

Integrasi YOLOv11 dan *Intersection-Based Method* Untuk Estimasi Karakteristik Parkir Berdasarkan *Parking Lot Surveillance Video*

Muhammad Kamal Robbani^{1,*}, Yudi Wibisono², Eddy Prasetyo Nugroho³

^{1,2,3} Fakultas Pendidikan Matematika dan Ilmu Pengetahuan Alam, Program Studi Ilmu Komputer, Universitas Pendidikan Indonesia, Bandung, Indonesia

Email: ¹*kamalrobbani88@upi.edu, ²yudi@upi.edu, ³eddypn@upi.edu
(* Email Corresponding Author: kamalrobbani88@upi.edu)

Received: July 25, 2025 | Revision: July 27, 2025 | Accepted: July 30, 2025

Abstrak

Pertumbuhan kendaraan yang tidak diimbangi dengan ketersediaan lahan parkir telah menimbulkan berbagai permasalahan seperti kemacetan, pemborosan bahan bakar, dan emisi berlebih. Penelitian ini mengembangkan sistem analisis parkir berbasis *computer vision* menggunakan model YOLOv11 untuk mendeteksi kendaraan secara otomatis di area parkir. Sistem menggabungkan pendekatan *intersection-based method* dan algoritma *object tracking* BoT-SORT untuk mengklasifikasikan status ketersediaan spot parkir. Hasil klasifikasi tersebut akan digunakan untuk mengekstraksi data karakteristik parkir. Data video diambil dari *livestream* publik yang diakses melalui *platform* Youtube di Kusatsu, Jepang, dan digunakan untuk pelatihan serta evaluasi model. Model mencapai nilai $mAP@50-95$ sebesar 0,926 pada pencahayaan terang dan 0,859 pada kondisi gelap. Selain itu, evaluasi terhadap akurasi estimasi menggunakan MAE dan R^2 menunjukkan hasil yang baik, dengan MAE 1,27 dan R^2 0,989 pada siang hari, serta MAE 0,91 dan R^2 0,91 pada malam hari.

Kata Kunci: YOLOv11, Computer Vision, Deteksi Objek, Klasifikasi, Manajemen Parkir

Abstract

The rapid growth of vehicles without a corresponding increase in parking space availability has led to various issues such as traffic congestion, fuel waste, and excessive emissions. This study develops a computer vision-based parking analysis system using the YOLOv11 model to automatically detect vehicles in parking areas. The system integrates an intersection-based method and the BoT-SORT object tracking algorithm to classify parking spot availability. The classification results are then used to extract parking characteristic data. Video data were obtained from a publicly accessible livestream on YouTube in Kusatsu, Japan, and used for training and evaluating the model. The model achieved an $mAP@50-95$ of 0.926 under bright lighting conditions and 0.859 in low-light conditions. Additionally, estimation accuracy was evaluated using MAE and R^2 metrics, showing promising results, with MAE of 1.27 and R^2 of 0.989 during daytime, and MAE of 0.91 and R^2 of 0.91 at night.

Keywords: YOLOv11, Computer Vision, Object Detection, Classification, Parking Management

1. PENDAHULUAN

Pertumbuhan jumlah kendaraan, khususnya mobil pribadi, di Indonesia mengalami peningkatan yang signifikan dalam beberapa tahun terakhir. Berdasarkan data Badan Pusat Statistik (BPS), pada akhir tahun 2022 jumlah mobil penumpang di Indonesia mencapai sekitar 17,2 juta unit, meningkat sebesar 65% dibandingkan tahun 2012[1]. Peningkatan ini secara langsung menuntut tersedianya fasilitas penunjang, termasuk tempat parkir, yang merupakan bagian yang tidak bisa dipisahkan dari sistem transportasi[2]. Sayangnya, pertumbuhan ketersediaan tempat parkir tidak sebanding dengan jumlah kendaraan yang ada, sehingga terjadi ketidakseimbangan antara permintaan (jumlah mobil yang membutuhkan parkir) dan penawaran (kapasitas parkir yang tersedia)[3]. Kondisi ini sering kali mendorong pengendara untuk memarkirkan kendaraannya di tepi jalan (*on-street parking*), yang pada akhirnya memicu kemacetan lalu lintas[4]. Selain itu, manajemen parkir yang tidak optimal memperparah permasalahan ini, yang pada akhirnya menyebabkan pengendara menghabiskan waktu untuk mencari spot kosong[2].

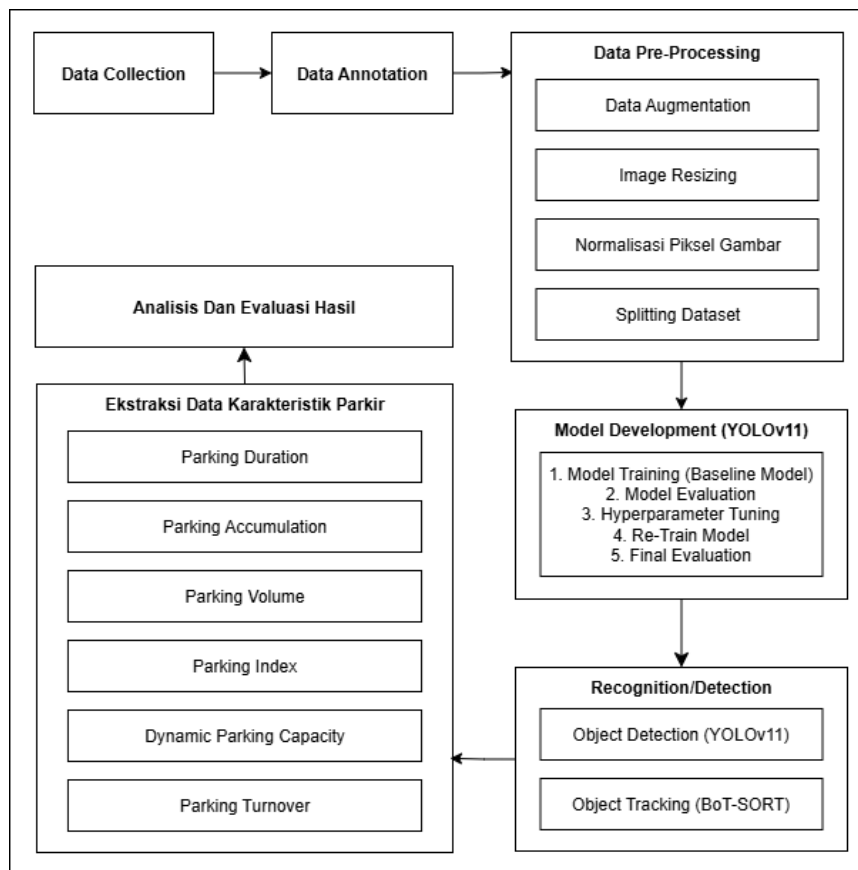
Masalah serupa juga terjadi di negara lain seperti Tiongkok. Jumlah kendaraan jauh melampaui jumlah ruang parkir yang tersedia. Berdasarkan data dari Kementerian Keamanan Publik Tiongkok menunjukkan bahwa pada tahun 2018, jumlah kepemilikan mobil di negara tersebut mencapai 240 juta unit, dengan tingkat pertumbuhan tahunan sebesar 10,51%. Sementara itu, jumlah tempat parkir yang tersedia hanya sekitar 102,5 juta unit, atau kurang dari 50% dari total kendaraan yang ada. Hal tersebut juga dibarengi dengan tingkat pemanfaatan tempat parkir yang belum optimal, yang mana di 90% kota di Tiongkok, tingkat pemanfaatan tempat parkir masih di bawah 50%. Akibatnya kemacetan dan inefisiensi terjadi secara signifikan[3]. Contoh lainnya, di Amerika Serikat, terjadi kerugian ekonomi yang ditimbulkan dari proses pencarian parkir[5]. Rata-rata pengendara menghabiskan \$345[3], dengan total \$73 milyar setiap tahunnya karena menghabiskan waktu, bahan bakar, dan menghasilkan emisi saat pengendara mencari spot parkir[5].

Penelitian ini berupaya menjawab tantangan tersebut dengan mengimplementasikan model YOLOv11 yang merupakan salah satu model *single-shot detector* (SSD)[6], untuk melakukan *object detection* mobil yang ada dalam area tempat parkir. Selanjutnya, hasil prediksi *bounding box* model YOLOv11 akan diintegrasikan dengan pendekatan *intersection-based method* untuk mengklasifikasikan ketersediaan spot parkir (terisi/tidak terisi). Hasil klasifikasi ketersediaan spot parkir tersebut, akan digunakan untuk mengekstraksi data karakteristik parkir, yaitu *parking accumulation*, *parking duration*, *parking volume*, *parking turnover*, *parking index*, dan *dynamic parking capacity*.

Harapannya data hasil ekstraksi tersebut selanjutnya dapat digunakan untuk analisis lebih lanjut oleh manajer parkir untuk mendapatkan *insight*, sehingga dapat digunakan untuk membantu manajer parkir dalam pengambilan keputusan yang berbasis data dalam upaya untuk mengoptimalkan manajemen parkir.

2. METODOLOGI PENELITIAN

Penelitian ini dirancang untuk mengembangkan sebuah sistem analisis tempat parkir berbasis *computer vision* yang mampu melakukan deteksi objek mobil, klasifikasi ketersediaan spot parkir, serta ekstraksi data karakteristik parkir secara otomatis berdasarkan *parking lot surveillance video*. Proses pengembangan dilakukan melalui serangkaian tahapan yang saling terintegrasi, mulai dari pengumpulan dan anotasi data, pelatihan model *object detection* menggunakan YOLOv11, *object tracking* menggunakan BoT-SORT, dan ekstraksi data karakteristik parkir. Alur metode penelitian secara lengkap ditampilkan pada gambar 1.



Gambar 1. Metode Penelitian

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan dan Persiapan Data

Data dalam penelitian ini diambil dari video *livestream* area parkir di Kusatsu, Jepang, yang dapat diakses secara terbuka melalui *platform* YouTube dan dapat diakses melalui link berikut: <https://www.youtube.com/watch?v=1PF1v9GJc>. Data terdiri dari 188 jam video hasil *download* selama periode sembilan hari, mulai dari 22 Mei 2025 hingga 30 Mei 2025, yang akan digunakan untuk ekstraksi data dan 264 gambar hasil *screenshot* yang akan digunakan untuk *fine-tuning* model YOLOv11. Contoh cuplikan dari video *parking lot surveillance camera* dapat dilihat pada gambar 2.



Gambar 2. (a) Contoh Kondisi Pencahayaan Gelap, (b) Contoh Kondisi Pencahayaan Terang

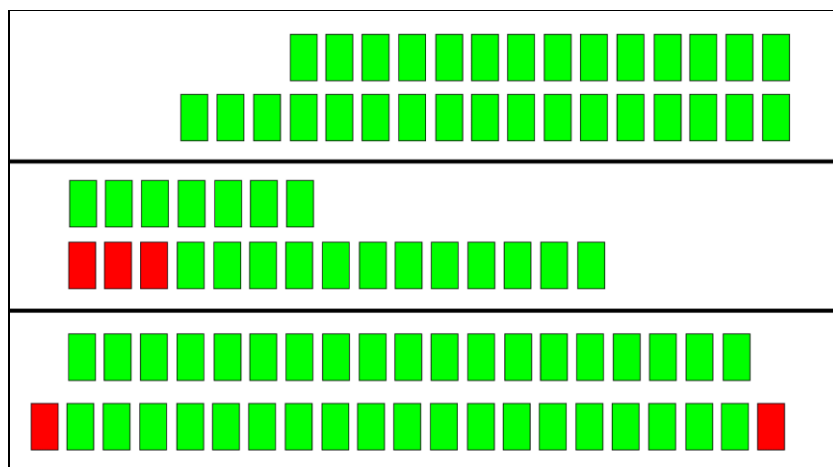
Lokasi ini dipilih karena merupakan area wisata yang cukup padat aktivitas, sehingga lalu lintas kendaraan yang terekam dalam video menunjukkan variasi yang tinggi, terutama saat akhir pekan atau hari libur nasional. Video tersebut dinilai layak sebagai sumber data karena memiliki durasi rekaman yang cukup panjang, kualitas visual yang memadai (resolusi 1080p dan *frame rate* 30 fps), sudut pandang kamera yang stabil, dan mencerminkan kondisi sebenarnya di lapangan tanpa adanya rekayasa dari penulis.

Meski demikian, terdapat beberapa keterbatasan dalam video, seperti area parkir tertentu yang tidak terekam karena sudut pandang kamera atau karena adanya distorsi visual akibat penggunaan kamera lensa yang cekung (*fisheye*). Contoh dari keterbatasan ini dapat dilihat pada gambar 3.



Gambar 3. (a) Contoh Efek Distorsi Karena *Fisheye Camera*, (b) Contoh Area Parkir yang Tidak Tertangkap Kamera Karena Sudut Pandang Kamera


Akibat keterbatasan tersebut, dari total 93 spot parkir yang tersedia, hanya 88 yang dapat dimanfaatkan untuk proses ekstraksi data karakteristik parkir. Ilustrasi spot parkir yang digunakan ditunjukkan pada gambar 4. Warna hijau menandai spot parkir yang digunakan, sementara warna merah menandai spot parkir yang tidak disertakan dalam analisis.



Gambar 4. Ilustrasi Spot Parkir yang Dianalisis

Video yang digunakan memiliki tingkat kejernihan visual sedang (*moderate visual clarity*). Elemen-elemen pribadi seperti wajah individu maupun nomor kendaraan tidak terlihat secara jelas atau tampak buram. Perlu ditegaskan bahwa penggunaan video ini semata-mata ditujukan untuk kepentingan akademik dan penelitian. Penulis tidak memiliki hak cipta atas video tersebut dan tidak menggunakannya untuk keperluan komersial ataupun distribusi ulang.

Pertama-tama, dilakukan *manual segmentation* area parkir untuk menentukan *Area of Interest* (ROI) menggunakan teknik *binary masking*. Hasil *segmentation* dapat dilihat pada gambar 5.



Gambar 5. (a) ROI Hasil Proses *Manual Segmentation*, (b) ROI Ketika Diterapkan

Selanjutnya dilakukan proses *data annotation*, yaitu proses pemberian lokasi dan kelas objek pada gambar, agar model dapat belajar mengenali pola visual objek dalam gambar[7]. Proses anotasi dilakukan secara manual dengan menggunakan *annotation tools* CVAT, lalu *dataset* dibagi menjadi *data training* dan *data validation* (80:20), dan dikonversi ke dalam YOLO format menggunakan *platform* Roboflow. Untuk *data pre-processing* selain dari proses *splitting dataset*, dilakukan secara otomatis oleh model YOLOv11[8].

3.2 Pengembangan dan Evaluasi Model YOLOv11

Model YOLOv11 dioptimalkan melalui proses *hyperparameter tuning* secara otomatis menggunakan *class* ‘Tuner’ pada *library* ‘Ultralytics’ yang menggunakan *genetic algorithms* untuk mencari nilai hyperparameter terbaik[9]. Selanjutnya dilakukan proses *fine-tuning* selama 200 epoch menggunakan *set hyperparameter* hasil proses *hyperparameter tuning*.

Evaluasi model dilakukan menggunakan metrik mAP@50-95 (*mean average precision*), yaitu sebuah metrik yang memberikan gambaran keseluruhan kinerja model dalam mendeteksi dan mengklasifikasikan berbagai objek dalam dataset[10]. Model mencapai nilai mAP@50-95 sebesar 0,873, yang menunjukkan kenaikan sebesar 0,032 dibandingkan dengan model *default* yang memiliki nilai mAP@50-95 sebesar 0,841. Rincian hasil proses *fine-tuning* pada dua model yang dibangun dapat dilihat pada gambar 6.

```
Ultralytics 8.3.107 Python-3.13.1 torch-2.6.0+cu118 CUDA:0 (NVIDIA GeForce RTX 4060 Laptop GPU, 8188MiB)
YOLO11m summary (fused): 125 layers, 20,030,803 parameters, 0 gradients, 67.6 GFLOPs
Class Images Instances Box(P R mAP50 mAP50-95) 100% | 2/2 [00:01:00:00, 1.26it/s]
all 53 2429 0.993 0.994 0.995 0.873
Speed: 0.2ms preprocess, 9.8ms inference, 0.0ms loss, 5.1ms postprocess per image
```

(a)

```
Ultralytics 8.3.107 Python-3.13.1 torch-2.6.0+cu118 CUDA:0 (NVIDIA GeForce RTX 4060 Laptop GPU, 8188MiB)
YOLO11m summary (fused): 125 layers, 20,030,803 parameters, 0 gradients, 67.6 GFLOPs
Class Images Instances Box(P R mAP50 mAP50-95) 100% | 2/2 [00:00:00:00, 2.36it/s]
all 53 2429 0.989 0.986 0.994 0.841
Speed: 0.2ms preprocess, 4.5ms inference, 0.0ms loss, 0.6ms postprocess per image
```

(b)

Gambar 6. (a) Performa YOLOv11 Setelah Tuning, (b) Performa YOLO Sebelum Tuning

Selanjutnya, dilakukan *testing* menggunakan 2 buah eksperimen yang berbeda, yaitu (1) menggunakan *dataset* dengan kondisi pencahayaan terang yang diambil pada pukul 09.00 - 15.00 dan (2) *dataset* dengan kondisi pencahayaan gelap yang diambil pada pukul 20.00 - 01.00 pada video hasil *download*. Hasil evaluasi *testing* dapat dilihat pada tabel 1.

Tabel 1. Hasil Evaluasi *Testing*

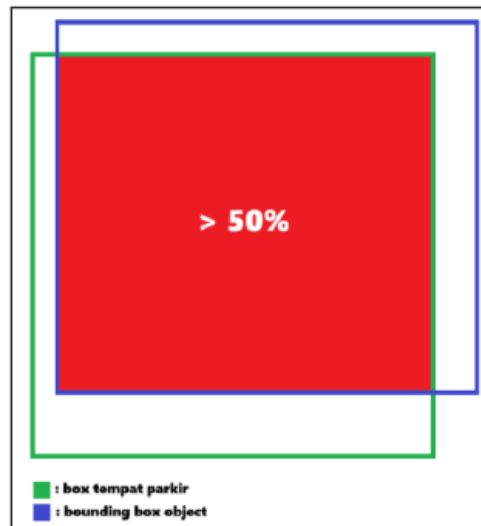
Kondisi	Metrik	Nilai
Terang	mAP@50	0,987
	mAP@50-95	0,926
Gelap	mAP@50	0,979
	mAP@50-95	0,859

Berdasarkan hasil *testing*, diketahui bahwa model menunjukkan kinerja yang lebih baik saat berada dalam kondisi pencahayaan terang (pukul 09.00-15.00), dibandingkan dengan kondisi gelap (pukul 20.00-01.00). Pada pencahayaan terang, model berhasil mencapai nilai mAP@50 sebesar 0,987 dan mAP@50-95 sebesar 0,926, yang mencerminkan tingkat akurasi yang tinggi dan konsisten pada berbagai ambang batas IoU. Sementara itu, saat diuji dalam kondisi pencahayaan gelap, performa model mengalami penurunan dengan nilai mAP@50 sebesar 0,979 dan mAP@50-95 sebesar 0,859. Meskipun hasil tersebut masih tergolong baik, penurunan ini mengindikasikan bahwa kualitas pencahayaan memberikan pengaruh terhadap efektivitas model dalam mendeteksi objek mobil. Secara umum, model

menunjukkan performa yang solid di kedua kondisi, namun kestabilan dan keakuratannya lebih terjaga ketika pencahayaan terang.


3.3 Ekstraksi Data Karakteristik Parkir

Proses ekstraksi data karakteristik parkir dilakukan dengan mengintegrasikan model YOLOv11 yang telah dikembangkan dengan pendekatan *intersection-based method*. Pendekatan *intersection-based method* merupakan sebuah pendekatan yang digunakan untuk melakukan klasifikasi ketersediaan suatu spot parkir (terisi/tidak), dengan cara melihat persentase *overlapping* antara *bounding box* objek mobil hasil prediksi *object detector* dan *bounding box* spot parkir [11]. Jika persentasenya di atas suatu *threshold* yang telah ditentukan, maka dianggap terisi dan sebaliknya. Ilustrasinya dapat dilihat pada gambar 7.



Gambar 7. Ilustrasi *Intersection-Based Method*

Bounding box spot parkir yang digunakan pada pendekatan *intersection-based method*, didapatkan dari hasil proses *manual segmentation*. Hasil dari *manual segmentation* berupa *binary mask* yang setiap *polygon* berwarna putih merepresentasikan sebuah spot parkir. Hasilnya dapat dilihat pada gambar 8.



Gambar 8. *Binary Mask Spot Parkir*

Untuk meningkatkan akurasi estimasi data karakteristik parkir, diterapkan pendekatan 4 *state transition* (terisi, tidak terisi, mungkin terisi, dan mungkin tidak terisi) dengan menambahkan 2 *temporary state*. *Current state* (terisi/tidak terisi) akan berubah jika *state* yang sama bertahan selama waktu *threshold* yang telah ditentukan. Ilustrasinya dapat dilihat pada gambar 9.




Gambar 9. Ilustrasi *State Transition*

Pendekatan ini digunakan untuk mengatasi mobil yang *overlap* secara tidak sengaja, namun mobil tidak parkir, atau prediksi *bounding box* objek mobil yang hilang sementara. Sehingga, status parkir tidak akan langsung berubah. Hal tersebut dapat terjadi akibat adanya *occlusion* atau sudut pandang kamera yang diagonal. Contohnya saat mobil yang sedang lewat, *overlapping* dengan *bounding box* spot parkir, seperti yang dapat dilihat pada gambar 10.




Gambar 10. Contoh Masalah *Overlapping* Sementara Karena Mobil Lewat

Selain itu, BoT-SORT diterapkan untuk melakukan *object tracking*. BoT-SORT merupakan sebuah metode *tracking-by-detection* yang digunakan untuk melakukan *multi-object tracking* (MOT)[12]. Tujuan penerapannya agar sebuah mobil yang parkir hanya bisa mengisi sebuah spot parkir, menggunakan ID hasil dari *object tracking* yang di-*assign* pada spesifik spot parkir. Jika ID sudah di-*assign* pada suatu spot parkir, maka ID tersebut tidak bisa digunakan di spot parkir lainnya. Hal ini digunakan untuk mengatasi masalah mobil yang parkir, namun *bounding box*-nya *overlapping* dengan lebih dari satu *bounding box* spot parkir akibat sudut pandang kamera. Contohnya dapat dilihat pada gambar 11.




Gambar 11. Contoh *Bounding Box* Mobil *Overlapping* dengan Lebih Dari Satu *Bounding Box* Spot Parkir

Lalu, untuk proses menentukan penempatan mobil pada suatu spot parkirnya, dilakukan dengan perhitungan jarak *centroid* terdekat antara *bounding box* mobil dengan *bounding box* spot parkir. Hal tersebut dapat dilakukan dengan menggunakan *euclidean distance* yang merupakan *distance metric* paling intuitif[13]. Mobil akan ditempatkan pada spot parkir yang memiliki jarak antar *centroid* terdekat. Ilustrasinya dapat dilihat pada gambar 12.




Gambar 12. Ilustrasi Penentuan Penempatan Spot Parkir Berdasarkan Jarak *Centroid*

Selain itu untuk menambahkan akurasi penempatan mobil, dilakukan *manual segmentation* berdasarkan hasil *spatial heatmap* yang menggambarkan rata-rata letak *centroid* mobil saat parkir. Hasilnya dapat dilihat pada gambar 13.



Gambar 13. (a) *Spatial Heatmap* Rata-Rata Mobil Parkir, (b) *Manual Segmentation* Berdasarkan *Spatial Heatmap*

Setiap polygon (berwarna putih) dalam hasil *manual segmentation* merepresentasikan sebuah spot parkir, dan hasil *manual segmentation* inilah yang digunakan dalam pendekatan *intersection-based method*. Hasilnya penempatan mobil pada suatu spot parkir menjadi lebih presisi, contohnya dapat dilihat pada gambar 14.



Gambar 14. (a) *Intersection-Based Method* Menggunakan *Bounding Box* Spot Parkir, (b) *Intersection-Based Method* Menggunakan *Bounding Box* Hasil *Spatial Heatmap*

Hasil dari proses klasifikasi ketersediaan spot parkir inilah yang selanjutnya digunakan untuk mengekstraksi data karakteristik parkir. Data karakteristik parkir diekstraksi dengan cara sebagai berikut:

- Parking accumulation:** Jumlah spot parkir yang terisi pada suatu periode tertentu[14]. Dilihat berdasarkan banyak spot parkir yang terisi (*state* = “terisi”) setiap interval waktu 60 menit.
- Parking index:** Persentase *parking accumulation* pada periode tertentu. Data diambil setiap interval waktu 60 menit. Persentase didapatkan dengan menggunakan persamaan 1[14].

$$\text{parking index} = \frac{\text{parking accumulation}}{\text{jumlah spot parkir (88)}} \quad (1)$$

- c. **Parking volume:** Banyaknya mobil yang menggunakan fasilitas parkir pada periode tertentu[14]. Menggunakan sebuah variabel sebagai *counter*, ketika ada *state* yang berubah “tidak terisi” → “terisi”, maka *counter* akan bertambah 1. Data diambil setiap interval waktu 60 menit.
- d. **Dynamic parking capacity:** Jumlah maksimum spot parkir yang terisi selama 60 menit[14]. Data diambil setiap interval waktu 60 menit. Nilai didapatkan dengan menggunakan persamaan 2[15].


$$\text{kapasitas dinamis} = \frac{\text{jumlah spot parkir} \times 60 \text{ menit}}{\text{rata-rata durasi parkir (menit)}} \quad (2)$$

- e. **Parking duration:** Durasi parkir suatu kendaraan. Durasi diambil ketika ada perubahan *state* “terisi” → “tidak terisi”. Durasi didapatkan dengan menggunakan persamaan 3.

$$\text{parking duration} = \text{parking end time} - \text{parking start time} \quad (3)$$

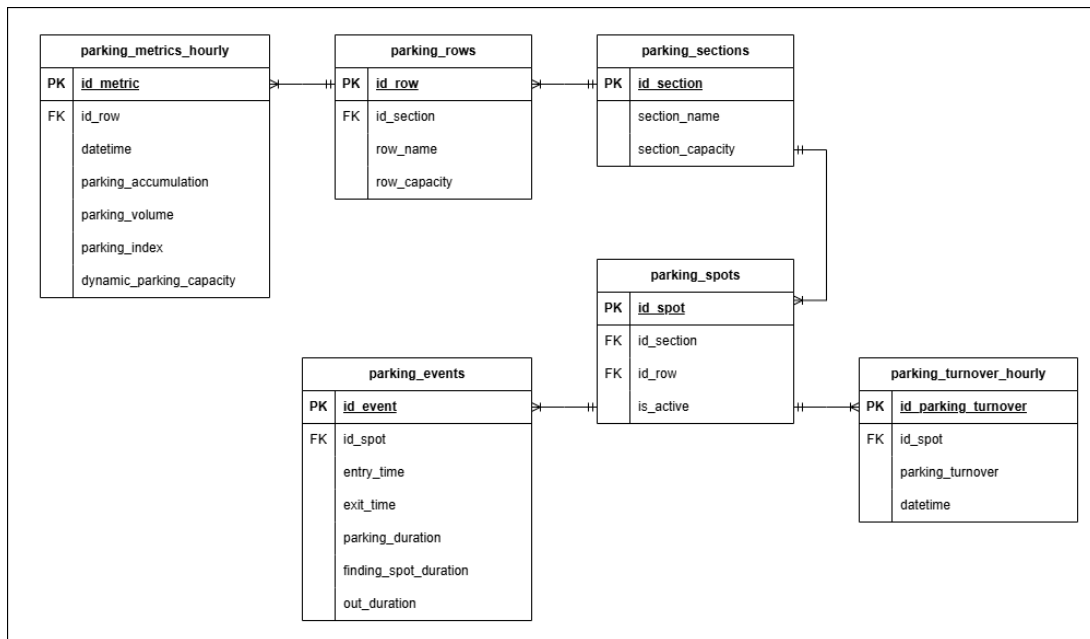
- f. **Parking turnover:** Frekuensi penggunaan ruang parkir selama periode tertentu[15]. Data diambil per-*parking spot* dengan menggunakan sebuah variabel sebagai *counter* yang disisipkan pada setiap *parking spot*. Ketika ada perubahan *state* “tidak terisi” → “terisi” pada suatu spesifik *parking spot*, maka *counter* akan bertambah pada spesifik *parking spot* tersebut. Data diambil setiap interval waktu 60 menit.

Penulis membagi tempat parkir menjadi 3 *section* (*section A*, *section B*, dan *section C*), yang masing-masing *section* memiliki 2 baris (*row*). Ilustrasinya dapat dilihat pada gambar 15 dengan panah berwarna kuning menggambarkan flow dari kendaraan.



Gambar 15. Pembagian *Section* dan *Row* Tempat Parkir

Data karakteristik parkir hasil proses ekstraksi tersebut, selanjutnya dimasukkan ke dalam *database* PostgreSQL. Skema dari *database* yang dibuat dapat dilihat pada gambar 16.



Gambar 16. Skema Database

Database terdiri dari 6 buah tabel yang penjelasan setiap tabelnya dijelaskan sebagai berikut:

- “parking_sections”**: Tabel untuk menyimpan data setiap *parking section*
- “parking_rows”**: Tabel untuk menyimpan data setiap *parking row*.
- “parking_spots”**: Tabel untuk menyimpan data setiap *parking spot*.
- “parking_event”**: Tabel untuk menyimpan data setiap mobil yang menggunakan fasilitas parkir.
- “parking_metrics_hourly”**: Tabel untuk menyimpan data karakteristik parkir per-*parking row* yang disimpan setiap interval 60 menit selain *parking turnover*.
- “parking_turnover_hourly”**: Tabel untuk menyimpan data *parking turnover* setiap spot parkirnya dalam interval waktu setiap 60 menit.

3.4 Evaluasi Hasil Estimasi Data Karakteristik Parkir

Untuk evaluasi hasil estimasi data karakteristik parkir, dilakukan 2 buah eksperimen menggunakan *dataset* yang sama saat proses *testing*. Evaluasi dilakukan hanya berdasarkan data *parking accumulation*, dengan alasan karena penulis tidak memiliki nilai aktual dari setiap karakteristik parkir dan kemudahan untuk mendapatkan nilai aktual *parking accumulation* secara manual. Metrik yang digunakan dalam proses evaluasi adalah *mean absolute error* (MAE) yang digunakan untuk menghitung rata-rata perbedaan *error* dalam *set of predictions*[16], dan *r-squared* (R^2) untuk mengevaluasi kualitas suatu model regresi yang merepresentasikan seberapa besar proporsi variasi *dependant variable* yang dapat dijelaskan oleh model[17]. Pada kondisi terang, diperoleh MAE sebesar 1,27 dan R^2 sebesar 0,989. Sementara itu pada kondisi gelap, nilai MAE lebih rendah dengan nilai sebesar 0,91, namun nilai R^2 sedikit turun menjadi 0,91. Hasil tersebut menunjukkan bahwa sistem sudah memiliki akurasi estimasi yang cukup baik dalam berbagai kondisi pencahayaan.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sebuah sistem analisis parkir berbasis *computer vision* yang mampu melakukan deteksi objek mobil, klasifikasi ketersediaan spot parkir, serta ekstraksi data karakteristik parkir secara otomatis berdasarkan *parking lot surveillance video*. Dengan mengimplementasikan model YOLOv11, sistem mampu melakukan object detection secara efisien dan akurat, yang kemudian dikombinasikan dengan *intersection-based method* untuk melakukan klasifikasi ketersediaan tempat parkir. Model telah dioptimalkan melalui proses *hyperparameter tuning* dan *fine-tuning*, dengan hasil evaluasi menunjukkan performa yang stabil pada kondisi pencahayaan terang maupun gelap. Nilai *mAP@50-95* mencapai 0,926 pada kondisi terang dan 0,859 pada kondisi gelap, yang menunjukkan bahwa model cukup adaptif terhadap variasi pencahayaan. Selain itu, sistem juga berhasil mengekstraksi enam indikator karakteristik parkir utama, yaitu *parking accumulation*, *parking duration*, *parking index*, *parking volume*, *parking turnover*, dan *dynamic parking capacity*. Evaluasi dari performa estimasi data karakteristik parkir menggunakan hasil estimasi *parking accumulation* juga menunjukkan hasil yang baik, dengan nilai MAE sebesar 1,27 dan R^2 sebesar 0,989 pada kondisi terang, serta nilai MAE sebesar 0,91 dan R^2 sebesar 0,91 pada kondisi gelap.

REFERENCES

- [1] A. Ahdiat, "Ini Pertumbuhan Jumlah Mobil di Indonesia 10 Tahun Terakhir," Databoks - Katadata. Accessed: Jul. 12, 2025. [Online]. Available: https://databoks.katadata.co.id/transportasi-logistik/sta_tistik/f266a30f3f686f1/ini-pertumbuhan-jumlah-mobil-di-indonesia-10-tahun-terakhir
- [2] M. R. Arfianto, "Analisis Desain User Interface pada Aplikasi Pencari Parkir Mobil," *Desainpedia J. Urban Des. Lifestyle Behav.*, vol. 1, no. 1, 2022, doi: 10.36262/dpj.v1i1.589.
- [3] Z. Zhao and Y. Zhang, "A Comparative Study of Parking Occupancy Prediction Methods considering Parking Type and Parking Scale," *J. Adv. Transp.*, vol. 2020, 2020, doi: 10.1155/2020/5624586.
- [4] D. A. Yulmida, S. W. Mudjanarko, M. I. Setiawan, and A. D. Limantara, "Analisis Kinerja Parkir Sepanjang Jalan Walikota Mustajab Surabaya," *UKaRsT*, vol. 1, no. 1, p. 11, 2018, doi: 10.30737/ukarst.v1i1.81.
- [5] B. Benjdira, A. Koubaa, W. Boulila, and A. Ammar, "Parking Analytics Framework using Deep Learning," in *Proceedings - 2022 2nd International Conference of Smart Systems and Emerging Technologies, SMARTTECH 2022*, 2022. doi: 10.1109/SMARTTECH54121.2022.00051.
- [6] N. Jegham, C. Y. Koh, M. Abdelatti, and A. Hendawi, "YOLO Evolution: A Comprehensive Benchmark and Architectural Review of YOLOv12, YOLO11, and Their Previous Versions," 2025, [Online]. Available: <http://arxiv.org/abs/2411.00201>
- [7] F. Galbusera and A. Cina, "Image annotation and curation in radiology: an overview for machine learning practitioners," 2024. doi: 10.1186/s41747-023-00408-y.
- [8] Ultralytics, "Data Preprocessing Techniques for Annotated Computer Vision Data," Ultralytics. Accessed: Jul. 15, 2025. [Online]. Available: https://docs.ultralytics.com/guides/preprocessing_annotated_data/
- [9] Ultralytics, "Ultralytics YOLO Hyperparameter Tuning Guide," Ultralytics. Accessed: Jul. 15, 2025. [Online]. Available: <https://docs.ultralytics.com/guides/hyperparameter-tuning/>
- [10] F. Fritsch, "Deep Neural Networks for Object Detection in Satellite Imagery," 2023.
- [11] A. Martynova *et al.*, "Revising deep learning methods in parking lot occupancy detection," pp. 1–22, 2023, [Online]. Available: <http://arxiv.org/abs/2306.04288>
- [12] N. Aharon, R. Orfaig, and B.-Z. Bobrovsky, "BoT-SORT: Robust Associations Multi-Pedestrian Tracking," no. 2, 2022, [Online]. Available: <http://arxiv.org/abs/2206.14651>
- [13] A. Ultsch and J. Löttsch, "Euclidean distance-optimised data transformation for cluster analysis in biomedical data (EDOtrans)," *BMC Bioinformatics*, vol. 23, no. 1, 2022, doi: 10.1186/s12859-022-04769-w.
- [14] G. Nurinda Abdi and A. Nur Jannah, "EVALUASI KARAKTERISTIK DAN KEBUTUHAN RUANG PARKIR SEPEDA MOTOR (STUDI KASUS PT TIRTA INVESTAMA WONOSOBO)," *Teknisia*, vol. 27, no. 1, 2022, doi: 10.20885/teknisia.vol27.iss1.art6.
- [15] G. Pramono, N. M. Rangkuti, and M. Lubis, "Analisa Durasi dan Kapasitas Parkir Manhattan Times Square," *J. Civ. Eng. Build. Transp.*, vol. 3, no. 1, 2019, doi: 10.31289/jcebt.v3i1.2457.
- [16] J. Qi, J. Du, S. M. Siniscalchi, X. Ma, and C. H. Lee, "On Mean Absolute Error for Deep Neural Network Based Vector-to-Vector Regression," *IEEE Signal Process. Lett.*, vol. 27, 2020, doi: 10.1109/LSP.2020.3016837.
- [17] H. Pham, "A new criterion for model selection," *Mathematics*, vol. 7, no. 12, 2019, doi: 10.3390/MATH7121215.