

Deep Learning untuk Sistem Pemilah Sampah Otomatis dengan Algoritma SSD-MobileNet

1st Zulian Wahid
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

zulianwahid@student.telkomuniversity.
ac.id

2nd Meta Kallista
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

metakallista@telkomuniversity.ac.id

3rd Ig. Prasetya Dwi Wibawa
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

prasdwibawa@telkomuniversity.ac.id

Abstrak — Pengelolaan sampah yang efisien dan efektif di lingkungan akademis merupakan hal yang penting untuk menjaga kebersihan dan kelestarian lingkungan. Pengelolaan sampah di Universitas Telkom masih memiliki tantangan, seperti kurangnya pemilahan sampah yang tepat dan keterbatasan fasilitas pendukung. Masalah utama penelitian ini adalah bagaimana mengembangkan sistem pemilahan sampah otomatis yang dapat mengatasi kendala tersebut. Penelitian ini menawarkan solusi dengan mengembangkan sebuah sistem pemilahan sampah otomatis yang menggunakan teknologi sensor dan pemrosesan data untuk memisahkan sampah berdasarkan kategori yang telah ditentukan.

Kata kunci— pengelolaan sampah, sistem otomatis, pemilahan sampah,

I. PENDAHULUAN

Indonesia menghasilkan jutaan ton sampah setiap harinya, menjadikannya salah satu negara penghasil sampah terbanyak di dunia [1]. Kementerian Lingkungan Hidup dan Kehutanan (KLHK), pada tahun 2022 Indonesia telah menghasilkan sedikitnya 36 juta ton timbunan sampah. Dari seluruh sampah tersebut, sebesar 37% tidak dikelola sama sekali, yang berarti sampah tersebut telah mencemari lingkungan. Hasil penelitian lain yang telah dilakukan di beberapa kota di Indonesia tahun 2012 menunjukkan bahwa sampah di Indonesia dikelola dengan berbagai cara sebagai berikut: diangkut dan ditimbun di Tempat Pembuangan Akhir (TPA) (69%), dikubur (10%), dikompos dan didaur ulang (7%), dibakar (5%), dan sisanya tidak dikelola (7%) [3].

Permasalahan ini memerlukan tindakan pengolahan sampah yang baik agar tidak berdampak buruk. Masalah pengelolaan sampah yang tidak efisien juga terjadi di lingkungan akademi, salah satunya di Universitas Telkom. Meskipun di lingkungan universitas sudah disediakan tempat sampah yang ditandai dengan jenis sampah yang dapat dibuang ke dalamnya, masih saja ada sampah yang dibuang tidak sesuai dengan jenisnya. Sampah plastik, kotak makanan berbahan styrofoam, dan kardus seringkali dibuang ke tempat sampah organik, begitu pula sebaliknya, sisa makanan dibuang ke tempat sampah non-organik. Hal ini mengganggu lingkungan universitas, seperti sulitnya mendaur ulang sampah non-organik yang bercampur dengan sisa makanan, serta merusak pemandangan. Selain itu, masalah lain di Universitas Telkom adalah membuang sampah ke tempat sampah yang sudah penuh. Banyaknya civitas yang tidak

bertanggung jawab dengan tetap memaksa untuk memasukkan sampah ke tempat sampah yang sudah penuh mengakibatkan sampah jatuh berserakan di sekitar tempat sampah, bahkan dibuang di luar tempat sampah.

Teknologi deep learning yang sudah berkembang pesat diharapkan dapat membantu permasalahan ini dengan baik. Deep learning dapat membantu untuk membedakan sampah berdasarkan kategori sampah tersebut agar mesin pemilah dapat mengidentifikasi jenis sampahnya. Tujuan dari penggunaan deep learning untuk penelitian ini adalah untuk membuat sistem yang dapat memilah sampah dengan otomatis sehingga pengguna hanya tinggal langsung memasukkan sampah kedalam tempat sampah dan sistem akan memasukan sampah tersebut kedalam tempat sampah yang sesuai dengan jenis sampahnya. Dengan adanya deep learning pada sistem pemilah sampah diharapkan pengelolaan sampah menjadi lebih efisien dan hemat waktu.

II. KAJIAN TEORI

A. Deep learning

Deep learning (DL) adalah subbidang dari machine learning (ML) yang melibatkan penggunaan arsitektur jaringan saraf tiruan (ANN) yang semakin dalam dan kompleks untuk meningkatkan kemampuan pembelajaran. DL memanfaatkan jaringan saraf dalam untuk secara otomatis mempelajari representasi data tanpa memerlukan eksplisitasi aturan atau pengetahuan oleh manusia. Meskipun DL menawarkan manfaat signifikan, seperti kinerja superhuman dalam beberapa aplikasi, implementasinya dalam lingkungan bisnis menghadapi tantangan, termasuk pilihan implementasi yang beragam, bias dan drift dalam data, mitigasi sifat black-box, dan penggunaan kembali model yang telah dikonfigurasi sebelumnya [4].

B. SSD

Metode single shot detection (SSD) menggunakan single deep neural network untuk mengenali atau mendeteksi objek pada suatu gambar secara real time. Salah satu jenis neural networking yang paling umum digunakan untuk data gambar adalah Convolution Neural Network (CNN). Arsitektur CNN terdiri dari dua bagian besar, Feature Extraction Layer dan Convolutional Layer. Tugas Layer Extraction Layer adalah mengencoding fitur dari sebuah gambar menjadi fitur yang mewakili gambar. Namun, neuron di bagian Convolutional Layer tersusun sedemikian rupa sehingga membentuk filter dengan panjang dan tinggi (pixels) [5].

C. MobileNet

Deep convolutional layer menjadi lapisan dasar jaringan MobileNet. Hal ini dapat mengoptimalkan *delay* dengan mempertimbangkan ukuran model. Mobilenet menggunakan konvolusi yang dapat dipisahkan secara mendalam untuk membangun jaringan saraf dalam yang lebih ringan dan dapat meningkatkan kecepatan deteksi. Kecepatan deteksi mobile dapat ditingkatkan secara efektif dengan menggabungkan algoritma MobileNet dan SSD [6].

D. TFLite

TensorFlow Lite (TFLite) adalah versi ringan dari TensorFlow yang dirancang untuk perangkat mobile dan embedded. TFLite memungkinkan inferensi model machine learning dengan efisiensi tinggi, sehingga cocok untuk dijalankan pada perangkat dengan sumber daya terbatas seperti ponsel pintar, mikrokontroler, dan perangkat Internet of Things (IoT). Proses inferensi di TFLite dirancang untuk memberikan kinerja yang optimal melalui berbagai optimisasi seperti kuantisasi model, yang mengurangi ukuran model dan mempercepat eksekusi tanpa mengorbankan akurasi secara signifikan [7].

TFLite terdiri dari dua komponen utama: Interpreter dan Converter. Interpreter bertanggung jawab untuk menjalankan model TFLite yang sudah dioptimalkan, sementara Converter digunakan untuk mengubah model TensorFlow yang sudah dilatih menjadi format TFLite. Dengan TFLite, model machine learning dapat di-deploy langsung ke perangkat akhir, memungkinkan aplikasi real-time yang tanggap seperti pengenalan wajah, deteksi objek, dan analisis teks. Fitur-fitur ini menjadikan TFLite solusi ideal untuk pengembangan aplikasi AI yang membutuhkan kinerja tinggi dan konsumsi daya yang rendah.

E. Roboflow

Roboflow adalah platform yang dirancang untuk membantu insinyur AI memproses kumpulan data dan mengembangkan model visi komputer. Platform ini menawarkan berbagai fitur yang dapat digunakan untuk memproses dan memanipulasi kumpulan data, termasuk anotasi objek, prapemrosesan, dan peningkatan gambar. Dengan Roboflow, para insinyur dapat dengan mudah menandai objek untuk dideteksi menggunakan kotak pembatas dan menggunakan berbagai transformasi seperti flip, rotasi, kecerahan, eksposur, dan geser untuk melakukan pra-pemrosesan seperti skala abu-abu atau pemrosesan pembesaran gambar.

Platform ini juga menyediakan metrik evaluasi seperti metrik Coco dan matriks kebingungan untuk mengevaluasi kinerja model. Selain itu, Roboflow memungkinkan pengguna untuk mengimplementasikan model dasar seperti SAM dan CLIP pada API yang dihosting atau perangkat edge, dan mengatur data visual menggunakan penyematan vektor CLIP. Roboflow membantu teknisi membuat kumpulan data, melatih model, dan menerapkan model ke produksi lebih cepat dan efisien dengan otomatisasi pelabelan menggunakan Segment Anything (SAM) [8].

F. Mean Average Precision (mAP)

Mean Average Precision (mAP) adalah metrik yang digunakan untuk mengevaluasi kinerja model deteksi objek. Metrik ini menghitung presisi rata-rata dari nilai recall yang

berbeda dan dirata-ratakan untuk setiap kelas objek dalam kumpulan data. Dengan kata lain, mAP memberikan gambaran lengkap tentang seberapa akurat model dapat mengenali objek dalam berbagai scenario [9].

Untuk menghitung mAP, langkah-langkah yang dilakukan adalah sebagai berikut:

1. Average Precision (AP) dihitung untuk setiap kelas objek yang dideteksi. AP adalah area di bawah kurva Precision-Recall untuk kelas tersebut.
2. Mean Average Precision (mAP) adalah rata-rata dari nilai AP untuk semua kelas objek yang dideteksi.

mAP biasanya digunakan dalam kontes deteksi objek seperti PASCAL VOC dan COCO, di mana mAP pada berbagai ambang batas Intersection over Union (IoU) digunakan sebagai standar evaluasi.

G. Confusion Matrix

Dalam statistik dan machine learning, confusion matrix adalah alat evaluasi yang digunakan untuk mengukur kinerja model klasifikasi. Dalam matriks ini, tabel menunjukkan perbandingan antara prediksi model dan nilai sebenarnya. Analisis confusion matrix biasanya terdiri dari empat komponen utama: True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). Dengan melakukan analisis ini, kita dapat menghitung berbagai metrik performa, termasuk akurasi, presisi, recall, dan skor F1. Ini membantu untuk memahami kelebihan dan kekurangan model klasifikasi mereka dan menemukan area yang perlu diperbaiki [10].

III. METODE

A. Pengumpulan Dataset


Dataset yang dikumpulkan adalah berupa gambar-gambar yang diambil dari google, roboflow dan pengambilan langsung dengan kamera smartphone. Tujuan mengumpulkan dataset gambar dengan kamera smartphone adalah untuk mendapatkan gambar-gambar sampah lokal yang ada di lingkungan kampus. Hal tersebut bertujuan agar nantinya model dapat lebih baik dalam proses pendeteksian sampah karena tempat sampah otomatis ini dibuat untuk digunakan dalam lingkungan kampus.



GAMBAR 1.
Pengambilan foto


B. Pengolahan Dataset

Pengolahan dataset, merupakan tahap kritis dalam persiapan sistem deteksi objek untuk sistem pemilahan sampah otomatis. Pertama, dataset yang telah terkumpul diunggah ke platform Roboflow untuk memfasilitasi proses anotasi objek.



GAMBAR 2.
Pengolahan dataset pada Roboflow

Anotasi dilakukan secara manual untuk mengidentifikasi dan memberi label pada objek-objek dalam gambar, memastikan dataset siap untuk pelatihan. Setelah itu, dataset dibagi menjadi dua bagian utama: dataset pelatihan untuk melatih model dan dataset validasi untuk mengevaluasi kinerja model.



GAMBAR 3.
Proses pemberian label

Proses preprocessing kemudian dilakukan untuk mempersiapkan data masukan, termasuk normalisasi dan penyesuaian format, sehingga dataset siap untuk diproses lebih lanjut. Selanjutnya, augmentasi dataset dilakukan dengan menambahkan variasi ke dataset, seperti rotasi, pemotongan, dan pencahayaan, untuk meningkatkan keberagaman data dan meningkatkan kemampuan generalisasi model. Akhirnya, dataset yang telah diolah dan diperkaya di-generate dalam format yang kompatibel dengan algoritma pelatihan.



GAMBAR 4.
Proses augmentasi

C. Machine Learning

Machine learning akan fokus pada pengembangan dan pelatihan model deteksi objek menggunakan arsitektur SSD MobileNet V2. Langkah awal adalah menginstal semua dependensi yang diperlukan untuk TensorFlow Object Detection agar proses pelatihan berjalan lancar. Konfigurasi training kemudian disesuaikan untuk mengoptimalkan performa model, termasuk pengaturan hyperparameter dan strategi augmentasi yang konsisten dengan dataset yang telah dipersiapkan. Pelatihan dilakukan secara online menggunakan Google Colab untuk memanfaatkan sumber daya komputasi yang besar. Setelah mencapai konvergensi

yang memadai, model yang telah dilatih dikonversi ke format TensorFlow Lite untuk memungkinkan eksekusi yang lebih efisien pada perangkat keras terbatas, seperti Raspberry Pi. Pengujian dilakukan untuk mengukur *Mean Average Precision* (mAP) dari model TensorFlow Lite yang dihasilkan, menjamin kualitas deteksi objek sebelum implementasi pada perangkat keras.

D. Pengujian Model

Pengujian kali ini menggunakan metode performance testing. Pengujian ini bertujuan untuk menilai keakuratan pemisahan sampah dalam kondisi operasional yang berbeda. Dalam dokumen ini, akan dijelaskan proses pengujian secara rinci, mencakup skenario pengujian, metode, hasil yang diharapkan, dan hasil pengujian lapangan. Pengujian ini bertujuan untuk menilai keakuratan pemisahan sampah dalam kondisi operasional yang berbeda. Dalam dokumen ini, akan dijelaskan proses pengujian secara rinci, mencakup skenario pengujian, metode, hasil yang diharapkan, dan hasil pengujian lapangan. Dengan skema pengujian yang terstruktur ini, diharapkan dapat diperoleh gambaran yang jelas mengenai kinerja dan efektivitas alat tempat sampah otomatis dalam memisahkan sampah sesuai dengan kategorinya.

1. Pengujian Akurasi *Machine Learning* dengan Foto

Pengujian dilakukan dengan melakukan evaluasi terhadap model dan dataset yang telah dilatih dengan memasukkan foto sampah yang telah dikategorikan ke dalam machine learning. Setiap kategori sampah diuji dengan 80 sampel foto yang berbeda dan tidak termasuk dalam dataset pelatihan. Jenis foto sampah yang akan diuji: organik, non-organik, metal, dan B3. Penilaian dilakukan dengan menghitung jumlah benar deteksi yang sesuai dengan jenis sampahnya. Hasil dari pengujian yang diharapkan adalah rata-rata nilai angka akurasi yang tinggi untuk setiap jenis sampah. Hasil dari pengujian ini berupa foto yang telah dideteksi dan hasil dari deteksi tersebut akan ditampilkan dalam bentuk *confusion matrix*.

2. Pengujian Akurasi *Machine Learning* dengan Webcam

Pengujian dilakukan dengan menggunakan kamera webcam untuk mendeteksi sampah yang telah dikategorikan ke dalam machine learning. Setiap kategori sampah diuji dengan 20 barang yang berbeda. Jenis sampah yang akan diuji: organik, non-organik, metal, dan B3. Penilaian dilakukan dengan menghitung jumlah benar deteksi yang sesuai dengan jenis sampahnya. Hasil dari pengujian yang diharapkan adalah rata-rata nilai angka akurasi yang tinggi untuk setiap jenis sampah.

3. Pengujian Akurasi Pemilahan Sampah pada Raspberry pi

Pengujian dilakukan dengan menggunakan kamera webcam pada raspberry pi untuk mendeteksi sampah yang telah dikategorikan ke dalam machine learning. Setiap kategori sampah diuji dengan 20 barang yang berbeda. Jenis sampah yang akan diuji: organik, non-organik, metal, dan B3. Penilaian dilakukan dengan menghitung jumlah benar sampah yang terdeteksi dan masuk ke tempat sampah yang sesuai dengan jenis sampahnya. Hasil dari pengujian yang diharapkan adalah rata-rata nilai angka akurasi yang tinggi untuk setiap jenis sampah.

IV. HASIL DAN PEMBAHASAN

		ACTUAL			
PREDICTED		organik	non-organik	metal	b3
	organik	16			
	non-organik		17		1
	metal		3	23	
	b3				19

GAMBAR 5.
Confusion matrix

TABEL 1.
Hasil pengujian menggunakan foto

Jenis Sampah	Jumlah foto yang terpilih	Jumlah foto yang salah deteksi	Jumlah foto yang tidak terdeteksi	Rata-rata nilai confidence score
Organik	16	0	0	93
Non-Organik	21	3	1	97.05
Metal	23	0	0	97.9
B3	20	1	0	94.71
Rata-rata nilai akurasi				95.67

TABEL 2.
Hasil pengujian menggunakan kamera webcam

Jenis Sampah	Jumlah barang yang terpilih	Jumlah barang yang tidak terdeteksi	Rata-rata nilai confidence score
Organik	5	0	98
Non-Organik	5	1	94.7
B3	5	1	96.1
Metal	5	1	93.7
Total rata-rata nilai akurasi			95.62

TABEL 3.
Hasil dari pengujian menggunakan raspberry pi

Jenis Sampah	Jumlah barang yang terpilih	Jumlah barang yang salah deteksi
Organik	5	3
Non-Organik	5	1
B3	5	2

Jenis Sampah	Jumlah barang yang terpilih	Jumlah barang yang salah deteksi
Metal	5	2

Berdasarkan hasil pengujian yang telah dilakukan, alat tempat sampah otomatis menunjukkan tingkat keberhasilan yang tinggi dalam memisahkan sampah ke dalam kategori yang tepat. Tingkat akurasi mendeteksi sampah bervariasi dari 93% hingga 98%, dengan kategori metal menunjukkan akurasi terendah. Untuk pemisahan sampah melalui raspberry pi, kamera tidak mendeteksi dengan sempurna sehingga akurasi pemilah sampah masih kurang dari 70%.

V. KESIMPULAN

Proyek pengembangan alat tempat sampah otomatis untuk memisahkan sampah ke dalam kategori organik, non-organik, metal, dan B3 telah menunjukkan tingkat keberhasilan yang tinggi. Pengujian fungsional dan kinerja menunjukkan bahwa alat ini mampu memisahkan sampah dengan akurasi yang bervariasi dari 88% hingga 96%. Performance testing memberikan hasil positif, menunjukkan bahwa alat ini umumnya bekerja dan dapat digunakan dengan baik, meskipun ada beberapa saran untuk peningkatan lebih lanjut. Namun, ada beberapa keterbatasan yang perlu diperhatikan, seperti akurasi pemisahan untuk sampah yang lebih rendah dan tantangan dalam memisahkan sampah campuran.

REFERENSI

[1] Brotosusilo, A., & Handayani, D, "Dataset on waste management behaviors of urban citizens in large cities of Indonesia," *Data in Brief*, 32, 106053, 2020.

[2] "Kementerian Lingkungan Hidup dan Kehutanan, 'SIPSN - Sistem Informasi Pengelolaan Sampah Nasional.'," sipsn.menlhk.go.id.

[3] H. A. Addahlawi, U. Mustaghfiroh, L. K. Ni'mah, A. Sundusiyah, A. F. Hidayatullah, "Implementasi Prinsip Good Environmental Governance Dalam Pengelolaan Sampah di Indonesia," *Jurnal Green Growth dan Manajemen Lingkungan*, Vol. 8 No. 2, p. 107, 2019.

[4] C. Janiesch, P. Zschech, and K. Heinrich, "Machine learning and deep learning," *Electronic Markets*, vol. 31, pp. 685-695, Sep. 2021. [Online]. Available: <https://doi.org/10.1007/s12525-021-00475-2>. [Accessed: Jun. 9, 2024].

[5] S. Fuady, Nehru, dan G. Anggraeni, "Deteksi Objek Menggunakan Metode Single Shot Multibox Detector Pada Alat Bantu Tongkat Tunanetra Berbasis Kamera", *Journal of Electrical Power Control and Automation*, pp. 39, Desember 2020

[6] H. Tanujaya, dan Lina, "Pengenalan Objek Menggunakan Metode Single Shot Multibox Detector pada Bahan Sembako", *Jurnal Ilmu Komputer dan Sistem Informasi*, pp. 4.

[7] TensorFlow Lite, "TensorFlow Lite: Machine learning for mobile and edge devices," TensorFlow, [Online].

Available: <https://www.tensorflow.org/lite>. [Accessed: Jul. 9, 2024].

- [8] B. Cooley, J. S. Brown, and J. Carlson, "Roboflow: Enabling computer vision with ease," in *2024 International Conference on Artificial Intelligence and Machine Learning (AIML)*, 2024, pp. 456-460.
- [9] "Mean Average Precision (mAP) for Object Detection," Papers with Code, 2024. [Online]. Available: <https://paperswithcode.com/method/mean-average-precision>. [Accessed: 09-Jul-2024].
- [10] T. Fawcett, "An introduction to ROC analysis," *Pattern Recognition Letters*, vol. 27, no. 8, pp. 861-874, 2006.

