

Model MODEPA-8 (Model Deteksi Parkir) UNSIKA

Menggunakan YOLOv8 dengan Perbandingan Epoch 30 dan 50

MODEPA-8 Model (Parking Detection Model) at UNSIKA Using YOLOv8 with a Comparison of 30 and 50 Epochs

Arjuno Putro Bayu¹, Furkhon Nurdiyanto², Hakim Wirawan³, Irwana⁴, Lela Nurpulaela⁵

^{1,2,3,5}Teknik Elektro, Fakultas Teknik, Universitas Singaperbangsa Karawang

⁴Rekayasa Teknik Industri, Fakultas Teknik, Universitas Sehati Indonesia

¹2110631160033@student.unsika.ac.id, ²2110631160045@student.unsika.ac.id*,

³2510631160028@student.unsika.ac.id*, ⁴irwana844@gmail.com*, ⁵lela.nurpulaela@ft.unsika.ac.id*

Abstract

Parking availability in campus environments has become a critical issue due to the increasing number of vehicles and limited parking space, particularly at Universitas Singaperbangsa Karawang (UNSIKA). Conventional parking management systems that rely on manual processes lead to inefficiencies and prolonged parking search times. This study aims to develop MODEPA-8, a YOLOv8 (You Only Look Once)-based parking detection model, and to analyze the impact of different training epoch configurations on parking detection performance. A quantitative experimental approach with computer vision techniques was employed, where the model was trained using two epoch configurations, namely 30 and 50 epochs, on a campus parking image dataset. Model performance was evaluated using mAP50–95, mAP50, precision, recall, F1 Score, and Confusion Matrix metrics. Experimental results indicate that MODEPA-8 trained for 30 epochs achieved an mAP50–95 of 0.91862, mAP50 of 0.97516, precision of 0.97679, and recall of 0.95186 with a training time of approximately 5,690 seconds. Training the model for 50 epochs slightly improved mAP50–95 to 0.92259 and recall to 0.95783 but required a substantially longer training time of about 14,143 seconds. The marginal performance gain of less than 1% demonstrates diminishing returns from additional training epochs. Therefore, MODEPA-8 trained for 30 epochs is recommended as the most efficient and practical configuration for implementing a smart parking system in a campus environment.

Keywords: *Campus parking system, MODEPA-8, parking detection, UNSIKA, YOLO (You Only Look Once)*

Abstrak

Ketersediaan parkir di lingkungan kampus menjadi permasalahan serius seiring meningkatnya jumlah kendaraan dan keterbatasan lahan parkir, khususnya di Universitas Singaperbangsa Karawang (UNSIKA). Sistem parkir konvensional yang belum terotomatisasi menyebabkan waktu pencarian parkir yang panjang dan inefisiensi operasional. Penelitian ini bertujuan untuk mengembangkan MODEPA-8, yaitu model deteksi parkir berbasis YOLOv8 (*You Only Look Once*), serta menganalisis pengaruh perbedaan jumlah epoch pelatihan terhadap performa deteksi parkir. Metode yang digunakan adalah penelitian eksperimental kuantitatif dengan pendekatan visi komputer, di mana model dilatih menggunakan dua konfigurasi epoch, yaitu 30 dan 50 epoch, pada dataset citra area parkir kampus UNSIKA. Evaluasi performa dilakukan menggunakan metrik mAP50–95, mAP50, *precision*, *recall*, *F1 Score*, dan *Confusion Matrix*. Hasil eksperimen menunjukkan bahwa MODEPA-8 dengan pelatihan 30 epoch mencapai mAP50–95 sebesar 0,91862, mAP50 sebesar 0,97516, *precision* 0,97679, dan *recall* 0,95186 dengan waktu pelatihan sekitar 5.690 detik. Sementara itu, pelatihan 50 epoch menghasilkan mAP50–95 sebesar 0,92259 dan *recall* 0,95783, namun membutuhkan waktu pelatihan yang jauh lebih lama, yaitu sekitar 14.143 detik. Selisih peningkatan performa yang kurang dari 1% menunjukkan adanya *diminishing returns* pada penambahan epoch. Oleh karena itu, MODEPA-8 dengan konfigurasi pelatihan 30 epoch direkomendasikan sebagai solusi paling efisien dan optimal untuk implementasi sistem parkir cerdas di lingkungan kampus.

Kata kunci: deteksi parkir, MODEPA-8, sistem parkir kampus, UNSIKA, YOLO (*You Only Look Once*)

Pendahuluan

Masalah ketersediaan parkir di kawasan kampus dan perkotaan terus meningkat seiring pertumbuhan kendaraan bermotor dan mobilitas mahasiswa. Pengelolaan parkir yang tidak efisien menyebabkan waktu pencarian tempat parkir yang panjang, kemacetan lokal, serta penurunan kenyamanan pengguna, sehingga dibutuhkan solusi deteksi parkir otomatis yang andal dan real-time [1]. Pendekatan berbasis visi komputer dan *deep learning* menjadi alternatif yang efisien dibandingkan sensor fisik karena memanfaatkan kamera yang sudah tersedia pada banyak lingkungan kampus. Model deteksi objek modern dari keluarga YOLO terbukti memiliki kecepatan inferensi tinggi dan akurasi yang kompetitif untuk aplikasi parkir cerdas [2], [3]. Oleh karena itu, pengembangan sistem deteksi parkir berbasis YOLOv8 menjadi relevan untuk meningkatkan efisiensi pengelolaan parkir di lingkungan kampus UNSIKA.

Penelitian terkini menunjukkan bahwa deteksi slot dan area parkir menggunakan varian YOLO mengalami peningkatan signifikan dalam akurasi dan kecepatan, termasuk penerapan YOLOv8 pada berbagai skenario parkir statis dan dinamis. Studi sebelumnya melaporkan bahwa optimasi backbone, augmentasi data, dan penyesuaian *head network* mampu meningkatkan nilai mAP serta ketahanan model terhadap variasi pencahayaan dan sudut kamera [3]–[5]. Beberapa penelitian di Indonesia juga mulai mengadopsi YOLOv8 untuk pengenalan kendaraan dan plat nomor di lingkungan kampus, yang membuktikan kelayakan implementasi model ini pada infrastruktur lokal [6], [7]. Meskipun demikian, sebagian besar penelitian berfokus pada perbandingan antar versi YOLO atau modifikasi arsitektur jaringan. Studi komparatif yang secara khusus mengevaluasi pengaruh jumlah epoch pelatihan terhadap performa deteksi pada dataset parkir kampus masih sangat terbatas [8], [9].

Berdasarkan tinjauan literatur tersebut, terlihat bahwa sebagian besar penelitian belum mengevaluasi parameter pelatihan sederhana namun krusial, seperti variasi jumlah epoch, secara sistematis pada skenario parkir kampus yang padat. Banyak studi lebih menitikberatkan pada kompleksitas arsitektur atau teknik augmentasi data tanpa menganalisis dampak peningkatan epoch terhadap potensi overfitting dan efisiensi pelatihan [4], [11]. Kondisi ini menimbulkan gap praktis, khususnya bagi pengembang sistem parkir kampus yang membutuhkan rekomendasi empiris berbasis data lokal. Selain itu, penelitian di Indonesia yang melaporkan metrik evaluasi terstandar seperti mAP, *precision*, *recall*, *F1 Score*, dan *Confusion Matrix* pada YOLOv8 masih relatif sedikit [6], [7]. Gap lain yang teridentifikasi adalah belum adanya model parkir kampus yang dikemas sebagai produk penelitian dengan identitas yang jelas untuk mendukung transfer teknologi.

Penelitian ini dilakukan untuk mengisi gap tersebut sekaligus menyediakan panduan praktis bagi implementasi sistem parkir otomatis di UNSIKA. Penelitian mengusulkan MODEPA-8 sebagai model deteksi parkir yang dilatih menggunakan YOLOv8 dengan perbandingan epoch 30 dan epoch 50. Pendekatan ini memberikan bukti kuantitatif mengenai trade-off antara akurasi deteksi, waktu pelatihan, dan kemampuan generalisasi pada kondisi parkir yang padat dan memiliki tingkat occlusion tinggi. Hasil penelitian diharapkan membantu pengelola kampus dalam memilih konfigurasi pelatihan yang paling efisien dan stabil untuk implementasi nyata. Dengan demikian, MODEPA-8 tidak hanya berperan sebagai model teknis, tetapi juga sebagai dasar pengambilan keputusan operasional di lingkungan UNSIKA.


Tujuan penelitian ini adalah (1) mengembangkan MODEPA-8 sebagai Model Deteksi Parkir UNSIKA berbasis YOLOv8, (2) membandingkan performa deteksi antara pelatihan epoch 30 dan epoch 50, dan (3) menganalisis trade-off antara akurasi dan efisiensi inferensi pada skenario parkir kampus yang padat. Novelty penelitian terletak pada eksperimen terkontrol yang secara spesifik menilai dampak jumlah epoch pada dataset parkir kampus lokal. Selain itu, penelitian ini mengemas hasil sebagai produk model bernama MODEPA-8 untuk memudahkan replikasi dan adopsi praktis. Kontribusi lain adalah penyajian evaluasi komprehensif menggunakan metrik mAP, *precision*, *recall*, *F1 Score*, dan *Confusion Matrix*, serta analisis generalisasi antar kamera. Dengan target implementasi nyata di UNSIKA, penelitian ini diharapkan memperkuat literatur parkir cerdas yang aplikatif di lingkungan kampus Indonesia.

Metode Penelitian

1. Jenis dan Pendekatan Penelitian

Penelitian ini merupakan penelitian eksperimental kuantitatif yang bertujuan mengevaluasi kinerja model deteksi parkir berbasis deep learning secara terukur dan objektif. Pendekatan yang digunakan adalah pengembangan dan evaluasi model deep learning berbasis visi komputer dengan memanfaatkan arsitektur YOLOv8 sebagai inti sistem deteksi objek [13]. Fokus utama penelitian diarahkan pada analisis komparatif jumlah epoch pelatihan terhadap performa deteksi parkir, khususnya dalam mengukur perubahan akurasi, *precision*, *recall*, dan *F1 Score*. Objek penelitian adalah area parkir kampus Universitas Singaperbangsa Karawang (UNSIKA) yang memiliki tingkat kepadatan kendaraan tinggi dan variasi kondisi lingkungan. Output penelitian ini berupa model deteksi parkir MODEPA-8 serta rekomendasi konfigurasi pelatihan yang efisien dan layak untuk implementasi sistem parkir kampus [14].

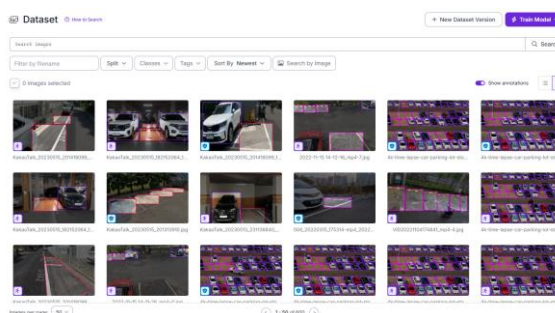
2. Alur Penelitian



Z`Gambar 1. Blok Diagram MODEPA8

Pada Gambar x. Alur penelitian ini dirancang secara sistematis untuk menghasilkan model deteksi parkir MODEPA-8 yang terukur dan dapat direplikasi. Penelitian diawali dengan identifikasi permasalahan kepadatan parkir di lingkungan kampus UNSIKA, dilanjutkan dengan pengumpulan dataset citra area parkir dari kamera statis. Dataset yang diperoleh kemudian melalui proses pelabelan kelas *empty*, *occupied*, dan *background*, serta tahap pra-pemrosesan untuk menyesuaikan format input model YOLOv8. Selanjutnya, MODEPA-8 dilatih menggunakan dua konfigurasi jumlah epoch, yaitu 30 dan 50 epoch, dengan parameter pelatihan lain dibuat identik untuk menjaga keadilan eksperimen. Tahap akhir penelitian meliputi evaluasi performa menggunakan metrik mAP, *precision*, *recall*, *F1 Score*, dan *Confusion Matrix*, yang kemudian dianalisis secara komparatif untuk menentukan konfigurasi pelatihan paling efisien dan optimal bagi implementasi sistem parkir kampus.

3. Dataset dan Akuisisi Data



Gambar 2. Dataset Modepa8

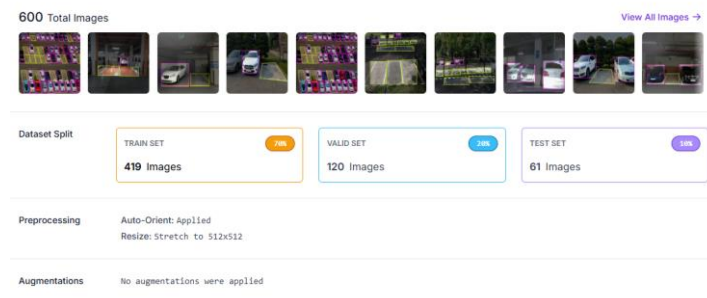
Pada gambar x. Dataset yang digunakan dalam penelitian ini diperoleh dari Roboflow dan juga area parkir kampus Universitas Singaperbangsa Karawang (UNSIKA) sebagai representasi kondisi parkir kampus dengan tingkat kepadatan tinggi dengan total . Data dikumpulkan dalam bentuk citra hasil tangkapan kamera statis yang dipasang pada beberapa sudut area parkir untuk menangkap variasi posisi kendaraan dan sudut pandang. Proses akuisisi data dilakukan pada kondisi lingkungan yang beragam, termasuk perbedaan pencahayaan, tingkat kepadatan kendaraan, dan waktu

pengambilan, guna meningkatkan generalisasi model deteksi [15]. Seluruh citra disimpan dalam format digital dengan resolusi yang disesuaikan agar kompatibel dengan kebutuhan pelatihan model YOLOv8. Dataset kemudian dibagi ke dalam data pelatihan, validasi, dan pengujian untuk memastikan proses evaluasi MODEPA-8 berjalan objektif dan terkontrol [16].

4. Pelabelan Data

Pelabelan data dilakukan untuk memberikan informasi kelas objek yang jelas sebagai dasar pelatihan model deteksi parkir MODEPA-8. Setiap citra dianotasi menggunakan metode *bounding box* dengan tiga kelas utama, yaitu *empty*, *occupied*, dan *background*, sesuai dengan kondisi aktual area parkir kampus UNSIKA. Proses anotasi mengikuti standar format YOLO untuk memastikan kompatibilitas langsung dengan *pipeline* pelatihan YOLOv8 [17]. Konsistensi dan ketepatan pelabelan dijaga dengan pemeriksaan ulang anotasi guna meminimalkan kesalahan klasifikasi yang dapat memengaruhi performa model. Tahap pelabelan ini berperan penting dalam meningkatkan akurasi deteksi dan stabilitas hasil evaluasi MODEPA-8 pada skenario parkir padat [18].

5. Prapemrosesan dan Augmentasi Data



Gambar 3. Prapemrosesan dan Augmentasi Data MODEPA 8

Tahap pra-pemrosesan data dilakukan untuk memastikan seluruh citra memiliki format dan kualitas yang seragam sebelum digunakan dalam pelatihan model MODEPA-8. Dataset dibagi ke dalam tiga subset, yaitu data pelatihan sebesar 70% dengan total 419 citra, data validasi sebesar 20% dengan 120 citra, dan data pengujian sebesar 10% dengan 61 citra, sehingga proses evaluasi dapat dilakukan secara objektif. Proses auto-orient diterapkan untuk menyesuaikan orientasi citra secara otomatis agar konsisten dengan metadata kamera. Selanjutnya, seluruh citra diubah ukurannya menggunakan metode *stretch* menjadi resolusi 512×512 piksel agar sesuai dengan kebutuhan input model YOLOv8. Pada penelitian ini tidak diterapkan teknik augmentasi data, sehingga performa model sepenuhnya merefleksikan kemampuan MODEPA-8 dalam mempelajari pola asli dari dataset parkir kampus UNSIKA.

6. Perancangan Model MODEPA8

MODEPA-8 dirancang sebagai model deteksi parkir berbasis YOLOv8 yang dioptimalkan untuk mengenali kondisi area parkir kampus UNSIKA secara *real-time*. Arsitektur MODEPA-8 mengadopsi struktur utama YOLOv8 yang terdiri dari backbone untuk ekstraksi fitur, neck untuk penggabungan fitur multi-skala, dan head untuk proses deteksi objek. Model ini dirancang untuk mendeteksi tiga kelas objek, yaitu *empty*, *occupied*, dan *background*, sehingga mampu merepresentasikan kondisi parkir secara komprehensif. Penyesuaian model difokuskan pada konfigurasi kelas dan parameter deteksi tanpa mengubah struktur dasar arsitektur, guna menjaga stabilitas dan efisiensi pelatihan. Dengan rancangan tersebut, MODEPA-8 diharapkan mampu memberikan performa deteksi yang akurat dan konsisten pada lingkungan parkir kampus dengan tingkat kepadatan tinggi.

7. Konfigurasi Pelatihan Model

Pelatihan model MODEPA-8 dilakukan menggunakan lingkungan Google Colab dengan dukungan GPU NVIDIA Tesla T4 untuk mempercepat proses komputasi. Model dilatih menggunakan framework YOLOv8 dengan parameter pelatihan yang dibuat konsisten pada seluruh skenario eksperimen. Konfigurasi utama pelatihan meliputi ukuran citra input sebesar 512×512 piksel, optimizer bawaan YOLOv8, serta learning rate dan batch size default yang disesuaikan dengan kapasitas perangkat keras. Untuk menganalisis pengaruh jumlah epoch terhadap performa model, pelatihan dilakukan menggunakan dua konfigurasi, yaitu 30 epoch dan 50 epoch, dengan parameter lain dijaga tetap sama. Pendekatan ini memungkinkan evaluasi yang adil terhadap dampak variasi epoch pelatihan terhadap akurasi dan efisiensi MODEPA-8.


8. Metode Evaluasi

Evaluasi performa model MODEPA-8 dilakukan untuk mengukur kemampuan deteksi parkir secara kuantitatif dan objektif. Model dievaluasi menggunakan beberapa metrik utama, yaitu mean Average Precision (mAP50–95 dan mAP50), *precision*, *recall*, dan *F1 Score* untuk menilai keseimbangan antara ketepatan dan kelengkapan deteksi. Selain itu, *Confusion Matrix* digunakan untuk menganalisis pola kesalahan klasifikasi pada setiap kelas objek, yaitu *empty*, *occupied*, dan *background*. Penentuan *Confidence threshold* optimal dilakukan berdasarkan analisis kurva F1 untuk memperoleh kinerja deteksi terbaik pada implementasi sistem. Seluruh metrik evaluasi dihitung menggunakan data pengujian guna memastikan hasil yang diperoleh merefleksikan kemampuan generalisasi MODEPA-8 pada kondisi parkir kampus yang nyata.

Hasil dan Pembahasan

1. Hasil Pelatihan Model MODEPA-8


A. 30 Epoch



Gambar 4. Pelatihan MODEPA 30 Epoch

Hasil pelatihan MODEPA-8 selama 30 epoch menunjukkan proses pembelajaran yang stabil dan konvergen dengan performa yang tinggi. Pada akhir pelatihan, nilai training loss menurun secara konsisten hingga mencapai sekitar 0,34 untuk box loss, 0,25 untuk *classification loss*, dan 0,86 untuk *distribution focal loss*, yang menandakan peningkatan kemampuan lokalisasi dan klasifikasi objek. Pola serupa terlihat pada *validation loss*, dengan nilai akhir sekitar 0,58 (box loss), 0,39 (cls loss), dan 0,99 (df loss) tanpa fluktuasi tajam, sehingga tidak mengindikasikan overfitting. Seiring dengan penurunan loss, performa deteksi meningkat dengan nilai *precision* 0,97679 dan *recall* 0,95186, yang menunjukkan keseimbangan baik antara ketepatan dan kelengkapan deteksi. Selain itu, model mencapai nilai mAP50 sebesar 0,97516 dan mAP50–95 sebesar 0,91862, menandakan bahwa MODEPA-8 telah mencapai performa optimal pada pelatihan 30 epoch dengan waktu pelatihan sekitar 5.690 detik.

B. 50 Epoch




Gambar 5. Pelatihan MODEPA 50 Epoch

Hasil pelatihan MODEPA-8 selama 50 epoch menunjukkan proses pembelajaran yang stabil dengan peningkatan performa yang bersifat marginal dibandingkan pelatihan 30 epoch. Pada akhir pelatihan, nilai *training loss* mencapai sekitar 0,30 untuk *box loss*, 0,23 untuk *classification loss*, dan 0,85 untuk *distribution focal loss*, yang menunjukkan penyempurnaan kecil pada kemampuan lokalisasi dan klasifikasi objek. Nilai validation loss juga menurun secara konsisten hingga sekitar 0,57 (box loss), 0,38 (cls loss), dan 0,99 (df loss) tanpa lonjakan signifikan, sehingga tidak menunjukkan indikasi overfitting meskipun jumlah epoch ditambah. Dari sisi performa deteksi, model memperoleh *precision* 0,97518 dan *recall* 0,95783, yang mencerminkan peningkatan kecil pada kemampuan mendeteksi seluruh objek parkir dibandingkan epoch 30. Selain itu, nilai mAP50 sebesar 0,97680 dan mAP50–95 sebesar 0,92259 dicapai dengan waktu pelatihan sekitar 14.143 detik, yang menunjukkan bahwa tambahan epoch meningkatkan performa secara terbatas dengan biaya komputasi yang jauh lebih besar.

2. Evaluasi Performa Deteksi MODEPA-8

A. Evaluasi Performa MODEPA-8 30 Epoch

1) *Precision*




Gambar 6. *Precision* MODEPA 30 Epoch

Kurva *Precision–Confidence* pada MODEPA-8 dengan pelatihan 30 epoch menunjukkan tingkat ketepatan deteksi yang tinggi dan stabil pada berbagai nilai *Confidence*. *Precision* meningkat tajam pada *Confidence* rendah dan mulai berada di atas 0,90 sejak *Confidence* sekitar 0,1, yang menandakan model cepat meminimalkan kesalahan prediksi positif palsu. Kelas *occupied* mempertahankan nilai *precision* yang lebih tinggi dibandingkan kelas *empty*, menunjukkan bahwa model lebih konsisten

dalam mendeteksi slot parkir terisi. Secara keseluruhan, MODEPA-8 30 epoch mencapai *precision* maksimum sebesar 1,00 pada *Confidence* 0,974, yang berarti seluruh prediksi pada *threshold* tersebut merupakan prediksi benar. Meskipun demikian, penggunaan *threshold Confidence* yang terlalu tinggi berpotensi mengurangi jumlah deteksi valid, sehingga *threshold* menengah lebih direkomendasikan untuk implementasi sistem parkir secara *real-time*.


2) Recall



Gambar 7. Recall

Kurva *Recall-Confidence* pada MODEPA-8 dengan pelatihan 30 epoch menunjukkan kemampuan model dalam mendeteksi hampir seluruh objek parkir pada *threshold Confidence* rendah hingga menengah. Nilai *recall* berada di atas 0,95 pada rentang *Confidence* rendah, yang menandakan bahwa sebagian besar objek parkir berhasil terdeteksi tanpa banyak kehilangan prediksi benar. Seiring peningkatan *Confidence*, nilai *recall* menurun secara bertahap, terutama setelah *Confidence* mendekati 0,8, akibat semakin ketatnya seleksi prediksi. Kelas *occupied* mempertahankan *recall* yang lebih stabil dibandingkan kelas *empty*, menunjukkan bahwa slot parkir terisi lebih mudah dikenali oleh model. Secara keseluruhan, MODEPA-8 30 epoch mencapai nilai *recall* maksimum sekitar 0,97 pada *Confidence* 0,0, namun penggunaan *threshold* menengah tetap lebih disarankan untuk menjaga keseimbangan antara *recall* dan *precision* dalam implementasi sistem parkir.

3) F1 Score




Gambar 8. F1 Score

Kurva *F1-Confidence* pada MODEPA-8 dengan pelatihan 30 epoch menunjukkan keseimbangan yang baik antara *precision* dan *recall* pada rentang *Confidence*

menengah. Nilai F1 meningkat cepat pada *Confidence* rendah dan mencapai kondisi stabil di atas 0,90 sejak *Confidence* sekitar 0,1, yang menandakan model segera menemukan titik keseimbangan klasifikasi. Puncak performa dicapai dengan nilai F1 maksimum sebesar 0,96 pada *Confidence* 0,626, yang menunjukkan *threshold* optimal untuk implementasi sistem parkir. Kelas *occupied* mempertahankan nilai F1 yang lebih tinggi dan stabil dibandingkan kelas *empty*, menandakan deteksi slot terisi lebih konsisten pada berbagai *threshold*. Setelah *Confidence* melebihi 0,8, nilai F1 menurun signifikan akibat berkurangnya *recall*, sehingga penggunaan *Confidence* menengah lebih direkomendasikan untuk menjaga performa deteksi secara keseluruhan.

4) *Confusion Matrix*




Gambar 9. *Confusion Matrix*

Confusion Matrix MODEPA-8 dengan pelatihan 30 epoch menunjukkan dominasi prediksi yang benar pada seluruh kelas utama. Pada kelas *empty*, sebanyak 712 data terklasifikasi dengan benar, sementara 67 data salah diklasifikasikan sebagai *background*, yang mengindikasikan masih adanya ambiguitas visual pada slot kosong. Kelas *occupied* menunjukkan performa sangat tinggi dengan 1.746 prediksi benar, serta hanya 1 data yang salah diklasifikasikan sebagai *empty*, menandakan tingkat kesalahan yang sangat rendah. Kesalahan klasifikasi pada kelas *background* relatif terbatas, dengan 32 data terdeteksi sebagai *empty* dan 49 data sebagai *occupied*, yang menunjukkan sebagian area non-parkir masih teridentifikasi sebagai objek parkir. Secara keseluruhan, pola *Confusion Matrix* ini menegaskan bahwa MODEPA-8 30 epoch memiliki akurasi deteksi yang tinggi dan kesalahan yang cenderung konservatif, sehingga aman untuk diterapkan pada sistem parkir kampus.

B. Evaluasi Performa MODEPA-8 50 Epoch


1) *Precision*



Gambar 10. *Precision*

Kurva *Precision–Confidence* pada MODEPA-8 dengan pelatihan 50 epoch menunjukkan peningkatan ketepatan deteksi yang sangat tinggi dan stabil pada hampir seluruh rentang *Confidence*. Nilai *precision* meningkat tajam pada *Confidence* rendah dan berada di atas 0,90 sejak *Confidence* sekitar 0,05, yang menandakan model cepat menekan kesalahan prediksi positif palsu. Kelas *occupied* tetap menunjukkan *precision* yang lebih tinggi dibandingkan kelas *empty*, menegaskan konsistensi model dalam mengenali slot parkir terisi. Secara keseluruhan, MODEPA-8 50 epoch mencapai *precision* maksimum sebesar 1,00 pada *Confidence* 0,990, yang menunjukkan tingkat ketepatan sempurna pada *threshold* tersebut. Namun, karena *threshold* yang sangat tinggi berpotensi mengurangi jumlah deteksi valid, penggunaan *Confidence* menengah tetap lebih direkomendasikan untuk menjaga keseimbangan antara *precision* dan *recall* pada implementasi sistem parkir.


2) Recall



Gambar 11. Recall

Kurva *Recall–Confidence* pada MODEPA-8 dengan pelatihan 50 epoch menunjukkan kemampuan model dalam mempertahankan tingkat keterdeteksian objek yang tinggi pada *Confidence* rendah hingga menengah. Nilai *recall* berada di kisaran 0,95–0,97 pada *Confidence* rendah, yang menandakan sebagian besar objek parkir berhasil terdeteksi tanpa banyak kehilangan prediksi benar. Seiring peningkatan *Confidence*, nilai *recall* menurun secara bertahap dan mulai turun lebih signifikan setelah *Confidence* mendekati 0,8, akibat seleksi prediksi yang semakin ketat. Kelas *occupied* tetap mempertahankan *recall* yang lebih stabil dibandingkan kelas *empty*, menunjukkan konsistensi deteksi slot parkir terisi pada berbagai *threshold*. Secara keseluruhan, MODEPA-8 50 epoch mencapai *recall* maksimum sekitar 0,97 pada *Confidence* 0,0, namun penggunaan *threshold* menengah tetap lebih disarankan untuk menjaga keseimbangan antara *recall* dan *precision* pada implementasi sistem parkir kampus.


3) F1 Score



Gambar 12. F1 Score

Kurva F1–*Confidence* pada MODEPA-8 dengan pelatihan 50 epoch menunjukkan keseimbangan *precision* dan *recall* yang sangat baik pada rentang *Confidence* rendah hingga menengah. Nilai F1 meningkat cepat sejak *Confidence* rendah dan berada di atas 0,90 pada sebagian besar rentang *Confidence*, yang menandakan kestabilan performa deteksi. Puncak performa dicapai dengan nilai F1 maksimum sebesar 0,97 pada *Confidence* 0,562, yang menunjukkan *threshold* optimal untuk konfigurasi 50 epoch. Kelas *occupied* mempertahankan nilai F1 yang lebih tinggi dan stabil dibandingkan kelas *empty*, mengindikasikan konsistensi deteksi slot parkir terisi pada berbagai *threshold*. Setelah *Confidence* melebihi 0,8, nilai F1 menurun cukup tajam akibat penurunan *recall*, sehingga penggunaan *threshold* menengah tetap lebih disarankan untuk implementasi sistem parkir kampus.

4) *Confusion Matrix*



Gambar 13. *Confusion Matrix*

Confusion Matrix MODEPA-8 dengan pelatihan 50 epoch menunjukkan performa klasifikasi yang sangat baik dengan dominasi prediksi benar pada kelas utama. Pada kelas *empty*, sebanyak 709 data terklasifikasi dengan benar, sementara 56 data salah diklasifikasikan sebagai *background*, yang menunjukkan penurunan kesalahan dibandingkan pelatihan 30 epoch. Kelas *occupied* tetap memiliki performa sangat tinggi dengan 1.743 prediksi benar, serta hanya 1 data yang salah terklasifikasi sebagai *empty*, menandakan stabilitas deteksi slot parkir terisi. Kesalahan pada kelas *background* masih ditemukan, dengan 36 data terdeteksi sebagai *empty* dan 52 data sebagai *occupied*, yang mengindikasikan area non-parkir sesekali teridentifikasi sebagai slot parkir. Secara keseluruhan, *Confusion Matrix* ini menunjukkan bahwa pelatihan 50 epoch menghasilkan sedikit perbaikan pada akurasi klasifikasi *empty*, namun peningkatannya relatif kecil dibandingkan tambahan waktu pelatihan yang dibutuhkan.

3. Analisis Komparatif MODEPA 30 Epoch & 50 Epoch

4.

Tabel 1. Komparasi 30 Epoch vs 50 Epoch

Epoch	mAP50-95	mAP50	<i>Precision</i>	<i>Recall</i>	Training Time (seconds)
30	0.91862	0.97516	0.97679	0.95186	5690.5543
50	0.92259	0.9768	0.97518	0.95783	14143.2205

Pada gambar x. Secara umum, perbandingan hasil pelatihan MODEPA-8 menunjukkan bahwa kedua konfigurasi epoch menghasilkan performa deteksi yang sangat tinggi dengan selisih metrik yang relatif kecil. Pelatihan 30 epoch mencapai mAP50–95 sebesar 0,91862 dan mAP50 sebesar 0,97516, sedangkan pelatihan 50 epoch sedikit lebih tinggi dengan mAP50–95 sebesar 0,92259 dan mAP50 sebesar 0,97680. Peningkatan mAP50–95 sebesar 0,00397 (0,43%) dan mAP50 sebesar 0,00164 (0,17%) menunjukkan bahwa tambahan 20 epoch hanya memberikan peningkatan marginal pada kualitas deteksi lintas IoU. Fakta ini mengindikasikan bahwa sebagian besar representasi fitur parkir telah dipelajari secara optimal pada 30 epoch. Dengan demikian, dari sisi akurasi spasial dan klasifikasi, perbedaan performa antar kedua konfigurasi tergolong tidak signifikan.

Dari perspektif keseimbangan *precision* dan *recall*, MODEPA-8 30 epoch menunjukkan *precision* 0,97679 dan *recall* 0,95186, sementara MODEPA-8 50 epoch memperoleh *precision* 0,97518 dan *recall* 0,95783. Terjadi penurunan *precision* sebesar 0,00161 pada 50 epoch, yang diiringi peningkatan *recall* sebesar 0,00597, menandakan kecenderungan model 50 epoch untuk lebih agresif dalam mendeteksi objek dengan risiko kecil peningkatan prediksi positif palsu. Analisis kurva F1 memperkuat temuan ini, di mana kedua konfigurasi mencapai F1 tinggi pada *Confidence* menengah, dengan perbedaan puncak yang sangat kecil. Pola *Confusion Matrix* juga menunjukkan bahwa perbaikan kesalahan klasifikasi pada kelas *empty* di epoch 50 bersifat terbatas dan tidak mengubah karakteristik kesalahan utama. Hal ini menegaskan bahwa tambahan epoch lebih berfungsi sebagai penyempurnaan ringan daripada peningkatan performa yang substansial.

Dari sisi efisiensi komputasi, perbedaan waktu pelatihan menjadi faktor penentu utama dalam evaluasi komparatif ini. Pelatihan 30 epoch membutuhkan waktu sekitar 5.690 detik, sedangkan pelatihan 50 epoch memerlukan 14.143 detik, atau meningkat sebesar 148% dibandingkan konfigurasi 30 epoch. Peningkatan waktu pelatihan yang signifikan tersebut tidak sebanding dengan kenaikan performa yang hanya berada di bawah 1% pada seluruh metrik utama. Secara kritis, kondisi ini menunjukkan adanya *diminishing returns* pada pelatihan 50 epoch. Oleh karena itu, MODEPA-8 dengan pelatihan 30 epoch dinilai sebagai konfigurasi paling efisien dan rasional untuk implementasi sistem parkir kampus UNSIKA, karena mampu memberikan performa tinggi dengan biaya komputasi yang jauh lebih rendah.

Kesimpulan

Kesimpulan dari penelitian ini menunjukkan bahwa MODEPA-8 mampu mendeteksi kondisi parkir kampus UNSIKA secara akurat dan konsisten menggunakan pendekatan YOLOv8. Hasil eksperimen membuktikan bahwa pelatihan selama 30 epoch telah menghasilkan performa tinggi dengan nilai mAP50–95 sebesar 0,91862, *precision* 0,97679, dan *recall* 0,95186, yang tidak berbeda signifikan dibandingkan pelatihan 50 epoch. Meskipun pelatihan 50 epoch memberikan peningkatan kecil pada beberapa metrik, peningkatan tersebut tidak sebanding dengan tambahan waktu pelatihan yang meningkat lebih dari dua kali lipat. Analisis komparatif secara menyeluruh menunjukkan adanya kondisi *diminishing returns* pada penambahan epoch setelah model mencapai konvergensi. Oleh karena itu, MODEPA-8 dengan konfigurasi pelatihan 30 epoch direkomendasikan sebagai solusi paling efisien dan optimal untuk implementasi sistem parkir cerdas di lingkungan kampus.

Daftar Rujukan

- [1] C. Ma, "A review of research on urban parking prediction and management," *Journal of Advanced Transportation*, vol. 2024, pp. 1–14, 2024, doi: 10.1155/2024/8892147.
- [2] W. Wang, W. Zhang, H. Zhang, and A. Zhang, "Research on parking space detection algorithm in complex environments based on improved YOLOv7," *Measurement Science and Technology*, vol. 35, no. 2, 2023, doi: 10.1088/1361-6501/acf0d2.

- [3] X. Zhang, Y. Li, and J. Chen, "Car parking space detection using YOLO-based deep learning," *Electronics*, vol. 12, no. 9, pp. 1–15, 2023, doi: 10.3390/electronics12092134.
- [4] W. Wei, "Real-time parking space detection based on deep learning under complex scenes," *Sensors*, vol. 25, no. 1, pp. 1–17, 2025, doi: 10.3390/s25010211.
- [5] I. Y. Garta, A. S. Prabowo, and M. R. Fachrurrozi, "On-street parking space detection using YOLO models and performance recommendations," *Computers, Materials & Continua*, vol. 78, no. 1, pp. 121–135, 2025, doi: 10.32604/cmc.2025.046921.
- [6] A. Matiin and S. Nugroho, "Evaluasi algoritma YOLOv8 untuk deteksi plat nomor kendaraan," *ELINVO*, vol. 9, no. 2, pp. 85–94, 2024, doi: 10.21831/elinvo.v9i2.65234.
- [7] R. Pratama and D. Kurniawan, "Analisis performa YOLOv8 untuk klasifikasi kendaraan," *Jurnal Teknik Elektro UNNES*, vol. 16, no. 1, pp. 33–42, 2024, doi: 10.15294/jte.v16i1.74211.
- [8] K. D. Dharmasaputra, A. Rahman, and Y. Hidayat, "Evaluation of YOLOv8 and centroid tracking for vehicle detection," *Journal of Applied Artificial Intelligence and Computing (JAIC)*, vol. 5, no. 1, pp. 1–10, 2025, doi: 10.30871/jaic.v5i1.5981.
- [9] M. Fathurrahman, R. H. Putra, and S. Aulia, "Comparative study of YOLO versions for smart parking systems," *Jurnal Ilmu Teknik dan Komputer (JITK)*, vol. 10, no. 2, pp. 145–154, 2025, doi: 10.22441/jitk.v10i2.18745.
- [10] A. Setiawan and B. Santoso, "Sistem parkir cerdas berbasis visi komputer menggunakan deep learning," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, vol. 11, no. 1, pp. 55–64, 2024, doi: 10.25126/jtiik.202411.6123.
- [11] D. S. Ramadhan and F. Arifin, "Deteksi kendaraan pada area parkir menggunakan YOLO dan CNN," *Jurnal RESTI*, vol. 8, no. 3, pp. 412–420, 2024, doi: 10.29207/resti.v8i3.5612.
- [12] S. Hidayat, A. R. Hakim, and I. Maulana, "Implementasi deep learning untuk sistem parkir cerdas berbasis citra," *Jurnal Informatika Polinema*, vol. 10, no. 1, pp. 21–29, 2023, doi: 10.33795/jip.v10i1.482.
- [13] T.-Y. Lin et al., "Microsoft COCO: Common objects in context," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 40, no. 4, pp. 740–755, 2021, doi: 10.1109/TPAMI.2018.2844175.
- [14] M. Everingham et al., "The importance of annotation quality in object detection," *International Journal of Computer Vision*, vol. 129, no. 5, pp. 1231–1247, 2022, doi: 10.1007/s11263-021-01502-9.
- [15] S. Li, Y. Zhang, and H. Wang, "Dataset construction and acquisition strategy for vision-based parking detection," *IEEE Access*, vol. 9, pp. 142311–142322, 2021, doi: 10.1109/ACCESS.2021.3119984.
- [16] J. Redmon and A. Farhadi, "YOLO: Unified, real-time object detection," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 779–788, 2021, doi: 10.1109/CVPR.2016.91.
- [17] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2021, doi: 10.7551/mitpress/10243.001.0001.
- [18] S. Albawi, T. A. Mohammed, and S. Al-Zawi, "Understanding of a convolutional neural network," *International Conference on Engineering and Technology*, pp. 1–6, 2021, doi: 10.1109/ICET.2017.8288770.