TRANSMISI: JURNAL ILMIAH TEKNIK ELEKTRO, 28, (4), OKTOBER 2026
p-ISSN 1411-0814 e-ISSN 2407-6422

RANCANG BANGUN ”SI PARTO” SEBAGAI PROTOTIPE ALAT PENDETEKSI PELANGGARAN PARKIR LIAR DAN BERHENTI TIDAK PADA TEMPATNYA BERBASIS IOT

Suci Sekar Mukti[1*)], Hanendyo Putro[1], Dani Fitria Brilianti[1], dan Helmi Wibowo[2]

[1]Program Studi Rekayasa Sistem Transportasi Jalan, Politeknik Keselamatan Transportasi Jalan, Tegal, Indonesia
[2]Program Studi Teknologi Otomotif, Politeknik Keselamatan Transportasi Jalan, Tegal, Indonesia

[*]*Penulis korespondensi, E-mail: skarmukti@gmail.com*

Abstrak

Parkir liar dan berhenti tidak pada tempatnya menjadi permasalahan serius di wilayah perkotaan Indonesia akibat keterbatasan lahan parkir, keberadaan juru parkir ilegal, serta rendahnya efek jera bagi pelanggar. Penelitian ini bertujuan mengembangkan dan menguji efektivitas Si Parto (Sistem Parkir dan Setop Liar), sebuah prototipe sistem pendeteksi pelanggaran berbasis *Internet of Things* (IoT) untuk mendukung pengawasan lalu lintas otomatis. Metode yang digunakan adalah *Software Development Life* Cycle (SDLC) model *Waterfall*, dengan rancangan sistem menggunakan miniatur mobil dan diorama untuk mensimulasikan kondisi jalan perkotaan. Deteksi objek kendaraan dilakukan menggunakan algoritma YOLOv11 dengan enam kelas, yaitu SUV, SUV 7 Seater, Sedan, Taksi, City Car, dan plat nomor, sedangkan pelacakan pergerakan kendaraan secara real-time dilakukan dengan Kalman Filter. Pengujian terhadap 600 frame menggunakan *Confusion Matrix* menunjukkan hasil akurasi 99,6%, precision 99,6%, recall 99,8%, dan F1-score 99,7%. Performa siang hari sedikit lebih baik dibanding malam hari karena faktor pencahayaan. Hasil *Black-Box Testing* menunjukkan seluruh fitur, termasuk deteksi pelanggaran, pelacakan kendaraan, identifikasi plat nomor, dan pengiriman notifikasi melalui Telegram (rata-rata respons 2,31 detik), berjalan optimal. Dengan hasil ini, Si Parto berpotensi menjadi solusi efektif untuk penegakan hukum lalu lintas berbasis IoT.

Kata kunci: parkir liar, iot, yolov11, kalman filter, Confusion Matrix, black box testing, sistem pengawasan

Abstract

Illegal parking and stopping in unauthorized areas have become serious issues in urban areas of Indonesia due to limited parking spaces, the presence of illegal parking attendants, and the lack of deterrent effects for violators. This study aims to develop and evaluate the effectiveness of Si Parto (Sistem Parkir dan Setop Liar), a prototype violation detection system based on the Internet of Things (IoT) to support automated traffic monitoring. The research employs the Software Development Life Cycle (SDLC) with the Waterfall model, designing the system using miniature vehicles and a diorama to simulate urban road conditions. Vehicle object detection is performed using the YOLOv11 algorithm with six object classes—SUV, SUV 7 Seater, Sedan, Taxi, City Car, and license plate—while real-time vehicle tracking is conducted using the Kalman Filter. Testing on 600 frames using the Confusion Matrix produced excellent results with an accuracy of 99.6%, precision 99.6%, recall 99.8%, and F1-score 99.7%. The system performed slightly better during daytime compared to nighttime due to lighting conditions. Black-Box Testing results indicated that all features, including violation detection, vehicle tracking, license plate identification, and Telegram notification (average response time of 2.31 seconds), functioned optimally. These findings demonstrate that Si Parto has strong potential as an effective IoT-based solution for traffic law enforcement.

Keywords: illegal parking, iot, yolov11, kalman filter, Confusion Matrix, black-box testing, monitoring system

1. Pendahuluan

Permasalahan terkait pelanggaran parkir liar serta berhenti tidak pada tempatnya menjadi salah satu isu lalu lintas yang semakin mengkhawatirkan di berbagai wilayah Indonesia, khususnya di kota-kota besar. Fenomena ini memengaruhi kelancaran arus lalu lintas serta tata ruang publik di kawasan perkotaan dan daerah padat penduduk. Beberapa faktor utama yang memicu munculnya pelanggaran tersebut meliputi terbatasnya lahan parkir, peningkatan jumlah kendaraan pribadi, serta lemahnya penegakan hukum di lapangan [1]. Kondisi ini tidak hanya mengganggu ketertiban lalu lintas, tetapi juga memperburuk tingkat kemacetan, menurunkan efisiensi transportasi, dan mengurangi kenyamanan pengguna jalan [2]. Oleh karena itu, pemerintah daerah didorong untuk mengembangkan solusi berbasis teknologi yang mampu

meningkatkan efisiensi pengawasan dan memperkuat penegakan hukum terhadap pelanggaran parkir liar secara efektif.

Dinas Perhubungan Provinsi DKI Jakarta memiliki tanggung jawab dalam menjalankan fungsi pemerintahan di bidang transportasi, termasuk pelaksanaan urusan rumah tangga daerah serta tugas pembantuan di sektor perhubungan. Jakarta, sebagai ibu kota negara dan pusat metropolitan terbesar di Asia Tenggara berdasarkan jumlah penduduknya [3], memiliki tantangan besar dalam hal manajemen transportasi. Berdasarkan data Provinsi DKI Jakarta Dalam Angka 2024, jumlah penduduk DKI Jakarta tahun 2023 mencapai 10.672.100 jiwa, dengan jumlah kendaraan bermotor sebanyak 22.907.080 unit [4]. Artinya, rata-rata satu orang memiliki lebih dari dua kendaraan bermotor. Namun, tidak semua rumah di Jakarta memiliki fasilitas garasi, terutama di kawasan permukiman padat dengan akses jalan yang sempit, sehingga banyak kendaraan diparkir di bahu jalan. Pertumbuhan jumlah kendaraan yang tidak diimbangi dengan penambahan lahan parkir menimbulkan pelanggaran parkir liar dan berkontribusi pada kemacetan lalu lintas [5].

Secara terminologi, parkir adalah kondisi ketika kendaraan tidak bergerak untuk sementara waktu karena ditinggalkan oleh pengemudinya [6]. Dalam konteks transportasi perkotaan, fasilitas parkir merupakan komponen penting guna menjaga keteraturan lalu lintas. Pelanggaran parkir telah menjadi masalah kronis di berbagai kota besar, seiring meningkatnya aktivitas ekonomi dan mobilitas masyarakat, khususnya di wilayah Jabodetabek [7]. Fenomena berhentinya kendaraan di bahu jalan dalam waktu lama umumnya dilakukan oleh pengemudi angkutan umum yang menunggu penumpang. Pelanggaran seperti ini menciptakan hambatan samping yang memperburuk arus lalu lintas dan menyebabkan kemacetan. Untuk mengatasi hal tersebut, diperlukan penegakan aturan yang lebih tegas terhadap pelanggaran parkir liar dan berhenti di badan jalan [8].

Tingginya kasus parkir liar juga disebabkan oleh rendahnya kesadaran pengendara dan maraknya juru parkir liar yang tidak memiliki izin resmi [9]. Oleh karena itu, dibutuhkan langkah penertiban yang lebih memberikan efek jera. Pemerintah Provinsi DKI Jakarta, melalui Bidang Pengendalian & Operasional Lalu Lintas dan Angkutan Jalan Dinas Perhubungan, telah memberlakukan sanksi berupa penderekan kendaraan dan penarikan retribusi sebesar Rp500.000,00 bagi pelanggar parkir liar. Namun, aturan tersebut kini tengah dikaji ulang, sehingga penarikan retribusi ditiadakan. Saat ini, pelanggar hanya dikenai penderekan kendaraan serta diwajibkan membuat surat pernyataan bermaterai bahwa pelanggaran tidak akan diulangi. Belum optimalnya penerapan regulasi serta ringannya sanksi membuat penegakan hukum belum menimbulkan efek jera bagi pelanggar [10].

Kasus parkir liar hampir terjadi di seluruh wilayah DKI Jakarta, baik di kawasan pusat maupun pinggiran kota. Kondisi ini dipengaruhi oleh minimnya lahan parkir resmi serta kurangnya jaringan transportasi umum yang memadai, sehingga masyarakat lebih memilih menggunakan kendaraan pribadi [11]. Permintaan akan ruang parkir yang tinggi tidak diimbangi dengan penyediaan fasilitas parkir yang cukup. Akibatnya, banyak ruang publik seperti bahu jalan disalahgunakan untuk kepentingan pribadi sebagai tempat parkir. Hal ini terutama sering terjadi di pusat perbelanjaan besar dan daerah komersial padat di Jakarta.

Pada tahun 2023, Suku Dinas Perhubungan (Sudinhub) Jakarta Selatan mencatat 6.659 kendaraan melanggar aturan parkir liar dan berhenti tidak pada tempatnya. Dari jumlah tersebut, 3.899 kendaraan roda empat dikenai sanksi penderekan, sementara 2.100 kendaraan roda dua, 228 kendaraan roda empat, dan 3 kendaraan roda tiga dijatuhi sanksi Operasi Cabut Pentil (OCP). Selain itu, 429 kendaraan roda dua juga diamankan melalui operasi angkut jaring [12]. Kegiatan penertiban tersebut menjadi bagian dari upaya pengendalian lalu lintas untuk mengurangi kemacetan, menjaga ketertiban umum, serta memperindah kota. Seiring dengan kemajuan teknologi, konsep *Internet of Things* (IoT) kini mulai diimplementasikan dalam sektor transportasi [13][14]. Teknologi IoT memungkinkan pengumpulan dan pemrosesan data *real-time* secara otomatis tanpa keterlibatan langsung manusia [15], sehingga dapat menjadi solusi dalam pemantauan dan pengawasan lalu lintas yang lebih cerdas dan efisien.

Beberapa contoh penerapan IoT yang sering dijumpai adalah adanya sistem transportasi cerdas pada kendaraan otonom dan sistem infrastruktur transportasi terhubung, misalnya tampilan informasi *real-time* terkait pemantauan posisi transportasi umum yang hendak dinaiki. Pemecahan masalah parkir liar dan berhenti tidak pada tempatnya juga dapat dilakukan dengan IoT melalui pemanfaatan sensor dan kamera yang kian mumpuni saat ini. Integrasi IoT dengan Telegram bot memberikan solusi praktis dan cepat dalam menyampaikan informasi pelanggaran kepada petugas tanpa harus berada di lokasi kejadian, sesuai dengan tren penerapan IoT pada sistem pemantauan lalu lintas modern Telegram menyediakan fitur yang dapat dimanfaatkan pengembang untuk membuat sistem yang mampu mengirimkan dan menerima pesan secara otomatis melalui jaringan internet [16].

Berdasarkan latar belakang tersebut, diperlukan pengembangan sistem pengawasan yang dapat mendukung kinerja Dinas Perhubungan. Si Parto (Sistem Parkir dan Setop Liar) dikembangkan sebagai sistem pengawasan untuk mendeteksi pelanggaran parkir liar dan berhenti tidak pada tempatnya. Diharapkan konsep sistem ini dapat diadopsi serta berkontribusi dalam membantu Dinas Perhubungan mengatasi permasalahan terkait pelanggaran

parkir dan pemberhentian kendaraan yang tidak sesuai aturan.

Beberapa penelitian sebelumnya telah mencoba mengembangkan sistem pendeteksi kendaraan, seperti yang dilakukan oleh Mulyana & Rofik yang dapat mengklasifikasikan jenis-jenis kendaraan di jalan raya, tetapi penelitian ini belum diterapkan untuk penegakan hukum berupa pendeteksian pelanggaran parkir [17]. Sedangkan penelitian terkait parkir berbasis visi komputer telah dilakukan oleh Ammar Rifqi Ramadhan menggunakan algoritma CNN dan SSD untuk mendeteksi kendaraan yang berhenti di area terlarang. Namun, sistem tersebut belum dilengkapi dengan pelacakan gerak kendaraan secara real-time sehingga tidak dapat membedakan kendaraan yang berhenti sesaat dengan yang benar-benar melanggar [18]. Berdasarkan kesenjangan penelitian tersebut, penelitian ini bertujuan untuk mengembangkan integrasi dari algoritma YOLOv11 dan Kalman Filter untuk mendeteksi serta melacak pelanggaran parkir secara *real-time*. Selain itu, sistem ini dilengkapi dengan notifikasi otomatis melalui Bot Telegram dan evaluasi berbasis *Confusion Matrix*. Dengan demikian, penelitian ini menawarkan pendekatan yang lebih komprehensif dan siap diterapkan sebagai solusi teknologi pengawasan lalu lintas berbasis IoT.

2. Metode

2.1. Algoritma YOLOv11

YOLOv11 *(You Only Look Once* versi 11) adalah algoritma deteksi objek yang digunakan dalam penelitian ini untuk mengenali kendaraan secara *real-time.* Populasi dari penelitian ini adalah 5 kendaraan. Hal tersebut sejalan dengan penelitian yang dilakukan oleh Ramadhan (2019) [19] dengan judul "Klasifikasi Jenis Mobil Paling Diminati di Indonesia Menggunakan Algoritma Naïve Bayes" sehingga didapatkan lima jenis mobil sebagai populasi pada penelitian ini. Klasifikasi jenis mobil ini terdiri dari jenis mobil *City Car*, Sedan, SUV, SUV *7 Seater* dan MPV. Terdapat taksi yang termasuk golongan MPV. YOLOv11 digunakan untuk mendeteksi enam kelas objek: SUV, SUV *7 Seater* , Sedan, Taksi, *City Car*, dan plat nomor. Hasil deteksi digunakan untuk mengetahui jenis kendaraan yang melanggar.

2.2. Algoritma Kalman Filter

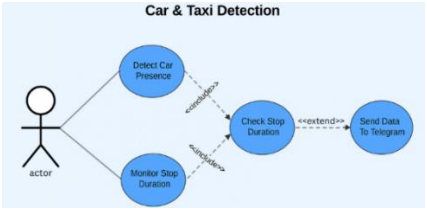
Kalman Filter adalah algoritma prediksi yang digunakan untuk *tracking* pergerakan kendaraan secara *real-time*. Fungsinya adalah untuk mengestimasikan posisi kendaraan pada waktu berikutnya *(predict),* mengoreksi estimasi tersebut berdasarkan data aktual *(correct),* menghasilkan ID unik untuk setiap kendaraan, dan menentukan apakah kendaraan berhenti lebih dari 60 detik sebagai indikator pelanggaran.

Kalman Filter bekerja dengan dua tahapan utama:
1. *Time Update (Predict):* Memperkirakan posisi kendaraan selanjutnya,
2. *Measurement Update (Correct):* Memperbarui prediksi berdasarkan data terbaru.

Filter ini dipilih karena mampu bekerja baik dalam kondisi pencahayaan berbeda (siang dan malam), serta mengurangi kesalahan deteksi akibat *noise* atau visual gangguan lainnya.

2.3. Metode *Waterfall*

Penelitian ini menggunakan pendekatan *Software Development Life Cycle (SDLC)* dengan model *Waterfall,* yang merupakan metode berurutan dan sistematis dari analisis hingga perawatan sistem. Penelitian ini menggunakan model pengembangan perangkat lunak Tahapan pengembangan sistem Si Parto adalah:
1. *Requirement Analysis*
   Analisis kebutuhan dilakukan dengan observasi dan wawancara kepada calon pengguna (petugas lapangan) untuk merumuskan fitur sistem yang dibutuhkan.
2. *System and Software Design*
   Merancang antarmuka sistem serta alur input-output, seperti bagaimana pelanggaran dideteksi dan dikirim melalui Telegram.
   a. *Use Case Diagram*



Gambar 1. ***Use Case Diagram***

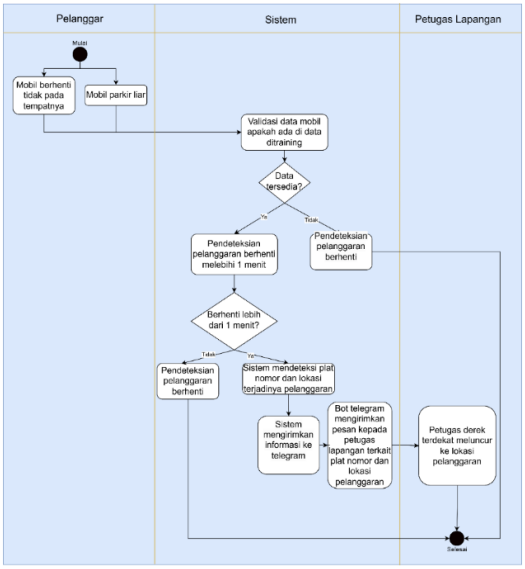
Penjelasan *Use Case Diagram* Berdasarkan Ketentuan:
1) *Actor*: Operator adalah entitas yang berinteraksi dengan sistem untuk memantau status deteksi mobil.
2) *Use Cases:*
   a) *Detect Car Presence:* Mendeteksi keberadaan mobil.
   b) *Monitor Stop Duration:* Memantau berapa lama mobil berhenti.
   c) *Check Stop Duration:* Memeriksa apakah mobil berhenti lebih dari 1 menit. Ini termasuk dalam proses monitoring waktu berhenti.
   d) *Send Data to Telegram:* Mengirim data mobil (termasuk plat nomor) ke Bot Telegram jika berhenti selama 1 menit atau lebih.

3) Relationships

a) *Include: Detect Car Presence dan Monitor Stop Duration* menyertakan bagian dari proses deteksi.

b) *Extend: Send Data to Telegram* diperluas dari *Check Stop Duration,* artinya akan dieksekusi jika durasi berhenti terpenuhi (lebih dari 1 menit).

b. *Diagram Activity*



Gambar 2. *Diagram Activity*

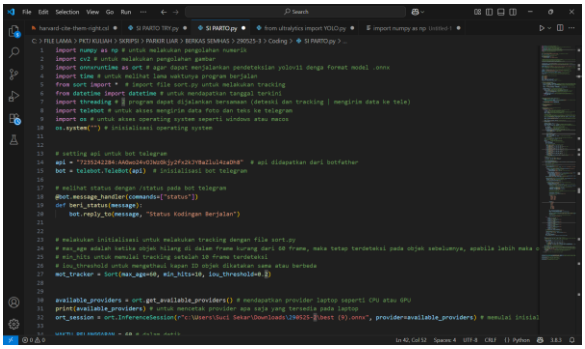
Penjelasan *Diagram Activity* sebagai berikut:

a. Mobil berhenti tidak pada tempatnya dan mobil yang melakukan parkir liar dilakukan oleh pelanggar.

b. Sistem akan mendeteksi apakah data mobil ada berdasarkan data dari *training*. Jika ada sistem akan menghitung apakah kendaraan berhenti lebih dari satu menit. Jika Tidak sistem pendeteksian pelanggaran akan terhenti. Jika Ya maka sistem akan mendeteksi plat nomor dan lokasi terjadinya pelanggaran. Sistem akan mengirimakn informasi tersebut ke Telegram. Kemudian Bot Telegram akan mengirimkan pesan kepada para petugas lapangan yang berisikan plat nomor dan lokasi pelanggaran.

c. Petugas lapangan terdekat dapat langsung menuju ke lokasi tersebut untuk melakukan penertiban terhadap pelanggaran.

3. *Implementation (Coding)*
Sistem dikembangkan menggunakan Python dengan integrasi YOLOv11 untuk deteksi dan Kalman Filter untuk pelacakan objek, dikemas dalam program *interface* sesuai kebutuhan pengguna menggunakan VSCode. Pada tahap ini juga dibuat Bot Telegram sebagai bagian dari sistem.



Gambar 3. Potongan *Script VSCode*

4. *Integration and System Testing*
Semua model serta modul diintegrasikan dan diuji secara menyeluruh untuk memastikan sistem berjalan optimal.

a. Skenario Penempatan Alat



Gambar 4. Skenario Penempatan Alat

Skenario penempatan alat Si Parto sebagai alat pendeteksi pelanggaran parkir ini menggunakan miniatur sebagai medianya. Gawai ditopang dengan tripod yang diletakkan di sisi kiri trotoar kiri dan posisi gawai diletakkan tepat di tengah-tengah jalan. Hal ini dilakukan untuk memudahkan pembacaan plat kendaraan dan pendeteksian pelanggaran melalui tangkapan gambar dan video yang baik.

b. Alur Integrasi Sistem:



Gambar 5. Alur Pengembangan Sistem

1) Anotasi dataset (Roboflow)
Tahap awal ini adalah proses membuat dataset yang akan digunakan untuk melatih model deteksi objek. Di sini, gambar-gambar dikumpulkan lalu diberi label (anotasi) sesuai dengan objek yang ingin dikenali, yakni

berbagai jenis kendaraan dan plat nomor. Roboflow membantu mempermudah proses anotasi dengan antarmuka visual, serta menyediakan *tools preprocessing* seperti augmentasi gambar untuk meningkatkan variasi dataset.

2) *Training* (Google Colab)
Setelah dataset selesai dianotasi, tahap selanjutnya adalah pelatihan model. Google Colab dipilih karena menyediakan GPU gratis yang mempercepat proses *training*. Model deteksi objek YOLOv11 dilatih menggunakan dataset dari Roboflow. Proses ini melibatkan pembelajaran model untuk mengenali pola dan ciri khas dari objek-objek yang telah dianotasi.
3) Output *Training* → ONNX
Hasil dari pelatihan model berupa file model terlatih. File ini kemudian dikonversi ke format ONNX *(Open Neural Network Exchange),* yaitu format standar lintas platform yang memudahkan model untuk dijalankan di berbagai lingkungan dan bahasa pemrograman, termasuk Python.
4) Eksekusi (VSCode = YOLOv11 + Kalman Filter)
Tahap ini adalah implementasi sistem menggunakan Python di VSCode. Model ONNX dijalankan bersama YOLOv11 untuk mendeteksi objek secara *real-time.* Hasil deteksi objek kemudian diproses menggunakan Kalman Filter (dengan bantuan pustaka FilterPy) untuk memprediksi dan memperhalus pergerakan objek, sehingga hasil deteksi lebih stabil dan akurat.
5) Input Sistem → Iriun Webcam
Sistem menerima input berupa video *real-time* dari Iriun Webcam. Iriun Webcam digunakan sebagai alat untuk menjadikan kamera *smartphone* atau perangkat lain sebagai sumber video. Video ini kemudian menjadi sumber data yang akan dianalisis oleh model deteksi.
6) Output Sistem → Notifikasi Telegram
Setelah deteksi objek dan pemrosesan selesai, hasil akhirnya adalah mengirim notifikasi melalui Bot Telegram. Notifikasi ini bisa berupa teks, gambar hasil deteksi, atau informasi lainnya. Untuk menghasilkan sistem yang siap diuji, diperlukan tahapan yang lebih rinci dan terstruktur.

c. Pengujian Sistem
Pengujian dengan *Confusion Matrix, Blackbox Testing,* dan perhitungan waktu *real-time.*

5. *Operation* and Maintenance
Tahap terakhir meliputi pengoperasian dan pemeliharaan sistem. Setelah pengujian, sistem dapat dikembangkan lebih lanjut dan diperbaiki jika ditemukan kesalahan saat digunakan. Pemerintah Daerah melalui Dinas Perhubungan dapat memanfaatkan prototipe ini sebagai model awal untuk mengadopsi dan mengembangkan konsep penertiban parkir yang diterapkan pada Si Parto.

3. Hasil dan Pembahasan

3.1. *Confusion Matrix*

Pengujian YOLOv11 dilakukan dengan melakukan pendeteksian selama 5 menit pada kondisi siang maupun malam, sehingga didapatkan 300 frame pada masing-masing kondisi berdasarkan prinsip FPS *(Frame Per Second)*. Untuk mengevaluasi performa model dalam mendeteksi pelanggaran parkir liar dan berhenti tidak pada tempatnya, digunakan empat metrik utama yaitu *precision* (presisi), *recall* (sensitivitas), *accuracy* (akurasi), dan F1-*score* terhadap 300 frame di siang hari dan 300 frame di malam hari. Metrik-metrik ini dihitung berdasarkan nilai *True Positive* (TP), *False Positive* (FP), dan *False Negative* (FN) yang diperoleh dari hasil pengujian menggunakan *Confusion Matrix*. Dimana TP artinya pelanggaran yang terdeteksi dengan benar, FP bukan pelanggaran, tetapi terdeteksi sebagai pelanggaran, dan FN Pelanggaran, tetapi tidak terdeteksi.

Perhitungan *Confusion Matrix* dilakukan terhadap pengujian empat prediksi.

$$\textit{Precision}\ (\text{Presisi}) = \frac{TP}{TP+FP} \quad (1)$$

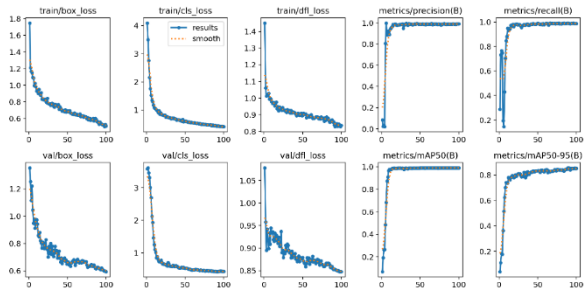
$$\textit{Recall}\ (\text{Sensifitas}) = \frac{TP}{TP+FN} \quad (2)$$

$$\text{Accuracy (Akurasi)} = \frac{TP+TN}{N} \quad (3)$$

$$\text{F1 } \textit{Score} = \frac{2*Recall*Precision}{Recall+Precision} \quad (4)$$

Ukuran besaran *precision, recall,* dan *accuracy* umumnya diberi nilai dalam bentuk persentase antara 1 sampai 100%. Sistem pada Si Parto akan dianggap baik jika tingkat *precision, recall,* dan *accuracy*-nya tinggi.

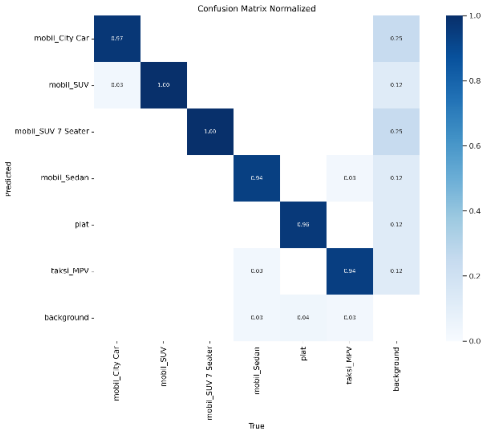
3.1.1. Performa *Training* Model



Gambar 6. Hasil *Training* Model

Selama pelatihan, nilai *loss* menurun secara stabil, menandakan proses pembelajaran yang efektif. Nilai akhir

box_loss (0,51) menunjukkan peningkatan akurasi posisi objek, sedangkan *cls_loss* (0,43) menandakan klasifikasi semakin tepat. Penurunan *dfl_loss* menunjukkan peningkatan presisi dalam pemetaan posisi objek. Pada data validasi, ketiga metrik loss juga menurun dengan tren positif tanpa indikasi *overfitting*. Nilai *precision* stabil di atas 0,95 sejak *epoch* ke-20, dengan *recall* tinggi (≈0,95), menunjukkan sedikit *false positive* dan kemampuan mendeteksi hampir semua objek. Nilai mAP50 mencapai 0,97 dan mAP50–95 stabil di atas 0,80, menandakan model memiliki performa deteksi yang presisi di berbagai kondisi dan kelas.



Gambar 7. ***Confusion Matrix Training***

Secara keseluruhan, model ini menunjukkan performa yang sangat baik pada beberapa kategori kendaraan. Semakin tinggi angka diagonal (kiri atas ke kanan bawah), semakin baik model dalam mengenali kelas tersebut. Angka di luar diagonal menunjukkan tingkat kesalahan *(false positive* atau *false negative)*.

1. Kelas *City Car* (akurasi 1.00) artinya model sangat akurat dan konsisten mendeteksi kelas ini. Kelas *City Car* sebesar 3% diprediksi salah sebagai SUV, sedangkan 12% dari *background* juga diprediksi salah sebagai SUV.
2. Kelas SUV (akurasi 1.00) artinya model akurat dan stabil dalam mendeteksi. Namun, dijumpai sebesar 3% dari *City Car* diprediksi salah sebagai SUV, 12% dari background juga diprediksi salah sebagai SUV.
3. Kelas SUV *7 Seater* (akurasi 1.00) artinya model akurat dan stabil dalam mendeteksi. Namun, dijumpai sebesar 25% dari *background* salah diprediksi sebagai SUV *7 Seater.*
4. Kelas Sedan (akurasi 0.94) artinya model cukup akurat dalam mendeteksi, tetapi kadang model gagal mengenali objek yang sebenarnya ada, dan tidak mengklasifikasikannya ke kelas yang benar, tetapi justru menganggapnya bukan objek *(background).* Sebesar 3% salah diprediksi sebagai plat, dan 3% salah ke *background*, dan 3% dari *background* diprediksi sebagai Sedan.
5. Kelas Plat (akurasi 0.96) artinya model cukup akurat dalam mendeteksi, tetapi 4% dari Plat malah diklasifikasikan sebagai *background*, 3% dari Sedan diprediksi sebagai Plat, 12% dari *background* juga salah diprediksi sebagai Plat.
6. Kelas Taksi (akurasi 0.94) artinya model cukup akurat dalam mendeteksi, dimana 3% salah diprediksi sebagai SUV, dan 3% ke *background*, 12% dari *background* salah diklasifikasikan sebagai Taksi.

3.1.2. Pengujian pada Siang dan Malam Hari

Tabel 1. Hasil Pengujian Algoritma YOLOv11 Data Siang

No	Gambar	*City Car*			Sedan			Taksi			SUV			SUV 7 *Seater*			Plat		
		TP	FP	FN	TP	FP	FN	TP	FP	FN	TP	FP	FN	TP	FP	FN	TP	FP	FN
1		1			1												2		
2			1		1												2		
3											1						1		
4								1									1		
5								1						1			2		
300	LAMPIRAN																		
	TOTAL	85	1	0	88	0	0	85	0	0	86	1	0	85	0	0	417	0	0

Precision (Presisi)

Presisi (*City Car*) = $\frac{85}{85+1}$ = 0,988372093 = 98,84%

Presisi (Sedan) = $\frac{88}{88+0}$ = 1 = 100%

Presisi (Taksi) = $\frac{85}{85+0}$ = 1 = 100%

Presisi (SUV) = $\frac{86}{86+1}$ = 0,9885057471 = 98,85%

Presisi (SUV *7 Seater*) = $\frac{85}{85+0}$ = 1 = 100%

Presisi (Plat) = $\frac{417}{417+0}$ = 1 = 100%

Recall (Sensifitas)

Recall (*City Car*) = $\frac{85}{85+0}$ = 1 = 100%

Recall (Sedan) = $\frac{88}{88+0}$ = 1 = 100%

Recall (Taksi) = $\frac{85}{85+0}$ = 1 = 100%

Recall (SUV) = $\frac{86}{86+0}$ = 1 = 100%

Recall (Taksi) = $\frac{85}{85+0}$ = 1 = 100%

Recall (Plat) = $\frac{417}{417+0}$ = 1 = 100%

Accuracy (Akurasi)

Akurasi (*City Car*) = $\frac{85}{85+1+0}$ = 0,988372093 = 98,84%

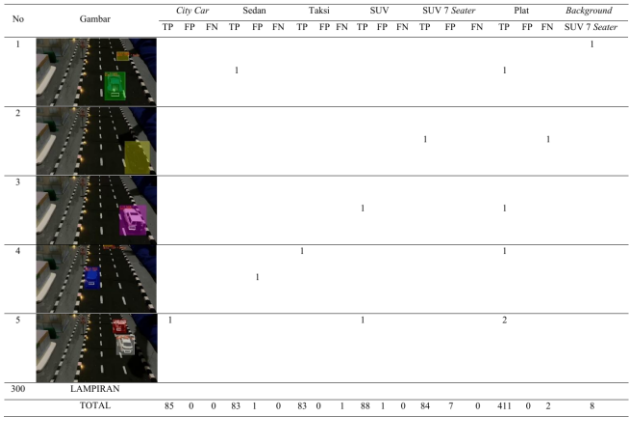
Akurasi (Sedan) = $\frac{88}{88+0+0}$ = 1 = 100%

Akurasi (Taksi) = $\frac{85}{85+0+0}$ = 1 = 100%

Akurasi (SUV) = $\frac{86}{86+1+0}$ = 0,9885057471 = 98,85%
Akurasi (SUV *7 Seater*) = $\frac{85}{85+0+0}$ = 1 = 100%
Akurasi (Plat) = $\frac{417}{417+0+0}$ = 1 = 100%

F1 *Score*
F1 *Score* (*City Car*) = $\frac{2*98,84\%*100\%}{98,84\%+100\%}$ = 99,41%
F1 *Score* (Sedan) = $\frac{2*100\%*100\%}{100\%+100\%}$ = 100%
F1 *Score* (Taksi) = $\frac{2*100\%*100\%}{100\%+100\%}$ = 100%
F1 *Score* (SUV) = $\frac{2*98,85\%*100\%}{98,85\%+100\%}$ = 99,42%
F1 *Score* (SUV *7 Seater*) = $\frac{2*100\%*100\%}{100\%+100\%}$ = 100%
F1 *Score* (Plat) = $\frac{2*100\%*100\%}{100\%+100\%}$ = 100%

Tabel 2. Hasil Pengujian Algoritma YOLOv11 Data Malam



Precision (Presisi)
Presisi (*City Car*) = $\frac{85}{85+0}$ = 1 = 100%
Presisi (Sedan) = $\frac{83}{83+1}$ = 0,9880952381 = 98,8%
Presisi (Taksi) = $\frac{83}{83+0}$ = 1 = 100%
Presisi (SUV) = $\frac{88}{88+1}$ = 0,9887640449 = 98,88%
Presisi (SUV *7 Seater*) = $\frac{80}{80+0}$ = 1 = 100%
Presisi (Plat) = $\frac{411}{411+0}$ = 1 = 100%

Recall (Sensifitas)
Recall (*City Car*) = $\frac{85}{85+0}$ = 1 = 100%
Recall (Sedan) = $\frac{83}{83+0}$ = 1 = 100%
Recall (Taksi) = $\frac{83}{83+1}$ = 0,9880952381 = 98,8%
Recall (SUV) = $\frac{88}{88+0}$ = 1 = 100%
Recall (Taksi) = $\frac{80}{80+0}$ = 1 = 100%
Recall (Plat) = $\frac{411}{411+2}$ = 0,995157385 = 99,5%

Accuracy (Akurasi)
Akurasi (*City Car*) = $\frac{85}{85+0+0}$ = 1 = 100%
Akurasi (Sedan) = $\frac{83}{83+1+0}$ = 0,9880952381 = 98,8%
Akurasi (Taksi) = $\frac{83}{83+0+1}$ = 0,9880952381 = 98,8%
Akurasi (SUV) = $\frac{88}{88+1+0}$ = 0,9887640449 = 98,88%
Akurasi (SUV *7 Seater*) = $\frac{80}{80+0+0}$ = 1 = 100%
Akurasi (Plat) = $\frac{411}{411+0+2}$ = 0,9951456311 = 99,5%

F1 *Score*
F1 *Score* (*City Car*) = $\frac{2*100\%*100\%}{100\%+100\%}$ = 100%
F1 *Score* (Sedan) = $\frac{2*100\%*98,8\%}{100\%+98,85\%}$ = 99,4%
F1 *Score* (Taksi) = $\frac{2*98,8\%*100\%}{98,8\%+100\%}$ = 99,4%
F1 *Score* (SUV) = $\frac{2*98,88\%*100\%}{98,88\%+100\%}$ = 99,43%
F1 *Score* (SUV *7 Seater*) = $\frac{2*100\%*100\%}{100\%+100\%}$ = 100%
F1 *Score* (Plat) = $\frac{2*99,5\%*100\%}{99,5\%+100\%}$ = 99,76%

3.1.3. Perbandingan Pengujian Kondisi Siang dan Malam Hari

Tabel 3. Perbandingan Pengujian Kondisi Siang dan Malam Hari

	Rata-Rata Siang Hari	Rata-Rata Malam Hari
Precision	99,6%	99,6%
Recall	100%	99,7%
Accuracy	99,6%	99,5%
F1 *Score*	99,8%	99,6%

Hasil pengujian YOLO pada kondisi siang dan malam menunjukkan performa model yang sangat baik pada keduanya, meskipun terdapat perbedaan pada beberapa metrik. Performa malam hari sedikit menurun, namun sebagian besar metrik tetap di atas 99%. Tidak ada standar mutlak untuk menentukan kualitas model, karena nilai performa yang dianggap "baik" bergantung pada konteks sistem dan kebutuhan aplikasi.

1. Presisi *(Precision)*
   Precision diukur untuk mengetahui sejauh mana sistem mampu mengidentifikasi pelanggaran secara tepat, tanpa memberikan alarm palsu terhadap kendaraan yang sebenarnya tidak melanggar.
   a. Pada siang hari, performa presisi model YOLO sangat tinggi dengan sebagian besar kelas mencapai nilai presisi 100%, kecuali pada dua kelas, yaitu *City Car* (98,84,%) dan SUV (98,85%). Nilai presisi tinggi ini mengindikasikan bahwa model sangat minim melakukan kesalahan prediksi positif palsu *(false positives)* di siang hari. Semua kelas selain *City Car* dan SUV memiliki *false positive* = 0, menunjukkan keakuratan deteksi yang sangat baik dalam kondisi pencahayaan optimal.
   b. Pada malam hari, performa model sedikit menurun, SUV tetap tinggi tetapi sedikit menurun ke 98,88% dan Sedan turun dari 100% menjadi 98,8%, kelas lainnya tetap memiliki presisi 100%. Penurunan

presisi pada malam hari menunjukkan bahwa pencahayaan yang rendah berpengaruh terhadap kemampuan model dalam membedakan objek dengan benar.

2. *Recall* (Sensitivitas)
   Recall adalah salah satu metrik evaluasi performa yang digunakan untuk mengukur kemampuan sistem dalam mengenali semua pelanggaran yang benar-benar terjadi.
   a. Pada siang hari, model menunjukkan performa ideal dengan *recall* 100% di semua kelas.
   b. Pada malam hari, *recall* tetap tinggi namun sedikit menurun pada kelas Taksi (98,8%) akibat satu *false negative* dan kelas Plat (99,51%) akibat dua *false negative.* Penurunan ini disebabkan kondisi pencahayaan malam yang membuat objek tampak buram, reflektif, atau sulit dibedakan dari latar belakang. Selain itu, terjadi delapan kasus salah deteksi, di mana bayangan tangan peneliti teridentifikasi sebagai SUV 7 *Seater*, menunjukkan bahwa model lebih rentan terhadap kesalahan klasifikasi pada objek berukuran besar dalam kondisi gelap.
3. Akurasi (Accuracy)
   Nilai akurasi berperan penting dalam mengevaluasi efektivitas sistem deteksi pelanggaran parkir liar dan berhenti tidak pada tempatnya. Dengan mengukur proporsi prediksi benar terhadap seluruh kejadian, akurasi menjadi indikator utama keandalan sistem di lapangan. Akurasi tinggi menunjukkan kemampuan sistem dalam mengenali pelanggaran secara tepat serta meminimalkan kesalahan deteksi, sehingga mendukung pengawasan otomatis yang efisien dan kredibel.
   a. Di siang hari, model menunjukkan performa sangat tinggi dan konsisten dengan akurasi 100% pada hampir semua kelas, kecuali kelas *City Car* (98,84%) dan SUV (98,85%). Artinya, dari total objek yang seharusnya terdeteksi, hampir seluruhnya berhasil diklasifikasikan dengan benar.
   b. Di malam hari, terdapat penurunan akurasi pada kelas Taksi (100% menjadi 98,8%) dan Plat (100% menjadi 99,5%), sedangkan kelas *City Car* dan SUV mengalami sedikit kenaikan menjadi 100% dan 98,88%. Meski begitu, akurasi untuk Sedan dan SUV *7 Seater* tetap stabil di 100%.
4. F1 *Score*
   Nilai F1 *Score* menjadi indikator penting untuk mengukur sejauh mana sistem pendeteksi pelanggaran parkir liar bekerja secara seimbang antara ketepatan (*precision*) dan kelengkapan (*recall*). Nilai F1 *Score* yang tinggi menunjukkan bahwa sistem tidak hanya mampu mendeteksi pelanggaran dengan benar, tetapi juga konsisten dalam menghindari kesalahan deteksi, yang sangat penting untuk implementasi sistem pengawasan otomatis berbasis citra.
   a. Pada siang hari, F1 *Score* mendekati atau sama dengan 100% pada seluruh kelas. Hal ini menunjukkan bahwa model bekerja sangat baik dalam kondisi terang, dengan performa deteksi yang seimbang dan minim kesalahan.
   b. Pada malam hari, penurunan terjadi di hampir seluruh kelas, kecuali SUV *7 Seater* yang konsisten di 100%.

3.2. *Blackbox Testing*

Black-Box Testing dinyatakan *"True"* jika output sistem sesuai dengan ekspektasi untuk setiap input yang diuji tanpa menilai kode program. Pada pengujian ini, cara sistem menghasilkan output—seperti algoritma, logika, atau struktur data—diabaikan; fokus utamanya adalah kesesuaian *output* terhadap *input* yang diberikan.

Tabel 4. Tabel Hasil Pengujian *Black-Box Testing*

No	Data Asli	Data Sistem (Prediksi)	Hasil *(True/False)*
1	Sistem mendeteksi pelanggaran parkir dan berhenti tidak pada tempatnya	Sistem dapat mendeteksi pelanggaran parkir dan berhenti tidak pada tempatnya	*True*
2	Sistem memberikan ID yang berbeda pada setiap kendaraan	Sistem dapat memberikan ID pada masing masing kendaraan secara tepat	*True*
3	Sistem mendeteksi plat kendaraan	Sistem dapat mendeteksi plat kendaraan	*True*
4	Sistem mengirimkan pesan ke Bot Telegram secara realtime	Sistem dapat mengirimkan pesan ke Bot Telegram secara realtime	*True*
5	Sistem mendeteksi pelanggaran dalam kondisi siang	Sistem dapat mendeteksi pelanggaran dalam kondisi siang	*True*
6	Sistem mendeteksi pelanggaran dalam kondisi malam	Sistem dapat mendeteksi pelanggaran dalam kondisi malam	*True*

Hasil *Black-Box Testing* menunjukkan bahwa Si Parto mampu menerima input dengan benar dan menghasilkan output sesuai spesifikasi, sehingga validasi fungsionalitas sistem dari sudut pandang pengguna akhir terpenuhi. Dari enam skenario pengujian, empat di antaranya (skenario 1, 2, 5, dan 6) melibatkan algoritma Kalman Filter untuk estimasi dan pelacakan posisi objek secara akurat dalam kondisi *noise* dan oklusi, sedangkan skenario 3 menggunakan YOLOv11 untuk deteksi objek langsung pada setiap frame.

1. Pada skenario nomor 1, sistem dapat mendeteksi pelanggaran parkir dan berhenti tidak pada tempatnya. Dilakukan 15 kali percobaan penarikan mobil untuk melintasi diorama pada masing-masing kondisi baik siang maupun malam, 5 dari 15 mobil berhenti lebih dari 60 detik dan dideteksi sebagai pelanggaran. Oleh karena itu, dapat disimpulkan bahwa sistem dapat memprediksi dan memperbarui posisi kendaraan secara *real-time*, termasuk mendeteksi kapan kendaraan berhenti dalam satu posisi selama periode tertentu,

misalnya 60 detik, yang merupakan indikator pelanggaran parkir atau berhenti tidak pada tempatnya.



Gambar 8. Sistem Dapat Mendeteksi Pelanggaran di Siang Hari



Gambar 9. Sistem Dapat Mendeteksi Pelanggaran di Malam Hari

2. Pada skenario 2, sistem berhasil memberikan ID unik pada setiap kendaraan secara tepat. Kalman Filter memprediksi posisi kendaraan pada frame berikutnya berdasarkan model gerak dan memperbaruinya dengan data deteksi terbaru, sehingga kendaraan dapat dikenali secara konsisten meskipun terjadi perubahan posisi, kecepatan, atau oklusi sementara. Melalui *multiple object tracking,* sistem mampu menjaga ID kendaraan tetap stabil, sehingga proses penghitungan, penggolongan, dan monitoring menjadi lebih akurat dan efisien. Pada siang hari, ID terakhir tercatat 16, sedangkan pada malam hari 42, karena meningkatnya *false positive* saat *background* terdeteksi sebagai objek.



Gambar 10. Sistem Berhasil Memberikan Setiap Kendaraan ID yang Berbeda

3. Pada skenario nomor 3, sistem dapat mendeteksi plat kendaraan. Hal ini terlihat pada Gambar 8., di mana setiap mobil yang teridentifikasi juga berhasil dikenali plat nomornya melalui kamera perangkat.

4. Pada skenario nomor 4, sistem dapat mengirimkan pesan ke Bot Telegram secara *real-time* dengan mudah dan efisien menggunakan Python melalui pemanfaatan library seperti `python-Telegram-bot` yang menyediakan interface mudah untuk berkomunikasi dengan Telegram Bot API. Setelah dilakukan perhitungan durasi dari sistem berhasil mendeteksi terjadinya pelanggaran hingga Bot Telegram mengirimkan pemberitahuan didapat rata-ratanya adalah 2.31 detik.

Tabel 5. Durasi Waktu Tunggu Pemberitahuan Terhadap Pelanggaran

No	Kondisi	Kelas	Waktu (Detik)
1	Siang	SUV	02.33
2	Siang	*City Car*	02.13
3	Siang	Sedan	02.25
4	Siang	Taksi	02.14
5	Siang	SUV 7 *Seater*	02.24
6	Malam	SUV	02.58
7	Malam	*City Car*	02.71
8	Malam	Sedan	02.20
9	Malam	Taksi	02.45
10	Malam	SUV 7 *Seater*	02.08
Rata-Rata			02.31

5. Pada skenario nomor 5 & 6, sistem dapat mendeteksi pelanggaran dalam kondisi siang dan malam. Hasil uji coba pada lima kelas kendaraan menunjukkan bahwa sistem mampu mendeteksi pelanggaran pada siang dan malam hari. Kalman Filter memungkinkan estimasi posisi yang stabil dan prediksi gerak yang adaptif terhadap perubahan pencahayaan, sehingga mengurangi kesalahan deteksi dan *false detection* akibat *noise* maupun gangguan visual. Dengan demikian, sistem pendeteksian pelanggaran dapat bekerja secara efektif dan akurat dalam berbagai kondisi terang maupun gelap.



Gambar 11. Sistem Berhasil Mendeteksi Pelanggaran di Siang Hari



Gambar 12. Sistem Berhasil Mendeteksi Pelanggaran di Malam Hari

4. Kesimpulan

Dari hasil pengembangan Si Parto yang berfungsi sebagai prototipe sistem pendeteksi pelanggaran parkir liar dan berhenti tidak pada tempatnya, dapat disimpulkan bahwa:

1. Penelitian pengembangan Si Parto berfokus pada pembangunan model deteksi pelanggaran parkir liar dan berhenti tidak pada tempatnya menggunakan miniatur dan diorama sebagai representasi visual. Dataset terdiri dari 450 gambar yang diperoleh melalui Roboflow, dengan pembagian data 70:20:10 untuk latih, uji, dan validasi, serta pelatihan model dilakukan selama 100 Epoch. Algoritma deteksi yang digunakan

adalah YOLOv11, sedangkan pelacakan objek menggunakan Kalman Filter. Untuk penelitian selanjutnya, model ini akan diimplementasikan langsung pada sistem pendeteksi pelanggaran parkir liar dan berhenti tidak pada tempatnya di dunia nyata.

2. *Confusion Matrix* dan *Black-Box Testing* digunakan sebagai instrumen pengujian dalam analisis data penelitian. Sebanyak 600 gambar pada kondisi siang dan malam dengan 6 skenario prediksi menunjukkan bahwa performa sistem pada siang hari lebih baik dengan rata-rata akurasi 99,6%, dibanding malam hari 98,3%. Meskipun belum mencapai 100%, hasil pengujian menunjukkan bahwa sistem layak digunakan dan dapat mendukung penegakan hukum lalu lintas. Selain itu, *Black-Box Testing* membuktikan seluruh prediksi valid, meskipun masih diperlukan pengembangan lebih lanjut untuk meningkatkan akurasi pada pencahayaan rendah dan mengurangi gangguan dari objek di area pemantauan.

Referensi

[1]. M. Cania, R. E. Putera, and Y. Yoserizal, "Diagnosis, Panduan dan Tindakan Koheren Dalam Strategi Penertiban Parkir Liar Oleh Dinas Perhubungan Kota Padang," *J. Ranah Publik Indones. Kontemporer*, vol. 2, no. 1, pp. 150–163, 2022, doi: 10.47134/rapik.v2i1.21.

[2]. A. A. Walean, M. Kaunang, and M. L. Kimbal, "Strategi Dinas Perhubungan Dalam Mengatasi Kemacetan Di Kota Manado Provinsi Sulawesi," *J. Adm. Publik*, vol. 5, no. 79, pp. 15–25, 2019.

[3]. Y. M. Yusuf, "20 Kota Terbesar di Asia Tenggara, Jakarta Termasuk?," IDX Channel. Accessed: Oct. 10, 2024. [Online]. Available: https://www.idxchannel.com/milenomic/20-kota-terbesar-di-asia-tenggara-jakarta-termasuk

[4]. R. N. Umi, G. P. Sari, and V. T. L. Simbolon, "Provinsi DKI Jakarta dalam Angka 2024," 2024. [Online]. Available: http://scioteca.caf.com/bitstream/handle/123456789/1091/RED2017-Eng-8ene.pdf?sequence=12&isAllowed=y%0Ahttp://dx.doi.org/10.1016/j.regsciurbeco.2008.06.005%0Ahttps://www.researchgate.net/publication/305320484_SISTEM_PEMBETUNGAN_TERPUSAT_STRATEGI_MELESTARI

[5]. M. R. Baihaky, "Strategi Dinas Perhubungan Kota Tangerang dalam Menertibkan Parkir Liar di Kota Tangerang Tahun 2022 (Studi Kasus Kawasan Pasar Lama Kota Tangerang)," Universitas Nasional, 2022.

[6]. E. A. De Carvalho, "Identifikasi Karakteristik Perparkiran Di Koridor Jalan Surapati, Kota Bandung," Institut Teknologi Nasional, 2021.

[7]. E. Maulana, "Wakadishub Minta Petugas Lebih Humanis dan Persuasif Saat Lakukan Penindakan," Beritajakarta.id. Accessed: Sep. 28, 2024. [Online]. Available: https://m.beritajakarta.id/read/133707/wakadishub-minta-petugas-lebih-humanis-dan-persuasif-saat-lakukan-penindakan

[8]. M. I. Saputra, "Pengaruh Penggunaan Ruang Parkir pada Badan Jalan terhadap Kinerja Ruas Jalan Tlogosari Raya Kelurahan Tlogosari Kulon Kecamatan Pedurungan Kota Semarang," Universitas Islam Sultan Agung Semarang, 2022.

[9]. Jamiat, S. Ningsih, and S. S. Saliro, "Pengelolaan Parkir di Kota Sambas," *Irajagaddhita*, vol. 1, no. 2, pp. 78–86, 2023, doi: 10.59996/irajagaddhita.v1i2.275.

[10]. M. Ad-Dairobbi, "Penerapan Sanksi Denda terhadap Parkir Liar Kota Palembang," Universitas Sriwijaya, 2020. [Online]. Available: https://doi.org/10.1016/j.jnc.2020.125798%0Ahttps://doi.org/10.1016/j.smr.2020.02.002%0Ahttp://www.ncbi.nlm.nih.gov/pubmed/810049%0Ahttp://doi.wiley.com/10.1002/anie.197505391%0Ahttp://www.sciencedirect.com/science/article/pii/B9780857090409500205%0Ahttp:

[11]. H. F. Nababan, "Tiga Tahun Terakhir, Puluhan Ribu Kendaraan yang Parkir Liar Ditindak," kompas.id. Accessed: Nov. 06, 2024. [Online]. Available: https://www.kompas.id/baca/metro/2022/08/03/dalam-tiga-tahun-56902-kendaraan-ditindak-karena-parkir-liar

[12]. A. Widiyanto, "Sudinhub Jaksel Beri Sanksi 6.659 Kendaraan Parkir Liar di Tahun 2023," Beritajakarta.id. Accessed: Sep. 28, 2024. [Online]. Available: https://m.beritajakarta.id/read/134270/sudinhub-jaksel-beri-sanksi-6659-kendaraan-parkir-liar-di-tahun-2023

[13]. A. Andika, "Agama Dan Perkembangan Teknologi Di Era Modern," *Abrahamic Relig. J. Stud. Agama-Agama*, vol. 2, no. 2, p. 129, 2022, doi: 10.22373/arj.v2i2.12556.

[14]. A. P. O. Amane *et al.*, *Pemanfaatan Dan Penerapan Internet Of Things (IOT) Di Berbagai Bidang (Studi Kasus & Implemtansi Pemanfaatan serta Penerapan IoT dalam berbagai Bidang)*. Jambi: PT. Sonpedia Publishing Indonesia Redaksi, 2023. [Online]. Available: www.sonpedia.com

[15]. A. F. Febriyansyah, "Penerapan Iot Dalam Sistem Transportasi Untuk Peningkatan Efisiensi Lalu Lintas," *Portaldata.org*, vol. 3, no. 2, p. 1, 2023.

[16]. A. J. Pranata, E. Nasrullah, and A. U. Darajat, "Deteksi Pengendara Motor tanpa Helm Menggunakan YOLOv8 dengan Notifikasi Real-Time Melalui Telegram," *Kohesi J. Multidisiplin Saintek*, vol. 9, no. 4, pp. 1–13, 2025.

[17]. D. I. Mulyana and M. A. Rofik, "Implementasi Deteksi Real Time Klasifikasi Jenis Kendaraan Di Indonesia Menggunakan Metode YOLOV5," *J. Pendidik. Tambusai*, vol. 6, no. 3, pp. 13971–13982, 2022, doi: 10.31004/jptam.v6i3.4825.

[18]. A. R. Ramadhan, "Pembangunan Purwarupa Sistem Pendeteksi Parkir Liar Kendaraan Berbasis Iot (Internet Of Things) Di Dinas Perhubungan Kota Bandung," Universitas Komputer, 2019.

[19]. J. H. Jaman, A. R. Sanjaya, and Carudin, "Klasifikasi Jenis Mobil Paling Diminati Di Indonesia Menggunakan Algoritma Naïve Bayes," *Fakt. Exacta*, vol. 13, no. 1, pp. 18–25, 2020, doi: 10.30998/faktorexacta.v13i1.5573.