

IMPLEMENTASI ALGORITMA *CONVOLUTIONAL NEURAL NETWORK* (CNN) PADA KLASIFIKASI GRADE JENIS SAMPAH PLASTIK DAN KALENG

Muhammad Fadli Setiawan^{1*}, Aris Haris Rismawana²

^{1,2}Prodi Teknik Informatika, Politeknik TEDC Bandung, Jl. Politeknik Jl. Pesantren, Cibabat, Kec. Cimahi Utara, Kota Cimahi, Jawa Barat 40513

Keywords:

Convolutional Neural Network, MobileNetV2, Image Classification, Plastic Waste, Can Waste, Streamlit

Correspondent Email:

fadliim4321@gmail.com

Abstrak. Pengelolaan sampah menjadi isu serius di perkotaan karena volume yang terus meningkat dan beragamnya kondisi sampah. Di Kota Bandung, sampah plastik dan kaleng dengan kondisi utuh maupun penyok sering kali menyulitkan proses pemilahan manual, yang memakan waktu dan rawan kesalahan. Penelitian ini menawarkan solusi klasifikasi otomatis menggunakan *Convolutional Neural Network* (CNN) dengan pendekatan *transfer learning* MobileNetV2. Dataset citra diperoleh dari *Kaggle* dan diproses melalui normalisasi serta resize sebelum pelatihan model. Hasil pengujian menunjukkan akurasi 84,33%, dengan performa terbaik pada kelas logam (precision dan *recall* >87%) serta terendah pada plastik penyok (*recall* 66,67%). Model diintegrasikan dalam antarmuka *Streamlit* untuk prediksi real-time. Temuan ini menegaskan bahwa CNN mampu mendukung pemilahan sampah plastik dan kaleng secara lebih cepat dan konsisten, meskipun peningkatan data masih dibutuhkan untuk memperkuat performa pada kelas tertentu.



Copyright © JITET (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

Abstract. Waste management is a critical issue in urban areas due to increasing volumes and diverse waste conditions. In Bandung City, plastic and can waste with intact or dented states often complicate manual sorting, which is time-consuming and error-prone. This study proposes an automatic classification solution using *Convolutional Neural Network* (CNN) with a *MobileNetV2 transfer learning* approach. The dataset was obtained from *Kaggle* and preprocessed through normalization and resizing before training. Experimental results achieved 84.33% accuracy, with the best performance in metal classes (precision and recall above 87%) and the lowest in dented plastic (recall 66.67%). The model was integrated into a *Streamlit*-based interface for real-time prediction. These findings highlight CNN's effectiveness in supporting faster and more consistent waste classification, although further dataset expansion is needed to improve performance in specific categories.

1. PENDAHULUAN

Pengelolaan sampah anorganik khususnya plastik dan kaleng merupakan tantangan serius di Indonesia karena kedua material ini sulit terurai dan seringkali mengganggu sistem daur ulang [1][2]. Data Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) mencatat bahwa timbulan sampah nasional pada tahun 2024 mencatat bahwa komposisi sampah nasional didominasi oleh sisa makanan sebesar 39,23 persen, diikuti oleh plastik

sebesar 19,75 persen dan logam sebesar 3,44 persen [1]. Meskipun persentase logam relatif kecil, kedua jenis sampah ini memiliki nilai ekonomi tinggi jika didaur ulang tetapi justru menjadi polutan persisten jika tidak terkelola dengan baik. Plastik memerlukan waktu ratusan tahun untuk terurai [2], sedangkan kaleng aluminium dapat bertahan 200 hingga 500 tahun di lingkungan [3].

Sebagian besar pemilahan sampah di Indonesia masih dilakukan secara manual oleh

petugas baik di bank sampah maupun di fasilitas daur ulang. Proses ini membutuhkan tenaga manusia dalam jumlah besar, rentan terhadap kesalahan identifikasi akibat kelelahan, dan tidak konsisten dari segi kualitas pemilahan [4]. Kondisi ini menyebabkan keterlambatan proses daur ulang, peningkatan biaya operasional, dan rendahnya efisiensi pemanfaatan kembali material.

Kemajuan teknologi kecerdasan buatan khususnya *deep learning* telah memberikan terobosan signifikan dalam klasifikasi citra visual. Salah satu metode yang paling efektif untuk pengenalan pola visual adalah *Convolutional Neural Network* (CNN) yang terbukti unggul dalam mengenali pola visual kompleks melalui proses pembelajaran fitur bertingkat [5]. CNN telah diimplementasikan di berbagai bidang seperti deteksi wajah, sistem pengawasan, dan pencitraan medis.

Pada ranah pengelolaan sampah, beberapa penelitian di Indonesia telah menerapkan CNN untuk membedakan kategori sampah umum. Haqqi dkk. [6] mengembangkan CNN untuk klasifikasi enam jenis sampah dengan akurasi 95 persen. Prosisko dkk. [7] menggunakan MobileNet untuk klasifikasi di bank sampah dengan akurasi hingga 96 persen pada kategori logam. Saputra dkk. [8] mengaplikasikan VGG-16 dengan akurasi validasi 84,62 persen.

Mayoritas studi tersebut hanya fokus pada perbedaan jenis material tanpa mempertimbangkan grade atau kondisi fisik sampah. Padahal perbedaan kondisi fisik seperti plastik utuh dan plastik penyok atau kaleng utuh dan kaleng penyok berpengaruh pada nilai jual, metode penanganan, dan kelayakan material untuk proses daur ulang tertentu. Kesenjangan ini menjadi dasar penelitian untuk mengimplementasikan algoritma CNN dalam mengklasifikasikan grade sampah plastik dan kaleng menjadi beberapa kategori. Dengan pendekatan ini diharapkan proses pengelolaan sampah dapat dilakukan lebih efisien, akurat, dan mendukung program daur ulang yang berkelanjutan.

2. TINJAUAN PUSTAKA

2.1. Pengelolaan Sampah

Sampah adalah sisa kegiatan sehari-hari manusia dan/atau proses alam yang berbentuk padat, sebagaimana didefinisikan dalam Undang-Undang Nomor 18 Tahun 2008 tentang

Pengelolaan Sampah [9]. Berdasarkan sifatnya, sampah dibedakan menjadi organik, yang dapat terurai secara alami, dan anorganik, yang sulit terurai seperti plastik, logam, kaca, dan kertas [10]. Sampah anorganik memerlukan penanganan khusus karena dapat mencemari lingkungan dalam jangka panjang serta menurunkan kualitas lingkungan hidup [11]. Pengelolaan sampah di Indonesia dilaksanakan dengan prinsip Reduce, Reuse, Recycle (3R) yang bertujuan mengurangi timbunan sampah di sumbernya, memanfaatkan kembali barang bekas, dan mendaur ulang material bernilai ekonomis [12].

2.2. Grade Sampah

Grade sampah merupakan pengelompokan material berdasarkan kualitas fisik dan tingkat kebersihan yang memengaruhi harga jual serta kelayakan daur ulang. Misalnya, dalam pengolahan limbah koper granular tembaga, sistem penilaian berbasis visi komputer dan *deep learning* mampu mengevaluasi tingkat kemurnian (*purity*) dan menentukan rating level yang mencerminkan kontaminasi—sehingga klasifikasi ini bukan hanya didasarkan pada bahan, tetapi juga kebersihannya secara visual dan fisik [13]. Sedangkan untuk logam baja bekas, pendekatan pengklasifikasian menggunakan fitur ketebalan dari citra RGB-D dan algoritma pembelajaran mendalam telah dikembangkan untuk menilai grade—menentukan apakah baja memiliki bentuk/ketebalan yang layak dan bebas cacat sebagai bagian dari proses grading [14].

2.3. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan arsitektur *deep learning* yang banyak digunakan untuk pengolahan citra digital karena kemampuannya mengekstraksi fitur secara otomatis [15]. Lapisan konvolusi (*convolutional layer*) berfungsi mendeteksi pola lokal pada citra, seperti tepi, tekstur, dan bentuk [16], dengan cara melakukan operasi konvolusi antara citra input I dan *kernel/filter* K sehingga menghasilkan *feature map* F yang dapat dirumuskan secara matematis:

$$F(i, j) = \sum_m \sum_n I(i + m, j + n) \cdot K(m, n) \quad (1)$$

Setelah fitur diekstraksi, lapisan pooling (*pooling layer*) mereduksi dimensi spasial dari *feature map*, misalnya melalui *max pooling*, yang hanya mempertahankan nilai maksimum dalam sebuah jendela, sehingga mengurangi jumlah parameter dan memperkuat kemampuan generalisasi model [17]. Lapisan *fully connected* kemudian menghubungkan semua neuron dari lapisan sebelumnya untuk melakukan klasifikasi akhir berdasarkan fitur yang diekstraksi [18].

2.4. MobileNetV2

MobileNetV2 adalah arsitektur *Convolutional Neural Network* (CNN) yang efisien untuk perangkat dengan sumber daya terbatas. Model ini menggunakan *depthwise separable convolution* untuk mengurangi jumlah parameter dan mempercepat inferensi, serta memperkenalkan *inverted residuals* dan *linear bottlenecks* yang mempertahankan kapasitas representasional secara efisien [19]. Struktur ini membuat MobileNetV2 ideal untuk aplikasi real-time pada perangkat edge, seperti klasifikasi citra dan deteksi objek. Sebagai contoh, studi klasifikasi Brand sepatu Nike di Indonesia menunjukkan model ini mampu mencapai akurasi tinggi dengan penggunaan sumber daya yang rendah [20].

2.5. Streamlit

Streamlit adalah pustaka Python *open-source* yang memungkinkan pembuatan aplikasi web interaktif dengan cepat dan sederhana [21]. Framework ini memudahkan pengembang menampilkan data, grafik, dan antarmuka interaktif tanpa perlu keahlian front-end [22], sehingga ideal untuk prototipe sistem machine learning. Streamlit mendukung pembaruan otomatis saat kode disimpan dan kompatibel dengan pustaka ilmiah populer seperti NumPy, Pandas, dan Matplotlib, mempermudah integrasi data dan visualisasi.

3. METODE PENELITIAN

3.1. Identifikasi Masalah

Pengelolaan sampah merupakan masalah penting di banyak kota besar, termasuk Kota Bandung. Sampah plastik dan kaleng yang terdapat di lingkungan memiliki berbagai kondisi fisik, seperti utuh dan penyok. Namun, proses klasifikasi sampah berdasarkan kondisi tersebut masih banyak dilakukan secara manual

oleh petugas, sehingga memakan waktu dan berpotensi menyebabkan kesalahan klasifikasi.

Oleh karena itu, diperlukan suatu sistem otomatis yang dapat mengklasifikasikan jenis dan grade sampah secara cepat dan akurat untuk mendukung pengelolaan dan pemilahan sampah yang lebih efektif. Permasalahan yang akan dibahas dalam penelitian ini adalah bagaimana menerapkan algoritma *Convolutional Neural Network* (CNN) untuk melakukan klasifikasi grade sampah plastik dan kaleng berdasarkan kondisi fisiknya (utuh atau penyok). Penelitian ini bertujuan untuk mengembangkan model klasifikasi citra yang mampu mengenali dan membedakan kondisi sampah plastik dan kaleng secara otomatis dengan menggunakan dataset gambar yang diperoleh dari Kaggle.

3.2. Tujuan dan Ruang Lingkup Penelitian

Tujuan utama penelitian ini adalah mengimplementasikan algoritma *Convolutional Neural Network* (CNN) dalam mengklasifikasikan grade jenis sampah plastik dan kaleng berdasarkan kondisi fisiknya, yaitu utuh dan penyok. Model yang dikembangkan diharapkan mampu memproses gambar sampah secara otomatis dan menghasilkan prediksi yang akurat, sehingga dapat mempercepat proses pemilahan sampah sekaligus mengurangi kesalahan akibat klasifikasi manual.


Ruang lingkup penelitian ini dibatasi pada:

1. Dua jenis sampah, yaitu plastik dan kaleng.
2. Dua kelas grade, yaitu utuh dan penyok.
3. Dataset yang digunakan bersumber dari platform publik Kaggle.
4. Data lapangan hanya berupa observasi kualitatif terhadap keluhan dan pengalaman petugas Dinas Lingkungan Hidup Kota Bandung tanpa pengambilan gambar langsung.

Penelitian ini berfokus pada pengembangan dan evaluasi model CNN untuk klasifikasi citra dan tidak mencakup implementasi sistem menyeluruh seperti integrasi perangkat keras.

3.3. Metode yang Diusulkan

Metode penelitian ini dirancang untuk mengklasifikasikan grade jenis sampah plastik dan kaleng menggunakan algoritma CNN dengan antarmuka aplikasi berbasis Streamlit. Alur metode penelitian ditunjukkan pada Gambar 1



Gambar 1. Alur metode penelitian yang diusulkan

Adapun tahapan metode penelitian yang di jelaskan pada Gambar 1 adalah sebagai berikut:

1. Pengumpulan Data: pengunduhan dataset citra plastik dan kaleng dari Kaggle.
2. Preprocessing Data: citra diubah ukurannya menjadi 224×224 piksel dan dilakukan normalisasi piksel ke rentang 0–1.
3. Perancangan Model CNN: CNN dibangun menggunakan arsitektur MobileNetV2 dengan pendekatan *transfer learning*.
4. Pelatihan Model: dilakukan selama 10 *epoch* dengan *optimizer* Adam (*learning rate* = 0,0001) dan fungsi *loss categorical crossentropy*.
5. Evaluasi Model: performa diukur menggunakan akurasi, precision, recall, F1-score, dan *confusion matrix*.
6. Implementasi UI: Model terlatih diintegrasikan ke dalam antarmuka berbasis Streamlit untuk klasifikasi otomatis.

3.4. Analisis

Analisis dilakukan dengan mengukur performa model CNN menggunakan metrik akurasi, precision, recall, dan F1-score. Selain itu, analisis kesalahan klasifikasi juga dilakukan untuk mengidentifikasi faktor penyebab model gagal mengenali beberapa gambar, seperti kualitas gambar atau kondisi fisik sampah yang ambigu. Dengan demikian, penulis dapat memberikan rekomendasi untuk perbaikan dan pengembangan model.

3.5. Penarikan Kesimpulan

Berdasarkan hasil pelatihan dan evaluasi model CNN pada dataset gambar sampah plastik dan kaleng, penulis menyimpulkan

bahwa algoritma CNN efektif dalam klasifikasi grade sampah tersebut. Model mampu membedakan kondisi utuh dan penyok dengan akurasi memadai. Penulis juga memberikan rekomendasi pengembangan lanjutan seperti penambahan variasi data, pengujian di lapangan, dan penerapan sistem klasifikasi otomatis dalam pengelolaan sampah yang lebih modern dan efisien.

4. HASIL DAN PEMBAHASAN

4.1. Deskripsi Dataset

Dataset yang digunakan dalam penelitian ini diperoleh dari beberapa sumber publik di platform Kaggle dan sumber daring lainnya. Seluruh data dikumpulkan, digabungkan, dan melalui tahap pembersihan (*data cleaning*) untuk memastikan kualitas dan relevansi. Data yang digunakan terbagi menjadi empat kelas: Logam GRADE A, Logam GRADE B, Plastik GRADE A, dan Plastik GRADE B.

Untuk memperjelas karakteristik dataset, Tabel 1 menunjukkan contoh sampel citra dari masing-masing kategori, yakni logam grade A, logam grade B, plastik grade A, dan plastik grade B. Visualisasi ini membantu memahami perbedaan visual antar kelas yang akan diklasifikasikan oleh model CNN.

Tabel 1. Dataset sampah plastik dan kaleng berdasarkan grade

Kelas	Grade A	Grade B
Logam		
Plastik		

Data citra yang digunakan memiliki resolusi 224x224 piksel dan berformat RGB. Setiap citra diambil dalam kondisi pencahayaan yang cukup dan latar belakang yang seragam untuk meminimalkan noise dan gangguan dalam proses klasifikasi.

Data dibagi menjadi tiga subset: *train set* untuk pelatihan model, *validation set* untuk memantau kinerja selama pelatihan, dan *test set* untuk pengujian akhir. Proporsi pembagian adalah 70% untuk *train set*, 15% untuk *validation set*, dan 15% untuk *test set*. Distribusi jumlah citra tiap kelas pada setiap subset dapat dilihat pada Tabel 2

Tabel 2. Distribusi jumlah data pada setiap subset

Subset	Logam GRADE A	Logam GRADE B	Plastik GRADE A	Plastik GRADE B	Total
Train	385	385	233	233	1.236
Val	82	82	50	50	264
Test	83	83	51	51	268
Total	550	550	334	334	1.768

Berdasarkan Tabel 2 di atas, jumlah citra untuk kategori logam lebih besar dibandingkan kategori plastik. Hal ini perlu diperhatikan karena ketidakseimbangan jumlah data dapat memengaruhi distribusi pembelajaran model.

4.2. Implementasi Model CNN

Penelitian ini menggunakan arsitektur MobileNetV2 yang telah dipra-latih (*pre-trained*) pada dataset ImageNet. Teknik *transfer learning* digunakan untuk memanfaatkan kemampuan ekstraksi fitur dari model ini, kemudian dilakukan *fine-tuning* agar sesuai dengan dataset spesifik.

Model terdiri dari base model MobileNetV2 yang dibekukan bobotnya, diikuti oleh:

1. Global Average Pooling untuk mereduksi dimensi fitur.
2. Dense Layer dengan 128 neuron dan aktivasi ReLU.
3. Dropout sebesar 0,5 untuk mencegah *overfitting*.
4. Dense Output Layer dengan 4 neuron dan aktivasi Softmax, sesuai jumlah kelas.

Layer (type)	Output Shape	Param #
mobilenetv2_1.00_224 (Functional)	(None, 7, 7, 1280)	2,257,984
global_average_pooling2d (GlobalAveragePooling2D)	(None, 1280)	0
dense (Dense)	(None, 128)	163,968
dropout (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 4)	516

Total params: 2,422,468 (9.24 MB)
Trainable params: 164,484 (642.52 KB)
Non-trainable params: 2,257,984 (8.61 MB)

Gambar 2. Ringkasan arsitektur model MobileNetV2


Pada Gambar 2 menunjukkan bahwa total parameter model adalah 2.422.468, terdiri dari 164.484 trainable parameters dan 2.257.984 non-trainable parameters. Konfigurasi ini memastikan model mampu mempelajari pola baru tanpa menghilangkan pengetahuan bawaan dari MobileNetV2.

4.3. Implementasi Model CNN

Dalam penelitian ini, proses pelatihan dilakukan menggunakan arsitektur MobileNetV2 dengan metode *transfer learning*. Dataset yang digunakan telah melalui tahap pra-pemrosesan dan pembagian menjadi tiga subset, yaitu data latih (training set), data validasi (validation set), dan data uji (test set), sesuai proporsi yang telah dijelaskan pada subbab sebelumnya. Pembagian ini bertujuan untuk memastikan bahwa proses pelatihan, validasi, dan pengujian dapat memberikan gambaran menyeluruh mengenai kemampuan model dalam melakukan generalisasi pada data yang belum pernah dilihat sebelumnya.


Pelatihan berlangsung selama 10 *epoch* dengan menggunakan *optimizer* Adam dan *learning rate* sebesar 0,0001 (1e-4). Pemilihan *optimizer* Adam didasarkan pada kemampuannya dalam menggabungkan keunggulan AdaGrad dan RMSProp, sehingga dapat menyesuaikan *learning rate* untuk setiap parameter secara adaptif, yang terbukti efektif pada berbagai permasalahan klasifikasi citra.

Selama pelatihan, dilakukan evaluasi secara berkala pada setiap *epoch* terhadap dua metrik utama, yaitu akurasi dan *loss* untuk data latih dan validasi. Evaluasi ini berfungsi untuk memantau sejauh mana model mampu mempelajari pola dari data latih sekaligus mempertahankan kemampuan generalisasi pada data validasi.



Gambar 3. Grafik akurasi pada tahap train dan validasi

Berdasarkan Gambar 3 terlihat bahwa proses pelatihan model menunjukkan tren peningkatan akurasi yang konsisten baik pada data latih maupun data validasi. Pada *epoch* pertama, akurasi data latih tercatat sebesar 42%, sedangkan akurasi data validasi berada di kisaran 40%. Seiring bertambahnya jumlah *epoch*, nilai akurasi meningkat secara signifikan hingga mencapai 89% pada data latih dan 83% pada data validasi pada *epoch* terakhir. Peningkatan ini menandakan bahwa model mampu mempelajari pola dan fitur penting dari data secara bertahap selama proses pelatihan.



Gambar 4. Grafik loss pada tahap train dan validasi

Selain itu, grafik *loss* pada Gambar 4 menunjukkan penurunan nilai yang konsisten sepanjang pelatihan. Nilai *loss* data latih turun dari 1,30 pada awal pelatihan menjadi 0,36 pada *epoch* ke-10. Demikian pula, nilai *loss* pada data validasi mengalami penurunan dari 0,95 menjadi 0,44. Penurunan *loss* yang selaras antara data latih dan validasi mengindikasikan bahwa model tidak mengalami *overfitting* yang signifikan, serta mampu melakukan generalisasi dengan baik terhadap data yang belum pernah dilihat sebelumnya.

Secara keseluruhan, kombinasi peningkatan akurasi dan penurunan *loss* yang konsisten ini menunjukkan bahwa arsitektur MobileNetV2 yang digunakan dalam penelitian

ini berhasil dioptimalkan dengan baik untuk menyelesaikan tugas klasifikasi jenis dan grade sampah plastik serta logam.

4.4. Evaluasi Model

Tahap evaluasi dilakukan menggunakan *test set* yang berjumlah 268 citra dan tidak pernah digunakan pada proses pelatihan maupun validasi. Tujuannya adalah untuk mengukur kemampuan model dalam mengklasifikasikan citra yang benar-benar baru (*unseen data*). Evaluasi dilakukan dengan menghitung akurasi keseluruhan serta metrik klasifikasi lainnya seperti *precision*, *recall*, dan *F1-score*.


Hasil pengujian menunjukkan bahwa model mampu mencapai akurasi keseluruhan sebesar 84,33%. Nilai ini menandakan bahwa dari seluruh citra pada *test set*, sekitar 84% berhasil diklasifikasikan dengan benar sesuai kelasnya.

Tabel 3. Hasil evaluasi model pada data uji

Kelas	Precision (%)	Recall (%)	F1-Score (%)
Logam GRADE A	87,21	90,36	88,76
Logam GRADE B	87,21	90,36	88,76
Plastik GRADE A	77,78	82,35	80,00
Plastik GRADE B	80,95	66,67	73,12
Rata-rata	83,29	82,44	82,66
Akurasi keseluruhan	84,33	—	—

Dari Tabel 3 di atas dapat diamati bahwa kelas Logam GRADE A dan Logam GRADE B memiliki kinerja yang seimbang dengan nilai *precision* dan *recall* yang sama-sama tinggi, menunjukkan kemampuan model yang baik dalam mengenali kedua kelas tersebut. Sebaliknya, kinerja model pada kelas Plastik GRADE B cenderung lebih rendah, khususnya pada nilai *recall* sebesar 66,67%, yang berarti cukup banyak citra kelas ini yang salah diklasifikasikan menjadi kelas lain.

Analisis lebih lanjut dilakukan dengan memanfaatkan *confusion matrix* seperti pada Gambar 5. Matriks ini memperlihatkan distribusi prediksi model dibandingkan label sebenarnya.



Gambar 5. *Confusion matrix* hasil prediksi pada test set

Berdasarkan Gambar 5 diatas, terlihat bahwa kesalahan terbanyak pada kelas Plastik GRADE B adalah terklasifikasi sebagai Plastik GRADE A, diikuti oleh salah klasifikasi menjadi Logam GRADE B. Kesalahan ini diduga dipicu oleh kemiripan tekstur dan warna objek, khususnya ketika plastik memiliki permukaan mengkilap yang memantulkan cahaya seperti logam.


Jika dibandingkan dengan pengklasifikasian manual oleh pengamat manusia, model ini memiliki tingkat ketepatan yang relatif mendekati, meskipun manusia masih unggul dalam membedakan objek dengan kondisi pencahayaan buruk. Hal ini menunjukkan bahwa meskipun kinerja model cukup baik, pengaplikasian di lapangan tetap memerlukan prosedur pemeriksaan ulang pada kasus-kasus dengan citra ambigu.

Implikasi dari hasil evaluasi ini adalah bahwa model sudah layak untuk diintegrasikan ke dalam sistem pendukung keputusan pemilahan sampah, namun perlu dikombinasikan dengan proses *post-processing* atau pemeriksaan tambahan pada kelas yang rawan salah prediksi. Dengan demikian, risiko kesalahan klasifikasi yang dapat memengaruhi proses daur ulang dapat diminimalkan.

4.5. Implementasi UI dengan Streamlit

Model klasifikasi citra yang telah dilatih kemudian diintegrasikan ke dalam antarmuka berbasis Streamlit. Aplikasi ini dirancang sederhana agar dapat digunakan oleh pengguna non-teknis. Melalui antarmuka tersebut, pengguna dapat mengunggah gambar sampah

plastik atau kaleng, kemudian sistem secara otomatis menampilkan hasil prediksi jenis dan grade sampah.



Gambar 6. Tampilan prediksi menggunakan Streamlit

Tampilan antarmuka ditunjukkan pada Gambar 6 Setelah pengguna mengunggah citra, aplikasi menampilkan gambar input, hasil klasifikasi berupa jenis material serta kondisi fisiknya (utuh atau penyok), tingkat kepercayaan (confidence), dan visualisasi probabilitas dalam bentuk grafik batang. Dengan fitur ini, hasil prediksi dapat dipahami dengan mudah baik oleh petugas lapangan maupun pihak pengelola.

Implementasi antarmuka ini menunjukkan bahwa model CNN yang dikembangkan tidak hanya dapat diuji pada lingkungan pemrograman, tetapi juga dapat digunakan secara praktis melalui platform interaktif. Dengan demikian, aplikasi ini berpotensi mendukung proses pemilahan sampah secara lebih cepat, akurat, dan efisien dibandingkan metode manual.

4.6. Pembahasan

Model CNN berbasis MobileNetV2 mampu mengklasifikasikan citra sampah plastik dan kaleng dengan akurasi 84,33% pada data uji. Kinerja terbaik dicapai pada kelas logam (Grade A dan Grade B) dengan precision dan recall di atas 87%. Sebaliknya, kelas plastik

penyok memiliki performa terendah dengan recall sebesar 66,67%, yang disebabkan oleh kemiripan visual antara plastik utuh dan penyok.

Integrasi model ke dalam antarmuka memungkinkan proses klasifikasi dilakukan secara real-time, menampilkan hasil prediksi beserta nilai confidence dan distribusi probabilitas tiap kelas. Implementasi ini menunjukkan bahwa penelitian tidak hanya menghasilkan model dengan performa baik, tetapi juga memberikan prototipe aplikasi yang siap digunakan.

Secara keseluruhan, CNN dengan *transfer learning* dari MobileNetV2 terbukti efektif untuk klasifikasi kondisi sampah plastik dan kaleng. Namun, akurasi pada kelas plastik penyok masih perlu ditingkatkan, misalnya dengan memperluas variasi dataset atau mengeksplorasi arsitektur CNN lain seperti EfficientNet.

5. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, diperoleh kesimpulan sebagai berikut:

1. Model CNN berbasis MobileNetV2 dengan *transfer learning* berhasil dikembangkan untuk klasifikasi citra sampah plastik dan kaleng, dengan akurasi uji mencapai 84,33%.
2. Kelebihan model adalah kinerjanya yang baik pada kelas logam (Grade A dan Grade B), dengan precision dan recall di atas 87%, serta integrasinya ke antarmuka Streamlit yang memungkinkan prediksi real-time secara praktis.
3. Kekurangan model terletak pada performa kelas plastik penyok, dengan recall hanya 66,67% akibat kemiripan visual dengan plastik utuh, sehingga tingkat kesalahan klasifikasi masih relatif tinggi pada kategori tersebut.
4. Penelitian ini menunjukkan bahwa CNN dapat dimanfaatkan sebagai solusi pendukung pemilahan sampah otomatis. Namun, pengembangan lebih lanjut masih diperlukan, antara lain dengan memperluas variasi dataset, menambah jumlah data uji nyata dari lapangan, atau menggunakan arsitektur yang lebih kompleks seperti EfficientNet untuk meningkatkan akurasi.

DAFTAR PUSTAKA

- [1] Kehutanan Kementerian Lingkungan Hidup dan, "Sistem Informasi Pengelolaan Sampah Nasional (SIPSN)." Accessed: Aug. 15, 2025. [Online]. Available: <https://sipsn.menlhk.go.id/>
- [2] Kumparan News, "Tantangan Mendaur Ulang Limbah Plastik dan Karton di Indonesia," Kumparan. Accessed: Aug. 15, 2025. [Online]. Available: <https://kumparan.com/kumparannews/tantangan-mendaur-ulang-limbah-plastik-dan-karton-di-indonesia-20aUC5zELRq>
- [3] Fauzi, "Sampah-Sampah yang Sulit Terurai dan Berapa Lama Prosesnya," TeknosID. Accessed: Aug. 15, 2025. [Online]. Available: <https://www.teknosid.com/blog/sampah-sampah-yang-sulit-terurai-dan-berapa-lama-prosesnya>
- [4] I. yolia dewi Widayanti, J. Maulindar, and Nurchim, "Perancangan Sistem Sampah Organik Dan Anorganik Berbasis Mikrokontroler Menggunakan Sensor Proximity," *INFOTECH J.*, vol. 9, no. 1, pp. 207–214, 2023.
- [5] Y. LeCun, Y. Bengio, and G. Hinton, "Deep Learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [6] M. Haqqi, L. Rochmah, A. D. Safitri, R. A. Pratama, and Tarwoto, "Implementation Of Machine Learning To Identify Types Of Waste Using CNN Algorithm," *J. Fasilkom*, vol. 14, no. 3, pp. 761–765, 2024.
- [7] A. R. Fahcruroji, Madona Yunita Wijaya, and Irma Fauziah, "Implementasi Algoritma Cnn Mobilenet Untuk Klasifikasi Gambar Sampah Di Bank Sampah," *PROSISKO J. Pengemb. Ris. dan Obs. Sist. Komput.*, vol. 11, no. 1, pp. 45–51, 2024.
- [8] E. Sutanty and D. Kusuma Astuti, "DECODE: Jurnal Pendidikan Teknologi Informasi Penerapan Model Arsitektur Vgg16 Untuk Klasifikasi Jenis Sampah," vol. 3, no. 2, pp. 407–419, 2023.
- [9] Republik Indonesia, *Undang-Undang Nomor 18 Tahun 2008 tentang Pengelolaan Sampah*. Indonesia: Undang-Undang Republik Indonesia Nomor 18 Tahun 2008 tentang Pengelolaan Sampah, 2008.
- [10] 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. 142–149, 2022.
- [11] A. Taufiq and M. F. Maulana, "Sosialisasi Sampah Organik dan Non Organik Serta

- Pelatihan Kreasi Sampah,” *J. Inov. dan Kewirausahaan*, vol. 4, no. 1, pp. 68–73, 2015.
- [12] R. Budi Setianingrum, “Pengelolaan Sampah Dengan Pola 3 R Untuk Memperoleh Manfaat Ekonomi Bagi Masyarakat,” *BERDIKARI J. Inov. dan Penerapan Ipteks*, vol. 6, no. 2, pp. 173–183, 2018.
- [13] K. Zhao, Y. Cui, Z. Liu, and S. Lian, “A Waste Copper Granules Rating System Based on Machine Vision,” pp. 1–9.
- [14] W. Xu, P. Xiao, L. Zhu, Y. Zhang, and J. Chang, “Engineering Applications of Artificial Intelligence Classification and rating of steel scrap using deep learning,” *Eng. Appl. Artif. Intell.*, vol. 123, no. January, p. 106241.
- [15] Anhar and R. A. Putra, “Perancangan dan Implementasi Self-Checkout System pada Toko Ritel menggunakan Convolutional Neural Network (CNN),” vol. 11, no. 2, pp. 466–478, 2023.
- [16] D. R. R. Putra, R. A. Saputra, and M. A. Asyrofi, “Implementasi Convolutional Neural Network (Cnn) Untuk Mendeteksi Penggunaan Masker Pada Gambar,” *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 3, pp. 710–714, 2023.
- [17] A. Prayoga, P. Sukmasetya, M. Resa, A. Yudianto, and R. A. Hasani, “Journal Of Applied Computer Science And Technology (JACOST) Arsitektur Convolutional Neural Network untuk Model Klasifikasi Citra Batik Yogyakarta,” vol. 4, no. 2, pp. 82–89, 2023.
- [18] G. R. Baihaqi *et al.*, “Implementasi Convolutional Neural Network Untuk Convolutional Neural Network Implementation For Colon,” vol. 12, no. 2, pp. 411–416, 2025.
- [19] M. Sandler, M. Zhu, A. Zhmoginov, and C. V Mar, “MobileNetV2: Inverted Residuals and Linear Bottlenecks”.
- [20] S. Saalim, R. Atmadja, A. H. Rismayana, P. Studi, and T. Informatika, “Klasifikasi Brand Sepatu Nike Berbasis Citra Dengan Algoritma Convolution Neural Network (Cnn),” vol. 25, pp. 67–74, 2025.
- [21] Streamlit, “Streamlit: A faster way to build and share data apps.” Accessed: Aug. 15, 2025. [Online]. Available: <https://streamlit.io/>
- [22] A. Tholib, *Implementasi Machine Learning berbasis Web dengan Framework Streamli*. Probolinggo: PustakaNurja, 2023.