

## **BAB V**

### **KESIMPULAN DAN SARAN**

#### **5.1 Kesimpulan**

Berdasarkan hasil penelitian ini dilakukan untuk mendeteksi objek sampah yang terdiri dari 5 jenis sampah dengan memanfaatkan model YOLOv8 yang dilakukan optimasi hyperparameter OFAT dan *Random Search*. Penelitian ini berhasil membangun sistem deteksi objek sampah berbasis YOLOv8 yang mampu mengklasifikasikan dan mendeteksi jenis sampah secara otomatis pada citra input. Model dilatih menggunakan dataset yang telah dilakukan *pre-processing* agar mampu mengenali variasi bentuk objek. Proporsi dataset yang digunakan pada penelitian ini yaitu 70% data training, 20% data validasi dan 10% data uji.

Proses optimasi hyperparameter yang dilakukan menggunakan OFAT (One Factor At a Time) dan *Random Search* terbukti mampu meningkatkan performa model YOLOv8 dibandingkan model default. Hasil pengujian deteksi menunjukkan bahwa model hasil optimasi (M2) memiliki rata-rata nilai sebesar 89%, sementara pada model default (M1) memiliki rata-rata nilai sebesar 75,6%. Peneliti membandingkan dengan model YOLOv8 default untuk mengetahui seberapa pengaruh dampak dari penggunaan optimasi hyperparameter menggunakan OFAT dan *Random Search*.

Berdasarkan hasil pengujian pada proporsi data 70:20:10, terdapat 3 model yang dilakukan pengujian yaitu YOLOv8 Default, YOLOv8 OFAT, dan YOLOv8 OFAT + RS. Model YOLOv8 default menghasilkan precision sebesar 0.919, recall 0.752, F1-Score 0.826 dan mAP 0.844. Pada model YOLOv8 OFAT memiliki precision 0.945, recall 0,734, F1-Score 0,824 dan mAP 0,854. Sementara pada model YOLOv8 OFAT + RS memiliki precision 0.874, recall 0.797, F1-Score 0.875, dan mAP 0.875. Walaupun terdapat penurunan pada metrik precision dibandingkan 2 model lain, namun pada metrik lainnya model YOLOv8 OFAT + RS lebih unggul dibandingkan model lainnya. Hal ini menunjukkan bahwa proses optimasi hyperparameter menggunakan OFAT dan *random search* berhasil memberikan peningkatan sensitivitas model terhadap deteksi objek.

## 5.2 Saran

Berdasarkan hasil penelitian ini, terdapat beberapa saran yang dapat dipertimbangkan untuk pengembangan penelitian selanjutnya. Pertama, untuk meningkatkan jumlah dataset dan variasi dataset khususnya pada sudut pengambilan gambar dan kondisi sampah yang berbeda seperti saling bertumpukan atau berserakan. Hal ini penting agar model lebih mampu dalam mendekripsi objek secara akurat di lingkungannya.

Kedua, dapat mencoba untuk menggunakan arsitektur YOLO versi lain mengingat YOLO memiliki beberapa versi dan selalu berkembang. Tujuannya sendiri yaitu untuk mengetahui pengaruh ukuran dan kompleksitas model terhadap waktu pelatihan dan tingkat akurasi deteksi. Atau juga dapat menggunakan algoritma lainnya yang memang digunakan untuk deteksi objek.

Ketiga, dapat mengeksplorasi metode optimasi lainnya yang dapat digunakan pada model YOLO yang berpotensi untuk menemukan kombinasi hyperparameter terbaik. Eksplorasi metode optimasi hyperparameter lainnya digunakan untuk membantu menemukan konfigurasi hyperparameter yang sebelum digunakan pada tahap pelatihan data guna menghindari percobaan pencarian konfigurasi hyperparameter secara manual.