

ASCID-Lab: Automated Student Card Identification and Detection System for Laboratory Management Using YOLOv8n and OCR

Muhammad Raihan Zaldiputra¹, Raffa Danendra Pramono², Keisyah Zahra Anatasya³, Dodik Ariyanto^{4*}, Faldiena Marcelita⁵, Mayanda Mega Santoni⁶

^{1,2,3} Teknologi Rekayasa Perangkat Lunak, Sekolah Vokasi, IPB University, Kota Bogor, 16128, Indonesia

^{4,5} Teknologi Rekayasa Komputer, Sekolah Vokasi, IPB University, Kota Bogor, 16128, Indonesia

⁶ Informatika, Ilmu Komputer, Universitas Pembangunan Nasional Veteran Jakarta, DKI Jakarta, 12450, Indonesia

Informasi Artikel

Diterima : 29 Mei 2026
Revisi : 31 Mei 2026
Publikasi : 30 Juni 2026

Kata Kunci:

Deteksi Objek
Face Recognition
Optical Character Recognition
Sistem Peminjaman Laboratorium
YOLOv8n

ABSTRAK (10 PT)

Pengelolaan peminjaman laboratorium komputer di Sekolah Vokasi IPB University masih dilakukan secara manual, sehingga menimbulkan ineffisiensi operasional, ketidakakuratan pencatatan, dan ketidakmampuan pemantauan secara real-time. Penelitian ini bertujuan mengembangkan sistem peminjaman laboratorium berbasis web yang mengotomatisasi proses verifikasi identitas mahasiswa melalui integrasi tiga teknologi utama, yaitu You Only Look Once version 8 Nano (YOLOv8n), Optical Character Recognition (OCR) menggunakan PaddleOCR, dan verifikasi wajah menggunakan ArcFace. Metodologi penelitian meliputi pengumpulan 110 citra Kartu Tanda Mahasiswa (KTM), anotasi bounding box pada empat region, preprocessing dan augmentasi hingga menghasilkan 600 citra, pelatihan model selama 150 epoch menggunakan GPU Tesla T4, serta integrasi ke dalam platform web menggunakan FastAPI dan Next.js. Hasil evaluasi menunjukkan model YOLOv8n mencapai mAP@0,5 sebesar 0,976, precision 0,977, dan recall 0,979. Sistem ini berhasil mengintegrasikan seluruh pipeline verifikasi KTM secara otomatis dan real-time, mengurangi ketergantungan pada proses manual dalam pengelolaan peminjaman laboratorium.

ABSTRACT (10 PT).

The management of computer laboratory borrowing at the Vocational School of IPB University is still conducted manually, resulting in operational inefficiency, inaccurate data recording, and inability to monitor usage in real-time. This study aims to develop a web-based laboratory borrowing system that automates student identity verification through the integration of three main technologies: You Only Look Once version 8 Nano (YOLOv8n), Optical Character Recognition (OCR) using PaddleOCR, and face verification using ArcFace. The research methodology includes collecting 110 Student Identity Card (KTM) images, bounding box annotation on four regions, preprocessing and augmentation to produce 600 images, model training for 150 epochs using a Tesla T4 GPU, and integration into a web platform using FastAPI and Next.js. Evaluation results show that the YOLOv8n model achieves a mAP@0.5 of 0.976, precision of 0.977, and recall of 0.979. This system successfully integrates the entire KTM verification pipeline automatically and in real-time, reducing reliance on manual processes in laboratory borrowing management.

This is an open-access article under the [CC BY-SA](#) license



*Penulis Koresponden

Email: dodikariyanto@apps.ipb.ac.id

Cara sitasi IEEE:

- [1] M. R. Zaldiputra, R. D. Pramono, K. Z. Anatasya, D. Ariyanto, F. Marcelita, and M. M. Santoni, "ASCID-Lab: Automated Student Card Identification and Detection System for Laboratory Management Using YOLOv8n and OCR," *Journal of Artificial Intelligence and Software Engineering (J-AISE)*, vol. 6, no. 2, pp. 309–320, Juni. 2026, doi: 10.30811/jaise.v6i2.9208.

1. PENDAHULUAN

Laboratorium komputer merupakan fasilitas akademik yang memerlukan pengelolaan administrasi yang efisien. Namun, proses peminjaman laboratorium di banyak perguruan tinggi, termasuk Sekolah Vokasi IPB University, masih dilakukan secara manual melalui pengisian formulir dan penyerahan Kartu Tanda Mahasiswa (KTM). Metode ini menimbulkan inefisiensi operasional, beban administrasi yang tinggi, serta ketidakakuratan data [1]. Selain rentan terhadap kesalahan pencatatan dan lambat dalam rekapitulasi data, metode manual juga belum mendukung pemantauan laboratorium secara real-time sehingga kurang sesuai dengan kebutuhan layanan akademik modern [2].


Permasalahan tersebut menunjukkan adanya kebutuhan akan pendekatan yang dapat mengotomatisasi proses administrasi peminjaman laboratorium secara lebih menyeluruh. Salah satu pendekatan yang dapat digunakan adalah pemanfaatan teknologi *computer vision*, khususnya *You Only Look Once version 8 Nano* (YOLOv8n) sebagai model deteksi objek yang dipadukan dengan *Optical Character Recognition* (OCR). YOLOv8n mengadopsi pendekatan berbasis *grid* menggunakan jaringan saraf konvolusi tunggal yang memungkinkan deteksi dilakukan langsung pada citra dengan kecepatan tinggi, sehingga sangat sesuai untuk kebutuhan identifikasi komponen pada kartu identitas secara *real-time* [3]. Hasil deteksi dari YOLOv8n selanjutnya dapat dimanfaatkan oleh teknologi *Optical Character Recognition* (OCR) yang memungkinkan komputer untuk membaca dan menginterpretasikan karakter dari dokumen yang dipindai maupun gambar yang difoto, sehingga informasi teks pada kartu identitas dapat diekstraksi secara otomatis tanpa bergantung pada entri data manual yang rentan terhadap kesalahan [4]. Selain itu, region foto wajah yang terdeteksi pada KTM dapat dimanfaatkan lebih lanjut untuk proses verifikasi identitas melalui *face recognition* (pengenalan wajah) guna memastikan bahwa wajah mahasiswa yang hadir sesuai dengan foto pada KTM sekaligus memvalidasi bahwa mahasiswa tersebut terdaftar dalam basis data system [5]. Di sisi lain, implementasi sistem informasi berbasis *web* juga telah banyak dibuktikan mampu meningkatkan efisiensi dalam pengelolaan data administratif jika dibandingkan dengan metode konvensional yang bersifat manual dan kurang terstruktur [6]. Dengan adanya integrasi pendekatan tersebut, diharapkan dapat terbentuk sebuah solusi yang lebih efektif, terstruktur, serta mampu mendukung kebutuhan pengelolaan administrasi peminjaman laboratorium secara lebih cepat, akurat, dan terintegrasi.

Berbagai penelitian telah dilakukan untuk mengembangkan sistem otomatis dalam proses verifikasi dan ekstraksi informasi dari kartu identitas. Iskandar dan Kesuma [7] membangun sistem deteksi kartu identitas berbasis OCR secara *real-time* menggunakan SSD MobileNet V2 FPNLite dan EasyOCR, dengan akurasi 95%, meskipun masih terbatas pada dataset kecil dan belum terintegrasi dalam platform berbasis *web*. Nguyen dkk. [8] mengembangkan sistem ekstraksi informasi KTM menggunakan YOLOv10 yang dikombinasikan dengan Tesseract OCR, menghasilkan akurasi deteksi 94,6% dan ekstraksi teks 95%, namun masih rentan terhadap variasi pencahayaan ekstrem dan keterbatasan generalisasi format kartu. Sementara itu, Chinapas dkk. [9] mengusulkan sistem verifikasi identitas berbasis perbandingan wajah menggunakan Dlib, FaceNet, dan ArcFace, di mana ArcFace mencapai akurasi tertinggi sebesar 99,06% untuk deteksi wajah dan 96,09% untuk verifikasi, meskipun masih memiliki keterbatasan pada kondisi pencahayaan tidak ideal dan variasi usia dan belum terintegrasi ke *web*. Ketiga penelitian tersebut menunjukkan bahwa meskipun teknologi *computer vision* telah memberikan hasil yang baik, masih terdapat tantangan pada aspek generalisasi, robustitas terhadap kondisi nyata, dan integrasi sistem yang lebih komprehensif.

Kesenjangan utama terletak pada integrasi deteksi region kartu, ekstraksi teks, dan verifikasi wajah dalam satu alur layanan laboratorium berbasis *web*. Berdasarkan kesenjangan tersebut, penelitian ini mengusulkan sistem peminjaman laboratorium berbasis *web* yang mengintegrasikan deteksi KTM menggunakan YOLOv8n, ekstraksi teks menggunakan PaddleOCR, dan verifikasi identitas menggunakan ArcFace. Kebaruan penelitian terletak pada integrasi ketiga teknologi tersebut dalam satu platform administrasi laboratorium berbasis KTM secara real-time untuk meningkatkan efisiensi, akurasi, dan keamanan peminjaman laboratorium di Sekolah Vokasi IPB University.

2. METODE

Metode yang digunakan pada penelitian ini terdiri dari pengumpulan data, *preprocessing* data, pelatihan model, evaluasi model, serta integrasi sistem *web*. Alur tahapan penelitian secara keseluruhan dapat dilihat pada Gambar 1.



Gambar 1. Flowchart Tahapan Penelitian

2.1 Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah citra Kartu Tanda Mahasiswa (KTM) yang dikumpulkan secara mandiri sebagai dataset utama. Dataset tersebut terdiri dari 110 citra yang diperoleh dari lingkungan Sekolah Vokasi IPB University, khususnya mahasiswa program studi Teknologi Rekayasa Perangkat Lunak angkatan 60, serta melalui media komunikasi daring. Data ini dipilih karena ketersediaan dan keseragaman format KTM. Data KTM digunakan terbatas untuk penelitian, informasi sensitif tidak dipublikasikan, dan citra ditampilkan dengan penyamaran bila diperlukan. Selain dataset utama, data pendukung berupa data jadwal praktikum serta data informasi laboratorium yang meliputi nama laboratorium, lokasi gedung, dan jam operasional turut dikumpulkan untuk mendukung pengembangan sistem secara menyeluruh.

Setiap citra KTM kemudian diberi anotasi menggunakan metode *bounding box* melalui platform Roboflow. Anotasi dilakukan terhadap empat kategori region yang terdapat pada KTM sebagaimana ditunjukkan pada Tabel 1.

Tabel 1. Jenis Anotasi

No	Label	Deskripsi
1	face_photo	Region foto wajah pada KTM
2	qr_code	Region QR code pada KTM
3	text_nama	Region teks nama mahasiswa
4	text_nim	Region teks NIM mahasiswa

2.2 Preprocessing dan Augmentasi Data

Tahap *preprocessing* data dilakukan untuk memastikan kualitas citra optimal sebelum digunakan dalam proses pelatihan model YOLOv8n. Proses ini bertujuan untuk menyeragamkan ukuran citra, memperbaiki orientasi gambar, serta meningkatkan variasi data agar model mampu mengenali objek KTM pada berbagai kondisi visual. Berdasarkan alur pengerjaan, tahap ini dibagi menjadi dua fase utama yaitu *preprocessing* pada platform Roboflow dan augmentasi data lanjutan pada lingkungan Google Colab.


2.2.1 Preprocessing pada Roboflow

Pada tahap awal, sebanyak 110 citra mentah yang telah dikumpulkan diunggah ke platform Roboflow untuk melalui proses standarisasi data. Preprocessing yang diterapkan meliputi auto-orient untuk menyesuaikan orientasi citra secara otomatis dan resize dengan ukuran 640×640 piksel agar sesuai dengan kebutuhan input model YOLOv8n. Proses resizing dilakukan untuk menyeragamkan dimensi citra sehingga data yang digunakan memiliki ukuran yang konsisten. Dengan ukuran citra yang seragam, proses pelatihan model dapat berjalan lebih stabil dan sesuai dengan konfigurasi input model deteksi objek.

2.2.2 Augmentasi Awal pada Roboflow

Selain preprocessing, dilakukan juga augmentasi awal pada Roboflow untuk meningkatkan keragaman data latih. Augmentasi dilakukan karena jumlah dataset awal masih terbatas, sehingga diperlukan penambahan variasi citra secara artifisial agar model dapat mempelajari objek KTM dalam kondisi yang lebih beragam. Teknik augmentasi yang digunakan meliputi rotasi dengan rentang -15° hingga $+15^\circ$, penyesuaian brightness -25% hingga $+25\%$, exposure -15% hingga $+15\%$, blur hingga 1,5 piksel, serta penambahan noise hingga 1,5% dari total piksel citra. Melalui proses ini, dataset pada Roboflow menghasilkan total 232 citra, dengan

pembagian 220 citra training, 6 citra validation, dan 6 citra testing. Konfigurasi augmentasi awal pada Roboflow ditunjukkan pada Gambar 2.



Gambar 2. Konfigurasi Augmentasi Awal Dataset pada Roboflow

2.2.3 Augmentasi Lanjutan pada Google Colab

Setelah melalui tahap preprocessing dan augmentasi awal pada Roboflow, dataset diekspor ke lingkungan Google Colab untuk menjalani tahap augmentasi lanjutan menggunakan skrip kustom `augment_dataset.py`. Tahap ini dilakukan karena distribusi dataset hasil Roboflow masih belum proporsional, yaitu 220 citra training, 6 citra validation, dan 6 citra testing. Jumlah data validation dan testing yang terlalu sedikit dinilai kurang representatif untuk proses validasi dan pengujian model.

Augmentasi lanjutan pada Google Colab bertujuan untuk menambah jumlah data dan menyesuaikan proporsi dataset agar lebih seimbang. Proses ini juga bertujuan untuk meningkatkan variasi data sehingga model menjadi lebih tangguh (*robust*) dalam mengenali KTM pada kondisi yang berbeda, seperti perubahan sudut pandang, pencahayaan, posisi objek, dan kualitas citra. Selain meningkatkan jumlah sampel pelatihan, proses augmentasi juga bertujuan untuk mengurangi risiko overfitting akibat keterbatasan jumlah dataset awal yang hanya terdiri dari 110 citra. Variasi transformasi seperti perubahan kecerahan dan pergeseran posisi *horizontal/vertical shifting* $\pm 10\%$ memungkinkan model mempelajari karakteristik objek pada berbagai kondisi visual yang berbeda, sehingga kemampuan generalisasi model terhadap data yang belum pernah dilihat menjadi lebih baik.

Proses augmentasi lanjutan dilakukan menggunakan skrip kustom `augment_dataset.py` pada lingkungan Google Colab. Skrip tersebut membaca dataset hasil ekspor dari Roboflow, mendeteksi pembagian data training, validation, dan testing, kemudian menambahkan jumlah citra pada masing-masing subset sesuai target yang telah ditentukan. Augmentasi hanya untuk training; validation dan testing berasal dari subset terpisah. Dokumentasi proses augmentasi lanjutan pada Google Colab ditampilkan pada Gambar 3.

```

Saving augment_dataset.py to augment_dataset.py
Smart-Lab Dataset Augmentor
Dataset: content/kanakita-6
Targets: train=480 imgs, valid=60 imgs, test=60 imgs
Detected splits: ['train', 'valid', 'test']

BEFORE augmentation:
train: 220 images
valid: 6 images
test: 6 images

[train] Augmenting 220 images -> target 480 total (260 new) ... 10/260 20/260 30/260 40/260 50/260 60/260 70/260 80/260 90/260 100/260 110/260 120/260 130/260 140/260 150/260
[train] 220 originals + 260 augmented = 480 total

[valid] Augmenting 6 images -> target 60 total (54 new) ... 10/54 20/54 30/54 40/54 50/54 54/54
[valid] 6 originals + 54 augmented = 60 total

[test] Augmenting 6 images -> target 60 total (54 new) ... 10/54 20/54 30/54 40/54 50/54 54/54
[test] 6 originals + 54 augmented = 60 total

=====
AFTER augmentation:
train 480 imgs 80.0%
valid 60 imgs 10.0%
test 60 imgs 10.0%
TOTAL 600 imgs
=====
Augmentation complete! Dataset siap untuk training.

```

Gambar 3. Proses Augmentasi Lanjutan Dataset pada Google Colab

Berdasarkan hasil augmentasi lanjutan tersebut, dataset mengalami peningkatan jumlah dari 232 citra menjadi total 600 citra. Dataset akhir terdiri dari 480 citra training, 60 citra validation, dan 60 citra testing, sehingga diperoleh proporsi 80% data training, 10% data validation, dan 10% data testing. Distribusi akhir dataset setelah proses augmentasi lanjutan divisualisasikan pada Gambar 4.



Gambar 4. Distribusi Dataset Akhir

2.3 Pelatihan Model

Tahap pelatihan model dilakukan untuk membangun kerangka kerja cerdas yang mengintegrasikan tiga teknologi utama: deteksi objek berbasis visi komputer, ekstraksi teks otomatis, dan verifikasi biometrik. Seluruh proses pelatihan dan pengujian integrasi ini dieksekusi menggunakan lingkungan Google Colab dengan akselerasi GPU Tesla T4 untuk mempercepat waktu komputasi. Model yang digunakan adalah YOLOv8n, varian *Nano* dari arsitektur YOLOv8 dipilih karena kemampuannya mendeteksi objek secara cepat dengan kebutuhan komputasi yang ringan, sehingga sesuai untuk kebutuhan sistem *real-time*. Konfigurasi parameter pelatihan yang diterapkan disajikan pada Tabel 2.

Tabel 2. Konfigurasi pelatihan model YOLOv8n

Parameter	Keterangan
Arsitektur	YOLOv8n
Epoch	150
Image size	640 × 640 px
Batch size	16
Optimizer	AdamW (lr=0,00125, momentum=0,9)
Early stopping	Patience = 50 epochs
Durasi Pelatihan	0,787 jam (± 47 menit)
GPU	Tesla T4

Pelatihan dijalankan selama 150 *epoch* dengan ukuran *input* citra 640×640 piksel yang disesuaikan dengan standar *resize* pada tahap *preprocessing*. *Optimizer* AdamW dipilih secara otomatis oleh sistem berdasarkan arsitektur model, dengan *learning rate* sebesar 0,00125 dan *momentum* 0,9 guna memastikan konvergensi model yang stabil selama pelatihan berlangsung. Mekanisme *early stopping* dengan *patience* 50 *epoch* juga diterapkan untuk menghentikan pelatihan secara otomatis apabila tidak terjadi peningkatan performa pada data validasi, sehingga dapat mencegah *overfitting* sekaligus mengefisienkan waktu komputasi. Selain itu, augmentasi data yang menghasilkan peningkatan jumlah citra dari 110 menjadi 600 citra digunakan untuk memperkaya variasi data pelatihan sehingga membantu meningkatkan kemampuan generalisasi model terhadap kondisi yang beragam. Bobot model terbaik (*best.pt*) disimpan berdasarkan nilai *mAP@0,5* tertinggi yang dicapai pada data validasi.

Setelah model YOLOv8n berhasil dilatih, *region text_nama* dan *text_nim* yang terdeteksi selanjutnya di-*crop* dan diproses oleh PaddleOCR untuk mengekstraksi informasi teks nama dan NIM mahasiswa secara otomatis. Sementara itu, *region face_photo* dimanfaatkan untuk proses verifikasi identitas melalui *face recognition*, di mana foto wajah pada KTM dibandingkan dengan wajah mahasiswa yang ditangkap secara *real-time* melalui kamera sekaligus memvalidasi keberadaan data mahasiswa dalam basis data sistem.

2.4 Evaluasi Model

Evaluasi model dilakukan untuk mengukur kemampuan YOLOv8n dalam mendeteksi empat region utama pada Kartu Tanda Mahasiswa (KTM), yaitu *face photo*, *qr code*, *text_nama*, dan *text_nim*. Evaluasi dilakukan menggunakan data validasi yang telah dipisahkan dari data pelatihan, sehingga performa model dapat dinilai berdasarkan kemampuannya mengenali citra yang tidak digunakan secara langsung dalam proses pelatihan. Tahap evaluasi ini bertujuan untuk memastikan bahwa model tidak hanya mampu mempelajari pola pada data latih, tetapi juga memiliki kemampuan generalisasi yang baik terhadap data baru.

Metrik evaluasi yang digunakan meliputi *precision*, *recall*, *mean Average Precision* pada ambang *Intersection over Union* 0,5 (*mAP@0,5*), serta *mAP@0,5:0,95*. *Precision* digunakan untuk mengukur tingkat ketepatan prediksi model, yaitu proporsi hasil deteksi yang benar dari seluruh objek yang diprediksi sebagai objek. Nilai *precision* yang tinggi menunjukkan bahwa model memiliki tingkat kesalahan deteksi positif palsu (*false positive*) yang rendah. *Recall* digunakan untuk mengukur kemampuan model dalam menemukan seluruh

objek yang seharusnya terdeteksi. Nilai *recall* yang tinggi menunjukkan bahwa model memiliki tingkat objek terlewat (*false negative*) yang rendah. Evaluasi juga menggunakan $mAP@0,5$ dan $mAP@0,5:0,95$ sebagai metrik utama pada tugas deteksi objek. $mAP@0,5$ menunjukkan rata-rata presisi deteksi pada ambang IoU sebesar 0,5, sehingga metrik ini digunakan untuk menilai keberhasilan model dalam mendeteksi objek secara umum. Sementara itu, $mAP@0,5:0,95$ menghitung rata-rata presisi pada beberapa ambang IoU yang lebih ketat, mulai dari 0,5 hingga 0,95. Oleh karena itu, metrik ini memberikan gambaran yang lebih komprehensif mengenai ketepatan lokalisasi *bounding box* yang dihasilkan model.

Evaluasi keseluruhan digunakan untuk memperoleh gambaran umum kemampuan model dalam mendeteksi seluruh region KTM, sedangkan evaluasi per kelas digunakan untuk mengetahui kelas mana yang memiliki performa paling baik maupun yang masih memerlukan peningkatan. Hasil evaluasi per kelas penting untuk dianalisis karena setiap region pada KTM memiliki karakteristik visual yang berbeda. Region *face_photo* dan *qr_code* umumnya memiliki pola visual yang lebih jelas, sedangkan region *text_nama* dan *text_nim* memiliki ukuran objek yang lebih kecil dan lebih sensitif terhadap variasi pencahayaan, ketajaman citra, serta sudut pengambilan gambar. Evaluasi juga dilakukan melalui analisis *confusion matrix* untuk melihat distribusi prediksi benar dan salah pada setiap kelas. Analisis ini digunakan untuk mengidentifikasi potensi kesalahan klasifikasi antarregion maupun kesalahan deteksi terhadap latar belakang. Dengan demikian, hasil evaluasi tidak hanya menunjukkan tingkat akurasi model secara kuantitatif, tetapi juga memberikan dasar untuk menganalisis kelemahan model dalam mendeteksi region tertentu pada KTM. Bobot model terbaik yang digunakan pada tahap evaluasi adalah file *best.pt*, yaitu bobot yang disimpan berdasarkan performa terbaik pada data validasi selama proses pelatihan. Penggunaan bobot terbaik ini bertujuan untuk memperoleh model dengan performa optimal, bukan semata-mata berdasarkan bobot pada epoch terakhir. Dengan pendekatan evaluasi tersebut, performa YOLOv8n dapat dinilai secara lebih objektif sebelum diintegrasikan ke dalam sistem peminjaman laboratorium berbasis web.

3. HASIL DAN PEMBAHASAN

Pada bagian ini disajikan hasil penelitian yang telah dilakukan berdasarkan tahapan metode yang diuraikan pada Bab 2. Pembahasan mencakup hasil pelatihan model deteksi objek YOLOv8n, hasil integrasi sistem berbasis web, serta analisis terhadap temuan-temuan yang diperoleh selama penelitian.

3.1. Hasil Pelatihan Model

Proses pelatihan model YOLOv8n dilaksanakan menggunakan konfigurasi yang telah dijelaskan pada Subbab 2.3. Pelatihan berlangsung selama 150 epoch dan diselesaikan dalam waktu 0,787 jam (sekitar 48 menit) pada akselerator GPU Tesla T4. Model akhir yang digunakan memiliki arsitektur fused dengan 73 lapisan, 3.006.428 parameter, dan kompleksitas komputasi sebesar 8,1 GFLOPs.


3.1.1 Proses Pembelajaran Model

Selama proses pelatihan, nilai *loss* pada data training menunjukkan tren penurunan yang konsisten, yang mengindikasikan bahwa model mampu mempelajari karakteristik visual pada citra KTM secara efektif. Tabel 3 menyajikan nilai *box loss*, *classification loss* (*cls loss*), *distribution focal loss* (DFL), serta nilai $mAP@0,5$ pada beberapa epoch representatif selama proses pelatihan.

Tabel 3. Perkembangan Nilai Loss dan Metrik Evaluasi Selama Pelatihan

<i>Epoch</i>	<i>Box loss</i>	<i>Cls loss</i>	DFL loss	$mAP@0,5$
1	1,367	2,218	1,279	0,572
25	0,626	0,429	0,901	0,913
50	0,502	0,343	0,864	0,918
75	0,415	0,290	0,835	0,928
100	0,343	0,247	0,821	0,931
150	0,191	0,161	0,778	0,945

Untuk memberikan gambaran yang lebih menyeluruh mengenai dinamika pembelajaran model selama proses pelatihan, tren penurunan *loss* serta perubahan metrik *precision*, *recall*, dan $mAP@50$ pada data training maupun validasi ditampilkan secara visual pada Gambar 5. Berdasarkan Gambar 5, ketiga komponen *loss* pada data training mengalami penurunan tajam pada *epoch-epoch* awal kemudian melandai hingga stabil, yang menunjukkan proses pembelajaran model berjalan dengan baik. Pada data validasi, *loss* juga cenderung menurun meskipun terdapat beberapa fluktuasi yang wajar. Sementara itu, nilai *precision* dan *recall* meningkat secara signifikan pada awal pelatihan lalu stabil di atas 0,95. Nilai $mAP@50$ menunjukkan performa yang konsisten pada kisaran 0,94–0,96, sedangkan $mAP@50-95$ meningkat secara bertahap hingga mencapai sekitar 0,70 pada akhir pelatihan.



Gambar 5. Kurva Training Loss

3.1.2 Evaluasi Model pada Data Validasi

Setelah pelatihan selesai, Bobot model terbaik dievaluasi menggunakan 60 citra validasi yang terdiri atas 240 instance objek. Evaluasi dilakukan menggunakan metrik Precision (P), Recall (R), mAP@0,5, dan mAP@0,5:0,95. Hasil evaluasi keseluruhan disajikan pada Tabel 4.

Tabel 4. Hasil Evaluasi Model Terbaik pada Data Validasi

Metrik	Nilai
<i>Precision</i>	0,977
<i>Recall</i>	0,979
<i>mAP@0,5</i>	0,976
<i>mAP@0,5:0,95</i>	0,715


Hasil pada Tabel 4 menunjukkan model YOLOv8n mencapai precision 0,977, recall 0,979, mAP@0,5 sebesar 0,976, dan mAP@0,5:0,95 sebesar 0,715. Nilai tersebut menunjukkan bahwa model mampu mendeteksi objek dengan baik, meskipun presisi lokalisasi bounding box masih dapat ditingkatkan pada ambang IoU yang lebih ketat. Hasil evaluasi per kelas disajikan pada Tabel 5.

Tabel 5. Hasil Evaluasi Model Terbaik Per Kelas

Kelas	Precision	Recall	AP@0,5	AP@0,5:0,95
<i>face_photo</i>	0,996	1,000	0,995	0,814
<i>qr_code</i>	0,996	1,000	0,995	0,820
<i>text_nama</i>	0,932	0,933	0,939	0,573
<i>text_nim</i>	0,981	0,983	0,975	0,654

Berdasarkan Tabel 5, kelas *face_photo* dan *qr_code* mencapai performa deteksi tertinggi dengan AP@0,5 masing-masing sebesar 0,995. Kedua kelas ini juga memperoleh *recall* sempurna (1,000), yang berarti seluruh instance foto wajah dan kode QR pada data validasi berhasil terdeteksi tanpa ada yang terlewat. Sementara itu, kelas *text_nim* memperoleh AP@0,5 sebesar 0,975, dan kelas *text_nama* memperoleh nilai terendah di antara keempat kelas, yaitu 0,939.

Matriks konfusi (*confusion matrix*) hasil evaluasi model ditampilkan pada Gambar 6, yang menggambarkan distribusi prediksi benar dan salah untuk setiap kelas.




Gambar 6. Matriks konfusi hasil evaluasi model YOLOv8n pada data validasi

3.2. Hasil Integrasi Web

Setelah model deteksi objek dievaluasi dan dinyatakan memenuhi standar performa yang diharapkan, tahap selanjutnya adalah mengintegrasikan model tersebut ke dalam sistem peminjaman laboratorium berbasis web sebagaimana diuraikan pada bab 3.1.

3.2.1 Arsitektur Sistem


Sistem peminjaman laboratorium yang dikembangkan merupakan aplikasi berbasis web yang dibangun menggunakan arsitektur berlapis (*layered architecture*), di mana setiap lapisan memiliki fungsi yang terpisah dan saling terhubung secara hierarkis. Gambaran arsitektur sistem secara keseluruhan ditunjukkan pada Gambar 7.



Gambar 7. Arsitektur Sistem Web

Berdasarkan Gambar 7, pengguna sistem terdiri dari dua peran yaitu mahasiswa dan admin. Keduanya mengakses sistem melalui halaman beranda, kemudian melakukan login sebelum diarahkan ke portal masing-masing. Sistem terdiri dari empat lapisan utama. Lapisan pertama adalah antarmuka web (*frontend*) yang mencakup beranda, login, portal mahasiswa, dan portal admin. Lapisan kedua adalah *layer backend* yang terdiri dari komponen autentikasi, manajemen laboratorium, dan *endpoint* verifikasi. Lapisan ketiga adalah *layer pipeline verifikasi* yang memproses citra KTM secara berurutan melalui YOLOv8n, PaddleOCR, dan ArcFace. Lapisan keempat adalah *layer basis data* yang menyimpan data mahasiswa, jadwal laboratorium, dan riwayat peminjaman.

Alur kerja pipeline verifikasi KTM secara rinci ditunjukkan pada Gambar 8. Pengguna mengakses website dan diarahkan ke beranda, kemudian melakukan login. Apabila login tidak valid, pengguna diminta mengulang proses login. Setelah login berhasil, mahasiswa memilih laboratorium dan jadwal yang diinginkan, kemudian melakukan scan KTM untuk memicu pipeline verifikasi. Pipeline memproses citra KTM secara berurutan melalui tiga tahap, yaitu deteksi region oleh YOLOv8n, ekstraksi nama dan NIM oleh PaddleOCR, serta verifikasi wajah KTM dengan webcam secara *real-time* oleh ArcFace. Apabila seluruh tahap verifikasi valid, sistem menyetujui peminjaman, menyimpan data ke basis data, dan mengirimkan notifikasi kepada mahasiswa. Sebaliknya, sistem menolak permintaan dan menampilkan pesan kesalahan yang spesifik kepada pengguna.



Gambar 8. Alur kerja pipeline verifikasi KTM

3.2.2 Implementasi Pipeline Verifikasi KTM

Sistem verifikasi KTM yang dikembangkan mengintegrasikan tiga komponen utama dalam satu pipeline pemrosesan, yaitu deteksi region KTM menggunakan YOLOv8n, ekstraksi teks menggunakan PaddleOCR, dan verifikasi wajah menggunakan ArcFace (*InsightFace*). Pengujian dilakukan dengan memindai KTM mahasiswa secara langsung melalui webcam yang terhubung ke sistem.



Gambar 9. Hasil deteksi empat region KTM oleh model YOLOv8n

Hasil pengujian menunjukkan bahwa sistem mampu menjalankan seluruh tahapan verifikasi secara berurutan, meliputi: (1) deteksi empat region pada citra KTM (*face_photo*, *qr_code*, *text_nama*, *text_nim*); (2) ekstraksi informasi teks berupa nama dan NIM dari region yang terdeteksi; (3) verifikasi kesesuaian wajah antara foto pada KTM dengan wajah mahasiswa yang hadir.


Sistem menerapkan kebijakan verifikasi ketat yang mensyaratkan seluruh tiga indikator terdeteksi dan tervalidasi sebelum proses peminjaman dapat dilanjutkan. Apabila salah satu indikator gagal terdeteksi atau tidak sesuai dengan data pada basis data, sistem akan menolak permintaan peminjaman dan menampilkan pesan kesalahan yang spesifik. Contoh hasil deteksi keempat region pada citra KTM yang dipindai secara langsung ditampilkan pada Gambar 9.

3.2.3 Implementasi Sistem Web


Sistem peminjaman laboratorium diimplementasikan sebagai website menggunakan FastAPI sebagai framework backend berbasis Python dan Next.js sebagai framework frontend berbasis React. Basis data yang digunakan adalah MySQL untuk menyimpan seluruh data persisten sistem, meliputi data mahasiswa, informasi laboratorium, jadwal praktikum, dan riwayat peminjaman. Komunikasi antara frontend dan backend dilakukan melalui RESTful API yang disediakan oleh FastAPI, sementara pipeline verifikasi KTM dijalankan sepenuhnya di sisi server sebagai bagian dari layanan backend. Tampilan halaman login sistem ditunjukkan pada Gambar 10.

Gambar 10. Halaman Login

Sistem membagi akses pengguna menjadi dua peran utama, yaitu mahasiswa dan admin. Mahasiswa melakukan autentikasi menggunakan NIM, setelah berhasil login sistem secara otomatis mengarahkan mahasiswa ke portal mahasiswa. Admin melakukan autentikasi menggunakan kredensial yang telah disediakan dan diarahkan ke portal admin.




Gambar 11. Halaman Jadwal



Gambar 12. Halaman Scan KTM

Portal mahasiswa menyediakan dua fungsi utama. Pertama, halaman jadwal laboratorium yang menampilkan daftar jadwal praktikum yang tersedia beserta informasi laboratorium terkait sebagaimana ditunjukkan pada Gambar 11. Kedua, halaman peminjaman laboratorium yang dilengkapi fitur scan KTM secara real-time melalui webcam sebagaimana ditunjukkan pada Gambar 12. Pada halaman ini, mahasiswa memilih jadwal yang diinginkan kemudian mengarahkan KTM ke kamera untuk memicu pipeline verifikasi otomatis. Setelah verifikasi berhasil, permintaan peminjaman dikirimkan ke sistem dengan status menunggu persetujuan admin. Mahasiswa dapat memantau status permohonan tersebut melalui halaman riwayat peminjaman dan akan menerima notifikasi ketika admin telah memberikan keputusan.



Gambar 13. Dashboard Admin

Portal admin menyediakan fungsi pengelolaan data yang lebih lengkap sebagaimana ditunjukkan pada Gambar 13, mencakup manajemen data laboratorium, manajemen jadwal praktikum, pengelolaan permohonan peminjaman dengan fungsi persetujuan atau penolakan, serta halaman laporan yang merangkum rekap seluruh aktivitas peminjaman laboratorium. Admin juga menerima notifikasi secara real-time setiap kali terdapat permohonan peminjaman baru yang masuk dari mahasiswa.

3.3 Pembahasan

Berdasarkan hasil pelatihan dan pengujian yang telah dipaparkan, bagian ini menyajikan analisis mendalam terhadap temuan-temuan utama penelitian, meliputi performa deteksi per kelas, interpretasi metrik evaluasi, perbandingan dengan penelitian terdahulu, serta keterbatasan yang diidentifikasi selama pelaksanaan penelitian.

3.3.1 Analisis Performa Deteksi Per Kelas

Hasil evaluasi pada Tabel 5 menunjukkan adanya perbedaan performa yang signifikan antarkeempat kelas objek. Kelas *face_photo* dan *qr_code* mencapai $AP@0,5$ tertinggi, masing-masing sebesar 0,995, dengan recall sempurna (1,000). Performa superior kedua kelas ini dapat dijelaskan oleh karakteristik visual objek yang bersangkutan. Foto wajah pada KTM memiliki pola visual yang khas berupa bentuk wajah manusia dengan komposisi warna yang kontras terhadap latar belakang kartu, sehingga memudahkan model dalam mengenali fitur-fitur pembeda. Demikian pula, kode QR memiliki pola geometris hitam-putih yang sangat distingtif dan konsisten di seluruh sampel KTM, menjadikannya objek yang relatif mudah dideteksi.

Sebaliknya, kelas *text_nama* memperoleh $AP@0,5$ terendah sebesar 0,939 dengan precision 0,932 dan recall 0,933. Rendahnya performa kelas ini dibandingkan kelas lainnya dapat dikaitkan dengan beberapa faktor. Pertama, panjang teks nama mahasiswa bervariasi secara signifikan antarsampel, mulai dari nama pendek hingga nama yang terdiri dari empat kata atau lebih, sehingga dimensi *bounding box ground truth* menjadi tidak seragam. Variasi ini menyebabkan model harus mempelajari rentang ukuran region yang lebih luas. Kedua, posisi teks nama pada beberapa sampel KTM berdekatan dengan elemen tekstual lain seperti nama program studi atau nama universitas, yang berpotensi menimbulkan ambiguitas spasial saat proses deteksi. Kelas *text_nim* menunjukkan performa yang lebih baik ($AP@0,5 = 0,975$) dibandingkan *text_nama* karena format NIM yang lebih konsisten, yaitu selalu berupa rangkaian angka dengan panjang tetap, sehingga model lebih mudah mempelajari pola visual yang seragam.

3.3.2 Analisis Metrik $mAP@0,5$ dan $mAP@0,5:0,95$

Perbedaan yang substansial antara nilai $mAP@0,5$ (0,976) dan $mAP@0,5:0,95$ (0,715) memberikan informasi penting mengenai kualitas lokalisasi *bounding box* yang dihasilkan oleh model. Metrik $mAP@0,5$ mengukur kemampuan deteksi pada ambang Intersection over Union (IoU) sebesar 0,5, yang berarti prediksi dianggap benar apabila area tumpang tindih antara *bounding box* prediksi dan *ground truth* mencapai minimal 50%. Sementara itu, $mAP@0,5:0,95$ merupakan rata-rata mAP yang dihitung pada sepuluh tingkat IoU secara bertahap dari 0,50 hingga 0,95, sehingga menuntut presisi lokalisasi yang jauh lebih ketat.

Gap sebesar 0,261 antara kedua metrik ini mengindikasikan bahwa meskipun model berhasil mendeteksi hampir seluruh objek dengan tepat, presisi batas-batas *bounding box* yang dihasilkan belum optimal pada ambang IoU yang tinggi. Fenomena ini terlihat jelas pada kelas *text_nama* yang memiliki $AP@0,5:0,95$ terendah sebesar 0,573, menunjukkan bahwa *bounding box* untuk region teks nama sering kali tidak sepenuhnya presisi dalam mendelimitasi area teks. Hal ini konsisten dengan analisis pada Subbab 3.3.1, di mana variasi panjang nama mahasiswa menyebabkan ketidakseragaman dimensi *bounding box*. Di sisi lain, kelas *qr_code* memperoleh $AP@0,5:0,95$ tertinggi (0,820) karena bentuk kode QR yang selalu berupa kotak dengan rasio aspek yang konsisten, sehingga model dapat memprediksi batas *bounding box* secara lebih akurat.

3.3.3 Perbandingan dengan Penelitian Terdahulu

Sistem yang dikembangkan menunjukkan performa yang lebih komprehensif dibandingkan penelitian sebelumnya. Iskandar dan Kesuma menggunakan SSD MobileNet V2 FPNLite dan EasyOCR dengan akurasi 95%, namun masih terbatas pada dataset kecil dan belum terintegrasi dalam platform web. Nguyen dkk. menggunakan YOLOv10 dan Tesseract OCR dengan akurasi deteksi 94,6%, namun rentan terhadap variasi pencahayaan ekstrem. Chinapas dkk. menggunakan ArcFace dengan akurasi verifikasi 96,09%, namun belum terintegrasi ke web. Penelitian ini berhasil mengatasi keterbatasan tersebut dengan mengintegrasikan YOLOv8n ($mAP@0,5 = 0,976$), PaddleOCR, dan ArcFace dalam satu platform web berbasis real-time, menjadikannya salah satu implementasi terintegrasi yang menggabungkan ketiga teknologi tersebut secara menyeluruh.

3.3.4 Keterbatasan Penelitian

Meskipun sistem yang dikembangkan menunjukkan performa yang menjanjikan, terdapat beberapa keterbatasan yang perlu diakui. Pertama, dataset yang digunakan hanya mencakup KTM dari satu institusi, yaitu Sekolah Vokasi IPB University, sehingga generalisasi model terhadap format KTM dari institusi lain belum dapat dijamin. Kedua, pengujian sistem dilakukan dalam kondisi pencahayaan yang relatif terkontrol, sehingga performa pada kondisi pencahayaan ekstrem seperti cahaya matahari langsung atau ruangan dengan penerangan sangat minim belum dievaluasi secara mendalam. Ketiga, nilai mAP@0,5:0,95 sebesar 0,715 mengindikasikan bahwa presisi lokalisasi bounding box masih dapat ditingkatkan, khususnya untuk kelas text nama yang memperoleh AP@0,5:0,95 terendah (0,573). Keempat, proses verifikasi wajah bergantung pada kualitas kamera webcam yang digunakan, sehingga variasi spesifikasi perangkat keras dapat memengaruhi konsistensi hasil verifikasi. Kelima, dataset pelatihan yang berjumlah 600 citra setelah augmentasi tergolong kecil jika dibandingkan dengan standar dataset deteksi objek pada umumnya, yang berpotensi membatasi kemampuan generalisasi model pada variasi kondisi yang lebih luas. Meskipun dataset awal yang digunakan relatif terbatas, strategi augmentasi data, pembagian dataset menjadi data pelatihan, validasi, dan pengujian, serta penerapan *early stopping* berkontribusi dalam mengurangi *overfitting* dan meningkatkan kemampuan generalisasi model. Namun demikian, pengujian pada dataset yang lebih beragam tetap diperlukan untuk memastikan robustitas model pada skenario penggunaan yang lebih luas.

4. KESIMPULAN

Penelitian ini telah berhasil mengembangkan sistem pinjaman laboratorium komputer berbasis web yang mengintegrasikan deteksi objek YOLOv8n, ekstraksi teks PaddleOCR, dan verifikasi wajah ArcFace (*InsightFace*) dalam satu pipeline verifikasi KTM secara otomatis. Model YOLOv8n yang dilatih menggunakan 600 citra hasil augmentasi mampu mendeteksi empat region pada KTM (*face_photo*, *qr_code*, *text_nama*, dan *text_nim*) dengan mAP@0,5 sebesar 0,976, precision 0,977, dan recall 0,979. Kelas *face_photo* dan *qr_code* mencapai performa tertinggi dengan AP@0,5 masing-masing 0,995 dan recall sempurna (1,000), sementara kelas *text_nama* memperoleh AP@0,5 terendah sebesar 0,939 yang disebabkan oleh variasi panjang teks nama antar sampel. Seluruh komponen teknologi tersebut telah berhasil diintegrasikan ke dalam sistem berbasis web menggunakan FastAPI dan Next.js yang memungkinkan proses verifikasi identitas mahasiswa dilakukan secara *real-time* tanpa intervensi manual.

Untuk pengembangan penelitian selanjutnya, disarankan agar dataset diperluas dengan mencakup KTM dari berbagai institusi guna meningkatkan generalisasi model. Selain itu, pengujian pada variasi kondisi pencahayaan yang lebih beragam perlu dilakukan untuk mengevaluasi ketangguhan sistem di lingkungan nyata. Peningkatan presisi lokalisasi bounding box, khususnya pada kelas teks, juga dapat dieksplorasi melalui penerapan arsitektur model yang lebih kompleks atau teknik fine-tuning lanjutan untuk memperbaiki nilai mAP@0,5:0,95 yang saat ini sebesar 0,715.

REFERENSI

- [1] M. Naufal Rizki, F. Wahyu Christanto, I. Saufik Suasana, E. Ahmad Firdaus, H. Saragih, and S. Maulani, "Sistem Manajemen Laboratorium Komputer Berbasis Website," *J. Sist. Inf. Galuh*, vol. 3, no. 2, pp. 33–46, 2025, doi: 10.25157/jsig.v3i2.4959.
- [2] M. Haq, Dasril, and M. Muhallim, "Face Recognition (Pengenalan Wajah) untuk Sistem Presensi Berbasis Website pada Laboratorium Software Universitas Andi Djemma," *JITET (Jurnal Inform. dan Tek. Elektro Ter.)*, vol. 14, no. 2, pp. 982–994, 2026, doi: <http://dx.doi.org/10.23960/jitet.v14i2.9078>.
- [3] A. I. Rizki, R. Regasari, M. Putri, and N. H. Shaffan, "Sistem Pintu Cerdas Berbasis Pengenalan Wajah dan Kartu Identitas Menggunakan YOLOv8 dan Optical Character Recognition (OCR)," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 4, pp. 1–9, 2025, [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/14700/6574>
- [4] M. F. Ulum, R. Mumpuni, and A. L. Nurlaili, "Evaluasi kinerja validasi KTM berbasis Tesseract OCR menggunakan metode Adaptive Thresholding dan Levenshtein Distance Adaptive Thresholding and Levenshtein Distance methods," *Pros. Semin. Nas. Penelit. Dan Pengabd. Kpd. Masy. LPPM Univ. 'Aisyiyah Yogyakarta*, vol. 4, no. 2021, pp. 892–901, 2026, [Online]. Available: <https://proceeding.unisayogya.ac.id/index.php/prosemnaslppm/article/view/2214>
- [5] R. D. Geralda, A. Irsyad, and M. L. Jundillah, "Implementasi Sistem Presensi Berbasis Face Recognition Menggunakan Model Pra-Latih Facenet Dan Cosine Similarity Dengan Pendekatan Waterfall Pada Website Praktikum Sistem Informasi," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 10, no. 2, pp. 2878–2886, 2026, doi: <https://doi.org/10.36040/jati.v10i2.17828>.
- [6] Arsul, M. Papuan, I. Hizbullah, and A. Dosu, "Perancangan Sistem Informasi Laboratorium Komputer Berbasis Website di Universitas Pasifik Morotai," *J. Tek. SILITEK*, vol. 01, no. 01, pp. 46–52, 2021, doi: <https://doi.org/10.51135/jts.v1i01.7>.
- [7] R. Iskandar and M. E. K. Kesuma, "Designing a Real-Time-Based Optical Character Recognition to Detect ID Cards," *Int. J. Electron. Commun. Syst.*, vol. 2, no. 1, pp. 23–29, 2022, doi: 10.24042/ijecs.v2i1.13108.
- [8] T. Q. Nguyen *et al.*, "A YOLOv10-Based System for Automated FPT University Student Card Information Extraction," *J. Adv. Inf. Technol.*, vol. 16, no. 6, pp. 777–785, 2025, doi: 10.12720/jait.16.6.777-785.
- [9] A. Chinapas, P. Polpinit, N. Intiruk, and K. R. Saikaew, "Personal verification system using ID card and face photo," *Int. J. Mach. Learn. Comput.*, vol. 9, no. 4, pp. 407–412, 2019, doi: 10.18178/ijmlc.2019.9.4.818.