

Implementasi *Data Augmentation* untuk Klasifikasi Sampah Organik dan Non Organik Menggunakan Inception-V3

Mochamad Rahina Bintang Pambayun ^{(1)*}, Yufis Azhar ⁽²⁾

Informatika, Fakultas Teknik, Universitas Muhammadiyah Malang, Malang, Indonesia
e-mail : rahinabintang@gmail.com, yufis@umm.ac.id.

* Penulis korespondensi.

Artikel ini diajukan 25 Maret 2024, direvisi 28 Juni 2024, diterima 22 Juli 2024, dan dipublikasikan 25 September 2024.

Abstract

The surge in global waste, particularly in Indonesia, with a total of 36.218 million tons per year, has become an urgent issue. Challenges in waste management are increasingly complex due to the lack of public understanding and awareness in classifying types of waste. One systemic approach to address waste classification issues involves the use of machine learning technology to categorize waste into two main types: organic and non-organic. The data used in this study comes from a Kaggle website dataset comprising 25,500 entries. This research employs a transfer learning approach with the Inception-V3 architecture and data augmentation implementation. Transfer learning is chosen for its proven performance in image data classification, while data augmentation is implemented to introduce diversity to the dataset. The research stages include business understanding, data preprocessing, data augmentation, data modelling, and evaluation. The results show that the use of transfer learning with the Inception-V3 approach and data augmentation implementation achieves an accuracy rate of 94%, which falls into the excellent category.

Keywords: *Classification, Transfer Learning, Convolutional Neural Network, Inception-V3, Garbage*

Abstrak

Lonjakan jumlah sampah global, terutama di Indonesia dengan total 36,218 juta ton per tahun, menjadi permasalahan mendesak. Tantangan dalam manajemen sampah semakin kompleks akibat minimnya pemahaman dan kesadaran masyarakat dalam pengelompokan jenis sampah. Salah satu pendekatan sistem yang dapat diimplementasikan untuk mengatasi permasalahan pengelompokan sampah adalah menggunakan teknologi *machine learning* untuk mengklasifikasikan sampah menjadi 2 kategori utama, yaitu organik dan non-organik. Data yang digunakan dalam penelitian ini adalah *dataset* sampah yang berasal dari *website* Kaggle dengan jumlah data sebanyak 25.500 data. Penelitian ini menggunakan pendekatan *transfer learning* dengan arsitektur Inception-V3 dan implementasi *data augmentation*. Pendekatan *transfer learning* dipilih karena performanya yang terbukti sangat baik dalam klasifikasi data citra, sedangkan *data augmentation* diimplementasikan untuk menambah variasi atau keragaman data. Tahapan penelitian ini meliputi pemahaman bisnis, *preprocessing* data, augmentasi data, *modelling* data, dan evaluasi. Hasil dari penelitian menunjukkan bahwa penggunaan pendekatan *transfer learning* Inception-V3 dan implementasi *data augmentation* menghasilkan tingkat akurasi sebesar 94% yang termasuk dalam kategori yang sangat baik.

Kata Kunci: *Klasifikasi, Transfer Pembelajaran, Jaringan Saraf Konvolusional, Inception-V3, Sampah*

1. PENDAHULUAN

Peningkatan jumlah sampah dari tahun ke tahun menandai sebuah isu global yang mendesak. Fenomena ini melibatkan pertumbuhan yang cepat dari limbah yang dihasilkan oleh aktivitas manusia yang tentu menciptakan tantangan signifikan dalam manajemen sampah di seluruh dunia (Lebreton & Andrady, 2019). Menurut Sistem Informasi Penanggulangan Sampah Nasional (SIPSN) tahun 2022, total sampah di Indonesia mencapai 36,218 juta ton per tahun, dengan penurunan 14,88% dari tahun sebelumnya. Namun, hanya 64,01% atau sekitar 23,18 juta ton



yang dapat dikelola secara efektif (Kementerian Lingkungan Hidup dan Kehutanan, 2022). Situasi ini mengindikasikan perlu adanya pendekatan yang lebih komprehensif untuk mengatasi permasalahan sampah di Indonesia. Ada dua jenis sampah, sampah non organik dan sampah organik, tergantung dari sifatnya. Sampah organik berasal dari sisa makhluk hidup seperti hewan, manusia, dan tumbuhan yang mengalami pembusukan atau pelapukan. Jenis sampah ini bersifat ramah lingkungan karena dapat diuraikan oleh bakteri dalam waktu yang lama dan berlangsung dengan cepat. Sementara itu, sampah non-organik (anorganik) berasal dari sisa manusia yang sulit diurai oleh bakteri dan membutuhkan waktu yang cukup lama bahkan hingga ratusan tahun untuk mengalami dekomposisi (Fadillah et al., 2019).

Saat ini, di lingkungan sekitar kita sering ditemukan kondisi sampah yang cenderung tercampur dan tidak terpisah (Widodo & Suleman, 2020). Permasalahan ini muncul karena kurangnya pemahaman dan kesadaran masyarakat dalam mengelola pembuangan sampah sesuai dengan jenisnya. Pengelolaan yang optimal, terutama dalam mengelompokkan sampah menjadi kategori organik dan non organik, menjadi hal yang penting untuk mencegah timbulnya bau yang tidak menyenangkan dan potensi penyebaran penyakit (Rosiana & Perdana, 2022). Adanya implementasi suatu sistem deteksi jenis sampah secara otomatis menjadi salah satu solusi untuk mengatasi masalah pengelompokkan sampah di Indonesia. Dengan adanya sistem ini, diharapkan dapat memfasilitasi pengelolaan sampah yang lebih efisien, khususnya untuk proses daur ulang dan pemanfaatan kembali.

Salah satu pendekatan sistem yang dapat diimplementasikan untuk mengatasi permasalahan terkait pengelompokan sampah adalah dengan memanfaatkan teknologi *machine learning*. Dengan menggunakan teknologi ini, kita dapat mengklasifikasikan sampah menjadi dua kategori utama, yaitu organik dan non-organik, dengan tingkat akurasi yang tinggi (Kartiko et al., 2022). Pendekatan ini berpotensi memberikan kontribusi yang signifikan terhadap pengelolaan sampah yang berkelanjutan dan efektif. Sebelumnya, Abdurrahman dan rekan-rekannya telah melakukan penelitian dengan mengaplikasikan Convolutional Neural Network (CNN), salah satu arsitektur *Deep Learning*, untuk mengklasifikasikan sampah organik dan non-organik. Meskipun hasil penelitian tersebut mencapai tingkat akurasi sebesar 89,65%, dari eksperimen yang telah dilakukan mengungkapkan kelemahan model dalam menggeneralisasi sampah non-organik. Hal ini dapat disebabkan oleh ketidakseimbangan kelas dan kurangnya data sampah non-organik pada *dataset* yang digunakan (Ibnul Rasidi et al., 2022). Untuk mengatasi kendala tersebut, penelitian ini akan melibatkan implementasi *data augmentation* dan pendekatan *transfer learning* menggunakan arsitektur model Inception-V3. Pemilihan model Inception-V3 didasarkan pada kemampuannya dalam menangani kompleksitas visual dan kemampuan generalisasi yang lebih baik.

Pendekatan *transfer learning* memungkinkan kita untuk memanfaatkan pengetahuan yang telah diperoleh oleh suatu model dalam menangani tugas tertentu dan mengaplikasikannya pada tugas terkait (Wang et al., 2019). Pemilihan arsitektur Inception-V3 sebagai model *pre-trained* dalam penelitian ini memberikan keuntungan dibanding model CNN karena kemampuannya yang sudah teruji dalam menangani tugas klasifikasi gambar yang kompleks (Minarno, Aripa, et al., 2023). Penelitian sebelumnya tentang *Image Retrieval* yang dilakukan oleh Agus Eko Minarno dan rekan-rekannya juga menunjukkan bahwa Inception-V3 memiliki performa yang sangat baik dalam menangani gambar yang kompleks (Minarno, Hasanuddin, et al., 2023). Model *pre-trained* Inception-V3 tidak hanya dapat mengenali pola dan fitur kompleks dalam data visual, tetapi juga telah dilatih pada *dataset* yang luas dan beragam, mencakup berbagai kategori gambar (Ahmed et al., 2023). Dengan mentransfer pengetahuan ini ke tugas klasifikasi sampah, diharapkan model dapat dengan cepat dan akurat mengidentifikasi perbedaan antara sampah organik dan non-organik.

Selain *transfer learning*, implementasi *data augmentation* turut diterapkan untuk meningkatkan keberagaman dan jumlah sampel dalam *dataset* pelatihan (Lin et al., 2018). Peningkatan variasi ini diharapkan dapat membantu model untuk mengatasi ketidakseimbangan kelas pada *dataset*



yang digunakan pada penelitian sebelumnya, serta membuat model dapat lebih adaptif terhadap variasi yang mungkin ditemui di lingkungan dunia nyata.

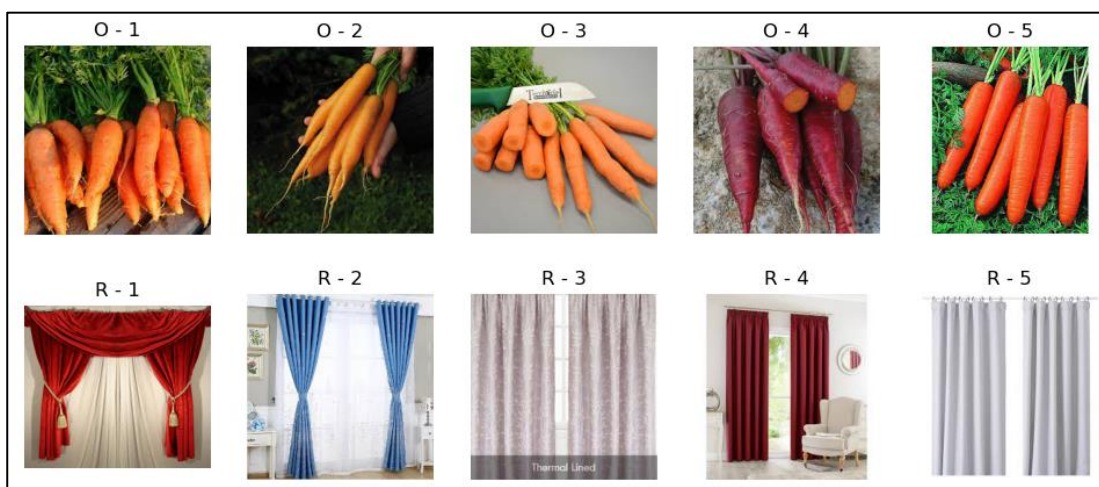
Penelitian ini berupaya untuk mengatasi kelemahan dalam penelitian sebelumnya yang dilakukan oleh Abdurrahman dan rekan-rekannya, yang mungkin mengalami masalah dengan ketidakseimbangan kelas dan generalisasi model (Ibnul Rasidi et al., 2022). Dengan memperkenalkan kombinasi *transfer learning* dan *data augmentation*, diharapkan model yang dihasilkan akan memiliki akurasi dan kemampuan generalisasi yang lebih tinggi, serta mampu mengklasifikasikan sampah organik dan non-organik dengan lebih efektif. Selain itu, penelitian ini juga memberikan kontribusi dalam bidang pengelolaan sampah dengan menyediakan solusi teknologi yang lebih canggih untuk pengelompokan sampah, yang pada gilirannya dapat membantu dalam upaya pengelolaan lingkungan yang lebih baik dan berkelanjutan.

2. METODE PENELITIAN

Penelitian ini mengadopsi pendekatan metodologi CRISP-DM (*Cross Industry Standard Process for Data Mining*). CRISP-DM adalah suatu kerangka kerja (*framework*) yang dikenal secara luas dalam dunia *data mining*. *Framework* ini dirancang untuk memberikan struktur yang terorganisir dalam mengatasi tahapan-tahapan utama dalam proses penambangan data. Tahapan penelitian ini mencakup serangkaian langkah yang sistematis, dimulai dari pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi, hingga penerapan (Hidayati et al., 2021). Dengan menerapkan metodologi CRISP-DM, penelitian ini dapat menjalankan proses penelitian dengan pendekatan yang terstruktur dan terorganisir. Selain itu, penerapan metodologi ini dapat memastikan bahwa setiap tahapan dijalankan secara efisien dan memberikan kontribusi yang signifikan terhadap pemahaman dan solusi terhadap permasalahan klasifikasi sampah organik dan non-organik.

2.1 Dataset

Dataset yang digunakan dalam penelitian ini sama dengan yang digunakan pada penelitian sebelumnya oleh Abdurrahman dan rekan-rekannya (Ibnul Rasidi et al., 2022). *Dataset* ini terdiri dari citra dalam format .jpg yang diperoleh dari *website* Kaggle dengan judul *dataset* "Waste Classification data" (Sekar, 2019). Jumlah total citra yang terkumpul mencapai 25.077 *instance*, yang telah dibagi menjadi dua bagian. Bagian pertama adalah data pelatihan (*train*), yang terdiri dari 12.565 citra untuk kelas organik dan 9.999 citra untuk kelas non-organik (*recycle*), sehingga total citra pada data pelatihan mencapai 22.564 (90%) dari keseluruhan *dataset*. Sementara itu, data pengujian (*test*) terdiri dari 1.401 citra untuk kelas organik dan 1.112 citra untuk kelas non-organik, dengan total 2.513 citra (10%) dari keseluruhan *dataset*.



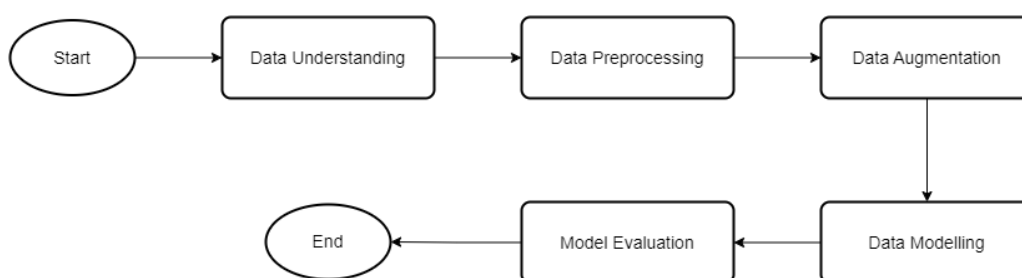
Gambar 1 Sampel Data



Untuk mempersingkat proses pelatihan dan mengimbangkan data antara kedua kelas (organik dan non-organik), diputuskan untuk menggunakan sampel dari masing-masing kelas sebanyak 5.000 data citra. Sampel ini diambil dengan tetap mempertahankan representasi proporsional dari data asli. Dengan demikian, total data yang akan digunakan dalam penelitian ini adalah 10.000 citra untuk pelatihan dan 2.513 citra untuk pengujian, yang menghasilkan total citra sebanyak 12.513. Gambar 1 berikut merupakan sampel dari *dataset* yang telah didapatkan. Label 'O' mewakili kelas Organik dan label 'R' mewakili kelas Recycle atau Non Organik.

2.2 Tahapan Penelitian

Tahapan penelitian ini berdasar pada metodologi CRISP-DM, di mana Langkah-langkah yang dilakukan di antaranya adalah mempelajari *dataset*, melakukan serangkaian *preprocessing* seperti *data cleaning*, *resizing* dan *normalization*, hingga menerapkan augmentasi untuk memperbanyak variasi data. Gambar 2 berikut merupakan tahapan yang dilakukan dalam pembuatan model klasifikasi sampah.




Gambar 2 Tahapan Penelitian

2.2.1 Business Understanding

Business understanding adalah tahap awal dalam metodologi CRISP-DM (*Cross Industry Standard Process for Data Mining*) yang bertujuan untuk memahami secara mendalam tantangan bisnis yang dihadapi. Pada tahap ini, fokusnya adalah merumuskan pertanyaan-pertanyaan yang relevan agar dapat diterjemahkan ke dalam tugas analisis data. Dengan pemahaman yang jelas tentang tujuan bisnis dan masalah yang ingin dipecahkan, tim data dapat memastikan bahwa pendekatan analisis data yang dilakukan selaras dengan kebutuhan bisnis (Schröer et al., 2021).

2.2.2 Data Preprocessing



Gambar 3 Beberapa Sampel Data yang Tidak Relevan

Pra-pemrosesan data memiliki peran yang sangat penting dalam pengembangan model *machine learning* dan membutuhkan perhatian yang seksama. Tujuan utama dari proses ini adalah untuk membersihkan, mengatur, dan menyelaraskan data agar sesuai dengan kebutuhan model yang sedang dikembangkan. Dalam tahap ini, terdapat tiga langkah penting yang umumnya diterapkan: pembersihan data (*data cleaning*), penyesuaian ukuran (*resizing*), dan normalisasi (*normalization*). Pembersihan data dilakukan untuk memastikan bahwa data pelatihan valid, konsisten, dan siap untuk diproses lebih lanjut. Selama proses ini dilakukan, ditemukan berbagai ketidaksesuaian data gambar, seperti ambiguitas antara label organik dan non-organik, kasus

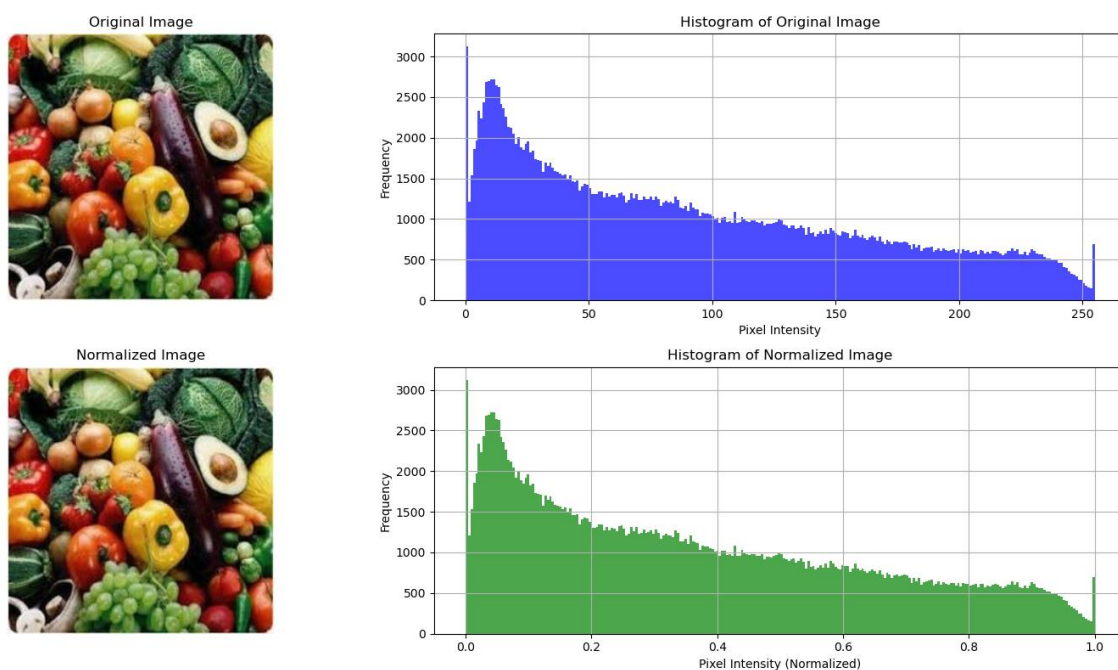


data yang salah label (di mana data organik disalah label sebagai non-organik, dan sebaliknya), hingga adanya data yang tidak relevan seperti terlihat pada Gambar 3. Penanganan masalah-masalah ini sangat penting untuk memastikan integritas dan akurasi hasil pelatihan model.

Langkah selanjutnya adalah *resizing*, di mana dimensi gambar diubah menjadi ukuran yang seragam, yaitu 299 x 299 piksel. Langkah ini tidak hanya meningkatkan efisiensi komputasi dengan memperbolehkan model seperti Inception-V3 untuk menangani input secara lebih terstruktur, tetapi juga mengoptimalkan penggunaan memori sistem (Luke et al., 2019). Ukuran 299 x 299 piksel dipilih berdasarkan rekomendasi dari model Inception-V3 yang digunakan (Fan et al., 2023). Hal ini dilakukan untuk memastikan kesesuaian dengan persyaratan teknis yang diperlukan (*InceptionV3*, 2015). Praktik ini secara signifikan dapat meminimalkan beban komputasi saat memproses *dataset* gambar yang mungkin besar, sekaligus meningkatkan kecepatan dan efisiensi keseluruhan sistem. Gambar 4 menunjukkan sampel citra setelah dilakukan proses *resizing*.



Gambar 4 Sampel Data Setelah Proses *Resizing*



Gambar 5 Histogram dari Sampel Data Sebelum dan Sesudah Proses Normalisasi



Setelah proses *resizing* dilakukan, langkah selanjutnya adalah melakukan normalisasi pada gambar. Normalisasi pada gambar dilakukan untuk meningkatkan kecepatan konvergensi, akurasi, dan stabilitas model dengan mengubah jangkauan dan distribusi nilai piksel pada gambar (Singh & Singh, 2020). Metode normalisasi yang digunakan adalah metode empiris (*empirical method*) dengan cara membagi setiap citra dengan nilai 255. Pendekatan ini secara efektif menyesuaikan intensitas piksel ke dalam kisaran 0 hingga 1 tanpa memengaruhi distribusi intensitas atau aspek visual (Pei et al., 2023). Gambar 5 menunjukkan perbandingan histogram antara data asli dan data yang telah dinormalisasi.

Dengan mengombinasikan proses *data cleaning*, *resizing*, dan *normalization*, *dataset* gambar dapat diproses untuk memastikan keseragaman dan kualitas yang optimal sebelum digunakan untuk melatih model klasifikasi sampah organik dan non-organik. Langkah-langkah ini menjadi landasan penting dalam memastikan bahwa data yang diberikan kepada model bersih, konsisten, dan siap untuk mempelajari pola yang relevan selama proses pelatihan.

2.2.3 Data Augmentation

Data augmentation adalah teknik yang digunakan untuk meningkatkan variasi dalam *dataset* pelatihan dengan membuat modifikasi terkontrol pada data yang ada (Mikolajczyk & Grochowski, 2018). Tujuan dari augmentasi ini adalah untuk memperkaya variasi dalam *dataset* pelatihan, sehingga model dapat menggeneralisasi pola dan fitur dengan lebih baik (Shorten & Khoshgoftaar, 2019). Beberapa metode augmentasi yang umum digunakan untuk mengatur variasi dalam *dataset* pelatihan antara lain adalah *rotation*, *gamma adjustment*, *noise injection*, dan *affine transform* (Zhang et al., 2019). Teknik *rotation* mengubah orientasi citra dalam sudut tertentu seperti 90 derajat atau 180 derajat. Hal ini membantu model memahami variasi posisi objek dalam data. *Gamma adjustment* mengubah kecerahan gambar dengan mengubah nilai *gamma* dalam transformasi *gamma*. Ini memungkinkan model untuk menyesuaikan variasi pencahayaan dalam data. *Noise injection* mengacaukan citra dengan menambahkan *noise* seperti Gaussian *noise*. Pemberian *noise* pada citra dapat meningkatkan toleransi model terhadap variasi *noise* di lingkungan nyata. *Affine transform* mencakup *scaling*, *translasi*, dan *shear*, yang dapat memperluas variasi posisi dan skala objek dalam citra untuk meningkatkan kemampuan model dalam mengenali variasi geometris (Vallez et al., 2022). Sampel data citra yang telah di augmentasi dapat dilihat pada Gambar 6.



Gambar 6 Sampel Data Setelah Proses Augmentasi


Dengan menerapkan teknik-teknik augmentasi data yang telah disebutkan di atas, sebanyak 40.000 citra baru dihasilkan untuk data pelatihan, sehingga total data pelatihan menjadi 50.000 citra. Proses augmentasi ini diharapkan dapat memberikan variasi yang diperlukan untuk melatih model agar lebih efektif dalam mengenali dan menggeneralisasi pola pada sampah organik dan non-organik. Dengan peningkatan jumlah dan keragaman data pelatihan, model diharapkan



mampu menangkap berbagai karakteristik dan variasi sampah yang mungkin ditemui di dunia nyata, sehingga meningkatkan akurasi dan kemampuan generalisasi model secara keseluruhan.

2.2.4 Data Modeling

Dalam tahap ini, pemodelan dilakukan dengan menerapkan salah satu arsitektur *deep neural network* yang telah terbukti efektif dalam klasifikasi gambar, yaitu Inception-V3. Inception-V3 merupakan model arsitektur Convolutional Neural Network (CNN) yang dikembangkan oleh Google untuk tugas klasifikasi gambar dan telah dilatih pada *dataset* ImageNet yang besar dan beragam (Lin et al., 2018). Kemampuan Inception-V3 untuk mengekstrak fitur dan pola kompleks dari data visual (*image*) menjadi alasan utama dari pemilihan model ini. Representasi diagram cara kerja Inception-V3 ditunjukkan pada Gambar 7. Pada diagram tersebut, (a) menunjukkan *layer* input atau citra, (b) menunjukkan lapisan konvolusi, (c) menunjukkan lapisan *subsampling*, dan (d) serta (e) menunjukkan *layer output* yang terhubung penuh.



Gambar 7 Diagram Cara Kerja Inception-V3

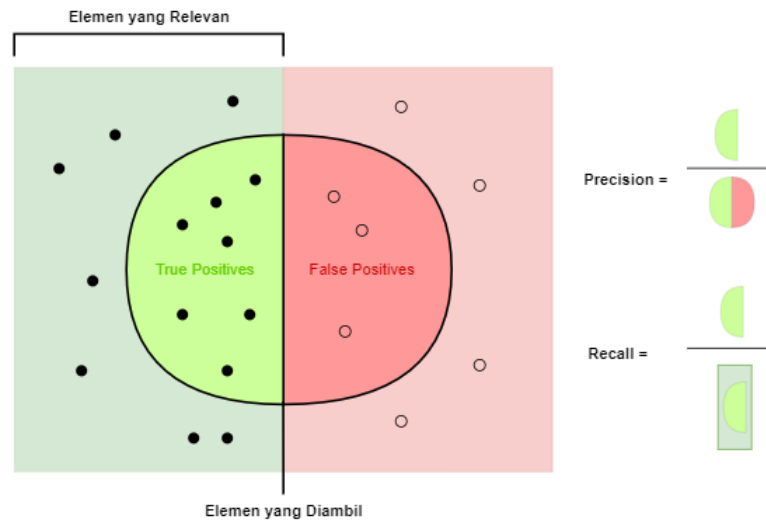
Proses pemodelan dimulai dengan memuat model Inception-V3 yang telah dilatih sebelumnya menggunakan bobot yang telah disesuaikan dengan *dataset* ImageNet. Model ini telah diakui memiliki kemampuan yang handal untuk menangani tugas-tugas klasifikasi gambar yang kompleks, dan pengetahuan yang terkandung dalam model tersebut diadopsi untuk mendukung tugas klasifikasi sampah organik dan non-organik. Setelah model dimuat, dilakukan pengaturan tambahan pada arsitektur, termasuk penggunaan *Global Average Pooling Layer* untuk meratakan *output* dari lapisan sebelumnya. Hal ini dapat menciptakan representasi yang lebih *compact*. Lapisan *Dense* dengan 1024-unit dan fungsi aktivasi ReLU ditambahkan untuk menambah kapasitas model. Lapisan *output* terakhir memiliki satu unit dengan fungsi aktivasi *sigmoid* yang sesuai dengan sifat tugas klasifikasi biner. Model kemudian diatur ulang menggunakan objek *Sequential* dari *library* Keras yang memungkinkan kombinasi lapisan-lapisan secara berurutan (NG, 2019). Proses ini akan menciptakan model yang siap untuk dilatih dengan menggunakan *dataset* sampah yang telah disiapkan sebelumnya.

Langkah terakhir dalam tahap pemodelan adalah pengompilan model. Dalam proses ini, parameter seperti *optimizer* ('adam'), fungsi *loss* ('binary_crossentropy' untuk tugas klasifikasi biner), dan metrik evaluasi (akurasi) ditentukan. Dengan demikian, konfigurasi dan persiapan model Inception-V3 telah berhasil dilakukan untuk tahap pelatihan dengan *dataset* sampah yang telah dipersiapkan sebelumnya.

2.2.5 Model Evaluation

Tahap evaluasi dalam pengembangan model *machine learning* mirip dengan memberikan penilaian akhir pada kinerja model. Seperti memberikan peringkat akhir pada seorang atlet setelah pertandingan, evaluasi ini menjadi langkah kritis untuk mengukur sejauh mana model memenuhi tujuan dan kebutuhan yang telah ditetapkan sejak awal. Evaluasi bertujuan untuk menilai kemampuan model klasifikasi sampah organik dan non-organik menggunakan teknologi *transfer learning* dan *data augmentation*.





Gambar 8 Precision & Recall

Langkah-langkah evaluasi mencakup berbagai metrik kinerja, seperti akurasi, *precision*, *recall*, dan *F1-score* (Nanmaran et al., 2022). Akurasi mengukur sejauh mana model dapat mengklasifikasikan sampah dengan benar, sedangkan *precision* menilai sejauh mana model memberikan label yang benar untuk kelas tertentu dari semua prediksinya. *Recall* mengukur sejauh mana model dapat mengidentifikasi seluruh sampah yang sebenarnya dalam *dataset*, dan *F1-score* menggabungkan *precision* dan *recall* untuk memberikan gambaran yang lebih holistik tentang kinerja model (Tripathi, 2021). Gambar 8 memberikan gambaran umum tentang bagaimana *precision* dan *recall* bekerja. Hasil evaluasi ini menjadi panduan penting dalam menentukan apakah model tersebut layak digunakan dalam situasi tertentu atau apakah perlu dilakukan peningkatan lebih lanjut. Misalnya, jika model memiliki akurasi tinggi tetapi presisi rendah, hal ini dapat mengindikasikan bahwa model cenderung memberikan label yang benar untuk kelas tertentu, tetapi mungkin terlalu sering memberikan label positif. Evaluasi yang cermat membantu dalam mengevaluasi *trade-off* antara berbagai metrik dan memastikan bahwa model dapat memberikan hasil yang dapat diandalkan dalam pengenalan sampah organik dan non-organik. Tahap evaluasi tidak hanya memberikan penilaian akhir pada kualitas model, tetapi juga memberikan wawasan yang berharga untuk perbaikan dan pengembangan model di masa depan.

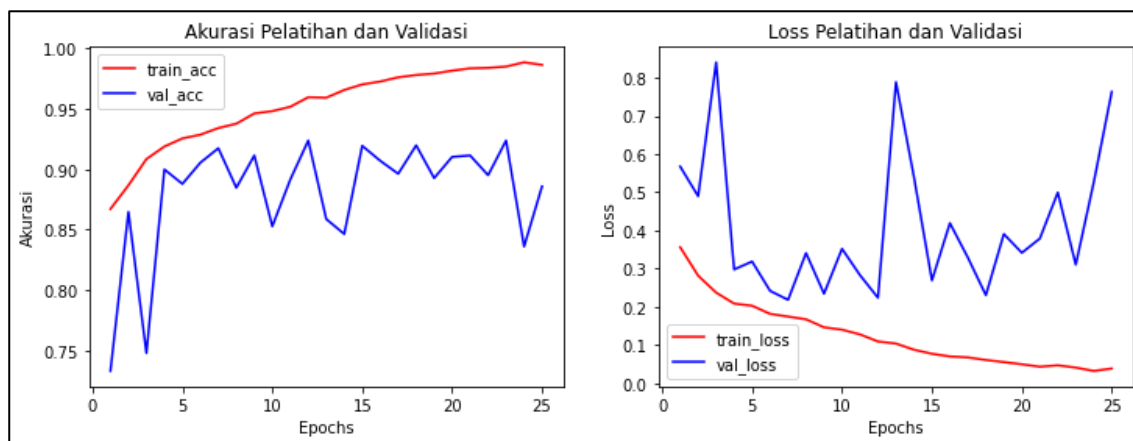
3. HASIL DAN PEMBAHASAN

Bab ini secara sistematis menguraikan proses pelatihan model Inception-V3 untuk klasifikasi sampah organik dan non-organik menggunakan pendekatan *transfer learning*. Proses dimulai dengan *fine-tuning* model selama 25 *epoch* atau iterasi guna mengoptimalkan kinerja. Evaluasi akan dilakukan pada setiap *epoch* menggunakan data pengujian untuk mengukur kemampuan model dalam mengklasifikasikan gambar yang belum pernah dilihat sebelumnya.

3.1 Hasil Pelatihan


Grafik pada Gambar 9 menampilkan perkembangan akurasi pelatihan (*training accuracy*) dan akurasi validasi (*validation accuracy*) serta kerugian pelatihan (*training loss*) dan kerugian validasi (*validation loss*) dari model yang telah dilatih menggunakan *original data* (data yang belum di augmentasi). Terlihat bahwa akurasi pada data pelatihan menunjukkan peningkatan yang konsisten di setiap *epoch*. Meski begitu, akurasi pada data pengujian mengalami fluktuasi dengan nilai akurasi berada pada rentang 0,73 hingga 0,92.





Gambar 9 Akurasi dan Loss dari Model yang menggunakan *Original Data*

Pada grafik *Loss Pelatihan dan Validasi*, terlihat bahwa nilai *loss* pelatihan menurun secara konsisten setiap kali *epoch* berlalu. Hal ini mencerminkan adanya kesinambungan dalam proses pembelajaran model. Namun, terdapat fluktuasi pada nilai *loss* validasi, yang cenderung meningkat seiring berjalannya waktu. Fenomena ini mengisyaratkan adanya masalah *overfitting* pada model. Selanjutnya, model dilatih kembali menggunakan data yang telah di *augmentasi*. Hasil dari proses pelatihan ini dapat dilihat pada Gambar 10.



Gambar 10 Akurasi dan Loss dari Model yang menggunakan *Augmented Data*

Dapat dilihat bahwa meskipun akurasi dan kerugian pada data uji masih cenderung mengalami fluktuatif, model yang dilatih menggunakan data yang telah di-*augmentasi* menunjukkan kinerja keseluruhan yang lebih baik dibandingkan dengan model yang menggunakan data asli (data yang belum di-*augmentasi*).

3.2 Evaluasi Model

Evaluasi model dilakukan dengan menggunakan *classification report* dan *confusion matrix* yang dapat dilihat pada Tabel 1 dan Tabel 2. Hasil menunjukkan bahwa model memiliki performa yang memuaskan dalam mengklasifikasikan sampah organik dan non-organik. Untuk kelas 'Organik', model dengan data yang telah di *augmentasi* mencapai nilai *precision* sebesar 0,92, *recall* sebesar 0,97, dan *F1-Score* sebesar 0,94. Hal ini menunjukkan bahwa model memiliki kemampuan tinggi untuk mengidentifikasi sampah organik dengan sangat baik. Di sisi lain, untuk kelas Non Organik, model mencapai nilai *precision* sebesar 0,96, *recall* sebesar 0,90, dan *F1-Score* sebesar 0,93.



Secara keseluruhan, model berhasil mencapai tingkat akurasi sebesar 0,94. Hal ini mencerminkan kemampuannya dalam melakukan klasifikasi yang tepat pada seluruh *dataset*. Implementasi augmentasi data juga terbukti meningkatkan kinerja model secara keseluruhan hingga 2%. Dalam evaluasi menyeluruh, nilai *precision*, *recall*, dan *F1-Score* menunjukkan keseimbangan yang optimal antara kelas Organik dan Non Organik dengan rata-rata nilai yang tinggi. Hasil evaluasi ini memberikan keyakinan yang kuat bahwa model Inception-V3 berhasil mengklasifikasikan sampah organik dan non-organik dengan tingkat akurasi dan kinerja yang sangat baik.

Tabel 1 Model Classification Result

	Precision		Recall		F1-Score	
	<i>Without Augmentation</i>	<i>With Augmentation</i>	<i>Without Augmentation</i>	<i>With Augmentation</i>	<i>Without Augmentation</i>	<i>With Augmentation</i>
Organik	0,91	0,92	0,95	0,97	0,93	0,94
Non Organik	0,94	0,96	0,88	0,90	0,91	0,93
Accuracy					0,92	0,94

Tabel 2 Confusion Matrix Menggunakan Augmented Data

		Prediksi	
		Organik	Non Organik
Aktual	Organik	1348	46
	Non Organik	115	997

3.3 Uji Coba

Percobaan dilakukan dengan menggunakan model untuk melakukan klasifikasi terhadap 100 sampel gambar sampah yang berasal dari berbagai kondisi yang diambil dari di situs Google. Seluruh sampel ini dipilih untuk mencakup keragaman kondisi sampah yang mungkin dihadapi dalam aplikasi praktis, sehingga pengujian dapat mencerminkan situasi yang lebih realistis. Kemampuan model diuji dalam mengenali dan mengklasifikasikan sampah ke dalam dua kategori utama, yaitu organik dan non-organik. Proses ini bertujuan untuk mengevaluasi sejauh mana model dapat memberikan prediksi yang akurat dan konsisten terhadap berbagai jenis sampah. Hasil dari identifikasi sampah menggunakan model Inception-V3 dapat dilihat pada Gambar 11 dan Gambar 12.



Gambar 11 Sampel Hasil Identifikasi Sampah Organik Menggunakan Inception-V3





Gambar 12 Sampel Hasil Identifikasi Sampah Non Organik Menggunakan Inception-V3

Dari hasil evaluasi percobaan seperti yang terlihat pada Tabel 3, menunjukkan bahwa model mampu mengklasifikasikan sampah organik dengan tingkat akurasi sempurna di 100%, yang menandakan kemampuan model sudah sangat baik dalam mengenali sampah organik. Namun, pada kategori sampah non-organik, meskipun tingkat akurasinya masih tinggi (96%), terdapat beberapa kesalahan klasifikasi. Sebanyak 2 data citra non-organik salah diklasifikasikan sebagai organik. Hal ini memberikan gambaran bahwa model perlu diperbaiki khususnya dalam mengenali sampah non-organik agar dapat meningkatkan akurasi secara keseluruhan.

Tabel 3 Hasil Pengujian

Kondisi Sampah	Data	Benar	Salah	Akurasi	Error
Organik	50	50	0	1,00	0,00
Non Organik	50	48	2	0,96	0,04

4. KESIMPULAN

Implementasi *transfer learning* dengan arsitektur Inception-V3 dan penerapan *data augmentation* berhasil menciptakan model klasifikasi sampah organik dan non-organik dengan tingkat akurasi data uji mencapai 94%. Model ini menunjukkan keunggulan istimewa dalam mengenali sampah organik dengan akurasi sempurna 100%. Namun, evaluasi yang lebih cermat masih diperlukan terutama dalam klasifikasi sampah non-organik, di mana akurasinya tidak mencapai level yang sama dengan sampah organik.

Penelitian ini berhasil menunjukkan bahwa kombinasi *transfer learning* dan *data augmentation* dapat memberikan peningkatan signifikan dalam akurasi dan kemampuan generalisasi model dibandingkan dengan metode Convolutional Neural Network (CNN) yang digunakan pada penelitian sebelumnya. Keunggulan metode *transfer learning* dengan arsitektur Inception-V3 terletak pada kemampuannya memanfaatkan fitur-fitur yang telah dipelajari dari *dataset* besar, sehingga mempercepat proses pelatihan dan meningkatkan performa pada *dataset* yang lebih kecil dan spesifik.

Untuk penelitian berikutnya, disarankan untuk fokus pada eksplorasi lebih lanjut mengenai teknik *data augmentation* yang lebih canggih. Teknik-teknik seperti Generative Adversarial Networks (GANs) untuk menghasilkan data baru, atau penggunaan augmentasi yang lebih bervariasi, dapat membantu meningkatkan keragaman data dan mengatasi masalah *overfitting* yang terjadi pada model saat ini. Selain itu, penelitian lanjutan juga dapat mengeksplorasi kombinasi arsitektur model lain atau teknik ensemble untuk lebih meningkatkan performa klasifikasi sampah non-organik.



DAFTAR PUSTAKA

- Ahmed, M., Afreen, N., Ahmed, M., Sameer, M., & Ahamed, J. (2023). An inception V3 approach for malware classification using machine learning and transfer learning. *International Journal of Intelligent Networks*, 4, 11–18. <https://doi.org/10.1016/j.ijin.2022.11.005>
- Fadillah, I., A. L., Kamil, F. El, Shalahuddin, M., Setiawan, I., N, A., M, H., A, N., S, R., & Fikri, K. (2019). Perubahan Pola Pikir Masyarakat tentang Sampah melalui Sosialisasi Pengolahan Sampah Organik dan Non Organik di Dusun Pondok, Kecamatan Gedangsari, Kab. Gunungkidul. *Prosiding Konferensi Pengabdian Masyarakat*, 1, 239–242. <https://sunankalijaga.org/prosiding/index.php/abdimas/article/view/201>
- Fan, Y., Li, J., Bhatti, U. A., Shao, C., Gong, C., Cheng, J., & Chen, Y. (2023). A Multi-Watermarking Algorithm for Medical Images Using Inception V3 and DCT. *Computers, Materials & Continua*, 74(1), 1279–1302. <https://doi.org/10.32604/cmc.2023.031445>
- Hidayati, N., Suntoro, J., & Setiaji, G. G. (2021). Perbandingan Algoritma Klasifikasi untuk Prediksi Cacat Software dengan Pendekatan CRISP-DM. *Jurnal Sains Dan Informatika*, 7(2), 117–126. <https://doi.org/10.34128/jsi.v7i2.313>
- Ibnul Rasidi, A., Pasaribu, Y. A. H., Ziqri, A., & Adhinata, F. D. (2022). Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network. *Jurnal Teknik Informatika Dan Sistem Informasi*, 8(1), 142-149–142 – 149. <https://doi.org/10.28932/jutisi.v8i1.4314>
- InceptionV3. (2015). Google. <https://keras.io/api/applications/inceptionv3/>
- Kartiko, Prima Yudha, A., Dimas Aryanto, N., & Arya Farabi, M. (2022). Klasifikasi Sampah di Saluran Air Menggunakan Algoritma CNN. *Indonesian Journal of Data and Science*, 3(2), 72–81. <https://doi.org/10.56705/ijodas.v3i2.33>
- Kementerian Lingkungan Hidup dan Kehutanan. (2022). *SIPSN - Sistem Informasi Pengelolaan Sampah Nasional*. Kementerian Lingkungan Hidup Dan Kehutanan. <https://sipsn.menlhk.go.id/sipsn/>
- Lebreton, L., & Andrady, A. (2019). Future scenarios of global plastic waste generation and disposal. *Palgrave Communications*, 5(1), 6. <https://doi.org/10.1057/s41599-018-0212-7>
- Lin, C., Li, L., Luo, W., Wang, K. C. P., & Guo, J. (2018). Transfer Learning Based Traffic Sign Recognition Using Inception-v3 Model. *Periodica Polytechnica Transportation Engineering*, 47(3), 242–250. <https://doi.org/10.3311/PPtr.11480>
- Luke, J. J., Joseph, R., & Balaji, M. (2019). IMPACT OF IMAGE SIZE ON ACCURACY AND GENERALIZATION OF CONVOLUTIONAL NEURAL NETWORKS. *International Journal of Research and Analytical Reviews*, 6(1), 70–80. www.ijrar.org
- Mikolajczyk, A., & Grochowski, M. (2018). Data augmentation for improving deep learning in image classification problem. *2018 International Interdisciplinary PhD Workshop (IIPhDW)*, 117–122. <https://doi.org/10.1109/IIPhDW.2018.8388338>
- Minarno, A. E., Aripa, L., Azhar, Y., & Munarko, Y. (2023). Classification of Malaria Cell Image using Inception-V3 Architecture. *JOIV: International Journal on Informatics Visualization*, 7(2), 273. <https://doi.org/10.30630/joiv.7.2.1301>
- Minarno, A. E., Hasanuddin, M. Y., & Azhar, Y. (2023). Batik Images Retrieval Using Pre-trained model and K-Nearest Neighbor. *JOIV: International Journal on Informatics Visualization*, 7(1), 115. <https://doi.org/10.30630/joiv.7.1.1299>
- Nanmaran, R., Srimathi, S., Yamuna, G., Thanigaivel, S., Vickram, A. S., Priya, A. K., Karthick, A., Karpagam, J., Mohanavel, V., & Muhibbullah, M. (2022). Investigating the Role of Image Fusion in Brain Tumor Classification Models Based on Machine Learning Algorithm for Personalized Medicine. *Computational and Mathematical Methods in Medicine*, 2022(1), 1–13. <https://doi.org/10.1155/2022/7137524>
- NG, K. (2019). Tuned Inception V3 for Recognizing States of Cooking Ingredients. *State Recognition Symposium*. <https://doi.org/10.32555/2019.dl.009>
- Pei, X., Zhao, Y. hong, Chen, L., Guo, Q., Duan, Z., Pan, Y., & Hou, H. (2023). Robustness of machine learning to color, size change, normalization, and image enhancement on micrograph datasets with large sample differences. *Materials & Design*, 232, 112086. <https://doi.org/10.1016/j.matdes.2023.112086>



- Rosiana, E., & Perdana, R. (2022). Rancang Bangun Sistem Robot Pemilah Sampah Anorganik dengan Inductive Proximity dan LDR Sebagai Sensor. *Building of Informatics, Technology and Science (BITS)*, 4(2), 1001–1009. <https://doi.org/10.47065/bits.v4i2.2017>
- Schröer, C., Kruse, F., & Gómez, J. M. (2021). A Systematic Literature Review on Applying CRISP-DM Process Model. *Procedia Computer Science*, 181, 526–534. <https://doi.org/10.1016/j.procs.2021.01.199>
- Sekar, S. (2019). *Waste Classification data*. Kaggle. <https://www.kaggle.com/datasets/techsash/waste-classification-data>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 1–48. <https://doi.org/10.1186/S40537-019-0197-0/FIGURES/33>
- Singh, D., & Singh, B. (2020). Investigating the impact of data normalization on classification performance. *Applied Soft Computing*, 97, 105524. <https://doi.org/10.1016/j.asoc.2019.105524>
- Tripathi, M. (2021). Analysis of Convolutional Neural Network based Image Classification Techniques. *Journal of Innovative Image Processing*, 3(2), 100–117. <https://doi.org/10.36548/jiip.2021.2.003>
- Vallez, N., Bueno, G., Deniz, O., & Blanco, S. (2022). Diffeomorphic transforms for data augmentation of highly variable shape and texture objects. *Computer Methods and Programs in Biomedicine*, 219, 106775. <https://doi.org/10.1016/j.cmpb.2022.106775>
- Wang, Y. H., Ou, Y., Deng, X. D., Zhao, L. R., & Zhang, C. Y. (2019). The Ship Collision Accidents Based on Logistic Regression and Big Data. *Proceedings of the 31st Chinese Control and Decision Conference, CCDC 2019*, 4438–4440. <https://doi.org/10.1109/CCDC.2019.8832686>
- Widodo, A. E., & Suleman, S. (2020). Otomatisasi Pemilah Sampah Berbasis Arduino Uno. *Indonesian Journal on Software Engineering (IJSE)*, 6(1), 12–18. <https://doi.org/10.31294/ijse.v6i1.7781>
- Zhang, Y. D., Dong, Z., Chen, X., Jia, W., Du, S., Muhammad, K., & Wang, S. H. (2019). Image based fruit category classification by 13-layer deep convolutional neural network and data augmentation. *Multimedia Tools and Applications*, 78(3), 3613–3632. <https://doi.org/10.1007/S11042-017-5243-3/METRICS>

