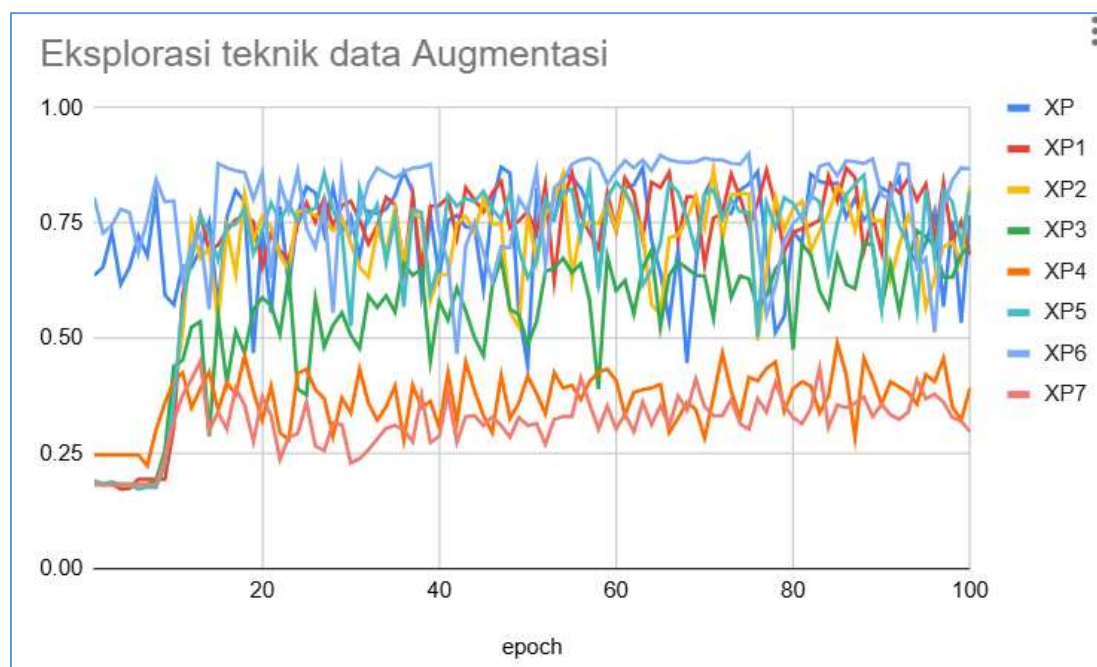
Eksperiment pada tahap ini peneliti akan menggunakan berbagai teknik augmentasi data.tujuan dari eksperiment ini adalah untuk meningkatkan performa model agar memiliki kemampuan yang lebih baik.berikut adalah kombinasi teknik yang digunakan yang ditunjukkan pada Tabel 4 berikut.

**Tabel 4 Eksperimen metode data augmentasi**

Eksperimen	Metode
1	Translate, Flip, Brightness
2	Crop, Flip
3	Flip,Crop, Translate
4	Mixup
5	Flip
6	Scale, Translate, Color Space
7	Crop, Resize, Flip, Color Space, Distortion

#### 4. Hasil Penelitian

Berdasarkan hasil penelitian bahwa pemodelan yang digunakan ialah pemodelan Xception kemudian pemodelan dilakukan Optimasi. Hasil dari Optimasi yang dipilih menggunakan batch\_size dengan ukuran 32, dengan parameter sebagai berikut ConvFilters = 64, Learning\_rate = 0.0001, dropout = 0.25.Setelah diperoleh parameter yang dioptimasi kemudian peneliti melakukan eksplorasi data augmentasi. Berikut adalah gambar graphic yang dihasilkan pada setiap eksperimen yang dilakukan.



**Gambar 4 Hasil validasi akurasi eksplorasi data augmentasi**

Pada Gambar 4 ini dapat dilihat bahwa tidak semua hasil dari Teknik augmentasi yang memberikan pengaruh yang signifikan dan memberikan Tingkat validasi akurasi yang lebih baik dari yang tanpa menggunakan Teknik augmentasi. Bahkan ada hasil yang dibawah dari pemodelan tanpa data augmentasi kurang baik dibanding menggunakan data augmentasi.

**Tabel 5 Hasil training dan evaluasi**

No	Training				Evaluasi			
	Acc	Loss	Val_Acc	Loss Val	Acc	Precision	Recall	F1-Score
0	99%	0.7%	87%	52%	76%	79%	75%	75%
1	97%	7%	86%	52%	69%	79%	64%	67%
2	99%	2%	86%	49%	83%	85%	81%	82%
3	51%	152%	73%	109%	70%	78%	66%	68%
4	22%	172%	48%	160%	39%	52%	32%	30%
5	91%	25%	85%	55%	81%	85%	77%	80%
6	99%	0.12%	90%	48%	86%	88%	83%	84%
7	56%	112%	45%	158%	29%	38%	21%	16%

Dapat kita lihat hasil dari Tabel 5 di atas bahwa hasil terbaik terdapat pada eksperimen ke 6. Pada eksperimen ini peneliti menggunakan Teknik yaitu Scale, Translate dan Color Space. dapat kita lihat pada grafik bahwa Teknik augmentasi ini cukup bisa menjaga Tingkat validasi akurasi. Pada eksperimen ke 6 diperoleh hasil Training akurasi 99%, Loss 0.12%, 90% Validasi, Loss Vall 48%. Kemudian pada tahap evaluasi, dimana pada penelitian ini peneliti menggunakan Confussion Matrix, Akurasi, Precision, Recall, dan F1-Score maka diperoleh hasil akurasi 86%, Precision 88%, Recall 83%, F1-Score 84%. penggunaan teknik ini terjadi peningkatan terhadap Akurasi 13%, Precision 11%, Recall 13% dan F1-Score 12%.

#### 4. Kesimpulan

Penerapan Artificial Intelligence telah banyak dikembangkan oleh peneliti untuk membangun manajemen pengelolaan sampah, di bidang analisis kimia seperti WtE (Waste To Energy) yaitu Pengelolaan sampah menjadi Energy Terbarukan, Pirolisis Pengelolaan Limbah Plastik Menjadi Bahan Bakar dan Gassifikasi, dibidang Logistik misal pengangkutan sampah dengan pemanfaatan

teknologi IoT (*Internet Of Things*). memberikan Alarm kepada Pengangkutan sampah jika tempat pembuangan sampah sudah penuh. Pemanfaatan (AI) Pencarian Jarak Terdekat dsb, selain itu juga Mengidentifikasi Tempat Pembuangan sampah Ilegal menggunakan Citra Satelit. Aplikasi perkotaan seperti pemanfaatan robotik dalam pengelolaan sampah, Tong Sampah Cerdas yang mampu mengklasifikasi sampah, dan analisis timbulan sampah dengan pemanfaatan machine learning. Dalam penelitian ini peneliti melakukan penelitian eksperimen dengan menggunakan CNN dengan Arsitektur Xception terhadap datasets TrashNet, Melakukan Optimasi untuk mencari Hyperparameter terbaik untuk pengklasifikasian sampah. Dan melakukan Eksplorasi data augmentasi yang sesuai untuk model dan datasets TrashNet. Hasil pada penelitian ini adalah melakukan optimasi xception model terhadap datasets *TrashNet*. Hasil Optimasi yang diperoleh dengan menggunakan Batchsize 32, menggunakan Adam (Adaptive Moment Estimation) dengan Learning Rate = 0.0001, dropout 0.25 memperoleh tingkat akurasi yang baik yaitu akurasi 99%, loss 0.7%, validasi akurasi 87% validasi loss 52%. Dan hasil pada evaluasi diperoleh hasil sebagai berikut Akurasi 76%, Precision 79%, Recall 75%, F1-Score 75%. Eksplorasi Data Augmentasi dengan memanfaatkan metode scale, translate dan color space. penggunaan teknik ini terjadi peningkatan terhadap Akurasi 13% , Precision 11%, Recall 13% dan F1-Score 12%. Kontribusi dalam penelitian ini yaitu mengimplementasikan Xception model terhadap datasets TrashNet untuk klasifikasi sampah. Dan mengusulkan beberapa metode data augmentasi yang menawarkan bukti empiris untuk menerima atau menolak teori. memberikan Solusi untuk pengembangan *Smart Waste Management*. Melakukan eksperimen yang memperkaya literatur dengan hasil yang baru. Serta membandingkan berbagai metode data augmentasi yang sesuai dengan datasets TrashNet. Rekomendasi diharapkan pengembangan berikutnya bisa mengimplementasikan model ke IoT / Pengembangan *Smart Waste Bin* yang merupakan kecerdasan buatan yang bisa berinteraksi langsung terhadap lingkungan realitas nyata yang tidak hanya bisa berinteraksi didalam komputer saja. Melakukan eksplorasi dengan model lainnya, menggunakan *hybrid method*, *transfer learning*, atau mencari teknik augmentasi menggunakan T-Sne. Memperkaya datasets hingga jutaan agar bisa di menggunakan transfer learning yang dilatih khusus dengan data sampah.

## Ucapan Terima Kasih

Saya mengucapkan terimakasih yang sebesar-besarnya kepada semua pihak yang telah memberikan dukungan dalam penyusunan jurnal ini. Secara khusus saya menyampaikan apresiasi kepada Dosen Pembimbing yaitu Dr. Syafri Arlis , S.Kom, M.Kom, yang telah memberikan arahan, motivasi dan bimbingannya dalam proses penelitian. serta kepada rekan – rekan sejawat, yang telah menjadi teman diskusi dan memberikan masukan yang konstruktif. Serta keluarga dan sahabat , atas do'a dan dukungannya. Semoga penelitian ini dapat memberikan kontribusi yang bermanfaat bagi pengembangan ilmu pengetahuan, khususnya di bidang Computer Vision dan Kecerdasan Buatan.

## Referensi

- [1] KLHK, "Sistem Informasi Pengelolaan Sampah Nasional (SIPSN)," Kementrian Lingkungan Hidup dan Kehutanan.
- [2] W. C. Purnomo, Solusi Pengelolaan Sampah Kota. Yogyakarta: Gadjadara University Press, 2023.
- [3] 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.
- [4] D. Pang *et al.*, "A Mini Review on AI-Driven Thermal Treatment of Solid Waste: Emission Control and Process Optimization," Jun. 01, 2025, Elsevier B.V. DOI: 10.1016/j.gerr.2025.100132.
- [5] J. Zhou, J. Liu, J. Ren, and C. He, "A Comprehensive Study of Machine Learning for Waste-to-Energy Process Modeling and Optimization," *Processes*, Vol. 13, No. 9, p. 2691, Aug. 2025, DOI: 10.3390/pr13092691.
- [6] P. Lisboa, S. Pascual, and V. Pérez, "Waste to Energy: Trends and Perspectives," *Chemical Engineering Journal Advances*, Vol. 14, May 2023, DOI: 10.1016/j.ceja.2023.100494.

- [7] M. Sharma Timilsina, Y. Chaudhary, P. Bhattarai, B. Uprety, and D. Khatiwada, "Optimizing Pyrolysis and Co-Pyrolysis of Plastic and Biomass using Artificial Intelligence," *Energy Conversion and Management: X*, Vol. 24, Oct. 2024, DOI: 10.1016/j.ecmx.2024.100783.
- [8] D. A. Akinpelu, O. A. Adekoya, P. O. Oladoye, C. C. Ogbaga, and J. A. Okolie, "Machine Learning Applications in Biomass Pyrolysis: From Biorefinery to End-of-Life Product Management," Sep. 01, 2023, Elsevier Ltd. DOI: 10.1016/j.dche.2023.100103.
- [9] E. R. Belden et al., "Machine Learning Predictions of Oil Yields Obtained by Plastic Pyrolysis and Application to Thermodynamic Analysis," *ACS Engineering Au*, Vol. 3, No. 2, pp. 91–101, Apr. 2023, DOI: 10.1021/acsengineeringau.2c00038.
- [10] Y. Ma, P. He, F. Lü, and H. Zhang, "Improving the Method for Calculating Carbon Emissions from Waste Incineration: Confirmed with Carbon-14 Testing of Flue Gas," *Carbon Research*, vol. 3, No. 1, Nov. 2024, DOI: 10.1007/s44246-024-00162-9.
- [11] K. Mizohata, K. Helariutta, J. Kauppinen, M. Lappalainen, T. Pellikka, and M. Oinonen, "Accelerator Mass Spectrometry for Tracing Fossil Carbon Content of Combusted Fuel," *Applied Radiation and Isotopes*, Vol. 225, Nov. 2025, DOI: 10.1016/j.apradiso.2025.111996.
- [12] Y. Kwon, K. Choi, and Y. C. Jang, "Greenhouse Gas Emissions from Incineration of Municipal Solid Waste in Seoul, South Korea," *Energies (Basel)*, Vol. 16, No. 12, Jun. 2023, DOI: 10.3390/en16124791.
- [13] H. Jerbi, V. G. A. Gnana Vincy, S. Ben Aoun, R. Abbassi, and M. Kchaou, "Optimizing Waste Management in Smart Cities: An IoT-based Approach using Dynamic Bald Eagle Search Optimization Algorithm (DBESO) and Machine Learning," *Journal of Urban Management*, 2025, DOI: 10.1016/j.jum.2025.05.015.
- [14] H. Fakhouri, A. Hudaib, F. Hamad, S. Fakhouri, N. Halalsheh, and M. S. Alkhalailah, "Vehicle Route Optimizer for Waste Collection and Routing Optimization Problem," *Intelligent Systems with Applications*, Vol. 27, Sep. 2025, DOI: 10.1016/j.iswa.2025.200521.
- [15] J. Cui, Y. Yan, L. Jiang, L. Zhang, and W. Xu, "Research on Optimization of Waste Sorting and Transportation Network in Smart Cities based on Garbage Volume Prediction," *Discover Computing*, Vol. 28, No. 1, Dec. 2025, DOI: 10.1007/s10791-025-09537-x.
- [16] X. Sun et al., "Revealing Influencing Factors on Global Waste Distribution Via Deep-Learning based Dumpsite Detection from Satellite Imagery," *Nat Commun*, Vol. 14, No. 1, Dec. 2023, DOI: 10.1038/s41467-023-37136-1.
- [17] A. D. Sakti et al., "Identification of Illegally Dumped Plastic Waste in a Highly Polluted River in Indonesia using Sentinel-2 Satellite Imagery," *SCI Rep*, Vol. 13, No. 1, Dec. 2023, DOI: 10.1038/s41598-023-32087-5.
- [18] R. N. Torres and P. Fraternali, "AerialWaste Dataset for Landfill Discovery in Aerial and Satellite Images," *SCI Data*, Vol. 10, No. 1, Dec. 2023, DOI: 10.1038/s41597-023-01976-9.
- [19] J.-S. Lee and D.-C. Shin, "Prediction of Waste Generation using Machine Learning: A Regional Study in Korea," *Urban Science*, Vol. 9, No. 8, p. 297, Jul. 2025, DOI: 10.3390/urbansci9080297.
- [20] S. Alam, M. Rokonzaman, K. S. Rahman, and W. S. Tan, "A Comparative Analysis of Forecasting Algorithms for Predicting Municipal Solid Waste Generation in Chittagong City," *International Journal of Environmental Science and Technology*, 2025, DOI: 10.1007/s13762-025-06488-0.
- [21] R. Awad, C. Budayan, and A. P. Gurgun, "Construction and Demolition Waste Generation Prediction by using Artificial Neural Networks and Metaheuristic Algorithms," *Buildings*, Vol. 14, No. 11, Nov. 2024, DOI: 10.3390/buildings14113695.
- [22] T. Cheng, D. Kojima, H. Hu, H. Onoda, and A. H. Pandyaswargo, "Optimizing Waste Sorting for Sustainability: An AI-Powered Robotic Solution for Beverage Container Recycling," *Sustainability (Switzerland)*, Vol. 16, No. 23, Dec. 2024, DOI: 10.3390/su162310155.
- [23] Y. Goorun, S. Marais, and F. Nicolls, "Robotic Waste Sorting using Deep Learning," *MATEC Web of Conferences*, Vol. 406, p. 10003, 2024, Doi: 10.1051/mateconf/202440610003.
- [24] A. M. Vukicevic et al., "Versatile Waste Sorting in Small Batch and Flexible Manufacturing Industries using Deep Learning Techniques," *SCI Rep*, Vol. 15, No. 1, Dec. 2025, DOI: 10.1038/s41598-025-87226-x.

- [25] H. T. N. Le and H. Q. T. Ngo, "Application of the Vision-based Deep Learning Technique for Waste Classification using the Robotic Manipulation System," *International Journal of Cognitive Computing in Engineering*, Vol. 6, pp. 391–400, Dec. 2025, DOI: 10.1016/j.ijcce.2025.02.005.
- [26] A. Pollak, A. Gupta, and D. Gohlich, "Optimized Operation Management with Predicted Filling Levels of the Litter Bins for a Fleet of Autonomous Urban Service Robots," *IEEE Access*, Vol. 12, pp. 7689–7703, 2024, DOI: 10.1109/ACCESS.2024.3352436.
- [27] M. P. Arthur, S. Shoba, and A. Pandey, "A Survey of Smart Dustbin Systems using the IoT and Deep Learning," *Artif Intell Rev*, Vol. 57, No. 3, Mar. 2024, DOI: 10.1007/s10462-023-10646-6.
- [28] H. Husnawati, A. B. J. Malyan, R. R. Putra, and S. Agustri, "Smart Trash Box Technology of Computer Vision to Support Ecogreen Campus," 2024, pp. 220–229. DOI: 10.2991/978-94-6463-386-3\_25.
- [29] A. Ishaq, S. J. Mohammad, A.-A. D. Bello, S. A. Wada, A. Adebayo, and Z. T. Jagun, "Smart Waste Bin Monitoring using IoT for Sustainable Biomedical Waste Management," *Environmental Science and Pollution Research*, Oct. 2023, DOI: 10.1007/s11356-023-30240-1.
- [30] A. Pandey, R. Raja, M. Gupta, F. A. Alenizi, P. Suanpang, and A. Nanthaamornphong, "Deep Learning Enabled Garbage Classification and Detection by Visual Context for Aerial Images," *Applied Computational Intelligence and Soft Computing*, Vol. 2025, No. 1, 2025, DOI: 10.1155/acis/9106130.
- [31] M. Chhabra, B. Sharan, M. Elbarachi, and M. Kumar, "Intelligent Waste Classification Approach based on Improved Multi-Layered Convolutional Neural Network," *Multimed Tools Appl*, Vol. 83, No. 36, pp. 84095–84120, Nov. 2024, DOI: 10.1007/s11042-024-18939-w.
- [32] M. M. Abo-Zahhad and M. Abo-Zahhad, "Real Time Intelligent Garbage Monitoring and Efficient Collection using Yolov8 and Yolov5 Deep Learning Models for Environmental Sustainability," *SCI Rep*, Vol. 15, No. 1, Dec. 2025, DOI: 10.1038/s41598-025-99885-x.
- [33] D. Zheng, R. Wang, Y. Duan, P. C. I. Pang, and T. Tan, "Focus-RCNet: A Lightweight Recyclable Waste Classification Algorithm based on Focus and Knowledge Distillation," *Vis Comput Ind Biomed Art*, Vol. 6, No. 1, Dec. 2023, DOI: 10.1186/s42492-023-00146-3.
- [34] Z. Lun, Y. Pan, S. Wang, Z. Abbas, M. S. Islam, and S. Yin, "Skip-YOLO: Domestic Garbage Detection using Deep Learning Method in Complex Multi-Scenes," *International Journal of Computational Intelligence Systems*, Vol. 16, No. 1, Dec. 2023, DOI: 10.1007/s44196-023-00314-6.
- [35] M. H. Moktar, H. Mohamed, S. S. H. Hajjaj, and M. Z. Baharuddin, "Medical Waste Sorting Machine Development with IoT and YOLO Model Utilization," *Journal of Engineering and Applied Science*, Vol. 72, No. 1, Dec. 2025, DOI: 10.1186/s44147-025-00661-5.
- [36] A. Ettalibi, A. Elouadi, and A. Mansour, "AI and Computer Vision-based Real-Time Quality Control: A Review of Industrial Applications," in *Procedia Computer Science*, Elsevier B.V., 2024, pp. 212–220. DOI: 10.1016/j.procs.2023.12.195.
- [37] 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.
- [38] F. Chollet, "Xception: Deep Learning with Depthwise Separable Convolutions."
- [39] 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.
- [40] S. Sathyanarayanan, "Confusion Matrix-based Performance Evaluation Metrics," *African Journal of Biomedical Research*, pp. 4023–4031, Nov. 2024, DOI: 10.53555/ajbr.v27i4s.4345.