



PENGARUH JARAK OBJEK CITRA PADA MODEL DETEKSI DAN KLASIFIKASI BOTOL PLASTIK MENGGUNAKAN YOLO

Nurvelly Rosanti¹, Retnani Latifah², Sirojul Munir³, Izzuddin Al Qossam Maududi⁴

^{1,2,4}Teknik Informatika, Universitas Muhammadiyah Jakarta

³Teknik Informatika, Sekolah Tinggi Teknologi Terpadu Nurul Fikri
Jakarta Selatan, DKI Jakarta, Indonesia 12640

nurvelly.rosanti@umj.ac.id, retnani.latifah@umj.ac.id, rojulman@nurulfikri.ac.id, izzuddinalqossammaududi@gmail.com

Abstract

Plastic bottle waste must be separated based on shape and size to facilitate recycling. Sorting plastic bottles can use object detection technology to facilitate classification using images. Image distance capture affects the classification of bottle waste because large bottles will look small when seen from a distance and vice versa. This study aims to create a plastic bottle detection and classification model using the YOLOv8 algorithm with the same bottle shape but different sizes and measure the effect of image distance on the model. Bottles consist of three sizes: large bottles measuring 1500 ml, medium bottles measuring 600 ml, and small sizes 330 ml. Pictures for the bottle image dataset were shot between 80 and 100 centimeters away. Roboflow was used to produce the dataset. Model performance evaluation used Mean Average Precision, and model testing used a confusion matrix. The test results for the same model with an image capture distance had an accuracy value of 100%. Testing of 80 cm distance images applied to the 100 cm model had an accuracy of 67%. Testing for 100 cm distance images applied to the 80 cm model was still quite good, with an accuracy of 91.6%. The results obtained show that the image distance affects the results of the model that has been built, so use an image that matches the distance applied to the model.

Keywords: Confusion Matrix, Mean Average Precision, Object Detection, Roboflow, YOLOv8

Abstrak

Sampah botol plastik perlu dipisahkan baik berdasarkan bentuk dan ukuran untuk mempermudah proses daur ulang. Pemilahan botol plastik dapat menggunakan teknologi deteksi objek untuk mempermudah klasifikasi menggunakan citra. Pengambilan jarak citra mempengaruhi klasifikasi sampah botol, hal ini disebabkan botol yang ukuran besar jika dilihat dari jauh akan terlihat kecil begitu juga sebaliknya. Penelitian ini bertujuan membuat model deteksi dan klasifikasi botol plastik menggunakan algoritma YOLOv8 dengan bentuk botol yang sama tapi ukuran berbeda serta mengukur pengaruh jarak citra terhadap model. Botol terdiri dari tiga ukuran yaitu botol besar ukuran 1500 ml, botol sedang ukuran 600 ml dan ukuran kecil 330 ml. Pengambilan foto untuk *dataset* citra botol dilakukan pada jarak 80 cm dan 100 cm. Pembuatan *dataset* menggunakan Roboflow. Evaluasi kinerja model menggunakan Mean Average Precision dan pengujian model menggunakan *confusion matrix*. Hasil pengujian untuk model yang sama dengan jarak pengambilan citra memiliki nilai akurasi 100%. Pengujian citra jarak 80 cm diterapkan ke model 100 cm memiliki akurasi 67%. Pengujian untuk citra jarak 100 cm diterapkan pada model 80 cm masih cukup baik dengan akurasi 91,6%. Hasil yang diperoleh bahwa jarak citra mempengaruhi hasil pada model yang sudah dibangun sehingga gunakan citra yang sesuai dengan jarak yang diterapkan pada model.

Kata kunci: Confusion Matrix, Deteksi Objek, Mean Average Precision, Roboflow, YOLOv8

1. PENDAHULUAN

Pemerintah dalam pengelolaan sampah sudah membuat aturan yang tertuang dalam PP No 81 Tahun 2012. Peraturan ini juga memuat tentang pemilahan sampah berdasarkan jenisnya. Jenis sampah ada tiga yaitu sampah organik, anorganik serta sampah bahan beracun dan berbahaya (B3). Dinas kebersihan Kota sudah melengkapi sarana umum dengan sarana tempat sampah yang berwarna-warni minimal tiga tempat sampah berdekatan dengan

keterangan organik, non organik dan B3. Dalam hal ini masyarakat dalam membuang sampah harus memasukkan jenis sampah sesuai dengan tempat yang tertulis pada tempat sampah tersebut. Penelitian terkait sampah juga sudah dilakukan dengan membuat prototipe aplikasi bank sampah dengan tujuan dapat mengelola sampah terpadu [1]. Pemisahan sampah menggunakan tempat sampah seperti ini masih pada tahap awal jika sampah ingin didaur ulang. Sampah yang sering ditemukan di area umum adalah

sampah botol plastik minuman sedangkan plastik sulit terurai di tanah. Sampah botol plastik yang ditemukan ada yang berbeda bentuk dan ukuran sesuai dengan merek produk.

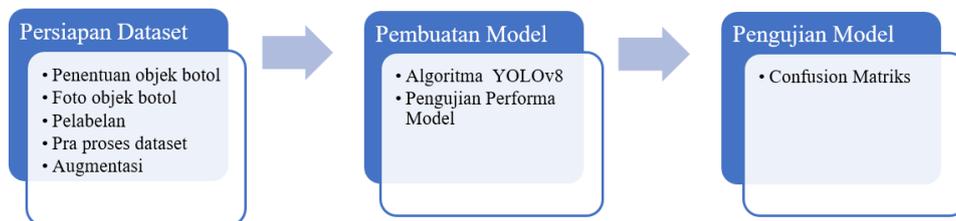
Untuk memudahkan dalam proses daur ulang dari berbagai jenis botol plastik tersebut, sampah botol plastik ini perlu dipisahkan baik berdasarkan bentuk, ukuran maupun merek sesuai dengan kebutuhan. Proses pemilahan sampah botol plastik tersebut dapat menggunakan teknologi deteksi objek. Deteksi objek menggunakan *machine learning* dengan metode *deep learning* sudah mampu memproses data gambar [2]. Penelitian terkait pemilahan sampah menggunakan deteksi objek sudah banyak dilakukan. Penelitian yang dilakukan oleh Wahyutama & Hwang [3] terkait deteksi objek tempat sampah telah dilakukan menggunakan algoritma YOLOv4 (*You Only Look Once version 4*). Penelitian tersebut fokus pada deteksi objek sampah kemudian mengelompokkannya sesuai dengan dengan empat jenis sampah secara otomatis yaitu kertas, kaleng, plastik dan selain benda ini. Di samping itu Wahyutama & Hwang [3] juga memanfaatkan teknologi *internet of things (iot)* untuk mendeteksi tempat sampah sudah penuh di wilayah tertentu. Hasil dari penelitian ini memiliki tingkat akurasi sampai 91% dalam deteksi objek sampah. Penelitian lain terkait deteksi sampah juga dilakukan oleh Parasian & Utaminigrum [4] metode yang digunakan dalam deteksi objek juga menggunakan algoritma YOLO. Objek yang dideteksi dalam penelitian Parasian & Utaminigrum adalah deteksi sampah organik dan anorganik. Untuk sampah organik terdiri dari empat

kelas dan sampah anorganik terdiri dari tiga kelas. Tingkat akurasi yang diperoleh dari hasil pengujian untuk deteksi sampah organik paling tinggi adalah 98% sedangkan akurasi untuk deteksi sampah anorganik paling tinggi adalah 94,6%.

Berdasarkan penelitian terdahulu bahwa tingkat akurasi deteksi objek menggunakan YOLO di atas 90% sehingga YOLO merupakan metode yang baik untuk diterapkan dalam deteksi objek digital [5][6]. Penelitian sebelumnya juga melakukan pemisahan sampah berdasarkan organik dan anorganik tentu secara objek jelas perbedaan bentuknya secara visual [7]. Pemilahan sampah botol plastik untuk daur ulang juga melakukan pemisahan sampah berdasarkan ukuran besar dan kecilnya botol agar memudahkan dalam pengelompokan sampah botol plastik tersebut. Penelitian ini membuat model deteksi objek sampah botol plastik menggunakan algoritma YOLOv8 dengan khusus objek sampah botol dengan bentuk botol yang sama hanya ukuran berbeda yaitu botol besar, sedang dan kecil. Penelitian ini bertujuan untuk membuat model klasifikasi objek botol yaitu kelas botol besar, botol sedang dan botol kecil, serta untuk mengetahui pengaruh jarak objek gambar terhadap klasifikasi. Pengklasifikasian ukuran botol ini dapat mempermudah proses pemilahan atau pemisahan sampah botol plastik berdasarkan ukuran botol plastik.

2. METODE PENELITIAN

Pembuatan model deteksi objek sampah botol plastik untuk mengelompokkan sampah botol berdasarkan ukuran menggunakan algoritma YOLOv8 dapat melalui tahap-tahapan seperti pada Gambar 1 berikut.



Gambar 1. Tahapan Pembuatan Model

Pada Gambar 1 secara garis besar terdapat empat fase dalam tahap-tahapan pembuatan model deteksi objek botol yaitu dimulai dari *input* berupa *dataset*, kemudian proses pembuatan model menggunakan algoritma YOLOv8. Setelah model terbentuk maka masuk tahapan berikutnya yaitu pengujian model dengan mengukur tingkat akurasi deteksi objek. Bagian terakhir adalah *output* berupa hasil klasifikasi botol yang terdeteksi yaitu pengelompokan botol besar, botol sedang dan botol kecil. Secara detail dari masing-masing fase sebagai berikut.

2.1. Persiapan Dataset

Pengumpulan *dataset* merupakan bagian penentu dari keberhasilan model. Proses pembuatan *dataset* dilakukan dengan membuat foto botol minimal 100 foto. *Dataset* yang dibutuhkan terdiri dari *dataset* latih dan *dataset* uji dengan

perbandingan 80% data latih dan 20% data uji [8]. Langkah-langkah yang dilakukan adalah sebagai berikut

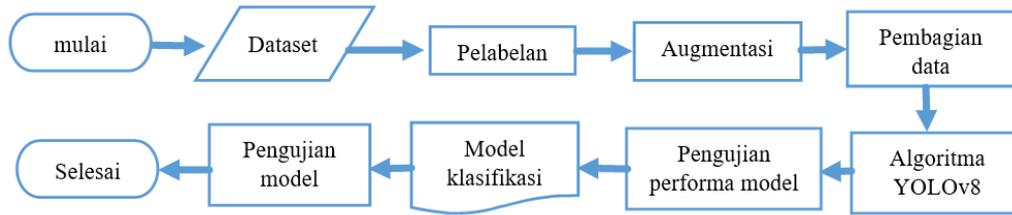
- Mempersiapkan botol plastik minuman mineral ukuran 1500 ml, 600 ml dan 300 ml.
- Mempersiapkan kamera *webcam* untuk pengambilan gambar dengan posisi tetap.
- Botol plastik dengan masing-masing ukuran difoto dengan posisi tegak, tidur dan miring.
- Hasil foto disimpan kemudian dilakukan pelabelan menggunakan *Roboflow* [9].

2.2 Pembuatan Model

Pada tahap ini *dataset* yang sudah disiapkan dan dilabeli maka masuk proses membuat model dengan melatih *dataset*

untuk mengenali objek botol. Algoritma YOLOv8 digunakan untuk pembuatan model ini disebabkan YOLOv8 baik pada objek detektor *real time*, bekerja baik pada ukuran objek yang kecil dan memiliki kemampuan deteksi objek

dengan akurasi yang tinggi [10][11]. Perancangan model yang diterapkan untuk klasifikasi botol berdasarkan jarak gambar dapat dilihat pada Gambar 2.



Gambar 2. Flowchart pembuatan model dengan YOLOv8

Pada Gambar 2 dapat diuraikan bahwa setelah persiapan *dataset* seperti proses pelabelan dan augmentasi maka tahap berikutnya masuk pada penggunaan algoritma YOLOv8 dengan pengaturan pembagian data.

2.3 Evaluasi Kinerja Model

Pada fase ini menguji kinerja model yang sudah dibuat dengan tujuan untuk mengevaluasi kinerja model deteksi objek yang telah dilatih dengan mengukur tingkat akurasi dan performa model. Pengujian model dilakukan menggunakan metode :

- a) *Mean Average Precision* (mAP) yaitu Matriks untuk mengukur akurasi deteksi objek dengan menghitung rata-rata presisi di setiap nilai recall. Semakin tinggi nilai mAP, semakin baik performa model deteksi objek [12][13]. Formula dari mAP sebagai berikut :

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$

N = jumlah kelas

AP_i = rata-rata presisi kelas ke i

- b) *Intersection over Union (IoU)* yaitu mengukur rasio antara luas area yang tumpang tindih antara beberapa bounding box dengan luas area gabungan dari bounding box tersebut [14].

2.4 Pengujian Model

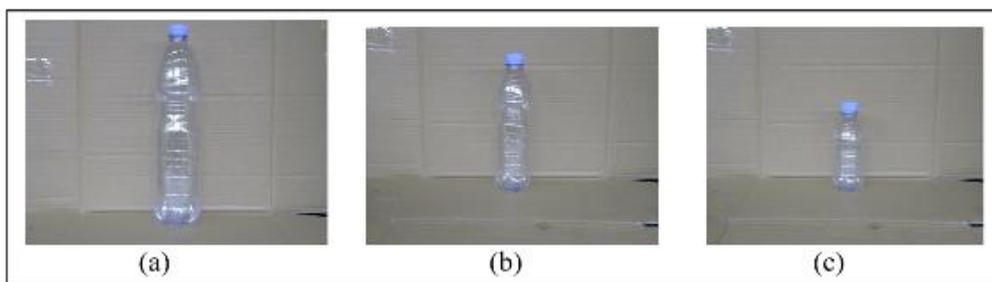
Pada tahap ini penerapan model yang sudah dihasilkan kemudian diuji menggunakan metode *confusion matrix* [15]. Pengujian model ini menggunakan *dataset* uji dengan hasil klasifikasi objek botol plastik sesuai dengan kelas botol plastik yang dideteksi yaitu kelas botol besar, kelas botol sedang dan kelas botol kecil berdasarkan jarak citra botol 80 cm dan 100 cm.

3. HASIL DAN PEMBAHASAN

3.1 Pembuatan Dataset

- a) Penentuan Objek Botol

Objek botol yang ditentukan adalah botol plastik berukuran 1500 ml, 600 ml dan 330 ml dengan bentuk botol yang sama hanya ukuran botol saja yang berbeda seperti pada Gambar 3 berikut.

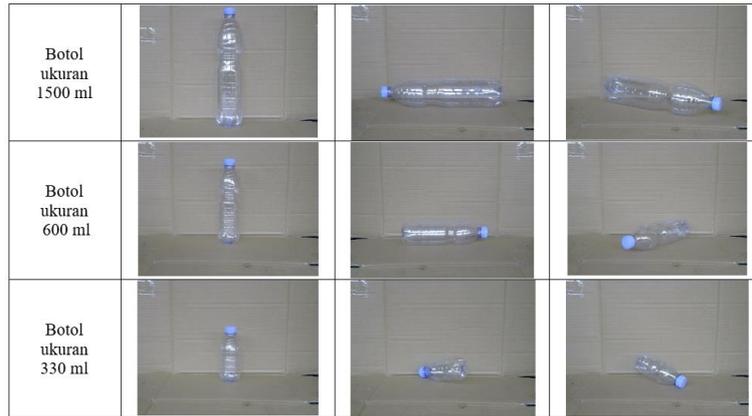


Gambar 3. (a) botol ukuran 1500 ml (b) botol ukuran 600 ml
(c) botol ukuran 330 ml

- b) Foto Objek Botol

Botol yang sudah ada kemudian difoto dengan skenario untuk jarak 80 cm dan 100 cm dari kamera. Untuk jarak 80 cm diambil foto botol ukuran 1500 ml dengan posisi tegak, tidur dan miring kiri dan miring kanan sebanyak 21 foto. Kemudian jarak 80 cm diambil foto botol ukuran 600 ml

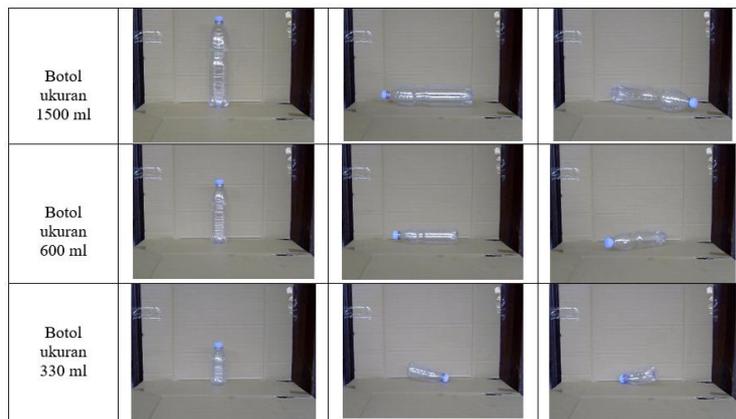
dengan posisi tegak, tidur dan miring kiri dan miring kanan sebanyak 21 foto. Berikutnya masih jarak 80 cm diambil foto botol ukuran 330 ml dengan posisi tegak, tidur dan miring kiri dan miring kanan sebanyak 21 foto. Total citra botol yang diperoleh dari jarak 80 cm adalah 63 citra. Hasil foto *dataset* jarak 80 cm seperti pada Gambar 4.



Gambar 4. Dataset foto jarak 80 cm

Untuk jarak 100 cm diambil foto botol ukuran 1500 ml dengan posisi tegak, tidur dan miring kiri dan miring kanan sebanyak 21 foto. Kemudian jarak 100 cm diambil foto botol ukuran 600 ml dengan posisi tegak, tidur dan miring kiri dan miring kanan sebanyak 21 foto. Berikutnya masih

jarak 100 cm diambil foto botol ukuran 330 ml dengan posisi tegak, tidur dan miring kiri dan miring kanan sebanyak 21 foto. Total citra botol yang diperoleh dari jarak 100 cm adalah 63 citra. Hasil foto *dataset* jarak 100 cm seperti pada Gambar 5.



Gambar 5. Dataset foto jarak 100 cm

Hasil foto botol dikelompokkan menjadi dua *dataset* yaitu *dataset* jarak 100 m dan *dataset* jarak 80 m terlihat bahwa botol ukuran botol yang sama tetapi diambil dari jarak yang berbeda terlihat berbeda.

Setelah foto objek botol selesai diambil, proses berikutnya adalah pelabelan. Pelabelan adalah menentukan kelas dari masing-masing botol yaitu kelas 1,5 L untuk botol ukuran besar, kelas 330 ml untuk botol ukuran sedang dan kelas 330 ml untuk botol ukuran kecil. Pelabelan menggunakan aplikasi *Roboflow* untuk *dataset* jarak 80 cm dan 100 cm secara terpisah, hasil pelabelan seperti pada Gambar 6.

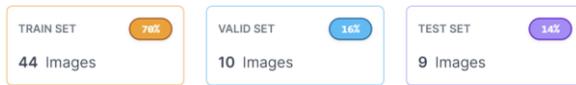
c) Pelabelan



Gambar 6. Proses Pelabelan Dataset

Pada Gambar 6 *dataset* sudah berlabel dan terklasifikasi 1,5L, 600 ml dan 330 ml menjadi data *train* sebanyak 44 citra, data validasi 10 citra dan data testing 9 citra dengan

persentase *split dataset* sebesar 70%, 16% dan 14% seperti pada Gambar 7.



Gambar 7. Persentase *split dataset*

d) Pra proses *dataset*

Untuk meningkatkan performa dan memperkecil waktu pelatihan maka dilakukan *auto orient* dan *resize*. *Auto orient* yang dipilih adalah yang tegak sedangkan *resize* yang diatur yaitu ukuran 640 x 640.

e) Augmentasi

Untuk menambah jumlah *dataset* maka dilakukan proses augmentasi dengan metode *flip horizontal* dan *flip vertikal* dengan rotasi -45° sampai 45° . Dengan proses augmentasi ini *dataset* bertambah menjadi 151 citra untuk masing-masing jarak.

f) Pengkodean YOLOv8

Dari Roboflow juga diperoleh kode python sebagai *input* pada YOLOv8 berupa *file* yml seperti pada contoh Gambar 8.

```
!pip install roboflow

from roboflow import Roboflow
rf = Roboflow(api_key="████████████████████████████████████████")
project = rf.workspace("ug-ppo52").project("botol-100ml")
dataset = project.version(2).download("yolov8")
```

Gambar 8. Kode program *dataset* dengan YOLOv8

3.2 Pembuatan Model

Model dibuat menggunakan pemrograman python dengan *input dataset* yang sudah disiapkan pada Gambar 9. Model dirancang untuk pengambilan citra berjarak 100 m dan 80 m seperti pada Gambar 9.

```
#Untuk 100cm

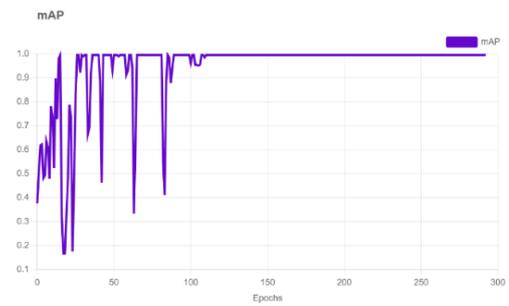
from roboflow import Roboflow
rf = Roboflow(api_key="iLMJYTW71iNq9CHaXJyw")
project = rf.workspace().project("botol-100ml")
model = project.version(1).model

#Untuk 80cm

from roboflow import Roboflow
rf = Roboflow(api_key="iLMJYTW71iNq9CHaXJyw")
project = rf.workspace().project("botol-80cm")
model = project.version(2).model
```

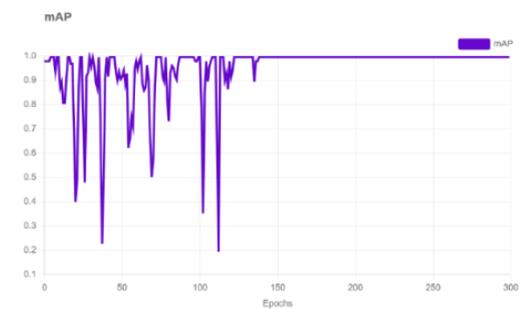
Gambar 9. Kode python menggunakan *Roboflow*

Model untuk jarak 100 m memiliki *mean average precision* (mAP) sebesar 99,5%, *precision* sebesar 97,5% dan *recall* yaitu 100% dengan grafik pada Gambar 10. Pada Gambar 10 dengan *epoch* 300 maka nilai mAP sudah stabil pada *epoch* 125 yaitu mendekati 100%.



Gambar 10. Grafik mAP data latih model 100 cm

Untuk model dengan jarak 80 m memiliki *mean average precision* (mAP) sebesar 99,5%, *precision* sebesar 99,6% dan *recall* yaitu 100% dengan grafik pada Gambar 10. Pada Gambar 11 dengan *epoch* 300 maka nilai mAP sudah stabil pada *epoch* 140 yaitu mendekati 100%.



Gambar 11. Grafik mAP data latih model 80 cm

Kedua model sudah memiliki performa latih baik yaitu dengan nilai tingkat kepercayaan di atas 99,5%.

3.3 Pengujian Model

Tahap terakhir adalah pengujian model dengan data aktual menggunakan metode *confusion matrix*. Kedua model tersebut diuji menggunakan data aktual masing-masing 4 citra. Hasil pengujian seperti pada Tabel 1, citra aktual dari jarak 80 cm diujikan pada model 80 cm dan 100 cm sehingga untuk model 80 cm mengenali secara tepat masing-masing kelas yaitu kelas 1,5L, 600 ml dan 330 ml berbeda dengan hasil jika diterapkan pada model 100 cm yaitu untuk citra 330 ml dikenali sebagai kelas 600 ml sedangkan untuk kelas 1,5L dan 600 ml tepat prediksinya.

Untuk pengujian pada Tabel 2 yaitu citra aktual dari jarak 100 cm diuji ke model 80 cm dan 100 cm sehingga diperoleh hasil untuk model 80 cm hanya satu dari data uji kelas 1,5L diprediksi sebagai kelas 600 ml dan untuk kelas yang lainnya diprediksi secara tepat kelasnya. Untuk citra jarak 100 cm diterapkan pada model 100 cm maka dengan tepat semua data uji diprediksi sesuai kelasnya yaitu 1,5 L, 600 ml dan 330 ml. tetapi hanya yang penting-penting saja.

Tabel 1. Pengujian jarak 80 cm untuk model 80 dan 100 cm

| Jarak | Uji | prediksi | | | |
|--------------------|-------|-------------|-------|--------------|-------|
| | | model 80 cm | | model 100 cm | |
| | | confidence | class | confidence | class |
| aktual 80 cm | 1,5-1 | 0,921 | 1,5L | 0,72 | 1,5L |
| | 1,5-2 | 0,957 | 1,5L | 0,902 | 1,5L |
| | 1,5-3 | 0,963 | 1,5L | 0,878 | 1,5L |
| | 1,5-4 | 0,96 | 1,5L | 0,884 | 1,5L |
| | 600-1 | 0,929 | 600ML | 0,779 | 600ML |
| | 600-2 | 0,938 | 600ML | 0,925 | 600ML |
| | 600-3 | 0,947 | 600ML | 0,93 | 600ML |
| | 600-4 | 0,957 | 600ML | 0,945 | 600ML |
| | 330-1 | 0,931 | 330ML | 0,906 | 600ML |
| | 330-2 | 0,957 | 330ML | 0,69 | 600ML |
| | 330-3 | 0,951 | 330ML | 0,888 | 600ML |
| | 330-4 | 0,945 | 330ML | 0,921 | 600ML |

Tabel 2. Pengujian jarak 100 cm untuk model 80 dan 100 cm

| Jarak | Uji | prediksi | | | |
|---------------------|-------|-------------|-------|--------------|-------|
| | | model 80 cm | | model 100 cm | |
| | | confidence | class | confidence | class |
| aktual 100 cm | 1,5-1 | 0,921 | 600ML | 0,879 | 1,5L |
| | 1,5-2 | 0,957 | 1,5L | 0,923 | 1,5L |
| | 1,5-3 | 0,956 | 1,5L | 0,918 | 1,5L |
| | 1,5-4 | 0,955 | 1,5L | 0,931 | 1,5L |
| | 600-1 | 0,917 | 600ML | 0,914 | 600ML |
| | 600-2 | 0,939 | 600ML | 0,921 | 600ML |
| | 600-3 | 0,959 | 600ML | 0,935 | 600ML |
| | 600-4 | 0,951 | 600ML | 0,932 | 600ML |
| | 330-1 | 0,913 | 330ML | 0,904 | 330ML |
| | 330-2 | 0,929 | 330ML | 0,939 | 330ML |
| | 330-3 | 0,947 | 330ML | 0,948 | 330ML |
| | 330-4 | 0,817 | 330ML | 0,939 | 330ML |

Berdasarkan Tabel 1 dan 2 tahap berikutnya dilakukan pengujian menggunakan *confusion matrix* dengan hasil pada Tabel 3 dan 4.

Tabel 3. Evaluasi Model 80 cm berdasarkan jarak citra

| Jarak Objek Citra | Precision | Recall | F1-Score |
|-------------------|-----------|--------|----------|
| Jarak 80 cm | 1 | 1 | 1 |
| Jarak 100 cm | 0,916 | 0,916 | 0,916 |

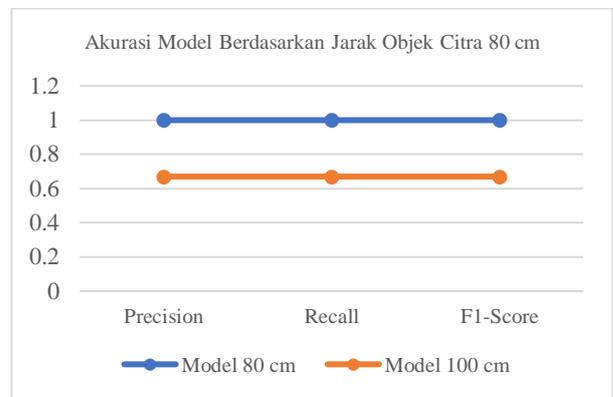
Pada Tabel 3 untuk data uji jarak 80 cm diterapkan pada model 80 cm diperoleh nilai *Precision*, *Recall*, *F1-Score*, adalah 1 atau dimaknai 100%. Untuk data uji jarak 100 cm diterapkan pada model 80 cm diperoleh nilai *Precision*, *Recall*, *F1-Score* adalah 0,916 atau 91,6%.

Tabel 4. Evaluasi Model 100 cm berdasarkan jarak citra

| Jarak Objek Citra | Precision | Recall | F1-Score |
|-------------------|-----------|--------|----------|
| Jarak 80 cm | 0,67 | 0,67 | 0,67 |
| Jarak 100 cm | 1 | 1 | 1 |

Pada Tabel 4 untuk data uji jarak 80 cm diterapkan pada model 100 cm diperoleh nilai *Precision*, *Recall*, *F1-Score* adalah 0,67 atau 67%. Untuk data uji jarak 100 cm diterapkan pada model 100 cm diperoleh nilai *Precision*, *Recall*, *F1-Score* adalah 1 atau 100%.

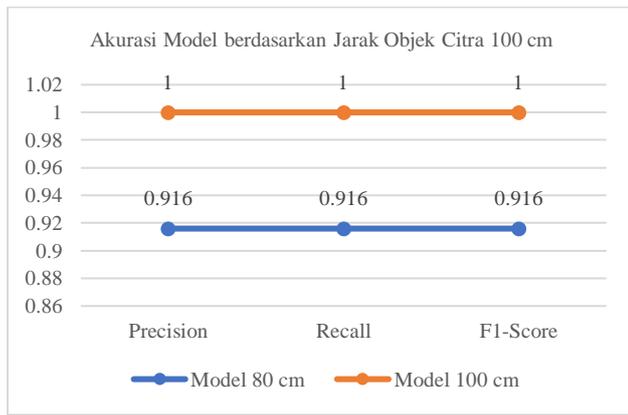
Berdasarkan evaluasi model pada Tabel 3 dan 4, maka dapat disimpulkan performa model berdasarkan jarak pengambilan citra objek botol seperti pada Gambar 9.



Gambar 12. Perbandingan akurasi berdasarkan jarak 80 cm

Pada Gambar 12, jika jarak pengambilan citra berjarak 80 cm diterapkan pada model 80 cm maka memperoleh akurasi yang baik yaitu 100%, tetapi jika diterapkan pada model 100 cm maka menghasilkan akurasi performa 67%.

Pada Gambar 13, untuk pengambilan citra botol pada jarak 100 cm diterapkan pada model 80 cm memiliki performa akurasi sebesar 91,6%, namun jika diterapkan pada model 100 cm memperoleh hasil akurasi 100%.



Gambar 13. Perbandingan akurasi berdasarkan jarak 100 cm

4. KESIMPULAN

Model 80 cm dan model 100 cm sangat baik diterapkan untuk data citra dengan jarak yang sesuai dengan modelnya, seperti untuk data uji jarak 80 cm diterapkan pada model 80 cm maka menghasilkan tingkat akurasi 100%, ini berarti citra dapat mengenali kelasnya dengan tepat yaitu kelas 1,5L, 600 ml dan 330 ml begitu juga untuk data uji dengan jarak 100 cm diterapkan pada model 100 cm. Hasil yang tidak baik terlihat pada data uji dengan jarak 80 cm diterapkan pada model 100 cm yaitu dengan hasil tingkat akurasi 67%, ini bermakna bahwa terdapat beberapa kesalahan prediksi objek citra, sedangkan untuk citra jarak 100 cm diterapkan pada model 80 cm masih cukup baik dengan akurasi 91,6%. Berdasarkan hasil penelitian bahwa jarak pengambilan citra mempengaruhi klasifikasi deteksi objek citra.

Ucapan Terima Kasih

Terima kasih kepada Universitas Muhammadiyah Jakarta melalui LPPM UMJ atas bantuan hibah penelitian ini.

DAFTAR PUSTAKA

[1] Sirojul Munir, Ahmad Adriansyah, Radon Dhelika, "Implementasi Arsitektur Aplikasi MVC pada Perancangan Aplikasi Bank Sampah Berbasis Web," *J. Teknol. Terpadu*, vol. 4, no. 2, hal. 76–81, 2018, doi: <https://doi.org/10.54914/jtt.v4i2.131>.

[2] Imamul Arifin, Reydiko Fakhra Haidi, "Penerapan Computer Vision Menggunakan Metode Deep Learning Pada Perspektif Generasi Ulul Albab," *J. Teknol. Terpadu*, vol. 7, no. 2, hal. 98–107, 2021, doi: <https://doi.org/10.54914/jtt.v7i2.436>.

[3] A. B. Wahyutama dan M. Hwang, "YOLO-Based Object Detection for Separate Collection of Recyclables and Capacity Monitoring of Trash Bins," *Electron.*, vol. 11, no. 9, 2022, doi: 10.3390/electronics11091323.

[4] P. O. Parasian dan F. Utamingrum, "Rancang Bangun Sistem Pengklasifikasi Jenis Sampah Organik dan Sampah Daur Ulang menggunakan Resnet50," vol. 6, no. 4, hal. 2548–964, 2022, [Daring]. Tersedia pada: <http://j-ptiik.ub.ac.id>.

[5] W. L. Mao, W. C. Chen, H. I. K. Fathurrahman, dan Y. H. Lin, "Deep learning networks for real-time regional domestic waste detection," *J. Clean. Prod.*, vol. 344, no. October 2021, hal. 131096, 2022, doi: 10.1016/j.jclepro.2022.131096.

[6] X. Long *et al.*, "PP-YOLO: An Effective and Efficient Implementation of Object Detector," 2020, [Daring]. Tersedia pada: <http://arxiv.org/abs/2007.12099>.

[7] Y. Resnet, K. R. Tanjung, H. Juwiantho, dan J. S. Surabaya, "Klasifikasi Benda Organik dan Anorganik Dengan Metode."

[8] T. L. C. Tran, Z. C. Huang, K. H. Tseng, dan P. H. Chou, "Detection of Bottle Marine Debris Using Unmanned Aerial Vehicles and Machine Learning Techniques," *Drones*, vol. 6, no. 12, hal. 14–16, 2022, doi: 10.3390/drones6120401.

[9] R. A. M. AlShehri dan A. K. J. Saudagar, "Detecting Threats from Live Videos using Deep Learning Algorithms," *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 11, hal. 643–658, 2023, doi: 10.14569/IJACSA.2023.0141166.

[10] H. Lou *et al.*, "DC-YOLOv8: Small-Size Object Detection Algorithm Based on Camera Sensor," *Electron.*, vol. 12, no. 10, hal. 1–14, 2023, doi: 10.3390/electronics12102323.

[11] M. Safaldin, N. Zaghden, dan M. Mejdoub, "An Improved YOLOv8 to Detect Moving Objects," *IEEE Access*, vol. 12, no. May, hal. 59782–59806, 2024, doi: 10.1109/ACCESS.2024.3393835.

[12] P. Jiang, D. Ergu, F. Liu, Y. Cai, dan B. Ma, "A Review of Yolo Algorithm Developments," *Procedia Comput. Sci.*, vol. 199, hal. 1066–1073, 2021, doi: 10.1016/j.procs.2022.01.135.

[13] R. Hesananda, D. N. Simatupang, N. Wiliani, I. Technology, dan S. Program, "Cloth Bag Object Detection Using The Yolo Algorithm V5," vol. 18, no. 2, 2022, doi: 10.33480/pilar.v18i2.3019.

[14] Jupiyandi Saniputra, F. R. Pratama, dan Yoga Dharmawan, "Pengembangan Deteksi Citra Mobil Untuk Mengetahui Jumlah Tempat Parkir Menggunakan Cuda Dan Modified Yolo Development of Car Image Detection To Find Out the Number of Parking Space Using Cuda and Modified Yolo," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 6, no. 4, hal. 413–419, 2019, doi: 10.25126/jtiik.201961275.

[15] L. Yu, M. Qian, Q. Chen, F. Sun, dan J. Pan, "An Improved YOLOv5 Model: Application to Mixed Impurities Detection for Walnut Kernels," *Foods*, vol. 12, no. 3, 2023, doi: 10.3390/foods12030624.