

DETEKSI JENIS SAMPAH SECARA *REALTIME* MENGGUNAKAN METODE *SINGLE SHOT MULTIBOX DETECTOR (SSD)*

Pernando, Muhammad Rafi Muttaqin, Yudhi Raymond Ramadhan

Program Studi Teknik Informatika S1, Fakultas Teknologi Industri
Sekolah Tinggi Teknologi Wastukencana, Jalan Cikopak No.53 Purwakarta, Indonesia
pernandopernando70@wastukencana.ac.id

ABSTRAK

Masalah sampah merupakan isu global yang banyak menjadi ancaman serius terhadap lingkungan dan kesehatan manusia. Banyak negara di dunia termasuk Indonesia masih menghadapi tantangan dalam mengelola sampah secara efektif dan efisien. Karena permasalahan tersebut, peneliti ingin membuat model objek deteksi menggunakan model dasar yaitu *SSD-MobileNet V2* untuk mengklasifikasikan jenis sampah organik maupun anorganik. Metode yang digunakan adalah *Single Shot Multibox Detector (SSD)* yang digunakan untuk mengolah data gambar dan Metode penelitian yang digunakan adalah *CRISP-DM*. *Dataset* dikumpulkan dengan cara primer berupa pengambilan foto langsung dari objek dan dibagi menjadi dua yaitu data *train* dan data *test*. Setelah model objek deteksi berhasil dibuat maka dilakukan pengujian dengan menggunakan gambar yang berbeda dari training maupun testing. Hasil pengujian menggunakan *confusion matrix* didapatkan hasil akurasi sebesar 93%.

Kata kunci: Objek Deteksi, *SSD Mobilenet V2*, *CRISP-DM*, Sampah

1. PENDAHULUAN

Masalah sampah merupakan isu global yang banyak menjadi ancaman serius terhadap lingkungan dan kesehatan manusia. Banyak negara di dunia termasuk Indonesia masih menghadapi tantangan dalam mengelola sampah secara efektif dan efisien. Untuk mengatasi masalah ini, penting untuk mengadopsi pendekatan yang berkelanjutan terhadap pengelolaan sampah. Salah satu langkah kunci dalam pengelolaan sampah adalah memisahkan sampah organik (seperti sisa makanan dan bahan organik lainnya) dari sampah anorganik (seperti plastik, kertas, logam, dan sebagainya). Namun, proses ini seringkali memerlukan partisipasi aktif dari masyarakat yang dapat menjadi sulit dan memakan waktu.

Pembangunan model objek deteksi sampah organik dan anorganik dapat membantu dalam upaya pengelolaan sampah yang efektif dan berkelanjutan. Tujuan dari model ini adalah untuk mengenali dan membedakan antara sampah organik dengan sampah anorganik. Penggunaan model objek deteksi sampah organik dan anorganik memiliki potensi untuk meningkatkan efisiensi dan keberlanjutan dalam pengelolaan sampah.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terkait

Penelitian yang berjudul “Pembuatan Aplikasi Deteksi Objek Menggunakan *TensorFlow Object Detection API* dengan Memanfaatkan *SSD MobileNet V2* Sebagai Model Pra-Terlatih” [1]. Pada penelitian ini ingin membuat aplikasi deteksi objek menggunakan *tensorflow object detection API* untuk menguji coba model *SSD MobileNetV2* sebagai model pre-trained.

Aplikasi berhasil dibuat menggunakan python dan dilakukan uji coba pada data test dengan hasil

dapat mendeteksi camera dengan akurasi 99%, handphone 89.1%, headphone 89.1%, Laptop 89.1%, dan mouse 98,8%.

2.2. Sampah

Sampah adalah materi yang dikeluarkan atau tidak digunakan lagi baik oleh manusia atau proses alam karena unsur-unsur atau fungsi utamanya telah diambil [2]. Sampah juga memiliki jenis seperti sampah organik/basah [3], sampah anorganik/kering [3] dan sampah bahan berbahaya dan beracun (B3) [3].

2.3. Kecerdasan Buatan

Kecerdasan buatan adalah suatu teknik yang dimanfaatkan untuk meniru kecerdasan makhluk hidup dalam menyelesaikan masalah [4].

2.4. Deep Learning

Deep Learning adalah pendekatan pembelajaran yang menggunakan Jaringan Saraf Tiruan yang berlapis-lapis (*Multi Layer*). Jaringan Saraf Tiruan ini dirancang sehingga menyerupai otak manusia, di mana neuron-neuron terhubung satu sama lain membentuk rangkaian neuron yang sangat kompleks [5].

2.5. CRISP-DM

CRISP-DM (Cross-Industry Standard Process for Data Mining) adalah metodologi data mining yang dikembangkan oleh konsorsium perusahaan yang didirikan oleh Komisi Eropa pada tahun 1996. Metodologi ini telah diakui sebagai proses standar dalam data mining [6]. *CRISP-DM* terdiri dari 5 tahap yaitu:

a. Business Understanding

Tahap awal adalah memahami tujuan dan kebutuhan dari perspektif bisnis, lalu mengartikan

- pemahaman tersebut menjadi definisi masalah dalam data mining [6].
- b. Data Understanding
Tahap ini dimulai dengan mengumpulkan data, yang kemudian diikuti oleh proses untuk mendapatkan pemahaman yang komprehensif tentang data tersebut [6].
 - c. Data Preparation
Tahap ini mencakup semua kegiatan untuk menyusun dataset akhir (data yang akan digunakan pada tahap pemodelan) dari data mentah [6].
 - d. Modelling
Pada tahap ini, berbagai teknik pemodelan akan dipilih dan diterapkan, dan beberapa parameter akan disesuaikan untuk mencapai nilai yang optimal [6].
 - e. Evaluation
Dalam tahap ini, evaluasi dilakukan terhadap efektivitas dan kualitas model sebelum digunakan, serta menentukan apakah model tersebut dapat mencapai tujuan yang telah ditetapkan pada tahap awal [6].
 - f. Deployment
Dalam tahap ini, pengetahuan atau informasi yang telah diperoleh akan diorganisir atau disajikan dalam format khusus agar dapat digunakan oleh pengguna [6].


2.6. Deteksi Objek

Deteksi objek adalah teknik komputer visi untuk mengidentifikasi contoh objek dalam gambar atau video. Algoritma deteksi objek sering menggunakan pembelajaran mesin atau pembelajaran mendalam untuk menghasilkan hasil yang signifikan.

Tujuan dari deteksi objek adalah untuk menggandakan kemampuan manusia dalam mengenali objek menggunakan komputer. Metode kerjanya adalah dengan menemukan keberadaan objek dalam gambar dan menggambar kotak pembatas di sekitarnya. Proses ini melibatkan dua langkah, yaitu mengklasifikasikan jenis objek dan kemudian menarik kotak pembatas di sekitar objek tersebut [7].

2.7. SSD-MobileNetV2


SSD MobileNet V2 adalah salah satu model arsitektur machine learning. SSD MobileNet V2 dirancang untuk mendeteksi satu objek atau beberapa objek secara *realtime* SSD MobileNet V2 digunakan untuk perangkat mobile (seluler) dengan spesifikasi yang cukup ringan. MobileNet menggunakan *depthwise separable convolution* yang secara signifikan mengurangi jumlah parameter jika dibandingkan dengan *regular convolution*, dari hal tersebut MobileNet menjadi *deep neural network* yang sangat ringan [8]. SSD MobileNet V2 adalah salah satu arsitektur model *Convolutional Neural Network (CNN)* [9]. CNN adalah salah bidang ilmu komputer untuk mengembangkan jaringan saraf tiruan dengan mengadopsi jaringan saraf manusia untuk mengenali dan mendeteksi objek [9].



Gambar 1. Arsitektur SSD MobileNet V2[10]

3. METODE PENELITIAN

3.1. Kerangka Penelitian



Gambar 2. Kerangka Penelitian

Gambar 2 menunjukkan kerangka penelitian yang digunakan oleh peneliti untuk melakukan penelitian ini berdasarkan metode CRISP-DM dengan pendekatan bertahap. Metode CRISP-DM terdiri dari beberapa fase, termasuk *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modelling*, *Evaluation*, dan *Deployment*.

3.2. Business Understanding

Tujuan dari penelitian ini adalah untuk dapat membuat aplikasi mobile yang dapat mendeteksi objek sampah dalam gambar digital dan dapat mengklasifikasikan objek tersebut secara *real time*.

3.3. Data Understanding

Data yang akan digunakan berupa citra digital (gambar) dari berbagai sampah yang ada disekitar. Data mentah berupa gambar dengan warna yang memperlihatkan objek sampahnya secara jelas karena akan berfokus pada objek sampah yang terdapat dalam gambar.



Gambar 3. Sampah Anorganik




Gambar 4. Sampah Organik

3.4. Data Preparation

Sebelum memulai proses pelatihan model, dibutuhkan memberi label kelas pada gambar untuk mengumpulkan informasi mengenai objek yang akan dideteksi. Labelling adalah proses untuk memberikan informasi mengenai objek di dalam gambar pada dataset yang diperoleh. Proses pelabelan objek dilakukan dengan mendefinisikan kotak pembatas (*bounding box*) dan menetapkan nama kelas atau label.

Table 1. Jumlah Dataset

NO	Nama Objek	Label	Data train	Data Test
1	Sterofoam	Anorganik	27	4
2	Bungkus Kopi	Anorganik	24	3
3	Tissue	Organik	22	9
4	Kantung Plastik	Anorganik	21	6
5	Kulit Pisang	Organik	28	5
6	Kaleng Minuman	Anorganik	30	7
7	Botol Plastik	Anorganik	23	7
8	Sayur	Organik	17	6
9	Masker Duckbill	Anorganik	15	4
10	Bungkus Rokok	Anorganik	16	4
Total			223	55



Gambar 5. Proses labeling objek sampah

3.5. Modelling

Model yang digunakan peneliti untuk penelitian ini adalah *SSD-MobileNetV2* karena *SSD-MobileNet V2* adalah model yang tergolong ringan dan dapat dijalankan di platform mobile. *SSD-MobileNet V2* juga mempunyai kemampuan untuk mendeteksi objek secara *real time*.

3.6. Evaluation

Model yang sudah selesai di latih menggunakan dataset training akan dievaluasi performa model tersebut untuk mengetahui apakah model tersebut sudah bagus atau tidak.

3.7. Deployment

Pada penelitian ini peneliti akan membuat aplikasi mobile untuk mendeteksi objek sampah organik dan anorganik dengan menggunakan bahasa pemrograman *kotlin* dan dibuat menggunakan *android studio*.

4. HASIL DAN PEMBAHASAN

Peneliti melakukan beberapa pengujian untuk mendapatkan hasil model objek deteksi terbaik

4.1. Pengujian Learning Rate

Table 2. Hasil Pengujian Learning Rate

Learning Rate	Loss training	Loss evaluasi
0.3	0.216	0.308
0.01	0.216	0.415
0.001	.0272	0.370

dari hasil tabel diatas didapatkan nilai loss terkecil yaitu pada learning rate sebesar 0.3 dari hasil pengujian. Hasil loss sebaiknya didapatkan nilai sekecil mungkin karena berarti tidak ada loss atau kesalahan pada model.

4.2. Pengujian Steps



Table 3. Hasil Pengujian Steps







Steps	Loss training	Loss evaluasi
5000	0.216	0.308
10000	0.183	0.341
20000	0.134	0.278

dari hasil pengujian steps pada tabel 3, didapatkan hasil loss atau kesalahan terkecil model ada pada steps 20000.

4.3. Pengujian Model

Table 4. Pengujian Model

Gambar	Benar	Salah	Objek
	3	0	Sterofoam
	3	0	Bungkus Kopi
	2	1	Sayur
	3	0	Plastik

Gambar	Benar	Salah	Objek
	3	0	Tissue
	3	0	Bungkus Rokok
	3	0	Kaleng
	3	0	Botol Plastik
	3	0	Masker
	2	1	Pisang

Dari hasil pengujian model pada tabel 4 diatas yang dilakukan dengan 30 data gambar untuk pengujian. Digunakan confusion matrix untuk mengukur akurasi dari model yang sudah dibuat.

Table 5 Confusion Matrix

N = 30	Aktual organik	Aktual anorganik
Prediksi organik	7	0
Prediksi anorganik	2	21
Total	9	21

$$Accuracy = \frac{\text{Prediksi benar}}{\text{jumlah data}}$$

$$Accuracy = \frac{28}{30}$$

$$Accuracy = 0,93$$

$$Accuracy = 0,93 * 100$$


$$Accuracy = 93\%$$

Dari hasil *confusion matrix* pada tabel 5 didapatkan hasil yaitu 28 gambar yang diprediksi benar dari 30 jumlah data yang setelah dibagi menghasilkan tingkat akurasi sebesar 93%.

Setelah model selesai dibuat dan di evaluasi langkah terakhir adalah untuk implementasi model yang sudah diekspor dalam format *tflite* ke dalam aplikasi mobile. Disini peneliti menggunakan bantuan dari *tensorflow* dan kode bersumber dari *tensorflow examples* yang bersumber dari link "https://github.com/tensorflow/examples/tree/master/lite/examples/object_detection/android".

Setelah *source code* aplikasi android sudah di *download* selanjutnya adalah membuka *source code* tersebut menggunakan *android studio*. Disini peneliti menggunakan *Android Studio Electric Eel 2022.1.1 Patch 2* dan menggunakan bahasa pemrograman *kotlin*. Setelah model di *import* ke dalam aplikasi *android* dan aplikasi *android* sudah selesai dibuat, pada gambar 6 adalah tampilan dari aplikasi *android*. Pada gambar 6 terdapat variabel seperti *fps*, *inference time*, *threshold*, *max results*, *number thread*, *delegate*, dan *ML model*.

Inference time adalah waktu yang dibutuhkan untuk melakukan satu deteksi. *Fps* adalah jumlah gambar yang ditampilkan dalam satu detik yang didapat dari membagi 1000 ms dengan waktu *inferensi*. *Threshold* adalah ambang batas ketika sebuah hasil deteksi akan dianggap terdeteksi jika nilai *confidence* objek tersebut di atas nilai *threshold*. *Max result* adalah jumlah maksimal deteksi dalam satu waktu. *Number thread* adalah jumlah proses bersamaan yang dapat dilakukan dalam satu waktu. *Menu delegate* memungkinkan untuk memilih tempat pemrosesan terjadi seperti *CPU*, *GPU*, atau *NNAPI*. Terakhir adalah *ML Model* yang merupakan pilihan model untuk menjalankan deteksi.



Gambar 1. Tampilan Aplikasi Android

5. KESIMPULAN DAN SARAN

Kesimpulan dari penelitian ini adalah peneliti berhasil membuat *model* untuk mendeteksi objek sampah organik dan anorganik. Peneliti menggunakan data *training* sebanyak 223 gambar dan untuk data *testing* sebanyak 55 gambar. Hasil perhitungan *confusion matrix* dari model yang sudah berhasil dibuat memiliki akurasi sebesar 93%, Peneliti sadar bahwa penelitian ini memiliki banyak kekurangan maka dari itu peneliti memiliki beberapa saran yaitu menambah variasi objek sampah pada dataset, menambahkan jenis sampah baru seperti sampah berbahaya dan menggunakan model objek deteksi yang lainnya.

DAFTAR PUSTAKA

- [1] P. Aningtiyas, A. Sumin, and S. Wirawan, "Pembuatan Aplikasi Deteksi Objek Menggunakan TensorFlow Object Detection API dengan Memanfaatkan SSD MobileNet V2 Sebagai Model Pra - Terlatih," *Jurnal Ilmiah Komputasi*, vol. 19, no. 3, Mar. 2020, doi: 10.32409/jikstik.19.3.68.
- [2] A. Kahfi, "TINJAUAN TERHADAP PENGELOLAAN SAMPAH," 2017. [Online]. Available: <http://nationalgeographic.co.id/berita/2016/08/in-donesia-penghasil-sampah-plastik->
- [3] Y. Kurniaty, W. Haji Bani NARARAYA, R. Nabila Turawan, and F. Nurmuhamad, "MENGEFEKTIFKAN PEMISAHAN JENIS SAMPAH SEBAGAI UPAYA PENGELOLAAN SAMPAH TERPADU DI KOTA MAGELANG," 2016. [Online].

- Available:
<http://dkpt.magelangkota.go.id/bidang/kebersihan>,
- [4] A. AHMAD, "Mengenal Artificial Intelligence, Machine Learning, Neural Network, dan Deep Learning," 2017. [Online]. Available: www.teknoindonesia.com
- [5] P. Adi Nugroho, I. Fenriana, and R. Arijanto, "IMPLEMENTASI DEEP LEARNING MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) PADA EKSPRESI MANUSIA," *JURNAL ALGOR*, vol. 2, no. 1, 2020, [Online]. Available: <https://jurnal.buddhidharma.ac.id/index.php/algor/index>
- [6] R. SETIAWAN, "PENERAPAN DATA MINING MENGGUNAKAN ALGORITMA K-MEANS CLUSTERING UNTUK MENENTUKAN STRATEGI PROMOSI MAHASISWA BARU (Studi Kasus : Politeknik LP3I Jakarta)," 2016.
- [7] R. KAMIL, "Perancangan Aplikasi Bahasa Isyarat 'Isyaratku' Dengan Deep Learning Serta Google Cloud Platform," 2021. [Online]. Available:
<http://jurnal.bsi.ac.id/index.php/simpatik>
- [8] A. HIDAYAHTULLAH, "SISTEM DETEKSI SIMBOL PADA SIBI (SISTEM ISYARAT BAHASA INDONESIA) SECARA REALTIME MENGGUNAKAN MOBILENET-SSD," 2022.
- [9] Evan, M. Wulandari, and E. Syamsudin, "Recognition of pedestrian traffic light using tensorflow and SSD MobileNet V2," in *IOP Conference Series: Materials Science and Engineering*, IOP Publishing Ltd, Dec. 2020. doi: 10.1088/1757-899X/1007/1/012022.
- [10] M. Rahman, D. Leman, and G. Artikel, "Movidius Neural Compute Stick untuk Pendeteksian Objek Manusia Secara Real Time dengan Metode Mobilenet-SSD Movidius Neural Compute Stick for Real Time Detection of Human Objects with the Mobilenet-SSD Method Article Info ABSTRAK," *JOMLAI: Journal of Machine Learning and Artificial Intelligence*, vol. 1, no. 3, pp. 2828–9099, 2022, doi: 10.55123/jomlai.v1i3.1025