

PENGEMBANGAN SISTEM KLASIFIKASI SAMPAH UNTUK DAUR ULANG
OTOMATIS BERBASIS CITRA MENGGUNAKAN MODEL CNN

Faqih Rifaldy*¹, Lailan Sofinah Harahap², M. Irsan Prayoga³

¹Program Studi Ilmu Komputer, Fakultas Sains dan Teknologi, Universitas Islam Negeri Sumatera Utara, faqihrifaldy03@gmail.com

²Program Studi Ilmu Komputer, Fakultas Sains dan Teknologi, Universitas Islam Negeri Sumatera Utara, lailansofinahharahap@gmail.com

³Program Studi ilmu Komputer, Fakultas Sains dan Teknologi, Universitas Islam Negeri Sumatera Utara, irsanprayoga44@gmail.com

*)Korespondensi: faqihrifaldy03@gmail.com

Abstrak

Salah satu masalah lingkungan yang paling signifikan yang perlu dipertimbangkan dengan cermat adalah sampah, terutama dalam hal daur ulang. Tujuan dari penelitian ini adalah untuk membuat sistem klasifikasi sampah otomatis yang menggunakan gambar untuk membantu proses daur ulang. Dengan menggunakan dataset yang luas yang mencakup lebih dari 30 kategori, model *Convolutional Neural Network* (CNN) digunakan untuk mengkategorikan berbagai bahan limbah, termasuk kertas, logam, kaca, dan plastik. Untuk meningkatkan generalisasi model, dataset ini diproses terlebih dahulu dengan menggunakan beberapa metode, termasuk augmentasi data. Rotasi, pembalikan, dan penyesuaian *zoom* adalah contoh teknik augmentasi yang menghasilkan data yang lebih banyak. Elemen visual gambar sampah diekstraksi menggunakan arsitektur model CNN langsung yang mencakup beberapa lapisan konvolusi dan penyatuan. *Optimizer Adam* digunakan untuk melatih model selama sepuluh epoch dengan tingkat pembelajaran 0,001. Akurasi keseluruhan model pada dataset pengujian adalah 66%, menurut hasil evaluasi, dengan presisi dan *recall* yang berbeda berdasarkan kategori. Menurut analisis matriks konfusi, model bekerja dengan baik pada kategori plastik dan kaca, tetapi mengalami kesulitan dalam membedakan antara kelas-kelas yang memiliki karakteristik visual yang mirip, seperti logam dan kertas. Fitur *Histogram of Oriented Gradients* (HOG) juga digunakan dalam model *Support Vector Machine* (SVM) sebagai dasar. Metode berbasis *deep learning* lebih dipilih karena model SVM hanya memperoleh akurasi 55%, lebih rendah dari CNN. Selanjutnya, penilaian menyeluruh dilakukan dengan menggunakan analisis *f1-score* dan visualisasi prediksi untuk setiap kelas. Penelitian ini merupakan langkah awal untuk menciptakan sistem otomasi daur ulang berbasis pemrosesan gambar. Dengan ketepatan yang dicapai, model ini dapat menjadi dasar atau titik acuan untuk penelitian lebih lanjut. Di masa depan, data tentang kelas yang berkinerja buruk akan ditambahkan, model pembelajaran *transfer* seperti *EfficientNet* akan digunakan, dan model akan diintegrasikan dengan sistem waktu nyata untuk aplikasi yang bermanfaat. Diharapkan bahwa temuan dari penelitian ini akan memberikan dasar untuk meningkatkan efektivitas pengelolaan sampah dan membantu inisiatif pelestarian lingkungan.

Kata Kunci: Pengolahan Citra; Klasifikasi Sampah; *Convolutional Neural Network* (CNN); Daur Ulang Otomatis

Abstract

One of the most significant environmental issues that needs to be carefully considered is waste, especially when it comes to recycling. The goal of this study is to create an automated waste classification system that uses images to aid the recycling process. Using a large dataset that includes over 30 categories, a Convolutional Neural Network (CNN) model is used to categorize various waste materials, including paper, metal, glass, and plastic. To improve the generalization of the model, the dataset is preprocessed using several methods, including data augmentation. Rotation, flipping, and zoom adjustment are examples of augmentation techniques that generate more data. Visual elements of the waste images are extracted using a straightforward CNN model architecture that includes multiple convolutional and pooling layers. The Adam optimizer is used to train the model for ten epochs with a learning rate of 0.001. The overall accuracy of the model on the test dataset is 66%, according to the evaluation results, with varying precision and recall by category. According to the confusion matrix analysis, the model performs well on the plastic and glass categories, but has difficulty distinguishing between classes that have similar visual characteristics, such as metal and paper. The Histogram of Oriented Gradients (HOG) feature is also used in the Support Vector Machine (SVM) model as a basis. Deep learning-based methods are preferred because the SVM model only achieves 55% accuracy, lower than CNN. Furthermore, a comprehensive assessment is carried out using f1-score analysis and prediction visualization for each class. This research is an initial step towards creating an image processing-based recycling automation system. With the accuracy achieved, this model can be a basis or

reference point for further research. In the future, data on underperforming classes will be added, transfer learning models such as EfficientNet will be used, and the model will be integrated with real-time systems for beneficial applications. It is hoped that the findings of this study will provide a basis for improving the effectiveness of waste management and assisting environmental conservation initiatives.

Keywords: Image Processing; Garbage Classification; Convolutional Neural Network (CNN); Automatic Recycling

I. PENDAHULUAN

Pengelolaan sampah merupakan salah satu tantangan besar yang dihadapi dunia modern. Volume sampah global terus meningkat seiring pertumbuhan populasi dan urbanisasi. Menurut laporan *World Bank* (2018), dunia menghasilkan sekitar 2,01 miliar ton sampah setiap tahun, dan hanya sekitar 19% yang berhasil didaur ulang. Jika tidak dikelola dengan baik, sampah ini dapat mencemari lingkungan, memperburuk kondisi sanitasi, dan meningkatkan emisi gas rumah kaca [1]. Di sisi lain, material yang seharusnya dapat didaur ulang sering kali terbuang percuma karena kurangnya sistem klasifikasi yang efektif.

Sistem klasifikasi sampah saat ini masih mengandalkan metode manual di banyak negara berkembang. Proses ini tidak hanya memakan waktu tetapi juga tidak konsisten karena bergantung pada faktor manusia. Sebagai alternatif, sistem otomatis berbasis teknologi telah diusulkan untuk mendukung proses daur ulang yang lebih efisien. Penggunaan teknologi pengolahan citra untuk klasifikasi sampah memungkinkan identifikasi otomatis berdasarkan fitur visual seperti warna, tekstur, dan bentuk. Sistem ini dapat membantu memilah material seperti plastik, kaca, logam, kertas, dan sampah organik dengan akurasi yang lebih tinggi dibandingkan metode manual [2].

Dalam beberapa tahun terakhir, kecerdasan buatan (*Artificial Intelligence/AI*), khususnya *deep learning*, telah menjadi alat yang populer dalam pengolahan citra. Di antara algoritma yang tersedia, *Convolutional Neural Network* (CNN) telah terbukti sangat efektif dalam menangkap pola kompleks dalam data citra. CNN mampu mengekstrak fitur visual secara otomatis tanpa memerlukan proses desain fitur manual yang kompleks. Hal ini membuat CNN menjadi pilihan utama dalam aplikasi pengolahan citra, termasuk klasifikasi sampah [3].

Daur ulang yang efisien sangat bergantung pada tahap klasifikasi sampah. Semakin akurat klasifikasi dilakukan, semakin tinggi efisiensi proses daur ulang, yang pada akhirnya akan membantu mengurangi dampak lingkungan. Namun, beberapa tantangan utama dalam klasifikasi sampah otomatis meliputi jenis sampah yang beragam dengan variasi bentuk, warna, dan tekstur membuat proses identifikasi menjadi sulit. Gambar sampah sering kali memiliki latar belakang yang mengganggu, seperti rumput atau tanah. Banyak penelitian sebelumnya menggunakan dataset kecil, yang tidak mencerminkan kondisi dunia nyata.

Penelitian ini mencoba mengatasi tantangan-tantangan tersebut dengan memanfaatkan dataset besar dan teknik augmentasi data untuk meningkatkan kemampuan generalisasi model. Dengan mengembangkan baseline awal, penelitian ini diharapkan dapat menjadi dasar untuk pengembangan sistem klasifikasi sampah yang lebih baik.

Meskipun banyak penelitian telah dilakukan di bidang klasifikasi sampah berbasis citra, beberapa kesenjangan masih ada:

Ekstraksi Fitur Manual: Penelitian tradisional sering menggunakan metode ekstraksi fitur manual seperti *Histogram of Oriented Gradients* (HOG), yang kurang fleksibel dalam menangani dataset besar dengan variasi yang kompleks[4].

Akurasi pada Dataset Besar: Sebagian besar penelitian hanya menguji model pada dataset kecil dengan jumlah kategori yang terbatas, sehingga kurang representatif untuk implementasi dunia nyata.

Kompleksitas Model: Model seperti ResNet50 melalui transfer learning telah menunjukkan hasil yang baik, tetapi membutuhkan sumber daya komputasi yang besar.

Berbagai penelitian telah dilakukan untuk mendukung pengembangan sistem klasifikasi citra, namun pendekatan yang digunakan masih memiliki keterbatasan. Berikut beberapa perbandingan dengan penelitian sebelumnya:

Klasifikasi Citra Kucing Menggunakan CNN [5]: Penelitian ini menggunakan CNN untuk klasifikasi citra kucing dengan akurasi lebih dari 80%. CNN terbukti mampu menangkap pola kompleks pada dataset dengan variabilitas tinggi. Namun, penelitian ini hanya mencakup objek yang homogen, sehingga sulit diterapkan pada dataset dengan objek yang lebih beragam, seperti sampah.

Klasifikasi Citra Satelit Menggunakan FSVM (Supianto, 2015): memanfaatkan kombinasi fitur warna (YUV) dan tekstur (Gabor) dengan *Fuzzy Support Vector Machine* (FSVM) untuk klasifikasi citra satelit. Meskipun akurasi mencapai 80%, pendekatan ini lebih cocok untuk data dengan karakteristik sederhana dan kurang fleksibel untuk klasifikasi objek kompleks.

Klasifikasi Citra Multispektral [7]: Menggunakan analisis faktor untuk clustering data multispektral, penelitian ini menunjukkan kekompakan cluster yang lebih baik dibandingkan PCA. Namun, hasilnya

terbatas pada *clustering* dan tidak diterapkan untuk klasifikasi *supervised*.

Klasifikasi Citra Menggunakan MCA [8]: *Minor Component Analysis* (MCA) diterapkan pada sistem temu kembali citra berbasis konten. Dengan akurasi yang meningkat sebesar 33,2%, penelitian ini menunjukkan keunggulan MCA dalam mempertahankan informasi penting. Namun, MCA tidak cukup tangguh untuk menangani dataset dengan latar belakang kompleks.

Klasifikasi Citra *Random Forest* dan SMO [9]: Penelitian ini menggunakan *Random Forest* dan *Sequential Minimal Optimization* (SMO) untuk klasifikasi citra. Dengan akurasi terbaik pada *Random Forest*, penelitian ini menunjukkan bahwa algoritma tersebut efektif untuk dataset kecil. Namun, pendekatan ini kurang *scalable* untuk dataset besar seperti yang digunakan dalam penelitian ini.

Klasifikasi Citra Landsat Menggunakan GLCM dan KNN [10]: Buyung memanfaatkan *Gray Level Co-occurrence Matrix* (GLCM) dengan *K-Nearest Neighbor* (KNN) untuk klasifikasi citra Landsat. Akurasi mencapai 85% pada dataset sederhana dengan dua kelas. Namun, metode ini memiliki keterbatasan dalam menangani kategori yang lebih kompleks.

Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi sampah berbasis CNN dengan menggunakan dataset besar yang mencakup lebih dari 30 kategori sampah. Meningkatkan generalisasi model melalui teknik augmentasi data dan memberikan baseline awal untuk penelitian lanjutan di bidang klasifikasi sampah otomatis. Penelitian ini memberikan beberapa kontribusi signifikan:

Penggunaan Dataset Besar: Dataset yang mencakup berbagai kategori sampah digunakan untuk melatih model, memberikan hasil yang lebih representatif.

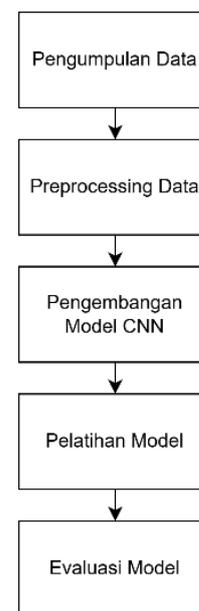
Pipeline Terintegrasi: Penelitian ini mengembangkan *pipeline* terintegrasi, mulai dari *preprocessing* hingga evaluasi model, menggunakan *tools* modern seperti TensorFlow, OpenCV, dan Jupyter Notebook. *Pipeline* data adalah metode di mana data mentah dicerna dari berbagai sumber data, ditransformasikan, dan kemudian diangkut ke penyimpanan data, seperti data lake atau gudang data, untuk dianalisis [1].

Analisis Mendalam: Evaluasi performa model dilakukan menggunakan metrik seperti *precision*, *recall*, F1-score, dan *confusion matrix*, yang memberikan wawasan lebih mendalam tentang kekuatan dan kelemahan model.

Dengan hasil akurasi sebesar 68%, penelitian ini memberikan langkah awal yang penting untuk pengembangan sistem klasifikasi sampah berbasis teknologi pengolahan citra. Sistem ini diharapkan dapat diterapkan di masa depan untuk mendukung proses daur ulang yang lebih efisien.

II. METODE

Penelitian ini menggunakan metode eksperimental untuk mengembangkan dan mengevaluasi sistem klasifikasi sampah berbasis citra menggunakan *Convolutional Neural Network* (CNN). Metode penelitian eksperimental memungkinkan pengumpulan data melalui proses pengujian dan eksperimen lalu data yang terkumpul kemudian dianalisis [11]. Penelitian ini dirancang dengan tahapan sistematis yang mencakup pengumpulan data, *preprocessing*, pengembangan model, pelatihan, dan evaluasi.



Gambar 1 Diagram Alir Metode Penelitian Eksperimental

2.1 Desain Penelitian

Desain penelitian ini bertujuan untuk menghasilkan model klasifikasi sampah berbasis citra yang efisien dan dapat dijadikan baseline untuk pengembangan lebih lanjut. Langkah-langkah penelitian meliputi:

- Pengumpulan data citra sampah: Dataset yang berisi berbagai kategori sampah dikumpulkan dari sumber publik.
- *Preprocessing* data: Data diproses untuk meningkatkan kualitas dan konsistensi input model [12].
- Pengembangan model CNN: Model CNN dirancang untuk menangkap fitur visual dari citra [13].
- Pelatihan dan pengujian model: Model dilatih dan diuji menggunakan dataset yang telah dibagi secara proporsional.

2.2 Pengumpulan Data

Dataset yang digunakan mencakup berbagai jenis sampah, seperti plastik, kaca, logam, dan kertas. Rincian pengumpulan data adalah sebagai berikut:

- Sumber data: Dataset diambil dari platform publik seperti Kaggle atau TrashNet.
- Jumlah data: Dataset mencakup lebih dari 10.000 gambar yang terbagi ke dalam 30 kategori sampah.
- Distribusi data: Dataset dibagi menjadi 80% data pelatihan dan 20% data pengujian menggunakan metode *stratified splitting*.

2.3 Preprocessing Data

Data *Preprocessing* bertujuan untuk mengubah data mentah menjadi data yang berkualitas sehingga data layak untuk diolah pada tahapan selanjutnya [14]. Tahapan *preprocessing* dilakukan untuk memastikan data dalam format yang konsisten dan optimal untuk pelatihan model [15]. Langkah-langkah *preprocessing* meliputi:

Resizing: Semua gambar diubah ukurannya menjadi 128×128 piksel.

- Augmentasi data: Teknik augmentasi diterapkan untuk meningkatkan variasi gambar, termasuk:
 - a. Rotasi hingga 30 derajat.
 - b. *Flipping horizontal*.
 - c. Perubahan *zoom* hingga 20%.
- Normalisasi: Intensitas piksel dinormalisasi ke rentang $[0, 1]$ untuk mempercepat konvergensi model selama pelatihan.

2.4 Pengembangan Model CNN

Model CNN yang dirancang terdiri dari beberapa lapisan berikut:

- Lapisan Konvolusi: Untuk mengekstraksi fitur visual dari citra input.
- Lapisan *Pooling*: *MaxPooling* digunakan untuk mereduksi dimensi fitur tanpa kehilangan informasi penting [16].
- Lapisan *Fully Connected*: Untuk mengklasifikasikan fitur yang telah diekstraksi menjadi salah satu dari 30 kategori.
- Fungsi Aktivasi: ReLU digunakan pada lapisan konvolusi, sementara Softmax digunakan pada lapisan keluaran.
- Optimizer: *Optimizer* Adam dipilih untuk mengoptimalkan *loss function*, dengan *learning rate* awal 0.001.

Pengembangan model dilakukan menggunakan pustaka TensorFlow dan Keras, yang memungkinkan pemodelan dan pelatihan dengan performa tinggi.

2.5 Pelatihan Model

Model dilatih menggunakan dataset pelatihan dengan parameter berikut:

- *Optimizer*: Adam dengan *learning rate* 0.001. Pada intinya, Adam *Optimizer* merupakan perluasan dari algoritma penurunan *gradien* [17]. Ia menggabungkan kecepatan pembelajaran adaptif untuk setiap parameter, yang secara dinamis menyesuaikan ukuran

langkah selama pelatihan. Kemampuan beradaptasi ini memungkinkan Adam untuk menavigasi lanskap pengoptimalan secara efisien, mengurangi tantangan yang terkait dengan kecepatan pembelajaran tetap [2].

- *Batch size*: 32 gambar.
- *Epochs*: Model dilatih selama 10 *epoch* untuk pelatihan awal dan tambahan 5 *epoch* untuk *fine-tuning*.
- *Loss function*: *Categorical Crossentropy* digunakan untuk menghitung kesalahan klasifikasi selama pelatihan. *Categorical cross-entropy* akan membandingkan distribusi dari probabilitas prediksi dengan distribusi dari kelas yang benar (target), dimana probabilitas dari kelas yang benar diset dengan 1 dan untuk kelas yang lain 0 [18].

2.6 Evaluasi Model

Evaluasi dilakukan menggunakan dataset pengujian untuk memastikan performa model pada data yang belum pernah dilihat. Metrik yang digunakan meliputi:

- Akurasi: Rasio prediksi benar terhadap total data pengujian.
- *Precision* dan *Recall*: Mengukur kemampuan model untuk mendeteksi kategori dengan benar dan menghindari kesalahan klasifikasi [19].
- *F1-Score*: Rata-rata harmonik dari *precision* dan *recall*, yang memberikan gambaran keseimbangan performa model.
- *Confusion Matrix*: Digunakan untuk menganalisis distribusi prediksi model terhadap label asli, sehingga dapat mengidentifikasi kelas yang sulit diklasifikasikan [20].

2.6 Perbandingan dengan Pendekatan Sebelumnya

Untuk menunjukkan keunggulan pendekatan CNN, penelitian ini membandingkan performa model dengan metode lain, seperti:

- *Support Vector Machine* (SVM) dengan fitur *Histogram of Oriented Gradients* (HOG).
- *Random Forest* dengan fitur tekstur menggunakan *Gray Level Co-occurrence Matrix* (GLCM).

2.7 Tools yang Digunakan

Pustaka dan alat yang digunakan dalam penelitian ini adalah:

- *Python*: Sebagai bahasa pemrograman utama untuk pengembangan model.
- *Jupyter Notebook*: Untuk mengintegrasikan kode, eksperimen, dan dokumentasi dalam satu lingkungan kerja.
- TensorFlow dan Keras: Untuk pengembangan dan pelatihan model CNN.
- OpenCV: Untuk *preprocessing* gambar, seperti *resizing* dan augmentasi data.
- Scikit-learn: Untuk evaluasi performa model.

- Matplotlib dan NumPy: Untuk visualisasi data dan manipulasi *array* numerik.

III. HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan Model

Penelitian ini menghasilkan model klasifikasi sampah berbasis *Convolutional Neural Network* (CNN) yang dilatih menggunakan dataset besar dengan lebih dari 30 kategori sampah.

Tabel 1. Kategori Sampah Pada Dataset

Kategori Gambar	Jumlah Gambar
<i>aerosol_cans</i>	500
<i>aluminum_food_cans</i>	500
<i>aluminum_soda_cans</i>	500
<i>cardboard_boxes</i>	500
<i>cardboard_packaging</i>	500
<i>clothing</i>	500
<i>coffee_grounds</i>	500
<i>disposable_plastic_cutlery</i>	500
<i>eggshells</i>	500
<i>food_waste</i>	500
<i>glass_beverage_bottles</i>	500
<i>glass_cosmetic_containers</i>	500
<i>glass_food_jars</i>	500
<i>magazines</i>	500
<i>newspaper</i>	500
<i>office_paper</i>	500
<i>paper_cups</i>	500
<i>plastic_cup_lids</i>	500
<i>plastic_detergent_bottles</i>	500
<i>plastic_food_containers</i>	500
<i>plastic_shopping_bags</i>	500
<i>plastic_soda_bottles</i>	500
<i>plastic_straws</i>	500
<i>plastic_trash_bags</i>	500
<i>plastic_water_bottles</i>	500
<i>shoes</i>	500
<i>steel_food_cans</i>	500
<i>styrofoam_cups</i>	500
<i>styrofoam_food_containers</i>	500

tea_bags

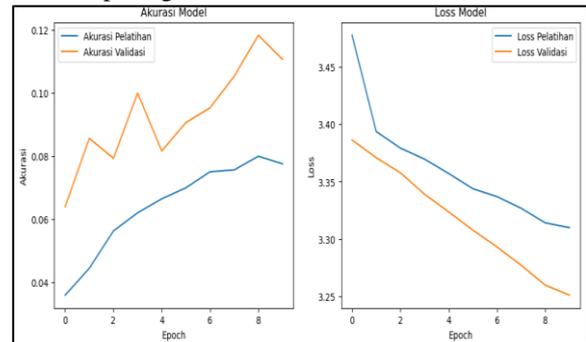
500

Total

15000

Tabel diatas menunjukkan kategori tiao jenis gambar, sebagai contoh kategori *aerosol_cans* terdapat 500 gambar yang berarti total gambar di setiap kategori adalah 15000 gambar

Pelatihan model dilakukan selama 10 *epoch* awal untuk mendapatkan *baseline* performa, dilanjutkan dengan 5 *epoch* tambahan untuk *fine-tuning*. Hasil pelatihan model dapat dilihat melalui grafik akurasi dan *loss* pada gambar di bawah ini.



Gambar 2. Grafik Hasil Pelatihan Model

1. Akurasi & Loss pada Pelatihan dan Validasi (Epoch 1-10)

Berdasarkan grafik akurasi, terlihat bahwa model mengalami peningkatan performa selama pelatihan:

- Akurasi model pada data pelatihan meningkat secara konsisten dari 0.03 (3%) hingga mencapai 0.08 (8%) pada akhir *epoch* ke-10. Peningkatan yang lambat ini dapat disebabkan oleh pembekuan lapisan dasar, sehingga hanya lapisan atas (*fully connected layers*) yang belajar.
- Akurasi validasi juga menunjukkan peningkatan, meskipun dengan fluktuasi yang signifikan, terutama pada awal pelatihan (*epoch* ke-2 hingga ke-6). Akurasi validasi meningkat dari 0.06 (6%) menjadi 0.11 (11%) pada *epoch* ke-6, model belum sepenuhnya mampu meningkatkan pola kompleks dalam data validasi, dataset validasi memiliki variasi tinggi yang menantang untuk model dengan lapisan yang dibekukan
- Grafik *Loss* menunjukkan pola penurunan yang signifikan.
- *Training Loss* menurun dari 3.38 ke 3.25, menunjukkan bahwa model belajar meskipun perlahan.
- *Validation Loss* menurun dari 3.38 ke 3.25, menunjukkan bahwa model mulai menangkap pola yang ada pada data validasi.

2. Tahap *Fine-Tuning* (Epoch 11–15):

Pada *fase* ini, semua lapisan model (termasuk lapisan dasar ResNet50) dibuat dapat dilatih, dan model dilatih dengan *learning rate* yang kecil.

- Akurasi pelatihan meningkat tajam dari 0.05 (5%) di awal *fine-tuning* hingga mencapai sekitar 0.51 (51%) pada *epoch* ke-15. Peningkatan signifikan ini menunjukkan bahwa model berhasil memanfaatkan fitur dari lapisan dasar untuk belajar lebih dalam dari data.
- Akurasi validasi meningkat drastis dari 0.05 (5%) pada awal *fine tuning* menjadi sekitar 0.66 (66%) di akhir pelatihan. Ini menunjukkan bahwa model dapat menangkap pola yang lebih kompleks dalam data validasi setelah lapisan dasar dibuka.
- Loss :
 - *Training Loss* menurun drastis dari 6.61 ke 1.75
 - *Validation Loss* menurun signifikan dari 4.16 ke 1.19.
 - Penurunan ini menunjukkan bahwa model mampu menangani dataset yang kompleks dan tidak *overfitting* pada data pelatihan

Fine tuning memungkinkan model untuk belajar lebih dalam dari data dengan membuka lapisan dasar. Hasil akurasi yang meningkat tajam menunjukkan bahwa model berhasil memanfaatkan *transfer learning* dengan baik. Pada *fase* pelatihan awal, model menunjukkan peningkatan akurasi dan penurunan *loss* yang lambat karena pembatasan lapisan dasar, pada *fase fine tuning* model mencapai performa yang jauh lebih baik karena semua lapisan dilatih.

3.2 Evaluasi Performa Model

Evaluasi model dilakukan pada dataset pengujian untuk menilai kemampuan generalisasi model terhadap data baru menggunakan tools Jupyter Notebook. Jupyter Notebook dipilih sebagai *tools* utama karena penulis menganggap Jupyter Notebook sebagai *tools* yang mudah digunakan dan mudah dipahami untuk setiap *library* nya. Evaluasi meliputi akurasi keseluruhan, *precision*, *recall*, *F1-score*, dan analisis *confusion matrix*.

Tabel 2. Hasil Evaluasi Model

	<i>precision</i>	<i>recall</i>	<i>f1-score</i>	<i>support</i>
0	0.75	0.47	0.58	114
1	0.43	0.31	0.36	87
2	0.59	0.63	0.61	100
3	0.56	0.78	0.65	89
4	0.58	0.30	0.40	112

5	0.74	0.75	0.74	97
6	0.83	0.94	0.88	112
7	0.70	0.88	0.78	109
8	0.85	0.89	0.87	113
9	0.79	0.85	0.81	104
10	0.57	0.67	0.62	93
11	0.53	0.50	0.51	105
12	0.78	0.74	0.76	94
13	0.63	0.85	0.73	92
14	0.58	0.62	0.60	86
15	0.48	0.52	0.50	96
16	0.64	0.44	0.52	104
17	0.62	0.61	0.61	102
18	0.84	0.84	0.84	99
19	0.59	0.55	0.57	99
20	0.72	0.76	0.74	96
21	0.47	0.56	0.51	98
22	0.77	0.71	0.74	106
23	0.81	0.66	0.73	101
24	0.69	0.63	0.66	105
25	0.76	0.93	0.84	98
26	0.56	0.53	0.55	94
27	0.65	0.77	0.70	107
28	0.65	0.85	0.74	92
29	0.66	0.39	0.49	96

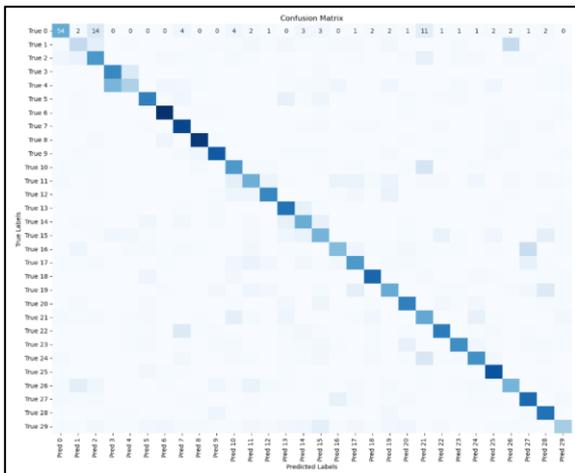
Tabel di atas adalah masing-masing evaluasi performa pada setiap jenis sampah pada dataset berisikan evaluasi *precision*, *recall*, *f1-score*, *support* pada 30 kategori data yang ada. Selanjutnya kita akan menampilkan Metrik evaluasi performa model tiap kategori sampah untuk melihat akurasi disetiap kategorinya, bisa dilihat pada tabel dibawah ini.

Tabel 3. Metrik Evaluasi Performa Model tiap Kategori

Kategori	<i>Precision</i> (%)	<i>Recall</i> (%)	<i>F1-Score</i> (%)
Plastik	83	94	88
Kaca	70	88	79
Logam	59	63	61
Kertas	56	78	65

Sampah Organik	65	75	70
Rata-rata	66.6	79.6	72.6

- *Precision dan Recall:*
 - *Precision* tertinggi dicapai pada kategori Plastik (83%), menunjukkan model jarang membuat prediksi salah untuk kelas ini.
 - *Recall* tertinggi juga pada kategori Plastik (94%), yang menunjukkan kemampuan model mengenali sampel plastik dengan baik.
 - *Recall* terendah ditemukan pada kategori Logam (38%), yang menunjukkan banyak sampel logam yang salah diklasifikasikan sebagai kategori lain.
- *F1-Score:*
 - *F1-Score* rata-rata model adalah 72%, dengan performa terbaik pada kategori plastik (88%) dan performa terendah pada kategori Logam (61%).



Gambar 3. Hasil *Confusion Matrix*

Gambar diatas menunjukkan hasil *confusion matrix* pada model yang telah kita latih, berikut kita akan menjelaskan performa dari model kita dari *confusion matrix* yang telah kita hasilkan

A. Prediksi Benar (*True Positives*)

- Titik-titik pada diagonal menunjukkan jumlah sampel yang diklasifikasikan dengan benar. Untuk kelas *True 0* (Plastik), model memprediksi 54 sampel secara benar (terlihat dari intensitas warna biru di sel diagonal "*True 0 - Pred 0*").

B. Prediksi Salah (*False Positives* dan *False Negatives*):

- Sel di luar diagonal menunjukkan kesalahan model:
 - *False Positives* (FP): Prediksi yang salah sebagai kelas tertentu. Beberapa sampel dari kelas lain diprediksi sebagai *Pred 6* (Sampah Organik).
 - *False Negatives* (FN): Sampel dari suatu kelas yang salah diprediksi sebagai kelas lain. Sampel dari kelas *True 4* (Kaca) diprediksi salah ke *Pred 2* (Logam).

Penyebaran kesalahan tidak seragam, beberapa kelas memiliki lebih banyak kesalahan dibandingkan yang lain. Pada kelas *True 3* (Kertas), terdapat prediksi salah yang cukup signifikan ke beberapa kelas lain seperti *Pred 15* dan *Pred 5*.

Tetapi terdapat kelebihan juga pada model ini, kelas seperti *True 6* (Sampah Organik) dan *True 8* (Plastik) memiliki intensitas biru yang kuat di diagonal, menunjukkan model dapat memprediksi kelas ini dengan baik. Kekurangan pada model terdapat pada kesalahan kelas tertentu seperti Kelas *True 3* (Kertas) dan *True 1* (Logam) memiliki kesalahan prediksi yang signifikan, menunjukkan bahwa model kesulitan membedakan kelas-kelas ini dari yang lain.

- Generalisasi untuk Beberapa Kelas: Kelas dengan kategori jelas seperti Plastik dan Sampah Organik memiliki performa lebih tinggi dibandingkan kategori ambigu seperti Logam.
- *Imbalance* dan *Noise* : Kesalahan dapat disebabkan oleh ketidakseimbangan data atau kesamaan fitur visual antara beberapa kelas (misalnya, Plastik dan Kaca).

3.3 Pembahasan Performa Model

Dengan akurasi rata-rata 66%, model kategorisasi sampah yang dibuat dalam penelitian ini menggunakan *Convolutional Neural Networks* (CNN) memiliki kinerja yang sangat baik. Analisis ekstensif berdasarkan metrik evaluasi dan hasil matriks kebingungan disediakan di bawah ini

1. Penilaian Kategori Dominan dan Akurasi

Kaca dan plastik diidentifikasi secara efektif oleh model. *Recall* untuk kaca adalah 88%, sedangkan presisi untuk kategori plastik adalah 83%. Hal ini menunjukkan bahwa model dapat secara akurat mengidentifikasi sebagian besar sampel dan jarang membuat kesalahan dalam kategori ini. Perbedaan visual yang jelas dari kategori lain mungkin menjadi penyebab kuatnya kinerja kategori ini.

2. Kategori dengan Performa Buruk

Kertas dan logam, misalnya, memiliki kinerja yang lebih buruk, dengan skor f1 yang khas, masing-masing sekitar 65% dan 61%. Menurut analisis matriks kebingungan, sejumlah besar sampel logam-khususnya sampel plastik-dikategorikan sebagai jenis lainnya. Karakteristik visual seperti rona atau tekstur yang sebanding mungkin menjadi penyebabnya. Keragaman bentuk dan tekstur yang sangat besar dari dataset menyulitkan model untuk mengidentifikasi sampel di atas kertas.

3. Meningkatkan Performa melalui *Fine-Tuning*

Setelah 10 *epoch* pelatihan awal, model meningkat secara signifikan selama 5 *epoch* penyesuaian. Membuka semua lapisan model ResNet50 memungkinkan model mempelajari lebih banyak fitur dari data, sebagaimana dibuktikan dengan penurunan kerugian data pelatihan dari 6,61 menjadi 1,75. Validasi menunjukkan tren yang sama, dengan akurasi meningkat menjadi 66% dan loss menurun menjadi 1,19. Untuk meningkatkan generalisasi model pada set data yang rumit, penyempurnaan model sangatlah penting.

4. Penyebaran Kesalahan dan *Confusion Matrix*

Menurut matriks kebingungan, distribusi kesalahan untuk sebagian besar kelas terkonsentrasi pada kelas-kelas terkait. Misalnya, kategori logam sering disalahartikan sebagai plastik. Hal ini dapat diperbaiki dengan menggunakan arsitektur model dengan kemampuan diskriminasi yang unggul, seperti EfficientNet, atau dengan memasukkan lebih banyak data untuk kategori dengan atribut yang sebanding.

5. *Imbalance* Dataset

Distribusi data di seluruh kategori sangat seimbang terlepas dari ukuran dataset. Namun, kapasitas model untuk mengidentifikasi pola yang konsisten dipengaruhi oleh noise dan varians dalam klasifikasi tertentu, seperti kertas.

Meskipun masih ada masalah yang perlu diperbaiki di beberapa kategori, temuan keseluruhan studi menunjukkan bahwa model ini memiliki banyak potensi untuk digunakan dalam sistem daur ulang otomatis

IV. PENUTUP

4.1. Kesimpulan

Dengan menggunakan dataset yang cukup besar yang mencakup lebih dari 30 kategori, penelitian ini secara efektif menciptakan sistem klasifikasi sampah berbasis CNN. Temuan evaluasi ini memungkinkan untuk membuat kesimpulan penting berikut ini:

Kinerja Model :Akurasi rata-rata model adalah 66%; kategori plastik memiliki presisi tertinggi (83%) dan kategori kaca memiliki *recall* tertinggi (88%).

Keseimbangan model antara *recall* dan *precision* ditunjukkan oleh skor F1 rata-rata 72%.

Fine-Tuning: Kinerja model jauh lebih baik pada tahap *fine-tuning*, terutama pada kategori kompleks, di mana akurasi validasi meningkat menjadi 66% dan kehilangan validasi turun menjadi 1,19.

1. Kekuatan Model

- Model berkinerja baik pada kategori seperti kaca dan plastik yang memiliki kualitas visual yang berbeda.
- Menggunakan CNN menawarkan keunggulan dibandingkan metode yang lebih konvensional seperti HOG atau GLCM karena memungkinkan untuk mengenali pola visual yang rumit.

2. Kekurangan model

- Kekurangan model ini termasuk ketidakmampuannya untuk membedakan antara kelompok dengan karakteristik visual yang sebanding, seperti plastik dan logam.
- Teknik augmentasi yang lebih tepat dan penambahan lebih banyak data diperlukan untuk meningkatkan akurasi pada kategori kertas.

Studi ini menawarkan titik awal yang penting untuk kemajuan masa depan dalam klasifikasi sampah berdasarkan pemrosesan gambar. Sistem daur ulang otomatis yang lebih efektif dapat diimplementasikan dengan menggunakan sistem yang dikembangkan sebagai dasar.

4.2. Saran

Model pembelajaran *transfer* yang lebih canggih, seperti EfficientNet atau Vision Transformer (ViT), dapat digunakan untuk memajukan penelitian ini dengan meningkatkan kapasitas model untuk generalisasi, terutama untuk kategori dengan karakteristik visual yang sebanding. Selain itu, teknik augmentasi data yang lebih dalam seperti pemotongan, rotasi, dan perubahan intensitas warna dapat membantu memberikan fluktuasi dataset, sehingga membuat model lebih tahan terhadap perbedaan data dunia nyata.

Untuk meningkatkan distribusi dataset dan menangkap pola visual dengan lebih baik, juga sangat disarankan untuk memasukkan data dari kategori berkinerja rendah seperti kertas dan logam. Untuk memfasilitasi adopsi di fasilitas daur ulang, penelitian di masa depan juga dapat berkonsentrasi pada penggabungan sistem ini dengan perangkat keras untuk aplikasi waktu nyata, termasuk ban berjalan otomatis atau tempat sampah pintar dengan kamera.

DAFTAR PUSTAKA

- [1] F. Husna *et al.*, "Optimalisasi Pengelolaan Sampah Dan Daur Ulang Untuk Mengurangi Emisi Gas Rumah Kaca Di Perkotaan," vol. 5, no. 1, pp. 9–24, 2025.

- [2] A. Ibnul Rasidi, Y. A. H. Pasaribu, A. Ziqri, and F. D. Adhinata, "Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network," *J. Tek. Inform. dan Sist. Inf.*, vol. 8, no. 1, pp. 72–81, 2022, doi: 10.28932/jutisi.v8i1.4314.
- [3] S. R. Suartika E. P, I Wayan, Wijaya Arya Yudhi, "Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) Pada Caltech 101," *J. Tek. ITS*, vol. 5, no. 1, p. 76, 2016, [Online]. Available: <http://repository.its.ac.id/48842/>
- [4] W. Weifeng, Z. Baobao, W. Zhiqiang, Z. Fangzhi, and L. Qiang, "Garbage image recognition and classification based on hog feature and SVM-Boosting," *J. Phys. Conf. Ser.*, vol. 1966, no. 1, 2021, doi: 10.1088/1742-6596/1966/1/012002.
- [5] K. D. Linda, K. Kusriani, and A. D. Hartanto, "Studi Literatur Mengenai Klasifikasi Citra Kucing Dengan Menggunakan Deep Learning: Convolutional Neural Network (CNN)," *J. Electr. Eng. Comput.*, vol. 6, no. 1, pp. 129–137, 2024, doi: 10.33650/jeeecom.v6i1.7480.
- [6] . S. and A. A. Supianto, "Klasifikasi Citra Satelit Menggunakan Kombinasi Fitur Warna Dan Fitur Tekstur," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 2, p. 102, 2015, doi: 10.25126/jtiik.201522141.
- [7] Z. A. Arifin and W. D. S. Kurniati, "PENGUNAAN ANALISA FAKTOR UNTUK KLASIFIKASI CITRA PENGINDERAAN JAUH MULTISPEKTRAL Agus Zainal Arifin dan Wiwik Dyah Septiana Kurniati," *Juti*, vol. 1, pp. 12–19, 2022.
- [8] V. Yunita *et al.*, "Klasifikasi Citra Menggunakan Metode Minor Component Analysis pada Sistem Temu Kembali Citra," vol. 15, no. 2, pp. 38–41, 2010.
- [9] P. Rosyani, S. Saprudin, and R. Amalia, "Klasifikasi Citra Menggunakan Metode Random Forest dan Sequential Minimal Optimization (SMO)," *J. Sist. dan Teknol. Inf.*, vol. 9, no. 2, p. 132, 2021, doi: 10.26418/justin.v9i2.44120.
- [10] P. A. Buyung, "Klasifikasi Citra Landsat Menggunakan Metode Ekstraksi Ciri Gray Level Co-Ocurent Matrix Dan K-Nearest Neighbor," 2016.
- [11] N. Ameliana, N. Suarna, and W. Prihartono, "Analisis Data Mining Pengelompokkan Umkm Menggunakan Algoritma K-Means Clustering Di Provinsi Jawa Barat," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 3, pp. 3261–3268, 2024, doi: 10.36040/jati.v8i3.9655.
- [12] A. Agung, A. Daniswara, I. Kadek, and D. Nuryana, "Data Preprocessing Pola Pada Penilaian Mahasiswa Program Profesi Guru," *J. Informatics Comput. Sci.*, vol. 05, pp. 97–100, 2023.
- [13] Y. Kasnanda Bintang, H. Imaduddin, Y. Kasnanda, and B. Corresponding Author, "Pengembangan Model Deep Learning Untuk Deteksi Retinopati Diabetik Menggunakan Metode Transfer Learning," vol. 9, no. 3, pp. 1442–1455, 2024, [Online]. Available: <https://doi.org/10.29100/jipi.v9i3.5588>
- [14] F. Alghifari and D. Juardi, "Penerapan Data Mining Pada Penjualan Makanan Dan Minuman Menggunakan Metode Algoritma Naïve Bayes," *J. Ilm. Inform.*, vol. 9, no. 02, pp. 75–81, 2021, doi: 10.33884/jif.v9i02.3755.
- [15] M. Resa Arif Yudianto, P. Sukmasetya, R. Abul Hasani, and D. Sasongko, "Pengaruh Data Preprocessing terhadap Imbalanced Dataset pada Klasifikasi Citra Sampah menggunakan Algoritma Convolutional Neural Network," *Build. Informatics, Technol. Sci.*, vol. 4, no. 3, pp. 1367–1375, 2022, doi: 10.47065/bits.v4i3.2575.
- [16] K. R. Wardani and L. Leonardi, "Klasifikasi Penyakit pada Daun Anggur menggunakan Metode Convolutional Neural Network," *J. Tekno Insentif*, vol. 17, no. 2, pp. 112–126, 2023, doi: 10.36787/jti.v17i2.1130.
- [17] D. Anggara, N. Suarna, and Y. Arie Wijaya, "Performance Comparison Analysis Of Optimizer Adam, SGD, and RMSPROP on The H5 Model," *J. Ilm. NERO*, vol. 8, no. 1, p. 2023, 2023, [Online]. Available: <https://www.kaggle.com/datasets/jonathanoheix/face-expression-recognition-dataset>
- [18] F. D. Rochmawati, "Perkembangan Bahasa Pemrograman Komputer Di Amerika Serikat Tahun 1955-1995," *Skripsi*, pp. 1–86, 2022, [Online]. Available: <http://digilib.uinkhas.ac.id/17639/1/FltriaDewiRochmawati.pdf>
- [19] Vian Armando, "BAB 3 Precision, Recall dan Accuracy," pp. 9–12, 2017.
- [20] R. Nurhidayat and K. E. Dewi, "Penerapan Algoritma K-Nearest Neighbor Dan Fitur

Ekstraksi N-Gram Dalam Analisis Sentimen Berbasis Aspek,” *Komputa J. Ilm. Komput. dan Inform.*, vol. 12, no. 1, pp. 91–100, 2023, doi: 10.34010/komputa.v12i1.9458.