

PERANCANGAN DAN PENGEMBANGAN MODEL CNN DALAM KLASIFIKASI JENIS SAMPAH DAUR ULANG

Dwi Okta Djoas¹, Indry Anggraeny², Hilda Apriliya Ningsih³, Ade Irgi Firdaus⁴, Riefaldi Diofano Saputra⁵, Fuad Nur Hasan⁶

Informatika, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika
Jl. Kramat Raya No.98, RT.2/RW.9, Kwitang, Kec. Senen, Kota Jakarta Pusat, Daerah Khusus Ibukota Jakarta 10450

E-mail: 15230125@bsi.ac.id¹, 15230282@bsi.ac.id², 15230253@bsi.ac.id³, 15230116@bsi.ac.id⁴,
15230116@bsi.ac.id⁵, *fuad.fnu@bsi.ac.id⁶

Abstrak - Penelitian ini merancang dan mengembangkan model klasifikasi sampah daur ulang berbasis Convolutional Neural Network (CNN) dengan arsitektur ResNet-50 menggunakan dataset Garbage Classification Kaggle yang berisi 15.150 citra dalam 12 kategori sampah rumah tangga. Data diproses melalui tahapan prapengolahan, normalisasi, dan augmentasi untuk meningkatkan keragaman citra, kemudian model dilatih menggunakan pendekatan transfer learning dan fine-tuning dengan penyeimbangan kelas untuk mengatasi ketimpangan distribusi data. Evaluasi menggunakan confusion matrix menunjukkan akurasi validasi sebesar 99% dengan weighted F1-score 0,99, yang menandakan performa klasifikasi yang sangat andal dan konsisten di seluruh kelas. Model selanjutnya diintegrasikan ke dalam aplikasi web Trash2Treasure menggunakan framework Next.js dan *backend* Elysia.js yang terhubung ke *endpoint* Hugging Face serta layanan AI untuk memberikan rekomendasi *upcycling* secara *real-time*. Hasil penelitian ini menunjukkan bahwa integrasi CNN dan sistem berbasis web berpotensi meningkatkan efisiensi pemilahan sampah rumah tangga, mendorong praktik ekonomi sirkular, dan mendukung pengelolaan lingkungan yang cerdas serta berkelanjutan pada skala rumah tangga.

Kata Kunci: Convolution Neural Network, Klasifikasi citra, Pengolahan sampah, ResNet-50.

I. PENDAHULUAN

Permasalahan sampah hingga kini masih menjadi isu lingkungan yang kompleks dan berdampak signifikan terhadap kualitas hidup masyarakat, terutama di kawasan permukiman. Menurut World Health Organization (WHO), sampah merupakan barang yang tidak digunakan, tidak disukai, atau dibuang yang berasal dari aktivitas manusia dan tidak muncul secara alami (Kuncoro et al., 2025). Setiap hari, aktivitas rumah tangga menghasilkan berbagai jenis sampah seperti plastik, kertas, kaca, logam, dan bahan organik. Namun, sebagian besar dari sampah tersebut masih tercampur karena masyarakat belum memiliki kebiasaan untuk melakukan pemilahan sejak dari sumbernya. Sebagian masyarakat menganggap bahwa memilah sampah merupakan kegiatan yang merepotkan dan tidak memberikan manfaat langsung. Kondisi ini menyebabkan proses daur ulang menjadi sulit dan membutuhkan biaya tambahan karena sampah harus dipilah kembali di tahap akhir. Selain itu, penumpukan sampah yang tidak terkelola dengan baik akan meningkatkan risiko pencemaran lingkungan, baik air, tanah, maupun udara, terutama di sekitar Tempat Pembuangan Akhir (TPA). Oleh karena itu, diperlukan upaya pengelolaan sampah yang lebih efisien dan modern guna mendukung keberlanjutan lingkungan. Seiring perkembangan teknologi, pemanfaatan kecerdasan buatan mulai menjadi salah satu solusi dalam mendukung proses pemilahan sampah secara otomatis, cepat, dan

akurat. Dalam bidang Computer Vision, metode Deep Learning telah digunakan secara luas untuk klasifikasi berbasis citra (Doly Ilham Saputra Huta Julu & Dewi Nurdiah, 2025). Salah satu arsitektur yang terbukti efektif adalah Convolutional Neural Network (CNN), karena kemampuannya dalam mengekstraksi fitur visual dari citra secara mendalam (Sadida Aulia et al., 2024). Dengan kemampuan tersebut, CNN memiliki potensi besar untuk membantu proses identifikasi dan klasifikasi jenis sampah secara otomatis.

Penelitian ini berfokus pada pengembangan model CNN berbasis arsitektur ResNet50 untuk klasifikasi jenis sampah daur ulang. Model dilatih menggunakan dataset publik *Garbage Classification* dari Kaggle yang terdiri dari ribuan citra sampah dari berbagai kategori seperti *cardboard*, *glass*, *metal*, *paper*, *plastic*, dan *trash*. Selanjutnya, model yang sudah dilatih diimplementasikan dalam aplikasi berbasis web bernama Trash2Treasure yang memungkinkan pengguna mengunggah gambar sampah dan menerima hasil klasifikasi secara otomatis. Sistem ini juga memberikan rekomendasi sederhana terkait pemanfaatan atau proses daur ulang serta menyimpan riwayat pemindaian pengguna. Dengan antarmuka yang *user-friendly*, aplikasi ini diharapkan dapat meningkatkan kesadaran masyarakat untuk memilah sampah sejak dari rumah. Dengan mengintegrasikan teknologi CNN dalam aplikasi klasifikasi sampah, penelitian ini menawarkan solusi praktis terhadap masalah

pemilahan sampah yang selama ini menjadi hambatan utama dalam proses daur ulang. Sistem yang dikembangkan diharapkan mampu mempercepat alur pemilahan, mengurangi volume sampah yang berakhir di TPA, serta mendukung terwujudnya konsep Artificial Intelligence for Environment. Dengan demikian, penelitian ini menjadi langkah konkret menuju pengelolaan sampah yang lebih cerdas, efisien, dan berkelanjutan di Indonesia.

II. TINJAUAN PUSTAKA

A. Deep Learning

Menurut (Mienye & Swart, 2024), pendekatan deep learning mencakup berbagai arsitektur jaringan saraf dalam dan aplikasinya dalam banyak domain, menunjukkan bahwa teknik ini terus berkembang dalam hal skala, kompleksitas, dan penerapan.

B. Artificial Neural Network (ANN)

Menurut (Wicaksono et al., 2024) dalam Indonesian Journal of Artificial Intelligence and Machine Learning, jaringan saraf tiruan (ANN) bekerja dengan meniru cara kerja otak manusia melalui neuron buatan yang saling terhubung. ANN dapat digunakan untuk berbagai tugas seperti klasifikasi dan prediksi karena kemampuannya mengolah data nonlinier secara efektif.

C. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu algoritma deep learning yang menerima input berupa gambar dan mengidentifikasi aspek atau objek dalam gambar yang dapat digunakan oleh mesin untuk belajar mengenali serta membedakan antara satu gambar dengan gambar lainnya (Dewi et al., 2024).

D. ResNet-50 (Residual Network)


Menurut (Oktaviana & Azhar, 2021) dalam Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi), arsitektur ResNet diperkenalkan untuk mengatasi masalah vanishing gradient pada jaringan dalam dengan menambahkan shortcut connection antar lapisan. Pendekatan ini membuat pelatihan jaringan menjadi lebih stabil dan akurat.

E. Confusion Matrix

Menurut (Putra et al., 2024) dalam Brilliant: Jurnal Riset dan Konseptual, confusion matrix digunakan untuk mengevaluasi performa sistem klasifikasi kualitas telur ayam konsumsi berbasis Convolutional Neural Network (CNN). Hasil penelitian menunjukkan bahwa CNN mampu mengidentifikasi tingkat kualitas telur dengan akurasi yang cukup tinggi, dan analisis confusion matrix membantu menilai tingkat kesalahan prediksi pada tiap kelas citra kerabang telur.

III. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimental untuk merancang dan mengembangkan model Convolutional Neural Network (CNN) yang mampu mengklasifikasikan jenis-jenis sampah daur ulang secara otomatis. Proses penelitian ini terdiri dari beberapa tahapan utama yang sistematis dan terstruktur.



Gambar 1. Alur Penelitian


A. Data Collection

Untuk tahap pengumpulan data, kami mengadopsi dataset publik yang komprehensif dari Kaggle. Dataset tersebut terdiri dari 15.150 gambar yang terbagi ke dalam 12 kategori sampah rumah tangga, di mana setiap kategori mencakup material umum dengan jalur daur ulang yang spesifik.

Tabel 1. Komposisi dan Jumlah Gambar Dataset

No	Kategori Sampah	Jumlah
1	Paper	1.050
2	Cardboard	899
3	Biological	986
4	Metal	769
5	Plastic	866
6	Green-glass	628
7	Brown-glass	607
8	White-glass	743
9	Clothes	4.963
10	Shoes	1.988
11	Batteries	948
12	Trash	703

Sampel acak citra dari dataset yang digunakan dalam penelitian.



Gambar 2. Contoh Citra dari Beberapa Kategori dalam Dataset

Gambar ini mengilustrasikan keragaman visual antar kelas serta variasi intra-kelas. Variasi ini penting untuk melatih model CNN

B. Data Processing

Data citra yang telah dikumpulkan kemudian diproses melalui beberapa tahapan esensial. Pertama, dataset dibagi menjadi data latih (80%) dan data validasi (20%), menghasilkan 12.412 citra untuk pelatihan dan 3.103 citra untuk validasi. Semua citra diseragamkan ukurannya menjadi 224x224 piksel dan nilai pikselnya dinormalisasi ke rentang menggunakan rescaling.

Untuk mencegah *overfitting* dan meningkatkan model, teknik augmentasi data diterapkan secara dinamis hanya pada data latih. Augmentasi ini mencakup operasi RandomFlip, RandomRotation, RandomZoom, RandomContrast, dan RandomTranslation.

C. Pelatihan Model

Pada tahap ini, dilakukan proses pelatihan untuk menghasilkan model klasifikasi sampah dengan performa terbaik. Penelitian ini mengimplementasikan metode transfer learning yang terbukti efektif dalam mempercepat proses pelatihan dan meningkatkan akurasi, terutama pada dataset dengan jumlah data terbatas. Arsitektur yang dipilih sebagai model dasar adalah ResNet-50, sebuah model Convolutional Neural Network (CNN) yang dikenal akan kedalaman dan kemampuannya dalam mengekstraksi fitur kompleks melalui penggunaan *residual connections*.

Arsitektur ResNet-50 yang digunakan merupakan model pralatih dari dataset ImageNet, di mana fitur-fitur dasar yang telah dipelajari dapat dimanfaatkan kembali. Implementasi model ini menggunakan input citra berukuran 224x224 piksel dengan tiga saluran warna (RGB). Di atas arsitektur dasar ResNet-50, sebuah head klasifikasi kustom

ditambahkan untuk menyesuaikan model dengan 12 kelas target pada penelitian ini.

Proses pelatihan melibatkan dua strategi utama, transfer learning awal dan fine-tuning. Pada transfer learning awal, seluruh lapisan backbone ResNet-50 dibekukan, dan hanya head klasifikasi kustom yang dilatih. Selanjutnya, pada tahap fine-tuning, 50 lapisan terakhir dari ResNet-50 diaktifkan kembali untuk dilatih bersama dengan head klasifikasi. Strategi ini memungkinkan model untuk beradaptasi lebih baik dengan fitur-fitur spesifik dari dataset sampah.

Beberapa hyperparameter kunci diatur untuk mengoptimalkan proses pelatihan, seperti yang disajikan pada Tabel 2.

Tabel 2. Konfigurasi Hypeparameter Pelatihan

No	Hyperparameter	Nilai
1	Arsitektur Dasar	ResNet-50
2	Input Size	(224,224,3)
3	Optimizer	Adam
4	Learning Rate	Exponential Decay (initial: 0.001)
5	Batch Size	32
6	Dense Layer	1 layer, 512 neuron
7	Regularisasi	Dropout (0.5), L2 (0.01)

Optimizer yang digunakan adalah Adam, dengan *learning rate* yang diatur untuk menurun secara eksponensial dari nilai awal 0.001. Untuk mengatasi distribusi data yang tidak seimbang antar kelas, diterapkan juga mekanisme class weighting.

D. Validasi dan Evaluasi Model

Untuk mengukur performa model klasifikasi secara objektif, digunakan beberapa metrik evaluasi standar yang dihitung dari Confusion Matrix. Matriks ini membandingkan prediksi model dengan label sebenarnya. Metrik-metrik yang digunakan adalah sebagai berikut:

1. Precision

Mengukur proporsi prediksi positif yang benar dari keseluruhan hasil yang diprediksi sebagai positif. Ini menunjukkan tingkat ketepatan model ketika mengklasifikasikan sebuah sampel ke dalam suatu kelas

$$\text{Precision} = \frac{TP}{TP + FP}$$

2. Recall

Mengukur proporsi sampel positif yang berhasil diidentifikasi dengan benar oleh model dari semua sampel yang seharusnya positif. Metrik ini menunjukkan kemampuan model untuk menemukan kembali semua data yang relevan dalam suatu kelas.

$$\text{Recall} = \frac{TP}{TP + FN}$$

3. F1-Score

Dihitung sebagai rata-rata harmonik dari Precision dan Recall. Metrik ini memberikan skor tunggal yang menyeimbangkan kedua metrik tersebut, dan sangat berguna untuk evaluasi pada dataset dengan distribusi kelas yang tidak seimbang.

$$F1\text{-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

4. Support

Merepresentasikan jumlah sampel aktual untuk setiap kelas dalam dataset, memberikan konteks bagi metrik lainnya.


Di mana TP (True Positive), FP (False Positive), dan FN (False Negative) adalah komponen inti dari confusion matrix.

E. Deployment

Untuk mengimplementasikan model klasifikasi yang telah dilatih, dibangun sebuah aplikasi web interaktif dengan arsitektur modern berbasis layanan. Sistem ini dirancang untuk memberikan pengalaman pengguna yang responsif dan alur kerja yang efisien, mulai dari input gambar hingga penyajian hasil klasifikasi beserta rekomendasi pemanfaatan.

Antarmuka pengguna dikembangkan menggunakan framework Next.js, memungkinkan pembuatan user interface yang cepat dan adaptif. Pada sisi server, logika aplikasi ditangani oleh *backend* yang dibangun menggunakan Elysia.js. *Backend* ini bertugas mengelola permintaan *request* dari pengguna, berkomunikasi dengan berbagai layanan eksternal, dan berinteraksi dengan basis data PostgreSQL untuk pencatatan riwayat.

Model klasifikasi ResNet-50 yang telah dilatih di-deploy sebagai *endpoint* API pada platform Hugging Face, sehingga proses inferensi klasifikasi dapat berjalan secara independen. Selain itu, sistem ini juga terintegrasi dengan layanan OpenAI untuk memberikan nilai tambah berupa saran *upcycling* atau daur ulang kreatif berdasarkan hasil klasifikasi sampah.




Gambar 3. Arsitektur Layanan Sistem Klasifikasi Sampah

IV. HASIL DAN PEMBAHASAN

Bagian ini menjelaskan hasil evaluasi model, implementasi sistem berbasis web, serta analisis performa sistem dalam mendeteksi dan mengklasifikasikan sampah.

A. Akurasi Model


Evaluasi performa model dilakukan melalui beberapa metrik untuk mendapatkan pemahaman yang komprehensif mengenai kemampuannya. Analisis ini mencakup evaluasi selama proses pelatihan dan pengujian pada data validasi yang terdiri dari 3.100 gambar.



Gambar 4. Performa Training dan Validasi Model Klasifikasi Sampah

Training curve yang disajikan pada Gambar 4 menampilkan dinamika proses belajar model selama 10 epoch. Grafik menunjukkan bahwa baik akurasi pelatihan maupun akurasi validasi menunjukkan tren peningkatan yang stabil dan konvergen pada nilai yang tinggi. Grafik juga menunjukkan penurunan nilai loss yang konsisten untuk kedua set data. Hal ini mengindikasikan bahwa model tidak mengalami *overfitting* yang signifikan dan berhasil menggeneralisasi pola dari data latih ke data validasi dengan baik.

Untuk analisis yang lebih mendalam, confusion matrix pada Gambar 5 digunakan untuk memvisualisasikan performa klasifikasi model pada setiap kelas secara individual.



Gambar 5. Performa Training dan Validasi Model Klasifikasi Sampah

Diagonal utama pada matriks menunjukkan jumlah prediksi yang benar yaitu True Positives untuk setiap kelas. Terlihat bahwa sebagian besar kelas memiliki nilai prediksi yang sangat tinggi di diagonal utama, seperti kelas *clothes* dengan 1.060 prediksi benar. Matriks ini juga menunjukkan bahwa kesalahan klasifikasi seperti nilai di luar diagonal sangat minim, mengindikasikan model memiliki kemampuan diskriminatif yang kuat antar kelas.

Hasil kuantitatif dari evaluasi ini dirangkum dalam laporan klasifikasi pada Tabel 3. Model mencapai akurasi keseluruhan sebesar 99% pada data validasi.

Tabel 3. Laporan Klasifikasi


Kategori	Precision	Recall	F1-Score	Support
Paper	0.98	0.99	0.98	210
Cardboard	1.00	0.98	0.99	178
Biological	0.97	1.00	0.98	197
Metal	0.98	0.99	0.99	153
Plastic	0.96	0.94	0.95	173
Green-glass	0.96	0.92	0.94	120
Brown-glass	0.99	0.98	0.98	121
White-glass	0.97	0.96	0.96	155
Clothes	1.00	1.00	1.00	1065
Shoes	0.98	0.98	0.98	395
Batteries	0.98	1.00	0.99	189
Trash	0.97	0.96	0.96	139
Accuracy			0.99	3100
Macro Average	0.98	0.98	0.98	3100
Weighted Average	0.99	0.99	0.99	3100

Dari tabel tersebut, dapat dilihat bahwa model menunjukkan performa yang sangat luar biasa di hampir semua metrik dan kelas. Kelas *clothes* mencapai F1-Score sempurna (1.00), yang didukung oleh jumlah *support* yang paling banyak. Sebagian besar kelas lain juga mencapai F1-Score 0.98 atau lebih tinggi. Performa terendah tercatat pada kelas *plastic* dengan F1-Score 0.95, meskipun angka ini masih tergolong sangat tinggi. Nilai macro average dan weighted average untuk F1-Score sebesar 0.98 dan 0.99 secara berurutan, mengonfirmasi bahwa model yang dikembangkan sangat andal dan akurat untuk tugas klasifikasi 12 jenis sampah ini.

B. Implementasi Sistem Web


Sistem klasifikasi sampah berbasis web yang dikembangkan telah berhasil diimplementasikan dengan baik dan berjalan sesuai perancangan. Aplikasi ini mengutamakan kemudahan penggunaan dengan tampilan antarmuka yang responsif dan intuitif. Pengguna dapat mengakses sistem melalui perangkat mobile maupun desktop,

serta melakukan autentikasi menggunakan akun Google sebelum masuk ke dashboard layanan.



Gambar 6. Halaman Login dan Dashboard Utama

Pada tampilan awal, pengguna disambut dengan halaman login yang sederhana. Setelah berhasil masuk, dashboard utama menampilkan fitur utama, yakni untuk memindai gambar sampah di sekitar dan menerima saran kreasi sesuai hasil klasifikasi. Seluruh fitur seperti informasi riwayat, berita, chat AI, dan profil dapat diakses melalui navigasi di bagian bawah aplikasi.



Gambar 7. Hasil Prediksi dan Saran Upcycling Otomatis

Setelah pengguna melakukan pemindaian gambar, sistem secara otomatis memproses dan menampilkan hasil prediksi jenis sampah utama beserta tingkat probabilitas masing-masing kategori. Bahkan sistem ini langsung memberikan ide *upcycling* hasil integrasi dengan OpenAI, misalnya menyarankan pemanfaatan sepatu bekas menjadi pot tanaman, lengkap dengan langkah pembuatan secara ringkas. Fitur ini menjadi nilai tambah dibanding sistem deteksi konvensional karena memberikan rekomendasi kreatif yang praktis.

Implementasi sistem ini berjalan efektif dan telah diuji dapat memberikan output klasifikasi dan

rekomendasi *upcycling* secara *real-time*, sesuai ekspektasi hasil desain arsitektur.

V. KESIMPULAN DAN SARAN

Kesimpulan

Penelitian ini berhasil merancang dan mengimplementasikan model klasifikasi sampah daur ulang berbasis Convolutional Neural Network (CNN) dengan arsitektur ResNet-50. Model ini terbukti sangat efektif dalam mengenali 12 kategori sampah dengan tingkat akurasi yang luar biasa, mencapai **99%** pada data validasi. Pendekatan *transfer learning* dan *fine-tuning* yang digunakan berhasil mempercepat proses pelatihan dan menghasilkan model dengan kemampuan generalisasi yang sangat baik, seperti yang ditunjukkan oleh nilai *weighted average* F1-Score sebesar 0.99.

Model ini telah berhasil diintegrasikan ke dalam aplikasi web interaktif yang memudahkan pengguna dalam mengidentifikasi jenis sampah dan memperoleh rekomendasi daur ulang berbasis AI secara *real-time*. Penerapan ini memberikan kontribusi signifikan terhadap potensi peningkatan efisiensi pengelolaan sampah sekaligus memperkuat aspek edukatif bagi masyarakat melalui saran *upcycling* yang kreatif.

Saran

Penelitian selanjutnya direkomendasikan untuk memperkaya dataset dengan konteks sampah yang lebih spesifik bagi Indonesia dan mengeksplorasi arsitektur model yang lebih efisien untuk implementasi pada platform web, dan juga mengintegrasikan fitur-fitur fungsional seperti informasi geografis bank sampah dan elemen gamifikasi untuk meningkatkan keterlibatan pengguna, serta memperluas adopsi sistem melalui kolaborasi dengan pemangku kepentingan terkait guna mendukung diseminasi edukasi dan implementasi praktis di masyarakat.

DAFTAR PUSTAKA

- Wicaksono, A., Kencana, I. P. E. N., & Sumarjaya, I. W. (2024). Image Classification Comparison Using Neural Network and Support Vector Machine Algorithm With VGG16 As Feature Extraction Method. *International Journal of Applied Mathematics and Computing*, 1(3), 41–52. <https://doi.org/10.62951/ijamc.v1i3.29>
- Dewi, S., Ramadhani, F., & Djasmayena, S. (2024). Klasifikasi Jenis Jerawat Berdasarkan Gambar Menggunakan Algoritma CNN (Convolutional Neural Network). *Hello World Jurnal Ilmu Komputer*, 3(2), 68–73. <https://doi.org/10.56211/helloworld.v3i2.518>
- Doly Ilham Saputra Huta Julu, & Dewi Nurdiah. (2025). Klasifikasi Sampah Organik Dan Non Organik Menggunakan Transfer Learning. *Jurnal Transformatika*, 23(1), 12–29. <https://doi.org/10.26623/transformatika.v23i1.12201>
- Kuncoro, D. F., Wirasto, A., & Triwibowo, D. N. (2025). *METHOMIKA: Jurnal Manajemen Informatika & Komputerisasi Akuntansi Klasifikasi Jenis Sampah Berbasis Convolutional Neural Network Dengan Optimasi Hyperparameter Tuning Arsitektur Mobilenet*. 9(1). <https://doi.org/10.46880/jmika.Vol9No1.pp130-144>
- Mienye, I. D., & Swart, T. G. (2024). A Comprehensive Review of Deep Learning: Architectures, Recent Advances, and Applications. *Information (Switzerland)*, 15(12). <https://doi.org/10.3390/info15120755>
- Oktaviana, U. N., & Azhar, Y. (2021). Garbage Classification Using Ensemble DenseNet169. *Jurnal RESTI*, 5(6), 1206–1215. <https://doi.org/10.29207/resti.v5i6.3673>
- Putra, F. N., Lestariningsih, Trichay, V. A., & Lestari, F. S. (2024). Sistem Grading Kualitas Telur Ayam Konsumsi berdasarkan Citra Kerabang Menggunakan Convolutional Neural. *Briliant: Jurnal Riset Dan Konseptual*, 9(3), 740–748. <https://doi.org/10.28926/briliant.v9i3.2014>
- Sadida Aulia, D., Arwoko, H., & Asmawati, E. (2024). Klasifikasi Sampah Rumah Tangga Menggunakan Metode Convolutional Neural Network. *METIK JURNAL*, 8(2), 114–120. <https://doi.org/10.47002/metik.v8i2.956>
- Solihin, F., Syarief, M., Rochman, E. M. S., & Rachmad, A. (2023). Comparison of Support Vector Machine (SVM), K-Nearest Neighbor (K-NN), and Stochastic Gradient Descent (SGD) for Classifying Corn Leaf Disease based on Histogram of Oriented Gradients (HOG) Feature Extraction. *Elinvo (Electronics, Informatics, and Vocational Education)*, 8(1), 121–129. <https://doi.org/10.21831/elinvo.v8i1.55759>