

Pengembangan Algoritma Convolutional Neural Networks (CNN) dengan Penambahan Layer Konvolusi untuk Klasifikasi Objek dalam Gambar Sampah

Yoke Annisa Putri Vandalis, Sopian Soim*, Lindawati Lindawati

Teknik Elektro, Sarjana Terapan Teknik Telekomunikasi, Politeknik Negeri Sriwijaya, Palembang, Indonesia

Email: yokeannisa.putri@gmail.com, sopiansoim@gmail.com, lindawati@polsri.ac.id

Email Penulis Korespondensi: sopiansoim@gmail.com

Submitted: 15/07/2024; Accepted: 08/09/2024; Published: 09/09/2024

Abstrak—Sampah merupakan masalah serius yang dihadapi dunia saat ini, seiring dengan meningkatnya aktivitas manusia dan pertumbuhan ekonomi global. Salah satu langkah penting dalam pengelolaan sampah adalah proses klasifikasi sampah, yang bertujuan untuk memisahkan jenis-jenis sampah berdasarkan karakteristiknya sehingga dapat didaur ulang, diolah, atau dibuang dengan cara yang tepat. Dalam penelitian sebelumnya, *Convolutional Neural Network* (CNN) terbukti menjadi salah satu algoritma yang efektif untuk klasifikasi multi-kelas. Oleh karena itu, penelitian ini mengembangkan model klasifikasi sampah otomatis menggunakan CNN yang dioptimasi, dengan fokus utama pada peningkatan akurasi melalui modifikasi arsitektur CNN. Dataset yang digunakan terdiri dari 17.366 gambar sampah yang berasal dari berbagai sumber, yang kemudian dibagi menjadi data pelatihan dan pengujian setelah melalui proses *preprocessing* untuk memastikan kualitas data yang baik sebelum digunakan untuk melatih model. Namun, salah satu tantangan utama dalam mengembangkan model CNN untuk klasifikasi multi-kelas adalah risiko kesulitan dalam pembelajaran fitur kelas, terutama ketika model dihadapkan dengan kelas yang terlalu banyak. Untuk mengatasi masalah tersebut, penelitian ini menerapkan strategi dengan penggunaan metode penambahan lapisan konvolusi pada arsitektur CNN. Metode ini bertujuan untuk memperdalam jaringan sehingga mampu menangkap fitur-fitur yang lebih kompleks dari data yang diberikan, yang pada gilirannya dapat meningkatkan generalisasi model terhadap data baru. Hasil evaluasi menunjukkan bahwa model CNN yang dimodifikasi berhasil mencapai akurasi pelatihan sebesar 88% setelah 40 *epoch*, dengan akurasi *testing* di sekitar 83%. Penelitian ini tidak hanya memberikan kontribusi dalam pengembangan teknologi klasifikasi sampah otomatis yang lebih canggih, tetapi juga memberikan landasan yang kuat untuk penelitian lebih lanjut di bidang ini. Dengan meningkatnya efektivitas pengelolaan sampah, diharapkan dapat memberikan dampak positif terhadap lingkungan dan kesehatan masyarakat secara keseluruhan.

Kata Kunci: Convolutional Neural Network (CNN); Deep Learning; Klasifikasi; Sampah; Lingkungan

Abstract—Waste is a serious issue facing the world today, with increasing human activity and global economic growth. One important step in waste management is the classification process, which aims to separate types of waste based on their characteristics so they can be recycled, processed, or disposed of properly. Previous research has shown that Convolutional Neural Networks (CNN) are effective algorithms for multi-class classification. Therefore, this study develops an optimized CNN model for automatic waste classification, with a primary focus on improving accuracy through modifications to the CNN architecture. The dataset used consists of 17,366 waste images from various sources, which are then divided into training and testing data after undergoing preprocessing to ensure good data quality before training the model. However, one of the main challenges in developing a CNN model for multi-class classification is the risk of difficulty in learning class features, especially when the model is faced with too many classes. To address this issue, this study implements a strategy by adding convolutional layers to the CNN architecture. This method aims to deepen the network to capture more complex features from the given data, which in turn can improve the model's generalization to new data. Evaluation results show that the modified CNN model achieved a training accuracy of 88% after 40 epochs, with a testing accuracy of around 83%. This research not only contributes to the development of more advanced automatic waste classification technology but also provides a strong foundation for further research in this field. With increased waste management effectiveness, it is hoped to have a positive impact on the environment and public health as a whole.

Keywords: Convolutional Neural Network (CNN); Deep Learning; Classification; Waste; Environment

1. PENDAHULUAN

Setiap kegiatan dan langkah yang dilakukan manusia sehari-hari, mulai dari bangun tidur hingga tidur di malam hari, dapat dipastikan menghasilkan limbah atau sampah. Oleh karena itu, sejak dahulu, sampah telah menjadi masalah utama bagi manusia [1-2]. Dengan perkembangan ekonomi, sosial, dan meningkatnya populasi, produksi limbah semakin bertambah [3]. Menghadapi situasi peningkatan pembuangan sampah dan degradasi lingkungan, bagaimana cara mengklasifikasikan sampah dengan akurat, memaksimalkan pemanfaatan sumber daya sampah, dan meningkatkan kualitas lingkungan hidup menjadi isu mendesak yang menjadi perhatian bersama di seluruh dunia [4-5]. Dorongan utama untuk menangani sampah dengan benar adalah kebutuhan mendesak untuk memulihkan keseimbangan ekologi yang telah terganggu [5]. Setiap pengelolaan sampah harus mengacu pada partisipasi dan keterlibatan semua elemen masyarakat. Salah satu caranya adalah dengan mengategorikan sampah individu, yang dapat dimulai dari sampah rumah tangga [6]. Namun, pemikiran masyarakat sendiri dapat menjadi salah satu faktor penghambat keberhasilan pengelolaan sampah. Dikatakan bahwa masih banyak negara berkembang yang cenderung membuang sampah sembarangan [7] dan kemungkinan ada masyarakat yang belum teredukasi dengan baik sehingga pengelolaan sampah belum dapat secara maksimal dilakukan

Setiap pengelolaan sampah harus mengacu pada partisipasi dan keterlibatan semua elemen masyarakat. Salah satu caranya adalah dengan mengkategorikan sampah individu, yang dapat dimulai dari sampah rumah tangga [6]. Kemajuan pesat dari pembelajaran mendalam mengenai perkembangan kecerdasan buatan dan teknologi dari visi komputer [8] yang ada telah memberikan kontribusi besar yang memunculkan teknologi klasifikasi sampah otomatis dapat menjadi angin segar dari permasalahan yang dihadapi seperti beban kerja, kesalahan dalam pemilahan [3]-[9] efisiensi waktu yang digunakan dan penghematan biaya yang akan dikeluarkan [10]-[11].

Teknologi yang digunakan merupakan penggabungan dari pembelajaran mesin dan analitik lanjutan dari karakteristik limbah dengan mempelajari gambar dalam pengklasifikasian secara otomatis [12], [13]. Dalam penelitian ini, *Convolutional Neural Network* (CNN) dipilih sebagai metode yang tepat untuk pengujian percobaan dalam mengklasifikasi 5 kelas yaitu *carboard*, *glass*, *metal*, *paper* dan *plastic*. CNN memiliki kemampuan mencapai tingkat akurasi tinggi, terutama dalam klasifikasi citra [14]. Metode klasifikasi menggunakan *Convolutional Neural Network* (CNN) adalah salah satu teknik utama dalam bidang *deep learning* yang telah secara luas diadopsi untuk pengenalan dan klasifikasi gambar. CNN menggunakan pendekatan berbasis hierarki untuk mengekstraksi fitur-fitur penting dari gambar dan mempelajari pola yang kompleks, sehingga memungkinkan gambar untuk diberi label sesuai dengan konten yang terkandung di dalamnya. Model ini telah membawa revolusi dalam berbagai aplikasi, termasuk dalam klasifikasi sampah padat [5]-[15]. Namun dalam penggunaannya mengenai klasifikasi banyak kelas, model CNN cukup kesulitan untuk mengekstrak fitur yang relevan yang membedakan antar kelas, terutama jika kelas-kelas tersebut memiliki kesamaan visual yang tinggi sehingga menyebabkan model tidak dapat generalisasi dengan baik pada data baru.


Melalui penambahan lapisan konvolusi pada model klasifikasi gambar limbah dapat memperkuat kemampuan model dalam mengekstraksi fitur dari gambar. Dengan menambah lebih banyak lapisan konvolusi, model mampu mempelajari representasi data gambar yang lebih kompleks dan mendalam, yang pada akhirnya dapat meningkatkan akurasi dalam klasifikasi [3]. Kemajuan dalam model ini didukung oleh penggunaan berbagai parameter yang meningkatkan efektivitasnya [16]. Misalnya, penggunaan fungsi aktivasi seperti ReLU (*Rectified Linear Unit*) membantu model menangani non-linearitas dalam data, sehingga memperbaiki kemampuan generalisasi dan akurasi prediksi [14]. Dari penelitian-penelitian sebelumnya sebagai acuan diantaranya menggunakan berbagai macam metode dan model yang beragam dalam pengembangan klasifikasi gambar otomatis. Namun tetap digunakan Algoritma *Convolutional Neural Networks* (CNN) dalam pengerjaan dan optimasi. Terlihat pada penelitian [3] memperlihatkan bagaimana *Convolutional Neural Networks* (CNN) melakukan perhitungan konvolusi dalam mengekstrak fitur daripada gambar, mengubah jumlah parameter model lalu dibantu oleh *Transfer Learning* sehingga akhirnya didapatkan akurasi sebesar 82.80%. Selain itu terbukti dengan. Namun pada penelitian ini terdapat kekurangan yaitu kurangnya uji coba dengan dataset eksternal untuk memvalidasi bagaimana keandalan dan kinerja model dalam konteks yang lebih luas.

Pada pengklasifikasian gambar didapatkan akurasi akhir sebesar 88.5% pada penelitian [17] dengan dataset yang sama dalam mengotomatisasi klasifikasi sampah dengan model yang saling dibandingkan setiap akurasi yang didapatkan pengenalan model yang ditingkatkan mencapai 96.55% dengan klasifikasi empat jenis sampah yaitu *food waste*, *recyclable waste*, *other waste*, dan *hazardous waste* [16]. Lalu dengan menguji percobaan klasifikasi yaitu berupa klasifikasi biner untuk memisahkan limbah organik dan limbah yang dapat didaur ulang dengan Akurasi yang didapatkan mencapai 93.28% [18]. Dilain hal terdapat 2 perbandingan dari pengujian cobaan pada arsitektur DCNN, yang dimana pada arsitektur DCNN dengan empat lapisan, akurasi klasifikasi adalah 61.67%, sedangkan pada arsitektur DCNN dengan lima lapisan, akurasi meningkat menjadi 70% [14]. Pada penelitian model yang menggunakan dataset *TrashNet* dan metode *hybrid Convolutional Neural Networks* (CNN) mencapai akurasi hingga 92% [5]. Lalu yang terakhir terdapat enam klasifikasi sampah dengan Akurasi yang didapatkan oleh dengan menggunakan metode *Multilayer Hybrid Convolution Neural Network* (MLH-CNN) adalah 92.6% pada penelitian [4].

Dari penjelasan sebelumnya, dapat disimpulkan bahwa *Convolutional Neural Network* (CNN) menunjukkan kinerja yang impresif dalam mengenali pola dan lokalisasi objek gambar, menetapkan standar dalam berbagai aplikasi pengenalan dan klasifikasi visual. Dengan pendekatan *deep learning*, terbukti dapat meningkatkan kemampuan sistem untuk mengenali dan mengklasifikasi sampah secara otomatis. Ini tidak hanya berpotensi meningkatkan akurasi model, tetapi juga berdampak positif terhadap upaya pengelolaan sampah di Indonesia, di mana peningkatan teknologi ini dapat membantu mengatasi tantangan dalam pengelolaan limbah yang semakin kompleks [19].

2. METODOLOGI PENELITIAN

Penelitian ini dilakukan untuk mengembangkan model algoritma *Convolutional Neural Network* (CNN) dari model CNN asli dengan mengklasifikasikan lima jenis sampah. Dalam pengembangannya, model dioptimalkan dengan melakukan modifikasi pada arsitektur lapisan CNN, bertujuan untuk mengevaluasi peningkatan akurasi model yang dibangun. Selanjutnya, akan dilakukan perbandingan antara model yang telah dioptimasi dengan model aslinya untuk menilai efektivitas dan peningkatan kinerja yang dicapai. Dapat dilihat alur metode penelitian pada Gambar 1



Gambar 1. Alur Penelitian

Penghimpunan data ini merupakan langkah awal yang sangat penting dalam penelitian ini, di mana dilakukan eksplorasi data gambar sampah dari berbagai sumber terpilih untuk kemudian dikompilasi menjadi satu dataset yang komprehensif. Data gambar sampah diambil dari beberapa situs web terkemuka seperti *Kaggle* dan *UC Irvine Machine Learning Repository*. Proses ini melibatkan pengunduhan, pengorganisasian, dan pengelompokan gambar-gambar sampah berdasarkan jenisnya. Dataset yang telah dikumpulkan mencakup total 17.366 gambar, yang terbagi menjadi 14.475 gambar untuk keperluan pelatihan (*training*) dan 2.891 gambar untuk pengujian (*testing*). Pembagian ini bertujuan untuk memastikan bahwa model yang dikembangkan dapat dilatih dengan baik dan diuji untuk menilai kinerjanya secara akurat. gambar-gambar dalam dataset ini diklasifikasikan ke dalam lima kategori utama secara berturut-turut, yaitu kardus, gelas, logam, kertas, dan plastik yang dapat dilihat pada Gambar 2.



Gambar 2. Contoh Dataset

Sebelum tahap modeling Arsitektur *Convolutional Neural Network (CNN)*, *preprocessing* data dilakukan untuk meningkatkan kualitas data dan kinerja model. *Preprocessing* ini melibatkan pembagian data menjadi 75% untuk pelatihan dan 25% untuk pengujian guna validasi model, serta proses penghubungan dan pelabelan pada dataset. Pada tahap pengembangan dan pelatihan model, arsitektur dasar *Convolutional Neural Network (CNN)* terdiri dari lapisan konvolusi untuk ekstraksi fitur dan lapisan ReLU untuk menambahkan non-linearitas. Lapisan pooling digunakan untuk mengurangi dimensi spasial, sementara *lapisan fully connected* menghubungkan *neuron*, dan lapisan output memberikan prediksi akhir. Struktur ini sangat efektif dalam pengolahan gambar untuk tujuan klasifikasi dan pengenalan. Selama pengembangan model, dilakukan metode penambahan 3 lapisan konvolusi tambahan untuk meningkatkan akurasi dan memperkuat dalam ekstraksi fitur yang lebih baik.

Dalam tabel 1, disajikan hyperparameter model yang digunakan dalam penelitian ini. Model ini terdiri dari 5 lapisan konvolusi dengan fungsi aktivasi ReLU dan lapisan *pooling*. Fitur-fitur yang diekstraksi oleh lapisan konvolusi diklasifikasikan oleh satu lapisan dense tunggal dalam jaringan *fully connected*. *Loss function* yang digunakan adalah *Categorical Cross-Entropy* karena kategori klasifikasi berjumlah lima. Fungsi aktivasi ReLU digunakan untuk menerapkan sparsitas aktivasi, di mana hanya sebagian kecil *neuron* yang aktif pada satu waktu tertentu. Ini dapat membantu dalam regularisasi model dan mencegah *overfitting*. Dengan 40 *epochs*, seluruh dataset pelatihan akan digunakan untuk memperbarui parameter model sebanyak 40 kali, dengan pembaruan parameter dilakukan setiap 32 sampel sesuai dengan ukuran batch yang digunakan.

Tabel 1. Hyperparameter Model

Parameter	Value
<i>Convolution Layer</i>	5
<i>Dense Layer</i>	1
<i>Loss Function</i>	<i>Categorical cross entropy</i>
<i>Activation function</i>	ReLU
<i>Optimizer</i>	Adam

<i>Number of epochs</i>	40
<i>Batch size</i>	32

Tujuan pengujian model adalah menghasilkan hasil klasifikasi sampah dari data uji yang digunakan. Evaluasi akurasi dilakukan dengan menggunakan metrik seperti akurasi, *precision*, *recall*, dan *F1-Score*. Akurasi mengukur seberapa baik model dalam mengidentifikasi kelas dengan benar secara keseluruhan. *Precision* mengevaluasi seberapa akurat model dalam mengidentifikasi kelas positif dari keseluruhan prediksi yang dibuat sebagai positif. *Recall* mengukur kemampuan model dalam mendeteksi semua instance positif dalam dataset, sehingga *recall* menunjukkan proporsi instance positif yang benar-benar terdeteksi oleh model dibandingkan dengan total instance positif yang ada dalam dataset. *F1-Score* digunakan untuk menyeimbangkan antara *precision* dan *recall*, memberikan gambaran yang lebih komprehensif tentang kinerja model. Persamaan 1 hingga 4 merupakan rumus untuk menghitung metrik-metrik tersebut[20].

Berdasarkan persamaan (1), akurasi dapat dihitung dengan membagi persentase prediksi positif dan negatif yang akurat dengan jumlah total data. Nilai akurasi dapat diperoleh menggunakan rumus berikut

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (1)$$

Persamaan (2) menjelaskan bahwa presisi adalah perbandingan antara jumlah total data positif yang diidentifikasi sebagai positif dengan jumlah total prediksi positif yang benar. Presisi dihitung menggunakan rumus berikut:

$$\text{Precision} = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

Recall didefinisikan sebagai rasio antara prediksi positif dengan semua data positif yang benar pada persamaan (3). Nilai recall dihitung menggunakan persamaan berikut:

$$\text{Recall} = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

F1-Score merupakan rata-rata harmonik dari recall dan precision, sebagaimana ditunjukkan pada persamaan (4). Rumus berikut digunakan untuk menghitung nilai F1-Score

$$\text{F1-Score} = 2 \left(\frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \right) \times 100 \quad (4)$$

Penjelasan

- True Positive (TP): Mewakili sampel gambar yang diklasifikasikan sebagai positif dan memang benar positif.
- True Negative (TN): Mewakili sampel gambar yang diklasifikasikan sebagai negatif dan memang benar negatif.
- False Positive (FP): Mewakili sampel gambar yang diklasifikasikan sebagai positif tetapi sebenarnya negatif.
- False Negative (FN): Mewakili sampel gambar yang diklasifikasikan sebagai negatif tetapi sebenarnya positif.


3. HASIL DAN PEMBAHASAN

3.1 Hasil

Pada penelitian yang dikembangkan, terlihat pada Gambar 3 akurasi pelatihan model Convolutional Neural Network (CNN) yang telah dimodifikasi dengan penambahan lapisan konvolusi tambahan. Modifikasi ini bertujuan untuk meningkatkan kemampuan generalisasi model dan mengurangi overfitting, yang merupakan masalah umum dalam pelatihan model deep learning ketika model terlalu sesuai dengan data pelatihan sehingga tidak berkinerja baik pada data yang tidak terlihat sebelumnya.

Penambahan lapisan konvolusi dirancang untuk menangkap fitur-fitur yang lebih kompleks dari gambar sampah yang digunakan dalam *dataset*. Dengan demikian, model dapat lebih akurat dalam mengenali dan mengklasifikasikan berbagai jenis sampah. Dari Gambar 3, terlihat bahwa model yang telah dimodifikasi mencapai keseimbangan yang baik antara akurasi pelatihan dan akurasi validasi. Pada garis biru yang mewakili akurasi pelatihan, akurasi dimulai dari sekitar 30% dan meningkat secara bertahap seiring bertambahnya jumlah *epoch*, hingga mencapai sekitar 85% hingga 88% pada epoch ke-40. Hal ini menunjukkan bahwa model berhasil belajar dengan baik dari data pelatihan tanpa mengalami *overfitting* yang signifikan.

Sementara itu, garis oranye yang mewakili akurasi validasi juga menunjukkan tren peningkatan yang stabil. Akurasi validasi dimulai dari sekitar 30% dan meningkat dengan cepat hingga mencapai sekitar 80% pada epoch ke-10. Setelah itu, akurasi validasi mengalami beberapa fluktuasi, namun tetap cenderung stabil di sekitar 80% hingga 83% hingga akhir pelatihan. Fluktuasi ini dapat disebabkan oleh beberapa faktor, termasuk variabilitas dalam data validasi dan proses pelatihan yang *stochastik*. Namun, kestabilan yang ditunjukkan oleh akurasi validasi setelah epoch ke-10 menunjukkan bahwa model tidak mengalami *overfitting* yang parah dan mampu mempertahankan kinerjanya pada data yang tidak terlihat.



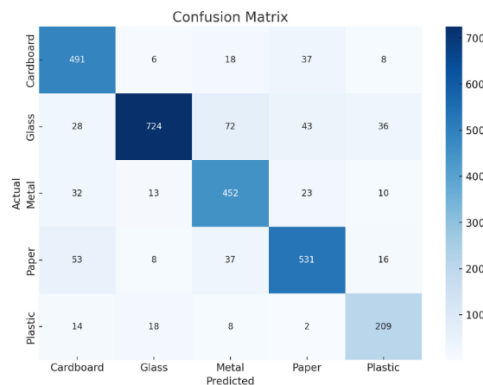
Gambar 3. Hasil Akurasi dari Model CNN setelah Perbaikan

Sesuai dengan Tabel 2, Hasil uji ini menunjukkan bahwa model yang dikembangkan memiliki tingkat akurasi sebesar 83%, yang berarti model mampu mengklasifikasikan sampah dengan benar dalam 83% dari total gambar yang diuji. Selain itu, *precision* atau ketepatan prediksi model mencapai 84%, yang berarti dari semua prediksi positif yang dibuat oleh model, 84% adalah benar-benar positif yang dihitung dengan Persamaan (1). *Recall* atau sensitivitas model berada pada angka 82%, yang menunjukkan bahwa model berhasil mengidentifikasi 82% dari semua sampah yang sebenarnya positif yang dihitung dengan Persamaan (2). F1-score, yang merupakan rata-rata harmonis dari *precision* dan *recall*, mencapai 83%, menunjukkan keseimbangan yang baik antara kemampuan model dalam mendeteksi sampah yang benar-benar ada dan menghindari kesalahan deteksi yang dihitung dengan Persamaan (3). Untuk menghitung persamaan tersebut digunakan *confusion Matrix* pada Gambar 4 mengilustrasikan hasil klasifikasi ini dengan jelas, memperlihatkan bagaimana model mengklasifikasikan setiap kategori sampah dan dimana kesalahan klasifikasi terjadi.

Tabel 2. Hasil Evaluasi dari Model CNN

Data	Akurasi	Precision	Recall	F1-Score
Data Uji	83%,	84%	82%	83%,

Confusion matrix yang ditampilkan dalam Gambar 4. merupakan alat evaluasi kinerja model klasifikasi sampah. Baris pada matriks ini mewakili kelas sampah yang sebenarnya, yakni *Cardboard*, *Glass*, *Metal*, *Paper*, dan *Plastic*, sedangkan kolomnya menunjukkan prediksi yang dilakukan oleh model. Angka-angka dalam sel matriks menunjukkan jumlah instance dari kelas sebenarnya yang diprediksi sebagai kelas tertentu. Misalnya, 491 gambar sampah cardboard diklasifikasikan dengan benar sebagai cardboard, sedangkan 28 gambar cardboard salah diklasifikasikan sebagai Glass. Diagonal utama dari kiri atas ke kanan bawah menunjukkan jumlah prediksi yang benar untuk setiap kelas, seperti 724 gambar Glass dan 452 gambar Metal yang diklasifikasikan dengan benar. Angka di luar diagonal utama menunjukkan jumlah kesalahan klasifikasi, seperti 72 gambar Glass yang salah diklasifikasikan sebagai Metal dan 53 gambar Paper yang salah diklasifikasikan sebagai Cardboard. Warna sel pada matriks mencerminkan jumlah instance, dengan warna yang lebih gelap menunjukkan jumlah yang lebih tinggi. Dari matriks ini, terlihat bahwa model berperforma cukup baik pada sebagian besar kelas, terutama pada Glass dengan jumlah prediksi benar tertinggi (724).



Gambar 4. Confusion Matrix

Tabel 3 tersebut membandingkan kinerja dua model Convolutional Neural Network (CNN) dalam klasifikasi sampah, yaitu model CNN dari penelitian sebelumnya dan model CNN yang telah dikembangkan dalam penelitian ini. Model CNN dari penelitian sebelumnya memiliki akurasi sebesar 82.80%, yang menunjukkan bahwa model tersebut dapat mengklasifikasikan sampah dengan benar dalam 82.80% dari total kasus. Sementara itu, model CNN

yang dikembangkan dalam penelitian ini memiliki akurasi yang lebih tinggi, yaitu 83%. Hal ini menunjukkan adanya peningkatan kinerja dalam klasifikasi sampah.

Selain itu, *precision* dari model sebelumnya adalah 82.64%, yang berarti dari semua prediksi positif yang dibuat oleh model, 82.64% adalah benar-benar positif. *Precision* dari model yang dikembangkan adalah 84%, menunjukkan peningkatan kemampuan model untuk mengidentifikasi sampah dengan benar dari prediksi yang dibuat. *Recall* dari model sebelumnya adalah 82.82%, yang berarti dari semua sampah yang sebenarnya positif, model berhasil mengidentifikasi 82.82% di antaranya. Sedangkan *recall* dari model yang dikembangkan adalah 82%, sedikit lebih rendah dari model sebelumnya tetapi tetap menunjukkan kinerja yang baik dalam mengidentifikasi sampah yang benar-benar positif.

F1-Score dari model sebelumnya adalah 82.61%, yang merupakan rata-rata harmonis dari *precision* dan *recall*. F1-Score dari model yang dikembangkan adalah 83%, menunjukkan peningkatan kinerja keseluruhan dalam keseimbangan antara *precision* dan *recall*. Secara keseluruhan, hasil ini menunjukkan bahwa model CNN yang dikembangkan dalam penelitian ini memiliki kinerja yang lebih baik dibandingkan dengan model dari penelitian sebelumnya dalam hal akurasi, *precision*, dan F1-Score, meskipun ada sedikit penurunan pada *recall*.

Tabel 3 Komparisasi Evaluasi Model

Algorithm	Akurasi	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
CNN Penelitian [3]	82.80%	82.64%	82.82%	82.61%
Pengembangan CNN	83%	84%	82%	83%

3.2 Implementasi/Pengujian (bila ada)


Dalam memastikan kinerja dan akurasi model, kami menggunakan dataset bebas yang diambil dari berbagai sumber di Google. *Dataset* bebas ini terdiri dari gambar-gambar yang diambil secara acak dan beragam untuk memastikan bahwa model diuji dengan berbagai jenis gambar yang realistis. Setiap gambar diproses untuk memastikan keseragaman dalam ukuran dan skala warna, diubah ukurannya menjadi 150x150 *piksel*, dan dinormalisasi agar nilai *piksel* berada dalam rentang [0, 1].

Pada Gambar 5 menunjukkan sebuah kotak kardus yang diprediksi sebagai "*cardboard*" (kardus) dengan tingkat *confidence* sebesar 1.00 atau 100%. Artinya, model yang digunakan untuk mengklasifikasikan objek dalam gambar sangat yakin bahwa objek tersebut adalah kardus.



Gambar 5. Hasil Prediksi *Cardboard*

Pada Gambar 6 menunjukkan sebuah wadah gelas yang diprediksi sebagai "*glass*" dengan tingkat kepercayaan sebesar 0.99 atau 99%. Artinya, model yang digunakan untuk mengklasifikasikan objek dalam gambar sangat yakin bahwa objek tersebut adalah gelas.



Gambar 6. Hasil Prediksi *Glass*

Pada Gambar 7 menunjukkan sebuah kaleng minuman yang diprediksi sebagai "*metal*" (logam) dengan tingkat *confidence* sebesar 1.00 atau 100%. Artinya, model yang digunakan untuk mengklasifikasikan objek dalam gambar sangat yakin bahwa objek tersebut adalah logam.

Predicted: metal, Confidence: 1.00



Gambar 7. Hasil Prediksi *Metal*

Pada Gambar 8 menunjukkan selembar kertas dengan prediksi "*paper*" dan tingkat kepercayaan sebesar 1.00 atau 100%. Artinya, model yang digunakan untuk mengklasifikasikan objek dalam gambar sangat yakin bahwa objek tersebut adalah kertas.

Predicted: paper, Confidence: 1.00



Gambar 8. Hasil Prediksi Glass Hasil Prediksi *Paper*

Pada Gambar 9 di atasnya tertulis "*Predicted: plastic, Confidence: 0.60,*" yang berarti model mengidentifikasi objek sebagai plastik dengan kepercayaan 60%. Objek dalam gambar adalah botol plastik yang terlihat remuk atau terdeformasi. Tingkat kepercayaan 0.60 menunjukkan keyakinan model yang cukup, tapi tidak sepenuhnya pasti. Model ini kemungkinan menggunakan Convolutional Neural Network (CNN) untuk klasifikasi limbah berdasarkan gambar.

Predicted: plastic, Confidence: 0.60



Gambar 9. Hasil Prediksi *Plastic*

Hasil pengujian menunjukkan bahwa model CNN memiliki kinerja yang baik dalam mengklasifikasikan gambar ke dalam lima kategori yang ditentukan. Model berhasil mengidentifikasi dengan benar sebagian besar gambar dalam *dataset* bebas, menunjukkan kemampuan generalisasi yang baik dalam mengenali karakteristik visual yang khas dari setiap kategori. Sebagian besar prediksi model disertai dengan tingkat kepercayaan yang tinggi, menunjukkan keyakinan model terhadap prediksinya, yang penting untuk aplikasi praktis di mana keputusan otomatis diperlukan

Namun, terkadang model juga melakukan kesalahan klasifikasi yang terlihat pada Gambar 10. Misalnya, gambar yang sebenarnya merupakan glass diprediksi menjadi metal. Kesalahan ini umumnya disebabkan oleh fitur

visual yang mirip antara kategori yang berbeda. Misalnya, permukaan reflektif atau transparan pada glass dapat menyebabkan model bingung dan menganggapnya sebagai metal. Kesalahan semacam ini menunjukkan bahwa meskipun model memiliki akurasi yang tinggi, masih ada ruang untuk perbaikan, terutama dalam menangani gambar-gambar dengan karakteristik yang lebih ambigu.

Predicted: metal, Confidence: 0.57



Gambar 10 Hasil Prediksi Glass Salah

3.3 Pembahasan

Penelitian ini bertujuan untuk mengembangkan model klasifikasi sampah otomatis menggunakan Convolutional Neural Network (CNN) yang dioptimasi melalui modifikasi arsitektur dengan penambahan lapisan konvolusi. Hasil penelitian menunjukkan bahwa modifikasi ini berhasil meningkatkan akurasi model secara signifikan. Akurasi pelatihan model CNN yang telah dimodifikasi mencapai 88% pada epoch ke-40, sementara akurasi validasi stabil di sekitar 83%. Evaluasi pada 250 gambar sampah menunjukkan bahwa model dapat mendeteksi 209 gambar dengan benar, menghasilkan akurasi 83%, presisi 84%, recall 82%, dan F1-score 83%.

Peningkatan akurasi ini menunjukkan bahwa penambahan lapisan konvolusi berhasil dalam ekstraksi fitur yang lebih baik, sehingga model dapat mengenali pola dan karakteristik gambar sampah dengan lebih akurat. Selain itu, penggunaan lapisan ReLU untuk non-linearitas terbukti efektif dalam meningkatkan kemampuan generalisasi model. Dengan meningkatkan kompleksitas arsitektur CNN melalui penambahan lapisan konvolusi, model mampu menangkap lebih banyak informasi dari gambar, yang pada akhirnya meningkatkan performa dalam tugas klasifikasi.

Penelitian sebelumnya menunjukkan bagaimana Convolutional Neural Networks (CNN) melakukan perhitungan konvolusi dalam mengekstrak fitur dari gambar, mengubah jumlah parameter model, dan dibantu oleh Transfer Learning sehingga akhirnya didapatkan akurasi sebesar 82.80%. Namun, penelitian ini berhasil mencapai akurasi validasi 83% tanpa menggunakan Transfer Learning, menunjukkan peningkatan efektivitas model yang dikembangkan. Hal ini penting karena menghilangkan ketergantungan pada model pra-latih yang mungkin tidak sepenuhnya sesuai dengan karakteristik dataset yang digunakan.

Kebaruan dari penelitian ini terletak pada modifikasi arsitektur CNN dengan penambahan lapisan konvolusi yang terbukti meningkatkan akurasi klasifikasi dan kemampuan generalisasi model. Penggunaan dataset yang lebih besar dan komprehensif, yang mencakup lima jenis sampah utama, memberikan validasi yang lebih kuat terhadap kemampuan model dalam klasifikasi sampah. Dataset yang beragam ini mencakup berbagai jenis sampah seperti sampah organik, plastik, kertas, logam, dan kaca, yang memungkinkan model untuk belajar dan mengenali berbagai karakteristik dari tiap jenis sampah.

Dengan temuan ini, diharapkan dapat memberikan kontribusi signifikan terhadap pengembangan teknologi klasifikasi sampah otomatis yang lebih akurat dan efisien. Model yang lebih akurat akan membantu dalam pengelolaan sampah yang lebih baik, meningkatkan efisiensi daur ulang, dan mengurangi beban lingkungan akibat penumpukan sampah. Teknologi ini dapat diimplementasikan dalam berbagai skala, dari fasilitas pengelolaan sampah kota hingga sistem rumah tangga, untuk mempermudah proses pemilahan sampah.

Keberhasilan penelitian ini juga membuka peluang untuk pengembangan lebih lanjut dalam bidang klasifikasi gambar menggunakan CNN. Salah satu arah penelitian lanjutan adalah menguji model pada dataset yang lebih bervariasi dan realistis, termasuk gambar sampah dalam kondisi yang berbeda-beda seperti pencahayaan rendah, gambar yang buram, atau gambar dengan latar belakang yang kompleks. Selain itu, penelitian lanjutan dapat mengeksplorasi penggunaan teknik augmentasi data untuk meningkatkan keragaman dataset dan, pada gilirannya, meningkatkan kemampuan generalisasi model.

Secara keseluruhan, penelitian ini menunjukkan bahwa modifikasi arsitektur Convolutional Neural Network (CNN) dengan penambahan lapisan konvolusi merupakan pendekatan yang efektif untuk meningkatkan akurasi dan kemampuan generalisasi dalam klasifikasi sampah. Temuan ini memberikan dasar yang kuat untuk pengembangan teknologi klasifikasi sampah otomatis yang lebih akurat dan efisien, serta membuka peluang untuk penelitian lebih lanjut dan implementasi praktis dalam skala yang lebih luas. Dengan terus meningkatkan teknologi ini, kita dapat mengambil langkah signifikan menuju pengelolaan sampah yang lebih baik dan lingkungan yang lebih bersih dan berkelanjutan.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa modifikasi arsitektur *Convolutional Neural Network* (CNN) dasar dengan penambahan lapisan konvolusi berhasil meningkatkan akurasi model dalam klasifikasi sampah, dengan akurasi pelatihan mencapai 88% pada *epoch* ke-40 dan akurasi validasi stabil di sekitar 83%. Evaluasi terhadap 250 gambar sampah menghasilkan akurasi 83%, presisi 84%, *recall* 82%, dan *F1-score* 83%. Penggunaan lapisan ReLU untuk menangani non-linearitas terbukti efektif dalam meningkatkan generalisasi model. Penambahan lapisan konvolusi ini menunjukkan kemampuan ekstraksi fitur yang lebih baik, memungkinkan model mengenali pola dan karakteristik gambar sampah secara akurat tanpa bantuan *Transfer Learning*. Hasil ini mengungguli penelitian sebelumnya yang mencapai akurasi 82.80% dengan *Transfer Learning*. Kebaruan penelitian ini terletak pada arsitektur CNN yang dimodifikasi dan *dataset* yang lebih komprehensif, yang semuanya memberikan kontribusi signifikan terhadap pengembangan teknologi klasifikasi sampah otomatis yang lebih akurat dan efisien, serta memberikan dasar kuat untuk penelitian lebih lanjut di bidang ini. Dengan modifikasi arsitektur yang dilakukan, termasuk penambahan lapisan konvolusi, model dapat mengenali berbagai jenis sampah dengan lebih baik dan efisien, meningkatkan efektivitas pengelolaan sampah secara keseluruhan. Secara keseluruhan, penelitian ini berhasil menunjukkan bahwa modifikasi arsitektur CNN dengan penambahan lapisan konvolusi dan penggunaan *dataset* yang lebih komprehensif dapat menghasilkan model klasifikasi sampah yang lebih akurat dan efisien. Hasil penelitian ini diharapkan dapat memberikan kontribusi yang signifikan terhadap pengembangan teknologi klasifikasi sampah otomatis di masa depan, serta dapat dijadikan dasar untuk penelitian lebih lanjut yang bertujuan untuk meningkatkan akurasi dan efisiensi model klasifikasi sampah. Dengan demikian, penelitian ini tidak hanya berhasil mencapai tujuannya, tetapi juga memberikan kontribusi yang berarti bagi pengembangan teknologi pengelolaan sampah yang lebih baik di masa mendatang.

REFERENCES

- [1] M. I. B. Ahmed *et al.*, “Deep Learning Approach to Recyclable Products Classification: Towards Sustainable Waste Management,” *Sustainability (Switzerland)*, vol. 15, no. 14, 2023, doi: 10.3390/su151411138.
- [2] J. Li *et al.*, “Automatic Detection and Classification System of Domestic Waste via Multimodel Cascaded Convolutional Neural Network,” *IEEE Trans Industr Inform*, vol. 18, no. 1, pp. 163–173, Jan. 2022, doi: 10.1109/TII.2021.3085669.
- [3] Q. Zhang, Q. Yang, X. Zhang, Q. Bao, J. Su, and X. Liu, “Waste image classification based on transfer learning and convolutional neural network,” *Waste Management*, vol. 135, pp. 150–157, Nov. 2021, doi: 10.1016/j.wasman.2021.08.038.
- [4] C. Shi, C. Tan, T. Wang, and L. Wang, “A waste classification method based on a multilayer hybrid convolution neural network,” *Applied Sciences (Switzerland)*, vol. 11, no. 18, 2021, doi: 10.3390/app11188572.
- [5] M. Malik *et al.*, “Waste Classification for Sustainable Development Using Image Recognition with Deep Learning Neural Network Models,” *Sustainability (Switzerland)*, vol. 14, no. 12, 2022, doi: 10.3390/su14127222.
- [6] N. Nnamoko, J. Barrowclough, and J. Procter, “Solid Waste Image Classification Using Deep Convolutional Neural Network,” *Infrastructures (Basel)*, vol. 7, no. 4, 2022, doi: 10.3390/infrastructures7040047.
- [7] R. Sultana, R. D. Adams, Y. Yan, P. M. Yanik, and M. L. Tanaka, “Trash and Recycled Material Identification using Convolutional Neural Networks (CNN),” in *Conference Proceedings - IEEE SOUTHEASTCON*, Institute of Electrical and Electronics Engineers Inc., Mar. 2020. doi: 10.1109/SoutheastCon44009.2020.9249739.
- [8] S. Liang and Y. Gu, “A deep convolutional neural network to simultaneously localize and recognize waste types in images,” *Waste Management*, vol. 126, pp. 247–257, May 2021, doi: 10.1016/j.wasman.2021.03.017.
- [9] M. Fan, K. Zuo, J. Wang, and J. Zhu, “A lightweight multiscale convolutional neural network for garbage sorting,” *Systems and Soft Computing*, vol. 5, Dec. 2023, doi: 10.1016/j.sasc.2023.200059.
- [10] W. L. Mao, W. C. Chen, C. T. Wang, and Y. H. Lin, “Recycling waste classification using optimized convolutional neural network,” *Resour Conserv Recycl*, vol. 164, Jan. 2021, doi: 10.1016/j.resconrec.2020.105132.
- [11] M. A. Islam, S. I. Rashid, N. U. I. Hossain, R. Fleming, and A. Sokolov, “An integrated convolutional neural network and sorting algorithm for image classification for efficient flood disaster management,” *Decision Analytics Journal*, vol. 7, Jun. 2023, doi: 10.1016/j.dajour.2023.100225.
- [12] P. Nowakowski and T. Pamuła, “Application of deep learning object classifier to improve e-waste collection planning,” *Waste Management*, vol. 109, pp. 1–9, May 2020, doi: 10.1016/j.wasman.2020.04.041.
- [13] B. Akshaya and M. T. Kala, “Convolutional Neural Network Based Image Classification and New Class Detection,” in *Proceedings of 2020 IEEE International Conference on Power, Instrumentation, Control and Computing, PICC 2020*, Institute of Electrical and Electronics Engineers Inc., Dec. 2020. doi: 10.1109/PICC51425.2020.9362375.
- [14] A. Altikat, A. Gulbe, and S. Altikat, “Intelligent solid waste classification using deep convolutional neural networks,” *International Journal of Environmental Science and Technology*, vol. 19, no. 3, 2022, doi: 10.1007/s13762-021-03179-4.



- [15] O. I. Funch, R. Marhaug, S. Kohtala, and M. Steinert, “Detecting glass and metal in consumer trash bags during waste collection using convolutional neural networks,” *Waste Management*, vol. 119, pp. 30–38, Jan. 2021, doi: 10.1016/j.wasman.2020.09.032.
- [16] X. Tian, L. Shi, Y. Luo, and X. Zhang, “Garbage Classification Algorithm Based on Improved MobileNetV3,” *IEEE Access*, vol. 12, pp. 44799–44807, 2024, doi: 10.1109/ACCESS.2024.3381533.
- [17] M. I. B. Ahmed *et al.*, “Deep Learning Approach to Recyclable Products Classification: Towards Sustainable Waste Management,” *Sustainability (Switzerland)*, vol. 15, no. 14, Jul. 2023, doi: 10.3390/su151411138.
- [18] M. Chhabra, B. Sharan, M. Elbarachi, and M. Kumar, “Intelligent waste classification approach based on improved multi-layered convolutional neural network,” *Multimed Tools Appl*, 2024, doi: 10.1007/s11042-024-18939-w.
- [19] T. V. Janahiraman and P. Subramaniam, “Gender classification based on asian faces using deep learning,” in *2019 IEEE 9th International Conference on System Engineering and Technology, ICSET 2019 - Proceeding*, 2019. doi: 10.1109/ICSEngT.2019.8906399.
- [20] S. Soim, “Development of Convolutional Neural Network Models to Improve Facial Expression Recognition Accuracy,” *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika (JITEKI)*, vol. 10, no. 2, pp. 279–289, 2024, doi: 10.26555/jiteki.v10i2.28863.