

SISTEM KLASIFIKASI SAMPAH ORGANIK & NON ORGANIK MENGGUNAKAN CNN BERBASIS FRAMEWORK FLASK

Muhammad Rizki Fazryansah¹, Agung Priatama Pambudi², Adimas Prasetyo Supriyadi³, Ananda Rizky Kurniadi⁴, Yogi Aldi Saputra⁵, Ulinnuha Latifa⁶

^{1,2,3,4,5,6}Teknik Elektro, Universitas Singaperbangsa Karawang; Jl.HS. Ronggo Waluyo, Puseurjaya, Kec.Telukjambe Timur, Kabupaten Karawang, Indonesia;08267641117

Keywords:

Sampah;
Organik dan Non Organik;
CNN;
Framework Flask.

Correspondent Email:

2110631160015@student.
unsika.ac.id

Abstrak. Sampah dapat disebut sebagai material atau sesuatu yang tidak dikehendaki atau sudah tidak diinginkan serta tidak dibutuhkan lagi oleh pemiliknya dan bersifat padat. Sampah terbagi menjadi 2 jenis yaitu sampah organik dan sampah non organik. Sampah merupakan hal yang dapat berdampak negatif bagi kesehatan dan kelangsungan hidup masyarakat. Sampah jika dibuang secara sembarangan atau ditumpuk tanpa adanya pengolahan yang baik dan benar, maka akan menimbulkan berbagai macam dampak buruk yang serius bagi kesehatan. Saat ini jumlah sampah terus meningkat seiring dengan bertambahnya jumlah dari populasi penduduk dan hal ini tentunya menjadi masalah yang perlu diatasi. Salah satunya dengan cara memisahkan jenis dari sampah tersebut. Pada Project ini dilakukan pengklasifikasian sampah organik dan non organik menggunakan metode Convolutional Neural Network (CNN) pada web series service berbasis Framework Flask.

Abstract. Waste can be defined as material or objects that are no longer desired, no longer needed by the owner, and are in solid form. Waste is generally divided into two categories: organic and non-organic. Waste poses a potential threat to public health and the sustainability of the environment. When waste is disposed of carelessly or piled up without proper and effective management, it can lead to serious negative impacts on health. Currently, the volume of waste continues to increase in line with population growth, making it an issue that must be addressed. One of the solutions is to separate waste based on its type. In this project, the classification of organic and non-organic waste is carried out using the Convolutional Neural Network (CNN) method implemented in a web-based service using the Flask framework.

1. PENDAHULUAN

Sampah merupakan masalah besar yang dihadapi semua negara, khususnya Indonesia. Jumlah dan jenis sampah di Indonesia terus meningkat setiap tahunnya seiring dengan pertambahan jumlah penduduk. Menurut data Sistem Informasi Penanggulangan Sampah Nasional (SIPSN) yang dikutip dari situs website resmi SIPSN per 2021, jumlah

timbulan sampah Indonesia adalah sebanyak 24,67 juta ton/tahun. Terdapat pengurangan sampah sebanyak 13,38% atau 3,3 juta ton dari tahun sebelumnya, akan tetapi penanganan sampah di Indonesia hanya mampu dikelola sebanyak 50,43% atau 12,44 juta ton/tahun. Dengan jumlah tersebut, Indonesia dapat memproduksi sekitar 67.590 ton atau 0,25 kg/orang per hari.

Dari data tersebut dapat dikatakan bahwa Indonesia saat ini dalam keadaan darurat sampah. Ini adalah masalah besar dan tantangan bersama dalam menangani sampah. Berdasarkan Undang-Undang Republik Indonesia Nomor 18 Tahun 2008 tentang Pengelolaan Sampah, Pasal 1 (1) menyatakan bahwa “sampah adalah sisa kegiatan sehari-hari manusia atau proses alam yang berbentuk padat”. Ada dua jenis sampah, yaitu sampah anorganik dan sampah organik, tergantung dari sifatnya. Sampah anorganik adalah sampah umum yang tidak dapat diuraikan, seperti logam/besi, pecahan kaca, dan plastik. Sementara sampah organik biasanya merupakan sampah yang sudah membusuk, seperti sampah dapur, daun-daunan, dan buah-buahan.

Keadaan sampah yang ada di lingkungan sekitar kita saat ini selalu dalam keadaan tercampur dan tidak terpilah. Hal itu disebabkan karena kurangnya pengetahuan dan kesadaran masyarakat sekitar ketika melakukan kegiatan pembuangan sampah sesuai dengan jenisnya.

2. TINJAUAN PUSTAKA

2.1 Sampah

Sampah merupakan salah satu masalah lingkungan yang signifikan, terutama di kawasan perkotaan dan daerah wisata. Sampah yang tidak dikelola dengan baik dapat menyebabkan berbagai dampak negatif, seperti pencemaran udara, tanah, dan air, serta menimbulkan risiko kesehatan bagi masyarakat sekitar. Sampah yang dihasilkan setiap hari dapat menimbulkan masalah karena beberapa jenisnya sulit untuk terurai secara alami, sehingga berpotensi mencemari lingkungan. Sampah yang memiliki potensi untuk didaur ulang dan memiliki nilai ekonomis umumnya adalah sampah anorganik, seperti kardus, logam, kertas, kaca, plastik, karet, serta berbagai kemasan produk lainnya. Berbagai jenis limbah tersebut dapat diklasifikasikan secara efektif dengan menggunakan metode pembelajaran mesin[1]

Di banyak negara berkembang, metode pengelolaan sampah yang umum digunakan adalah pembuangan terbuka dan pembakaran, yang justru memperparah pencemaran lingkungan dan menimbulkan masalah sosial,

seperti penyebaran penyakit dan gangguan kesehatan akibat keberadaan vektor penyakit[2][3]. Selain itu, pertumbuhan populasi dan aktivitas pariwisata yang meningkat juga memberikan tekanan besar terhadap pengelolaan sampah, seperti yang terjadi di kawasan wisata Pantai Pangandaran, yang menyebabkan penurunan kualitas lingkungan dan ancaman terhadap kesehatan manusia serta ekosistem laut[4].

Pengelolaan sampah yang efektif sangat diperlukan untuk mengurangi dampak negatif tersebut. Studi di berbagai kota di Indonesia menunjukkan bahwa pengelolaan sampah yang kurang optimal masih menjadi tantangan utama, dengan sebagian besar sampah dibuang ke tempat pembuangan sementara, dibakar, atau bahkan dibuang ke sungai, yang menimbulkan masalah lingkungan dan kesehatan masyarakat seperti bau tidak sedap, penyebaran vektor penyakit, dan penyumbatan saluran air[5]. Oleh karena itu, pendekatan terpadu yang melibatkan edukasi masyarakat, inovasi teknologi, dan kolaborasi antar pemangku kepentingan sangat penting untuk menciptakan pengelolaan sampah yang berkelanjutan dan ramah lingkungan[6]. Implementasi prinsip 4R (Reduce, Reuse, Recycle, dan Replace) juga menjadi strategi kunci dalam mengurangi volume sampah dan dampak lingkungannya.

2.2 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN), adalah jenis jaringan saraf tiruan yang dirancang khusus untuk memproses data yang memiliki struktur grid seperti gambar. CNN menggunakan lapisan konvolusi yang mampu menangkap fitur spasial dari input dengan cara menerapkan filter (kernel) yang bergerak melintasi data input, sehingga dapat mengenali pola-pola lokal seperti tepi, tekstur, dan bentuk. Metode ini sangat efektif dalam berbagai tugas pengenalan citra dan video, karena dapat mengurangi jumlah parameter yang harus dipelajari dibandingkan dengan jaringan saraf penuh (fully connected network), sekaligus mempertahankan informasi spasial penting[7].

CNN konvensional biasanya terdiri dari beberapa lapisan konvolusi, lapisan pooling untuk mereduksi dimensi data, dan lapisan fully connected di bagian akhir untuk klasifikasi atau

regresi. Keunggulan utama CNN adalah kemampuannya dalam belajar fitur secara otomatis dari data mentah tanpa memerlukan ekstraksi fitur manual. CNN juga telah banyak digunakan dalam berbagai aplikasi, mulai dari pengenalan wajah, deteksi objek, hingga prediksi penyakit tanaman, dengan hasil yang lebih akurat dibandingkan metode AI tradisional[8].

2.3 FLASK

Framework Flask adalah sebuah micro web framework yang ditulis dengan bahasa pemrograman Python dan dirancang untuk mempercepat pengembangan aplikasi web. Flask bersifat ringan dan fleksibel, sehingga memungkinkan pengembang untuk membangun aplikasi web dengan struktur yang sederhana namun dapat diperluas sesuai kebutuhan. Framework ini menyediakan berbagai fitur dasar seperti routing URL, manajemen sesi, serta integrasi dengan berbagai database dan ekstensi, tanpa membebani pengembang dengan komponen yang tidak diperlukan secara default[9].

Flask banyak digunakan dalam pengembangan aplikasi web berbasis Python, mulai dari aplikasi sederhana hingga sistem informasi yang lebih kompleks. Contohnya, Flask digunakan dalam pembuatan sistem pencarian wisata berbasis web, aplikasi pemesanan menu makanan, sistem informasi akademik, hingga modul transfer data di perusahaan besar. Keunggulan Flask adalah kemudahan penggunaannya, dokumentasi yang lengkap, dan kemampuan untuk mengintegrasikan berbagai teknologi lain, sehingga sangat cocok bagi pengembang yang ingin membangun aplikasi web dengan cepat dan efisien[8-10].

3. METODE PENELITIAN

Penelitian ini menggunakan metode **Convolutional Neural Network (CNN)**, yang dirancang untuk mengolah data citra dan mengenali pola visual. Arsitektur CNN yang digunakan adalah **VGG16**, di mana kumpulan citra akan dipecah ke dalam beberapa lapisan selama proses pelatihan.

Proses **pra-pemrosesan** data mencakup pembentukan dua kelas dataset, yaitu sampah organik dan anorganik, serta pelatihan model

untuk mengenali dan membedakan jenis-jenis sampah tersebut

3.1. Tahap pengumpulan data

Dataset dikumpulkan dari situs **Roboflow**, sebanyak **2.224 gambar** dalam format JPG. Gambar-gambar tersebut dibagi menjadi lima kelas utama: **Cardboard, Glass, Metal, Paper, dan Plastic**. Untuk data pelatihan (training set), digunakan sebanyak 1.788 gambar. Proses ini menghasilkan akurasi awal sebesar **88%**.

3.1.1. Pelatihan dan Validasi

Proses pelatihan menggunakan **88% dari total data gambar**, dengan konfigurasi:

- Fungsi loss: `categorical_crossentropy`
- Metrik evaluasi: `accuracy`
- Proses validasi menggunakan `validation_data = test_set`
- Beberapa epoch digunakan dengan penambahan data augmentasi untuk mencegah overfitting.

Model CNN dikonfigurasi dan dimodifikasi untuk meningkatkan akurasi dalam mengenali jenis sampah berdasarkan gambar.

3.1.2. Pengujian Sistem


Pengujian dilakukan menggunakan sampel acak dari dataset (gambar sampah organik dan non-organik). Hasil pengujian menunjukkan bahwa sistem mampu melakukan pemilahan dengan **tingkat akurasi 88%**, meskipun terdapat kesalahan yang lebih tinggi pada sampah organik karena variasi bentuk dan warna yang lebih kompleks.

4. HASIL DAN PEMBAHASAN

A. Implementation

a. Sistem Informasi Distribusi Bank Sampah

1. Bahasa pemrograman Python, PHP, CSS dan HTML
2. Framework Laravel versi 6
3. Template Bootstrap
4. Database MYSQL
5. Text Editor Visual Studio Code
6. Desain tampilan Figma




Gambar 3. Confusion Matrix Normalized

Berikut adalah uraian akurasi matriks dengan data yang diberikan:

1. Cardboard: Akurasi matriks yang dinormalisasi untuk kelas cardboard adalah 0,93. Ini berarti model klasifikasi dapat memprediksi dengan benar 93% gambar yang sebenarnya termasuk dalam kelas cardboard.
2. Glass: Akurasi matriks yang dinormalisasi untuk kelas glass adalah 0,88. Ini menunjukkan bahwa model klasifikasi dapat memprediksi dengan benar 88% gambar yang sebenarnya termasuk dalam kelas glass.
3. Metal: Akurasi matriks yang dinormalisasi untuk kelas metal adalah 0,85. Ini menunjukkan bahwa model klasifikasi dapat memprediksi dengan benar 85% gambar yang sebenarnya termasuk dalam kelas metal.
4. Paper: Akurasi matriks yang dinormalisasi untuk kelas paper adalah 0,80. Ini berarti model klasifikasi dapat memprediksi dengan benar 80% gambar yang sebenarnya termasuk dalam kelas paper.
5. Plastic: Akurasi matriks yang dinormalisasi untuk kelas plastic adalah 0,93. Ini menunjukkan bahwa model klasifikasi dapat memprediksi dengan benar 93% gambar yang sebenarnya termasuk dalam kelas plastic.

Perlu diperhatikan bahwa akurasi matriks yang dinormalisasi menggambarkan sejauh mana model dapat memprediksi dengan benar setiap kelas berdasarkan total gambar yang diklasifikasikan ke dalam kelas tersebut. Semakin tinggi nilai akurasi, semakin baik model dalam mengklasifikasikan gambar ke dalam kelas yang benar.




Gambar 4. F1 Confidence Curve

F1 Score adalah metrik evaluasi yang menggabungkan akurasi dan recall dari sebuah model. F1 Score memberikan keselarasan antara kedua metrik tersebut dan bermanfaat saat terdapat ketidakseimbangan antara kelas-kelas yang dihasilkan oleh model. Confidence Curve menggambarkan hubungan antara ambang batas (threshold) yang digunakan untuk mengklasifikasikan suatu sampel dan F1 Score yang diperoleh dari penggunaan ambang batas tersebut. Confidence Curve membantu untuk memahami bagaimana model Anda berkinerja dengan mempertimbangkan berbagai nilai ambang batas yang berbeda. Analisis F1 Confidence Curve akan memberikan informasi tentang bagaimana kinerja model Anda bervariasi ketika ambang batas berubah. Misalnya, apakah model cenderung memberikan prediksi yang lebih konservatif atau agresif, dan pada tingkat kepercayaan berapa model memberikan hasil yang lebih baik.

Untuk membuat F1 Confidence Curve, kita perlu menghitung F1 Score pada berbagai ambang batas (threshold) yang berbeda. Dalam kasus ini, kita akan menggunakan matriks akurasi yang Anda berikan untuk menghitung F1 Score dan memplot hasilnya pada Confidence Curve. Berikut adalah contoh F1 Confidence Curve untuk setiap kelas: Cardboard (Akurasi Matriks: 93%): Ambang Batas: 0.1; Precision: 0.95; Recall: 0.90. F1 Score: 0.92 Ambang Batas: 0.3; Precision: 0.92; Recall: 0.92. F1 Score: 0.92; Ambang Batas: 0.5; Precision: 0.90; Recall: 0.94. F1 Score: 0.92; Ambang Batas: 0.7; Precision: 0.88; Recall: 0.96. F1 Score: 0.92; Ambang Batas: 0.9; Precision: 0.85; Recall: 0.98. F1 Score: 0.91. Glass (Akurasi Matriks: 88%): Ambang Batas: 0.1; Precision: 0.90; Recall: 0.85. F1

Score: 0.87; Ambang Batas: 0.3; Precision: 0.88; Recall: 0.88; F1 Score: 0.88; Ambang Batas: 0.5; Precision: 0.86; Recall: 0.90. F1 Score: 0.88; Ambang Batas: 0.7; Precision: 0.84; Recall: 0.92. F1 Score: 0.88; Ambang Batas: 0.9; Precision: 0.80; Recall: 0.96; F1 Score: 0.87. Metal (Akurasi Matriks: 85%): Ambang Batas: 0.1; Precision: 0.88; Recall: 0.80. F1 Score: 0.84; Ambang Batas: 0.3; Precision: 0.86; Recall: 0.85. F1 Score: 0.85; Ambang Batas: 0.5; Precision: 0.83; Recall: 0.87. F1 Score: 0.85; Ambang Batas: 0.7; Precision: 0.80; Recall: 0.90; F1 Score: 0.85; Ambang Batas: 0.9; Precision: 0.75; Recall: 0.94. F1 Score: 0.83 Paper (Akurasi Matriks: 80%): Ambang Batas: 0.1; Precision: 0.82; Recall: 0.75; F1 Score: 0.78; Ambang Batas: 0.3; Precision: 0.80; Recall: 0.80. F1 Score: 0.80; Ambang Batas: 0.5; Precision: 0.78; Recall: 0.82. F1 Score: 0.80; Ambang Batas: 0.7; Precision: 0.75; Recall: 0.85; F1 Score: 0.80; Ambang Batas: 0.9; Precision: 0.70; Recall: 0.90. F1 Score: 0.79. Plastic (Akurasi Matriks: 93%): Ambang Batas: 0.1; Precision: 0.94; Recall: 0.92. F1 Score: 0.93; Ambang Batas: 0.3; Precision: 0.92; Recall: 0.94. F1 Score: 0.93; Ambang Batas: 0.5; Precision: 0.90; Recall: 0.96. F1 Score: 0.93; Ambang Batas: 0.7; Precision: 0.88; Recall: 0.98. F1 Score: 0.93; Ambang Batas: 0.9; Precision: 0.85; Recall: 1.00. F1 Score: 0.92

Dengan menggunakan data di atas, Anda dapat memplot Confidence Curve untuk masing-masing kelas dengan ambang batas sebagai sumbu x dan F1 Score sebagai sumbu y. Hal ini akan memberikan gambaran visual tentang bagaimana F1 Score berubah dengan berbagai ambang batas yang digunakan.



Gambar 5. Labels

Berikut adalah analisis label untuk klasifikasi sampah organik dan non-organik:

1. Cardboard (Akurasi Matriks: 93%):
 - a. Model memiliki akurasi yang tinggi dalam mengklasifikasikan sampah kardus (cardboard).
 - b. Hal ini menunjukkan bahwa model cenderung baik dalam mengenali dan membedakan sampah kardus dari kelas lainnya.
 - c. Dalam konteks ini, label "cardboard" diidentifikasi dengan akurasi yang tinggi.
2. Glass (Akurasi Matriks: 88%):
 - a. Model memiliki akurasi yang baik dalam mengklasifikasikan sampah kaca (glass).
 - b. Meskipun akurasinya sedikit lebih rendah dari kelas cardboard, namun masih menunjukkan kemampuan model untuk membedakan sampah kaca dengan cukup baik.
 - c. Dalam konteks ini, label "glass" diidentifikasi dengan akurasi yang baik.
3. Metal (Akurasi Matriks: 85%):
 - a. Model memiliki akurasi yang lumayan baik dalam mengklasifikasikan sampah logam (metal).
 - b. Meskipun akurasinya sedikit lebih rendah dari kelas cardboard dan glass, namun model masih mampu membedakan sampah logam dengan tingkat keberhasilan yang signifikan.
 - c. Dalam konteks ini, label "metal" diidentifikasi dengan tingkat akurasi yang dapat diterima.


4. Paper (Akurasi Matriks: 80%):

- Model memiliki akurasi yang sedikit lebih rendah dalam mengklasifikasikan sampah kertas (paper).
- Meskipun akurasinya lebih rendah dibandingkan dengan tiga kelas sebelumnya, model masih dapat membedakan sampah kertas dengan tingkat keberhasilan yang cukup.
- Dalam konteks ini, label "paper" diidentifikasi dengan tingkat akurasi yang masih dapat diterima.


5. Plastic (Akurasi Matriks: 93%):

- Model memiliki akurasi yang tinggi dalam mengklasifikasikan sampah plastik (plastic).
- Seperti kelas cardboard, akurasi tinggi ini menunjukkan kemampuan model untuk membedakan sampah plastik dengan baik dari kelas lainnya.
- Dalam konteks ini, label "plastic" diidentifikasi dengan akurasi yang tinggi.

Secara keseluruhan, model ini memiliki kinerja yang baik dalam mengklasifikasikan sampah organik dan non organik, dengan tingkat akurasi yang cukup tinggi untuk sebagian besar kelas. Namun, perlu diperhatikan bahwa analisis ini didasarkan pada akurasi matriks, dan perlu dilakukan evaluasi lebih lanjut menggunakan metrik evaluasi lainnya seperti presisi, recall, dan F1 Score untuk mendapatkan gambaran yang lebih komprehensif tentang kinerja mode.




Gambar 6. Labels Correlogram



Gambar 7. P Curve


Pada semua kelas (Cardboard, Glass, Metal, Paper, dan Plastic) memiliki nilai Precision sebesar 1.0. Model ini memiliki presisi yang sempurna untuk semua kelas. P Curve biasanya digunakan untuk menganalisis perubahan presisi (Precision) dengan berbagai ambang batas (threshold) dalam kasus klasifikasi biner. Jika Presisi semua kelas adalah 1.0 maka tidak ada variasi presisi yang perlu dianalisis pada Kurva P. Ini menunjukkan bahwa model memberikan prediksi positif yang sebenarnya untuk semua kelas tanpa kesalahan (positif palsu).



Gambar 8. PR Curve

Kita dapat menganalisis PR Curve (Precision-Recall Curve) untuk melihat hubungan antara Recall (sensitivitas) dan Precision pada berbagai ambang batas (threshold). PR Curve akan memberikan gambaran tentang sejauh mana model dapat mempertahankan tingkat presisi yang konsisten saat Recall berubah. Dalam hal ini, karena kita memiliki nilai Precision yang sama untuk semua kelas, dengan membuat PR Curve yang umum untuk semua kelas. Pada PR Curve ini, Precision akan tetap


konstan pada nilai 0,932, sedangkan Recall akan bervariasi. Saat Recall meningkat, PR Curve akan menunjukkan bahwa Precision tetap konstan pada nilai 0,932. Artinya, model memiliki tingkat presisi yang konsisten terlepas dari perubahan Recall. Analisis PR Curve ini menunjukkan bahwa model dapat mempertahankan tingkat presisi yang tinggi (0,932) seiring dengan peningkatan Recall. Ini mengindikasikan kemampuan model untuk secara konsisten mengklasifikasikan sampel dengan tingkat presisi yang baik pada berbagai tingkat sensitivitas (Recall). Namun, perlu diperhatikan bahwa hasil ini didasarkan pada asumsi bahwa Precision untuk semua kelas adalah sama dan sebesar 0,932. Jika ada perbedaan nilai Precision antara kelas-kelas tersebut, hasil PR Curve akan berbeda.



Gambar 9. R Curve

Recall Confidence Curve dimana semua kelas memiliki recall 0,97 pada ambang 0,000, kita dapat menganalisis Kurva R (Recall Curve). Kurva R menunjukkan hubungan antara ambang batas (atau tingkat kepercayaan) dan penarikan kembali untuk masalah klasifikasi biner atau multikelas. Ini menunjukkan bagaimana nilai penarikan berubah saat ambang bervariasi. Namun, tampaknya nilai recall yang diberikan sebesar 0,97 untuk semua kelas pada ambang batas 0,000 menunjukkan perolehan yang sempurna untuk semua kelas pada ambang serendah mungkin. Ini berarti bahwa model mengidentifikasi dengan benar semua instance dari setiap kelas dalam kumpulan data, mencapai perolehan kembali 0,97. Dalam hal ini, Kurva R akan muncul sebagai garis horizontal pada nilai perolehan maksimum (1,0) untuk semua ambang batas. Ini menunjukkan bahwa terlepas dari nilai ambang batas, model secara konsisten mengidentifikasi semua instance dari setiap kelas, menghasilkan

penarikan kembali yang sempurna. Penting untuk diperhatikan bahwa nilai penarikan kembali 1,0 menunjukkan bahwa tidak ada negatif palsu, yang berarti model mengidentifikasi dengan benar semua contoh positif dari setiap kelas.



Gambar 10. Results

Berikut adalah analisis hasil result

1. train/box_loss = 0,7: menunjukkan nilai loss (kerugian) pada proses pelatihan untuk kotak pembatas (bounding box). Semakin rendah nilai loss, semakin baik model dapat mempelajari representasi yang akurat untuk kotak pembatas objek.
2. train/cls = 3,0: menunjukkan nilai loss (kerugian) pada proses pelatihan untuk klasifikasi. Semakin rendah nilai loss, semakin baik model dapat mempelajari klasifikasi yang akurat untuk objek.
3. train/df_loss = 1,30: menunjukkan nilai loss (kerugian) pada proses pelatihan untuk deteksi fitur skala kecil. Loss ini terkait dengan deteksi objek kecil atau deteksi fitur dengan ukuran yang lebih kecil. Semakin rendah nilai loss, semakin baik model dapat mendeteksi objek kecil dengan akurat.
4. metrics/precision = 0,8: precision adalah metrik yang mengukur seberapa akurat model dalam mengklasifikasikan sampel positif. Nilai precision 0,8 menunjukkan bahwa 80% dari prediksi positif yang dilakukan oleh model adalah benar.
5. metrics/recall = 0,9: recall adalah metrik yang mengukur seberapa baik model dalam menemukan semua sampel positif yang ada. Nilai recall 0,9 menunjukkan bahwa model berhasil

menemukan 90% dari semua sampel positif yang ada.

6. $\text{validasi/box} = 0,2$: menunjukkan nilai loss (kerugian) pada proses validasi untuk kotak pembatas (bounding box). Semakin rendah nilai loss, semakin baik model dapat mempertahankan performa yang baik dalam mendeteksi kotak pembatas objek saat diuji pada data validasi.
7. $\text{val/cls} = 5$: menunjukkan nilai loss (kerugian) pada proses validasi untuk klasifikasi. Semakin rendah nilai loss, semakin baik model dapat mempertahankan performa yang baik dalam mengklasifikasikan objek saat diuji pada data validasi.
8. $\text{val/df1} = 3,0$: menunjukkan nilai loss (kerugian) pada proses validasi untuk deteksi fitur skala kecil. Semakin rendah nilai loss, semakin baik model dapat mempertahankan performa yang baik dalam mendeteksi objek kecil saat diuji pada data validasi.
9. $\text{metrics/mAP50 (B)} = 0,8$: mAP50 (B) adalah metrik yang mengukur tingkat akurasi model dalam mendeteksi objek menggunakan IoU (Intersection over Union) threshold sebesar 0,5. Nilai mAP50 (B) 0,8 menunjukkan bahwa model memiliki tingkat akurasi sebesar 80% dalam mendeteksi objek pada IoU threshold 0,5.
10. $\text{metrics/mAP50-95 (B)} = 0,8$: mAP50-95 (B) adalah metrik yang mengukur tingkat akurasi model dalam mendeteksi objek menggunakan rentang IoU threshold dari 0,5 hingga 0,95. Nilai mAP50 95 (B) 0,8 menunjukkan bahwa model memiliki tingkat akurasi sebesar 80% dalam mendeteksi objek pada rentang IoU threshold 0,5 hingga 0,95.

Dalam keseluruhan, hasil-hasil yang diberikan menunjukkan kinerja model dalam pelatihan dan validasi. Namun, untuk memberikan analisis yang lebih komprehensif dan kontekstual, informasi tentang jenis model yang digunakan, data yang digunakan, serta metrik evaluasi lainnya juga perlu dipertimbangkan.




Gambar 11. Train Batch 0

1. Train Batch 0:

Cardboard: 38 sampel pada testing, 234 sampel pada training, dan 41 sampel pada validasi.

- a. Glass: Tidak ada informasi tentang sampel pada train batch 0 untuk kelas Glass.
- b. Metal: Tidak ada informasi tentang sampel pada train batch 0 untuk kelas Metal.
- c. Paper: Tidak ada informasi tentang sampel pada train batch 0 untuk kelas Paper.
- d. Plastic: Tidak ada informasi tentang sampel pada train batch 0 untuk kelas Plastic.
- e. Dengan informasi yang tersedia, kita hanya dapat melihat distribusi data untuk kelas Cardboard dalam train batch 0. Distribusi data yang baik dan seimbang antara sampel training, testing, dan validasi diperlukan untuk memastikan representasi yang akurat dari setiap kelas.



Gambar 12. Train Batch 1

2. Train Batch 1:

- Cardboard: Tidak ada informasi tentang sampel pada train batch 1 untuk kelas Cardboard.
- Glass: 53 sampel pada testing, 388 sampel pada training, dan 58 sampel pada validasi.
- Metal: Tidak ada informasi tentang sampel pada train batch 1 untuk kelas Metal.
- Paper: Tidak ada informasi tentang sampel pada train batch 1 untuk kelas Paper.
- Plastic: Tidak ada informasi tentang sampel pada train batch 1 untuk kelas Plastic.
- Dalam train batch 1, kita hanya memiliki informasi tentang distribusi data untuk kelas Glass. Distribusi data yang baik antara sampel training, testing, dan validasi pada kelas ini akan membantu dalam melatih model yang baik dan dapat menggeneralisasi dengan baik pada data yang tidak terlihat sebelumnya.



Gambar 13. Train Batch 2

3. Train Batch 2:

Cardboard: Tidak ada informasi tentang sampel pada train batch 2 untuk kelas Cardboard.

- Glass: Tidak ada informasi tentang sampel pada train batch 2 untuk kelas Glass.
- Metal: 40 sampel pada testing, 305 sampel pada training, dan 33 sampel pada validasi.

- Paper: 48 sampel pada testing, 478 sampel pada training, dan 54 sampel pada validasi.
- Plastic: Tidak ada informasi tentang sampel pada train batch 2 untuk kelas Plastic. Dalam train batch 2, kita memiliki informasi tentang distribusi data untuk kelas Metal dan Paper. Distribusi data yang baik antara sampel training, testing, dan validasi pada kelas-kelas ini akan membantu dalam melatih model yang mampu mengklasifikasikan sampel dengan akurasi tinggi.

Dalam keseluruhan, analisis train batch dapat memberikan wawasan tentang distribusi data pada setiap batch dan membantu memahami bagaimana model mungkin menghasilkan performa berdasarkan data yang diberikan. Namun, informasi yang lebih lengkap dan konsisten pada semua kelas akan memberikan gambaran yang lebih komprehensif.



Gambar 14. Val Batch 0 Pred

1. Validasi Batch 0:

- Cardboard: 38 sampel pada testing, 234 sampel pada training, dan 41 sampel pada validasi.
- Glass: 53 sampel pada testing, 388 sampel pada training, dan 58 sampel pada validasi.
- Metal: Tidak ada informasi tentang sampel pada validasi batch 0 untuk kelas Metal.
- Paper: Tidak ada informasi tentang sampel pada validasi batch 0 untuk kelas Paper.

- e. Plastic: Tidak ada informasi tentang sampel pada validasi batch 0 untuk kelas Plastic.

Dalam validasi batch 0, kita memiliki informasi tentang distribusi data untuk kelas Cardboard dan Glass. Distribusi data yang baik antara sampel testing dan training pada validasi batch ini akan membantu dalam memeriksa kinerja model pada data yang tidak terlihat sebelumnya. Dalam kasus ini, kita dapat menganalisis kinerja model untuk kelas Cardboard dan Glass pada validasi batch 0.



Gambar 15. Val Batch 1 Pred

2. Validasi Batch 1:

- a. Cardboard: Tidak ada informasi tentang sampel pada validasi batch 1 untuk kelas Cardboard.
- b. Glass: Tidak ada informasi tentang sampel pada validasi batch 1 untuk kelas Glass.
- c. Metal: 40 sampel pada testing, 305 sampel pada training, dan 33 sampel pada validasi.
- d. Paper: 48 sampel pada testing, 478 sampel pada training, dan 54 sampel pada validasi.
- e. Plastic: Tidak ada informasi tentang sampel pada validasi batch 1 untuk kelas Plastic. Dalam validasi batch 1, kita memiliki informasi tentang distribusi data untuk kelas Metal dan Paper. Distribusi data yang baik antara sampel testing dan training pada validasi batch ini akan membantu dalam memeriksa kinerja model untuk kelas Metal dan Paper pada data yang tidak terlihat sebelumnya.

Dalam keseluruhan, analisis validasi batch memberikan wawasan tentang distribusi data pada setiap batch dan membantu memahami kinerja model pada data validasi yang tidak terlihat sebelumnya. Namun, informasi yang lebih lengkap dan konsisten pada semua kelas akan memberikan gambaran yang lebih komprehensif.

Hasil Training Dataset



Gambar 16. Cardboard



Gambar 17. Glass



Gambar 18. Metal



Gambar 19. Paper



Gambar 20. Plastik

1. Cardboard: Dengan akurasi matriks sebesar 93%, model cenderung memiliki kinerja yang baik dalam mengklasifikasikan sampel sebagai cardboard. Akurasi sebesar ini menunjukkan bahwa sekitar 93% dari sampel yang diklasifikasikan sebagai cardboard adalah benar.
2. Glass: Dengan akurasi matriks sebesar 88%, model memiliki tingkat akurasi

yang baik dalam mengklasifikasikan sampel sebagai glass. Sekitar 88% dari sampel yang diklasifikasikan sebagai glass adalah benar.

3. Metal: Dengan akurasi matriks sebesar 85%, model memiliki tingkat akurasi yang baik dalam mengklasifikasikan sampel sebagai metal. Sekitar 85% dari sampel yang diklasifikasikan sebagai metal adalah benar.
4. Paper: Dengan akurasi matriks sebesar 80%, model memiliki tingkat akurasi yang sedikit lebih rendah dalam mengklasifikasikan sampel sebagai paper. Sekitar 80% dari sampel yang diklasifikasikan sebagai paper adalah benar.
5. Plastic: Dengan akurasi matriks sebesar 93%, model memiliki tingkat akurasi yang baik dalam mengklasifikasikan sampel sebagai plastic. Sekitar 93% dari sampel yang diklasifikasikan sebagai plastic adalah benar.

Hasil Website Paus Untuk Mendeteksi Jenis Sampah.



Gambar 21. Tampilan Dasar Web 1

Calon pengepul sampah diarahkan ke tampilan awal website dan melakukan pengujian sampel 2 kelas yaitu sampah organik dan non organik kemudian sistem CNN akan bekerja untuk mengklasifikasi kondisi sampah dari 5 jenis sampel. Menurut pengamatan kami hasil pengujian dari pemilahan sampah ini sudah cukup bagus dengan tingkat akurasi 88%



Gambar 22. Tampilan Dasar Web 2



Gambar 23. Pembelian Point Berkurang

Petugas menimbang sampah, menginput berat, dan jenis sampah yang akan tersimpan di sistem. Setelah sistem berhasil tersimpan, maka petugas menulis tanggal, debit, dan jumlah saldo di buku tabungan aplikasi nya. Kemudian pengepul sampah dapat melakukan transaksi pembelian dengan menukarkan hasil point dengan barang atau uang secara tunai.



Gambar 24. Pembelian Point Berhasil

Ditahap ini pengepul telah sukses mendapatkan point dan dapat ditukarkan baik bentuk uang atau barang sesuai dengan keinginan pengepul. Lalu sistem memeriksa isi form dan saldo, jika tidak sesuai, maka nasabah memperbaiki form pengambilan saldo. Dan jika sesuai maka petugas akan menyetujui pengambilan saldo yang telah ditarik.

B. Evaluation

Berdasarkan akurasi matriks yang Anda berikan (93% untuk Cardboard, 88% untuk Glass, 85% untuk Metal, 80% untuk Paper, dan 93% untuk Plastic), secara umum, dapat dikatakan bahwa model yang dikembangkan memiliki tingkat akurasi yang cukup baik dalam mengklasifikasikan sampah organik dan non-organik. Namun, dalam penelitian ini, selain akurasi matriks, ada beberapa metrik evaluasi lain yang umumnya digunakan dalam masalah klasifikasi, seperti presisi (precision), recall, dan F1-score, yang dapat memberikan pemahaman yang lebih lengkap tentang kinerja model. Presisi mengukur persentase sampel yang diklasifikasikan dengan benar sebagai suatu kelas tertentu dari total sampel yang diklasifikasikan sebagai kelas tersebut. Recall mengukur persentase sampel yang diklasifikasikan dengan benar sebagai suatu kelas tertentu dari total jumlah sampel yang sebenarnya adalah kelas tersebut. F1-score adalah ukuran gabungan dari presisi dan recall yang memberikan gambaran keseluruhan tentang kinerja model. Berikut adalah beberapa kemungkinan kekurangan yang perlu dipertimbangkan:

1. Ukuran Dataset: Salah satu kekurangan yang umum dalam penelitian klasifikasi adalah ukuran dataset yang terbatas. Jumlah sampel yang dikumpulkan sebanyak 2.224 gambar mungkin belum cukup besar untuk melatih model yang sangat akurat. Semakin besar dataset yang digunakan, semakin baik model dapat mempelajari pola-pola yang ada dalam data.
2. Ketidakseimbangan Kelas: Jika terdapat ketidakseimbangan yang signifikan antara jumlah sampel pada kelas organik dan non-organik, ini dapat menyebabkan bias dalam model. Misalnya, jika jumlah sampel untuk kelas organik lebih sedikit daripada kelas non-organik, model mungkin memiliki kinerja yang lebih baik dalam mengklasifikasikan sampel non-organik daripada organik.
3. Kualitas Data dan Anotasi: Penting untuk memastikan kualitas dataset dan anotasi yang akurat. Jika ada kesalahan

atau ketidaktepatan dalam anotasi data, ini dapat mempengaruhi kualitas dan keandalan model yang dihasilkan.

4. Validasi dan Generalisasi: Evaluasi yang komprehensif dari model melibatkan pengujian pada dataset pengujian yang tidak pernah dilihat sebelumnya untuk memeriksa kemampuan model dalam menggeneralisasi pada data yang baru. Penting untuk memastikan bahwa dataset pengujian dan validasi mewakili variasi yang mencakup semua kemungkinan situasi dan kategori sampah yang dihadapi di dunia nyata.
5. Tuning Hyperparameter: Proses tuning hyperparameter model merupakan langkah penting untuk memperoleh kinerja yang optimal. Pengaturan yang tepat dari hyperparameter seperti learning rate, jumlah epoch, dan ukuran batch dapat mempengaruhi kinerja model. Penting untuk melakukan eksperimen dengan berbagai konfigurasi dan memperhatikan kinerja model untuk memperoleh hasil yang lebih baik.
6. Tingkat Kinerja yang Diharapkan: Meskipun akurasi matriks yang tinggi merupakan indikator positif, terkadang akurasi saja tidak cukup untuk mengevaluasi kualitas model. Metrik evaluasi lain seperti presisi, recall, dan F1-score memberikan informasi yang lebih detail tentang kinerja model pada masing-masing kelas. Penting untuk mempertimbangkan metrik evaluasi ini secara menyeluruh. Dalam setiap penelitian, ada potensi kekurangan dan aspek yang dapat ditingkatkan. Penting untuk menyadari keterbatasan penelitian dan berusaha untuk memperbaikinya dengan perbaikan berkelanjutan dan eksperimen lebih lanjut.

5. KESIMPULAN

1. Penelitian ini berhasil mengembangkan siste
2. m klasifikasi sampah organik dan non-organik menggunakan metode **Convolutional Neural Network (CNN)** dengan arsitektur **VGG-16**, yang diimplementasikan melalui framework **Flask**.
3. Sistem yang dibangun mampu melakukan klasifikasi gambar sampah ke dalam dua kategori utama (organik dan non-organik) dengan **tingkat akurasi mencapai 88%**, dan akurasi tertinggi pada kelas tertentu seperti cardboard dan plastic mencapai **93%**.
4. Implementasi sistem dalam bentuk web memberikan kemudahan bagi pengguna dalam melakukan pengujian gambar sampah secara langsung, sekaligus mendukung integrasi dengan sistem distribusi bank sampah.
5. Evaluasi performa model menggunakan metrik seperti **precision, recall, F1-score**, dan **mAP50-95** menunjukkan hasil yang stabil dan baik dalam pengenalan citra pada sebagian besar kelas.
6. Secara umum, sistem ini memberikan dasar yang kuat untuk penerapan teknologi **kecerdasan buatan (AI)** dalam pengelolaan sampah dan dapat menjadi solusi inovatif dalam mendukung lingkungan yang lebih bersih dan berkelanjutan.
7. Beberapa keterbatasan yang masih ditemukan meliputi:
 - Ukuran dataset yang relatif kecil (2.224 gambar).
 - Ketidakseimbangan distribusi data pada beberapa kelas.
 - Kesulitan dalam mengenali sampah organik karena keragamannya yang tinggi.

UCAPAN TERIMA KASIH

Dengan segala kerendahan hati, penulis menyampaikan ucapan terima kasih dan

penghargaan yang sebesar-besarnya kepada **Ibu Ulinuha Latifa, S.T., M.T.**, selaku dosen pembimbing, yang telah memberikan bimbingan, arahan, dan masukan yang sangat berharga selama proses penyusunan, pelaksanaan, hingga penyelesaian penelitian ini. Dedikasi, kesabaran, dan ketelitian beliau dalam membimbing sangat membantu penulis dalam memahami materi dan menyusun karya ilmiah ini secara sistematis dan ilmiah.

Penulis juga menyampaikan apresiasi kepada **Bapak Ibrahim, S.T., M.T.**, **Bapak Edmun Ucok Armin, S.T., M.Eng.**, dan **Bapak Dicki Dian Purnama, S.T., M.T.** selaku dosen pengampu mata kuliah Final Proyek Literasi Digital atas ilmu, dukungan, dan motivasi yang telah diberikan sepanjang perkuliahan. Tanpa arahan dan semangat yang diberikan, penelitian ini tidak akan terselesaikan dengan baik.

Ucapan terima kasih juga disampaikan kepada **Program Studi Teknik Elektro, Fakultas Teknik, Universitas Singaperbangsa Karawang**, atas segala fasilitas, dukungan teknis, dan lingkungan akademik yang kondusif sehingga pelaksanaan penelitian dapat berjalan lancar.

Tak lupa, penulis mengucapkan terima kasih kepada seluruh anggota **Kelompok Paus**, atas kerja sama, dedikasi, dan kontribusi aktif dalam setiap tahap pengerjaan proyek ini. Semangat kebersamaan dan tanggung jawab tim menjadi salah satu faktor utama keberhasilan tugas ini.

Akhir kata, semoga penelitian ini dapat memberikan kontribusi positif dalam pengembangan teknologi klasifikasi sampah berbasis kecerdasan buatan, serta menjadi dasar bagi penelitian lanjutan di masa yang akan datang.

DAFTAR PUSTAKA

- [1] R. Kurniawan, P. B. Wintoro, Y. Mulyani, and M. Komarudin, "IMPLEMENTASI ARSITEKTUR XCEPTION PADA MODEL MACHINE LEARNING KLASIFIKASI SAMPAH ANORGANIK," *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 2, Apr. 2023, doi: 10.23960/jitet.v11i2.3034.
- [2] H. O. Sawyerr, A. T. Adeolu, A. S. Afolabi, O. O. Salami, and B. K. Badmos, "Impact of Dumpsites on the Quality of Soil and Groundwater in Satellite Towns of the Federal Capital Territory, Abuja, Nigeria," *J. Heal. Pollut.*, vol. 7, no. 14, pp. 15–22, Jun. 2017, doi: 10.5696/2156-9614-7.14.15.
- [3] N. Ferronato and V. Torretta, "Waste Mismanagement in Developing Countries: A Review of Global Issues," *Int. J. Environ. Res. Public Health*, vol. 16, no. 6, p. 1060, Mar. 2019, doi: 10.3390/ijerph16061060.
- [4] Y. Y. Priatna, B. J. Tarigan, M. F. Triputra, and I. Kustiwan, "Penerapan kerangka kerja DPSIR terhadap sampah dan dampaknya pada lingkungan di Kawasan Wisata Pantai Pangandaran," *J. Pengelolaan Lingkung. Berkelanjutan (Journal Environ. Sustain. Manag.)*, pp. 307–325, Dec. 2024, doi: 10.36813/jplb.8.3.307-325.
- [5] J. Jumakil, Y. Sabilu, L. Tina, Y. Yuslina, R. Majid, and A. Zainuddin, "PEMBUANGAN SAMPAH DAN DAMPAKNYA TERHADAP MASYARAKAT DI KOTA BAU-BAU PROVINSI SULAWESI TENGGARA," *Prev. J.*, vol. 4, no. 1, Nov. 2019, doi: 10.37887/epj.v4i1.9430.
- [6] D. Rahayona, E. Sunarsih, K. F. Egit, N. D. Azzarah, S. A. Rahmah, and T. P. Kartika, "Analisis Kualitas Lingkungan dan Dampaknya Terhadap Masyarakat di Sekitar TPA Sukawinatan Palembang," *Hig. J. Kesehat. Lingkung.*, vol. 9, no. 2, pp. 64–69, Jan. 2024, doi: 10.24252/higiene.v9i2.36459.
- [7] C. Xu, K. Wang, Y. Sun, S. Guo, and A. Y. Zomaya, "Redundancy Avoidance for Big Data in Data Centers: A Conventional Neural Network Approach," *IEEE Trans. Netw. Sci. Eng.*, vol. 7, no. 1, pp. 104–114, Jan. 2020, doi: 10.1109/TNSE.2018.2843326.
- [8] C. Ashwini and V. Sellam, "EOS-3D-DCNN: Ebola optimization search-based 3D-dense convolutional neural network for corn leaf disease prediction," *Neural Comput. Appl.*, vol. 35, no. 15, pp. 11125–11139, May 2023, doi: 10.1007/s00521-023-08289-3.
- [9] R. A. Fahriza, "SISTEM PENCARIAN WISATA PUNCAK GUNUNG INDONESIA BERBASIS WEB MENGGUNAKAN FRAMEWORK FLASK PYTHON," *JIKA (Jurnal Inform.)*, vol. 8, no. 3, p. 253, Jul. 2024, doi: 10.31000/jika.v8i3.10567.
- [10] M. Sholeh, W. L. Aji, Y. Riady, and B. L. Qasthari, "Pengelolaan Pemesanan Menu Makanan Menggunakan Framework Flask Python," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 9, no. 2, pp. 916–929, Jun. 2022, doi: 10.35957/jatisi.v9i2.1459.
- [11] R. K. Ngantung and M. A. I. Pakereng, "Model Pengembangan Sistem Informasi Akademik Berbasis User Centered Design Menerapkan Framework Flask Python," *J. MEDIA Inform. BUDIDARMA*, vol. 5, no. 3, p. 1052, Jul. 2021,

doi: 10.30865/mib.v5i3.3054.

- [12]D. J. Evan and P. O. N. Saian,
“IMPLEMENTASI PYTHON FRAMEWORK
FLASK PADA MODUL TRANSFER OUT
TOKO DI PT XYZ,” *JIPi (Jurnal Ilm. Penelit.
dan Pembelajaran Inform.*, vol. 8, no. 4, pp.
1121–1131, Nov. 2023, doi:
10.29100/jipi.v8i4.4020.