

ANALISIS PERFORMA CAPSULE NETWORK (CAPSNET) DALAM KLASIFIKASI SAMPAH ORGANIK DAN ANORGANIK

Muhammad Arif, Tri Aristi Saputri

Teknik Informatika, Universitas Dharma Wacana
Jl. Kenanga No.3, Mulyojati, Kec. Metro Barat, Kota Metro, Lampung
arifdharmawacana@gmail.com

ABSTRAK

Pengelolaan sampah memerlukan teknologi pemisahan otomatis yang akurat untuk mendukung proses daur ulang. Namun, algoritme *Convolutional Neural Network* (CNN) tradisional memiliki keterbatasan dalam memahami hubungan spasial objek akibat rotasi atau kondisi yang tumpang tindih. Penelitian ini bertujuan menerapkan arsitektur *Capsule Network* (CapsNet) untuk meningkatkan akurasi klasifikasi sampah organik dan anorganik secara dinamis. Metode penelitian menggunakan dataset sekunder sebanyak 5.000 citra dari Kaggle yang diproses dengan mekanisme *Dynamic Routing* (3 iterasi), fungsi aktivasi *Squash*, dan optimasi *Label Smoothing* 0.1. Hasil evaluasi menunjukkan model CapsNet mencapai akurasi 81,20% pada data uji. Secara spesifik, model memiliki responsivitas tinggi pada limbah organik dengan *Recall* 0,8440 dan *Precision* 0,8333 pada kategori anorganik. Meskipun terdapat kesalahan klasifikasi sebesar 18,80% akibat ambiguitas tekstur dan *noise* latar belakang, penelitian ini menyimpulkan bahwa CapsNet efektif dalam mempertahankan informasi hierarki spasial untuk klasifikasi objek limbah yang bervariasi.

Kata kunci : *Capsule Network*, Klasifikasi Sampah, Organik, Anorganik, *Deep Learning*.

1. PENDAHULUAN

Masalah pengelolaan sampah di Indonesia saat ini berada pada kondisi yang sangat krusial, di mana penumpukan limbah rumah tangga maupun industri yang tidak terkelola dengan baik berdampak signifikan terhadap kerusakan ekosistem [1]. Praktik pengelolaan tradisional yang hanya mengandalkan pemindahan sampah ke Tempat Pembuangan Sementara (TPS) tanpa adanya pemilahan di sumbernya justru memicu timbulnya persoalan lingkungan baru [2]. Keterbatasan fasilitas wadah sampah yang ada saat ini, yang belum dilengkapi dengan sistem pemisahan otomatis, menyebabkan limbah organik dan anorganik tercampur, sehingga menurunkan efektivitas proses daur ulang secara drastis [3]. Oleh karena itu, diperlukan inovasi berupa solusi pemisahan otomatis berbasis teknologi pengolahan citra digital yang mampu mendeteksi jenis limbah secara cepat dan akurat [4].

Beberapa upaya penelitian sebelumnya telah mencoba menerapkan teknologi *Computer Vision* dan *Machine Learning*, seperti penggunaan *Support Vector Machine* (SVM) yang dikombinasikan dengan ekstraksi fitur GLCM [1]. Namun, algoritma konvensional tersebut sering kali kesulitan beradaptasi dengan variasi bentuk objek dan latar belakang citra yang kompleks, sehingga mendorong penggunaan *Deep Learning* untuk performa yang lebih optimal [5]. Meskipun arsitektur *Convolutional Neural Network* (CNN) telah menunjukkan efisiensi tinggi dengan akurasi di atas 90%, arsitektur ini memiliki kelemahan mendasar dalam mempertahankan informasi spasial hierarkis akibat operasi *pooling* yang agresif [6], [7]. Hal ini menyebabkan hilangnya detail krusial saat objek mengalami perubahan posisi, rotasi, atau kondisi tumpang tindih [8], [9].

Penelitian ini bertujuan untuk melakukan analisis mendalam terhadap kinerja arsitektur *Capsule Network* (CapsNet) dalam melakukan klasifikasi biner pada citra sampah. Selain itu, studi ini dimaksudkan untuk mengevaluasi sejauh mana keandalan algoritma tersebut dalam mengenali objek secara dinamis serta mempertahankan hubungan spasial antar komponen objek dibandingkan dengan metode konvensional [10].

Sebagai solusi atas keterbatasan CNN, penelitian ini mengusulkan penerapan arsitektur *Capsule Network* (CapsNet) yang menggunakan mekanisme *routing* dinamis dan representasi vektor [11]. Model akan dilatih dan dievaluasi menggunakan dataset sekunder dari Kaggle yang terdiri dari 5.000 citra sampah dengan resolusi 128x128 piksel [12]. Strategi penyelesaian mencakup penerapan teknik augmentasi data, optimasi *Early Stopping*, serta penggunaan fungsi aktivasi *Squash* dengan *Label Smoothing* sebesar 0.1 untuk meningkatkan kemampuan generalisasi model terhadap variasi data sampah rumah tangga yang beragam [13].

2. TINJAUAN PUSTAKA

2.1. Prinsip Dasar dan Klasifikasi Sampah

Limbah dipahami sebagai sisa-sisa dari aktivitas manusia atau proses alami yang tidak lagi memiliki kegunaan dan dapat mencemari lingkungan jika tidak ditangani dengan tepat [10]. Proses pengelolaan yang ideal seharusnya dimulai dengan pemisahan limbah di tingkat rumah tangga untuk membedakan antara limbah organik yang dapat terurai dengan yang membutuhkan proses daur ulang khusus atau anorganik [7]. Namun, kurangnya disiplin dan keterbatasan dalam sistem pemisahan konvensional menyebabkan kedua jenis limbah ini sering kali

tercecer di Tempat Pembuangan Akhir [2]. Oleh karena itu, penerapan teknologi otomatisasi yang memanfaatkan sistem *computer vision* sangat penting untuk mempercepat deteksi dan klasifikasi limbah berdasarkan ciri-ciri visualnya [4].

2.2. Teknologi Pengolahan Citra dan Evolusi Algoritma

Pengolahan gambar digital merujuk pada teknik untuk mengubah data spasial yang ada dalam piksel gambar demi mengidentifikasi ciri-ciri tertentu seperti warna dan pola [4]. Klasifikasi yang memanfaatkan fitur GLCM dan *Color Moments* pada model *Support Vector Machine* (SVM) telah menunjukkan perkembangan dalam mengenali limbah [1]. Namun, metode tradisional yang bergantung pada ekstraksi manual sering mengalami penurunan akurasi saat menghadapi perubahan posisi dan pencahayaan, yang mendorong peralihan kepada arsitektur *Deep Learning* [5]. Dalam ranah ini, *Convolutional Neural Network* (CNN) merupakan algoritma yang paling sering dipakai karena kemampuannya mengidentifikasi fitur secara bertahap [14]. Meski efisien, CNN memiliki keterbatasan bawaan akibat proses *max pooling* yang mengabaikan hubungan spasial, sehingga kinerjanya menurun saat berhadapan dengan rotasi ekstrem [9].

2.3. Arsitektur Capsule Network (CapsNet)

Untuk mengatasi isu hilangnya informasi posisi, CapsNet diperkenalkan dengan menggantikan elemen skalar dengan vektor yang disebut kapsul [15]. CapsNet mampu mempertahankan hubungan orientasi fitur melalui mekanisme *Dynamic Routing*. Mekanisme ini menetapkan informasi mana yang harus dikirim ke lapisan lebih tinggi berdasarkan prinsip kecocokan prediksi, memungkinkan model mengenali struktur hierarki objek secara menyeluruh [8]. Dalam desainnya, fungsi aktivasi *Squashing* digunakan untuk menekan ukuran vektor ke rentang [0, 1] tanpa mengubah orientasinya, yang krusial untuk konsistensi representasi fitur spasial [11]. Sifat *equivariance* pada CapsNet memungkinkannya mencapai generalisasi yang lebih baik karena pemahaman mendalam mengenai hubungan spasial objek yang tidak teratur seperti sampah [8], [9].

2.4. Evaluasi dan Metrik Kinerja

Prapemrosesan citra seperti *resizing* menjadi 128x128 piksel dan normalisasi dilakukan untuk memastikan kestabilan pelatihan [16]. Teknik augmentasi seperti rotasi 30 derajat dan *horizontal flip* membantu model tangguh menghadapi situasi nyata [16]. Dalam evaluasi, digunakan *Confusion Matrix* sebagai alat utama untuk menghitung metrik Akurasi, Presisi, *Recall*, dan *F1-Score* [16]. Penerapan *Binary Crossentropy* dengan *Label Smoothing* 0.1 juga dilakukan untuk meningkatkan kemampuan generalisasi model pada data yang ambigu [10].

2.5. Penelitian Sebelumnya

Sejumlah penelitian terdahulu telah mengeksplorasi penggunaan teknologi untuk klasifikasi limbah dengan berbagai pendekatan. [16] melakukan penelitian mengenai pra-pemrosesan gambar menggunakan Roboflow yang berhasil meningkatkan akurasi deteksi model hingga kisaran 86% - 90% melalui teknik augmentasi. Di sisi lain, [6] mengimplementasikan algoritma CNN dengan arsitektur *Transfer Learning Xception* yang mencapai tingkat akurasi sangat tinggi sebesar 96,43%. [10] juga menegaskan bahwa CNN mampu memisahkan jenis sampah dengan ekstraksi fitur secara otomatis. Namun, penelitian oleh [8] menunjukkan bahwa meskipun CNN efisien, arsitektur *Capsule Network* (CapsNet) terbukti lebih tangguh (*robust*) terhadap perubahan posisi dan transformasi affine dibandingkan CNN konvensional.

Meskipun CapsNet memiliki potensi besar, kinerjanya dapat bervariasi tergantung pada objek yang diuji. [9] membandingkan CNN dan CapsNet dalam klasifikasi rumah adat, di mana CNN mengungguli CapsNet dengan akurasi 98% berbanding 72%, menunjukkan bahwa CapsNet mungkin memerlukan optimasi lebih lanjut untuk objek tertentu. Pengembangan CapsNet juga telah merambah ke domain medis, seperti penelitian [11] yang memodifikasi CapsNet dengan blok residual untuk meningkatkan performa deteksi pada gambar medis yang kompleks. Selain itu, [13] menemukan bahwa integrasi teknik segmentasi dapat meningkatkan akurasi dan tingkat keterjelasan (*explainability*) pada model CapsNet. Berbeda dengan penelitian [17] yang berfokus pada pengintegrasian model CNN ke dalam antarmuka web berbasis Flask, penelitian ini sepenuhnya menitikberatkan pada analisis eksperimental algoritma CapsNet. Inovasi dalam penelitian ini terletak pada evaluasi mendalam mengenai kemampuan CapsNet dalam mempertahankan hierarki spasial objek sampah rumah tangga yang tidak beraturan dengan optimasi *Label*

3. METODE PENELITIAN

3.1. Jenis dan Pendekatan Penelitian

Penelitian ini merupakan penelitian kuantitatif yang mengadopsi pendekatan eksperimen laboratorium berbasis komputer. Pendekatan ini dipilih untuk menghitung dan menganalisis parameter kinerja algoritma secara objektif melalui metrik seperti akurasi, presisi, *recall*, dan *f1-score* [13]. Eksperimen dilaksanakan menggunakan simulasi komputer dengan dataset citra digital limbah rumah tangga untuk menguji keandalan arsitektur *Capsule Network* (CapsNet) dalam mengenali pola hierarkis spasial [8]. Lingkungan komputasi berbasis awan menggunakan platform Google Colaboratory dengan bahasa pemrograman Python serta pustaka pendukung seperti TensorFlow, Keras, NumPy, dan Scikit-Learn [14].

3.2. Alur dan Tahapan Penelitian



Gambar 1. Diagram alur penelitian

Tahapan penelitian dimulai dengan identifikasi masalah yang berfokus pada klasifikasi sampah organik dan anorganik rumah tangga, kemudian dilanjutkan dengan studi literatur untuk mendalami kajian *Capsule Network* dan mekanisme *Dynamic Routing*. Proses pengumpulan data citra dilakukan dengan mengunduh dataset dari Kaggle melalui pustaka *kagglehub*, yang diteruskan dengan seleksi dan pelabelan data menggunakan metode *sampling* otomatis sebanyak 2.500 gambar per kelas. Setelah data terkumpul, dilakukan pembentukan dataset melalui penyusunan struktur folder yang sistematis sebelum memasuki tahap pra-proses data yang mencakup normalisasi piksel sebesar 1/255 dan perubahan ukuran citra menjadi 128x128 piksel.

Langkah berikutnya adalah pembagian dataset dengan rasio *split data* sebesar 80% untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian. Data latih kemudian diberikan perlakuan augmentasi berupa penerapan *Rotation* dan *Horizontal Flip* guna meningkatkan variasi data. Perancangan model *Capsule Network* dilakukan dengan mengintegrasikan *Adam Optimizer* dan teknik *Label Smoothing* 0.1, yang dilanjutkan dengan proses pelatihan model selama 30 *epoch* menggunakan fitur *Early Stopping*. Setelah model terlatih, tahap evaluasi dilakukan melalui analisis grafik plot akurasi dan *loss*, serta analisis kesalahan klasifikasi dengan pembuatan *Confusion Matrix* dan *Classification Report*. Tahapan diakhiri dengan uji coba prediksi (*inference*) secara visual pada gambar acak untuk melihat skor probabilitas, hingga penyimpanan hasil penelitian yang mencakup dokumentasi grafik performa dan bobot model [5], [15].

3.3. Data Penelitian dan Pembentukan Dataset

Data yang digunakan adalah data sekunder berupa citra RGB dari repositori Kaggle yang terdiri dari dua kategori biner: Organik (sisir makanan, sayuran, buah) dan Anorganik (botol plastik, kaleng, kaca, kertas). Pembentukan dataset melibatkan proses *resizing* ke dimensi 128x128 piksel, *rescaling* nilai piksel ke rentang [0, 1], serta pemberian label biner (0 untuk anorganik dan 1 untuk organik) untuk mendukung fungsi kerugian *Binary Crossentropy* [14]. Untuk menghindari *overfitting*, metode augmentasi data seperti rotasi maksimal 30 derajat dan *horizontal flip* diterapkan pada data latih [16]. Dataset sebanyak 5.000 citra dibagi secara tidak bias dengan

proporsi 80% (4.000 citra) untuk data latih, 10% (500 citra) untuk data validasi sebagai pemicu *early stopping*, dan 10% (500 citra) untuk data uji sebagai evaluasi akhir.

3.4. Arsitektur Model CapsNet

Struktur model terdiri dari tiga lapisan utama: *Convolutional Layer* (256 filter, kernel 9x9), *Primary Capsules* (vektor 8-dimensi), dan *Digit Capsules* (vektor 16-dimensi). Interaksi antar lapisan memanfaatkan *Dynamic Routing* sebanyak 3 iterasi dan fungsi aktivasi *Squash* untuk menormalkan panjang vektor [11]. Fungsi aktivasi *Squash* didefinisikan sebagai berikut:

$$v_j = \frac{|s_j|^2}{1 + |s_j|^2} \frac{s_j}{|s_j|} \quad (1)$$

Keterangan: v_j adalah vektor output non-linear dari kapsul j dan s_j adalah vektor input keseluruhan. Besaran atau panjang dari vektor v_j dihitung dengan norma Euklidian untuk menggambarkan probabilitas klasifikasi. Pelatihan dijalankan menggunakan GPU T4 dengan *Adam Optimizer* (laju pembelajaran 0.0001) dan *Binary Crossentropy* yang dipadukan dengan *Label Smoothing* 0.1. Strategi optimasi mencakup *Early Stopping* dengan kesabaran 5 epoch dan *ReduceLROnPlateau* (faktor 0.5) untuk menemukan titik minimum global yang lebih halus. Evaluasi metrik kinerja dilakukan secara eksklusif pada data uji menggunakan *Confusion Matrix* untuk menghitung Akurasi, Presisi, Recall, dan *F1-Score*.


4. HASIL DAN PEMBAHASAN

4.1. Implementasi Arsitektur Model

Pada tahap ini, arsitektur *Capsule Network* (CapsNet) diterapkan menggunakan bahasa pemrograman Python dengan memanfaatkan pustaka TensorFlow dan Keras untuk memproses citra sampah rumah tangga. Implementasi dimulai dengan lapisan konvolusi pertama (*Conv2D*) yang menggunakan 256 filter dan ukuran kernel 9x9 untuk mengekstrak ciri dasar dari citra berdimensi 128x128 piksel dengan aktivasi ReLU. Selanjutnya, fitur tersebut diolah oleh *Primary Capsules* menjadi vektor berdimensi 8 dengan fungsi aktivasi *squash* untuk menjaga rentang nilai antara 0 hingga 1. Unsur inti dari model ini adalah kelas *DigitCapsule* yang menjalankan algoritme *dynamic routing* sebanyak tiga iterasi (*routings=3*) untuk mengenali objek meskipun terjadi perubahan posisi dan rotasi. Lapisan terakhir terdiri dari kapsul berukuran 16 yang mewakili peluang kelas, di mana hasil klasifikasi biner ditentukan melalui fungsi norma Euklidian. Seluruh struktur dioptimalkan menggunakan *Adam optimizer* (laju pembelajaran 0.0001) dan fungsi kerugian *Binary Crossentropy* dengan *label smoothing* 0.1 untuk meningkatkan stabilitas serta mencegah *overfitting*. Pelatihan dilakukan pada platform Google Colab dengan akselerasi GPU selama maksimum 30 *epoch*.

4.2. Hasil Pengujian dan Evaluasi

Evaluasi dilakukan secara kuantitatif menggunakan 10% data uji (500 sampel: 250 organik dan 250 anorganik) untuk mengukur kemampuan generalisasi model. Berdasarkan grafik akurasi dan *loss* pada Gambar 4, model menunjukkan perkembangan pembelajaran yang konsisten dengan akurasi validasi di atas 81% dan kerugian validasi yang stabil di bawah 0.50. Hal ini mengonfirmasi efektivitas *label smoothing* dan aktivasi *squash* dalam menjaga kestabilan model.



Gambar 2. Grafik Akurasi dan Loss Pelatihan CapsNet

Pemeriksaan matriks kebingungan pada Gambar 5 menunjukkan bahwa model berhasil memprediksi secara akurat 211 observasi sampah organik dan 195 observasi sampah anorganik dari total 500 data uji. Rincian metrik performa klasifikasi disajikan dalam Tabel 1, yang menunjukkan akurasi total sebesar 81,20%.

Tabel 1. Metrik Evaluasi Klasifikasi

Kelas	Precision	Recall	F1-Score	Support
O (Organik)	7,932	8,440	8,178	250
R (Anorganik)	8,333	7,800	8,058	250
Accuracy			8,120	500
Macro Avg	8,133	8,120	8,118	500

4.3. Pembahasan Hasil Prediksi dan Analisis Kesalahan

Analisis data menunjukkan bahwa CapsNet sangat responsif dalam mendeteksi sampah organik dengan nilai *recall* mencapai 0.8440. Sebaliknya, tingkat presisi lebih tinggi ditemukan pada kategori anorganik (0.8333), yang menandakan tingkat kepastian prediksi yang lebih baik pada kelas tersebut. Melalui evaluasi visual pada Gambar 6, model terbukti sangat meyakinkan dalam mengidentifikasi objek dengan struktur geometris konsisten seperti botol plastik (99,0%) dan limbah organik alami (95,6%).



Gambar 3. Visualisasi Sampel Prediksi CapsNet

Meskipun mencapai akurasi 81,20%, terdapat kesalahan sebesar 18,80% (94 citra). Faktor penyebab utama kesalahan meliputi ambiguitas tekstur, di mana objek organik dengan potongan rapi sering disalahpahami sebagai anorganik, serta kompleksitas latar belakang (*noise*) yang memengaruhi ekstraksi fitur awal. Selain itu, variasi pencahayaan dan oklusi (penumpukan objek) menyulitkan algoritme *dynamic routing* dalam mencapai konsensus vektor yang tepat. Hasil ini memberikan landasan untuk penelitian masa depan guna menerapkan teknik segmentasi objek sebelum citra dimasukkan ke dalam jaringan kapsul.

5. KESIMPULAN DAN SARAN

Penelitian ini menyimpulkan bahwa implementasi model *Capsule Network* (CapsNet) berhasil mencapai akurasi sebesar 81,20% pada data uji melalui mekanisme *Dynamic Routing* dan aktivasi *squash* yang efektif mempertahankan informasi spasial objek, meskipun masih terdapat kendala pada ambiguitas tekstur dan gangguan latar belakang yang menyebabkan kesalahan klasifikasi pada 94 sampel citra. Sebagai langkah pengembangan, disarankan untuk melakukan optimalisasi arsitektur melalui eksplorasi *EM Routing*, pengayaan dataset dengan augmentasi pencahayaan yang lebih intensif, serta integrasi teknik pra-pemrosesan seperti *background removal* guna meningkatkan presisi dan mengurangi interferensi bising lingkungan pada proses ekstraksi fitur.

DAFTAR PUSTAKA

- [1] I. Z. Nisa, S. N. Endah, P. S. Sasongko, R. Kusumaningrum, K. Khadijah, dan R. Rismiyati, "Klasifikasi Citra Sampah Menggunakan Support Vector Machine dengan Ekstraksi Fitur Gray Level Co-Occurrence Matrix dan Color Moments," *J. Teknol. Inf. Dan Ilmu Komput.*, vol. 9, no. 5, hlm. 921–930, Okt 2022, doi: 10.25126/jtiik.2022954868.
- [2] J. Wong, "Aplikasi Klasifikasi Sampah Organik dan Non Organik dengan Metode GLCM Dan LS-SVM," *Bull. Comput. Sci. Res.*, vol. 3, no. 1, hlm. 83–89, Des 2022, doi: 10.47065/bulletincsr.v3i1.198.
- [3] I. Ismail, A. Z. Nusri, dan S. Rahman, "Sistem Smart Trash Pemilah Sampah Organik dan Anorganik Berbasis Internet of Things," *J. SAINTEKOM*, vol. 13, no. 2, hlm. 193–201, Sep 2023, doi: 10.33020/saintekom.v13i2.487.
- [4] R. N. J. S.Intam, A. Raihan, M. Alfajri, A. B. Kaswar, D. D. Andayani, dan Asnidar, "Sistem Klasifikasi Jenis Sampah Berdasarkan Kombinasi Fitur Warnac Tekstur Menggunakan Artificial Neural Network Berbasis Pengolahan Citra Digital," *J. Teknol. Inf. Dan Ilmu Komput.*, vol. 11, no. 2, hlm. 411–420, Agu 2024, doi: 10.25126/jtiik.20241128330.
- [5] A. Ikhlas dan B. Hendrik, "Literature Review: Studi Komparasi Klasifikasi Sampah

- menggunakan Algoritma Deep Learning,” vol. 14.
- [6] M. Muslihati, S. Sahibu, dan I. Taufik, “Implementasi Algoritma Convolutional Neural Network untuk Klasifikasi Jenis Sampah Organik dan Non Organik: Implementation of the Convolutional Neural Network Algorithm for Classifying Types of Organic and Non-Organic Waste,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 3, hlm. 840–852, Mei 2024, doi: 10.57152/malcom.v4i3.1346.
- [7] D. Sadida Aulia, H. Arwoko, dan E. Asmawati, “Klasifikasi Sampah Rumah Tangga Menggunakan Metode Convolutional Neural Network,” *METIK J.*, vol. 8, no. 2, hlm. 114–120, Des 2024, doi: 10.47002/metik.v8i2.956.
- [8] A. Marchisio, A. D. Marco, A. Colucci, M. Martina, dan M. Shafique, “RobCaps: Evaluating the Robustness of Capsule Networks against Affine Transformations and Adversarial Attacks,” 25 April 2023, *arXiv: arXiv:2304.03973*. doi: 10.48550/arXiv.2304.03973.
- [9] Y. F. Riti, Y. Wahyuningsih, J. Roosandriantini, dan P. W. Siswanto, “Perbandingan Algoritma Convolutional Neural Netwok dan Capsule Network Dalam Klasifikasi Jenis Rumah Adat,” *Teknika*, vol. 12, no. 3, hlm. 243–251, Nov 2023, doi: 10.34148/teknika.v12i3.702.
- [10] A. Ibnul Rasidi, Y. A. H. Pasaribu, A. Ziqri, dan F. D. Adhinata, “Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network,” *J. Tek. Inform. Dan Sist. Inf.*, vol. 8, no. 1, Apr 2022, doi: 10.28932/jutisi.v8i1.4314.
- [11] S. B. Şengül dan İ. A. Özkan, “MResCaps: Enhancing capsule networks with parallel lanes and residual blocks for high-performance medical image classification,” *Int. J. Imaging Syst. Technol.*, vol. 34, no. 4, hlm. e23108, Jul 2024, doi: 10.1002/ima.23108.
- [12] M. Farhan, M. F. Aditiya, D. I. Shafa, dan A. Halim, “Classification of Organic and Non-Organic Waste Using Convolutional Neural Network (CNN),” vol. 2, no. 2, 2025.
- [13] D. Vranay, M. Hliboký, L. Kovács, dan P. Sinčák, “Using Segmentation to Boost Classification Performance and Explainability in CapsNets,” *Mach. Learn. Knowl. Extr.*, vol. 6, no. 3, hlm. 1439–1465, Jun 2024, doi: 10.3390/make6030068.
- [14] G. Aprisia Bahagia dan M. Akbar, “KLASIFIKASI SAMPAH ORGANIK DAN ANORGANIK MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN),” *JATI J. Mhs. Tek. Inform.*, vol. 8, no. 5, hlm. 10349–10355, Sep 2024, doi: 10.36040/jati.v8i5.11038.
- [15] F. Fatharani, K. P. Kania, J. Hutahaeen, dan S. R. Wulan, “Deteksi Intensi Chatbot Berbahasa Indonesia dengan Menggunakan Metode Capsule Network,” *J. Inf. Syst. Res. JOSH*, vol. 3, no. 4, hlm. 590–596, Jul 2022, doi: 10.47065/josh.v3i4.1821.
- [16] T. Mulia, M. Kallista, dan I. P. D. Wibawa, “Preprocessing Gambar Sampah untuk Sistem Pemilah Sampah Otomatis menggunakan Roboflow”.
- [17] M. R. Fazryansah, A. P. Pambudi, A. R. Kurniadi, A. P. Supriyadi, Y. A. Saputra, dan U. Latifa, “SISTEM KLASIFIKASI SAMPAH ORGANIK & NON ORGANIK MENGGUNAKAN CNN BERBASIS FRAMEWORK FLASK,” *J. Inform. Dan Tek. Elektro Terap.*, vol. 13, no. 3, Jul 2025, doi: 10.23960/jitet.v13i3.6706.