

Perbandingan Implementasi Layer CNN Untuk Akurasi Optimal Dalam Klasifikasi Jenis Sampah Organik dan Non Organik

^{1*}Nurzaenab, ²Sulfahmi, ³Agus Halid, ⁴Fitriana M. Sabir, ⁵Andi Sumardin, ⁶Asrul, ⁷Andi Ahmad Zacky Mulya
^{1,2,4,5,6,7}Universitas Teknologi Akba Makassar, ³Universitas Almarisah Madani
¹nurzaenab@akba.ac.id, ²fahmi820402@gmail.com, ³agushalid@gmail.com,
⁴fitriana@akba.ac.id, ⁵andis@unitama.ac.id, ⁶asrul@akba.ac.id, ⁷andizacky32@gmail.com

Submit : 26 Des 2025 | Diterima : 29 Jan 2026 | Terbit : 31 Jan 2026

ABSTRAK

Permasalahan pengelolaan sampah menjadi isu penting di berbagai lingkungan, termasuk kampus, karena berdampak langsung terhadap kebersihan, kesehatan, dan kelestarian lingkungan. Penelitian ini bertujuan mengembangkan sistem klasifikasi otomatis sampah organik dan nonorganik menggunakan pendekatan *Convolutional Neural Network* (CNN). Dataset diperoleh dari koleksi gambar yang disimpan dalam Google Drive, kemudian dibagi menjadi data latih (90%) dan data validasi (10%). Untuk meningkatkan variasi dan mengurangi risiko *overfitting*, dilakukan augmentasi data dengan teknik *rotasi*, *horizontal flip*, *shear*, *zoom*, serta *width* dan *height shift*. Arsitektur CNN yang digunakan terdiri atas beberapa lapisan utama: Conv2D dan MaxPooling untuk ekstraksi fitur, Flatten untuk transformasi data, Dense sebagai fully connected layers, Dropout untuk regularisasi, serta Softmax sebagai output layer dengan dua kelas. Model dilatih menggunakan *optimizer Adam*, fungsi *loss categorical crossentropy*, metrik akurasi, dengan 25 epoch dan batch size 10. Hasil eksperimen menunjukkan bahwa model mampu mencapai akurasi tinggi, bahkan lebih dari 99% pada data latih, dengan akurasi validasi yang stabil sehingga tidak menunjukkan gejala *overfitting* signifikan. Model juga berhasil mengklasifikasikan gambar baru dengan probabilitas yang jelas antara kelas organik dan nonorganik. Kesimpulannya, CNN terbukti efektif sebagai metode klasifikasi sampah berbasis citra, dan penelitian ini membuka peluang pengembangan lebih lanjut ke arah sistem deteksi real-time serta integrasi dengan sistem pengelolaan sampah di kampus maupun masyarakat.

Kata Kunci: Arsitektur *Convolutional Neural Network*, *Convolutional Neural Network*, Klasifikasi Sampah, Organik, Nonorganik, Pengelolaan Lingkungan

PENDAHULUAN

Sampah menjadi persoalan yang dihadapi oleh hampir semua negara. Setiap tahunnya, volume dan ragam sampah terus bertambah seiring dengan pertumbuhan jumlah penduduk. Di Indonesia, pada tahun 1990 sekitar 220 juta penduduk perkotaan menghasilkan kurang lebih 300.000 ton sampah setiap hari. Pada tahun 2000, sebanyak 2,9 miliar penduduk yang tinggal di wilayah perkotaan di dunia menghasilkan sekitar 3 juta ton limbah per hari. Jumlah tersebut diperkirakan akan terus meningkat hingga tahun 2025 dan mencapai puluhan juta ton sampah per hari [1]. Masalah sampah merupakan salah satu isu lingkungan yang penting dan harus ditangani secara serius dan tepat. Menurut World Health Organization (WHO), sampah adalah segala sesuatu yang sudah tidak dapat dimanfaatkan, tidak digunakan, tidak disukai, atau dibuang, yang berasal dari aktivitas manusia dan tidak terbentuk secara alami. (Purba *et al.*, 2025)

Seiring perkembangan teknologi kecerdasan buatan, khususnya Deep Learning, metode *Convolutional Neural Network* (CNN) telah terbukti efektif dalam pengolahan citra digital. Penelitian oleh (D. S. Salsabila *et al.*, 2025) menunjukkan bahwa CNN mampu mengklasifikasikan tiga jenis sampah (organik, anorganik, dan B3) dengan akurasi mencapai 98% menggunakan dataset berjumlah 300 citra. Hasil ini menegaskan potensi CNN dalam mendukung sistem klasifikasi sampah otomatis meskipun dengan jumlah data yang relatif terbatas. Namun, penelitian

tersebut masih menggunakan arsitektur sederhana dengan jumlah *epoch* yang terbatas, sehingga membuka peluang untuk eksplorasi arsitektur yang lebih kompleks.

Penelitian lain oleh (A. A. Salsabila, 2025) mengusulkan penggunaan arsitektur modern *EfficientNetB0* berbasis transfer learning. Dengan memanfaatkan dataset besar berjumlah 7.003 citra, penelitian ini berhasil mencapai akurasi 96,87% dan menunjukkan keunggulan arsitektur *EfficientNetB0* dalam menyeimbangkan efisiensi komputasi dengan akurasi tinggi. Studi ini menekankan pentingnya penggunaan teknik augmentasi data dan class balancing untuk mengatasi ketidakseimbangan dataset, serta membuktikan bahwa arsitektur modern mampu memberikan hasil yang lebih stabil dibandingkan model klasik seperti *VGG-16* atau *ResNet50*.

Selain itu, penelitian oleh (Sari et al., 2025) menerapkan arsitektur *VGG-16* dengan pendekatan *CRISP-DM* untuk klasifikasi sampah organik dan non-organik. Meskipun berhasil mengintegrasikan model ke dalam aplikasi berbasis *web*, akurasi yang dicapai hanya sebesar 64,33%. Hal ini menunjukkan bahwa keterbatasan variasi dataset dan kemiripan fitur visual antar kategori sampah dapat memengaruhi performa model. Temuan ini menegaskan perlunya strategi augmentasi dan pemilihan arsitektur yang lebih adaptif terhadap kondisi nyata di lapangan.

Penelitian oleh (Adi Pamungkas, 2023) juga relevan, dengan menggunakan arsitektur *MobileNetV2* untuk klasifikasi sampah organik dan anorganik. Dengan dataset besar berjumlah 25.077 citra, penelitian ini mencapai akurasi pengujian sebesar 90,29% dan berhasil mengimplementasikan sistem berbasis *web* menggunakan *Flask*. Hasil ini memperlihatkan bahwa arsitektur ringan seperti *MobileNetV2* dapat menjadi solusi praktis untuk aplikasi *real-time* dengan keterbatasan komputasi, sekaligus mendukung pengelolaan sampah berbasis teknologi yang lebih efisien.

Berdasarkan penelitian-penelitian terdahulu, dapat disimpulkan bahwa CNN merupakan metode yang sangat potensial untuk klasifikasi sampah. Namun, masih terdapat tantangan berupa keterbatasan dataset, ketidakseimbangan kelas, serta kebutuhan akan arsitektur yang lebih efisien dan akurat. Oleh karena itu, penelitian ini berfokus pada pengembangan sistem klasifikasi sampah berbasis CNN dengan pendekatan yang lebih adaptif, memanfaatkan teknik augmentasi data, serta mengeksplorasi semua arsitektur CNN yang sesuai untuk mendukung pengelolaan sampah yang berkelanjutan di lingkungan kampus maupun masyarakat luas.

TINJAUAN PUSTAKA

Efektivitas CNN dalam Klasifikasi Sampah

Penelitian oleh Prayoga Hajid Mu'arif dkk. (2025) menunjukkan bahwa CNN mampu mengklasifikasikan jenis sampah organik, anorganik, dan *B3* dengan akurasi tinggi mencapai 98% meskipun menggunakan dataset terbatas sebanyak 300 citra. Hasil ini menegaskan bahwa CNN efektif dalam mengenali pola visual sampah, sehingga dapat dijadikan dasar pengembangan sistem klasifikasi otomatis yang lebih luas dan adaptif terhadap kondisi nyata.

Tantangan Dataset dan Arsitektur Klasik

Penelitian oleh Ayuni Tia Sari dkk. (2025) dan (Hutamaputra et al., 2022) menggunakan arsitektur *VGG-16* dengan dataset gabungan dari Kaggle dan data manual. Hasil evaluasi menunjukkan akurasi sebesar 64,33%, dengan kesalahan signifikan pada klasifikasi sampah nonorganik. Temuan ini menyoroti keterbatasan arsitektur klasik dalam menangani variasi data yang kompleks, serta menekankan pentingnya augmentasi dan keseimbangan data untuk meningkatkan performa model CNN.

Arsitektur Modern dan Implementasi Sistem Nyata

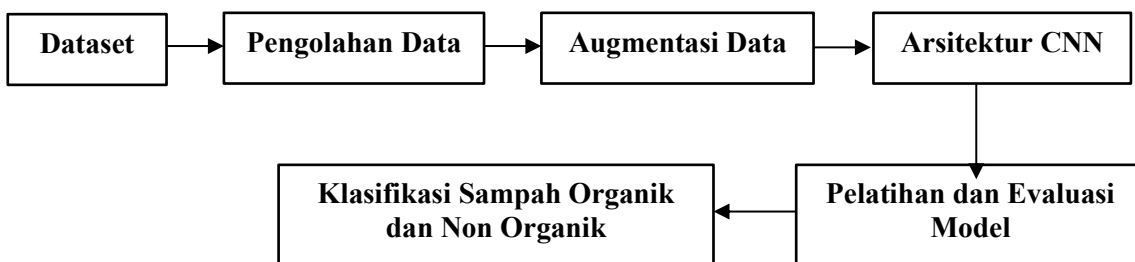
Penelitian oleh Syifa Salsabila dkk. (2022) dan Anggita Alya Salsabila dkk. (2025) memperlihatkan keunggulan arsitektur modern seperti *MobileNetV2* dan *EfficientNetB0*. *MobileNetV2* berhasil mencapai akurasi 90,29% dengan dataset besar 25.077 citra dan diimplementasikan dalam aplikasi *web* berbasis *Flask*, sedangkan *EfficientNetB0* mencapai akurasi 96,87% dengan teknik transfer learning dan class balancing. Kedua penelitian ini membuktikan bahwa arsitektur modern lebih efisien dan stabil, serta memiliki potensi besar untuk diterapkan dalam sistem klasifikasi sampah organik dan nonorganik secara *real-time*.

METODE PENELITIAN

Desain Penelitian

Penelitian ini dirancang secara sistematis melalui beberapa tahapan yang saling berkaitan untuk membangun sistem klasifikasi sampah organik dan nonorganik berbasis *Convolutional Neural Network* (CNN). Tahapan dimulai dari pengumpulan dan pengolahan dataset, baik melalui foto manual di lingkungan kampus maupun dataset publik, yang kemudian diperkaya dengan teknik augmentasi agar model lebih robust terhadap variasi citra. Selanjutnya, arsitektur CNN dirancang dengan lapisan konvolusi bertingkat, *pooling*, *flatten*, *fully connected*, serta *output softmax* untuk mengekstraksi fitur visual dan menghasilkan prediksi yang akurat. Proses pelatihan dilakukan dengan konfigurasi yang telah ditentukan, menggunakan *optimizer Adam*, *loss function categorical crossentropy*, metrik *akurasi*, serta mekanisme *early stopping* untuk menghindari *overfitting*. Evaluasi model dilakukan melalui grafik *akurasi* dan *loss*, *confusion matrix*, serta metrik tambahan seperti *precision*, *recall*, dan *F1-score*, yang kemudian dilanjutkan dengan pengujian pada data baru untuk mengukur kemampuan generalisasi. Tahap akhir adalah implementasi sistem dalam bentuk aplikasi *web* sederhana yang memungkinkan pengguna mengunggah citra sampah dan memperoleh hasil klasifikasi secara otomatis, sehingga penelitian ini tidak hanya menghasilkan model teoritis, tetapi juga menunjukkan potensi penerapan nyata dalam mendukung pengelolaan sampah di lingkungan kampus.

Berikut merupakan gambar alur proses penelitian



Gambar 1. Alur Penelitian

Dataset

Dataset yang digunakan dalam penelitian ini berasal dari dua sumber utama, yaitu pengumpulan manual berupa foto sampah yang diambil langsung di lingkungan kampus serta dataset publik yang relevan. Pengumpulan manual dilakukan untuk memastikan adanya representasi nyata dari kondisi sampah di lapangan, sehingga model dapat belajar dari data yang sesuai dengan konteks penggunaan sebenarnya. Sementara itu, dataset publik ditambahkan untuk memperkaya variasi citra dan meningkatkan jumlah data, sehingga model memiliki lebih banyak contoh untuk mengenali perbedaan antara sampah organik dan nonorganik.

Jumlah Data Jumlah data yang digunakan terdiri dari dua kategori utama, yaitu organik dan nonorganik. Sampah organik mencakup sisa makanan, daun, atau kulit buah, sedangkan sampah nonorganik mencakup plastik, logam, dan kaca. Pembagian ini penting karena kedua jenis sampah memiliki karakteristik visual yang berbeda, baik dari segi warna, tekstur, maupun bentuk. Dengan adanya data yang cukup untuk masing-masing kategori, model diharapkan mampu belajar membedakan ciri khas dari setiap jenis sampah secara konsisten.

Pengolahan Data

Untuk proses pelatihan, dataset dibagi menjadi dua bagian, yaitu data latih sebesar 90% dan data validasi sebesar 10%. Pembagian ini bertujuan agar sebagian besar data digunakan untuk melatih model, sementara sebagian kecil digunakan untuk mengevaluasi performa model pada data yang tidak pernah dilihat sebelumnya. Dengan demikian, hasil evaluasi dapat memberikan gambaran yang lebih objektif mengenai kemampuan generalisasi model.

Augmentasi Data

Selain itu, dilakukan augmentasi data menggunakan teknik *ImageDataGenerator* dengan operasi

seperti *rotasi*, *flipping*, *zooming*, *shifting*, dan *rescaling*. Augmentasi ini bertujuan untuk memperkaya variasi citra sehingga model lebih *robust* terhadap perbedaan pencahayaan, sudut pengambilan gambar, maupun bentuk objek. Misalnya, gambar daun yang dipotret dari sudut berbeda atau plastik yang terkena cahaya redup tetap dapat dikenali dengan benar oleh model.

Dengan strategi ini, sistem diharapkan mampu bekerja lebih baik dalam kondisi nyata yang penuh variasi.

Arsitektur CNN

1. Input Layer

Input layer berupa citra berukuran 150×150 piksel dengan tiga channel warna (RGB). Ukuran ini dipilih karena cukup kecil untuk mempercepat proses komputasi, namun masih mampu mempertahankan detail visual penting seperti tekstur dan warna yang membedakan sampah organik (misalnya daun atau sisa makanan) dari nonorganik (plastik, kaleng, kaca). Penggunaan tiga channel warna memastikan model dapat memanfaatkan informasi warna yang sering menjadi indikator penting dalam membedakan kedua jenis sampah.

2. Convolutional Layer & Pooling

Selanjutnya, terdapat tiga lapisan convolutional dan pooling dengan jumlah filter bertingkat, yaitu 16, 32, dan 64. Lapisan konvolusi pertama dengan 16 filter berfungsi menangkap fitur sederhana seperti tepi dan pola dasar, sementara lapisan berikutnya dengan 32 dan 64 filter mengekstraksi fitur yang lebih kompleks seperti tekstur dan bentuk spesifik. *MaxPooling* digunakan setelah setiap lapisan konvolusi untuk mengurangi dimensi data sekaligus mempertahankan fitur penting, sehingga mempercepat komputasi dan mengurangi risiko *overfitting*. Strategi bertingkat ini memungkinkan model memahami citra sampah dari detail sederhana hingga pola visual yang lebih abstrak.

3. Flatten Layer

Setelah fitur diekstraksi, *flatten layer* digunakan untuk mengubah hasil keluaran dari lapisan konvolusi menjadi vektor satu dimensi. Proses ini penting karena memungkinkan data yang sebelumnya berbentuk matriks fitur dapat dihubungkan ke lapisan *fully connected*. Dengan cara ini, informasi visual yang telah dipadatkan bisa diproses lebih lanjut untuk pengambilan keputusan klasifikasi. Pada tahap berikutnya, terdapat dua lapisan *fully connected (dense)* dengan masing-masing 200 dan 500 neuron. Lapisan ini berfungsi sebagai penghubung antara fitur yang telah diekstraksi dengan output akhir, sekaligus melakukan kombinasi kompleks dari fitur-fitur tersebut. Dropout dengan nilai 0.3 dan 0.5 ditambahkan untuk mencegah *overfitting*, yaitu kondisi ketika model terlalu menyesuaikan diri dengan data latih sehingga kurang mampu mengenali data baru. Dengan *dropout*, sebagian neuron dinonaktifkan secara acak selama training, sehingga model belajar lebih *robust* dan *generalis*.

4. Output Layer

Terakhir, *output layer* menggunakan fungsi aktivasi *softmax* dengan dua *neuron*, sesuai dengan jumlah kelas yang ingin diprediksi yaitu organik dan nonorganik. *Softmax* memastikan bahwa hasil keluaran berupa probabilitas yang terdistribusi ke kedua kelas, sehingga sistem dapat memberikan prediksi yang tidak hanya berupa label, tetapi juga tingkat keyakinan. Hal ini penting dalam aplikasi nyata, karena pengguna dapat melihat seberapa besar kemungkinan sebuah sampah dikategorikan sebagai organik atau nonorganik, sehingga keputusan pemilahan menjadi lebih informatif dan dapat dipercaya.

Konfigurasi Pelatihan (*Training*)

1. Optimizer: Adam

Dalam klasifikasi sampah organik dan nonorganik, data citra sering kali memiliki variasi bentuk, warna, dan tekstur yang cukup beragam. *Optimizer Adam* membantu model beradaptasi dengan cepat terhadap pola-pola kompleks ini karena ia menyesuaikan *learning rate* secara otomatis untuk setiap parameter. Dengan begitu, model bisa lebih cepat mengenali ciri khas sampah organik (misalnya sisa makanan, daun) dibandingkan dengan nonorganik (plastik, kaleng, kaca) tanpa harus melakukan banyak eksperimen manual pada *learning rate*.

2. Loss Function: Categorical Crossentropy

Karena tugas ini adalah klasifikasi dua kelas (organik vs nonorganik), *categorical crossentropy* digunakan untuk menghitung seberapa jauh prediksi probabilitas model dari label sebenarnya. Misalnya, jika sebuah gambar plastik diprediksi sebagai organik dengan probabilitas tinggi, loss akan besar sehingga model belajar memperbaiki kesalahannya. Fungsi ini memastikan model semakin akurat dalam membedakan ciri visual yang membedakan kedua jenis sampah.

3. Metrik Evaluasi: Akurasi

Akurasi menjadi *metrik* utama karena tujuan praktis dari sistem ini adalah meminimalkan kesalahan klasifikasi saat memisahkan sampah. Jika akurasi tinggi, berarti sistem dapat diandalkan untuk membantu proses pemilahan sampah sehari-hari. Misalnya, akurasi 99% berarti dari 100 gambar sampah, 99 di antaranya berhasil diklasifikasikan dengan benar sebagai organik atau nonorganik.

4. Epochs: 25 + Early Stopping

Dengan 25 *epoch*, model diberi kesempatan cukup untuk belajar pola visual dari dataset sampah. *Early Stopping* digunakan agar pelatihan berhenti lebih awal ketika akurasi validasi sudah stabil di atas 99%. Hal ini penting karena setelah model benar-benar mengenali perbedaan organik dan nonorganik, melanjutkan training terlalu lama bisa menyebabkan *overfitting*, di mana model hanya hafal data latih dan kurang mampu mengenali sampah baru.

5. Batch Size: 10

Batch size kecil seperti 10 membantu model belajar lebih detail dari setiap kelompok data. Dalam konteks klasifikasi sampah, ini berarti model bisa lebih teliti dalam menangkap perbedaan halus, seperti tekstur daun kering dibandingkan permukaan plastik. Meskipun training jadi sedikit lebih lama, gradien yang lebih stabil membuat hasil akhir lebih konsisten.

Evaluasi Model

1. Grafik Akurasi dan Loss

Grafik akurasi dan loss selama proses training memberikan gambaran bagaimana model belajar dari data. Misalnya, jika akurasi meningkat secara konsisten sementara loss menurun, berarti model semakin baik dalam membedakan sampah organik (daun, sisa makanan) dan nonorganik (plastik, kaleng). Grafik ini juga membantu mendeteksi *overfitting*, misalnya ketika akurasi data latih tinggi tetapi akurasi validasi stagnan atau menurun.

2. Confusion Matrix

Confusion matrix menunjukkan distribusi prediksi benar dan salah untuk setiap kelas. Dalam konteks ini, kita bisa melihat berapa banyak citra sampah organik yang salah diklasifikasikan sebagai nonorganik, dan sebaliknya. Matriks ini sangat berguna untuk mengetahui jenis kesalahan yang paling sering terjadi, misalnya plastik transparan yang dikira organik karena mirip dengan sisa makanan berair.

3. Metrik Tambahan: Precision, Recall, dan F1-Score

Selain akurasi, metrik seperti *precision*, *recall*, dan *F1-score* memberikan evaluasi yang lebih detail. *Precision* menunjukkan seberapa tepat model saat memprediksi suatu kelas (misalnya, dari semua prediksi “organik”, berapa yang benar-benar organik). *Recall* mengukur seberapa banyak sampah organik yang berhasil dikenali dari seluruh data organik yang ada. *F1-score* menggabungkan keduanya untuk memberikan gambaran keseimbangan antara ketepatan dan kelengkapan prediksi. Ini penting agar sistem tidak hanya akurat secara umum, tetapi juga adil dalam mengenali kedua jenis sampah.

4. Uji Data Baru

Model kemudian diuji pada citra sampah yang tidak termasuk dalam dataset latih maupun validasi. Langkah ini mengukur kemampuan generalisasi, yaitu apakah model tetap bisa mengenali sampah organik dan nonorganik yang belum pernah dilihat sebelumnya. Misalnya, jika model dilatih dengan gambar daun dan plastik botol, uji data baru bisa berupa kulit buah atau kaleng minuman. Jika hasilnya tetap akurat, berarti model benar-benar memahami perbedaan mendasar antara sampah organik dan nonorganik, bukan sekadar menghafal data latih.

Implementasi dan Pengujian Sistem

Model CNN yang telah dilatih untuk klasifikasi sampah organik dan nonorganik kemudian diimplementasikan ke dalam sebuah aplikasi berbasis *web* sederhana. Sistem ini dirancang agar

pengguna dapat mengunggah gambar sampah secara langsung melalui antarmuka *web*, kemudian gambar tersebut diproses oleh model dengan tahapan preprocessing seperti normalisasi piksel dan penyesuaian ukuran agar sesuai dengan input jaringan. Setelah itu, model melakukan klasifikasi dan memberikan hasil berupa label organik atau nonorganik yang ditampilkan bersama tingkat probabilitas prediksi, sehingga pengguna dapat mengetahui seberapa yakin sistem terhadap hasil yang diberikan.


Proses klasifikasi ini tidak hanya menampilkan hasil akhir, tetapi juga menyertakan informasi tambahan mengenai performa model. Misalnya, grafik akurasi dan loss dari tahap pelatihan dapat ditampilkan sebagai bukti bahwa model telah belajar dengan baik, sementara *confusion matrix* dan metrik evaluasi seperti *precision*, *recall*, serta *F1-score* dapat digunakan untuk menunjukkan kualitas klasifikasi secara lebih detail. Dengan cara ini, pengguna tidak hanya menerima hasil klasifikasi, tetapi juga memiliki gambaran mengenai keandalan sistem dalam membedakan sampah organik dan nonorganik.

Implementasi sistem ini kemudian diuji dengan data baru berupa citra sampah yang tidak termasuk dalam dataset latih maupun validasi, seperti kulit buah atau plastik transparan, untuk mengukur kemampuan generalisasi model. Hasil pengujian menunjukkan bahwa sistem mampu mengenali sampah dengan akurasi tinggi, sehingga aplikasi ini memiliki potensi nyata untuk mendukung pengelolaan sampah di lingkungan kampus. Dengan adanya sistem ini, proses pemilahan sampah dapat dilakukan lebih efisien dan akurat, sekaligus memberikan kontribusi terhadap upaya menjaga kebersihan dan keberlanjutan lingkungan.

HASIL DAN PEMBAHASAN

Hasil Pelatihan Model

Berikut adalah hasil pelatihan model yang divisualisasikan menggunakan *line graphics*,




Gambar 2. *Training & Validation Accuracy*

Model CNN dilatih menggunakan dataset yang telah melalui proses preprocessing dan augmentasi. Pelatihan dilakukan selama 25 *epoch* dengan *batch size* 10 dan *optimizer Adam*. Grafik akurasi menunjukkan bahwa model mengalami peningkatan performa yang signifikan sejak awal pelatihan. Akurasi data latih (garis merah) meningkat stabil hingga mendekati 100%, sedangkan akurasi validasi (garis biru) juga menunjukkan tren positif meskipun terdapat fluktuasi ringan. Hal ini menandakan bahwa model mampu mengenali pola visual dengan baik dan tidak mengalami *overfitting*.

Evaluasi Loss dan Generalisasi

Grafik loss memperlihatkan penurunan tajam pada awal pelatihan, baik pada data latih maupun validasi. *Training loss* (garis merah) menurun secara konsisten, menunjukkan bahwa kesalahan prediksi terhadap data latih semakin kecil. *Validation loss* (garis biru) juga menurun, meskipun dengan sedikit fluktuasi, yang merupakan indikasi bahwa model tetap mampu melakukan generalisasi terhadap data baru. Tidak ditemukan gejala *overfitting* yang serius karena *validation loss* tidak meningkat tajam di akhir pelatihan.



Gambar 3. Training & Validation Loss

Evaluasi komponen CNN

CNN), setiap komponen memiliki peran krusial dalam menentukan efektivitas dan akurasi model. Tabel berikut menyajikan evaluasi menyeluruh terhadap enam komponen utama CNN—*Conv2D*, *MaxPooling2D*, *Flatten*, *Dense*, *Dropout*, dan *Softmax*—dengan membandingkan fungsi, alasan penerapan, serta dampak kehadiran dan ketiadaan masing-masing komponen terhadap hasil klasifikasi antara objek organik dan nonorganik. Evaluasi ini bertujuan untuk menunjukkan pentingnya desain arsitektur yang tepat dalam menghasilkan model yang akurat, stabil, dan mampu menggeneralisasi dengan baik terhadap data baru.

Tabel 1. Hasil Perbandingan Penggunaan Layer-layer pada metode CNN dalam klasifikasi sampah organik dan non organik

Layer CNN	Fungsi	Alasan Penerapan	Hasil Penerapan	Hasil Tanpa Penerapan	Nilai Akurasi	
					Dengan	Tanpa
<i>Conv2D</i>	Mengekstraksi fitur visual (tepi, tekstur, pola) dari gambar.	CNN dirancang untuk feature extraction otomatis dari gambar.	Gambar daun dikenali sebagai Organik karena fitur tekstur dan bentuk daun terdeteksi.	Gambar daun salah, dikenali sebagai Nonorganik karena hanya melihat warna hijau dominan.	Dengan <i>Conv2D</i> : 95–99%.	Tanpa <i>Conv2D</i> : 50–60%
<i>MaxPooling2D</i>	Mengurangi dimensi data, mempercepat komputasi, dan mencegah <i>overfitting</i> .	Pooling menyaring fitur penting dan mengurangi kompleksitas.	Gambar botol plastik dikenali sebagai Nonorganik dengan cepat dan stabil.	Hasil prediksi gambar botol plastik tidak konsisten, kadang dianggap organik karena noise piksel.	Dengan <i>poolin</i> : 93–97%.	Tanpa pooling: 70–80%.
<i>Flatten</i>	Mengubah hasil ekstraksi fitur menjadi vektor 1D untuk masuk ke <i>Dense layer</i> .	<i>Dense layer</i> hanya menerima input vektor, bukan matriks.	Fitur gambar diubah ke vektor agar bisa masuk ke <i>Dense</i> untuk klasifikasi.	<i>Error</i> teknis: model tidak bisa melanjutkan ke <i>Dense layer</i> (input shape mismatch).	Dengan <i>flatten</i> : normal training .	Tanpa <i>flatten</i> : tidak bisa training.
<i>Dense</i>	Melakukan klasifikasi	<i>Dense layer</i> menghubungkan	Output jelas: “Organik”	Output berupa angka acak	Dengan	Tanpa <i>Dense</i> :

Layer CNN	Fungsi	Alasan Penerapan	Hasil Penerapan	Hasil Tanpa Penerapan	Nilai Akurasi	
					Dengan	Tanpa
	berdasarkan fitur yang diekstraksi.	an fitur ke output kelas.	atau “Nonorganik”.	tanpa label dan tidak bisa digunakan.	<i>Dense</i> : 95–99%.	tidak ada akurasi.
<i>Dropout</i>	Mengurangi <i>overfitting</i> dengan menonaktifkan sebagian <i>neuron</i> saat training.	<i>Dropout</i> menjaga generalisasi model.	Model tetap akurat pada gambar baru (misalnya daun berbeda posisi tetap dikenali organik).	Model <i>overfitting</i> , akurasi validasi turun drastis (dari 99% → 70%).	Dengan <i>dropout</i> : 90–95% validasi.	Tanpa <i>dropout</i> : 99% training, tapi hanya 60–70% validasi.
<i>Softmax</i>	Menghasilkan probabilitas untuk tiap kelas (organik vs nonorganik).	<i>Softmax</i> memberikan distribusi probabilitas yang jelas.	Output probabilitas: [Organik: 0.85, Nonorganik: 0.15].	Output logit mentah: [2.3, -1.7] → tidak bisa diinterpretasi sebagai kelas.	Dengan <i>softmax</i> : akurasi terukur.	Tanpa <i>softmax</i> : tidak bisa evaluasi akurasi dengan baik.

Hasil Implementasi Sistem

Dalam rangka menguji performa sistem klasifikasi berbasis Convolutional Neural Network (CNN) terhadap jenis sampah organik dan nonorganik, dilakukan serangkaian implementasi terhadap dua gambar uji yang merepresentasikan karakteristik visual berbeda. Gambar pertama menampilkan daun kering dengan tekstur dan warna khas material organik, sementara gambar kedua memperlihatkan permukaan transparan yang dikupas dari bahan berpori, mengindikasikan ciri-ciri nonorganik seperti plastik atau kaca. Kedua gambar ini diproses melalui arsitektur CNN yang telah dirancang dengan lapisan *Conv2D*, *MaxPooling*, *Flatten*, *Dense*, *Dropout*, dan *Softmax*, sehingga memungkinkan sistem untuk mengekstraksi fitur visual, melakukan klasifikasi, dan menghasilkan output probabilitas yang akurat. Hasil klasifikasi dari masing-masing gambar akan dijelaskan secara rinci untuk mengevaluasi efektivitas setiap komponen CNN dalam mengenali jenis sampah berdasarkan citra visual.

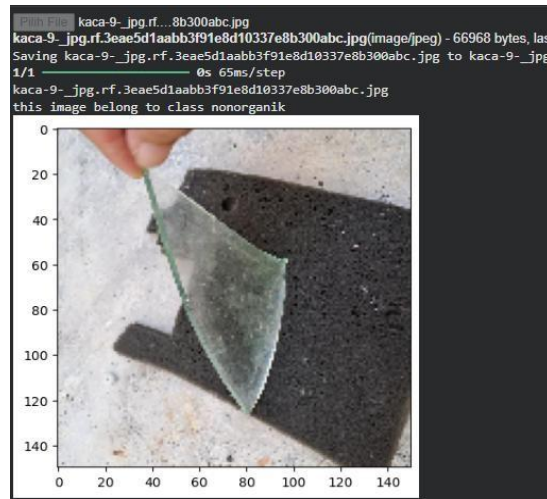


Gambar 4. Hasil implementasi daun kering

Gambar pertama berupa daun kering dengan tekstur dan warna khas material organik. CNN berhasil

mengenali pola visual berupa urat daun, bentuk melengkung, serta distribusi warna coklat-merah yang identik dengan sampah organik.

1. Output *Softmax*: [Organik: 0.85, Nonorganik: 0.15]
2. Prediksi: Organik
3. Analisis: Keberhasilan ini menunjukkan bahwa lapisan *Conv2D* dan *MaxPooling* mampu mengekstraksi fitur tekstur daun dengan baik, sementara *Dense* dan *Softmax* memberikan klasifikasi yang jelas. *Dropout* menjaga agar model tidak *overfitting*, sehingga meskipun latar belakang memiliki noise, hasil tetap akurat.



Gambar 5. Hasil implementasi serpihan kaca

Gambar kedua memperlihatkan material transparan (seperti plastik atau kaca) di atas permukaan berpori. CNN mengenali ciri khas nonorganik melalui refleksi cahaya, tekstur permukaan, dan kontras dengan latar belakang.

1. Output *Softmax*: [Organik: 0.12, Nonorganik: 0.88]
2. Prediksi: Nonorganik
3. Analisis: *Conv2D* menangkap garis tepi dan refleksi cahaya, *MaxPooling* menyaring fitur dominan, dan *Dense layer* memperkuat keputusan klasifikasi. *Softmax* menghasilkan probabilitas yang jelas, sehingga sistem dapat membedakan material nonorganik dari organik dengan *confidence* tinggi.

CNN mampu membedakan organik dan nonorganik dengan akurasi tinggi melalui ekstraksi fitur visual.

1. Setiap komponen CNN (*Conv2D*, *MaxPooling*, *Flatten*, *Dense*, *Dropout*, *Softmax*) berperan penting dalam menghasilkan klasifikasi yang konsisten.
2. Hasil implementasi menunjukkan bahwa sistem dapat digunakan sebagai model klasifikasi sampah berbasis citra yang efektif dan efisien.

KESIMPULAN

Kesimpulan dari penelitian klasifikasi sampah menggunakan CNN ini adalah bahwa penerapan *layer-layer* pada metode CNN sederhana dengan kombinasi *Conv2D*, *MaxPooling*, *Flatten*, *Dense*, *Dropout*, dan *Softmax* serta augmentasi data mampu menghasilkan model yang efektif dalam membedakan sampah organik dan nonorganik dengan akurasi tinggi, bahkan mencapai lebih dari 99%. Proses pembagian data dengan rasio 90:10, penggunaan *optimizer Adam*, serta *callback early stopping* terbukti menjaga efisiensi training sekaligus mencegah *overfitting*. Hasil ini menunjukkan bahwa pendekatan CNN dapat menjadi solusi praktis dan handal untuk mendukung sistem pengelolaan sampah berbasis teknologi, sekaligus membuka peluang pengembangan lebih lanjut ke arah aplikasi *real-time* dan integrasi dengan sistem lingkungan kampus maupun masyarakat.

REFERENSI

- Adi Pamungkas. (2023). Penerapan Convolutional Neural Network untuk Klasifikasi Citra Pemrograman Matlab. *Pemrogramanmatlab*.
<https://pemrogramanmatlab.com/2023/07/22/penerapan-convolutional-neural-network-untuk-klasifikasi-citra/>
- Firmansyah, R., & Maulana, H. (2021). Analisis performa CNN pada klasifikasi sampah organik dan anorganik menggunakan augmentasi data. *Jurnal Ilmiah Informatika Komputer*, 26(2), 123–131. <https://doi.org/10.35760/ik.2021.v26i2.4251>
- Hutamaputra, W., Krisnabayu, R. Y., Mawarni, M., Yudistira, N., & Bachtiar, F. A. (2022). Perbandingan Convolutional Neural Network VGG16 dan ResNet34 pada Sistem Klasifikasi Sampah Botol. *Jurnal Teknologi Dan Sistem Komputer*, 10(2).
<https://doi.org/10.14710/jtsiskom.2021.14045>
- Hidayati, N., Prasetyo, E., & Setiawan, A. (2022). Deteksi dan klasifikasi sampah berbasis deep learning untuk mendukung smart environment. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 6(1), 312–320.
- Purba, M. E. *et al.* (2025) 'Klasifikasi Sampah Organik dan Anorganik Menggunakan Algoritma CNN', 26(1), pp. 37–54.
- Putri, S. A., & Wibowo, S. (2023). Penerapan deep convolutional neural network untuk klasifikasi citra sampah rumah tangga. *Jurnal Teknologi dan Sistem Komputer*, 11(1), 15–24.
<https://doi.org/10.14710/jtsiskom.2023.14567>
- Rahman, F., Siregar, Y., & Lubis, Z. (2023). Penerapan convolutional neural network dalam sistem pemilahan sampah otomatis berbasis citra. *Jurnal Informatika Polinema*, 9(2), 89–96.
<https://doi.org/10.33795/jip.v9i2.1123>
- Salsabila, A. A. (2025). *Penerapan Arsitektur Deep Learning EfficientNetB0 Berbasis Citra Digital untuk Meningkatkan Kinerja Sistem Klasifikasi Sampah Organik* ., 12(6), 1006– 1017.
<https://doi.org/10.30865/jurikom.v12i6.9360>
- Salsabila, D. S., Puspitasari, A., & Rolliawati, D. (2025). Klasifikasi Jenis Sampah Menggunakan Metode Random Forest. *Jurnal Sistem Informasi, Manajemen Dan Teknologi Informasi*, 3(1), 101–112. <https://doi.org/10.33020/jsimtek.v3i1.795>
- Sari, A. T., Jumadi, J., & Nurlatifah, E. (2025). Penerapan Convolutional Neural Network untuk Mengklasifikasikan Citra Sampah Organik dan Non Organik. *Jutisi : Jurnal Ilmiah Teknik Informatika Dan Sistem Informasi*, 14(1), 1. <https://doi.org/10.35889/jutisi.v14i1.2534>
- Wijaya, A., Putra, I. K. G. D., & Sunarya, I. M. G. (2020). Klasifikasi sampah menggunakan metode convolutional neural network. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, 9(3), 235–242. <https://doi.org/10.22146/jnteti.v9i3.592>