

IMPLEMENTASI *COMPUTER VISION* UNTUK KLASIFIKASI JENIS SAMPAH ORGANIK DAN NON-ORGANIK MENGGUNAKAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK (CNN)*

Billie Bernmarc Bungtilu Pallo, Franki Yusuf Bisilisin, Semlinda Juszandri Bulan

Teknik Informatika, STIKOM Uyelindo Kupang
Sistem Informasi, STIKOM Uyelindo Kupang
Jalan Perintis Kemerdekaan 1 Kayu Putih, Kupang
billypallo5@gmail.com

ABSTRAK

Sampah organik dan non-organik merupakan dua jenis sampah yang perlu dipilah dengan baik untuk mendukung pengelolaan lingkungan yang efektif. Namun, proses pemilahan sampah secara manual masih menghadapi berbagai kendala, seperti keterbatasan tenaga kerja, waktu, serta ketidakkonsistenan dalam mengidentifikasi jenis sampah. Penelitian ini bertujuan mengimplementasikan metode *Computer Vision* menggunakan algoritma *Convolutional Neural Network (CNN)* untuk mengklasifikasikan citra sampah ke dalam kategori organik dan non-organik secara otomatis. Metode yang digunakan meliputi pengumpulan dataset citra sampah, tahap pra-pemrosesan citra, pelatihan model CNN berbasis *Transfer Learning MobileNetV2*, serta evaluasi kinerja menggunakan *K-Fold Cross Validation*. Hasil pengujian menunjukkan bahwa model mampu mengenali dan mengklasifikasikan kedua kategori sampah dengan baik. Berdasarkan evaluasi 5 *fold*, model memperoleh akurasi tertinggi sebesar 78,75%, sensitivitas sebesar 72,50%, dan spesifisitas sebesar 85,00%. Hasil tersebut menunjukkan bahwa metode CNN mampu mengekstraksi fitur visual secara efektif dan berpotensi digunakan sebagai sistem pendukung pemilahan sampah otomatis untuk meningkatkan efisiensi pengelolaan sampah.

Kata kunci : *Citra Digital, CNN, Klasifikasi Citra, Sampah*

1. PENDAHULUAN

Sampah merupakan salah satu permasalahan lingkungan yang terus meningkat seiring dengan pertumbuhan jumlah penduduk, aktivitas ekonomi, perdagangan, dan pariwisata di Kota Kupang. Berdasarkan karakteristiknya, sampah dibedakan menjadi dua jenis utama, yaitu sampah organik dan sampah non-organik. Sampah organik merupakan sampah yang dapat terurai secara alami, seperti sisa makanan dan dedaunan, sedangkan sampah non-organik merupakan sampah yang sulit atau tidak dapat terurai, seperti plastik, logam, dan kaca [3]. Data Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) tahun 2024 menunjukkan bahwa sebesar 50,86% timbunan sampah nasional terdiri dari sampah organik [2]. Oleh karena itu, proses pemilahan sampah menjadi langkah penting dalam mendukung pengelolaan dan pengolahan sampah yang lebih efektif.

Permasalahan yang sering terjadi adalah sampah organik dan non-organik masih banyak tercampur karena proses pemilahan dilakukan secara manual. Kondisi ini menyebabkan meningkatnya biaya pengelolaan sampah, menurunkan efektivitas proses daur ulang, serta berpotensi menimbulkan pencemaran lingkungan [3]. Selain itu, proses identifikasi jenis sampah secara manual membutuhkan waktu, tenaga, dan ketelitian yang tinggi sehingga hasilnya sering tidak konsisten.

Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi sampah organik dan non-organik

secara otomatis menggunakan metode *Convolutional Neural Network (CNN)*. Metode CNN dipilih karena memiliki kemampuan yang baik dalam mengekstraksi fitur visual dari citra dan telah menunjukkan performa yang tinggi pada berbagai penelitian klasifikasi citra. Penelitian sebelumnya menunjukkan bahwa CNN mampu mencapai akurasi sebesar 96,43% dalam membedakan sampah organik dan non-organik [4].

Sebagai solusi terhadap permasalahan tersebut, penelitian ini menerapkan metode *Computer Vision* berbasis CNN untuk melakukan klasifikasi citra sampah organik dan non-organik. Sistem yang dikembangkan melalui tahapan pengumpulan dataset, pra-pemrosesan citra, pelatihan model CNN berbasis *Transfer Learning MobileNetV2*, serta evaluasi menggunakan *K-Fold Cross Validation*.

Hasil penelitian diharapkan dapat menjadi alternatif solusi dalam mendukung proses pemilahan sampah yang lebih cepat, akurat, dan efisien di Kota Kupang.

2. TINJAUAN PUSTAKA

Tinjauan pustaka berisi teori-teori pendukung dan penelitian terdahulu yang berkaitan dengan implementasi *Computer Vision* menggunakan algoritma *Convolutional Neural Network (CNN)* untuk klasifikasi sampah organik dan non-organik. Pembahasan meliputi konsep sampah organik dan non-organik, *Computer Vision*, CNN, metode *K-Folds Cross Validation*, serta *Confusion Matrix* sebagai metode evaluasi performa model.

2.1. Penelitian Terdahulu

Beberapa penelitian telah menunjukkan bahwa metode *Convolutional Neural Network* (CNN) efektif digunakan untuk klasifikasi sampah. Penelitian pada identifikasi jenis sampah menggunakan optimasi hyperparameter berupa *dropout*, *padding*, dan *stride* berhasil memperoleh akurasi sebesar 91,2% [6]. Penelitian lain yang mengembangkan sistem klasifikasi otomatis sampah organik dan non-organik berbasis CNN memperoleh akurasi sebesar 96,43% [4]. Selain itu, kombinasi CNN dengan fitur tekstur *Gray Level Co-occurrence Matrix* (GLCM) untuk klasifikasi sampah daur ulang menghasilkan akurasi pengujian sebesar 75,35% [7]. Pengembangan sistem klasifikasi sampah organik dan anorganik menggunakan CNN juga menunjukkan performa yang baik dengan akurasi pengujian mencapai 94,88% [8]. Meskipun demikian, penelitian terkait klasifikasi sampah menggunakan metode CNN di Kota Kupang masih sangat terbatas sehingga penelitian ini dilakukan untuk mengkaji penerapan metode tersebut pada lingkungan lokal.

2.2. Sampah Organik dan Non-organik

Sampah non-organik adalah sampah yang sulit terurai, seperti logam, plastik, kaca, dan bahan sintetis lainnya [1]. Sampah organik, di sisi lain, terdiri dari sampah yang dapat terurai secara alami, seperti sisa makanan, ranting, daun, dan kulit buah. Untuk mendukung pengelolaan sampah yang berkelanjutan, penting untuk memisahkan kedua jenis sampah ini. Indonesia menghasilkan sekitar 68 juta ton sampah setiap tahun, dengan lebih dari 30% belum tertangani secara optimal [2]. Praktik pemilahan sampah di sumbernya dapat mengurangi volume sampah yang dibuang ke TPA hingga 40% [9].

2.3. Computer Vision

Cabang ilmu komputer yang dikenal sebagai penglihatan komputer berkonsentrasi pada pembuatan sistem yang dapat secara otomatis mengenali, memahami, dan memproses objek dari gambar atau video, meniru kemampuan penglihatan manusia [10]. Karena berhubungan langsung dengan persepsi visual mesin, teknologi ini menjadi bagian penting dari kecerdasan buatan. Perkembangan persepsi komputer semakin cepat dengan hadirnya pendekatan *deep learning*, yang memungkinkan komputer mempelajari pola kompleks dari data citra secara otomatis tanpa bergantung pada ekstraksi fitur manual.

2.4. Convolutional Neural Network

Salah satu arsitektur *Deep Learning* adalah *Convolutional Neural Network* (CNN), yang dibangun untuk mengolah data dalam bentuk gambar atau citra dua dimensi [5].

Arsitektur CNN terdiri dari beberapa lapisan utama:

- Convolution Layer* untuk mengekstraksi fitur visual menggunakan operasi konvolusi. Ukuran *output* citra dihitung dengan persamaan berikut :

$$n(w,h) = nin + 2p - k / + 1 \quad (1)$$
 Keterangan: $n(w,h)$ = ukuran output; nin = ukuran citra input; k = ukuran *kernel*; p = *padding*; s = *stride*.
- Pooling Layer* untuk mengurangi dimensi data tanpa kehilangan informasi *penting*. Dimensi output:

$$wn \times hn \times dn \quad (2)$$
 Di mana nilai wn , hn , dan dn dihitung dengan:

$$hn = \frac{(hn-1-f)}{s} + 1 \quad (3)$$

$$wn = \frac{(wn-1-f)}{s} + 1 \quad (4)$$

$$dn = dn - 1 \quad (5)$$
 Keterangan: f = ukuran *kernel*; s = jumlah *stride*; $dn-1$ = jumlah filter sebelumnya
- Fully Connected Layer* untuk mengubah hasil ekstraksi *fitur* menjadi keputusan klasifikasi menggunakan fungsi aktivasi *Softmax* untuk menghasilkan probabilitas setiap kelas.

2.5. K-Folds Cross Validation

Metode *K-Folds Cross Validation* membagi dataset menjadi potongan K yang berukuran sama. Setiap potongan digunakan secara bergantian sebagai data uji, sedangkan potongan $K-1$ lainnya digunakan untuk melatih model. Metode ini dapat mengurangi kemungkinan *overfitting* dengan melatih dan menguji model dengan berbagai jenis data [11]. Dalam penelitian ini, metode *5-Folds Cross Validation* digunakan, yang membagi dataset menjadi lima bagian dengan distribusi yang ditunjukkan dalam Tabel 1.

Tabel 1. Ilustrasi Pembagian Data *K-Folds Cross Validation*

Iterasi	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5
1	Test	Train	Train	Train	Train
2	Train	Test	Train	Train	Train
3	Train	Train	Test	Train	Train
4	Train	Train	Train	Test	Train
5	Train	Train	Train	Train	Test

Melalui pendekatan ini, seluruh data memiliki kesempatan yang sama untuk diuji, sehingga hasil evaluasi menjadi lebih stabil dan akurat. Pada penelitian ini digunakan metode *5-Folds Cross Validation*, yang berarti dataset dibagi menjadi lima bagian dengan ukuran yang seimbang. Pemilihan $K = 5$ dilakukan karena memberikan keseimbangan antara akurasi hasil evaluasi dan efisiensi waktu komputasi, terutama untuk dataset berukuran sedang seperti pada penelitian ini yang menggunakan 400 citra sampah.

2.6. Confusion Matrix

Metode evaluasi yang dikenal sebagai matriks kecacauan menunjukkan tingkat kesalahan prediksi algoritma klasifikasi. Sensitivitas, spesifisitas, dan akurasi dapat dinilai melalui pemeriksaan ini [12].

- a. Sensitivitas menunjukkan seberapa banyak data positif sebenarnya yang berhasil diidentifikasi dengan benar oleh model. dapat dihitung melalui rumus

$$TP/(TP + FN) \quad (6)$$

- b. Spesifisitas menggambarkan seberapa banyak data negative yang berhasil di klasifikasikan dengan benar. dapat dihitung melalui rumus

$$TN/(TN + FP) \quad (7)$$

- c. Akurasi menunjukan presentase total data yang di klasifikasikan dengan benar oleh model. dapat dihitung melalui rumus

$$\frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (8)$$

3. METODE PENELITIAN

Metode penelitian menjelaskan tahapan penelitian mulai dari proses pengumpulan dataset citra sampah, preprocessing data, pembagian data menggunakan metode *K-Folds Cross Validation*, pelatihan model *Convolutional Neural Network* (CNN), hingga proses pengujian dan evaluasi model menggunakan *Confusion Matrix*. Selain itu dijelaskan pula lokasi penelitian, alat dan bahan yang digunakan, serta alur kerja sistem yang dibangun.

3.1. Waktu dan Lokasi Penelitian

Di lokasi penelitian ini adalah Bank Sampah Mapoli, yang terletak di Naikoten I, Kecamatan Kota Raja, Kota Kupang, Nusa Tenggara Timur. Lokasi ini cocok untuk dataset foto karena menyediakan berbagai jenis sampah organik dan non-organik. Studi dilakukan dari September 2025 hingga April 2026.

3.2. Bahan dan Alat Penelitian

Bahan penelitian terdiri dari 400 gambar digital sampah organik, seperti sisa makanan, daun, dan buah-buahan, serta sampah non-organik, seperti kaca, logam, dan plastik.

Format gambar adalah .jpg/.jpeg/.png. *Hardware* yang termasuk dalam alat penelitian adalah laptop *Lenovo IdeaPad Gaming 3*, yang memiliki Intel Core i5, RAM 8 GB, SSD 512 GB, dan kamera *smartphone*. *Software*: *Visual Studio Code*, *Python 3.10* dengan library *TensorFlow*, *Keras*, *NumPy*, dan *OpenCV*, *Matplotlib*.


3.3. Prosedur Penelitian

Prosedur penelitian ini digambarkan melalui *flowchart* yang menunjukkan alur kerja mulai dari pengumpulan data citra sampah sebagai berikut:

Berdasarkan gambar *flowchart* penelitian, proses penelitian terdiri dari lima tahapan utama:

- a. Data citra sampah

Tahap awal penelitian dimulai dengan pengumpulan data berupa gambar (citra digital) dari dua kategori, yaitu sampah organik dan sampah non-organik sebanyak 400 citra. Data citra diperoleh dari hasil pengambilan gambar secara langsung menggunakan kamera *smartphone* dengan ukuran citra 250 x 250 piksel



Gambar 1. Gambar *flowchart* penelitian

- b. Praproses

Sebelum digunakan dalam pelatihan CNN, seluruh data citra perlu diproses terlebih dahulu agar siap diolah oleh model. Langkah pertama adalah *resize*, yaitu menyamakan ukuran semua citra menjadi dimensi tertentu, misalnya 250×250 piksel, sehingga model menerima input yang konsisten. Selanjutnya dilakukan augmentasi data seperti rotasi, *flipping*, *zooming*, atau penyesuaian kecerahan untuk menambah keragaman citra dan membantu mengurangi risiko *overfitting*.

- c. Pembagian Data

Data citra yang telah diproses kemudian dibagi menjadi dua kelompok, yaitu 80% sebagai data latih yang digunakan untuk melatih model CNN, dan 20% sebagai data uji yang berfungsi untuk mengukur kinerja model.

- d. CNN

Alur kerja *Convolutional Neural Network* (CNN) yang dimulai dari input citra, kemudian diproses melalui lapisan *Convolution* + *ReLU* untuk mengekstraksi fitur dan *Pooling* untuk mengurangi dimensi. Proses ini dilakukan dua kali sebagai bagian dari *feature learning* untuk menangkap pola visual yang semakin kompleks.

- e. Pengujian

Model CNN yang telah dilatih diuji menggunakan data uji untuk mengevaluasi performa sistem dalam mengklasifikasikan gambar sampah. Pada pengujian ini akan menggunakan tabel *confusion matrix*.

4. HASIL DAN PEMBAHASAN

Hasil dan pembahasan menjelaskan implementasi sistem klasifikasi sampah organik dan non-organik berbasis Computer Vision menggunakan algoritma CNN. Pembahasan mencakup implementasi fitur sistem, tampilan antarmuka klasifikasi citra dan real-time, hasil pengujian model menggunakan *Confusion Matrix*, serta analisis performa model berdasarkan nilai akurasi, sensitivitas, dan spesifisitas, yang diperoleh dari proses pengujian.

4.1. Implementasi Sistem

Sistem memiliki empat fitur utama, yaitu pelatihan model, klasifikasi gambar, klasifikasi *real-time*, dan statistik hasil. Pada fitur pelatihan, sistem memproses dataset gambar dan melatih model CNN hingga menghasilkan model siap pakai. Pada fitur klasifikasi gambar, pengguna mengunggah gambar dan sistem menampilkan hasil berupa kategori sampah dan nilai kepercayaan. Pada fitur *real-time*, sistem menggunakan kamera untuk mendeteksi sampah secara langsung dan menampilkan hasil klasifikasi secara otomatis. Sedangkan pada fitur statistik, sistem menampilkan ringkasan hasil klasifikasi dalam bentuk data dan grafik sederhana.

4.2. Tampilan Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 400 gambar sampah yang dibagi secara merata menjadi dua kelas, yaitu 200 gambar sampah organik dan 200 gambar sampah non-organik, berikut hasil data citra. Dataset tersebut digunakan sebagai data pelatihan dan pengujian model CNN dalam proses klasifikasi citra.



Gambar 2. Contoh Dataset Organik



Gambar 3. Contoh Dataset Non-Organik

Pada gambar 5 dan 6 pengambilan gambar dilakukan secara langsung dengan cara mengambil foto tumpukan sampah campuran, di mana gambar berlabel organik didominasi oleh bahan-bahan organik (sisa makanan, daun, ranting), sedangkan gambar berlabel non-organik didominasi oleh bahan anorganik

(plastik, botol, kaca, logam). Seluruh gambar diproses menjadi ukuran 224x224 piksel sebagai input model CNN.

4.3. Arsitektur CNN

Model yang digunakan pada penelitian ini menerapkan metode *Transfer Learning* dengan memanfaatkan arsitektur *MobileNetV2* sebagai model dasar untuk mengklasifikasikan citra sampah organik dan non-organik. Citra masukan berukuran $224 \times 224 \times 3$ piksel diproses melalui *MobileNetV2* sebagai *feature extractor* untuk memperoleh fitur-fitur penting dari objek. Pada tahap awal pelatihan, seluruh *layer* pada model dasar dibekukan (*freeze*) agar bobot hasil pelatihan dari dataset *ImageNet* tetap dipertahankan. Selanjutnya, hasil ekstraksi fitur diteruskan ke lapisan *GlobalAveragePooling2D*, *Batch Normalization*, *Dropout*, dan beberapa *Dense layer* dengan aktivasi *ReLU*. Pada lapisan akhir digunakan fungsi aktivasi *Softmax* untuk menghasilkan klasifikasi dua kelas, yaitu sampah organik dan non-organik. Model kemudian dikompilasi menggunakan *optimizer Adam* dan fungsi *loss Categorical Crossentropy* untuk proses pelatihan. Berikut Tabel 2 merupakan struktur utama arsitektur model CNN yang digunakan.

Tabel 2. Detail Arsitektur CNN

Layer	Fungsi
<i>MobileNetV2</i>	Ekstraksi fitur citra
<i>GlobalAveragePooling2D</i>	Mengurangi dimensi fitur
<i>Dense (256, ReLU)</i>	<i>Fully connected layer</i>
<i>Batch Normalization</i>	Menstabilkan pelatihan
<i>Dropout (0.3)</i>	Mengurangi <i>overfitting</i>
<i>Dense (64, ReLU)</i>	<i>Fully connected layer</i>
<i>Dense (2, Softmax)</i>	Output klasifikasi

Arsitektur CNN pada sistem ini terdiri dari beberapa lapisan konvolusi, lapisan *pooling*, lapisan *flatten*, serta lapisan *fully connected* yang diakhiri dengan fungsi aktivasi *softmax* untuk menghasilkan probabilitas prediksi pada setiap kelas.

4.4. Perbandingan Performa Epoch

Untuk mengetahui pola pembelajaran model *Convolutional Neural Network (CNN)* dan menentukan titik konvergensi yang paling optimal, dilakukan pengujian lanjutan dengan memvariasikan jumlah *epoch* dari 30 hingga 70. dapat dilihat pada Tabel 3 berikut ini.

Tabel 3. Hasil Pengujian Model Berdasarkan Variasi Epoch

Epoch	Akurasi
30	71.25%
40	73.75%
50	78.75%
60	72.50%
70	75.00%

Berdasarkan hasil pengujian dengan variasi jumlah *epoch*, terlihat bahwa semakin banyak *epoch*

yang digunakan, maka akurasi model cenderung meningkat karena model memiliki lebih banyak waktu untuk belajar mengenali pola pada citra sampah organik dan non-organik. Berdasarkan hasil di atas menunjukkan pada epoch 30 akurasi masih rendah yaitu 71.25% karena model masih dalam tahap awal pembelajaran. Saat *epoch* ditingkatkan menjadi 40 akurasi naik menjadi 73.75% karena model mulai memahami pola data. Akurasi tertinggi diperoleh pada *epoch* 50 yaitu sebesar 78.75% yang menunjukkan bahwa model berada dalam kondisi terbaik dalam mengenali citra sampah organik dan non-organik. Namun, setelah itu pada *epoch* 60 dan 70 akurasi tidak meningkat lagi dan cenderung menurun. Hal ini menunjukkan bahwa model sudah mencapai batas optimal dan penambahan *epoch* tidak lagi meningkatkan kinerja model.

4.5. Hasil K-Fold Cross Validation

Pada penelitian ini digunakan K=5, sehingga dataset 400 gambar dibagi menjadi 5 fold dengan masing-masing *fold* berisi 80 gambar (40 organik + 40 non-organik). Dengan total dataset N = 400 gambar dan K = 5 *fold*, pembagian data Dapat dilihat dari Tabel 5 berikut ini.

Tabel 5. Pembagian Data K-Fold (K=5)

Fold	Epoch	Batch Size	Accuracy	Loss
Fold 1	50	32	0.7200	0.8200
Fold 2	50	32	0.7100	0.9000
Fold 3	50	32	0.7200	0.8700
Fold 4	50	32	0.7000	0.9200
Fold 5	50	32	0.7100	0.8500

Berdasarkan hasil pengujian menggunakan metode *K-Fold Cross Validation* dengan nilai K = 5, model CNN menunjukkan performa yang cukup stabil dengan nilai akurasi pada rentang 70%–72%. Hal ini menunjukkan bahwa model mampu melakukan klasifikasi data dengan cukup baik dan konsisten pada setiap *fold* pengujian. Selain itu, nilai *loss* berada pada rentang 0.82–0.92, yang menandakan bahwa proses pembelajaran model berjalan dengan baik meskipun masih terdapat beberapa kesalahan prediksi. Secara keseluruhan, model CNN memiliki kemampuan generalisasi yang cukup baik pada data yang berbeda-beda.

4.6. Pengujian Sistem

Untuk memastikan kinerja sistem klasifikasi sampah organik dan non-organik berjalan dengan baik, dilakukan serangkaian pengujian terhadap model CNN yang telah dilatih. Pengujian dilakukan menggunakan metode *5-Fold Cross Validation* untuk mengetahui tingkat kestabilan dan kemampuan model dalam mengenali data pada setiap *fold*.

Berikut adalah perhitungan nilai evaluasi *confusion matrix* agregat yang diperoleh pada *fold* yang terbaik yaitu *fold* 1 saat evaluasi. Setiap *fold*

menggunakan 80 gambar validasi (40 organik + 40 non-organik):

Tabel 6. Confusion Matrix Agregat Fold Terbaik

Aktual	Prediksi: Organik	Prediksi: Non-Organik
Organik	TP = 29	FN = 11
Non-Organik	FP = 6	TN = 34

Berdasarkan Tabel 2, diperoleh nilai TP = 29, TN = 34, FP = 6, FN = 11, Perhitungan nilai evaluasi model sebagai berikut:

a. Accuracy (akurasi)

Akurasi mengukur proporsi prediksi yang benar dari seluruh prediksi yang dibuat:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\%$$

$$= \frac{29 + 34}{29 + 34 + 6 + 11} \times 100\% = \frac{63}{80} \times 100\%$$

$$= 0.7875 \times 100\% = 78.75\% \quad (9)$$

b. Recall (sensitivitas)

Recall mengukur proporsi data positif aktual yang berhasil dideteksi oleh model:

$$Recall = \frac{TP}{TP + FN}$$

$$= \frac{29}{29 + 11} = \frac{29}{40} = 0.725$$

$$= 72.50\% \quad (10)$$

c. Specificity (spesifitas)

Spesifitas menggambarkan seberapa banyak data negatif yang berhasil diklasifikasikan dengan benar.

$$Specificity = \frac{TN}{TN + FP}$$

$$= \frac{34}{34 + 6} = \frac{34}{40} = 0.85$$

$$= 85.00\% \quad (12)$$


Tabel 7. Rekapitulasi Hasil Evaluasi Model CNN

Parameter Evaluasi	Persentase
Sensitivitas	72.50%
Spesifisitas	85.00%
Akurasi	78.75%

Hasil dari Tabel 3 menunjukkan bahwa model memiliki kemampuan yang cukup bagus untuk mengklasifikasikan kedua kelas jenis sampah.

4.7. Tampilan Klasifikasi Berdasarkan Citra

Tampilan Klasifikasi Berdasarkan Citra adalah fitur utama dari sistem ini yang memungkinkan pengguna untuk mengklasifikasikan jenis sampah dengan cara mengunggah atau menyeret (*drag-and-drop*) gambar sampah ke dalam sistem Halaman ini dirancang agar mudah digunakan oleh siapa saja, termasuk pengguna yang tidak memiliki latar belakang teknis.



Gambar 4. Tampilan Hasil Klasifikasi Berdasarkan Citra

Berdasarkan Gambar 4, berikut adalah penjelasan rinci mengenai komponen-komponen yang terdapat pada tampilan Klasifikasi Berdasarkan Citra:

a. Area Unggah Gambar (*Drop Zone*)

Komponen utama pada halaman ini adalah kotak besar dengan border bergaris putus-putus yang berfungsi sebagai area unggah gambar. Pengguna dapat mengklik area tersebut untuk membuka dialog pemilihan file, atau langsung menyeret gambar dari perangkat ke dalam kotak tersebut. Format gambar yang didukung adalah JPG, JPEG, dan PNG dengan ukuran maksimal 10 MB.

b. Pratinjau Gambar

Setelah pengguna mengunggah gambar, sistem akan menampilkan pratinjau citra yang diunggah. Hal ini memungkinkan pengguna untuk memverifikasi kasi bahwa gambar yang diunggah sudah benar sebelum proses klasifikasi dijalankan.

c. Proses Klasifikasi Otomatis


Setelah gambar berhasil diunggah, sistem secara otomatis melakukan *preprocessing* terhadap citra, yaitu mengubah ukuran gambar menjadi 224x224 piksel dan melakukan normalisasi nilai piksel ke rentang 0-1. Citra yang telah diproses kemudian dimasukkan ke dalam model CNN untuk diprediksi.

d. Hasil Klasifikasi

Sistem menampilkan hasil klasifikasi berupa label kategori sampah, yaitu Sampah Organik atau Sampah Non-Organik, disertai dengan nilai persentase kepercayaan (*Confidence Score*) model terhadap prediksi tersebut. Semakin tinggi nilai *confidence score*, semakin yakin model terhadap hasil klasifikasinya.

4.8. Tampilan Klasifikasi Secara *Real-Time*

Tampilan Klasifikasi Secara *Real-Time* merupakan fitur unggulan dari sistem ini yang memungkinkan pengguna untuk mengklasifikasikan sampah secara langsung menggunakan kamera *smartphone* atau *webcam* tanpa perlu mengambil gambar terlebih dahulu. Fitur ini memanfaatkan *library OpenCV* untuk mengakses kamera dan memproses setiap *frame* video secara berkesinambungan.



Gambar 5. Tampilan Hasil Klasifikasi Secara *Real-Time*

Berdasarkan Gambar 4, berikut adalah penjelasan rinci mengenai komponen-komponen yang terdapat pada tampilan Klasifikasi Berdasarkan secara *Real-Time*:

a. Area Tampilan Kamera

Bagian utama halaman ini menampilkan *feed video* langsung (*live video*) dari kamera yang terhubung. Area ini menampilkan objek sampah yang sedang diarahkan ke kamera secara *real-time*, sehingga pengguna dapat melihat apa yang sedang dianalisis oleh sistem.

b. Kotak Deteksi Objek (*Bounding Box*)

Sistem menampilkan kotak pembatas berwarna pada objek yang sedang dianalisis di dalam *frame video*. Warna kotak dibedakan berdasarkan hasil klasifikasi kotak berwarna hijau menandakan sampah organik, sedangkan kotak berwarna biru menandakan sampah non-organik.

c. Label Klasifikasi *Real-Time*


Di atas atau di bawah *bounding box*, sistem menampilkan label hasil klasifikasi secara langsung beserta nilai *confidence score* dalam persentase. Label ini diperbarui setiap *frame* sehingga pengguna dapat melihat perubahan klasifikasi secara instan ketika objek yang diarahkan ke kamera berganti.

d. Tombol Mulai dan Berhenti

Pengguna dapat mengontrol proses klasifikasi *real-time* menggunakan tombol Mulai untuk mengaktifkan kamera dan memulai proses deteksi, serta tombol Berhenti untuk menghentikan proses dan menutup koneksi kamera.

4.9. Tampilan Statistik Klasifikasi

Tampilan Statistik Klasifikasi merupakan halaman yang menampilkan ringkasan dan rekap data dari seluruh aktivitas klasifikasi yang telah dilakukan oleh sistem, baik melalui unggahan citra maupun klasifikasi secara *real-time*. Halaman ini dirancang untuk memberikan gambaran menyeluruh mengenai kinerja sistem dan distribusi jenis sampah yang telah diklasifikasikan.



Gambar 6. Tampilan Statistik Klasifikasi

Berdasarkan Gambar 6, berikut adalah penjelasan rinci mengenai komponen-komponen yang terdapat pada tampilan Klasifikasi Berdasarkan secara *Real-Time*:

a. Total Klasifikasi

Kotak pertama menampilkan jumlah total keseluruhan klasifikasi yang telah dilakukan oleh sistem sejak pertama kali digunakan. Angka ini mencakup semua klasifikasi dari kedua metode input, baik melalui unggahan citra maupun deteksi *real-time*.

b. Jumlah Sampah Organik

Kotak kedua menampilkan total jumlah klasifikasi yang menghasilkan label Sampah Organik, disertai dengan persentase proporsi dari keseluruhan total

klasifikasi, sehingga pengguna dapat mengetahui seberapa besar proporsi sampah organik yang diidentifikasi oleh sistem.

c. Jumlah Sampah Non-Organik

Kotak kedua menampilkan total jumlah klasifikasi yang menghasilkan label Sampah Organik, disertai dengan persentase proporsi dari keseluruhan total klasifikasi, sehingga pengguna dapat mengetahui seberapa besar proporsi sampah organik yang diidentifikasi oleh sistem.

d. Riwayat Klasifikasi

Halaman ini juga menampilkan grafik batang atau grafik lingkaran (*pie chart*) yang memvisualisasikan distribusi proporsi antara sampah organik dan non-organik. Representasi visual ini memudahkan pengguna memahami perbandingan jumlah kedua jenis sampah dalam sekali pandang.

4.10. Pengujian Aplikasi

Pengujian aplikasi dilakukan untuk memastikan bahwa seluruh fitur pada sistem klasifikasi sampah organik dan non-organik dapat berjalan sesuai dengan fungsinya. Metode pengujian yang digunakan adalah Black Box Testing, yaitu pengujian yang berfokus pada kesesuaian keluaran sistem terhadap masukan yang diberikan tanpa melihat proses internal program.

Tabel 8. Hasil Pengujian Aplikasi

No	Fitur Yang Di Uji	Skenario Pengujian	Hasil yang diharapkan	Hasil
1	Pelatihan Model	Menjalankan Proses Training Dataset	Model CNN berhasil dilatih dan disimpan	Berhasil
2	Klasifikasi Gambar	Mengunggah Gambar Sampah	Sistem menampilkan hasil klasifikasi dan confidence score	Berhasil
3	Klasifikasi <i>Real-Time</i>	Mengaktifkan kamera dan mendeteksi objek sampah	Sistem menampilkan hasil klasifikasi secara langsung	Berhasil
4	Statistik Klasifikasi	Membuka halaman statistik	Sistem menampilkan Jumlah klasifikasi dan grafik statistic	Berhasil
5	Upload File	Mengunggah file JPG, JPEG, dan PNG	Sistem menerima dan memproses file yang valid	Berhasil

Berdasarkan hasil pengujian yang telah dilakukan, seluruh fitur utama pada aplikasi dapat berjalan sesuai dengan fungsinya. Fitur klasifikasi gambar mampu menerima citra masukan dan menampilkan hasil prediksi dengan baik. Fitur klasifikasi *real-time* juga dapat melakukan deteksi menggunakan kamera secara langsung dan menampilkan hasil klasifikasi secara otomatis. Selain itu, fitur statistik mampu menampilkan rekapitulasi hasil klasifikasi yang telah dilakukan pengguna. Dengan demikian, aplikasi yang dikembangkan telah memenuhi kebutuhan fungsional sistem dan dapat digunakan untuk membantu proses klasifikasi sampah organik dan non-organik secara otomatis.

5. KESIMPULAN DAN SARAN

Berdasarkan proses analisis, implementasi sistem, dan pengujian metode yang dilakukan dalam penelitian ini dapat disimpulkan bahwa penerapan *Computer Vision* menggunakan algoritma *Convolutional Neural Network* (CNN) berhasil

digunakan untuk mengklasifikasikan sampah organik dan non-organik secara otomatis. Model CNN yang dilatih menggunakan dataset citra sampah dari Bank Sampah Mapoli, Kota Kupang, mampu mengenali karakteristik visual objek berdasarkan bentuk, warna, dan tekstur sampah dengan cukup baik. Hasil pengujian menggunakan metode *5-Fold Cross Validation* menunjukkan bahwa model memiliki performa klasifikasi yang baik dengan nilai akurasi, sensitivitas, dan spesifisitas yang tinggi. Hasil tersebut menunjukkan bahwa model mampu membedakan kedua jenis sampah dengan tingkat kesalahan yang relatif rendah sehingga dapat digunakan sebagai pendukung proses pemilahan sampah berbasis teknologi. Selain itu, sistem juga dapat dikembangkan menjadi aplikasi *mobile* atau diintegrasikan dengan perangkat keras otomatis seperti *conveyor belt* dan robot pemilah sampah agar dapat diterapkan secara langsung di lingkungan masyarakat. Pengujian lapangan pada berbagai lokasi seperti pasar, tempat pembuangan akhir (TPA), dan lingkungan rumah

tangga juga perlu dilakukan untuk mengetahui kemampuan sistem dalam kondisi nyata yang lebih kompleks dan beragam.

DAFTAR PUSTAKA

- [1] E. R. Sinaga dan M. R. Milu, "Efisiensi Pengelolaan Sampah dengan Minimalisasi Sampah Organik Rumah Tangga," *Oehonis: Jurnal Poltekkes Kupang*, vol. 6, no. 1, pp. 8-13, 2023.
- [2] Kementerian Lingkungan Hidup dan Kehutanan, "Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) Tahun 2024," Jakarta: KLHK, 2024.
- [3] M. N. Indrayani et al., "Edukasi Pentingnya Pengelolaan Sampah Organik dan Non Organik di Rumah Tangga," *JKTm*, vol. 6, no. 3, pp. 101-109, 2024.
- [4] M. Muslihati, S. Sahibu, dan I. Taufik, "Implementasi Algoritma Convolutional Neural Network untuk Klasifikasi Jenis Sampah Organik dan Non Organik," *MALCOM*, vol. 4, no. 3, pp. 840-852, 2024.
- [5] Z. Li, W. Yang, S. Peng, dan F. Liu, "A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects," *arXiv*, pp. 1-21, 2020.
- [6] R. D. Ramadhani et al., "Optimasi Akurasi Metode Convolutional Neural Network untuk Identifikasi Jenis Sampah," *Jurnal RESTI*, vol. 5, no. 2, pp. 312-318, 2021.
- [7] M. R. Abdan dan M. Akbar, "Klasifikasi Sampah Daur Ulang Menggunakan CNN dan GLCM," *Jurnal Informatika Teknologi dan Sains*, vol. 7, no. 3, pp. 1221-1230, 2025.
- [8] M. E. Purba et al., "Klasifikasi Sampah Organik dan Anorganik Menggunakan Algoritma CNN," *Jurnal Sifo Mikroskil*, vol. 26, no. 1, pp. 37-54, 2025.
- [9] K. Wijaya et al., "Pemilahan Sampah Organik dan Anorganik melalui Sosialisasi guna Meminimalisir Penumpukan Sampah," *Jurnal Dinamika Pengabdian*, vol. 10, no. 1, pp. 27-33, 2024.
- [10] H. Zhang, "A Review of Convolutional Neural Network Development in Computer Vision," *EAI Endorsed Transactions on IoT*, vol. 7, no. 28, pp. 1-12, 2022.
- [11] W. Wijiyanto et al., "Teknik K-Fold Cross Validation untuk Mengevaluasi Kinerja Mahasiswa," *Jurnal Algoritma*, vol. 21, no. 1, pp. 239-248, 2024.
- [12] J. G. M. Sanu, "Identifikasi Kematangan Buah Nanas Menggunakan Citra Digital dengan Metode K-NN dan SVM," *Jurnal HOAQ*, vol. 16, no. 1, pp. 35-45, 2025.