

KOMPARASI RESNET50, MOBILENETV2 DAN CUSTOM CNN DALAM KLASIFIKASI SAMPAH ORGANIK DAN ANORGANIK

Faizul Anwar Wandi, Muhammad Afrizal Kesuma, Cellia Auzia Nugraha, Oktaria Indi Cahyani, Ifnu Umar, Anindita Septiarini, Joan Angelina Widians, Akhmad Irsyad

Informatika, Universitas Mulawarman

Jalan Kuaro, Gunung Kelua, Kec. Samarinda Ulu, Kota Samarinda, Indonesia

faizulanwarwandi@gmail.com

ABSTRAK

Peningkatan jumlah sampah akibat aktivitas manusia mendorong adanya sistem pengelolaan yang lebih efektif dan berbasis teknologi. Permasalahan utama terletak pada proses pemilahan sampah yang masih dilakukan secara manual sehingga kurang efisien, tidak konsisten, serta rentan terhadap kesalahan. Selain itu, belum banyak penelitian yang membandingkan beberapa arsitektur Convolutional Neural Network (CNN) dalam satu kerangka eksperimen yang seragam. Penelitian ini bertujuan untuk membandingkan performa ResNet50, MobileNetV2, dan Custom CNN dalam mengklasifikasikan sampah organik dan anorganik. Metode yang digunakan meliputi pengumpulan dataset berjumlah 29.589 citra, *preprocessing* melalui normalisasi dan augmentasi, pembangunan model berbasis *deep learning*, serta evaluasi menggunakan akurasi dan *loss*. Hasil pengujian menunjukkan Custom CNN memperoleh akurasi tertinggi sebesar 90,41% dengan waktu pelatihan paling efisien, diikuti MobileNetV2 sebesar 89,57%, dan ResNet50 sebesar 80,70%. Pengujian lanjutan menggunakan data baru menunjukkan bahwa Custom CNN unggul pada kelas organik dengan akurasi 100%, sementara ResNet50 lebih baik pada kelas anorganik dengan akurasi 90%, dan MobileNetV2 cenderung stabil pada kedua kelas. Temuan ini menunjukkan bahwa setiap arsitektur memiliki keunggulan berbeda, serta performa pada data uji tidak selalu mencerminkan kemampuan generalisasi model di kondisi nyata.

Kata kunci : *Convolutional Neural Network (CNN), Custom CNN, ResNet50, MobileNetV2, Klasifikasi Sampah*

1. PENDAHULUAN

Pertumbuhan populasi global yang pesat dan meningkatnya aktivitas industri hingga konsumsi masyarakat, telah menyebabkan akumulasi sampah yang signifikan. Banyak negara berkembang, termasuk Indonesia, menghadapi kondisi ini dengan sangat sulit. Berdasarkan data tahun 2025 dari Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) Kementerian Lingkungan Hidup dan Kehutanan, timbulan sampah di Indonesia mencapai sekitar 25.141.493 ton per tahun. Namun, dari jumlah tersebut hanya sekitar 34% yang berhasil dikelola dengan baik, sementara sisanya masih belum tertangani secara optimal.

Kondisi tersebut menunjukkan bahwa sistem pengelolaan sampah masih menghadapi berbagai keterbatasan, baik dari segi infrastruktur, teknologi, maupun kesadaran masyarakat. Tanpa penanganan yang tepat, penumpukan sampah dapat mempengaruhi kesehatan masyarakat, keberlanjutan ekosistem, dan lingkungan [1][2].

Pada praktiknya, proses pemilahan sampah masih banyak dilakukan secara manual oleh tenaga manusia. Metode ini memiliki beberapa keterbatasan, seperti ketidakonsistenan dalam identifikasi jenis sampah, keterbatasan kecepatan proses, serta potensi kesalahan akibat kelelahan atau subjektivitas manusia. Selain itu, variasi visual sampah yang sangat beragam, baik dari segi bentuk, warna, tekstur, maupun kondisi fisiknya, menjadikan proses identifikasi manual semakin sulit dilakukan secara akurat [3].

Berdasarkan kondisi tersebut, terdapat dua permasalahan utama yang menjadi fokus penelitian ini. Pertama, proses pemilahan sampah secara manual dinilai tidak efisien dan rentan terhadap kesalahan, sehingga dibutuhkan pendekatan yang lebih otomatis dan objektif. Kedua, meskipun berbagai arsitektur CNN seperti ResNet50, MobileNetV2, dan custom CNN telah digunakan secara individual dalam penelitian terdahulu, belum terdapat studi yang secara khusus membandingkan ketiga arsitektur tersebut dalam satu kerangka eksperimen yang terkontrol dengan dataset dan protokol evaluasi yang identik pada konteks klasifikasi sampah organik dan anorganik.

Dalam situasi seperti ini, pendekatan yang lebih otomatis, objektif, dan skalabel diperlukan untuk proses identifikasi jenis sampah. Teknologi pengolahan citra digital berbasis kecerdasan buatan dianggap dapat menjadi solusi alternatif yang menjanjikan karena dapat secara konsisten menganalisis fitur visual sampah tanpa bergantung pada kelelahan atau subjektivitas manusia [4].

Kemajuan dalam bidang kecerdasan buatan, khususnya teknik *deep learning* berbasis Convolutional Neural Network (CNN), telah membuka peluang baru untuk mengotomatisasi klasifikasi sampah secara akurat. CNN mampu mengekstraksi fitur-fitur hierarkis dari citra secara otomatis, mulai dari tepi dan tekstur pada lapisan awal hingga representasi semantik tingkat tinggi pada lapisan yang lebih dalam [5].

Kemampuan ini menjadikan CNN sangat relevan untuk tugas pengenalan visual kompleks seperti klasifikasi sampah yang memiliki variasi tinggi antar sampel. Dalam perkembangannya, berbagai arsitektur CNN telah diusulkan dengan karakteristik berbeda [6].

ResNet50 memanfaatkan koneksi pintas antar lapisan sehingga mampu membangun jaringan yang sangat dalam secara stabil dan menghasilkan representasi fitur visual yang lebih kaya dan akurat [7].

MobileNetV2 memanfaatkan teknik konvolusi yang lebih ringan dan efisien sehingga cocok untuk dijalankan pada perangkat dengan sumber daya komputasi terbatas [8].

Sementara itu, *custom CNN* menawarkan fleksibilitas penuh dalam perancangan arsitektur sesuai kebutuhan spesifik dataset yang digunakan.

Beberapa penelitian terdahulu telah menerapkan masing-masing arsitektur tersebut secara individual dalam klasifikasi sampah. Metode ResNet50 telah digunakan untuk klasifikasi sampah organik dan anorganik menggunakan lebih dari 22.000 citra dengan akurasi validasi sebesar 80,15% [9].

Di sisi lain, penelitian yang mengimplementasikan MobileNetV2 dengan pendekatan *transfer learning* menunjukkan hasil yang menjanjikan karena mencapai akurasi validasi sebesar 86,73% menggunakan dataset 2.527 citra dengan efisiensi komputasi yang tinggi, bahkan tanpa akselerator GPU khusus [10].

Adapun perbandingan antara *custom CNN* dan MobileNetV2 yang dilakukan oleh Hanif dan Arief menunjukkan kesenjangan performa yang cukup signifikan, yaitu 88% berbanding 71%, yang mengindikasikan bahwa pemilihan arsitektur berpengaruh besar terhadap hasil klasifikasi [11].

Namun demikian, belum terdapat studi yang secara khusus membandingkan ketiga arsitektur tersebut ResNet50, MobileNetV2, dan *custom CNN* dalam satu kerangka eksperimen yang terkontrol dengan dataset dan protokol evaluasi yang identik pada konteks klasifikasi sampah organik dan anorganik.

Oleh karena itu, penelitian ini bertujuan untuk membandingkan performa tiga arsitektur CNN, yaitu ResNet50, MobileNetV2, dan *custom CNN*, dalam mengklasifikasikan sampah organik dan anorganik menggunakan dataset dan protokol evaluasi yang identik. Ketiga arsitektur ini akan diuji dan dibandingkan secara langsung dalam satu kerangka eksperimen yang terkontrol untuk mengetahui arsitektur mana yang paling optimal dari segi akurasi maupun efisiensi komputasi, sehingga dapat menghasilkan kesimpulan yang objektif dan dapat dipertanggungjawabkan.

2. TINJAUAN PUSTAKA

2.1. Sampah Organik dan Anorganik

Sampah merupakan barang atau bahan sisa yang dihasilkan dari aktivitas rumah tangga maupun proses alam yang tidak lagi digunakan atau rusak. Sampah

organik adalah kategori sampah yang mudah terurai secara alami oleh tanah, sedangkan sampah anorganik merupakan sampah yang sulit terurai sehingga membutuhkan waktu yang sangat lama dalam proses dekomposisinya [12].

Kurangnya pemisahan antara kedua jenis sampah ini secara manual menjadi kendala utama dalam efisiensi pengelolaan limbah di masyarakat [13].

Penelitian ini menggunakan dataset *Waste Classification* dari Kaggle oleh Sashaank Sekar yang berisi ribuan citra sampah organik (O) dan anorganik (R) sebagai data latih dan uji [14].

2.2. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah jenis *deep neural network* yang dirancang khusus untuk memproses data dalam bentuk *grid*, seperti citra digital, karena kedalaman jaringannya yang tinggi [12].

Arsitektur CNN bekerja dengan cara mengekstraksi fitur unik dari sebuah gambar melalui beberapa lapisan, yaitu *convolutional layer* untuk ekstraksi fitur, *pooling layer* untuk mereduksi dimensi data, dan *fully connected layer* untuk klasifikasi akhir [15].

Penggunaan teknik *pooling* sangat krusial untuk mempertahankan informasi penting sekaligus mengurangi beban komputasi dan mencegah *overfitting* [16]. Dalam proses klasifikasi, fungsi aktivasi *Softmax* sering digunakan pada lapisan output untuk menentukan probabilitas kelas objek [17].

2.3. ResNet50

ResNet50 (*Residual Network*) merupakan arsitektur CNN yang memperkenalkan konsep *shortcut connection* atau *residual learning* untuk mengatasi masalah *vanishing gradient* pada jaringan yang sangat dalam [18].

Arsitektur ini memungkinkan pelatihan jaringan hingga 50 lapisan tanpa menurunkan performa model dengan cara mempelajari pemetaan residu [14].

Performa model ini diukur menggunakan metrik evaluasi seperti akurasi, yang dihitung berdasarkan perbandingan antara prediksi yang benar dengan total data pengujian:

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

Implementasi ResNet50 pada klasifikasi sampah terbukti memberikan hasil identifikasi yang kuat terhadap variasi kondisi lingkungan [14].

2.4. MobileNetV2

MobileNetV2 adalah arsitektur yang dikembangkan untuk efisiensi tinggi pada perangkat dengan sumber daya terbatas seperti *mobile* atau *embedded devices*. Inovasi utama dari arsitektur ini adalah penggunaan *inverted residuals* dan *linear bottlenecks* yang menjaga aliran informasi tetap efisien melalui jaringan [19].

MobileNetV2 memanfaatkan *depthwise separable convolution* yang secara signifikan mengurangi jumlah parameter dan operasi matematika dibandingkan konvolusi standar. Untuk mengoptimalkan hasil pada dataset kecil, penggunaan teknik *Transfer Learning* dengan membekukan lapisan awal model pre-trained terbukti efektif meningkatkan akurasi klasifikasi [13].


2.5. Custom CNN

Arsitektur Custom CNN dikembangkan untuk memberikan fleksibilitas dalam menyesuaikan jumlah lapisan dan parameter sesuai dengan karakteristik spesifik dataset. Dalam model kustom, fungsi aktivasi ReLU (*Rectified Linear Unit*) umumnya diterapkan pada lapisan konvolusi untuk memperkenalkan sifat non-linear dengan rumus $f(x) = \max(0, x)$. Berbeda dengan model pre-trained, Custom CNN memungkinkan eksperimen mandiri pada ukuran filter (misalnya 3×3) dan jumlah neuron pada dense layer untuk mencapai performa optimal pada domain yang lebih sempit [17].

Penggunaan arsitektur kustom yang digabungkan dengan teknik augmentasi data seperti rotasi dan flipping juga dapat meningkatkan ketahanan model terhadap variasi gambar [20].

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan yang terstruktur untuk mengklasifikasikan sampah organik dan anorganik menggunakan citra digital. Proses penelitian dimulai dari pengumpulan dataset, dilanjutkan dengan preprocessing data, pembangunan tiga model CNN yang berbeda (ResNet50, MobileNetV2, dan Custom CNN), evaluasi komparatif model, hingga penarikan kesimpulan. Tahapan metode penelitian dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Metode Penelitian

3.1. Pengumpulan Dataset

Dataset yang digunakan merupakan dataset *Waste Classification Data* yang tersedia secara publik di Kaggle. Dataset terdiri dari dua kelas yaitu sampah organik (O) dan sampah anorganik atau *recyclable* (R). Dataset juga terbagi menjadi dua folder utama yaitu folder TRAIN yang digunakan untuk melatih model dan folder TEST digunakan untuk menguji performa model pada data yang belum pernah dilihat sebelumnya. Penelitian ini menggunakan 22.564 gambar sebagai data *training*, 4.512 gambar sebagai data *validation*, dan 2.513 gambar sebagai data *testing*. Sampel dataset yang terdiri dari kelas organik dan anorganik dapat dilihat pada Gambar 2.



Gambar 2. Sampel Dataset Sampah Organik dan Anorganik

3.2. Preprocessing Data

Tahap preprocessing data bertujuan untuk menyiapkan data citra agar siap digunakan dalam pelatihan model CNN. Tahap ini melibatkan standarisasi ukuran gambar sebagai keseimbangan antara detail gambar dan efisiensi komputasi, sedangkan normalisasi piksel dilakukan untuk memastikan konvergensi yang lebih baik selama pelatihan [21].

Proses ini dilakukan menggunakan ImageDataGenerator dari pustaka TensorFlow Keras. Langkah-langkah yang dilakukan meliputi:

- Normalisasi piksel dengan membagi nilai piksel dengan 255 sehingga nilai berada pada rentang $[0, 1]$
- Augmentasi data pada set pelatihan yang mencakup rotasi hingga 15 derajat, pergeseran lebar dan tinggi sebesar 10%, *shear* 10%, *zoom* 10%, serta *horizontal flip*.
- Pembagian data latih menjadi 80% *data training* dan 20% *data validation* menggunakan parameter *validation split*.
- Penyesuaian ukuran citra, di mana Custom CNN menggunakan ukuran 128×128 piksel, sedangkan ResNet50 dan MobileNetV2 memerlukan ukuran input 224×224 piksel sesuai standar arsitektur *pre-trained* ImageNet.

3.3. Pembangunan Model

Tiga model CNN dikembangkan dan dilatih menggunakan data latih untuk membandingkan kinerjanya dalam mengklasifikasikan citra sampah organik dan anorganik. Model pertama adalah Custom CNN, dibangun menggunakan Keras Sequential dengan tiga blok konvolusi (32, 64, 128 filter, kernel 3×3) diikuti *MaxPooling2D*, lapisan *Dense* 128 neuron, serta *Dropout* 0,3 dan 0,5 untuk mencegah *overfitting*.

Model kedua dan ketiga, yaitu ResNet50 dan MobileNetV2, menggunakan pendekatan *transfer learning* dengan bobot *pre-trained* ImageNet. Seluruh lapisan *base model* dibekukan pada tahap awal, kemudian 20 lapisan terakhir dibuka untuk *fine-tuning*. Kedua model dilengkapi lapisan *GlobalAveragePooling2D*, *Dense* 256 neuron, *Dropout* 0,5, dan output *Sigmoid* untuk klasifikasi biner.

3.4. Training Model

Ketiga model dilatih dengan *batch size* 32 dan fungsi *binary crossentropy*. Custom CNN dikompilasi

dengan Adam ($lr = 0,001$) dengan maksimal 50 *epoch*, namun dihentikan lebih awal pada *epoch* ke-27 karena *validation loss* tidak menunjukkan perbaikan yang signifikan, sedangkan ResNet50 dan MobileNetV2 dikompilasi dengan Adam ($lr = 0,0001$) dengan maksimal 30 *epoch*. Ketiga model menggunakan dua *callback*, yaitu *EarlyStopping* (memantau *val_loss*, *patience* = 5) dan *ReduceLROnPlateau* (faktor 0,2, *patience* = 2).

3.5. Evaluasi Model

Evaluasi ketiga model menggunakan metrik Akurasi (persentase prediksi benar) dan Test Loss (nilai fungsi kerugian pada data uji). Analisis *training history* (kurva akurasi dan *loss* pada set *training* dan *validation*) juga dianalisis untuk mendeteksi indikasi *overfitting* maupun *underfitting*.

3.6. Hasil Perbandingan Model

Berdasarkan evaluasi model yang diperoleh, dilakukan perbandingan untuk menentukan model dengan performa terbaik di antara ketiga model tersebut. Parameter yang menjadi perbandingan adalah akurasi dan waktu *training* untuk setiap model.

4. HASIL DAN PEMBAHASAN

Data yang sudah melalui tahapan *preprocessing* kemudian digunakan untuk melatih model CNN dengan tiga arsitektur yang berbeda, yaitu Custom, ResNet50, dan MobileNetV2.

4.1. Hasil Preprocessing Data

Hasil distribusi dataset yang telah melalui tahapan *preprocessing* dapat dilihat pada Tabel 1.

Tabel 1. Distribusi Dataset Sampah

Subset	Kelas Organik (O)	Kelas Anorganik/ Recyclable (R)	Total
Training	12.565	9.999	22.564
Validation	2.513	1.999	4.512
Testing	1.401	1.112	2.513

Berdasarkan Tabel 1, total keseluruhan gambar pada data *training* berjumlah 22.564 citra, yang kemudian dibagi menjadi 18.052 data *training* (80%) dan 4.512 data *validation* (20%) menggunakan parameter *validation_split* pada *ImageDataGenerator*. Data *testing* yang digunakan secara terpisah berjumlah 2.513 citra.

4.2. Arsitektur Model

Penelitian ini membandingkan tiga arsitektur CNN, yaitu Custom CNN, ResNet50, dan MobileNetV2 untuk mengklasifikasikan sampah organik dan anorganik. Berikut adalah rincian arsitektur dari masing-masing model.

4.3. Custom CNN

Model Custom CNN dirancang dari awal menggunakan arsitektur *Sequential* dengan tiga blok konvolusi yang tersusun secara bertingkat. Input citra berukuran $128 \times 128 \times 3$ diproses melalui Conv2D dengan jumlah filter yang meningkat secara progresif (32, 64, 128) untuk mengekstraksi fitur dari yang sederhana ke kompleks. Rincian arsitektur Custom CNN dapat dilihat pada Tabel 2.

Tabel 2. Arsitektur Custom CNN

Layer	Konfigurasi	Output Shape
Conv2D + ReLU	32 filter, 3×3	(None, 126, 126, 32)
MaxPooling2D	2×2	(None, 63, 63, 32)
Conv2D + ReLU	64 filter, 3×3	(None, 61, 61, 64)
MaxPooling2D	2×2	(None, 30, 30, 64)
Dropout	Rate = 0.3	(None, 30, 30, 64)
Conv2D + ReLU	128 filter, 3×3	(None, 28, 28, 128)
MaxPooling2D	2×2	(None, 14, 14, 128)
Flatten	-	(None, 25.088)
Dense + ReLU	128 unit	(None, 128)
Dropout	Rate = 0.5	(None, 128)
Dense + Sigmoid	1 unit (output)	(None, 1)

Total parameter pada model Custom CNN adalah sekitar 3,4 juta parameter. Model dikompilasi menggunakan *optimizer Adam* dengan *learning rate* awal 0,001 dan fungsi *loss binary crossentropy*.

4.4. ResNet50

Dalam penelitian ini, ResNet50 digunakan sebagai *feature extractor* melalui teknik *transfer learning* dengan strategi *fine-tuning* pada 20 layer terakhir. Layer *classifier* baru ditambahkan berupa *GlobalAveragePooling2D*, *Dense*(256, ReLU), *Dropout*(0,5), dan *Dense*(1, Sigmoid), dengan input berukuran $224 \times 224 \times 3$.

4.5. MobileNetV2


Mirip dengan ResNet50, MobileNetV2 digunakan dengan bobot *pre-trained ImageNet* melalui teknik *transfer learning* dengan *fine-tuning* pada 20 layer terakhir, menggunakan konfigurasi *classifier* yang identik, dengan input berukuran $224 \times 224 \times 3$.

4.6. Hasil Pelatihan

Berdasarkan arsitektur tiap model yang dibangun, diperoleh hasil pelatihan sebagai berikut.

4.7. Custom CNN

Pelatihan Custom CNN dihentikan secara otomatis pada *epoch* ke-27 dari maksimum 50 *epoch* yang direncanakan. Hasil pelatihan model Custom CNN dapat dilihat pada Gambar 3.




Gambar 3. Hasil Pelatihan Custom CNN

Pada epoch pertama, model sudah mampu mencapai akurasi *training* sebesar 79.22% dan akurasi validasi 81.69%. Akurasi *training* terus meningkat secara konsisten hingga mencapai kisaran 87–90% pada epoch-epoch terakhir. Mekanisme EarlyStopping berhasil mencegah *overfitting* dengan menghentikan pelatihan saat *val_loss* tidak membaik dalam 5 epoch berturut-turut. Nilai *training loss* akhir berada di kisaran 0.28 dengan *val_loss* sekitar 0.26.

4.8. ResNet50

Model ResNet50 menyelesaikan proses pelatihan pada epoch ke-17, lebih cepat dibandingkan Custom CNN. Hasil pelatihan model ResNet50 dapat dilihat pada Gambar 4.

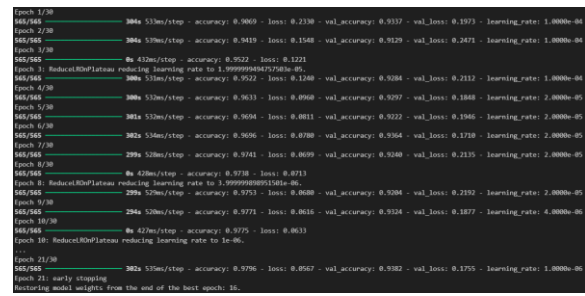


Gambar 4. Hasil Pelatihan ResNet50

Akurasi *training* yang dicapai pada epoch pertama sebesar 75,34% dengan *val_accuracy* sebesar 72.14%. Selama proses pelatihan, terdeteksi fluktuasi yang cukup signifikan pada *validation loss*, terutama pada epoch ke-5 (*val_loss*=0.7216) dan epoch ke-8 (*val_loss*=0.7012), mengindikasikan bahwa model mengalami ketidakstabilan dalam menyesuaikan bobot pre-trained ImageNet dengan *domain dataset* sampah ini. Mekanisme ReduceLROnPlateau secara aktif menurunkan *learning rate* mulai dari epoch ke-8, dari 1×10^{-4} hingga 1×10^{-6} , namun performa validasi tidak mengalami peningkatan signifikan. Akurasi *training* akhir tercatat sebesar 84.97% dengan *val_accuracy* 82.49% pada epoch ke-17.

4.9. MobileNetV2

Karakteristik yang ditunjukkan MobileNetV2 saat pelatihan paling berbeda dibandingkan dua model lainnya. Hasil pelatihan model MobileNetV2 dapat dilihat pada Gambar 5.



Gambar 5. Hasil Pelatihan MobileNetV2

Sejak epoch pertama, model MobileNetV2 sudah mencapai akurasi *training* 90.69% dan *val_accuracy* 93.37%, menandakan kemampuan representasi fitur yang kuat dari bobot *pre-trained* ImageNet. Akurasi training terus meningkat pesat, mencapai lebih dari 97% pada epoch-epoch selanjutnya. ReduceLROnPlateau aktif sejak epoch ke-3, menurunkan *learning rate* secara agresif. Pelatihan dihentikan pada epoch ke-21 oleh *EarlyStopping*. Meskipun *train accuracy* sangat tinggi (>97%), *val_accuracy* stabil di kisaran 93–94%, mengindikasikan adanya *gap* antara performa *training* dan validasi yang perlu diperhatikan.

4.10. Perbandingan Performa Model pada Data Uji

Evaluasi akhir dilakukan menggunakan data uji sebanyak 2.513 citra yang sepenuhnya terpisah dari proses *training* maupun validasi. Hasil perbandingan performa ketiga model dapat dilihat pada Tabel 3.

Tabel 3. Perbandingan Performa Ketiga Model pada Data Uji

Model	Test Accuracy	Test Loss	Epochs	Waktu Training (menit)
Custom CNN	90.41%	0.2682	27	77.5
ResNet50	80.70%	0.4253	17	154.4
MobileNetV2	89.57%	0.2979	21	104.5

Berdasarkan Tabel 3, akurasi tertinggi berhasil diperoleh oleh Custom CNN, yaitu sebesar 90.41% dengan *test loss* 0.2682 setelah 27 epoch pelatihan dengan waktu *training* 77.5 menit. MobileNetV2 menyusul di posisi kedua dengan akurasi 89.57% dan *test loss* 0.2979 dalam 21 epoch dengan waktu *training* 104.5 menit. ResNet50 menunjukkan performa terendah dibandingkan dua model lainnya, dengan akurasi hanya sebesar 80.70% dan *test loss* tertinggi 0.4253 dalam 17 epoch serta waktu *training* sebanyak 154.4 menit, menjadikannya model dengan waktu *training* terlama.

Hasil yang diperoleh Custom CNN cukup mengejutkan mengingat model ini dibangun dari awal tanpa menggunakan bobot *pre-trained*. Pencapaian akurasi 90.41% pada data uji menunjukkan bahwa arsitektur tiga blok konvolusi yang sederhana dengan jumlah filter progresif (32-64-128) sudah cukup efektif untuk tugas klasifikasi biner sampah organik dan

anorganik. Hal ini dapat terjadi karena karakteristik visual antara kedua kelas cukup berbeda, sampah organik umumnya memiliki tekstur, warna, dan bentuk yang khas dibandingkan sampah anorganik, sehingga fitur level menengah yang dihasilkan lapisan konvolusi sudah cukup diskriminatif.

Keunggulan Custom CNN juga terletak pada kesederhanaan dan efisiensinya. Dengan sekitar 3.4 juta parameter dan ukuran input yang lebih kecil (128×128), model ini memerlukan sumber daya komputasi yang jauh lebih rendah, terbukti dengan waktu training yang hanya membutuhkan waktu sebanyak 77.5 menit. Teknik regularisasi berupa *Dropout* dan mekanisme *EarlyStopping* terbukti berhasil menghindarkan model dari *overfitting*, ditunjukkan oleh nilai *test loss* yang paling rendah (0.2682) di antara ketiga model.

4.11. Pengujian Model dengan Data Baru

Berbeda dengan data uji yang masih berasal dari distribusi dataset yang sama, pengujian ini menggunakan data eksternal dengan variasi kondisi yang lebih beragam sehingga lebih merepresentasikan skenario penggunaan di dunia nyata. Pada penelitian ini, data tambahan digunakan sebagai pengujian lanjutan untuk mengevaluasi kemampuan generalisasi model. Data tersebut terdiri dari 20 citra yang terbagi ke dalam dua kelas, yaitu organik dan anorganik, dengan masing-masing kelas berjumlah 10 citra. Seluruh citra yang digunakan merupakan data yang tidak pernah dilihat oleh model selama proses pelatihan maupun pengujian.

Tabel 4. Hasil Uji Data Baru pada Kelas Organik

Arsitektur Model	Benar	Salah	Persentase
Custom CNN	10	0	100.00%
ResNet50	5	5	50.00%
MobileNetV2	8	2	80.00%

Berdasarkan hasil pengujian kelas organik pada Tabel 4, model Custom CNN menunjukkan performa terbaik dengan tingkat akurasi mencapai 100%, di mana seluruh data uji berhasil diklasifikasikan dengan benar. Sementara itu, MobileNetV2 memperoleh akurasi sebesar 80%, dan ResNet50 hanya mencapai 50%, yang menunjukkan bahwa model ini mengalami kesulitan dalam mengenali karakteristik sampah organik pada data baru.

Tabel 5. Hasil Uji Data Baru pada Kelas Anorganik

Arsitektur Model	Benar	Salah	Persentase
Custom CNN	7	3	70.00%
ResNet50	9	1	90.00%
MobileNetV2	8	2	80.00%

Sebaliknya, pada hasil pengujian kelas anorganik pada Tabel 5, performa terbaik ditunjukkan oleh ResNet50 dengan akurasi 90%, diikuti oleh MobileNetV2 sebesar 80%, dan Custom CNN sebesar 70%. Hal ini menunjukkan bahwa ResNet50 memiliki kemampuan yang lebih baik dalam mengenali pola

pada sampah anorganik dibandingkan dengan model lainnya. Perbedaan performa antar model ini menunjukkan bahwa setiap arsitektur memiliki keunggulan dalam menangani jenis data tertentu.

Custom CNN yang dilatih secara spesifik pada dataset penelitian cenderung lebih optimal dalam mengenali sampah organik, karena karakteristik fitur yang lebih sederhana atau konsisten. Di sisi lain, ResNet50 yang merupakan model *pre-trained* dengan arsitektur yang lebih dalam mampu menangkap fitur kompleks yang lebih umum ditemukan pada sampah anorganik. Selain itu, hasil ini juga menunjukkan bahwa nilai akurasi pada data uji tidak selalu mencerminkan performa model pada data baru.

5. KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa model Custom CNN yang lebih sederhana mampu mengungguli model *pre-trained* seperti MobileNetV2 dan ResNet50 dalam klasifikasi citra sampah organik dan anorganik dengan akurasi sebesar 90,41%, yang mengindikasikan bahwa kesesuaian kapasitas model dengan karakteristik dataset memiliki peran yang lebih penting dibandingkan sekadar kompleksitas arsitektur. Berdasarkan pengujian tambahan menggunakan data baru, Custom CNN juga menunjukkan performa terbaik pada kelas organik dengan tingkat akurasi tertinggi dibandingkan model lainnya, sementara ResNet50 lebih unggul dalam mengklasifikasikan kelas anorganik, dan MobileNetV2 cenderung memberikan performa yang stabil pada kedua kelas meskipun tidak menjadi yang terbaik secara spesifik. Untuk penelitian selanjutnya, disarankan melakukan komparasi dengan arsitektur CNN lain yang lebih ringan seperti EfficientNet atau ShuffleNet guna memperoleh keseimbangan yang optimal antara akurasi dan efisiensi komputasi.

DAFTAR PUSTAKA

- [1] M. Iqbal, R. Yudha Irianto, A. Kamaludin, F. Jurusan Kesehatan Lingkungan, and P. Kesehatan Bandung, "Tantangan Penanganan Sampah di Kawasan Perkotaan (Studi Kualitatif)," *JURNAL PROMOTIF PREVENTIF*, vol. 7, no. 2, pp. 287–294, Apr. 2024, [Online]. Available: <http://journal.unpacti.ac.id/index.php/JPP>
- [2] S. M. Latif and T. N. Bacin, "Evaluasi Risiko Kesehatan Masyarakat akibat Keberadaan Sampah Organik Terbuka dan Potensi Penularan Zoonosis di Kawasan Perkotaan," *ULIL ALBAB : Jurnal Ilmiah Multidisiplin*, vol. 4, pp. 2124–2131, Aug. 2025.
- [3] A. A. Fathurrahman and F. Akbar, "Perancangan Sistem Identifikasi Jenis Sampah Menggunakan Tensorflow Object Detection Dan Transfer Learning," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 10, no. 1, pp. 64–71, May 2024, doi: 10.25077/teknosi.v10i1.2024.64-71.

- [4] N. A. Fauzan, P. Sukmasetya, and N. Nuryanto, "Leveraging Deep Learning and Convolutional Neural Network for Digital Waste Image Classification," in *E3S Web of Conferences*, EDP Sciences, Apr. 2025. doi: 10.1051/e3sconf/202562203009.
- [5] W. Vidiadivani and K. G. Suhartana, "Klasifikasi Jenis Sampah Menggunakan Metode Transfer Learning Pada Convolutional Neural Network (CNN)," *Jurnal Elektronik Ilmu Komputer Udayana*, vol. 12, pp. 589–596, Feb. 2024.
- [6] M. Rifqi Abdan and M. Akbar, "KLASIFIKASI SAMPAH DAUR ULANG MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK DAN GRAY LEVEL CO-OCCURRENCE MATRIX," *Jurnal Informatika Teknologi dan Sains*, vol. 7, no. 3, pp. 1211–1220, Jul. 2025.
- [7] R. Muzhaffar and I. Suharjo, "Penerapan CNN Berbasis Arsitektur ResNet-50 untuk Klasifikasi Citra Beras Organik dan Anorganik," *Jurnal Pustaka Data (Pusat Akses Kajian Database, Analisa Teknologi, dan Arsitektur Komputer)*, vol. 5, no. 2, pp. 351–358, Dec. 2025, doi: 10.55382/jurnalpustakadata.v5i2.1117.
- [8] D. Ramayanti, D. Asri, and L. Lionie, "Implementasi Model Arsitektur VGG16 dan MobileNetV2 Untuk Klasifikasi Citra Kupu-Kupu," *JSAI: Journal Scientific and Applied Informatics*, vol. 5, no. 3, pp. 182–187, Nov. 2022, doi: 10.36085.
- [9] A. Sihabillah, A. Tholib, and I. I. Basit, "OPTIMASI MODEL RESNET50 UNTUK KLASIFIKASI SAMPAH," *INDEXIA: Informatic and Computational Intelligent Journal*, vol. 06, no. 02, pp. 102–111, Nov. 2024.
- [10] R. Firnando, M. Ali Buchari, A. Dwi Marjusalinah, and R. Fadli Isnanto, "Performance analysis of MobileNetV2 based automatic waste classification using transfer learning," *Jurnal Mandiri IT*, vol. 14, no. 1, pp. 257–268, 2025, [Online]. Available: www.ejournal.isha.or.id/index.php/Mandiri
- [11] M. Hanif and Z. S. Arief, "Analisis Perbandingan Kinerja CNN Sekuensial dan Transfer Learning MobileNetV2 untuk Klasifikasi Sampah," *Jurnal Aplikasi Informatika dan Multimedia*, vol. 1, no. 1, pp. 16–20, Jun. 2025, [Online]. Available: <https://journal.aptika.org/index.php/japtika>
- [12] F. Dwiatmoko, D. Utami, N. A. Sivi, U. Nahdlatul, and U. Lampung, "Klasifikasi Citra Sampah Organik dan Non Organik Menggunakan Algoritma CNN (Convolutional Neural Network)," *EXPLORE*, vol. 14, no. 1, 2024.
- [13] M. Syarif, S. Prasetyo, E. Oktaviana Az Zahra, Y. Indra Kristiawan, and R. Dwi Irawan, "Klasifikasi Sampah Organik dan Anorganik Menggunakan Transfer Learning MobileNetV2 pada Citra Digital," *Seminar Nasional Teknologi Informasi dan Bisnis (SENATIB)*, pp. 1028–1033, Jul. 2025.
- [14] A. Sihabillah, A. Tholib, and I. I. Basit, "OPTIMASI MODEL RESNET50 UNTUK KLASIFIKASI SAMPAH," *INDEXIA: Informatic and Computational Intelligent Journal*, vol. 06, no. 02, pp. 102–111, Nov. 2024.
- [15] G. Aprisia Bahagia, M. Akbar Teknik Informatika, and M. buana Yogyakarta Gejayan Jembatan Merah Yogyakarta, "KLASIFIKASI SAMPAH ORGANIK DAN ANORGANIK MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 5, pp. 10349–10355, Nov. 2024.
- [16] A. Zafar *et al.*, "A Comparison of Pooling Methods for Convolutional Neural Networks," *Applied Sciences (Switzerland)*, vol. 12, no. 17, Sep. 2022, doi: 10.3390/app12178643.
- [17] K. Dwi Septian, N. Khalisa, and I. Djafar, "Penerapan Metode Convolutional Neural Network Untuk Klasifikasi Jenis Sampah Bawah Air," *JURNAL DIPAKOMTI*, vol. 17, no. 1, pp. 39–50, Aug. 2025, doi: 10.36774/dipakomti.v17i1.1773.
- [18] P. O. Parasian and F. Utaminigrum, "Rancang Bangun Sistem Pengklasifikasi Jenis Sampah Organik dan Sampah Daur Ulang menggunakan Resnet50," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 6, no. 2, pp. 2548–964, Feb. 2022, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [19] S. E. Thio and J. Susilo, "Identifikasi Pemilahan Sampah Berbasis Algoritma Transfer Learning CNN Menggunakan MobileNetV2 dan EfficientNetB0," *Bit-Tech (Binary Digital - Technology)*, vol. 8, no. 1, pp. 25–32, Aug. 2025, doi: 10.32877/bt.v8i1.1900.
- [20] N. Rahman and S. K. Das, "A Fusion of Three Custom-Tailored Deep Learning Architectures for Waste Classification," in *International Conference on Sustainable Technologies for Industry 4.0 (STI)*, Dhaka: IEEE, Dec. 2022.
- [21] M. Rifqi Abdan and M. Akbar, "KLASIFIKASI SAMPAH DAUR ULANG MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK DAN GRAY LEVEL CO-OCCURRENCE MATRIX," *Jurnal Informatika Teknologi dan Sains*, vol. 7, no. 3, pp. 1211–1220, Aug. 2025.