

Klasifikasi Sampah Multi-Kelas Berbasis Deep Learning Menggunakan Model VGG16

Vina Ayumi

Fakultas Teknik dan Informatika, Universitas Dian Nusantara, Indonesia
vina.ayumi@dosen.undira.ac.id

Article Info

Article history:

Received, 2026-01-09

Revised, 2026-01-29

Accepted, 2026-01-30

Kata Kunci:

klasifikasi sampah,
deep learning,
convolutional neural network,
VGG16,
transfer learning.

ABSTRAK

Proses pemilahan sampah secara manual masih menghadapi berbagai kendala, seperti rendahnya efisiensi dan potensi kesalahan klasifikasi. Penelitian ini bertujuan untuk mengimplementasikan dan menganalisis kinerja model VGG16 berbasis deep learning dalam melakukan klasifikasi sampah multi-kelas menggunakan citra digital. Dataset yang digunakan terdiri dari enam kelas sampah, yaitu kardus, kaca, logam, kertas, plastik, dan sampah residu, dengan jumlah citra awal yang tidak seimbang. Untuk mengatasi permasalahan tersebut, dilakukan augmentasi data hingga setiap kelas memiliki 500 citra. Dataset kemudian dibagi menjadi data latih sebesar 70%, data validasi 15%, dan data uji 15%. Eksperimen dilakukan menggunakan pendekatan transfer learning dengan memvariasikan parameter pelatihan, yaitu optimizer RMSProp, Adam, dan Stochastic Gradient Descent (SGD) serta batch size 16, 32, dan 64. Kinerja model dievaluasi menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*. Hasil penelitian menunjukkan bahwa pemilihan parameter pelatihan berpengaruh signifikan terhadap performa model. Konfigurasi terbaik diperoleh pada model VGG16 dengan *optimizer Adam* dan batch size 16, yang menghasilkan akurasi pengujian tertinggi sebesar 85,87%. Penelitian ini diharapkan dapat menjadi dasar pengembangan sistem pemilahan sampah otomatis berbasis visi komputer.

ABSTRACT

Keywords:

waste classification,
deep learning,
convolutional neural network,
VGG16,
transfer learning

The manual waste sorting process has faced various challenges, such as low efficiency and a high potential for classification errors. This study aimed to implement and analyze the performance of a deep learning-based VGG16 model for multi-class waste classification using digital images. The dataset used consisted of six waste classes, namely cardboard, glass, metal, paper, plastic, and residual waste, with an imbalanced initial number of images. To address this issue, data augmentation was performed so that each class contained 500 images. The dataset was then divided into 70% training data, 15% validation data, and 15% testing data. The experiments were conducted using a transfer learning approach by varying training parameters, including the RMSProp, Adam, and Stochastic Gradient Descent (SGD) optimizers, as well as batch sizes of 16, 32, and 64. Model performance was evaluated using accuracy, precision, recall, and F1-score metrics. The results showed that the selection of training parameters significantly affected model performance. The best configuration was achieved using the VGG16 model with the Adam optimizer and a batch size of 16, which produced the highest testing accuracy of 85.87%. This study was expected to serve as a foundation for the development of automated computer vision-based waste sorting systems.

This is an open access article under the CC BY-SA license.



Penulis Korespondensi:

Vina Ayumi,
Fakultas Teknik dan Informatika,
Universitas Dian Nusantara, Indonesia
Email: vina.ayumi@dosen.undira.ac.id

1. PENDAHULUAN

Permasalahan sampah menjadi isu global yang terus meningkat seiring dengan pertumbuhan populasi dan aktivitas konsumsi masyarakat. Peningkatan volume sampah yang tidak diimbangi dengan sistem pengelolaan yang efektif dapat menimbulkan dampak serius terhadap lingkungan, kesehatan, dan keberlanjutan ekosistem. Salah satu tantangan utama dalam pengelolaan sampah adalah proses pemilahan yang masih banyak dilakukan secara manual, sehingga memerlukan waktu, tenaga, dan biaya yang besar serta berpotensi menimbulkan kesalahan klasifikasi [1], [2], [3], [4].

Pemilahan sampah berdasarkan jenis material, seperti kaca, logam, kertas, plastik, kardus, dan sampah residu, merupakan tahap krusial dalam mendukung proses daur ulang dan pengurangan limbah. Namun, karakteristik visual antar jenis sampah sering kali memiliki kemiripan, seperti warna, tekstur, dan bentuk, yang menyulitkan proses identifikasi secara konvensional. Kondisi ini mendorong perlunya pemanfaatan teknologi berbasis kecerdasan buatan untuk meningkatkan akurasi dan efisiensi klasifikasi sampah [2], [5], [6], [7], [8].

Perkembangan teknologi *deep learning*, khususnya Convolutional Neural Network (CNN), telah menunjukkan kinerja yang unggul dalam pengolahan dan pengenalan citra digital. CNN mampu mengekstraksi fitur secara otomatis dari citra tanpa memerlukan rekayasa fitur manual, sehingga cocok diterapkan pada permasalahan klasifikasi citra kompleks. Berbagai penelitian sebelumnya membuktikan bahwa model CNN dapat digunakan secara efektif untuk klasifikasi objek, termasuk dalam konteks pengelolaan sampah berbasis citra.

Berbagai penelitian telah dilakukan untuk mengatasi permasalahan klasifikasi sampah dengan memanfaatkan metode *Convolutional Neural Network* (CNN). Penelitian oleh Rasidi et al. (2022) mengklasifikasikan sampah ke dalam kategori organik dan non-organik menggunakan CNN. Hasil penelitian menunjukkan bahwa model CNN mampu memberikan akurasi yang baik untuk mendukung proses pemilahan sampah otomatis, khususnya dalam tahap awal daur ulang [9].

Kurniawan et al. (2023) mengimplementasikan arsitektur *Xception* untuk klasifikasi sampah anorganik. Penelitian ini menekankan bahwa sampah anorganik memiliki karakteristik visual yang kompleks, sehingga diperlukan model *deep learning*. Hasil pengujian menunjukkan bahwa arsitektur *Xception* mampu menghasilkan performa yang baik dalam mengenali jenis sampah anorganik yang berpotensi untuk didaur ulang dan memiliki nilai ekonomi [10].

Selanjutnya, Bintang dan Azhar (2024) mengkaji penggunaan *data augmentation* pada model Inception-V3 untuk klasifikasi sampah organik dan non-organik. Penelitian ini menunjukkan bahwa teknik augmentasi data dapat meningkatkan generalisasi model, terutama ketika jumlah dataset terbatas. Pendekatan transfer learning pada Inception-V3 dapat mengenali perbedaan antar kelas sampah [11].

Penelitian lain oleh Bahagia dan Akbar (2024) menerapkan metode CNN konvensional untuk klasifikasi sampah organik dan anorganik. Fokus utama penelitian ini adalah pengembangan sistem klasifikasi berbasis citra yang sederhana namun efektif untuk tugas pengenalan sampah. Hasil penelitian membuktikan bahwa CNN tetap mampu memberikan performa yang baik meskipun menggunakan arsitektur yang relatif lebih ringan [12].

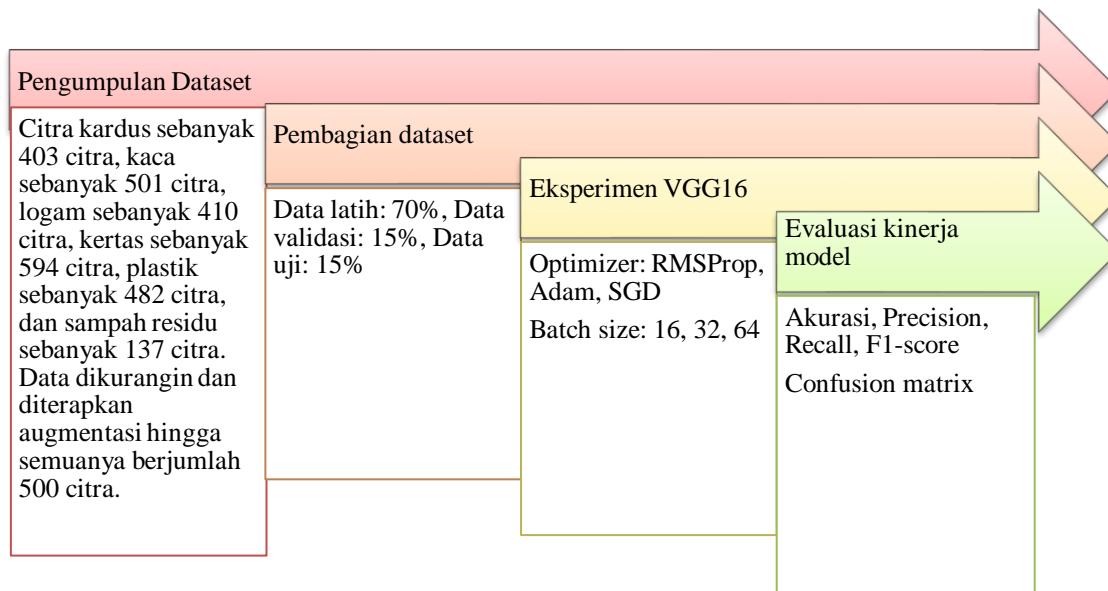
Salah satu arsitektur CNN yang banyak digunakan adalah VGG16, yang dikenal memiliki struktur sederhana namun mampu menghasilkan performa yang tinggi dalam tugas klasifikasi citra. Dengan memanfaatkan pendekatan *transfer learning*, model VGG16 dapat dilatih ulang pada dataset khusus dengan jumlah data yang relatif terbatas, sehingga menghemat waktu komputasi dan meningkatkan stabilitas pembelajaran. Penggunaan *optimizer Adam* juga berperan penting dalam mempercepat konvergensi dan meningkatkan kinerja model selama proses pelatihan [13], [14], [15], [16].

Pada penelitian ini, digunakan dataset citra sampah multi-kelas yang terdiri dari enam kategori, yaitu kardus sebanyak 403 citra, kaca sebanyak 501 citra, logam sebanyak 410 citra, kertas sebanyak 594 citra, plastik sebanyak 482 citra, dan sampah residu sebanyak 137 citra. Dataset yang tidak sepenuhnya seimbang antar kelas menjadi tantangan tersendiri dalam proses klasifikasi, sehingga diperlukan pemilihan arsitektur model dan parameter pelatihan yang tepat, termasuk penggunaan batch size 32, untuk memperoleh hasil klasifikasi yang optimal. Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi kinerja model VGG16 dalam melakukan klasifikasi sampah multi-kelas berbasis citra digital.

2. METODE PENELITIAN

Penelitian ini diawali dengan pengumpulan dataset citra sampah yang terdiri dari enam kelas, yaitu kardus sebanyak 403 citra, kaca 501 citra, logam 410 citra, kertas 594 citra, plastik 482 citra, dan sampah residu 137 citra. Dataset kemudian dibagi menjadi data latih sebesar 70%, data validasi 15%, dan data uji 15% untuk memastikan proses pelatihan dan pengujian model berjalan secara proporsional. Eksperimen dilakukan

menggunakan arsitektur VGG16 dengan variasi optimizer RMSProp, Adam, dan SGD serta batch size 16, 32, dan 64 untuk memperoleh konfigurasi terbaik. Tahap penelitian dapat dilihat pada **Gambar 1**.



Gambar 1 Tahap Penelitian

Dataset yang digunakan dalam penelitian ini adalah citra sampah yang terdiri dari enam kelas, yaitu kardus sebanyak 403 citra, kaca 501 citra, logam 410 citra, kertas 594 citra, plastik 482 citra, dan sampah residu 137 citra [17]. Dataset yang digunakan dalam penelitian ini berupa citra sampah yang terdiri dari enam kelas, yaitu kardus, kaca, logam, kertas, plastik, dan sampah residu. Jumlah citra awal pada setiap kelas tidak seimbang, dengan kardus sebanyak 403 citra, kaca 501 citra, logam 410 citra, kertas 594 citra, plastik 482 citra, dan sampah residu 137 citra. Untuk mengatasi permasalahan ketidakseimbangan data (*class imbalance*) yang dapat memengaruhi kinerja model, dilakukan proses augmentasi data pada setiap kelas hingga masing-masing berjumlah 500 citra. Teknik *augmentasi* yang digunakan yaitu rotasi, *flipping*, *zooming* dan *shifting*.

Setelah proses augmentasi, dataset dibagi menjadi tiga bagian, yaitu data latih (*training data*) sebesar 70%, data validasi (*validation data*) sebesar 15%, dan data uji (*testing data*) sebesar 15%. Pembagian ini bertujuan untuk memastikan bahwa model dapat dilatih secara optimal, divalidasi selama proses pembelajaran, serta diuji menggunakan data yang belum pernah dilihat sebelumnya. Data latih digunakan untuk memperbarui bobot model, data validasi berfungsi untuk memantau performa model dan mencegah *overfitting*, sedangkan data uji digunakan untuk mengevaluasi kemampuan generalisasi model.

Eksperimen dilakukan dengan menerapkan arsitektur VGG16 yang merupakan salah satu *model Convolutional Neural Network* (CNN) populer dalam klasifikasi citra. Model VGG16 digunakan dengan pendekatan *transfer learning*, di mana bobot awal diambil dari hasil pelatihan pada *dataset ImageNet*. Pada penelitian ini, dilakukan pengujian terhadap beberapa konfigurasi parameter pelatihan, khususnya variasi *optimizer* dan *batch size*. *Optimizer* yang digunakan meliputi RMSProp, Adam, dan *Stochastic Gradient Descent* (SGD) untuk mengetahui pengaruh masing-masing algoritma optimasi terhadap kecepatan konvergensi dan akurasi model. Selain itu, *batch size* divariasikan menjadi 16, 32, dan 64 guna menganalisis pengaruh jumlah sampel dalam satu iterasi pelatihan terhadap stabilitas dan performa model.

Kinerja model dievaluasi menggunakan beberapa metrik evaluasi yang umum digunakan dalam klasifikasi multi-kelas, yaitu akurasi, *precision*, *recall*, dan *F1-score*. Akurasi digunakan untuk mengukur persentase prediksi yang benar secara keseluruhan, sementara *precision* dan *recall* memberikan gambaran yang mengenai kemampuan model dalam mengklasifikasikan setiap kelas sampah.

3. HASIL DAN ANALISIS

Pada tahap eksperimen ini, model VGG16 dilatih menggunakan batch size 16 untuk menganalisis pengaruh berbagai optimizer terhadap kinerja klasifikasi sampah multi-kelas. Batch size 16 dipilih karena mampu memberikan pembaruan bobot yang lebih sering, sehingga berpotensi meningkatkan kemampuan model dalam mempelajari fitur-fitur detail dari citra sampah. Hasil eksperimen akurasi model VGG16 dengan batch size 16 dilihat pada **Tabel 1**.

Tabel 1 Hasil Akurasi Model VGG16 dengan *Batch Size* 16

No	Optimizer	Batch Size	Akurasi Pelatihan (%)	Akurasi Validasi (%)	Akurasi Pengujian (%)
1	RMSProp	16	89,85	83,72	82,64
2	Adam	16	91,32	86,45	85,87
3	SGD	16	85,76	79,13	78,05

Berdasarkan hasil pengujian, model VGG16 dengan batch size 16 dapat melakukan klasifikasi sampah multi-kelas dengan tingkat akurasi yang cukup baik pada seluruh *optimizer* yang digunakan. Perbedaan nilai akurasi pada tahap pelatihan, validasi, dan pengujian menunjukkan bahwa pemilihan *optimizer* berpengaruh signifikan terhadap kemampuan model dalam mempelajari serta menggeneralisasi fitur citra sampah. *Optimizer Adam* memberikan performa terbaik dengan akurasi pelatihan sebesar 91,32%, validasi 86,45%, dan pengujian 85,87%, yang mengindikasikan kemampuan konvergensi yang cepat dan generalisasi yang baik dalam mengenali berbagai jenis sampah seperti kardus, kaca, logam, kertas, plastik, dan sampah residu pada data yang belum pernah dilatih.

Optimizer RMSProp menunjukkan kinerja menengah dengan akurasi pelatihan 89,85%, validasi 83,72%, dan pengujian 82,64%, menandakan stabilitas pelatihan yang cukup baik namun dengan kemampuan generalisasi yang masih di bawah Adam. Sementara itu, *optimizer SGD* menghasilkan akurasi terendah, yaitu 85,76% pada pelatihan, 79,13% pada validasi, dan 78,05% pada pengujian, yang menunjukkan laju konvergensi lebih lambat dan kebutuhan pengaturan parameter tambahan agar performa model dapat ditingkatkan. Untuk hasil eksperimen akurasi model VGG16 dengan batch size 32 dilihat pada **Tabel 2**.

Tabel 2 Hasil Akurasi Model VGG16 dengan *Batch Size* 32

No	Optimizer	Batch Size	Akurasi Pelatihan (%)	Akurasi Validasi (%)	Akurasi Pengujian (%)
1	RMSProp	32	87,64	81,93	80,72
2	Adam	32	89,85	85,27	84,64
3	SGD	32	84,42	78,36	77,18

Berdasarkan hasil pengujian pada Tabel 2, penggunaan batch size 32 pada model VGG16 menunjukkan peningkatan stabilitas pelatihan dan kemampuan generalisasi dibandingkan *batch size* yang lebih kecil. Hal ini terlihat dari perbedaan nilai akurasi pelatihan, validasi, dan pengujian yang relatif seimbang pada seluruh *optimizer*. *Optimizer Adam* kembali menghasilkan performa terbaik dengan akurasi pelatihan sebesar 89,85%, validasi 85,27%, dan pengujian 84,64%, yang mengindikasikan bahwa ukuran *batch* yang lebih besar membantu model dalam mempelajari representasi fitur citra sampah secara lebih konsisten.

Optimizer RMSProp menunjukkan kinerja menengah dengan akurasi pengujian sebesar 80,72%, sementara SGD menghasilkan performa terendah dengan akurasi pengujian 77,18%. Meskipun demikian, seluruh *optimizer* mengalami peningkatan dibandingkan konfigurasi *batch size* 16, yang menunjukkan bahwa *batch size* 32 memberikan keseimbangan yang lebih baik antara kecepatan konvergensi dan akurasi. Secara keseluruhan, hasil ini menegaskan bahwa kombinasi VGG16 dengan *optimizer Adam* dan *batch size* 32 merupakan konfigurasi yang efektif untuk klasifikasi sampah multi-kelas. Untuk hasil eksperimen akurasi model VGG16 dengan batch size 64 dilihat pada **Tabel 3**.

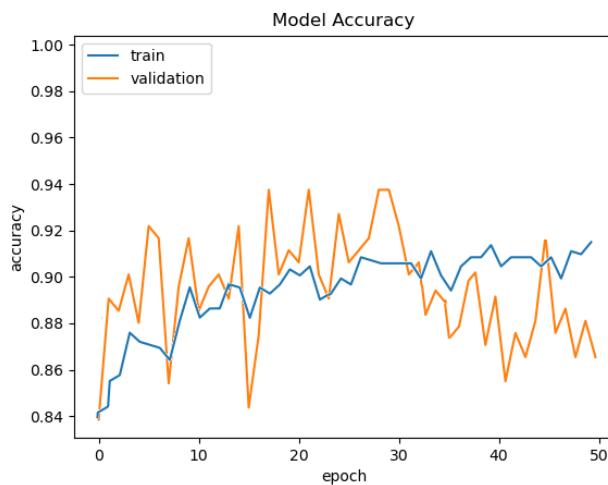
Tabel 3 Hasil Akurasi Model VGG16 dengan *Batch Size* 64

No	Optimizer	Batch Size	Akurasi Pelatihan (%)	Akurasi Validasi (%)	Akurasi Pengujian (%)
1	RMSProp	64	80,14	79,06	80,14
2	Adam	64	83,58	82,91	83,58
3	SGD	64	76,21	75,03	76,21

Berdasarkan, penggunaan batch size 64 pada model VGG16 menunjukkan penurunan kinerja dibandingkan *batch size* 16 dan 32 pada seluruh optimizer. *Optimizer Adam* tetap memberikan performa terbaik dengan akurasi pengujian sebesar 82,91%, diikuti oleh RMSProp sebesar 79,06% dan SGD sebesar 75,03%. Penurunan akurasi ini mengindikasikan bahwa ukuran batch yang terlalu besar mengurangi frekuensi pembaruan bobot, sehingga model kurang optimal dalam menangkap variasi fitur citra sampah yang kompleks. Meskipun batch size 64 mampu memberikan pelatihan yang lebih stabil, hasil ini menunjukkan bahwa konfigurasi tersebut

kurang efektif untuk klasifikasi sampah multi-kelas, dan menguatkan bahwa *batch size* menengah dengan optimizer adaptif lebih sesuai untuk mencapai kinerja optimal.

Berdasarkan hasil eksperimen, parameter dengan akurasi tertinggi diperoleh pada model VGG16 menggunakan *optimizer Adam* dengan *batch size* 16, yang menghasilkan akurasi pengujian sebesar 85,87%, lebih tinggi dibandingkan konfigurasi *batch size* 32 dan 64. Hal ini menunjukkan bahwa *batch size* yang lebih kecil memungkinkan pembaruan bobot yang lebih sering sehingga model mampu mempelajari fitur citra sampah secara lebih detail. *Optimizer Adam* berperan penting dalam meningkatkan kinerja model melalui mekanisme pembelajaran adaptif yang mempercepat konvergensi dan menjaga stabilitas pelatihan. Meskipun *batch size* 32 memberikan pelatihan yang lebih stabil, hasil ini menegaskan bahwa kombinasi Adam dan *batch size* 16 paling optimal dalam memaksimalkan akurasi klasifikasi sampah multi-kelas pada penelitian ini. Hasil akurasi pada tahap pelatihan dan validasi untuk kombinasi *optimizer Adam* dengan *batch size* 16 dapat dilihat pada **Gambar 2**.



Gambar 2 Grafik akurasi *optimizer Adam* dengan *batch size* 16

4. KESIMPULAN

Penelitian ini berhasil mengimplementasikan model VGG16 berbasis transfer learning untuk melakukan klasifikasi sampah multi-kelas yang terdiri dari kardus, kaca, logam, kertas, plastik, dan sampah residu. Proses augmentasi data berhasil mengatasi ketidakseimbangan jumlah citra pada setiap kelas, sehingga model dapat dilatih secara lebih optimal dan memiliki kemampuan generalisasi yang baik. Hasil eksperimen menunjukkan bahwa pemilihan parameter pelatihan, khususnya *optimizer* dan *batch size*, sangat berpengaruh terhadap kinerja klasifikasi citra sampah. Berdasarkan evaluasi terhadap variasi *optimizer* dan *batch size*, diperoleh bahwa *optimizer Adam* dengan *batch size* 16 menghasilkan performa terbaik dengan akurasi pengujian tertinggi sebesar 85,87%. Konfigurasi ini mampu memberikan pembaruan bobot yang lebih sering dan adaptif, sehingga model dapat mempelajari fitur citra sampah secara lebih detail dibandingkan konfigurasi lainnya. Meskipun *batch size* 32 menunjukkan stabilitas pelatihan yang lebih baik, nilai akurasi tertinggi tetap dicapai pada *batch size* 16, sedangkan *batch size* 64 cenderung menurunkan kinerja model.

UCAPAN TERIMA KASIH

Terima kasih kepada Lembaga Riset dan Pengabdian kepada Masyarakat (LRPM) Universitas Dian Nusantara (UNDIR) yang telah mendanai penelitian ini melalui skema penelitian internal. Terima kasih juga kepada Ibu Marissa Utama sudah menyediakan dataset untuk penelitian ini.

REFERENSI

- [1] G. White, C. Cabrera, A. Palade, F. Li, and S. Clarke, “WasteNet: Waste Classification at the Edge for Smart Bins,” *arXiv Prepr. arXiv2006.05873*, 2020.
- [2] M. M. Hossen *et al.*, “A Reliable and Robust Deep Learning Model for Effective Recyclable Waste Classification,” *IEEE Access*, 2024.
- [3] F. S. Alsubaei, F. N. Al-Wesabi, and A. M. Hilal, “Deep learning-based small object detection and classification model for garbage waste management in smart cities and iot environment,” *Appl. Sci.*, vol. 12, no. 5, p. 2281, 2022.
- [4] W.-L. Mao, W.-C. Chen, C.-T. Wang, and Y.-H. Lin, “Recycling waste classification using optimized convolutional neural network,” *Resour. Conserv. Recycl.*, vol. 164, p. 105132, 2021.

- [5] S. A. Wulandari, M. Ma'ruf, A. Priyatno, N. Halimun, Z. M. Abdulah, and U. Amartiwi, "DjunkGo: A Mobile Application for Trash Classification with VGG16 Algorithm," *GMPI Conf. Ser.*, vol. 2, pp. 67–72, 2023, doi: 10.53889/gmpics.v2.175.
- [6] H. M. Tran, T. M. Le, H. V Pham, M. T. Vu, and S. V. T. Dao, "An Integrated Learning Approach for Municipal Solid Waste Classification," *IEEE Access*, 2024.
- [7] J. Li *et al.*, "Automatic Detection and Classification System of Domestic Waste via Multimodel Cascaded Convolutional Neural Network," *IEEE Trans. Ind. Informatics*, vol. 18, no. 1, pp. 163–173, Jan. 2022, doi: 10.1109/TII.2021.3085669.
- [8] A. Kurunayaka, P. Kathriarachchi, and M. Pathirana, "A Study on the Ayurveda Plant Recognition for Remedial Medications Using Image Processing Techniques," 2020.
- [9] A. I. Rasidi, Y. A. H. Pasaribu, A. Ziqri, and F. D. Adhinata, "Klasifikasi sampah organik dan non-organik menggunakan convolutional neural network," *J. Tek. Inform. Dan Sist. Inf.*, vol. 8, no. 1, pp. 142–149, 2022.
- [10] R. Kurniawan, P. B. Wintoro, Y. Mulyani, and M. Komarudin, "Implementasi Arsitektur Xception Pada Model Machine Learning Klasifikasi Sampah Anorganik," *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 2, 2023.
- [11] R. Bintang and Y. Azhar, "Implementasi Data Augmentation untuk Klasifikasi Sampah Organik dan Non Organik Menggunakan Inception-V3," *JISKA (Jurnal Inform. Sunan Kalijaga)*, vol. 9, no. 3, pp. 192–204, 2024.
- [12] G. A. Bahagia and M. Akbar, "Klasifikasi Sampah Organik dan Anorganik menggunakan Metode Convolutional Neural Network (CNN)," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 5, pp. 10349–10355, 2024.
- [13] V. H. Kaya, İ. Akgül, and Ö. Z. TANIR, "IsVoNet8: A Proposed Deep Learning Model for Classification of Some Fish Species," *Tarim Bilim. Dergisi-journal Agric. Sci.*, 2022, doi: 10.15832/ankutbd.1031130.
- [14] N. S. Kumar, T. Niksheta, P. K. Pareek, D. P., R. B. Madhumala, and S. R. Sowmya, "A Novel Transfer Learning Technique for Rice Leaf Disease Detection," pp. 1–7, 2022, doi: 10.1109/ICATIECE56365.2022.10046827.
- [15] Y. Zhang, C. Song, and D. Zhang, "Deep Learning-Based Object Detection Improvement for Tomato Disease," *IEEE Access*, vol. 8, pp. 56607–56614, 2020, doi: 10.1109/ACCESS.2020.2982456.
- [16] N. Tran-Thi-Kim, T. Pham-Viet, I. Koo, V. Y. Mariano, and T. Do-Hong, "Enhancing the Classification Accuracy of Rice Varieties by Using Convolutional Neural Networks," *Int. J. Electr. Electron. Eng. Telecommun.*, pp. 150–160, 2023, doi: 10.18178/ijeetc.12.2.150-160.
- [17] F. Nekouei, "Trash Type Image Dataset," 2022. [Online]. Available: <https://www.kaggle.com/datasets/farzadnekouei/trash-type-image-dataset>