JURNAL TELISKA **P-ISSN: 2085-0786**
Volume 18 No II Juli 2025 Page 15-27 **E-ISSN: 2654-2765**

SISTEM *MACHINE LEARNING YOU ONLY LOOK ONCE* UNTUK IDENTIFIKASI PELAKU PEMBUANG SAMPAH SECARA *REAL-TIME*

Muhammad Jefi Wahyuda
Teknik Elektro, Jurusan Teknik Elektro – Politeknik Negeri Sriwijaya
yudaplg53@gmail.com

ABSTRAK

Penelitian ini mengembangkan sebuah sistem rekognisi pelaku pembuang sampah sembarangan secara *real-time* menggunakan teknik pemrosesan citra berbasis model *You Only Look Once (YOLO*). Masalah pembuangan sampah sembarangan merupakan isu lingkungan yang serius dan memerlukan penanganan segera untuk menjaga kebersihan serta kesehatan masyarakat. Sistem yang diusulkan bertujuan untuk mendeteksi dan mengidentifikasi pelaku pembuang sampah sembarangan secara otomatis melalui analisis video yang direkam oleh kamera pengawas. Hasil uji coba menunjukkan bahwa sistem yang dikembangkan dapat secara efektif mendeteksi pelaku pembuangan sampah dengan akurasi 100% pada saat keadaan terang dan 80% pada saat keadaan gelap secara langsung. Setelah dipasang, sistem ini diharapkan dapat membantu pemerintah dan lembaga terkait mengurangi tingkat pembuangan sampah sembarangan dan meningkatkan kesadaran masyarakat akan pentingnya menjaga lingkungan bersih.

Kata kunci : Rekognisi, *Real-Time*, *Image Processing*, Sampah Sembarangan, *You Only Look Once.*

ABSTRACT

The This research develops a real-time litterer recognition system using image processing techniques based on the You Only Look Once (YOLO) model. The problem of littering is a serious environmental issue that requires immediate attention to maintain cleanliness and public health. The proposed system aims to automatically detect and identify litterers through video analysis recorded by surveillance cameras. The test results show that the developed system can effectively detect littering perpetrators with 100% accuracy in bright conditions and 80% in dark conditions directly. Once installed, this system is expected to help the government and related institutions reduce the level of littering and increase public awareness of the importance of maintaining a clean environment.

Keywords: *Recognition, Real-Time, Image Processing, garbage indiscriminately, You Only Look Once.*

1. PENDAHULUAN

Pembuangan sampah sembarangan merupakan salah satu tantangan lingkungan yang signifikan di berbagai kota besar di dunia, termasuk di Indonesia. Praktik ini tidak hanya merusak keindahan lingkungan, tetapi juga menimbulkan dampak negatif terhadap kesehatan masyarakat dan ekosistem. Upaya pemerintah dan berbagai organisasi lingkungan untuk mengatasi masalah ini sering kali terkendala oleh kurangnya sistem pengawasan yang efektif dan efisien. Oleh karena itu, diperlukan solusi inovatif yang dapat membantu dalam. Mendeteksi dan menindak pelaku pembuangan sampah sembarangan secara cepat dan tepat.

Seiring dengan perkembangan teknologi, khususnya dalam bidang kecerdasan buatan *Artificial Intelligence* dan *Image Processing*, kini tersedia berbagai metode yang dapat digunakan untuk mengatasi masalah ini. Salah satu metode *You Only Look Once (YOLO),* sebuah algoritma deteksi objek yang mampu bekerja dalam waktu nyata dengan akurasi tinggi. *YOLO* memiliki keunggulan dalam hal kecepatan dan efisiensi, karena mampu mendeteksi objek dalam satu kali pemrosesan gambar atau video.

Penelitian ini bertujuan untuk mengembangkan sistem rekognisi pelaku pembuang sampah sembarangan secara real-

DOI : 10.5281/zenodo.15855681

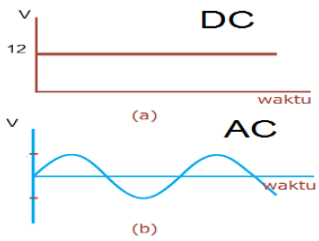
P-ISSN: 2085-0786
E-ISSN: 2654-2765

time dengan memanfaatkan teknologi pemrosesan citra berbasis *YOLO*. Sistem yang diusulkan ini dirancang untuk mendeteksi tindakan pembuangan sampah sembarangan dari video yang diambil oleh kamera pengawas, kemudian mengidentifikasi pelaku melalui rekognisi wajah. Dengan adanya sistem ini, diharapkan dapat memudahkan pihak berwenang dalam mengidentifikasi dan menindak pelaku pembuangan sampah sembarangan serta meningkatkan kesadaran masyarakat akan pentingnya menjaga kebersihan lingkungan.

2. TINJAUAN PUSTAKA

2.1. *Power Supply*

Perangkat yang mengubah energi menjadi bentuk lain disebut "catu daya". Ini biasanya terdiri dari trafo, penyearah, dan penghalus tegangan, dan berfungsi sebagai sumber tenaga listrik untuk elektronik, seperti baterai atau baterei. Namun, itu juga dapat merujuk pada perangkat yang mengubah energi dari sumber lain (misalnya, mekanik, kimia, atau surya) menjadi energi listrik. Komponen utama seperti transformator, dioda, dan kondensator biasanya membentuk prinsip rangkaian catu daya. Dua jenis daya yang tersedia adalah tegangan bolak-balik dan tegangan searah.



Gambar 1. Tegangan DC dan AC [2]

Dalam sumber AC, rangkaian penyearah yang dibuat oleh diode memungkinkan sumber DC untuk disearahkan dari sumber AC. Pada sumber AC, tegangan kadang-kadang berayun ke kutub positif atau negatif saja [2].

2.2. *Mini* PC

Mini PC adalah jenis komputer multi-user kelas menengah yang berada di bawah kelas mainframe dan sistem komputer single-user seperti komputer pribadi. Dalam dunia modern, istilah "komputer mini" telah dianggap ketinggalan zaman, dan istilah seperti "komputer menengah" IBM, yang merujuk pada sistem midrange, telah digunakan. Komputer mini biasanya lebih besar dan dapat menangani lebih dari satu orang karena microprocessor yang digunakan untuk memproses data jauh lebih kuat daripada *microprocessor* PC. Beberapa contohnya adalah mini PC seperti Raspberry Pi, Banana Pi, Orange Pi, dan Cubie Board [3].



Gambar 2. Mini PC [3]

Adapun spesifikasi mini PC yang digunakan pada penelitian ini seperti tabel berikut:

Tabel 1. Spesifikasi Mini PC

Spesifikasi	Detail
CPU	Intel HD Graphics 500
RAM	8 GB
Power Input	12V
Power Adaptor	10V - 240V / 50 HZ – 60 HZ
Decoder Format	H.263,H.264,H.265,HD MPEG4
Video Format	3GP,AVI,FLV,MKV,MOV,MP4,MPG,OGG,VOB,WMV
Audio Format	AAC,AC3,APE,FLAC,M4A,MP2,MP3,WAV,WMA
Photo Format	BMP,GIF,JPEG,JPG,PNG,TIFF

2.3. Router

Proses routing dilakukan oleh alat yang berfungsi sebagai router untuk mengirimkan paket data ke lokasi tertentu melalui jaringan atau Internet. Proses routing terjadi pada lapisan ketiga, atau jaringan, dari stack

DOI : 10.5281/zenodo.15855681

P-ISSN: 2085-0786
E-ISSN: 2654-2765

protokol *Open Systems Interconnection* (OSI). Router memiliki fitur DHCP (*Dynamic Host Configuration Protocol),* yang memungkinkan kita membagi alamat IP dengan mengatur DHCP. Fitur lain Router adalah NAT (*Network Adress Translator*), yang memungkinkan pembagian alamat IP atau koneksi internet ke alamat IP lain.

Router digunakan untuk mengoneksikan dua jaringan dengan berbagai jenis media. Salah satu contohnya adalah router nirkabel, yang biasanya dapat menghubungkan komputer melalui radio dan mendukung kabel UTP. Selain itu, mereka juga dapat membagi sebuah jaringan besar ke dalam beberapa subnetwork untuk meningkatkan efisiensi dan membuatnya lebih mudah untuk diawasi [4].

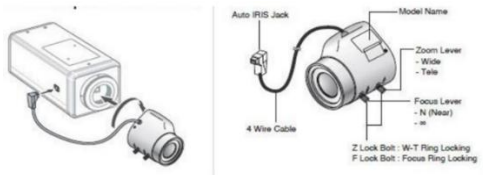


Gambar 3. Router [4]

2.4. *Closed Circuit Television* (CCTV)

Kamera video (CCTV) mengirimkan signal video ke beberapa monitor. Sistem CCTV biasanya terdiri dari komunikasi antara kamera dan monitor, tetapi teknologi modern terdiri dari kamera yang dapat melakukan berbagai gerakan, seperti putar, tekuk, dan zoom.

Selain itu, cctv memiliki kemampuan untuk dioperasikan dari jarak jauh melalui ruang kontrol atau melalui komputer pribadi atau telepon genggam, serta dapat terhubung ke jaringan LAN, Wi-Fi, dan internet. Akibatnya, sistem CCTV dapat melakukan pengawasan sepanjang hari untuk memenuhi kebutuhan pengguna [5].



Gambar 4. *Closed Circuit Television* (CCTV) [5]

Adapun spesifikasi CCTV yang digunakan pada penelitian ini seperti tabel berikut:

Tabel 1. Spesifikasi Mini PC

Spesifikasi	Detail
Resolution	4 MP
Image Sensor	1/3” Color CMOS
Image Compression	H.265
IR	Distance 10M
Audio	Build-in Mic & Speak
Micro SD Card	Up to 128GB
Connection	WiFi 2.4 GHz
Working Temp	0 °C ~ 45 ° C
Working Humidity	10% - 95

2.5. *Image Processing*

Salah satu proses yang dapat digunakan untuk memproses gambar dua dimensi adalah pemrosesan gambar. Pemrosesan gambar juga dapat mencakup semua tindakan yang dilakukan untuk memperbaiki, menganalisis, atau mengubah gambar. Konsep dasar pemrosesan suatu objek menjadi gambar menggunakan pengolahan citra berasal dari kemampuan indera penglihatan manusia. Ide ini kemudian terkait dengan kemampuan otak manusia. Selama bertahun-tahun, pengolahan gambar telah digunakan dengan tingkat keberhasilan yang relatif tinggi. Pengolahan gambar mencakup banyak bidang ilmu, termasuk fotografi, matematika, elektronik, optik, dan teknologi komputer. Kebanyakan kali, tujuan pengolahan gambar adalah untuk mengubah atau menganalisis gambar sehingga dapat dikomunikasikan dengan lebih baik dengan data baru [6].

3. METODOLOGI

Penelitian ini dilakukan melalui beberapa tahapan utama: pengumpulan data, pelabelan data, pelatihan model *YOLO*, implementasi rekognisi wajah, serta pengujian dan evaluasi sistem.

1. Pengumpulan Data
   Data Foto/video yang berisi tindakan pembuangan sampah sembarangan dikumpulkan dari kamera pengawas di

DOI : 10.5281/zenodo.15855681

P-ISSN: 2085-0786
E-ISSN: 2654-2765

tempat umum. Foto/Video mencakup berbagai kondisi pencahayaan dan sudut pandang untuk memastikan model dapat beradaptasi dengan berbagai situasi.

2. Pelabelan Data
   Foto/Video yang telah dikumpulkan dilabeli secara manual untuk menandai tindakan pembuangan sampah dan objek relevan lainnya. Pelabelan dilakukan menggunakan perangkat lunak anotasi, dan data yang telah dilabeli dibagi menjadi data pelatihan dan data pengujian.
3. Pelatihan Model YOLO
   Data pelatihan digunakan untuk melatih model YOLO dengan *framework deep learning*, seperti Darknet. *Hyperparameter* model disesuaikan untuk mengoptimalkan kinerja deteksi objek. Model dilatih untuk mengenali tindakan pelaku pembuangan sampah dalam berbagai skenario dan kondisi lingkungan.
4. Implementasi Rekognisi Wajah
   Setelah model *YOLO* dapat merekognisi tindakan pembuangan sampah dengan akurat, algoritma rekognisi wajah seperti *FaceNet* atau *OpenFace* diintegrasikan dengan sistem. Wajah pelaku yang tertangkap kamera diekstraksi dan dibandingkan dengan database wajah yang sudah ada untuk identifikasi.
5. Pengujian dan Evaluasi Sistem
   Sistem diuji menggunakan data pengujian yang sebelumnya tidak digunakan dalam pelatihan untuk mengevaluasi akurasi deteksi dan identifikasi. Metrik evaluasi seperti *precision, recall, dan accuracy* digunakan untuk menilai kinerja. Pengujian juga mencakup evaluasi performa sistem dalam kondisi *real-time.*
6. Implementasi dan Integrasi Sistem:
   Sistem yang teruji diimplementasikan di lingkungan nyata. Kamera pengawas dipasang di lokasi strategis, dan sistem rekognisi diintegrasikan dengan telegram untuk pemantauan dan penindakan langsung. Antarmuka pengguna memungkinkan petugas memantau, meninjau, dan menindak pelanggaran secara *real-time.*

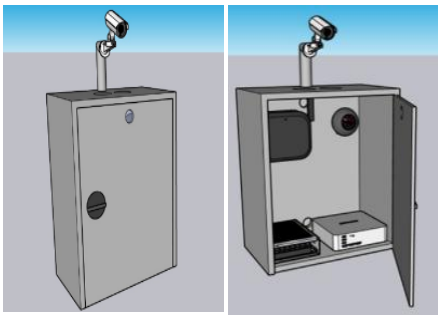
3.1. Perancangan Perangkat

a. Perancangan Perangkat Mekanik

Perancangan desain mekanik adalah langkah penting dalam membangun sistem yang menggunakan teknologi pemrosesan gambar *You Only Look Once* (*YOLO*) untuk mendeteksi pembuang sampah secara real-time. Pada titik ini, dilakukan pembuatan kerangka sistem fisik yang diperlukan. Untuk menjamin operasi sistem yang optimal tanpa mengganggu monitoring pelaku pembuang sampah, faktor ukuran dan proporsi komponen sangat penting.

Pemilihan bahan, struktur, dan tata letak komponen adalah bagian dari desain mekanik. Untuk menjaga kinerja sistem, setiap komponen harus ditempatkan secara efisien. Mengingat variasi lingkungan yang mungkin terjadi, seperti di dekat perairan atau taman, penggunaan material yang kuat dan tahan lama sangat penting. Perangkat keras sistem terdiri dari satu komponen yang dirancang untuk memantau lingkungan sekitar lokasi. Setiap komponen dirancang untuk memenuhi kebutuhan dan aktivitas pemantauan lingkungan. Sistem yang mendeteksi pembuang sampah di masyarakat secara *real-time* harus dirancang dengan baik untuk beroperasi dengan baik dan akurat.

Desain juga mempertimbangkan kemudahan perawatan dan pemeliharaan. Untuk memudahkan proses perbaikan atau penggantian jika diperlukan, aksesibilitas ke komponen penting dirancang. Bentuk mekanik dari sistem deteksi ini bisa dilihat pada Gambar 3.1



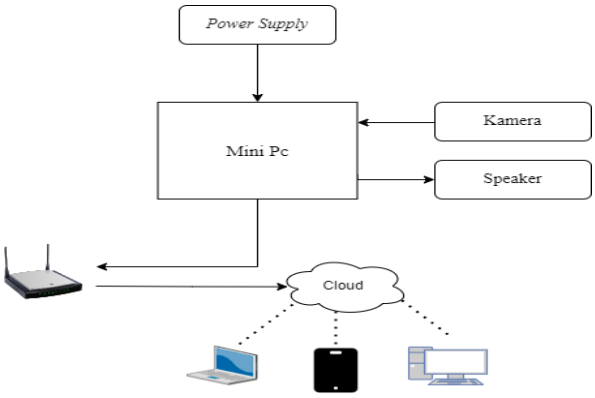
Gambar 5. Perangkat Mekanik

DOI : 10.5281/zenodo.15855681

P-ISSN: 2085-0786
E-ISSN: 2654-2765

b. Blok Diagram

Salah satu komponen terpenting dalam perancangan suatu alat adalah blok diagram rangkaian; jika disusun sebaik mungkin, mereka akan menghasilkan suatu sistem yang dapat berfungsi sesuai dengan prinsip kerja dari rancangan alat yang dibuat. Ada dua jenis sampah yang diletakkan di dekat perairan dan di taman, menunjukkan perancangan sistem deteksi manusia untuk membuang sampah secara sembarangan menggunakan pengolahan gambar berbasis mesin. Mini PC terhubung ke sumber daya, yang berfungsi sebagai daya sistem. Selain itu, Mini PC memiliki kamera webcam, yang digunakan untuk mengidentifikasi pelaku dan melakukan deteksi. Selain itu, output dari sistem ini adalah tampilan program yang memungkinkan rekognisi pelaku pembuang sampah secara *real-time* dan melalui web. Diagram blok sistem rekognisi pelaku pembuang sampah pada Gambar 3. 2.



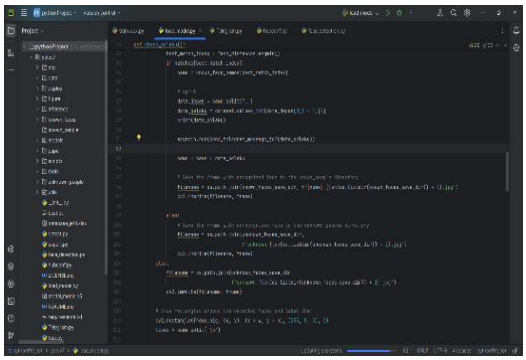
Gambar 6. Blok Diagram Perangkat

c. Perancangan *Software*

Selama proses penelitian sistem ini, perancangan software adalah komponen penting. Ada beberapa program yang digunakan untuk membantu penulis dalam proses penyempurnaan alat, mulai dari pembuatan program kontrol dengan beberapa aplikasi yang menggunakan bahasa *python*. Nanti, simulasi dan pengambilan data akan dilakukan dengan beberapa aplikasi.

Telegram adalah hasil akhir dari pengembangan *Internet of Things* yang melacak pembuang sampah secara real time. Perancangan telegram digunakan pada perangkat ini untuk memantau hasil pendeteksian dari kamera yang terpasang pada sistem. Telegram berfungsi sebagai antarmuka untuk menampilkan data dan informasi yang dihasilkan oleh kamera yang terpasang pada sistem. Dengan menggunakannya, pengguna dapat mengakses dan melihat hasil pendeteksian aktivitas manusia, termasuk aktivitas membuang sampah, secara *real-time.*

Rangkaian perangkat sistem yang dirancang untuk mengidentifikasi pelaku pembuang sampah secara real time menggunakan pengolahan gambar *You Only Look Once* akan terhubung ke internet, yang memungkinkan pemantauan mudah dan akses jarak jauh ke hasil kerja sistem. Dalam lingkungan yang diinstal oleh sistem ini, Telegram akan menampilkan aktivitas dan hasil deteksi. Untuk membangun *Internet of Things* pada sistem ini, Template *Argon* dan *PyCharm*. Pada Gambar 3.3. Merupakan Tampilan *PyCharm.*



Gambar 7. Tampilan *PyCharm*

4. HASIL DAN PEMBAHASAN

4.1 Data Training

Pada proses ini, 860 data dilatih, dengan porsi 80 persen, 10 persen, dan 10 persen. Data dibagi menjadi tiga bagian: pelatihan, pengujian, dan validasi. Pembagian ini dilakukan untuk mengoptimalkan kinerja dan generalisasi model yang akan dibangun. Pada tahap pelatihan, di mana 80 persen data digunakan, jumlah data yang lebih besar digunakan untuk membantu

DOI : 10.5281/zenodo.15855681

P-ISSN: 2085-0786
E-ISSN: 2654-2765

model belajar dan memahami pola dan fitur data dengan lebih baik. Semakin banyak data yang digunakan untuk pelatihan, semakin baik model dapat menyesuaikan diri dengan variasi dalam data dan membuat representasi masalah yang lebih akurat.

Setelah pelatihan, model diuji kinerjanya dengan data yang tidak pernah digunakan selama pelatihan pada tahap pengujian di mana sepuluh persen data digunakan sebagai data uji. Tujuan dari pengujian ini adalah untuk mengetahui seberapa baik model dapat menggeneralisasi data yang belum pernah dilihat sebelumnya. Tanpa "pengetahuan sebelumnya" tentang data pengujian, ini dapat dilakukan secara objektif.

Selain itu, pada tahap validasi dengan 10% data, dataset digunakan untuk menyempurnakan dan menyesuaikan parameter model. Validasi data membantu mengevaluasi kinerja model selama proses pelatihan dan membantu menghindari overfitting, yaitu ketika model terlalu terfokus pada data pelatihan dan tidak dapat menggeneralisasi data baru. Validasi dataset juga membantu dalam memilih model terbaik dari banyak model yang telah dilatih dengan parameter yang berbeda.

Perbedaan antara jumlah data yang diperlukan untuk pelatihan model dan evaluasi kinerjanya menyebabkan pembagian dataset ini. Hal ini memungkinkan untuk mengimbangi pelatihan model yang baik dengan evaluasi yang objektif, yang menghasilkan model pengajaran mesin yang lebih baik.

Saat *machine learning* bekerja*, algoritma* yang telah didefinisikan mencari pola dari setiap kelas pada data yang dilatih. Ini dikenal sebagai proses pelatihan. Proses ini berkonsentrasi pada mengoptimalkan bobot dan bias dalam jaringan *neural* agar model dapat merekognisi pelaku dengan akurat saat membuang sampah. Proses pelatihan ini sangat penting untuk memastikan bahwa model dapat mengenali secara *real-time* menggunakan metode *YOLO.*

Setelah pelatihan selesai, model yang dilatih dapat digunakan untuk rekognisi pelaku secara *real-time* menggunakan metode *YOLO*, yang memungkinkan model mendeteksi objek dalam video dengan akurat. Proses identifikasi ini sangat penting untuk memastikan bahwa model dapat merekognisi pelaku pembuang sampah dengan akurat, sehingga sistem rekognisi pelaku pembuang sampah secara *real-time* dapat berfungsi dengan baik. Menjalankan perintah pelatihan model bisa dilihat pada Gambar 4. 1.

```
#start training
!python train.py --workers 1 --device 0 --batch-size 16 --epochs 20
--data data/face.yaml --cfg cfg/training/yolov7-face.yaml
--img 640 640 --hyp data/hyp.scratch.face.yaml --name yolov7_face
--weights yolov7_training.pt
```

Gambar 8. Perintah Pelatihan Model

Tujuan dari script Python yang disebut "train.py" adalah untuk mengajarkan model deteksi objek yang menggunakan arsitektur *YOLOv7* dengan data wajah dan data diri. Pelatihan akan dilakukan dalam 20 epoch, dengan 16 sampel diproses dalam satu batch setiap epoch. Selama proses pelatihan, satu pekerja (worker) akan memuat data, dan pelatihan dilakukan pada perangkat GPU dengan nomor 0.

Untuk pelatihan, model YOLOv7 digunakan dengan konfigurasi arsitektur yang diatur dalam file *"yolov7-trash.yaml"*. Dataset yang digunakan untuk pelatihan juga diatur dalam file "trash.yaml," dan ukuran gambar diubah menjadi 640 x 640 piksel untuk memenuhi kebutuhan model.

File *"hyp.scratch.trash.yaml"* berisi *hyperparameter* yang memengaruhi proses pelatihan, seperti kecepatan belajar dan momentum. File *"yolov7_training.pt"* berisi bobot model awal, yang digunakan sebagai titik awal pelatihan.

Akan ada folder dengan nama eksperimen *"yolov7_face"* di mana hasil pelatihan dan bobot model yang diperbarui akan disimpan. Analisis lebih lanjut diperlukan untuk mengetahui seberapa efektif pelatihan dan kinerja model. Ini harus dilakukan dengan memeriksa *log* pelatihan dan hasil deteksi pada dataset pengujian yang relevan. Kualitas dataset, kompleksitas model, pengaturan

DOI : 10.5281/zenodo.15855681

P-ISSN: 2085-0786
E-ISSN: 2654-2765

hyperparameter, dan tujuan dari tugas deteksi objek yang dihadapi akan menentukan kesuksesan pelatihan dan kinerja model.

Setelah pelatihan selesai, hasil penilaian yang diprediksi akan ditampilkan dan model akan dibuat untuk menggunakan kamera CCTV untuk merekognisi pelaku. Hasil prediksi pengujian atau hasil uji coba suatu model atau sistem disebut sebagai hasil prediksi pengujian. Saat melakukan pengujian terhadap model atau sistem, input khusus diberikan, dan hasil prediksi atau keluaran yang dihasilkan oleh model atau sistem diamati. Hasil ini dapat berupa nilai prediksi, klasifikasi, atau nilai objek yang ditemukan, dan digunakan untuk menilai kinerja dan akurasi model. Hasil tes prediksi menunjukkan kecepatan 14.5/13.6/28.1 ms dengan ukuran batch inference 32, dapat dilihat pada Tabel 1.

Tabel 1. *Predict Result Testing*

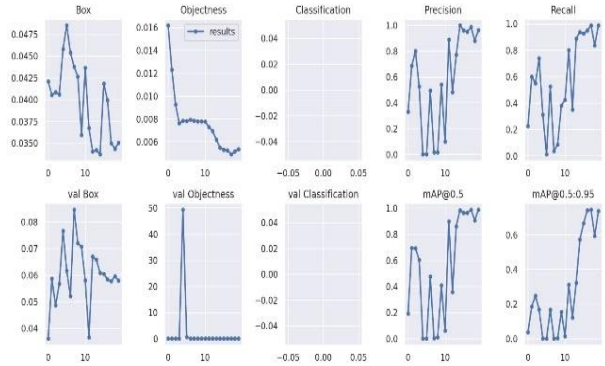
Class	Precision	Recall	mAP 50	mAP 95
All	0.987	0.987	0.987	0.744

Hasil pengujian model deteksi objek yang menggunakan *YOLO (You Only Look Once)* pada dataset ditunjukkan dalam data tabel. Parameter deteksi objek yang sangat penting adalah kecepatan inferensi, terutama untuk aplikasi real-time. Menurut data, waktu inferensi rata-rata 14.5 milidetik (ms) untuk setiap gambar menunjukkan bahwa model dapat mendeteksi objek dengan cepat. Selain itu, waktu inferensi minimum adalah 13.6 ms, yang menunjukkan bahwa beberapa gambar bahkan dapat ditemukan dalam waktu yang sangat singkat, waktu inferensi maksimum adalah 28.1 ms, yang menunjukkan bahwa ada beberapa situasi di mana waktu inferensi bisa sedikit lebih lama.

Precision adalah ukuran ketepatan sistem dalam mengenali objek. Nilai precision untuk semua kelas adalah 0.987, yang menunjukkan bahwa model memiliki kemampuan mengenali objek yang cukup tepat.

Nilai *Recall* 0,955 untuk semua kelas, menunjukkan kemampuan sistem untuk menemukan semua kasus yang relevan (objek yang sebenarnya). Nilai pengembalian yang tinggi menunjukkan bahwa model dapat menemukan sebagian besar objek yang ada pada dataset.

Selanjutnya, mAP *(mean Average Precision)* adalah ukuran performa deteksi secara keseluruhan. Dengan pertimbangan berbagai nilai ambang batas *IoU (Intersection over Union)* yang digunakan dalam evaluasi deteksi, mAP pada *IoU* 0.50 adalah 0,987 untuk semua kelas dan mAP pada *IoU* 0.95 adalah 0,744 untuk semua kelas. Secara keseluruhan, berdasarkan hasil mAP 50, model *YOLO* menunjukkan kinerja yang baik dalam mendeteksi objek dengan nilai mAP 50 sebesar 0.987, yang menunjukkan bahwa model dapat mengenali objek dalam gambar dengan akurasi yang tinggi dan *Recall* yang baik. Nilai mAP ini menunjukkan bahwa model dapat mengenali objek dengan tingkat presisi yang tinggi. Kecepatan inferensi yang baik dalam performa deteksi objek seperti pada Gambar 4.2.



Gambar 9. Kurva Training

Gambar 4.2 menunjukkan tiga jenis kurva yang berbeda: *loss* kotak, *loss* objek, dan *loss* klasifikasi. *Loss* kotak menunjukkan seberapa baik algoritma dapat menentukan lokasi pusat sebuah objek dan seberapa baik kotak batas yang diprediksi menutupi sebuah objek. Probabilitas bahwa sebuah objek berada dalam suatu wilayah tertentu yang diajukan dikenal sebagai objeknya. *Objectness* tinggi menunjukkan kemungkinan besar jendela gambar mengandung objek. *Loss* klasifikasi tidak memberikan gambaran kurva dikarenakan

DOI : 10.5281/zenodo.15855681

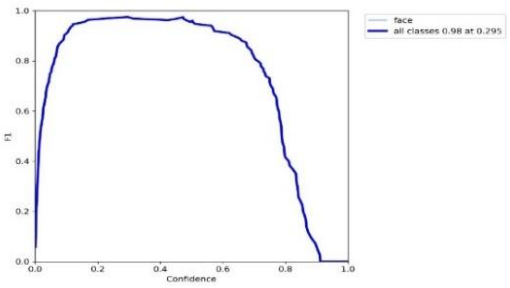
P-ISSN: 2085-0786
E-ISSN: 2654-2765

kelas yang dilatih hanya satu objek kelas yaitu objek wajah.

Sebelum mencapai titik datar setelah sekitar 20 epoch, model tersebut mengalami peningkatan yang cepat dalam hal presisi, *recall,* dan presisi rata-rata sebelum mencapai titik datar setelah 20 epoch. Namun, *loss* kotak dan objek dari data validasi juga menurun setelah 20 epoch. yang akan menjadi best weight yang nantinya akan digunakan untuk menjalankan CCTV untuk merekognisi pelaku pembuang sampah sembarangan secara *real-time*.

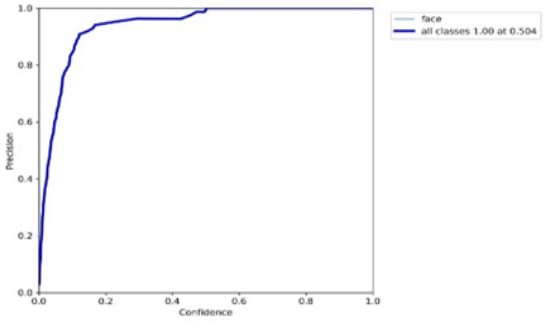
Kurva F1, kurva *precision*, dan kurva *Recall* juga akan terlihat. Model *YOLO* yang telah dibuat sangat baik dalam mendeteksi objek. Dengan nilai F1 sebesar 0.98 pada *threshold* (ambang batas) sebesar 0.295, evaluasi menggunakan metrik F1 menunjukkan hasil yang mengesankan. Nilai F1 adalah metrik yang menggabungkan presisi dan *Recall*, dan memberikan gambaran tentang kemampuan model untuk mengklasifikasikan dan menemukan objek dengan keseimbangan yang baik antara ketepatan dan ketangkapan deteksi.

Model ini sangat baik dalam merekognisi pelaku sampah dalam gambar atau video. Itu juga dapat mendeteksi objek lain dalam dataset, yang mencakup berbagai kategori. Kesuksesan model dalam memperoleh nilai F1 yang tinggi menunjukkan bahwa model ini dapat diandalkan untuk tugas-tugas deteksi objek yang beragam dan kompleks. Ambang batas sebesar 0.295 membantu mengatur tingkat kepercayaan atau ketelitian dalam mengklasifikasikan deteksi objek, sehingga model dapat membuat keputusan yang lebih bijaksana dan efisien. Kurva F1 dapat ditampilkan pada Gambar 4.3.



Gambar 10. Kurva F1

Dengan menggunakan kurva *precision*, kinerja model *YOLO* dievaluasi. Ini menunjukkan bagaimana presisi model berubah ketika berada di threshold, atau ambang batas. Hasil penilaian menunjukkan bahwa model *YOLO* memberikan prediksi positif yang sangat baik pada tingkat ambang sebesar 0,504, dan nilai presisi mencapai 1.00. Semua objek yang diidentifikasi oleh model sebagai positif benar-benar relevan, dengan presisinya 1.00. Hal ini menunjukkan bahwa model memiliki kemampuan untuk mengenali objek yang telah ditentukan dengan akurat. Kurva presisi ini membantu dalam menentukan tingkat kepercayaan atau ketelitian yang diperlukan untuk mengklasifikasikan deteksi objek sebagai positif atau negatif. Model *YOLO* memiliki nilai presisi yang tinggi dan dapat memberikan hasil prediksi yang akurat dan relevan untuk objek tertentu. Tingkat ambang batas 0.504 menunjukkan bahwa model mengklasifikasikan objek dengan sangat selektif untuk mendapatkan hasil yang akurat. Secara keseluruhan, hasil evaluasi menunjukkan bahwa model *YOLO* mendeteksi objek dengan sangat baik. Kurva *Precision* dapat dilihat pada Gambar 4. 4.



Gambar 11. Kurva *Precision*

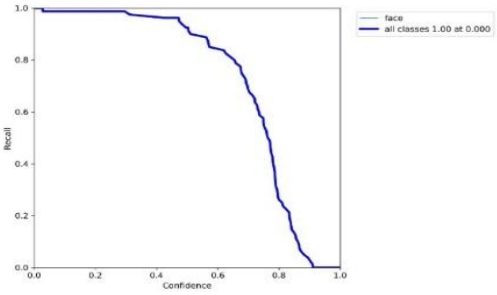
Hasil evaluasi model *YOLO* menunjukkan kurva *Recall* yang menunjukkan seberapa baik model mampu mengingatkan atau mendeteksi semua objek yang relevan dalam gambar atau video. Nilai *Recall* adalah 1.00 pada tingkat ambang batas 0.00. Pada tingkat ambang yang sangat rendah, model *YOLO* dapat mengingatkan atau mendeteksi hampir semua objek positif dalam gambar atau video. Artinya, model cenderung mendeteksi sebagian besar

DOI : 10.5281/zenodo.15855681

P-ISSN: 2085-0786
E-ISSN: 2654-2765

atau bahkan semua objek sebagai positif tanpa melakukan banyak penolakan (*false negative*).

Namun, perlu diperhatikan penggunaan ambang batas yang sangat rendah, seperti 0.00, dapat menyebabkan peningkatan jumlah *false positive*, ini terjadi ketika model mengira objek itu positif meskipun sebenarnya tidak relevan. Oleh karena itu, pengaturan ambang batas harus dipertimbangkan dengan cermat untuk menjaga keseimbangan antara *recall* yang tinggi dan tingkat kesalahan *false positive*, yang dapat mempengaruhi akurasi keseluruhan model dalam merekognisi. Secara keseluruhan, hasil evaluasi menunjukkan bahwa model *YOLO* dapat mengidentifikasi hampir semua objek yang ada dalam gambar atau video dan sangat baik dalam aspek *recall*. Kurva *recall* dapat dilihat pada Gambar 4. 5.



Gambar 12. Kurva *Recall*

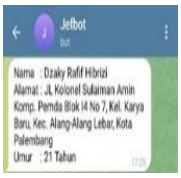
4.2 Data Pengujian

Pengujian *real-time* adalah bagian penting dari evaluasi kinerja dan keandalan alat. Tujuan pengujian ini adalah untuk memastikan apakah alat dapat merekognisi pelaku pembuang sampah secara akurat. Untuk mencapainya, sejumlah uji coba dilakukan dengan data yang telah disiapkan.

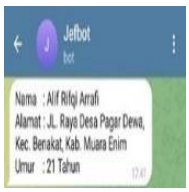
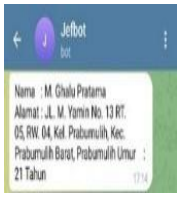
Setelah pengujian selesai, selanjutnya menganalisis hasilnya dengan menggunakan *confusion matrix*. Tabel *confusion matrix* memungkinkan kita untuk menilai kinerja alat pengklasifikasian data. True Positive (TP), False Positive (FP), True Negative (TN), dan False Negative (FN) adalah empat matriks utama yang dievaluasi dalam tabel ini.

Beberapa metrik evaluasi penting alat dapat dihitung dengan data dari confusion matrix tersebut. Ini adalah presisi (*precision*), *recall* (sensitivitas), dan tingkat akurasi (*accuracy*). Tingkat akurasi menunjukkan seberapa akurat alat mengidentifikasi data positif, dan presisi menunjukkan seberapa baik alat menemukan semua data positif yang sebenarnya. Hasil pengujian rekognisi pelaku pembuang sampah dapat dilihat pada *Table 2* dan *Tabel 5*.

Tabel 2. Hasil Rekognisi Pada Saat Terang

No	Bounding Box dan Nilai Cahaya	Rekognisi Pelaku Di Telegram	Keterangan
1	 4460 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar
2	 4412 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar
3	 5295 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar
4	 4076 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar
5	 4502 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar

DOI : 10.5281/zenodo.15855681

6	 4325 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar
7	 4628 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar
8	 4426 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar
9	 4358 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar
10	 4012 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar

Pada Tabel 2 dapat ditentukan Model metode *confusion matrix* dapat dilihat pada Tabel 3.

Tabel 3 Metode *Confusion Matrix* Saat Terang

		Observed	
		True	*False*
Predicted Class	*True*	TP = 10	TN = 0
	False	FP = 0	FN = 0

Menurut *confusion matrix* Tabel 4.3 dari model memprediksi 10 percobaan dengan data positif yang diprediksi benar (TP), data positif yang diprediksi salah (FP), data negatif yang diprediksi salah (FN), dan jumlah data negatif yang diprediksi benar (TN). Tabel tersebut memungkinkan kita untuk menghitung nilai *precision, recall, dan accuracy* masing-masing kelas, serta rata-rata kelas.

Precision digunakan untuk mengukur ketepatan antara informasi yang diminta pengguna dan jawaban yang diberikan sistem. Persamaannya adalah sebagai berikut:

$$Precission = \frac{TP}{(TP+FP)} X\ 100\%$$
$$Precission = \frac{10}{(10+0)} X\ 100\%$$
$$Precission = 100\%$$

Keberhasilan sistem dalam menemukan kembali data diukur melalui recall, yang dilakukan sesuai dengan persamaan berikut:

$$Recall = \frac{TP}{(TP+FN)} X\ 100\%$$
$$Recall = \frac{10}{(10+0)} X\ 100\%$$
$$Recall = 100\%$$

Accuracy digunakan untuk mengukur kinerja dan efektivitas model tersebut dalam mendeteksi objek sebagai berikut:

$$Accuracy = \frac{TP+TN}{(TP+TN+FP+FN)} X\ 100\%$$
$$Accuracy = \frac{10+0}{(10+0+0+0)} X\ 100\%$$
$$Accuracy = 100\%$$

Tabel 4 menunjukkan rata-*rata precision, recall, dan accuracy* dari *real test* pada rekognisi pelaku sebagai berikut:

Tabel 4. Hasil *Confusion Matrix* Saat Terang

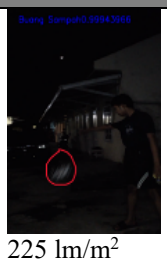
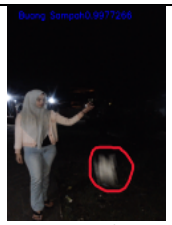
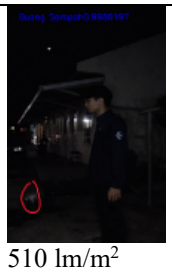
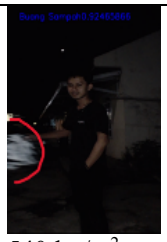
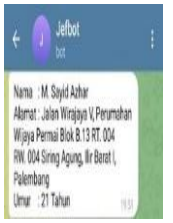
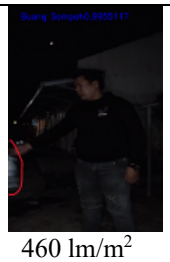
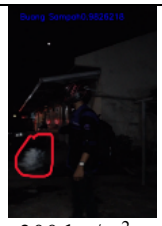
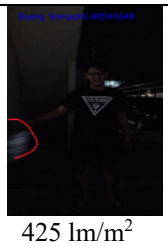
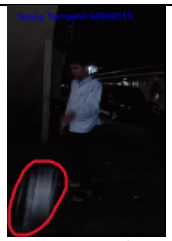
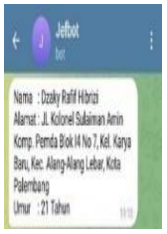
Class	Jumlah Data	*Precision*	*Recall*	*Accuracy*
Rekognisi	10	100%	100%	100%

Tabel 5 berikut merupakan hasil rekognisi sistem pada telegram pada saat kondisi gelap.

DOI : 10.5281/zenodo.15855681

P-ISSN: 2085-0786
E-ISSN: 2654-2765

Tabel 5. Hasil Rekognisi Pada Saat Gelap

No	Bounding Box dan Nilai Cahaya	Rekognisi Pelaku Di Telegram	Keterangan
1	 225 lm/m^2		Berhasil dalam merekognisi pelaku dengan data salah
2	 894 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar
3	 510 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar
4	 540 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar
5	 736 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar
6	 460 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar
7	 425 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar
8	 300 lm/m^2		Tidak berhasil dalam merekognisi pelaku
9	 425 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar
10	 510 lm/m^2		Berhasil dalam merekognisi pelaku dengan data benar

Pada *Tabel 5* dapat ditentukan Model metode *confusion matrix* dapat dilihat pada Tabel 6.

Tabel 6. Metode *Confusion Matrix* Saat Gelap

		Observed	
		True	*False*
Predicted Class	*True*	TP = 8	TN = 0
	False	FP = 1	FN = 1

Menurut *confusion matrix* Tabel 4.6 dari model memprediksi 10 percobaan dengan data positif yang diprediksi benar (TP), data positif yang diprediksi salah (FP), data negatif yang diprediksi salah (FN), dan jumlah data negatif yang diprediksi benar (TN). Tabel tersebut memungkinkan kita untuk menghitung nilai *precision, recall, dan accuracy* masing-masing kelas, serta rata-rata kelas.

Precision digunakan untuk mengukur

DOI : 10.5281/zenodo.15855681

P-ISSN: 2085-0786
E-ISSN: 2654-2765

ketepatan antara informasi yang diminta pengguna dan jawaban yang diberikan sistem. Persamaannya adalah sebagai berikut:

$$Precission = \frac{TP}{(TP+FP)} X\ 100\%$$
$$Precission = \frac{8}{(8+1)} X\ 100\%$$
$$Precission = 88.9\%$$

Keberhasilan sistem dalam menemukan kembali data diukur melalui *recall*, yang dilakukan sesuai dengan persamaan berikut:

$$Recall = \frac{TP}{(TP+FN)} X\ 100\%$$
$$Recall = \frac{8}{(8+1)} X\ 100\%$$
$$Recall = 88.9\%$$

Accuracy digunakan untuk mengukur kinerja dan efektivitas model tersebut dalam mendeteksi objek sebagai berikut:

$$Accuracy = \frac{TP+TN}{(TP+TN+FP+FN)} X\ 100\%$$
$$Accuracy = \frac{8+0}{(8+0+1+1)} X\ 100\%$$
$$Accuracy = 80\%$$

Tabel 7 menunjukkan rata-*rata precision, recall, dan accuracy* dari *real test* pada rekognisi pelaku sebagai berikut;

Tabel 7. Hasil Confusion Matrix Saat Gelap

Class	Jumlah Data	*Precision*	*Recall*	*Accuracy*
Rekognisi	10	88.9%	88.9%	80%

5. KESIMPULAN

Sistem yang menggunakan teknologi pemrosesan citra *You Only Look Once* (YOLO) secara real-time merekognisi pelaku yang membuang sampah sembarangan. Sistem ini dapat memantau lingkungan secara efektif, memberikan informasi langsung tentang pelanggaran, dan mendukung upaya penegakan peraturan kebersihan dengan kemampuan analisis gambar yang cepat, akurat, dan akurasi uji coba rekognisi pelaku saat keadaan terang 100% dan keadaan gelap 80%, intensitas cahaya juga dapat mempengaruhi efektif kinerja sistem terhadap pelaku pembuang sampah sembrangan. Oleh karena itu, sistem diperlukan untuk meningkatkan keandalan dan kondisi lingkungan yang kompleks.

DAFTAR PUSTAKA

[1] H. H. Al Asyhar, S. A. Wibowo, and G. Budiman, "Implementasi Dan Analisis Performansi Metode You Only Look Once (Yolo) Sebagai Sensor Pornografi Pada Video," *eProceedings Eng.*, vol. 7, no. 2, p. 3631, 2020.

[2] E. P. Sitohang, D. J. Mamahit, and N. S. Tulung, "Rancang Bangun Catu Daya Dc Menggunakan Mikrokontroler Atmega 8535," *J. Tek. Elektro danKomput.*, vol. 7, no. 2, pp. 135–142, 2018.

[3] S. G. Anggraeni, "Bab ii tinjauan pustaka 2.1," pp. 6–15, 2018, [Online]. Available:https://elibrary.unikom.ac.id/id/eprint/277/8/UNIKOM_Silvia Gusti Anggraeni_Bab II.pdf.

[4] R. Fatriawans, "Pengertian Jaringan Router," pp. 1–5, 2017

[5] A. Wakefield and J. Fleming, "Closed Circuit Television (CCTV)," *SAGE Dict. Polic.*, no. September 1968, pp. 8–24, 2013, doi: 10.4135/9781446269053.n11.

[6] Okta Felia, Nyayu Latifah Husni, T. Elektro, J. T. Elektro, and P. N. Sriwijaya, "Sistem Pengenalan Aktivitas Manusia Real-Time Menggunakan Image Processing Berbasis Machine Learning" Diajukan Sebagai Salah Satu Syarat Untuk Mendapatkan Gelar Sarjana Terapan pada Program Studi Teknik Elektro *OLEH*. 2023.

[7] M. Abdallah, M. Abu Talib, S. Feroz, Q. Nasir, H. Abdalla, and B. Mahfood, "Artificial intelligence applications in solid waste management: A systematic research review," *Waste Manag.*, vol. 109, pp. 231–246, 2020, doi: 10.1016/j.wasman.2020.04.057.

DOI : 10.5281/zenodo.15855681

[8] K. Banjarey, S. Prakash Sahu, and D. Kumar Dewangan, "A Survey on Human Activity Recognition using Sensors and Deep Learning Methods,"*Proc. - 5th Int. Conf. Comput. Methodol. Commun. ICCMC 2021*, no. Iccmc, pp. 1610–1617, 2021, doi: 10.1109/ICCMC51019.2021.9418255.

[9] H. F. Nweke, Y. W. Teh, M. A. Al-garadi, and U. R. Alo, "Deep learning algorithms for human activity recognition using mobile and wearable sensor networks: State of the art and research challenges," *Expert Syst. Appl.*, vol. 105, pp. 233–261, 2018, doi: 10.1016/j.eswa.2018.03.056.

[10] R. R. Pratama, "Analisis Model Machine Learning Terhadap PengenalanAktifitas Manusia," *MATRIK J. Manajemen, Tek. Inform. dan RekayasaKomput.*, vol. 19, no. 2, pp. 302–311, 2020, doi: 10.30812/matrik.v19i2.688

DOI : 10.5281/zenodo.15855681