

**IDENTIFIKASI MULTI-INFORMASI PLAT NOMOR KENDARAAN
BERMOTOR DENGAN YOLOV12 DAN *OPTICAL CHARACTER
RECOGNITION* (OCR) PADA PLAT WILAYAH PROVINSI LAMPUNG**

(SKRIPSI)

Oleh

**Septia Rosalia
NPM 2257051018**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG**

2026

**IDENTIFIKASI MULTI-INFORMASI PLAT NOMOR KENDARAAN
BERMOTOR DENGAN YOLOV12 DAN *OPTICAL CHARACTER
RECOGNITION* (OCR) PADA PLAT WILAYAH PROVINSI LAMPUNG**

Oleh

Septia Rosalia

Skripsi

**Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA KOMPUTER**

Pada

Jurusan Ilmu Komputer

Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG**

2026

ABSTRAK

IDENTIFIKASI MULTI-INFORMASI PLAT NOMOR KENDARAAN BERMOTOR DENGAN YOLOV12 DAN *OPTICAL CHARACTER RECOGNITION* (OCR) PADA PLAT WILAYAH PROVINSI LAMPUNG

Oleh

Septia Rosalia

Identifikasi kendaraan secara otomatis merupakan aspek penting dalam sistem pemantauan lalu lintas modern, namun akurasi dan kelengkapan informasi yang diekstraksi dari plat nomor masih menjadi tantangan. Penelitian ini mengembangkan sistem pengenalan plat nomor berbasis multi-informasi menggunakan YOLOv12 dan OCR, yang mampu mendeteksi posisi plat nomor sekaligus mengidentifikasi kode wilayah, nomor registrasi, dan masa berlaku kendaraan dengan fokus pada wilayah Provinsi Lampung. Dataset yang digunakan berjumlah 7.638 citra dengan pembagian 80% latih, 10% validasi, dan 10% uji, melalui tahapan preprocessing, deteksi, pengenalan karakter, dan klasifikasi wilayah. Hasil evaluasi menunjukkan performa YOLOv12 dengan precision 0,96997, recall 0,98914, dan mAP@0,5 sebesar 0,99356, modul OCR mencapai akurasi 98,90%, serta klasifikasi wilayah dengan akurasi 98,99%, precision 89,20%, dan recall 91,76%. Penelitian ini membuktikan bahwa integrasi YOLOv12 dan OCR efektif untuk identifikasi plat nomor dalam kondisi nyata, dengan potensi penerapan pada sistem transportasi cerdas dan pemantauan lalu lintas.

Kata Kunci : Deteksi Objek, OCR, Pengenalan Plat Nomor, Sistem Transportasi Cerdas, YOLOv12

ABSTRACT

MULTI-INFORMATION IDENTIFICATION OF MOTOR VEHICLE LICENSE PLATES USING YOLOV12 AND OPTICAL CHARACTER RECOGNITION (OCR) ON LICENSE PLATES IN THE LAMPUNG PROVINCE REGION

By

Septia Rosalia

Automatic vehicle identification is a critical aspect of modern traffic monitoring systems; however, the accuracy and completeness of information extracted from license plates remain a challenge. This study develops a multi-information-based license plate recognition system using YOLOv12 and OCR, capable of detecting the position of license plates while identifying the region code, registration number, and vehicle validity period, with a focus on the Lampung Province. The dataset consists of 7,638 images, divided into 80% training, 10% validation, and 10% test sets, undergoing stages of preprocessing, detection, character recognition, and region classification. Evaluation results show that YOLOv12 achieved a precision of 0.96997, a recall of 0.98914, and an mAP@0.5 of 0.99356; the OCR module achieved an accuracy of 98.90%; and region classification achieved an accuracy of 98.99%, a precision of 89.20%, and a recall of 91.76%. This study demonstrates that the integration of YOLOv12 and OCR is effective for license plate identification in real-world conditions, with potential applications in intelligent transportation systems and traffic monitoring.

Keywords: Intelligent Transportation Systems, License Plate Recognition, Object Detection, OCR, YOLOv12

Judul Skripsi : **IDENTIFIKASI MULTI-INFORMASI
PLAT NOMOR KENDARAAN
BERMOTOR DENGAN YOLOV12 DAN
OPTICAL CHARACTER RECOGNITION
(OCR) PADA PLAT WILAYAH PROVINSI
LAMPUNG**

Nama Mahasiswa : **Septia Rosafia**

Nomor Pokok Mahasiswa : **2257051018**

Program Studi : **S1-Ilmu Komputer**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**



1. Komisi Pembimbing

Dr. rer. nat. Akmal Junaidi, M.Sc.

NIP. 197101291997021001

Ridho Sholehurrohman, M. Mat.

NIP. 232111970128101

2. Ketua Jurusan Ilmu Komputer

Dwi Sakethi, S.Si., M.Kom.

NIP. 196806111998021001

3. Ketua Program Studi S1 Ilmu Komputer

Tristiyanto, S.Kom., M.I.S., Ph.D.

NIP. 198104142005011001

MENGESAHKAN

1. Tim Penguji

Ketua : **Dr. rer. nat. Akmal Junaidi, M.Sc.**



Sekretaris : **Ridho Sholehurrohman, M. Mat.**



Penguji
Bukan Pembimbing : **Rico Andrian, S.Si., M.Kom.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Heri Satria, S.Si., M.Si.
NIP. 197110012005011002

Tanggal Lulus Ujian Skripsi: 4 Mei 2026

PERNYATAAN

Saya yang bertanda tangan di bawah ini.

Nama : Septia Rosalia

NPM : 2257051018

Dengan ini menyatakan bahwa skripsi saya yang berjudul “**Identifikasi Multi- Informasi Plat Nomor Kendaraan Bermotor dengan YOLOV12 dan *Optical Character Recognition (OCR)* Pada Plat Wilayah Provinsi Lampung**” merupakan hasil karya saya sendiri dan bukan karya orang lain. Seluruh tulisan yang tertuang di skripsi ini telah mengikuti kaidah penulisan karya ilmiah Universitas Lampung. Apabila di kemudian hari terbukti skripsi saya merupakan hasil penjiplakan atau dibuat orang lain, maka saya bersedia menerima sanksi berupa pencabutan gelar yang telah saya terima.



Bandar Lampung, 6 Mei 2026

Septia Rosalia

NPM. 2257051018

RIWAYAT HIDUP



Penulis bernama Septia Rosalia, lahir di Liwa pada tanggal 03 September 2004. Penulis berdomisili di Perum BKP Blok K No. 86 LK. III Kemiling Permai Kecamatan Kemiling Kota Bandar Lampung. Penulis menempuh pendidikan formal di SDN Gunung Sugih dan lulus pada Tahun 2016 kemudian melanjutkan pendidikan di SMPN Sekuting Terpadu dan lulus pada Tahun 2019, serta melanjutkan pendidikan di SMAN 1 Liwa dan lulus pada Tahun 2022. Pada Tahun 2022 penulis melanjutkan pendidikan tinggi pada Program Studi S1 Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

Selama masa perkuliahan, penulis aktif dalam kegiatan akademik dan organisasi dengan pengalaman sebagai berikut:

1. Menjadi Anggota Muda Ilmu Komputer (ADAPTER) Himpunan Mahasiswa Jurusan Ilmu Komputer pada periode 2022/2023.
2. Menjadi Anggota Bidang Kaderisasi Himpunan Mahasiswa Jurusan Ilmu Komputer pada periode 2023/2024.
3. Menjadi Bendahara Biro Kesekretariatan Himpunan Mahasiswa Jurusan Ilmu Komputer pada periode 2024/2025.
4. Menjadi Asisten Dosen Jurusan Ilmu Komputer pada mata kuliah Matematika Diskrit Tahun 2024.
5. Menjadi Asisten Dosen Jurusan Ilmu Komputer pada mata kuliah Analisis dan Desain Sistem Informasi Tahun 2025.

6. Menjadi Koordinator Asisten Dosen Jurusan Ilmu Komputer pada mata kuliah *Cloud Computing* 2025.
7. Menjadi Anggota Divisi Acara pada acara pekan Raya Jurusan Ilmu Komputer Tahun 2023.
8. Menjadi Koordinator Divisi Bazar Danus pada acara *Computer Science Showdown* Tahun 2023.
9. Mengikuti Studi Independen Bersertifikat (MSIB) Angkatan 7 *Bangkit Academy-Cohort Cloud Computing* Tahun 2024.
10. Melaksanakan Kerja Praktik di PT. Telkom Infrastruktur Indonesia *Sub District* Lampung pada periode 2024/2025 dengan program kerja pengembangan *website* dan divisi *Data Management*.
11. Kuliah Kerja Nyata (KKN) di Desa Setia Bakti, Kecamatan Seputih Banyak, Kabupaten Lampung Tengah (2025).

MOTTO

“Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya.”

(QS. Al-Baqarah: 286)

“Barang siapa bertakwa kepada Allah niscaya Dia akan mengadakan baginya jalan keluar, dan memberinya rezeki dari arah yang tidak disangka-sangka.”

(QS. Ath-Thalaq: 2–3)

“Jangan pernah menyerah sebelum mencoba.”

PERSEMBAHAN

Alhamdulillahirobbilalamin

Puji syukur saya panjatkan kepada Allah SWT atas segala limpahan rahmat dan karunia-Nya sehingga skripsi ini dapat terselesaikan dengan baik. Shalawat serta salam semoga senantiasa tercurah kepada Nabi Muhammad SAW sebagai teladan bagi umat manusia.

Kupersembahkan skripsi ini kepada

Kedua Orang Tuaku Tercinta

Kalian telah lebih dahulu dipanggil oleh-Nya, namun doa kalian mengantarkanku hingga titik ini. Terima kasih atas segala pengorbanan dan kasih sayang. Semoga semua kebaikan kalian menjadi amal jariyah dan Allah SWT melapangkan tempat kalian di sisi-Nya.

Kakak-Kakakku Tercinta

Terima kasih atas doa dan dukungan serta semangat, perhatian, kesabaran, dan segala usaha hingga sampai di titik ini.

Teman-Temanku Tersayang

Terima kasih atas dukungan, semangat dan canda tawa yang selalu menguatkan. Kebersamaan ini menjadi kenangan berharga yang tidak akan terlupakan.

Seluruh Keluarga Besar Ilmu Komputer 2022

Terima kasih atas kebersamaan dan dukungan selama masa studi.

Almamater Tercinta, Jurusan Ilmu Komputer dan Universitas Lampung yang telah menjadi tempat penulis menimba ilmu dan bekal untuk masa depan.

SANWANCANA

Puji syukur penulis panjatkan ke hadirat Allah Subhanahu Wa Ta'ala atas segala rahmat dan karunia-Nya. Shalawat serta salam semoga selalu tercurah kepada Nabi Muhammad Shallallahu 'Alaihi Wasallam. Dengan rahmat dan ridha-Nya, penulis dapat menyelesaikan skripsi yang berjudul: "Identifikasi Multi-Informasi Plat Nomor Kendaraan Bermotor dengan YOLOV12 dan *Optical Character Recognition* (OCR) pada Plat Wilayah Provinsi Lampung" dengan baik. Skripsi ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer pada Jurusan Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung. Penulis menyadari bahwa dalam proses penyusunan skripsi ini tidak lepas dari bantuan, doa, serta dukungan dari berbagai pihak. Oleh karena itu, penulis menyampaikan terima kasih yang sebesar-besarnya kepada:

1. Mak dan Bak yang telah lebih dahulu berpulang ke sisi Allah SWT. Meskipun tidak lagi bersama, penulis meyakini bahwa doa dan kasih sayang yang telah diberikan semasa hidup senantiasa menyertai setiap langkah penulis hingga sampai pada tahap ini. Segala pencapaian yang diraih tidak terlepas dari didikan, pengorbanan dan nilai-nilai kehidupan yang telah ditanamkan. Semoga Allah SWT senantiasa melimpahkan rahmat, mengampuni segala dosa dan menempatkan mereka di tempat terbaik di sisi-Nya.
2. Kakak-kakak penulis yaitu Wo Meriyanti, Udo Rido Septadinata dan Abang Riki Agusta yang selalu memberikan doa, dukungan dan semangat kepada penulis. Terima kasih atas perhatian, kesabaran serta segala usaha dan pengorbanan yang telah diberikan. Dukungan kalian menjadi salah satu kekuatan bagi penulis dalam menyelesaikan skripsi ini.

3. Bapak Dr. Eng. Heri Satria, S.Si., M.Si. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
4. Bapak Dwi Sakethi, S.Si., M.Kom. selaku Ketua Jurusan Ilmu Komputer FMIPA Universitas Lampung.
5. Ibu Yunda Heningtyas, M.Kom. selaku Sekretaris Jurusan Ilmu Komputer FMIPA Universitas Lampung.
6. Bapak Tristiyanto, S.Kom., M.I.S., Ph.D. selaku Kepala Program Studi S1 Ilmu Komputer.
7. Bapak Dr. rer. nat. Akmal Junaidi, M.Sc. selaku Pembimbing Utama yang telah meluangkan waktu untuk membimbing penulis selama penyusunan skripsi ini. Terima kasih atas arahan, masukan dan diskusi yang diberikan sehingga penulis dapat memahami setiap tahap penelitian dengan lebih baik. Arahan dan bimbingan yang diberikan sangat membantu penulis dalam menyelesaikan skripsi ini.
8. Bapak Ridho Sholehurrohman, M. Mat. selaku Pembimbing Pembantu yang telah memberikan bimbingan selama proses penyusunan skripsi ini. Terima kasih atas waktu, arahan dan masukan yang diberikan sehingga penulis dapat memahami arah penelitian dengan lebih baik, termasuk hal-hal yang sebelumnya belum terpikirkan. Bapak juga senantiasa meluangkan waktu untuk berdiskusi dan membantu penulis ketika menghadapi kesulitan, sehingga mempermudah setiap proses dalam penelitian maupun penulisan skripsi.
9. Bapak Rico Andrian, S.Si., M.Kom. selaku Pembahas yang telah memberikan masukan, kritik dan saran dalam penyusunan skripsi ini. Terima kasih atas arahan yang diberikan sehingga penulis dapat memperbaiki dan menyempurnakan skripsi ini.
10. Seluruh dosen Jurusan Ilmu Komputer FMIPA Universitas Lampung, yang telah membekali penulis dengan pengetahuan, pengalaman serta wawasan selama masa perkuliahan.
11. Seluruh staf dan karyawan Jurusan Ilmu Komputer, khususnya Ibu Ade Nora Maela, Bang Zainuddin, Pak Dahud, dan Mas Syam yang telah

membantu penulis dalam berbagai urusan administrasi selama masa perkuliahan.

12. Sahabat penulis Ulfa, Fitri dan Safira yang telah menjadi teman sejak masa SMP hingga sekarang. Terima kasih atas kebersamaan yang terus terjaga, dukungan dan perhatian yang selalu diberikan. Terima kasih juga telah menjadi tempat berbagi cerita, tawa serta suka dan duka selama perjalanan yang telah dilalui bersama hingga sampai di titik ini.
13. Sahabat seperjuangan semasa kuliah Apaya Kr Kr (Afina, Zahra, Ayu, Nadya, Kezia) dan Deta yang selalu memberikan dukungan dan menemani penulis selama masa perkuliahan hingga proses penyusunan skripsi. Terima kasih atas kebersamaan, cerita serta canda tawa yang telah dilalui bersama. Terima kasih juga karena selalu ada, saling memahami dan menerima penulis dari awal perkuliahan hingga saat ini. Semoga pertemanan ini tetap terjaga dengan baik meskipun masa kuliah telah berakhir.
14. Teman-teman RT 17 (Pimpinan HIMAKOM 2024) terima kasih atas kebersamaan selama berorganisasi. Banyak pengalaman dan hal baru yang penulis dapatkan dari proses yang dijalani bersama serta berbagai hal yang telah dilewati bersama.
15. Teman-teman angkatan 2022 Jurusan Ilmu Komputer yang telah menjadi bagian dari perjalanan penulis selama masa perkuliahan. Terima kasih atas kebersamaan, dukungan dan proses yang dijalani bersama selama ini.
16. Semua pihak yang telah membantu penulis baik selama perkuliahan maupun dalam proses penyusunan skripsi ini. Terima kasih atas dukungan, bantuan, dan kontribusi yang telah diberikan sehingga penulis dapat menyelesaikan skripsi ini dengan baik.
17. Dan yang terakhir kepada diri penulis sendiri terima kasih telah bertahan sampai di titik ini. Terima kasih karena tidak memilih untuk menyerah, meskipun proses yang dijalani tidak selalu mudah dan sering terasa berat. Terima kasih karena tetap berusaha, tetap melangkah bahkan di saat merasa lelah, ragu dan hampir berhenti. Skripsi ini bukan sekadar hasil akhir, tetapi bukti dari proses panjang yang penuh usaha, kesabaran dan keteguhan.

Terima kasih karena sudah terus mencoba, belajar dari setiap kesulitan, dan menyelesaikan apa yang telah dimulai.

Penulis menyadari bahwa skripsi ini masih memiliki keterbatasan dan belum sepenuhnya sempurna. Kritik dan saran yang membangun sangat penulis harapkan untuk perbaikan ke depan. Semoga skripsi ini dapat memberikan manfaat dan menambah wawasan bagi pembaca.

Bandar Lampung, 6 Mei 2026

Penulis,



Septia Rosalia
NPM. 2257051018

DAFTAR ISI

	Halaman
DAFTAR ISI.....	xiv
DAFTAR GAMBAR	xviii
DAFTAR TABEL.....	xxi
DAFTAR KODE PROGRAM.....	xxii
I. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah.....	4
1.4 Tujuan	5
1.5 Manfaat	6
II. TINJAUAN PUSTAKA	7
2.1 Penelitian Terdahulu	7
2.2 Plat Nomor Kendaraan.....	11
2.3 Pengolahan Citra Digital	15
2.4 Pengolahan Video Digital	17
2.5 <i>Cropping</i> Citra	19
2.6 Citra <i>Resize</i>	20
2.7 Deteksi Objek.....	21
2.8 <i>Computer Vision</i>	22
2.9 <i>Artificial Intelligence</i>	23
2.10 <i>Machine Learning</i>	24
2.11 <i>Deep Learning</i>	26

2.12	<i>Convolutional Neural Network</i>	26
2.13	<i>You Only Look Once (YOLO)</i>	29
2.14	<i>You Only Look Once Version 12 (YOLOv12)</i>	30
2.15	<i>Optical Character Recognition (OCR)</i>	34
2.16	<i>Hyperparameter</i>	39
2.17	<i>Confusion Matrix</i>	40
2.18	<i>Mean Average Precision (mAP)</i>	44
III.	METODE PENELITIAN	45
3.1	Waktu dan Tempat	45
3.1.1	Tempat Penelitian	45
3.1.2	Waktu Penelitian	45
3.2	Alat Pendukung	47
3.2.1	Perangkat Keras (<i>Hardware</i>)	47
3.2.2	Perangkat Lunak (<i>Software</i>)	47
3.3	Tahapan Penelitian	52
3.3.1	Pengumpulan Data	53
3.3.2	<i>Pre-processing</i>	53
3.3.3	Pembagian Data	56
3.3.4	Augmentasi Data Latih	57
3.3.5	<i>YOLOV12 Model</i>	57
3.3.6	<i>OCR Engine</i>	59
3.3.7	<i>Group Contouring</i>	60
3.3.8	<i>Classification</i>	61
3.3.9	<i>Evaluation Score</i>	61
3.3.10	Skenario Pengujian Model	62

3.3.11	Analisis Kinerja Model	63
IV.	HASIL DAN PEMBAHASAN.....	64
4.1	Pengambilan Data	64
4.2	<i>Pre-processing</i>	66
4.2.1	Ekstraksi Video ke <i>Image</i>	67
4.2.2	<i>Cropping</i>	68
4.2.3	<i>Resizing</i>	69
4.2.4	Anotasi Data.....	71
4.3	Pembagian Data	72
4.4	Augmentasi Data Latih	73
4.5	<i>Hyperparameter Tuning</i>	75
4.6	<i>Training Model</i>	76
4.7	<i>Model Validation</i>	78
4.8	Hasil dan Analisis Model	79
4.9	Integrasi OCR Engine	92
4.9.1	Konfigurasi <i>OCR Engine</i>	92
4.9.2	<i>Character Recognition Process</i>	94
4.9.3	<i>Text Extraction</i>	97
4.9.4	<i>Post-Processing Text Cleaning</i>	99
4.10	<i>Group contouring</i>	103
4.11	<i>Testing Model</i>	107
4.12	Klasifikasi Wilayah	110
4.13	Hasil Klasifikasi Wilayah	111
4.14	Evaluasi Model.....	113
4.14.1	Evaluasi Hasil Pengujian Deteksi	113

4.14.2	Evaluasi Hasil Pengujian Klasifikasi	119
4.15	Analisis Hasil OCR.....	134
V.	SIMPULAN DAN SARAN.....	140
5.1	Kesimpulan	140
5.2	Saran.....	141
	DAFTAR PUSTAKA	143

DAFTAR GAMBAR

Gambar	Halaman
Gambar 1. Struktur dan Komponen Plat Nomor Kendaraan Bermotor di Indonesia.	12
Gambar 2. Pengolahan citra digital pada plat nomor kendaraan (Jia <i>et al.</i> , 2021).	16
Gambar 3. Representasi Pengolahan Video Digital (Decorte <i>et al.</i> , 2024).....	17
Gambar 4. Representasi <i>Cropping</i> Citra.	20
Gambar 5. Representasi Citra <i>Resize</i>	21
Gambar 6. Penerapan <i>computer vision</i> pada OCR untuk mendeteksi dan mengekstrak teks otomatis (Szeliski, 2021).....	22
Gambar 7. AI, ML, and DL <i>Relationship</i>	23
Gambar 8. Arsitektur CNN (Auni & Sugiharti, 2025).....	27
Gambar 9. <i>Convolutional Layer</i> (Purwono <i>et al.</i> , 2022).....	28
Gambar 10. <i>Pooling Layer</i> (Purwono <i>et al.</i> , 2022).....	28
Gambar 11. <i>Fully Connected Layer</i> (Purwono <i>et al.</i> , 2022).....	29
Gambar 12. Representasi Visual Proses Deteksi Objek dengan YOLO.	30
Gambar 13. Arsitektur YOLOv12 (dimodifikasi dari Sapkota <i>et al.</i> , 2025).....	32
Gambar 14. Perbandingan YOLOv12 dengan metode populer lain pada dataset COCO (Tian <i>et al.</i> , 2025).....	34
Gambar 15. Tahapan umum proses <i>Optical Character Recognition</i> pada sistem LPR (dimodifikasi dari Selmi <i>et al.</i> , 2019).....	35
Gambar 16. Diagram alur proses identifikasi plat nomor kendaraan menggunakan YOLOv12 dan modul OCR.	36
Gambar 17. Struktur Tahapan Penelitian.	52
Gambar 18. Ilustrasi proses pengambilan dataset 1.	66

Gambar 19. Ilustrasi proses pengambilan dataset 2.....	66
Gambar 20. Ilustrasi proses pengambilan dataset 3.....	66
Gambar 21. Representasi <i>Frame</i> Hasil Ekstraksi dari Video.....	67
Gambar 22. Representasi Hasil <i>Cropping</i> Pada <i>Frame</i>	68
Gambar 23. Representasi Hasil <i>Resizing</i> Pada <i>Frame</i>	69
Gambar 24. Anotasi <i>bounding box</i> menggunakan <i>LabelImg</i>	71
Gambar 25. File Hasil Anotasi <i>Bounding box</i>	71
Gambar 26. Visualisasi Hasil <i>Mosaic Augmentation</i>	74
Gambar 27. File konfigurasi <i>YAML</i> dataset.....	77
Gambar 28. Perbandingan metrik evaluasi model <i>YOLOv12</i>	79
Gambar 29. Grafik Hasil <i>Training</i> Model dengan <i>Epoch</i> 50 dan <i>Learning rate</i> 0,0001.....	81
Gambar 30. Grafik Hasil <i>Training</i> Model dengan <i>Epoch</i> 100 dan <i>Learning rate</i> 0,0001.....	82
Gambar 31. Grafik Hasil <i>Training</i> Model dengan <i>Epoch</i> 150 dan <i>Learning rate</i> 0,0001.....	84
Gambar 32. Grafik Hasil <i>Training</i> Model dengan <i>Epoch</i> 50 dan <i>Learning rate</i> 0,001.....	85
Gambar 33. Grafik Hasil <i>Training</i> Model dengan <i>Epoch</i> 100 dan <i>Learning rate</i> 0,001.....	87
Gambar 34. Grafik Hasil <i>Training</i> Model dengan <i>Epoch</i> 150 dan <i>Learning rate</i> 0,001.....	88
Gambar 35. Perbandingan Waktu <i>Training</i> Model <i>YOLOv12</i>	91
Gambar 36. Contoh plat nomor sebagai input proses ekstraksi teks.....	98
Gambar 37. Hasil ekstraksi teks.....	98
Gambar 38. File <i>CSV</i> hasil <i>Post-Processing</i> <i>OCR</i>	101
Gambar 39. Visualisasi hasil ekstraksi teks plat nomor kendaraan sebelum dan sesudah proses <i>Post-Processing</i>	102
Gambar 40. Visualisasi hasil <i>group contouring</i> pada karakter plat nomor kendaraan.....	104
Gambar 41. File <i>CSV</i> hasil <i>group contouring</i> informasi plat nomor.....	105

Gambar 42. Hasil Pengujian YOLOv12	108
Gambar 43. Visualisasi hasil deteksi pembacaan karakter plat nomor kendaraan.	109
Gambar 44. Visualisasi hasil evaluasi <i>group contouring</i> per komponen.	110
Gambar 45. Distribusi Plat Nomor Berdasarkan Provinsi.	112
Gambar 46. Distribusi plat nomor kendaraan per kota/kabupaten di Provinsi Lampung.	112
Gambar 47. Perbandingan hasil prediksi dengan <i>Ground truth</i>	114
Gambar 48. Visualisasi Perhitungan IoU.....	115
Gambar 49. Distribusi nilai IoU antara prediksi dan <i>ground truth</i>	116
Gambar 50. <i>Confusion Matrix</i> Evaluasi Klasifikasi.	117
Gambar 51. Visualisasi Hasil Pengenalan Karakter.	121
Gambar 52. Perbandingan Akurasi Karakter OCR pada Evaluasi <i>Frame</i> dan Evaluasi Objek.	126
Gambar 53. Distribusi Tingkat Ketepatan Karakter pada Evaluasi Objek.	127
Gambar 54. Analisis Perbandingan Tingkat Kesalahan Karakter.....	128
Gambar 55. Distribusi Nilai <i>Object Mean CER</i> pada Seluruh Plat.	129
Gambar 56. <i>Confusion Matrix</i> Evaluasi Klasifikasi.	130
Gambar 57. Plat nomor Bandar Lampung Tulisan Buram.	135
Gambar 58. Kesalahan Pembacaan Plat Nomor Kendaraan akibat Sudut Pengambilan Gambar yang Miring.	136
Gambar 59. Plat nomor kendaraan dengan kondisi pantulan cahaya matahari...	137
Gambar 60. Plat nomor kendaraan dengan warna karakter pudar.	138

DAFTAR TABEL

Tabel	Halaman
Tabel 1 Penelitian Terdahulu Terkait Identifikasi Plat Nomor Kendaraan.....	7
Tabel 2 Kode Seri Belakang Plat.	14
Tabel 3. <i>Confusion Matrix</i> (Sathyanarayanan, 2024).	41
Tabel 4. Jadwal Kegiatan.	46
Tabel 5. Alat Pendukung (Perangkat Keras).....	47
Tabel 6. Jumlah data sebelum dan sesudah augmentasi	73
Tabel 7. Konfigurasi <i>Hyperparameter</i>	75
Tabel 8 Hasil Evaluasi Model dengan Variasi <i>Epoch</i> dan <i>Learning rate</i>	90
Tabel 9. Evaluasi performa model deteksi objek.	118
Tabel 10. Contoh Data Pengujian.	122
Tabel 11. Matriks <i>Levenshtein Distance</i>	124
Tabel 12. Hasil <i>Testing</i> OCR.	131
Tabel 13. Hasil Evaluasi Klasifikasi OCR.....	132

DAFTAR KODE PROGRAM

Kode Program	Halaman
Kode Program 1. <i>Cropping</i> Image.....	68
Kode Program 2. <i>Resizing</i> Image.....	70
Kode Program 3. Pembagian Dataset.....	72
Kode Program 4. <i>Training</i> Model YOLOv12.....	77
Kode Program 5. Validasi Model YOLOv12.	78
Kode Program 6. Inisialisasi direktori OCR.	93
Kode Program 7. Konfigurasi GPU untuk <i>EasyOCR</i>	93
Kode Program 8. Implementasi <i>adaptive brightness</i> pada citra.	95
Kode Program 9. Peningkatan kontras dengan CLAHE.....	96
Kode Program 10. Penerapan <i>adaptive thresholding</i> untuk pemisahan karakter.	96
Kode Program 11. Penerapan <i>Otsu threshold</i> pada citra plat.	97
Kode Program 12. <i>Testing</i> Model YOLOv12.....	107

I. PENDAHULUAN

1.1 Latar Belakang

Perkembangan teknologi informasi dan komunikasi yang sangat pesat membawa perubahan besar dalam berbagai aspek kehidupan, termasuk sistem transportasi dan manajemen lalu lintas. Meningkatnya jumlah kendaraan bermotor di berbagai negara menimbulkan tantangan dalam pengawasan lalu lintas, penegakan hukum, serta pengelolaan administrasi kendaraan. Kondisi ini mendorong pengembangan sistem identifikasi kendaraan yang efisien, akurat, dan otomatis untuk mendukung keamanan serta efektivitas pengawasan (Mandal *et al.*, 2020).

Provinsi Lampung sebagai salah satu provinsi dengan pertumbuhan kendaraan yang signifikan menghadapi tantangan serupa dalam pengawasan dan pengelolaan lalu lintas. Berdasarkan data Badan Pusat Statistik Provinsi Lampung tahun 2024, jumlah kendaraan bermotor di Provinsi Lampung mencapai 4.036.997 unit yang tersebar di 15 kabupaten/kota. Kota Bandar Lampung memiliki jumlah tertinggi, yaitu 1.012.534 unit, diikuti Lampung Tengah 615.841 unit, Lampung Selatan 528.354 unit, dan Lampung Timur 468.300 unit (Badan Pusat Statistik Provinsi Lampung, 2024). Peningkatan jumlah kendaraan ini menyebabkan kemacetan dan pelanggaran lalu lintas, serta menimbulkan tantangan dalam sistem pengawasan dan manajemen lalu lintas. Sistem pengawasan manual menjadi kurang efektif dalam memantau volume kendaraan yang besar, sehingga banyak pelanggaran tidak terpantau secara optimal. Kondisi ini menunjukkan perlunya penerapan sistem deteksi otomatis berbasis teknologi untuk meningkatkan efektivitas pengawasan dan keamanan lalu lintas di wilayah Provinsi Lampung (Amyrulloh & Samuji, 2024).

Teknologi *License Plate Recognition* (LPR) menjadi solusi efektif untuk identifikasi dan pemantauan kendaraan otomatis. Dengan metode *deep learning*, LPR meningkatkan akurasi dan efisiensi pada sistem keamanan, pemantauan lalu lintas, serta pembayaran otomatis (Salsabila & Sriani, 2024; Satya *et al.*, 2025). Tanda Nomor Kendaraan Bermotor (TNKB) sebagai identitas resmi kendaraan berperan penting dalam sistem LPR dan menjadi dasar pengawasan serta penegakan hukum. Ketentuan teknis TNKB di Indonesia diatur dalam Peraturan Kapolri Nomor 7 Tahun 2021 guna mencegah pemalsuan dan mendukung sistem identifikasi elektronik (Kaimuddin Haris *et al.*, 2024; Ristantyo *et al.*, 2022). Kombinasi elemen-elemen pada plat nomor menghasilkan satu kesatuan data yang memuat beragam informasi, sehingga plat nomor berfungsi sebagai media multi-informasi yang mendukung proses pengawasan lalu lintas (Hanif *et al.*, 2023).

YOLO (*You Only Look Once*) merupakan algoritma deteksi objek *real-time* yang diperkenalkan pertama kali pada 2015 (Redmon *et al.*, 2016). Versi terbaru, YOLOv12, mengintegrasikan mekanisme perhatian untuk meningkatkan akurasi tanpa mengorbankan kecepatan. Inovasi utama mencakup *Area Attention Module*, R-ELAN, dan *FlashAttention*. *Area Attention* membagi peta fitur untuk menjaga bidang pandang luas dengan komputasi efisien. R-ELAN memperkuat agregasi fitur melalui konvolusi dalam dan koneksi residual, sementara *FlashAttention* mengoptimalkan akses memori dan mempercepat inferensi. Kombinasi dari inovasi ini memungkinkan YOLOv12 mencapai keseimbangan optimal antara kecepatan dan akurasi, menjadikannya pilihan yang cocok untuk deteksi objek *real-time* seperti identifikasi plat nomor kendaraan (Alif & Hussain, 2025).

Proses pengenalan karakter plat nomor dilakukan menggunakan teknologi *Optical Character Recognition* (OCR). OCR adalah teknik dalam pengolahan citra dan *computer vision* yang mampu mengubah gambar huruf atau angka menjadi karakter teks yang dapat dikenali sistem. Penggunaan

OCR meningkatkan fleksibilitas serta kecerdasan sistem komputer dalam mengekstraksi informasi pada plat nomor kendaraan (Hanif *et al.*, 2023). Teknologi OCR dalam sistem pengenalan plat nomor kendaraan menunjukkan tingkat keberhasilan pengenalan karakter yang tinggi, menjadikannya pilihan yang efisien dan efektif dalam berbagai aplikasi (Salimah *et al.*, 2021).

Beberapa penelitian sebelumnya telah mengembangkan sistem deteksi dan pengenalan plat nomor kendaraan dengan berbagai pendekatan. Kombinasi YOLO dan OCR terbukti memberikan hasil deteksi yang akurat pada berbagai penelitian. Penelitian oleh Buleu *et al.* (2025) menunjukkan bahwa penggunaan YOLOv12 dan *PaddleOCR* mampu mencapai akurasi deteksi plat nomor sebesar 99,6%. Penelitian oleh Sarhan *et al.* (2024) berhasil mengintegrasikan YOLOv8 dan *EasyOCR* sehingga memperoleh akurasi pengenalan karakter 99,4% pada plat nomor berbahasa Arab. Penelitian oleh Kothai *et al.* (2024) menerapkan YOLO terpadu dengan *super-resolution GAN*, menghasilkan akurasi sebesar 98,5%. Penelitian oleh Moussaoui *et al.* (2024) menggunakan integrasi YOLOv8 dan OCR dalam penelitiannya dan menghasilkan akurasi deteksi plat Arab-Latin sebesar 98,3%. Penelitian-penelitian tersebut menunjukkan efektivitas kombinasi YOLO dan OCR dalam sistem pengenalan plat nomor dengan akurasi tinggi pada berbagai kondisi dan jenis karakter.

Penelitian ini merupakan pengembangan dari studi Utami (2024) yang menerapkan metode Faster R-CNN untuk klasifikasi karakter plat nomor di lima kabupaten/kota di Provinsi Lampung dengan akurasi 90,62%. Hasil tersebut menunjukkan potensi *deep learning* dalam identifikasi kendaraan, namun peningkatan akurasi dan cakupan wilayah masih diperlukan agar sistem dapat dimanfaatkan secara luas. Penelitian ini mengimplementasikan algoritma YOLOv12 yang memiliki keunggulan dalam kecepatan dan akurasi dibandingkan Faster R-CNN, serta memperluas area deteksi menjadi 15 kabupaten/kota di Provinsi Lampung. Sistem yang dikembangkan menggabungkan YOLOv12 untuk deteksi dan OCR untuk

pengenalan karakter, dengan tujuan menghasilkan identifikasi plat nomor yang lebih akurat dan komprehensif guna mendukung pengawasan lalu lintas serta pelacakan kendaraan secara otomatis. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* dengan dataset yang merepresentasikan kondisi nyata, sehingga hasilnya diharapkan mampu meningkatkan efektivitas sistem dalam membantu aparat melakukan pemantauan kendaraan, mendeteksi pelanggaran, serta mendukung penanganan kasus seperti pencurian kendaraan bermotor di wilayah pengawasan.

1.2 Rumusan Masalah

Rumusan masalah yang menjadi fokus dalam penelitian ini adalah sebagai berikut :

1. Bagaimana mengimplementasikan YOLOv12 dan *Optical Character Recognition* (OCR) untuk mendeteksi dan mengenali plat nomor kendaraan di Provinsi Lampung?
2. Bagaimana performa sistem identifikasi plat nomor kendaraan berbasis YOLOv12 dan *Optical Character Recognition* (OCR) dalam mendeteksi serta mengenali karakter alfanumerik pada plat nomor kendaraan di Provinsi Lampung?

1.3 Batasan Masalah

Batasan masalah yang digunakan sebagai fokus dalam tujuan penelitian ini sebagai berikut :

1. Penelitian ini akan menggunakan bahasa pemrograman python dengan mengimplementasikan YOLOv12 untuk deteksi plat nomor kendaraan dan teknologi *Optical Character Recognition* (OCR) untuk pengenalan karakter alfanumerik pada plat nomor.

2. Informasi yang akan diidentifikasi pada plat nomor meliputi kode wilayah provinsi, nomor seri plat nomor kendaraan, kode wilayah kota/kabupaten, serta bulan dan tahun masa berlaku plat nomor kendaraan, dengan fokus evaluasi pada 15 wilayah kabupaten/kota di Provinsi Lampung.
3. Dalam penelitian ini data citra plat nomor kendaraan dikumpulkan secara manual pada siang hari dengan kondisi pencahayaan yang baik untuk memastikan kualitas gambar yang optimal.
4. Fokus penelitian ini adalah pada kendaraan yang berada di area parkir Universitas Lampung, dengan pengambilan data dilakukan di dua lokasi, yaitu area parkir motor Terpadu dan area parkir UPT Bahasa Universitas Lampung.
5. Penelitian ini mencakup plat nomor kendaraan pribadi.

1.4 Tujuan

Tujuan dari penelitian ini adalah :

1. Mengimplementasikan algoritma YOLOv12 untuk mendeteksi area plat nomor kendaraan secara otomatis pada citra kendaraan yang diambil di Provinsi Lampung.
2. Menerapkan teknologi *Optical Character Recognition* (OCR) untuk mengenali karakter alfanumerik pada plat nomor kendaraan yang telah terdeteksi, guna mengekstraksi informasi penting seperti kode wilayah, nomor registrasi, dan masa berlaku pajak kendaraan.
3. Mengevaluasi kinerja sistem identifikasi multi-informasi plat nomor kendaraan yang mengintegrasikan algoritma YOLOv12 dan teknologi OCR dalam mendeteksi serta mengenali karakter alfanumerik pada plat nomor kendaraan di Provinsi Lampung.

1.5 Manfaat

Manfaat yang diharapkan dari penelitian ini adalah :

1. Memberikan solusi teknologi yang efektif dalam mendeteksi area plat nomor kendaraan menggunakan algoritma YOLOv12, sehingga mempermudah proses identifikasi kendaraan di Provinsi Lampung.
2. Meningkatkan akurasi pengenalan karakter plat nomor kendaraan melalui penerapan teknologi *Optical Character Recognition (OCR)*, yang dapat mengoptimalkan pengambilan informasi penting seperti asal wilayah, nomor registrasi, serta masa berlaku pajak kendaraan.
3. Mengevaluasi kinerja sistem integrasi YOLOv12 dan OCR sebagai referensi pengembangan sistem pengenalan plat nomor.
4. Mendukung pengembangan otomasi dan keamanan transportasi, khususnya dalam aplikasi *Intelligent Transportation System (ITS)*, dengan kemampuan mengidentifikasi dan memantau kendaraan secara lebih efisien.
5. Memberikan manfaat praktis bagi instansi terkait, seperti kepolisian dan dinas perhubungan, dalam pengawasan dan penegakan hukum terkait pelanggaran administrasi serta kriminalitas yang melibatkan kendaraan.

II. TINJAUAN PUSTAKA

Bab ini menyajikan tinjauan mengenai literatur serta penelitian terdahulu yang relevan dengan topik penelitian. Penyusunan teori-teori pendukung bertujuan membangun dasar pemahaman yang kuat sekaligus menjadi acuan dalam pengembangan kerangka berpikir dan pemilihan metode penelitian.

2.1 Penelitian Terdahulu

Penelitian ini merujuk pada penelitian-penelitian sebelumnya yang digunakan sebagai dasar penguatan kajian dan arah pengembangan penelitian. Tabel 1 menyajikan beberapa penelitian yang digunakan sebagai referensi dalam penelitian.

Tabel 1 Penelitian Terdahulu Terkait Identifikasi Plat Nomor Kendaraan.

No.	Judul Penelitian	Objek	Metode	Data	Pokok Pembahasan
1.	Klasifikasi Karakter Plat Nomor Kendaraan Menggunakan <i>Faster Region-Based Convolutional Neural Network</i> (Faster R-	Karakter plat nomor kendaraan Indonesia	Faster R-CNN dengan <i>backbone</i> ResNet-50	850 citra plat nomor kendaraan (<i>split</i> : 80% latih, 10% validasi, 10% uji)	Deteksi dan klasifikasi karakter plat nomor kendaraan berdasarkan wilayah kabupaten/kota di Provinsi Lampung, dengan rata-rata <i>accuracy</i>

No.	Judul Penelitian	Objek	Metode	Data	Pokok Pembahasan
	CNN) (M. Utami, 2024)				94,59%, <i>precision</i> 86,90%, <i>recall</i> 86,48%, dan F1-score 86,44%
2.	<i>A Deep learning-Based System for Automatic License Plate Recognition Using YOLOv12 and PaddleOCR</i> (Buleu <i>et al.</i> , 2025)	Plat nomor kendaraan Romania	YOLOv12 dan <i>PaddleOCR</i>	744 gambar kendaraan Romania, augmented reality hingga 14.880 sampel virtual	Pengembangan sistem ALPR Romania untuk deteksi plat nomor, jenis kendaraan, serta wilayah registrasi; <i>precision</i> 99.6% dan F1-score 97.8%
3.	<i>Egyptian car plate recognition based on YOLOv8, Easy-OCR, and CNN</i> (Sarhan <i>et al.</i> , 2024)	Plat nomor kendaraan Mesir	YOLOv8, <i>EasyOCR</i> , dan CNN	2.450 gambar (EALPR dataset), plus 96.759 gambar karakter untuk OCR	Sistem dua tahap: deteksi dengan YOLOv8 lalu pengenalan karakter Arab dengan CNN; akurasi deteksi 94.26% dan <i>Training</i>

No.	Judul Penelitian	Objek	Metode	Data	Pokok Pembahasan
					pengenalan 99.4%
4.	<i>An Efficient Deep learning Approach for Automatic License Plate Detection with Novel Feature extraction</i> (Kothai <i>et al.</i> , 2024)	Plat nomor kendaraan dalam sistem manajemen lalu lintas dan parkir	YOLO dan SRGAN	model diuji pada <i>real-time</i> CCTV video dan gambar kendaraan beragam kondisi	Penggabungan deteksi dan pengenalan karakter dalam satu jaringan; akurasi 98.5% dengan performa lebih baik daripada R-CNN, CNN, dan LSTM
5.	<i>Enhancing automated vehicle identification by integrating YOLO v8 and OCR techniques for high-precision license plate detection and</i>	Sistem identifikasi kendaraan otomatis	YOLOv8, Pemrosesan Citra, dan OCR	270 gambar kendaraan	Deteksi dan pengenalan plat nomor dengan akurasi deteksi 99%, pengenalan karakter 98%, <i>precision</i> 99.9%, <i>recall</i> 99.5%, dan F1-score 99.68%

No.	Judul Penelitian	Objek	Metode	Data	Pokok Pembahasan
	<i>recognition</i> (Moussaoui <i>et al.</i> , 2024)				
6.	Identifikasi Multi-Informasi Plat Nomor Kendaraan Dengan YOLOV12 Dan <i>Optical Character Recognition</i> (OCR) di Provinsi Lampung	Karakter plat nomor kendaraan di 15 kabupaten/kota Provinsi Lampung	YOLOv12 dan OCR	pada dataset kendaraan Provinsi Lampung	Sistem mendeteksi dan mengenali huruf/angka plat, kemudian mengklasifikasikannya otomatis sesuai identitas wilayah dan masa berlaku plat nomor kendaraan.

Penelitian-penelitian dalam Tabel 1 menunjukkan penggunaan metode *Deep learning*, khususnya arsitektur YOLO (*You Only Look Once*) dan teknologi *Optical Character Recognition* (OCR), yang terbukti efektif dalam mendeteksi dan mengenali plat nomor kendaraan secara otomatis. Pada penelitian Utami (2024) mengimplementasikan *Faster R-CNN* dengan *backbone* ResNet-50 untuk klasifikasi karakter plat nomor kendaraan Indonesia, menghasilkan rata-rata *accuracy* 94,59%, *precision* 86,90%, *recall* 86,48%, dan *F1-score* 86,44%. Penelitian oleh Buleu *et al.* (2025) merancang sistem ALPR untuk plat nomor kendaraan di Romania menggunakan kombinasi YOLOv12 dan *PaddleOCR*, dengan hasil deteksi yang sangat tinggi, yakni *precision* 99,6% dan *F1-score* 97,8%. Pada penelitian Sarhan *et al.* (2024) mengembangkan sistem pengenalan plat nomor Mesir berbasis YOLOv8, *EasyOCR*, serta CNN yang mampu

mencapai akurasi hingga 99,4% bahkan pada kondisi yang bervariasi. Penelitian oleh Kothai *et al.* (2024) juga menunjukkan efektivitas pendekatan *deep learning* dengan menggunakan YOLO sebagai *one-stage detector* dan SRGAN untuk peningkatan kualitas gambar, mencapai akurasi deteksi rata-rata 98,5%, *precision* 94,52%, dan *recall* 96,35%, yang menunjukkan performa unggul dalam kondisi gambar berkualitas rendah dan kompleks. Penelitian oleh Moussaoui *et al.* (2024) mengintegrasikan YOLOv8, teknik pemrosesan citra, serta OCR untuk meningkatkan akurasi deteksi dan pengenalan, dengan *precision* 99.9%, *recall* 99.5%, dan *F1-score* 99.68% pada dataset 270 gambar. Adapun penelitian terkait plat nomor di Indonesia dilakukan dengan menggabungkan YOLOv12 dan OCR untuk identifikasi multi-informasi kendaraan di 15 kabupaten/kota Provinsi Lampung, yang tidak hanya mengenali huruf/angka pada plat, tetapi juga mengklasifikasikan karakter berdasarkan kode wilayah sesuai identitas daerah.

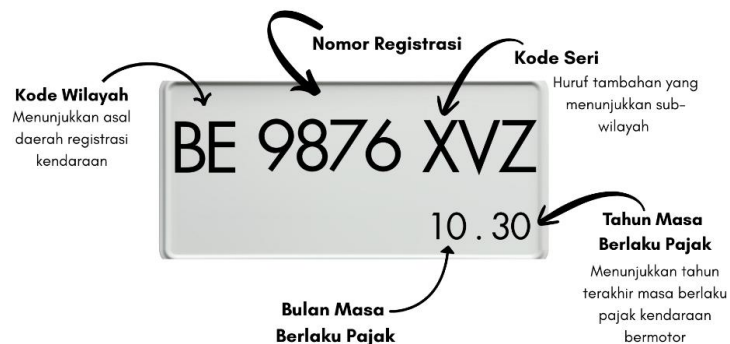
2.2 Plat Nomor Kendaraan

Plat nomor kendaraan merupakan identitas resmi yang wajib dimiliki oleh setiap kendaraan bermotor (Ramadhan *et al.*, 2021). Fungsi plat nomor tidak hanya sebagai penanda registrasi, tetapi juga sebagai media yang menghimpun beragam unsur informasi dalam satu tampilan. Pemahaman mengenai konsep multi informasi diperlukan untuk menjelaskan bagaimana satu objek visual dapat memuat beberapa keterangan administratif secara bersamaan. Konsep tersebut menggambarkan keberadaan sejumlah elemen informatif yang tersusun dalam satu struktur sehingga setiap bagian memiliki makna dan tujuan tertentu (Hanif *et al.*, 2023).

Penerapan multi informasi tampak pada plat nomor kendaraan. Kode huruf di bagian awal menunjukkan wilayah asal registrasi. Deretan angka berperan sebagai nomor identifikasi yang membedakan satu kendaraan dengan kendaraan lainnya. Seri huruf di bagian akhir mengindikasikan

urutan pendaftaran. Warna dasar plat membawa informasi tambahan yang berkaitan dengan klasifikasi penggunaan kendaraan, seperti hitam dan putih untuk kendaraan pribadi, kuning untuk kendaraan umum, dan merah untuk kendaraan pemerintah. Informasi mengenai masa berlaku registrasi ditampilkan melalui stiker atau label khusus pada bagian bawah plat sehingga petugas dapat memastikan status administratif kendaraan secara cepat. Seluruh elemen tersebut menjadikan plat nomor sebagai media yang memuat beberapa lapis informasi yang diperlukan dalam proses identifikasi dan pengawasan kendaraan (Hanif *et al.*, 2023).

Tanda Nomor Kendaraan Bermotor (TNKB) atau plat nomor merupakan bukti registrasi resmi yang diterbitkan oleh Kepolisian Negara Republik Indonesia dengan ketentuan teknis terkait bentuk, ukuran, bahan, warna, dan cara pemasangan. Penerapan TNKB bertujuan menjamin keabsahan kepemilikan kendaraan serta mendukung penegakan hukum lalu lintas (Ramadhan *et al.*, 2021).



Gambar 1. Struktur dan Komponen Plat Nomor Kendaraan Bermotor di Indonesia.

Berdasarkan Undang-Undang Nomor 22 Tahun 2009 tentang Lalu Lintas dan Angkutan Jalan, setiap kendaraan bermotor wajib memiliki TNKB yang sesuai dengan data pada STNK. Pelanggaran seperti penggunaan TNKB palsu atau tidak sesuai standar dapat dikenakan sanksi kurungan paling lama dua bulan atau denda maksimal Rp500.000,00 (Handono & Sudiro, 2025). Peraturan Kepolisian Nomor 7 Tahun 2021 mengatur

spesifikasi dan warna pelat, misalnya kendaraan pribadi berwarna dasar putih tulisan hitam dan kendaraan umum berwarna dasar kuning tulisan hitam, yang mendukung sistem *Electronic Traffic Law Enforcement (ETLE)* untuk meningkatkan keterbacaan dan pengawasan kendaraan (Kepolisian Negara Republik Indonesia, 2021).

Di Provinsi Lampung, pengelolaan dan registrasi kendaraan diperkuat melalui Peraturan Gubernur Lampung Nomor 17 Tahun 2024 tentang Keringanan Pajak Kendaraan Bermotor dan Bea Balik Nama Kendaraan Bermotor untuk meningkatkan kepatuhan administrasi dan memperbarui data kendaraan (Pemerintah Provinsi Lampung, 2024). Kebijakan opsen PKB dan BBNKB sebesar 66% dari pokok pajak mulai diterapkan pada Januari 2025 sebagai bagian dari strategi fiskal daerah (Fadliya, Sofi, Nugraha, *et al.*, 2025). Polda Lampung menerapkan Samsat Digital Drive Thru untuk mempercepat penerbitan TNKB dan STNK secara terintegrasi (Dinas Komunikasi, Informatika dan Statistik Provinsi Lampung, 2025). Penelitian Handono & Sudiro (2025) menegaskan bahwa TNKB yang sah dan sesuai standar merupakan elemen penting dalam sistem identifikasi kendaraan, terutama pada penerapan teknologi deteksi otomatis berbasis *computer vision*.

2.2.1 Format Plat Nomor Kendaraan di Indonesia

Berdasarkan Undang-Undang Nomor 22 Tahun 2009 tentang Lalu Lintas dan Angkutan Jalan serta ketentuan Kepolisian Negara Republik Indonesia, plat nomor kendaraan atau Tanda Nomor Kendaraan Bermotor (TNKB) memiliki format standar yang memuat informasi penting, yaitu (Kepolisian Negara Republik Indonesia, 2021):

1. Kode Wilayah: Huruf awal yang menunjukkan wilayah registrasi kendaraan, biasanya berdasarkan provinsi atau daerah tertentu (contoh: BE untuk Lampung).

2. Nomor Registrasi: Kombinasi angka yang diberikan secara unik kepada setiap kendaraan.
3. Kode Seri: Huruf tambahan di akhir nomor registrasi yang menunjukkan sub-wilayah atau jenis kendaraan.
4. Masa Berlaku: Dicantumkan pada bagian bawah plat sebagai penanda berakhirnya masa berlaku registrasi dan pajak kendaraan.

Format ini wajib dipatuhi dan TNKB harus memenuhi standar bentuk, ukuran, bahan, warna, dan cara pemasangan sebagaimana diatur dalam Pasal 68 UU LLAJ (Kepolisian Negara Republik Indonesia, 2021).

2.2.2 Kode Wilayah Provinsi Lampung

Provinsi Lampung memiliki kode plat “BE” yang merupakan identitas resmi untuk kendaraan bermotor yang terdaftar di wilayah tersebut. Setiap kendaraan dengan plat BE dapat dikenali asalnya hingga tingkat kabupaten/kota melalui kombinasi huruf seri belakang pada TNKB (Kepolisian Daerah Lampung, 2019).

Berikut rincian kode seri belakang plat BE yang menunjukkan asal kabupaten/kota di Provinsi Lampung (KAPOLDA LAMPUNG, 2019):

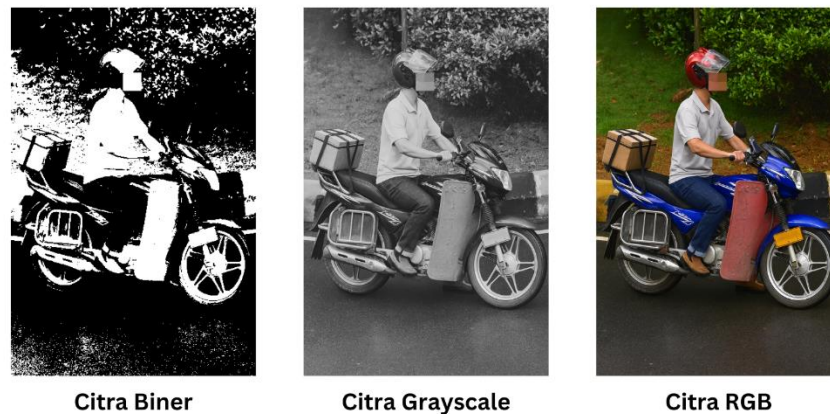
Tabel 2 Kode Seri Belakang Plat.

Kabupaten/Kota	Kode Seri Belakang
Kota Bandar Lampung	A, B, C
Kabupaten Lampung Selatan	D, E, O
Kota Metro	F
Kabupaten Lampung Tengah	G, H, I
Kabupaten Lampung Utara	J, K
Kabupaten Lampung Barat	M

Kabupaten/Kota	Kode Seri Belakang
Kabupaten Lampung Timur	N, P
Kabupaten Tulang Bawang	S, T
Kabupaten Tanggamus	V, Z
Kabupaten Way Kanan	W
Kabupaten Pesawaran	R
Kabupaten Pringsewu	U
Kabupaten Mesuji	L
Kabupaten Tulang Bawang Barat	Q
Kabupaten Pesisir Barat	X

2.3 Pengolahan Citra Digital

Pengolahan citra digital merupakan bidang kajian dalam ilmu komputer yang berfokus pada teknik pemrosesan gambar menggunakan bantuan algoritma matematis dan perangkat digital. Citra digital sendiri dapat dipandang sebagai representasi visual dua dimensi yang tersusun atas elemen terkecil yang disebut piksel. Setiap piksel memuat informasi berupa intensitas atau warna, sehingga susunan keseluruhan piksel membentuk suatu citra yang dapat dianalisis lebih lanjut (Malik & Kavita, 2020). Melalui pengolahan citra digital, kualitas citra dapat ditingkatkan, informasi penting di dalamnya dapat diekstraksi, serta citra dapat diubah menjadi bentuk lain yang sesuai dengan kebutuhan analisis tertentu, misalnya pada sistem deteksi objek atau pengenalan pola (Deshmukh & Tantarapale, 2020).



Gambar 2. Pengolahan citra digital pada plat nomor kendaraan (Jia *et al.*, 2021).

Citra digital dapat diklasifikasikan menjadi tiga kategori berdasarkan sifat nilai pikselnya (Fauziah *et al.*, 2023).

1. Citra Biner: Memiliki dua nilai intensitas, hitam (0) dan putih (1), yang berfungsi memisahkan objek dari latar belakang dan digunakan pada pengolahan dokumen, deteksi tepi, serta pengenalan simbol atau teks.
2. Citra *Grayscale*: Memiliki rentang nilai intensitas 0–255 yang merepresentasikan gradasi keabuan dari hitam hingga putih. Setiap piksel menunjukkan tingkat kecerahan tertentu, sehingga citra ini mampu menampilkan detail dan tekstur halus, serta sering digunakan dalam analisis medis, fotografi digital, dan pra-pemrosesan citra.
3. Citra Berwarna (RGB): Menggunakan model warna RGB dengan tiga kanal utama: merah, hijau, dan biru. Kombinasi intensitas ketiganya menghasilkan variasi warna yang kaya dan realistis, sehingga banyak digunakan dalam fotografi digital, video, visualisasi grafis, dan aplikasi multimedia.

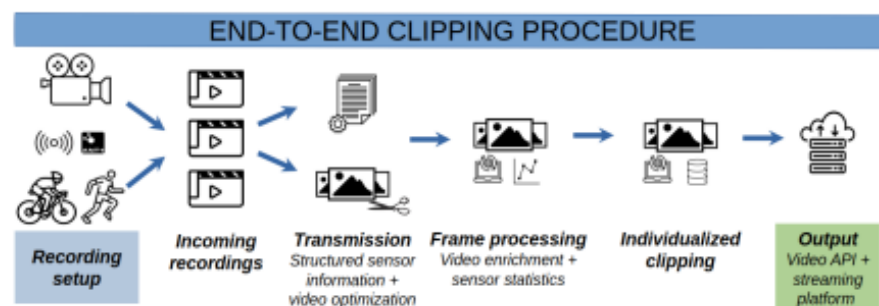
Pemilihan format berkas video menjadi salah satu faktor yang dapat memengaruhi kualitas citra yang dihasilkan ketika *frame* diambil dari video. Setiap format video menggunakan metode kompresi atau *codec* yang berbeda untuk menyimpan data visual. Format MOV yang banyak

digunakan pada perangkat *Apple* biasanya menyimpan data visual dengan *codec* berkualitas tinggi seperti *ProRes*. Format MP4 yang lebih umum digunakan pada berbagai perangkat umumnya menggunakan *codec* H.264 yang bersifat *lossy*. Perbedaan karakteristik *codec* tersebut dapat menyebabkan penurunan kualitas citra ketika terjadi proses konversi format (term7, 2021)

2.4 Pengolahan Video Digital

Pengolahan video digital merupakan cabang ilmu komputer yang berfokus pada pemrosesan dan analisis data visual bergerak yang tersusun dari rangkaian *frame* citra digital. Video memiliki dimensi waktu yang menghubungkan setiap *frame* sehingga informasi yang diperoleh mencakup aspek spasial dan temporal. Kompleksitas pengolahan muncul karena sistem harus menjaga konsistensi antar-*frame* serta memperhatikan dinamika gerakan objek dalam rentang waktu tertentu (Rota *et al.*, 2023).

Teknologi ini banyak dimanfaatkan dalam bidang keamanan, pemantauan lalu lintas, hiburan, dan kesehatan. Pertumbuhan jumlah kamera digital serta kebutuhan analisis *real-time* mendorong pengembangan sistem yang cepat, efisien, dan akurat. Pendekatan modern tidak hanya berfokus pada peningkatan kualitas visual, tetapi juga pada kemampuan mengekstraksi informasi penting untuk mendukung pengambilan keputusan (Xu *et al.*, 2023).



Gambar 3. Representasi Pengolahan Video Digital (Decorte *et al.*, 2024).

Proses pengolahan video digital umumnya mengikuti *pipeline end-to-end* yang meliputi tahap *recording setup* untuk pengambilan video, pengelolaan data mentah pada *incoming recordings*, optimasi pengiriman melalui *transmission*, serta ekstraksi fitur *spasial-temporal* pada *frame processing*. Hasil analisis kemudian disusun pada *individualized clipping* dan diintegrasikan melalui tahap *output* untuk mendukung sistem analitik (Abba *et al.*, 2024).

Kualitas visual yang buruk, seperti variasi pencahayaan dan perubahan tampilan objek, dapat menyebabkan hilangnya informasi visual penting sehingga menurunkan akurasi dalam deteksi dan pelacakan objek. Proses segmentasi dan pelacakan dimulai dengan deteksi objek menggunakan *bounding box* sebagai representasi posisi objek, yang menjadi langkah penting dalam mendukung sistem pelacakan *real-time* yang mampu mengelola banyak target secara cepat dan akurat dalam lingkungan dinamis, sehingga mendukung analisis data dalam skala besar (Guan *et al.*, 2025). Pemodelan visual dan temporal dilakukan melalui representasi pola video menggunakan fitur seperti *motion vector*, *optical flow*, dan representasi volumetrik untuk menangkap korelasi antar-*frame* (Zhou *et al.*, 2023). Teknologi *deep learning* seperti 3D-CNN dan RNN digunakan untuk mempelajari pola spasial-temporal secara adaptif dalam mendukung deteksi aktivitas, anomali, dan identifikasi objek pada video dinamis (Rota *et al.*, 2023; Xu *et al.*, 2023).

Pemilihan format berkas dan *codec* memengaruhi kualitas visual dalam pengolahan video digital. Format video berfungsi sebagai wadah yang menyimpan data video, audio, dan metadata, sedangkan *codec* digunakan untuk melakukan kompresi dan dekompresi agar ukuran berkas sesuai dengan kebutuhan penyimpanan dan distribusi. Format MOV banyak digunakan pada perangkat *Apple* dan sering dipakai dalam produksi video berkualitas tinggi karena umumnya menggunakan *codec Apple ProRes* yang mampu mempertahankan detail visual. Format MP4 lebih umum digunakan pada berbagai perangkat dan mengikuti standar MPEG-4

sebagai struktur penyimpanan media digital (ISO/IEC, 2020). *Codec* yang sering digunakan pada format MP4 adalah H.264 yang bersifat *lossy*, sehingga ukuran berkas dapat diperkecil meskipun sebagian informasi visual berkurang (Term7, 2021).

Konversi dari MOV ke MP4 dapat memengaruhi kualitas visual apabila terjadi perubahan *codec*, misalnya dari *ProRes* ke H.264. Kompresi pada H.264 mengurangi sebagian informasi visual untuk menghasilkan ukuran berkas yang lebih kecil. Kualitas citra yang menurun akibat proses kompresi *lossy* dapat menghambat kemampuan model deep learning dalam mendeteksi objek secara akurat, karena model bergantung pada kelengkapan informasi visual yang tersimpan dalam setiap *frame* (Gandor & Nalepa, 2022).

2.5 Cropping Citra

Cropping citra merupakan salah satu operasi fundamental dalam bidang *digital image processing* yang bertujuan memotong atau mengekstrak bagian tertentu dari sebuah citra. *Cropping* secara teknis didefinisikan sebagai pemilihan dan ekstraksi *region of interest (ROI)* dari citra asli dengan menetapkan koordinat batas area yang diinginkan, sehingga menghasilkan citra baru dengan dimensi lebih kecil namun tetap mempertahankan informasi penting yang terkandung di dalamnya (Nguyen *et al.*, 2022).

Tujuan utama *Cropping* adalah meningkatkan fokus pada objek atau area yang menjadi perhatian utama dalam analisis citra dengan mengeliminasi informasi yang tidak relevan atau mengganggu. *Cropping* berkontribusi pada pengurangan kompleksitas komputasi karena ukuran data yang diproses menjadi lebih kecil, efisiensi penggunaan memori meningkat, dan waktu pemrosesan algoritma berikutnya menjadi lebih cepat (Srivastava *et al.*, 2021). Dalam konteks *preprocessing*, *Cropping* memiliki peran penting pada berbagai aplikasi seperti *object recognition*, deteksi wajah,

analisis medis, dan sistem pengenalan pola (Valente *et al.*, 2023). Pemisahan objek target dari latar belakang atau *noise* terbukti krusial untuk meningkatkan akurasi model *machine learning* (Patsanis *et al.*, 2025).



Gambar 4. Representasi *Cropping* Citra.


2.6 Citra *Resize*

Citra digital merupakan representasi visual dalam bentuk piksel dengan resolusi tertentu. Proses perubahan ukuran citra (*image resizing*) menjadi tahapan penting dalam banyak aplikasi pengolahan citra, untuk menyesuaikan dimensi terhadap kebutuhan sistem, baik untuk efisiensi komputasi maupun standarisasi input. Teknik *resizing* memiliki peran krusial dalam meningkatkan performa sistem berbasis visi komputer, khususnya dalam konteks *deep learning*, karena kualitas dan metode *resizing* yang digunakan dapat memengaruhi akurasi dan kemampuan model dalam melakukan generalisasi (Talebi *et al.*, 2021).

Resize citra diperlukan dalam berbagai bidang seperti visi komputer dan deteksi objek. Ukuran gambar yang terlalu besar dapat memperlambat pelatihan model *deep learning*, sedangkan ukuran terlalu kecil bisa mengurangi performa model dalam hal akurasi, presisi, dan *recall*. Keseimbangan antara efisiensi komputasi dan kualitas citra menjadi aspek penting yang perlu diperhatikan (Saponara & Elhanashi, 2022).

Proses *resizing* juga berhubungan erat dengan aspek normalisasi data. Pada sistem pembelajaran mesin dan *deep learning*, citra seringkali harus disesuaikan ke ukuran standar agar dapat diproses secara konsisten oleh

model. Normalisasi ini membantu menjaga homogenitas data masukan sehingga meningkatkan stabilitas dan akurasi sistem (Huang *et al.*, 2020).



Gambar 5. Representasi Citra *Resize*.

2.7 Deteksi Objek

Deteksi objek merupakan bidang penting dalam *computer vision* yang bertujuan mengidentifikasi dan melokalisasi objek pada gambar atau video. Deteksi objek tidak hanya mengklasifikasi objek, tetapi juga memberikan koordinat *bounding box* sebagai lokasi spasialnya. Perkembangan *deep learning*, khususnya *Convolutional Neural Networks* (CNN), memungkinkan ekstraksi fitur kompleks secara otomatis dari data visual (Cao *et al.*, 2025).

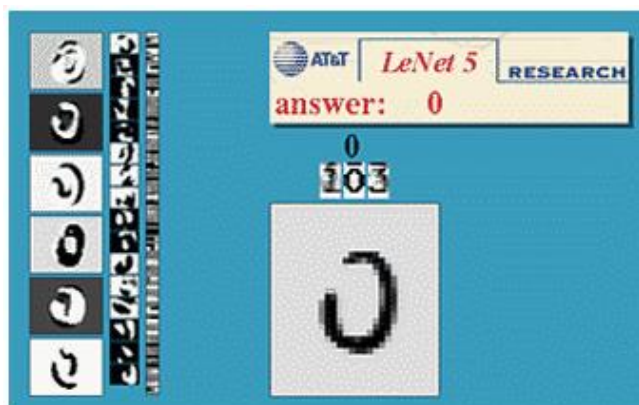
Sistem deteksi objek terdiri atas dua komponen utama, yaitu *feature extraction* untuk mengekstraksi fitur informatif dan *classification* untuk menentukan kelas serta lokasi objek. Integrasi keduanya melalui arsitektur *end-to-end* membuat model dapat belajar langsung dari data mentah. Pendekatan ini menjadi dasar bagi arsitektur modern seperti YOLO, SSD, dan DETR yang menyeimbangkan akurasi dan kecepatan (Cao *et al.*, 2025). Model berbasis CNN seperti YOLOv8 dan YOLOv10 mengusung arsitektur satu tahap dengan *decoupled head* dan *adaptive label assignment*, sedangkan model berbasis *transformer* seperti DETR menyederhanakan proses dengan menghilangkan *anchor box* dan NMS.

Inovasi terbaru seperti RT-DETR menawarkan deteksi *real-time* yang lebih efisien dan akurat (Kotthapalli *et al.*, 2025).

2.8 Computer Vision

Computer vision merupakan bidang interdisipliner yang berfokus pada pengembangan metode matematis untuk merekonstruksi struktur tiga dimensi dan penampilan objek dari citra digital. Meski manusia mudah memahami bentuk tiga dimensi, membuat komputer melakukan hal serupa merupakan tantangan karena sifatnya sebagai *inverse problem* usaha memperoleh informasi tak diketahui dari data terbatas (Szeliski, 2021).

Berbagai penerapan *computer vision* dapat ditemukan dalam kehidupan nyata. Misalnya, *Optical Character Recognition* (OCR) digunakan untuk membaca kode pos tulisan tangan, *machine inspection* dalam kontrol kualitas industri, pengenalan objek di jalur *checkout* otomatis, logistik gudang, registrasi citra medis, serta kendaraan tanpa pengemudi (Szeliski, 2021).




Gambar 6. Penerapan *computer vision* pada OCR untuk mendeteksi dan mengekstrak teks otomatis (Szeliski, 2021).

Kemajuan *computer vision* modern banyak dipengaruhi oleh perkembangan *deep learning* dan *neural networks*. Arsitektur *Convolutional Neural networks* (CNN) merevolusi tugas seperti klasifikasi

citra, deteksi objek, dan segmentasi semantik. Varian *Region-based CNN* (R-CNN) unggul dalam deteksi objek (Cao *et al.*, 2025). Mask R-CNN memungkinkan pemisahan setiap objek secara detail pada scene yang kompleks (El Akrouchi *et al.*, 2025).

2.9 Artificial Intelligence

Artificial Intelligence (AI) adalah bidang ilmu komputer yang berfokus pada pengembangan sistem dan algoritma yang memungkinkan mesin untuk meniru kemampuan kognitif manusia, seperti pembelajaran, penalaran, persepsi, dan pengambilan keputusan (Stuart Russell & Peter Norvig, 2020). AI telah mengalami perkembangan pesat dalam dekade terakhir, terutama dengan kemajuan dalam bidang *machine learning* dan *deep learning* yang memungkinkan komputer menganalisis data berskala besar dengan akurasi tinggi. Model *deep learning* seperti *Convolutional Neural networks* (CNN) telah merevolusi berbagai aplikasi pengenalan citra, deteksi objek, dan analisis data visual (Liu *et al.*, 2024).



Gambar 7. AI, ML, and DL Relationship.

Teknologi pengenalan dalam AI memungkinkan mesin mengenali pola dan menganalisis informasi dari berbagai sumber data, menjadi dasar bagi aplikasi yang memproses gambar, video, dan input lain secara efektif (Jin *et al.* 2022). Kemajuan AI modern didorong oleh tiga faktor utama yaitu ketersediaan *big data*, peningkatan daya komputasi, dan pengembangan

algoritma *machine learning* yang memungkinkan performa setara atau melampaui manusia dalam berbagai domain (Liu *et al.*, 2024).

2.10 *Machine Learning*

Machine Learning (ML) merupakan cabang dari *Artificial Intelligence* (AI) yang memungkinkan sistem komputer belajar dan mengambil keputusan berdasarkan data tanpa perlu diprogram secara eksplisit. Dalam bidang *computer vision* dan pengolahan citra, ML berperan penting dalam meningkatkan kemampuan sistem mengenali serta memahami gambar (T. M. Almuqati *et al.*, 2024). Perkembangan *deep learning* telah berkontribusi besar terhadap peningkatan performa dalam deteksi dan pengenalan objek. ML dapat dikategorikan menjadi tiga paradigma utama, yaitu *Supervised Learning*, *Unsupervised Learning*, dan *Reinforcement Learning*, yang masing-masing memiliki karakteristik, keunggulan, serta tantangan berbeda dalam implementasinya (Gupta *et al.*, 2025). Penjelasan mengenai ketiga paradigma tersebut disajikan sebagai berikut:

1. *Supervised Learning*

Supervised Learning adalah paradigma *machine learning* yang memanfaatkan dataset berlabel untuk melatih model agar mampu memprediksi output pada data baru (T. M. Almuqati *et al.*, 2024). Model mempelajari hubungan antara input dan output dengan cara meminimalkan selisih antara hasil prediksi dan nilai aktual. Pendekatan ini umum digunakan pada tugas klasifikasi maupun regresi dalam *computer vision*, seperti deteksi dan pengenalan objek (Gupta *et al.*, 2025). Keunggulannya terletak pada akurasi tinggi jika data latih berkualitas, sedangkan kelemahannya mencakup kebutuhan dataset besar, risiko *overfitting*, dan keterbatasan generalisasi pada data baru (T. M. Almuqati *et al.*, 2024; Gupta *et al.*, 2025).

2. *Unsupervised Learning*

Unsupervised Learning adalah paradigma *machine learning* yang mempelajari pola tersembunyi dari data tanpa label atau target output (T. M. Almuqati *et al.*, 2024). Algoritma belajar tanpa acuan benar atau salah, dengan tujuan mengelompokkan data berdasarkan kesamaan atau mengekstraksi fitur yang lebih ringkas. Metode umum yang digunakan meliputi *clustering*, *association rules*, dan *dimensionality reduction*. Dalam bidang *computer vision*, paradigma ini digunakan untuk *feature extraction*, *image segmentation*, dan *anomaly detection*. Tantangan yang dihadapi mencakup kesulitan evaluasi hasil, interpretasi yang bersifat subjektif, serta pemilihan parameter yang tepat (Gupta *et al.*, 2025).

3. *Reinforcement Learning*


Reinforcement Learning adalah paradigma *machine learning* di mana agen belajar membuat keputusan melalui interaksi dengan lingkungan untuk memaksimalkan reward kumulatif. Proses pembelajaran dilakukan menggunakan mekanisme *trial and error* dengan umpan balik berupa *reward* atau *punishment* (Li, 2024). Komponen utama *Reinforcement Learning* meliputi *agent*, *environment*, *actions*, *states*, dan *rewards*, yang bersama-sama menghasilkan *policy* optimal (Gupta *et al.*, 2025). Penerapan *Reinforcement Learning* dalam *computer vision* mencakup *object tracking*, *image captioning*, dan *visual navigation*. Tantangan utama pada *Reinforcement Learning* mencakup perancangan *reward function* yang tepat, kebutuhan komputasi tinggi, serta waktu konvergensi yang lama untuk permasalahan kompleks (Li, 2024).

2.11 *Deep Learning*

Deep learning merupakan subbidang *machine learning* yang terinspirasi dari cara kerja otak manusia dalam memproses informasi melalui jaringan saraf artifisial berlapis. *Deep learning* kini dianggap sebagai standar emas dalam komunitas *machine learning* karena mampu menghasilkan performa tinggi pada berbagai tugas kompleks, seperti *computer vision*, natural language processing, serta pengenalan suara dan video (Alzubaidi *et al.*, 2021). Arsitektur *deep neural networks* terdiri atas banyak *hidden layer* yang mempelajari fitur data secara bertahap dengan pelatihan menggunakan algoritma *backpropagation* untuk menyesuaikan bobot berdasarkan kesalahan prediksi (Mienye & Swart, 2024). Keunggulan utama *deep learning* adalah kemampuannya mengekstraksi fitur penting dari data mentah secara otomatis tanpa membutuhkan *feature engineering* manual yang intensif, berbeda dengan pendekatan *machine learning* tradisional (Archana & Jeevaraj, 2024).

2.12 *Convolutional Neural Network*

Convolutional Neural Network (CNN) merupakan jenis jaringan saraf tiruan yang dirancang untuk mengolah data berbentuk grid seperti citra digital. Model ini menjadi komponen utama dalam *computer vision* karena mampu mengekstraksi dan memahami pola visual secara otomatis (Indolia *et al.*, 2018). Jaringan saraf konvensional menghubungkan setiap neuron ke seluruh neuron pada lapisan berikutnya, sedangkan CNN menggunakan koneksi terbatas hanya pada area tertentu dari lapisan sebelumnya. Area koneksi yang dikenal sebagai *receptive field* berperan penting dalam menjaga konteks spasial citra agar tetap utuh selama proses pengolahan (Li *et al.*, 2024).




Gambar 8. Arsitektur CNN (Auni & Sugiharti, 2025).

Arsitektur CNN terdiri atas beberapa komponen utama yang berfungsi dalam pembelajaran fitur visual. *Convolutional layer* mengekstraksi fitur, *pooling layer* mengurangi dimensi data, dan *fully connected layer* berperan pada tahap pengambilan keputusan. CNN mempelajari pola sederhana pada lapisan awal serta pola kompleks pada lapisan lebih dalam. Dua karakteristik penting yang dimiliki meliputi *weight sharing* dan *local connectivity*. *Weight sharing* menunjukkan penggunaan bobot seragam dalam satu lapisan, sedangkan *local connectivity* berarti setiap neuron hanya menerima masukan dari area lokal tertentu untuk menghasilkan keluaran spesifik pada citra (Indolia *et al.*, 2018).

2.12.1 Convolutional Layer


Convolutional layer merupakan komponen utama dalam arsitektur CNN yang berfungsi mengekstraksi pola dan fitur penting dari citra menggunakan *filter* kecil, seperti 3x3 atau 5x5 piksel, yang digeser untuk menghasilkan *feature map* berisi representasi tepi, tekstur, atau bentuk objek (X. Zhao *et al.*, 2024) Bobot pada *kernel* diperbarui selama proses pelatihan agar mampu mengenali fitur yang relevan secara otomatis. Fungsi aktivasi seperti *Rectified Linear Unit* (ReLU) diterapkan untuk menambahkan non-linearitas dan mencegah *vanishing gradient*, sehingga proses pembelajaran menjadi lebih stabil (Krichen, 2023).



Gambar 9. Convolutional Layer (Purwono et al., 2022).

2.12.2 Pooling Layer

Pooling layer merupakan komponen penting dalam arsitektur CNN yang berfungsi mengurangi dimensi spasial *feature* map serta menekan jumlah parameter dan kompleksitas komputasi. Proses *down-sampling* dilakukan dengan *max pooling* atau *average pooling* untuk mempertahankan informasi utama dan menghapus detail kurang relevan (Saha & Gokhale, 2024). Jenis *pooling* yang paling umum digunakan adalah *max pooling*, karena mampu mempertahankan fitur dominan seperti tepi dan tekstur. Lapisan *pooling* meningkatkan *local translation invariance* sehingga jaringan tetap mengenali fitur meski terjadi pergeseran posisi objek pada citra (L. Zhao & Zhang, 2024).

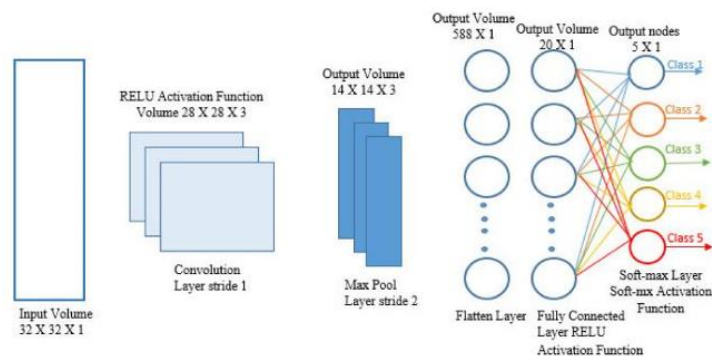


Gambar 10. Pooling Layer (Purwono et al., 2022).

2.12.3 Fully Connected Layer

Fully Connected (FC) layer merupakan bagian akhir dari arsitektur CNN yang berfungsi sebagai pengklasifikasi utama. Setiap neuron terhubung dengan seluruh neuron di lapisan sebelumnya,

membentuk jaringan yang padat (Alzubaidi *et al.*, 2021). Hasil dari lapisan konvolusi atau *pooling* diratakan melalui proses *flattening* sebelum diklasifikasikan. Fungsi aktivasi seperti *ReLU* menambah non-linearitas agar model mengenali pola kompleks, sedangkan *Dropout* mengurangi *overfitting* dan meningkatkan kestabilan pembelajaran (Salehin & Kang, 2023).



Gambar 11. *Fully Connected Layer* (Purwono *et al.*, 2022)

2.13 *You Only Look Once* (YOLO)

You Only Look Once (YOLO) adalah algoritma deteksi objek *single-stage* yang memproses seluruh citra dalam satu kali *forward pass* jaringan saraf konvolusional, sehingga prediksi *bounding box* dan kelas objek dapat dilakukan secara bersamaan dengan latensi rendah (Redmon *et al.*, 2016). Algoritma ini pertama kali diperkenalkan oleh Redmon *et al.*, pada 2015. YOLO terus berkembang hingga versi YOLOv12 yang dirilis Ultralytics pada 2025, dengan peningkatan akurasi, deteksi objek kecil, dan efisiensi pemrosesan (Tian *et al.*, 2025; Ultralytics Team, 2025).



Gambar 12. Representasi Visual Proses Deteksi Objek dengan YOLO.

Gambar 12 memperlihatkan bahwa YOLOv8 berhasil mendeteksi plat nomor kendaraan Indonesia dengan memprediksi posisi *bounding box* secara tepat. Hasil deteksi kemudian diproses menggunakan *EasyOCR* untuk mengekstraksi informasi teks. Metode ini memperoleh akurasi deteksi sebesar 100%, sedangkan akurasi pengenalan karakter plat mencapai sekitar 74,66% (Salsabila & Sriani, 2024).

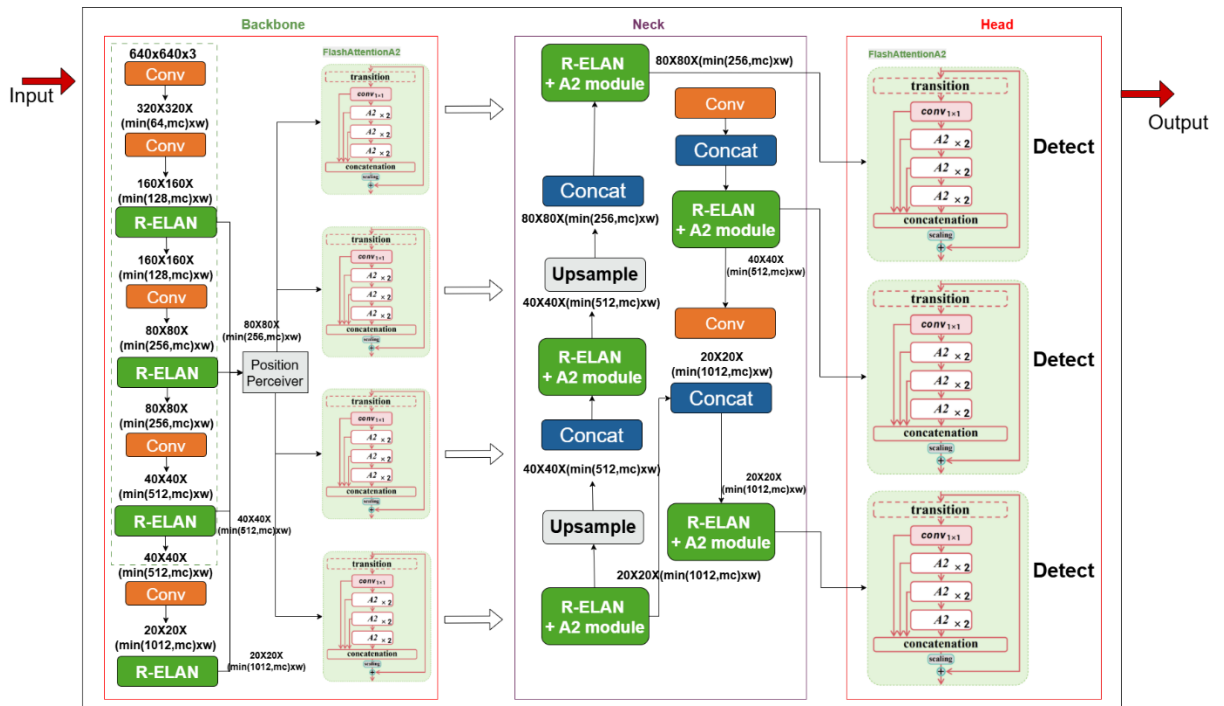
2.14 *You Only Look Once Version 12 (YOLOv12)*

YOLOv12 merupakan versi terbaru yang dikembangkan *Ultralytics* pada 2025 (Ultralytics Team, 2025). Algoritma ini mempertahankan konsep dasar pendahulunya dengan peningkatan arsitektur untuk mengatasi tantangan seperti deteksi objek kecil, tumpang tindih, dan variasi pencahayaan (Tian *et al.*, 2025). YOLOv12 memperkenalkan sejumlah inovasi untuk menyeimbangkan aspek kecepatan dan akurasi. Inovasi tersebut meliputi penggunaan *Residual Efficient Layer Aggregation Network (R-ELAN)* yang meningkatkan proses agregasi fitur serta mengatasi kendala optimasi pada model attention berskala besar, serta penerapan *Area Attention* yang dipadukan dengan *FlashAttention* guna

memperluas cakupan *receptive field* secara efisien tanpa mengurangi kinerja inferensi *real-time* (Tian *et al.*, 2025; Ultralytics Team, 2025).

R-ELAN dikembangkan dari arsitektur ELAN sebagai modul agregasi fitur yang lebih efisien. Modul ini berfungsi memperbaiki aliran optimasi pada model *attention* berukuran besar dengan memanfaatkan koneksi residual dan pola agregasi fitur mirip *bottleneck* (Ultralytics Team, 2025). *Separable convolutions* menjaga hubungan spasial sambil menekan jumlah parameter, membuat model tetap ringan dengan akurasi tinggi (Alif & Hussain, 2025). *Area attention* dengan *FlashAttention* memfokuskan perhatian pada wilayah penting citra serta mempercepat proses komputasi (Tian *et al.*, 2025). Secara garis besar, arsitektur YOLOv12 terdiri dari tiga komponen utama yaitu (Ultralytics Team, 2025; Alif & Hussain, 2025):

1. *Backbone*, mengekstraksi fitur multi-skala menggunakan R-ELAN dan konvolusi separabel.
2. *Neck*, menggabungkan fitur dari berbagai tingkat resolusi dengan dukungan *area attention* untuk mempertahankan konteks global.
3. *Head*, menghasilkan prediksi koordinat *bounding box*, *confidence score*, dan probabilitas kelas objek.



Gambar 13. Arsitektur YOLOv12 (dimodifikasi dari Sapkota *et al.*, 2025).

Gambar 13 menampilkan rancangan arsitektur YOLOv12 secara menyeluruh. Bagian *Backbone* menggunakan konfigurasi *R-ELAN* untuk mengekstraksi fitur awal dari citra masukan. *Neck* melakukan *upsampling* dan *concatenation* antar peta fitur guna menggabungkan informasi multi-skala agar mampu mendeteksi objek dengan berbagai ukuran. *Head* menerapkan deteksi berbasis *FlashAttention* yang meningkatkan efisiensi komputasi sekaligus menjaga akurasi (Tian *et al.*, 2025).

Tahap prediksi pada YOLOv12 menggunakan fungsi *loss* gabungan yang mempertimbangkan kesalahan koordinat, kesalahan klasifikasi, dan kesalahan *confidence*. Proses prediksi menggunakan *loss function* gabungan yang mencakup kesalahan koordinat, klasifikasi, dan *confidence* dengan penerapan *Complete IOU (CIOU) Loss* serta *binary cross-entropy* (Tian *et al.*, 2025; Wang *et al.*, 2022). Rumus *confidence score* dalam YOLO diformulasikan sebagai (Sun *et al.*, 2024):

$$C = P(\text{object}) \times IoU_{pred}^{truth} \quad (1)$$

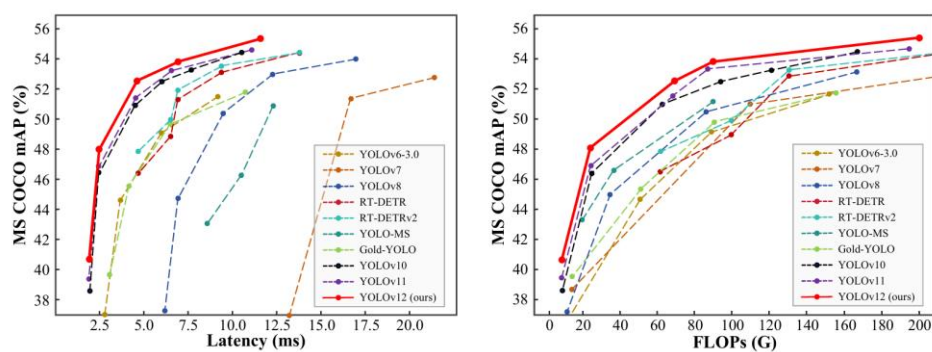
Model memperkirakan keberadaan objek pada suatu lokasi melalui $P(\text{object})$ yang dikalikan dengan tingkat tumpang tindih antara *bounding box* prediksi dan *ground truth* menggunakan *Intersection over Union* (IOU). Kombinasi ini menghasilkan *confidence score* tinggi ketika model mampu mendeteksi dan memprediksi posisi objek secara akurat dalam citra (Sun *et al.*, 2024).

Nilai *Intersection over Union* (IoU) dihitung untuk menilai kesesuaian antara prediksi dan area sebenarnya pada plat nomor. Nilai IOU menjadi tolok ukur kuantitatif untuk menilai ketepatan posisi *bounding box* model. Proporsi area tumpang tindih dibanding luas gabungannya menentukan nilai IOU; prediksi presisi menghasilkan nilai mendekati 1, sedangkan kesalahan posisi menurunkannya. Penerapan konsep ini menjaga akurasi tinggi sistem YOLO dalam mengenali keberadaan serta posisi objek (Cai *et al.*, 2023). Rumus IOU dinyatakan sebagai (Cai *et al.*, 2023; Rezatofighi *et al.*, 2019):

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (2)$$

Area overlap menunjukkan luas irisan antara *bounding box* prediksi dan *ground truth*, sedangkan *area union* menggambarkan luas gabungan keduanya (Rezatofighi *et al.*, 2019).

Pengujian pada dataset COCO menunjukkan bahwa YOLOv12 mengalami peningkatan signifikan dibandingkan dengan YOLOv11. Varian YOLOv12-N (nano) mampu mencapai mean *Average Precision* (mAP50–95) sebesar 40,6% dengan latensi inferensi hanya 1,64 ms pada GPU NVIDIA T4. Varian YOLOv12-M (medium) memberikan peningkatan akurasi hingga beberapa persen dibanding pendahulunya, meskipun memiliki jumlah parameter yang lebih sedikit, sehingga meningkatkan efisiensi sumber daya secara keseluruhan (Tian *et al.*, 2025).



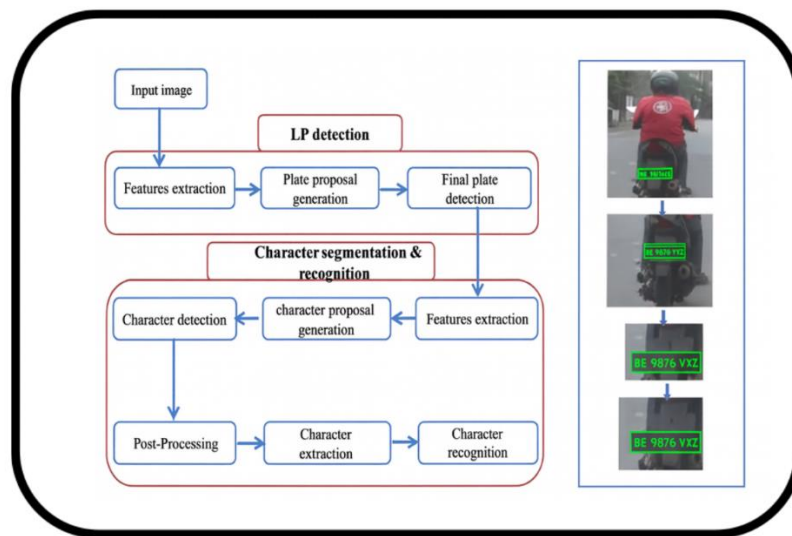
Gambar 14. Perbandingan YOLOv12 dengan metode populer lain pada dataset COCO (Tian *et al.*, 2025).

Kombinasi akurasi tinggi, latensi rendah, dan efisiensi komputasi menjadikan YOLOv12 ideal untuk sistem identifikasi plat nomor kendaraan. Sebagai detektor *real-time* berbasis perhatian, YOLOv12 mampu mendeteksi objek secara cepat dan akurat dalam berbagai kondisi (Tian *et al.*, 2025). Ekstraksi teks dilakukan menggunakan *EasyOCR*, pustaka *open-source* berbasis *deep learning* yang mendukung pengenalan karakter multibahasa termasuk Indonesia, dengan akurasi sekitar 81% (Anthony, Herman, & Andik Yulianto, 2024). Pendekatan ini memungkinkan ekstraksi nomor registrasi, kode wilayah, dan masa berlaku pajak secara efisien. YOLOv12 adaptif terhadap variasi ukuran objek, pencahayaan, sudut, dan plat sebagian tertutup, menghasilkan deteksi yang akurat dan konsisten (Tian *et al.*, 2025).

2.15 Optical Character Recognition (OCR)

Optical Character Recognition (OCR) adalah teknologi dalam pengolahan citra dan *computer vision* yang mengubah gambar berisi teks menjadi karakter digital yang dapat diproses komputer. Proses OCR mencakup deteksi plat menggunakan model seperti YOLOv8 atau YOLOv12 untuk menghasilkan *bounding box*, pemotongan citra untuk mengekstraksi area karakter, dan pengenalan karakter menggunakan engine seperti *EasyOCR*, *PaddleOCR*, atau *Tesseract*. Pengenalan karakter melibatkan *filtering*,

thresholding, deteksi teks dengan CRAFT, ekstraksi fitur menggunakan ResNet, dan pengenalan melalui LSTM (Buleu *et al.*, 2025; Sarhan *et al.*, 2024).



Gambar 15. Tahapan umum proses Optical Character Recognition pada sistem LPR (dimodifikasi dari Selmi *et al.*, 2019).

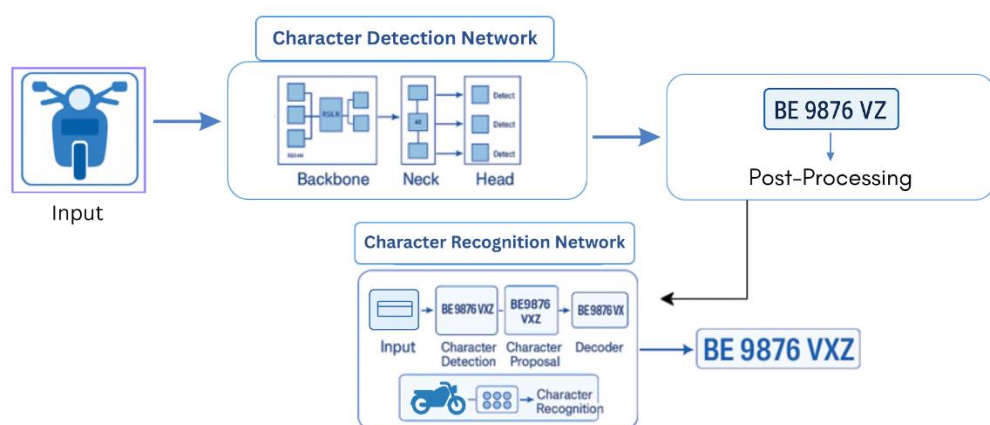
Proses identifikasi plat nomor dilakukan setelah area plat terdeteksi. Citra plat yang telah dipotong diproses untuk mengenali karakter alfanumerik pada TNKB, termasuk kode wilayah, nomor registrasi, dan masa berlaku pajak (Salimah *et al.*, 2021). Gambar 15 menunjukkan tahapan sistem *License Plate Recognition* (LPR) yang dimulai dari *input image*, deteksi plat melalui ekstraksi fitur dan *plate proposal generation*, segmentasi karakter, hingga *Post-Processing* untuk menghasilkan teks digital (Selmi *et al.*, 2019).

Algoritma OCR mencakup metode *template matching* hingga teknik berbasis *machine learning* dan *deep learning*. Beberapa *engine* OCR yang umum digunakan dalam sistem LPR memiliki karakteristik dan keunggulan berbeda. *Tesseract* OCR merupakan *engine* bersifat *open-source* yang dikembangkan oleh Google, dikenal memiliki akurasi tinggi terhadap berbagai jenis font serta mendukung lebih dari 100 bahasa. Versi 4.0 dan 5.0 dari *Tesseract* telah mengintegrasikan *Long Short-Term*

Memory (LSTM) guna meningkatkan akurasi pengenalan karakter (Awan Aprilino & Imam Husni Al Amin, 2022).

EasyOCR berbasis *deep learning* yang mendukung lebih dari 80 bahasa dan memiliki tingkat akurasi tinggi pada berbagai kondisi pencahayaan. *EasyOCR* menggunakan arsitektur CRAFT (*Character Region Awareness for Text detection*) untuk deteksi teks dan CRNN (*Convolutional Recurrent Neural Network*) dengan komponen utama berupa ekstraksi fitur menggunakan ResNet, *sequence labeling* dengan LSTM, dan decoding berbasis CTC (*Connectionist Temporal Classification*) untuk pengenalan karakter (Sainui, Thepporn, *et al.*, 2024).

PaddleOCR dikembangkan oleh Baidu dan menawarkan performa tinggi dengan kecepatan *inference* yang cepat, untuk aplikasi *real-time*. *PaddleOCR* menggunakan kombinasi model deteksi DB (*Differentiable Binarization*) dan model pengenalan berbasis *attention mechanism*, dengan proses dua tahap di mana CNN mengekstraksi fitur citra dan RNN atau transformer melakukan *sequence modeling* menggunakan CTC loss (Buleu *et al.*, 2025; Du *et al.*, 2020).



Gambar 16. Diagram alur proses identifikasi plat nomor kendaraan menggunakan YOLOv12 dan modul OCR.

Gambar 16 menunjukkan arsitektur sistem OCR berbasis *deep learning* yang terdiri dari dua komponen utama, yaitu *Character Detection Network*

dan *Character Recognition Network*. Tahap pertama, *Character Detection Network* menggunakan YOLO dengan *backbone* (RELAN), *neck* (RELAN + A2), dan *head* untuk mendeteksi area plat nomor pada citra kendaraan. Hasil deteksi YOLO kemudian diproses melalui *Post-Processing*, yang berfungsi untuk menyaring hasil deteksi dengan menghapus *bounding box* yang tidak relevan, seperti deteksi ganda atau salah deteksi, serta memotong area karakter yang terdeteksi untuk diekstraksi dan dikirim ke *recognition network*.

Hasil potongan plat tersebut diproses oleh *Character Recognition Network*, yang mendeteksi dan mengenali setiap karakter menggunakan pendekatan *sequence-to-sequence* hingga menghasilkan teks akhir. Kombinasi kedua jaringan ini memungkinkan sistem bekerja secara *end-to-end*, mulai dari deteksi plat hingga pengenalan karakter secara otomatis (Selmi *et al.*, 2022;Khan *et al.*, 2022).

Kinerja OCR dipengaruhi kualitas citra, pencahayaan, dan kondisi fisik plat. Penelitian ini menggunakan citra siang hari dengan pencahayaan optimal agar akurasi pengenalan karakter meningkat. Evaluasi dilakukan dengan menghitung persentase karakter yang dikenali benar terhadap total karakter (Hanif *et al.*, 2023):

$$A_1 = \frac{P}{Q} \times 100\% \quad (3)$$

Rumus persamaan (3) mengekspresikan tingkat keberhasilan sistem dalam mengenali karakter plat nomor, di mana A_1 menunjukkan *persentase* keberhasilan, P merupakan jumlah karakter yang dikenali dengan benar, dan Q adalah total karakter yang ada pada plat. Nilai mendekati 100% menunjukkan hampir semua karakter terdeteksi akurat, sedangkan nilai lebih rendah menandakan beberapa karakter gagal dikenali (Hanif *et al.*, 2023).

Kinerja pengenalan karakter tidak cukup dinilai dari persentase karakter yang terbaca dengan benar. Penilaian yang lebih akurat memerlukan metrik yang mampu menggambarkan jenis dan tingkat kesalahan secara rinci. *Levenshtein Distance* (LD) merupakan salah satu metrik tersebut, yaitu ukuran berbasis operasi edit karakter yang membandingkan keluaran OCR dengan *ground truth* berlabel manual. Perhitungan LD menentukan jumlah minimum operasi *insertion*, *deletion*, dan *substitution* yang dibutuhkan agar hasil OCR sesuai dengan teks referensi. Nilai LD yang rendah menunjukkan sedikitnya kesalahan pengenalan sehingga akurasi sistem meningkat. Hubungan rekursif untuk menghitung *Levenshtein Distance* dirumuskan pada persamaan (4) sebagai berikut (Karadag *et al.*, 2025):

$$Lev(i, j) = \begin{cases} \max(i, j) & \text{if } \min(i, j) = 0 \\ \min \begin{cases} Lev(i - 1, j) + 1, \\ Lev(i, j - 1) + 1, \\ Lev(i - 1, j - 1) + \delta(s_i, t_j) \end{cases} & \text{otherwise,} \end{cases} \quad (4)$$

Variabel i dan j merepresentasikan posisi karakter pada string hasil OCR dan string *ground truth* sehingga fungsi $Lev(i, j)$ menunjukkan jarak antara i karakter pertama pada hasil OCR dan j karakter pertama pada *ground truth*. Fungsi $\delta(s_i, t_j)$ bernilai 0 apabila karakter identik dan bernilai 1 apabila karakter berbeda sehingga ketiga operasi penyuntingan tersebut dapat dievaluasi secara konsisten. Mekanisme perhitungan ini memilih nilai minimum dari ketiga operasi sehingga LD mampu memberikan penilaian yang lebih terperinci terhadap bentuk kesalahan yang muncul pada proses pengenalan karakter. Nilai LD yang rendah menunjukkan kesalahan minimal sehingga kinerja sistem dalam membaca plat nomor kendaraan menjadi lebih baik (Karadag *et al.*, 2025).

2.16 *Hyperparameter*

Hyperparameter merupakan parameter konfigurasi yang ditetapkan sebelum proses pelatihan model *machine learning* dan tidak dapat dipelajari langsung dari data. Berbeda dengan parameter model yang dioptimalkan selama pelatihan, *hyperparameter* mengatur arsitektur serta mekanisme pembelajaran model dan ditentukan secara manual atau melalui metode optimasi tertentu (Yang & Shami *et al.*, 2024). Pemilihan *hyperparameter* yang tepat berpengaruh terhadap kinerja model, karena konfigurasi yang tidak optimal dapat menurunkan akurasi atau menghambat konvergensi. Dalam arsitektur *deep learning*, *hyperparameter* mencakup *learning rate*, ukuran *batch*, jumlah *epoch*, dan *optimizer* sebagai bagian dari strategi pembelajaran (Raiaan *et al.*, 2024).

Learning rate mengatur besarnya pembaruan bobot, dimana nilai terlalu tinggi dapat menyebabkan kegagalan konvergensi, sedangkan nilai terlalu rendah memperlambat proses pelatihan (Alzubaidi *et al.*, 2021). Ukuran *batch* memengaruhi kestabilan *gradient* dan kebutuhan memori, jumlah *epoch* menentukan kecukupan proses pelatihan untuk menghindari *underfitting* dan *overfitting*, sedangkan *optimizer* berperan dalam kecepatan konvergensi serta akurasi model (Ali & Zhang *et al.*, 2024).

Pada arsitektur berbasis *convolutional neural network* untuk deteksi objek, terdapat beberapa *hyperparameter* yang perlu ditentukan, di antaranya ukuran batch (*batch size*), jumlah *epoch*, jumlah filter dan ukuran kernel (Raiaan *et al.*, 2024). *Confidence threshold* menentukan batas kepercayaan minimum suatu deteksi, dimana nilai terlalu tinggi dapat meningkatkan *false negative*, sedangkan nilai terlalu rendah meningkatkan *false positive* (Zhao *et al.*, 2024). Parameter *IoU threshold* digunakan dalam *non-maximum suppression* untuk mengeliminasi kotak pembatas yang tumpang tindih, dengan nilai optimal umumnya berada pada kisaran 0,4 hingga 0,6 (Diwan *et al.*, 2023). Teknik *mosaic* meningkatkan variasi data

pelatihan dengan menggabungkan beberapa gambar, sehingga memperkuat kemampuan generalisasi model (Bochkovskiy *et al.*, 2020).

2.17 *Confusion Matrix*

Confusion Matrix adalah alat evaluasi utama dalam *machine learning* untuk menilai performa model klasifikasi dengan menampilkan jumlah prediksi benar dan salah tiap kelas (Sathyanarayanan, 2024). Matriks ini memvisualisasikan hubungan antara kelas sebenarnya dan prediksi, memudahkan identifikasi kesalahan klasifikasi (Valero-Carreras *et al.*, 2023). Dalam sistem identifikasi plat nomor, *Confusion Matrix* digunakan untuk mengukur akurasi YOLO dan OCR dalam mengenali karakter alfanumerik (Salsabila & Sriani, 2024). *Confusion Matrix* terdiri dari empat komponen utama yang menjadi dasar perhitungan metrik evaluasi dalam klasifikasi biner (Salsabila & Sriani, 2024; Sathyanarayanan, 2024):

1. *True Positive* (TP): Jumlah prediksi positif yang benar, yaitu model memprediksi positif dan nilai sebenarnya juga positif.
2. *True Negative* (TN): Jumlah prediksi negatif yang benar, yaitu model memprediksi negatif dan nilai sebenarnya juga negatif.
3. *False Positive* (FP): Jumlah prediksi positif yang salah (*Type I Error*), yaitu model memprediksi positif tetapi nilai sebenarnya negatif.
4. *False Negative* (FN): Jumlah prediksi negatif yang salah (*Type II Error*), yaitu model memprediksi negatif tetapi nilai sebenarnya positif.

Representasi visual *Confusion Matrix* untuk klasifikasi biner dapat ditunjukkan dalam bentuk Tabel 3 sebagai berikut:

Tabel 3. *Confusion Matrix* (Sathyanarayanan, 2024).

	Prediksi Positif	Prediksi Negatif
Aktual Positif	<i>True Positive (TP)</i>	<i>False Negative (FN)</i>
Aktual Negatif	<i>False Positive (FP)</i>	<i>True Negative (TN)</i>

Komponen pada *Confusion Matrix* digunakan untuk menghitung metrik evaluasi yang menilai performa model secara menyeluruh, menggambarkan kemampuan model mengklasifikasikan data dengan tepat dan mengenali kesalahan selama pengujian (Salsabila & Sriani, 2024; Sathyanarayanan, 2024).

1. *Accuracy* (Akurasi)

Akurasi adalah metrik evaluasi yang menilai kinerja model klasifikasi dengan menghitung rasio prediksi benar terhadap seluruh data. Nilai tinggi mencerminkan tingkat ketepatan model dalam mengklasifikasikan data sesuai hasil sebenarnya (Sathyanarayanan, 2024). Perhitungan akurasi dapat dilakukan menggunakan persamaan (4) berikut (Rainio *et al.*, 2024; Sathyanarayanan, 2024):

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (5)$$

Rumus persamaan (5) mendefinisikan TP (*True Positive*) sebagai jumlah kasus positif yang benar terprediksi, TN (*True Negative*) sebagai data negatif yang tepat terdeteksi, FP (*False Positive*) sebagai data negatif yang salah diklasifikasikan positif, dan FN (*False Negative*) sebagai data positif yang salah diklasifikasikan negatif (Sathyanarayanan, 2024). Nilai akurasi memberikan gambaran ketepatan model dalam klasifikasi, di mana angka tinggi menunjukkan kemampuan model membedakan kelas secara konsisten (Rainio *et al.*, 2024).

2. *Precision* (Presisi)

Presisi mengukur ketepatan model klasifikasi dalam memprediksi kelas positif, dihitung sebagai proporsi *True Positive* (TP) terhadap seluruh prediksi positif, termasuk *False Positive* (FP). Nilai presisi tinggi menunjukkan model mampu meminimalkan kesalahan pada prediksi positif, sehingga hasil lebih andal (Rainio *et al.*, 2024). Nilai presisi secara matematis dapat dihitung menggunakan persamaan (6) berikut (Rainio *et al.*, 2024; Sathyanarayanan, 2024):

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

Rumus persamaan (6) menunjukkan TP sebagai jumlah data positif yang diprediksi dengan benar, sedangkan FP mencerminkan data negatif yang salah diklasifikasikan sebagai positif. Nilai *precision* menilai akurasi model dalam prediksi positif, dengan nilai mendekati 1 menunjukkan sedikit kesalahan dalam mengenali kasus positif, sehingga klasifikasi lebih andal. Metrik ini penting ketika *False Positive* memiliki dampak signifikan, seperti pada deteksi spam atau aplikasi diagnosis medis (Rainio *et al.*, 2024; Sathyanarayanan, 2024).

3. *Recall*

Recall mengukur kemampuan model dalam mengklasifikasikan data positif secara benar (Rainio *et al.*, 2024). Nilai *recall* tinggi menandakan model mampu mengenali sebagian besar data positif dan mengurangi kesalahan prediksi negatif palsu. Metrik ini penting dalam konteks seperti diagnosis medis, di mana *False Negative* dapat menimbulkan konsekuensi serius (Sathyanarayanan, 2024). Nilai *recall* secara matematis dihitung menggunakan persamaan (7) sebagai berikut (Rainio *et al.*, 2024; Sathyanarayanan, 2024):

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

Rumus persamaan (7) menunjukkan bahwa TP adalah jumlah kasus positif yang berhasil dideteksi dengan benar, sedangkan FN adalah data positif yang gagal dikenali dan salah diklasifikasikan sebagai negatif. Nilai *recall* tinggi menandakan kemampuan model mendeteksi sebagian besar data positif, sehingga risiko *False Negative* berkurang. Metrik ini penting untuk aplikasi seperti deteksi plat nomor, diagnosis medis, atau pendeteksian penipuan, di mana kegagalan mengenali kasus positif dapat berdampak serius pada hasil analisis (Rainio *et al.*, 2024; Sathyanarayanan, 2024).

4. F1-score

F1-score merupakan metrik yang menggabungkan *precision* dan *recall* dalam satu ukuran. Metrik ini menilai keseimbangan kemampuan model dalam mendeteksi data positif dan tingkat ketepatan prediksi. F1-score dihitung sebagai rata-rata harmonik dari *precision* dan *recall*, sehingga memberikan gambaran performa model yang proporsional meskipun terjadi ketidakseimbangan kelas (Sathyanarayanan, 2024). Persamaan perhitungan F1-score disajikan pada Persamaan (8) berikut (Rainio *et al.*, 2024; Sathyanarayanan, 2024):

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (8)$$

Rumus persamaan (8) menunjukkan bahwa *precision* mencerminkan proporsi data yang diklasifikasikan sebagai positif dan benar-benar positif, sedangkan *recall* menggambarkan proporsi data positif aktual yang berhasil terdeteksi. Nilai F1-score tinggi menandakan performa

model seimbang, sehingga kesalahan berupa *False Positive* maupun *False Negative* dapat diminimalkan. Penggunaan *F1-score* penting pada dataset dengan distribusi kelas tidak seimbang, karena menilai keberhasilan prediksi keseluruhan sekaligus kemampuan model mengenali kelas minoritas secara tepat (Rainio *et al.*, 2024; Sathyanarayanan, 2024).

2.18 Mean Average Precision (mAP)

Mean Average Precision (mAP) digunakan untuk mengevaluasi kinerja detektor objek dengan menghitung rata-rata *Average Precision* (AP) pada setiap kelas. AP diperoleh dari luas area di bawah kurva *precision-recall*, yang menunjukkan hubungan antara *precision* dan *recall* pada berbagai ambang batas prediksi. Nilai mAP tinggi menunjukkan kemampuan model mendeteksi semua kelas secara konsisten (Padilla *et al.*, 2020; Rainio *et al.*, 2024). Nilai *Mean Average Precision* (mAP) ditentukan melalui perhitungan matematis yang dinyatakan pada persamaan (9) berikut (Padilla *et al.*, 2020):

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (9)$$

Rumus persamaan (9) menunjukkan bahwa N adalah jumlah kelas pada dataset, sedangkan AP_i merupakan nilai *Average Precision* untuk kelas ke- i . Nilai AP diperoleh dari luas area di bawah kurva *precision recall* yang mencerminkan ketepatan dan kelengkapan deteksi pada berbagai ambang kepercayaan model. Perhitungan mAP dilakukan dengan merata-ratakan nilai AP setiap kelas. Model dengan mAP tinggi mampu mendeteksi seluruh kelas objek secara konsisten, sehingga menjadi tolok ukur komprehensif performa keseluruhan model deteksi objek (Padilla *et al.*, 2020; Rainio *et al.*, 2024).

III. METODE PENELITIAN

3.1 Waktu dan Tempat

3.1.1 Tempat Penelitian

Penelitian ini dilaksanakan di Lab. Komputasi Dasar Jurusan Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung yang berlokasi di Jl. Prof. Dr. Ir Soemantri Brojonegoro No. 1, Gedong Meneng, Kec. Rajabasa, Kota Bandar Lampung.

3.1.2 Waktu Penelitian

Penelitian ini dilakukan pada semester ganjil sampai semester genap dengan perkiraan waktu bulan September 2025 – Januari 2026. Tabel 4 berikut merupakan jadwal kegiatan yang akan dilakukan.

3.2 Alat Pendukung

Alat pendukung yang digunakan dalam penelitian ini, yaitu:

3.2.1 Perangkat Keras (Hardware)

Perangkat keras yang digunakan dalam penelitian ini ditunjukkan dalam Tabel 5 berikut.

Tabel 5. Alat Pendukung (Perangkat Keras).

No	Perangkat	Spesifikasi
1.	Laptop	<ul style="list-style-type: none"> • Laptop : Lenovo • <i>Processor</i> : 11th Gen Intel(R) Core(TM) i7-1165G7 @ 2.80GHz (2.80 GHz) • Penyimpanan : SSD 512GB • RAM : 8,00 GB • GPU : Intel(R) Iris(R) Xe Graphics
2.	<i>Smartphone</i>	<ul style="list-style-type: none"> • Penyimpanan internal : 128 GB • Prosesor : Apple A13 Bionic • Kamera : 12 MP Wide • Format gambar : HEIF dan JPEG • Format Video : MOV • Sistem fokus : Autofokus PDAF ganda dengan OIS

3.2.2 Perangkat Lunak (Software)

Perangkat lunak yang digunakan dalam proses penelitian ini yaitu:

a. Sistem Operasi Windows 11 Home Single Language 64-bit.

Sistem operasi yang digunakan dalam penelitian ini adalah Windows 11 *Home Single Language* 64-bit yang dikembangkan oleh Microsoft. Sistem operasi ini berfungsi sebagai platform utama untuk menjalankan seluruh perangkat lunak yang dibutuhkan selama penelitian. Lingkungan yang disediakan memungkinkan berbagai program dapat dijalankan dengan baik, terutama untuk proses pengolahan data, pelatihan model, serta pengujian model sehingga seluruh tahapan penelitian dapat dilakukan secara terstruktur dan berjalan dengan lancar.

b. Visual Studio Code versi 1.91.1.

Visual Studio Code merupakan editor berbasis *open-source* yang dikembangkan oleh Microsoft dan dapat dijalankan pada berbagai sistem operasi. Pada penelitian ini, VS Code versi 1.91.1 digunakan untuk penulisan, pengeditan, dan pengujian kode program berbasis Python. Penggunaannya mencakup pengembangan tampilan *interface* menggunakan HTML dan CSS, sekaligus proses integrasi model melalui *Flask*, sehingga seluruh proses pengembangan dapat dilakukan dalam satu lingkungan kerja.

c. Python versi 3.9.0.

Python versi 3.9.0 digunakan sebagai bahasa utama dalam penelitian ini. Pemilihan *Python* didukung oleh ketersediaan pustaka yang telah berkembang dengan baik untuk kebutuhan *machine learning* dan *deep learning*. Struktur penulisan pada *Python* yang relatif sederhana memudahkan proses pengembangan, sehingga alur penelitian mulai dari prapemrosesan video, pelatihan model, hingga ekstraksi teks

dapat dijalankan secara lebih efektif dalam satu lingkungan yang saling terhubung.

d. Google Collab

Google Colaboratory (Colab) merupakan layanan *notebook* berbasis *cloud* dari Google yang berjalan di lingkungan *Jupyter Notebook*. Platform ini digunakan dalam penelitian untuk pelatihan model YOLOv12. Penggunaan *Colab* memungkinkan pemanfaatan GPU tanpa perlu konfigurasi pada perangkat lokal, sehingga proses pelatihan model dapat berjalan lebih cepat dibandingkan dengan CPU. Hal ini membantu proses eksperimen yang membutuhkan komputasi tinggi agar dapat dilakukan dengan lebih efisien.

e. Google Drive

Google Drive merupakan layanan penyimpanan *cloud* dari Google yang terhubung dengan Google Colaboratory dalam penelitian ini. Google Drive digunakan untuk menyimpan dataset video, bobot model YOLOV12 yang telah dilatih, serta hasil dari proses pemrosesan. Integrasi dengan *Colab* dilakukan melalui proses *mounting* pada *notebook*, sehingga data dan model dapat diakses langsung selama proses pelatihan tanpa perlu mengunggah ulang file setiap sesi.

f. UI/UX

Antarmuka pengguna pada penelitian ini dikembangkan menggunakan HTML dan CSS sebagai bagian *front-end*, sedangkan *Flask* berbasis *Python* digunakan sebagai *back-end web framework* yang menghubungkan antarmuka dengan model YOLOv12. Pengguna dapat mengunggah berkas video melalui halaman antarmuka, kemudian *Flask* akan meneruskan berkas tersebut ke model untuk diproses

secara otomatis. Hasil deteksi objek dan ekstraksi teks kemudian ditampilkan kembali kepada pengguna melalui halaman yang sama.

g. *Packages*

1) OpenCV

OpenCV (*Open Source Computer Vision Library*) merupakan pustaka *open-source* untuk pengolahan citra dan visi komputer. Pada penelitian ini, *OpenCV* digunakan untuk mengambil *frame* dari video, mengubah ruang warna, serta menampilkan hasil deteksi berupa *bounding box* pada setiap *frame* yang diproses oleh model YOLOv12.

2) Ultralytics YOLO (YOLOv12)

Ultralytics YOLO merupakan *framework* deteksi objek yang digunakan untuk mengimplementasikan model YOLOv12 pada penelitian ini. YOLOv12 menggunakan pendekatan berbasis *attention* melalui modul *Area Attention* (A^2) dan *Residual Efficient Layer Aggregation Network* (R-ELAN). Model ini digunakan untuk mendeteksi objek target pada setiap *frame* video secara otomatis.

3) EasyOCR

EasyOCR merupakan pustaka *Python* berbasis *deep learning* yang digunakan untuk melakukan *Optical Character Recognition* (OCR). Dalam penelitian ini, *EasyOCR* digunakan untuk membaca teks pada objek yang terdeteksi dalam *frame* video agar hasil deteksi dari YOLOv12 dapat dilengkapi dengan informasi teks.

4) MoviePy

MoviePy merupakan pustaka *Python* yang digunakan untuk mengolah berkas video. Dalam penelitian ini, *MoviePy* digunakan untuk memuat video, mengambil bagian yang diperlukan, dan menyusun kembali hasil pemrosesan menjadi video keluaran.

5) NumPy

NumPy (*Numerical Python*) merupakan pustaka *Python* yang digunakan untuk mengolah data dalam bentuk *array*. Dalam penelitian ini, *NumPy* digunakan untuk merepresentasikan gambar dan *frame* video serta membantu proses prapemrosesan seperti normalisasi dan pengaturan ukuran data sebelum dan sesudah proses *inference* pada model YOLOv12.

6) Matplotlib

Matplotlib merupakan pustaka *Python* yang digunakan untuk visualisasi data. Penelitian ini, *Matplotlib* digunakan untuk menampilkan grafik evaluasi model seperti *loss* dan metrik *precision*, *recall*, serta *mAP*, serta visualisasi hasil deteksi objek pada data uji.

7) Pandas

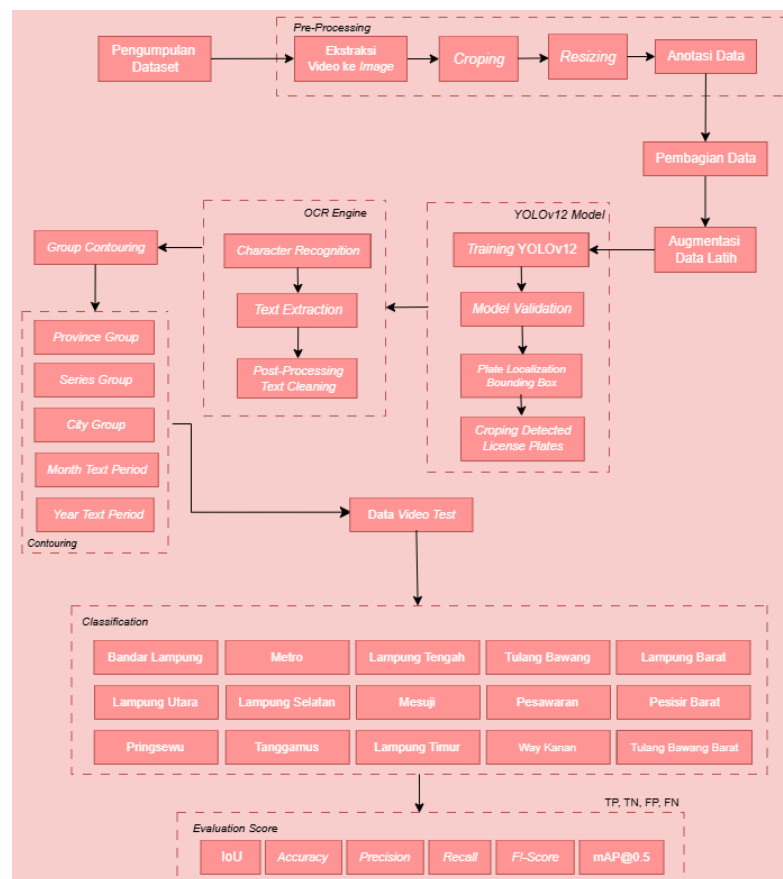
Pandas merupakan pustaka *Python* yang digunakan untuk pengolahan data berbentuk tabel. Pustaka *Pandas* dimanfaatkan untuk mengatur, menyimpan, dan mengekspor hasil deteksi serta ekstraksi teks ke dalam format CSV, sehingga data dapat dikelola dan ditinjau per *frame* dengan lebih mudah.

8) PyTorch

PyTorch digunakan untuk menjalankan dan memproses model YOLOv12 serta EasyOCR, sehingga sistem dapat melakukan deteksi objek dan membaca teks dari gambar atau video. Penggunaan *PyTorch* membantu proses pengolahan data visual agar berjalan lebih cepat dan terstruktur, sehingga hasil deteksi objek dan pembacaan teks dapat diperoleh secara lebih efisien tanpa memperlambat proses komputasi.

3.3 Tahapan Penelitian

Struktur metodologi penelitian Identifikasi Multi-Informasi Plat Nomor Kendaraan dengan YOLOV12 dan *Optical Character Recognition* (OCR) di Provinsi Lampung ditunjukkan pada Gambar 17 berikut.



Gambar 17. Struktur Tahapan Penelitian.

3.3.1 Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data primer berupa video yang direkam secara langsung menggunakan kamera *smartphone* pada beberapa lokasi, yaitu area parkir motor Terpadu dan area parkir Beringin di Universitas Lampung, pada pukul 11.00–16.00 WIB. Fokus pengambilan data dilakukan pada kendaraan pribadi yang beroperasi di Provinsi Lampung. Setiap video direkam dengan durasi 20-60 detik, resolusi 1080p, dan *frame rate* 30 fps untuk memastikan detail visual yang memadai dalam proses deteksi dan pengenalan plat nomor. Data direkam dengan menempatkan kamera pada posisi tampak depan kendaraan agar area plat nomor terlihat jelas. Pengumpulan data dilakukan dari tiga titik sudut pengambilan, yaitu sudut sekitar 30° dari kanan, sudut sekitar 30° dari kiri, dan sudut 0° atau tampak depan kendaraan untuk memperoleh variasi sudut pandang yang representatif. Pemilihan waktu pengambilan data tersebut bertujuan untuk memperoleh kondisi pencahayaan yang optimal, sehingga kualitas video yang dihasilkan dapat mendukung proses ekstraksi citra yang akurat.

3.3.2 *Pre-processing*

Pre-processing adalah tahap yang dilakukan untuk mempersiapkan data agar proses klasifikasi karakter plat nomor kendaraan dapat berjalan secara optimal. Tahap ini meliputi beberapa proses utama, yaitu ekstraksi video ke *image*, *Cropping*, dan *resizing* citra serta anotasi data.

3.3.2.1 Ekstraksi Video ke *Image*

Ekstraksi video ke *image* merupakan tahap awal dalam proses pengolahan data yang bertujuan mengkonversi video rekaman menjadi kumpulan *frame* citra secara berurutan. Pada tahap ini, video hasil rekaman menggunakan kamera

Smartphone di berbagai lokasi penelitian diproses menjadi *frame-frame* citra dengan format JPG. Proses ekstraksi dilakukan secara berkala dengan interval pengambilan lima *frame* setiap 10 detik untuk memperoleh citra plat nomor kendaraan yang representatif dan tidak berlebihan secara jumlah. Pemilihan format JPG dipertimbangkan karena mampu mempertahankan detail visual objek sekaligus mengoptimalkan kebutuhan ruang penyimpanan. Citra hasil ekstraksi ini menjadi dasar bagi tahap pra-pemrosesan berikutnya seperti *resizing* dan anotasi. Ekstraksi video ke image memegang peranan penting sebagai langkah awal yang menentukan kualitas data untuk pelatihan dan evaluasi model deteksi serta pengenalan karakter plat nomor kendaraan.

3.3.2.2 Cropping

Cropping merupakan tahap lanjutan setelah citra diperoleh dari proses ekstraksi video. Tahap ini dilakukan untuk memotong area gambar sehingga hanya menyisakan bagian kendaraan yang memuat plat nomor. Citra hasil ekstraksi masih menampilkan berbagai objek yang tidak diperlukan, seperti latar parkir, pejalan kaki, dan kendaraan lain di sekitar lokasi perekaman. Elemen-elemen tersebut berpotensi mengalihkan fokus model dan dapat menurunkan akurasi proses deteksi. Proses cropping dilakukan secara manual pada tahap awal untuk memastikan area plat nomor tertangkap secara proporsional pada setiap citra. Pemotongan citra juga bertujuan menjaga kesesuaian rasio objek saat melalui proses *resizing*, sehingga bentuk karakter tidak berubah secara tidak seimbang atau mengalami distorsi proporsi. Ketepatan pemotongan sangat penting karena detail bentuk karakter

menentukan keberhasilan tahap pengenalan teks pada proses selanjutnya.

3.3.2.3 Resizing

Setelah tahap ekstraksi video ke image selesai, tahap selanjutnya adalah *resizing* citra plat nomor kendaraan. *Resizing* bertujuan menyesuaikan ukuran citra agar memenuhi persyaratan input model YOLOv12, yakni citra dengan ukuran 640 x 640 piksel. Citra hasil ekstraksi awalnya memiliki resolusi 1920 x 1080 piksel, kemudian diubah menjadi ukuran 640 x 640 piksel untuk menjaga konsistensi dan efisiensi pada proses pelatihan model. Penyesuaian ukuran dilakukan dengan tetap mempertahankan proporsi objek sehingga kualitas visual yang dibutuhkan untuk mendeteksi area plat nomor tetap terjaga. Hasil *resizing* menjadikan data citra siap digunakan pada tahap pelatihan dan evaluasi model deteksi serta pengenalan karakter plat nomor kendaraan di Provinsi Lampung.

3.3.2.4 Anotasi Data

Setelah citra plat nomor kendaraan selesai melalui tahap *resizing*, tahap selanjutnya adalah anotasi data. Anotasi merupakan proses penandaan kelas pada citra plat nomor yang telah diproses. Pada proses ini, *bounding box* dibuat untuk menandai area plat nomor sekaligus memberikan label kelas yang sesuai untuk setiap objek yang teridentifikasi. Tujuan anotasi adalah membantu model dalam mengenali posisi dan bentuk karakter pada plat nomor selama proses pelatihan.

Proses anotasi dalam penelitian ini dilakukan menggunakan LabelImg yang dikembangkan oleh *HumanSignal* (tersedia di <https://github.com/HumanSignal/labelImg>). Alat ini memungkinkan pembuatan *bounding box* secara manual untuk menandai area plat nomor dengan label kelas "*license plate*". Hasil anotasi disimpan dalam format TXT yang memuat koordinat *bounding box* beserta label kelas, digunakan sebagai *ground truth* dalam pelatihan model YOLOv12 dan OCR. Ketepatan dan konsistensi anotasi sangat penting untuk memastikan model dapat mendeteksi posisi, bentuk, dan karakter plat nomor secara efektif, meningkatkan akurasi pengenalan multi-informasi plat nomor kendaraan di Provinsi Lampung.

3.3.3 Pembagian Data

Setelah proses anotasi selesai, dataset yang telah diberi label dibagi menggunakan metode *group-wise random split*. Metode ini digunakan untuk memastikan bahwa seluruh citra yang berasal dari satu video tetap berada pada subset yang sama, sehingga tidak terjadi kebocoran data antar data latih, validasi, dan uji. Pendekatan ini penting karena citra dalam satu video memiliki kemiripan sudut, pencahayaan, dan posisi objek. Pada penelitian ini, dataset dibagi dengan proporsi 80% untuk data latih, 10% untuk data validasi, dan 10% untuk data uji.

Data latih berfungsi sebagai dasar dalam pembangunan dan pelatihan model, sehingga jumlahnya perlu memadai agar model mampu mengenali pola dan karakteristik citra plat nomor kendaraan secara optimal. Data validasi digunakan untuk memantau performa model selama pelatihan serta mencegah *overfitting*, yaitu kondisi ketika model terlalu menyesuaikan diri pada data latih sehingga kehilangan kemampuan generalisasi. Data uji berperan penting

untuk mengukur kemampuan generalisasi model terhadap data baru yang belum pernah dilihat sebelumnya, serta menjadi indikator kinerja akhir dalam mengenali plat nomor kendaraan secara nyata.

3.3.4 Augmentasi Data Latih

Augmentasi data adalah teknik untuk menambah variasi data latih tanpa harus mengumpulkan data baru. Penerapan augmentasi pada penelitian ini difokuskan hanya pada data latih, sedangkan data validasi dan data uji tetap menggunakan data asli tanpa perubahan. Pengaturan tersebut dilakukan agar hasil evaluasi model dapat merepresentasikan kondisi sebenarnya di lapangan. Metode augmentasi yang digunakan berupa *mosaic augmentation* yang tersedia sebagai fitur bawaan pada YOLOv12, dengan pengaturan parameter *mosaic* = 1 pada proses pelatihan. Teknik ini bekerja dengan cara menggabungkan empat citra yang dipilih secara acak menjadi satu citra baru dalam satu komposisi.

Proses penggabungan dilakukan secara dinamis pada setiap iterasi pelatihan sehingga kombinasi citra yang terbentuk selalu bervariasi. Variasi tersebut membantu model dalam mempelajari objek plat nomor pada berbagai kondisi, seperti perbedaan posisi, ukuran, dan latar belakang. Penerapan augmentasi yang terbatas pada data latih memastikan bahwa data validasi dan data uji tidak terpengaruh oleh proses tersebut. Hasil evaluasi yang diperoleh dapat mencerminkan performa model secara lebih objektif sesuai kondisi nyata.

3.3.5 YOLOV12 Model

Setelah seluruh tahapan pengumpulan data, pra-pemrosesan, dan anotasi selesai, penelitian ini menggunakan arsitektur YOLOv12 sebagai model utama deteksi plat nomor kendaraan di Provinsi Lampung. Arsitektur YOLOv12 terdiri atas tiga bagian utama, yaitu

backbone, *neck*, dan *head*, yang diimplementasikan secara berurutan untuk menghasilkan prediksi lokasi plat nomor secara akurat.

Pada bagian *backbone*, citra hasil *pra-pemrosesan* (*Cropping* dan *resizing* ke 640x640 piksel) diproses melalui lapisan konvolusional dan blok R-ELAN untuk mengekstraksi fitur utama dari area kendaraan. Modul *Position Perceiver* dan *Area Attention* (A^2) digunakan agar model memusatkan perhatian pada area plat nomor dan mengurangi gangguan latar belakang.

Bagian *neck* menggabungkan fitur dari berbagai skala resolusi melalui mekanisme *upsampling* dan *concatenation*. Penerapan tahap ini memberikan informasi visual yang lebih lengkap sehingga area plat nomor dapat diidentifikasi secara konsisten pada citra dengan ukuran objek yang bervariasi. Struktur *neck* juga membantu mempertahankan detail penting yang diperlukan untuk mendeteksi karakter pada plat.

Proses dilanjutkan pada bagian *head* yang menghasilkan keluaran berupa koordinat *bounding box*, label kelas, dan nilai *confidence score*. Ketiga keluaran tersebut dimanfaatkan sebagai dasar penentuan posisi plat nomor sebelum memasuki tahap ekstraksi karakter. Aktivasi mekanisme *FlashAttention A²* dilakukan pada tahap inferensi sebagai bagian dari proses keluaran *head*. Mekanisme tersebut dipilih untuk mempercepat pemrosesan *attention* dengan mengurangi kebutuhan akses memori sekaligus mempertahankan ketelitian perhitungan pada peta fitur yang berukuran besar. Pemanfaatan *FlashAttention A²* mendukung proses deteksi agar berjalan lebih efisien ketika memproses citra kendaraan dengan kondisi pencahayaan berbeda, objek kecil, ataupun kendaraan yang sedang bergerak. Integrasi metode ini menghasilkan alur deteksi yang stabil dan responsif terhadap variasi kondisi lapangan.

Pelatihan model dilakukan menggunakan dataset hasil anotasi manual dengan konfigurasi ukuran citra 640x640 piksel. Dataset dibagi menjadi 80% data latih, 10% data validasi, dan 10% data uji, sehingga model dapat belajar pola dari data latih sekaligus dipantau performanya pada data validasi untuk mencegah *overfitting*.

Evaluasi model dilakukan menggunakan metrik *mean Average Precision* (mAP), *precision*, *recall*, dan *F1-score* pada data uji berupa video kendaraan. Proses *training* dimonitor melalui kurva loss dan akurasi, dengan penyimpanan model terbaik berdasarkan performa pada data validasi. Setelah model dilatih, video uji diproses *frame per frame* untuk mendeteksi plat nomor, di mana hasil deteksi berupa *bounding box* pada setiap *frame* menjadi masukan bagi tahap *Optical Character Recognition* (OCR) untuk mengenali karakter alfanumerik serta mengekstraksi informasi kode wilayah dan masa berlaku plat nomor kendaraan.

3.3.6 OCR Engine

Tahap pengenalan karakter dilakukan setelah model *You Only Look Once* (YOLOv12) berhasil mendeteksi lokasi plat nomor kendaraan dalam bentuk *bounding box*. Proses ini bertujuan untuk mengekstraksi karakter alfanumerik dari area plat yang terdeteksi menggunakan teknologi *Optical Character Recognition* (OCR). Penerapan OCR menjadi bagian penting dalam sistem karena hasil pengenalan karakter akan digunakan untuk proses identifikasi serta ekstraksi informasi kendaraan.

Tahap pengenalan karakter menggunakan *EasyOCR* sebagai *engine Optical Character Recognition* (OCR) untuk membaca karakter pada area plat nomor kendaraan yang telah diperoleh dari tahap deteksi. Pengujian dilakukan untuk menilai tingkat akurasi, kecepatan pemrosesan, serta kemampuan mengenali karakter pada

berbagai kondisi citra seperti pencahayaan, sudut pengambilan, dan tingkat keburaman. Ambang batas *confidence score* ditetapkan sebesar 0,5 guna memastikan hanya karakter dengan tingkat kepercayaan tinggi yang diterima, sehingga kesalahan pembacaan akibat *noise* atau ketidaktepatan segmentasi dapat diminimalkan. Hasil tahap ini berupa deretan karakter yang teridentifikasi dari area plat nomor dan menjadi dasar untuk proses ekstraksi informasi kendaraan.

3.3.7 *Group contouring*

Setelah proses ekstraksi karakter dan pembersihan teks (*text cleaning*) pada tahap *OCR Engine*, langkah berikutnya adalah *group contouring*. *Group contouring* berperan penting dalam memetakan hasil ekstraksi karakter menjadi struktur informasi yang terorganisasi berdasarkan elemen-elemen utama plat nomor, seperti kelompok provinsi, seri, kota, bulan, dan tahun. Tahap ini dilakukan dengan mengelompokkan setiap karakter hasil OCR ke dalam kelompok spesifik sehingga format dan struktur plat nomor dapat dikenali secara utuh, sekaligus memastikan bahwa informasi dalam citra plat nomor sesuai dengan aturan administratif wilayah di Provinsi Lampung. Proses *group contouring* dimulai dengan segmentasi dan pemetaan setiap bagian karakter menggunakan analisis kontur pada hasil citra OCR. Setiap kontur yang sesuai dengan pola atau aturan plat nomor, termasuk posisi kode provinsi, kode seri, nama kota, bulan, dan tahun, diidentifikasi dan diklasifikasikan ke dalam kelompok relevan. Teknik ini mampu mengisolasi data penting sehingga informasi alfanumerik dari plat nomor dapat dibedakan antar kelompok secara otomatis. Dengan pengelompokan presisi, sistem dapat memproses data lebih lanjut ke tahap klasifikasi wilayah administratif sesuai kebutuhan, seperti

pengenalan kendaraan berdasarkan kabupaten atau kota di Lampung.

3.3.8 *Classification*

Tahapan klasifikasi pada penelitian ini dilaksanakan setelah tahap ekstraksi karakter melalui OCR dan pengelompokan data menggunakan teknik *group contouring*. Tujuan klasifikasi ini adalah menentukan asal wilayah kendaraan berdasarkan karakter plat nomor yang berhasil dikenali. Wilayah administratif yang dijadikan kelas mencakup 15 kabupaten/kota di Provinsi Lampung, yaitu Bandar Lampung, Metro, Lampung Tengah, Tulang Bawang, Lampung Barat, Lampung Utara, Lampung Selatan, Mesuji, Pesawaran, Pesisir Barat, Pringsewu, Tanggamus, Lampung Timur, Way Kanan, serta Tulang Bawang Barat. Setiap plat nomor yang telah diproses dipetakan ke dalam salah satu kelas wilayah tersebut sesuai dengan hasil pengenalan karakter.

Metode klasifikasi memanfaatkan analisis ciri visual dari karakter plat nomor yang sudah melalui proses segmentasi dan pemetaan kontur. Pendekatan ini memungkinkan sistem menangkap pola-pola khusus dari setiap plat nomor sehingga asal kabupaten atau kota dapat ditentukan secara tepat.

3.3.9 *Evaluation Score*

Tahap evaluasi penelitian ini bertujuan mengukur efektivitas dan akurasi sistem dalam mendeteksi serta mengenali plat nomor kendaraan di Provinsi Lampung. Model YOLOv12 digunakan untuk deteksi objek karena kemampuannya dalam mengenali plat nomor secara *real-time* dengan presisi tinggi, sementara *OCR Engine* diterapkan untuk identifikasi karakter alfanumerik pada citra hasil *Cropping*. Data pelatihan dan pengujian dibagi secara proporsional

agar model mampu belajar pola karakter dan variasi posisi plat nomor secara optimal.

Berbagai metrik evaluasi digunakan sebagai parameter kinerja model. *Intersection over Union* (IOU) menilai kesesuaian antara kotak prediksi model dengan posisi objek sebenarnya, *accuracy* mengukur proporsi prediksi yang benar, *precision* menilai ketepatan prediksi positif, dan *recall* mengukur kemampuan model menemukan seluruh objek relevan. *F1-score* digunakan untuk menyeimbangkan *precision* dan *recall*, sementara *mean Average Precision* (mAP) menjadi metrik utama untuk menilai performa deteksi secara keseluruhan pada berbagai tingkat ambang batas.

Evaluasi mencakup seluruh tahapan, mulai dari deteksi objek, segmentasi karakter, pengenalan karakter menggunakan OCR, hingga klasifikasi wilayah berdasarkan elemen multi-informasi plat nomor. Penggunaan metrik ini memberikan gambaran menyeluruh tentang kemampuan sistem, memungkinkan identifikasi kekuatan dan kelemahan model, sekaligus menjadi acuan untuk pengoptimalan sebelum penerapan di lapangan. Pemilihan YOLOv12, OCR Engine, dan metrik evaluasi tersebut dilakukan untuk memastikan bahwa sistem dapat bekerja secara akurat, efisien, dan sesuai dengan aturan administrasi kendaraan di Provinsi Lampung.

3.3.10 Skenario Pengujian Model

Tahap pengujian dilakukan setelah model menyelesaikan proses pelatihan dan validasi. Pengujian ini bertujuan untuk menilai kemampuan sistem dalam melakukan klasifikasi wilayah kendaraan berdasarkan kode plat nomor yang berhasil dikenali. Data yang digunakan merupakan data uji yang telah dipisahkan dari *dataset* pelatihan dan validasi. Data uji tersebut terdiri dari 39 video

kendaraan dan tidak dilibatkan dalam proses *training* model. Pemisahan data dilakukan agar pengujian dapat menggambarkan kemampuan sistem saat memproses data baru.

Setiap video uji diproses mengikuti alur sistem yang telah dirancang sebelumnya. Video dianalisis *frame per frame* menggunakan model YOLOv12 untuk mendeteksi area plat nomor kendaraan. Hasil deteksi berupa *bounding box* kemudian diteruskan ke tahap OCR untuk membaca karakter alfanumerik pada plat. Teks yang dihasilkan selanjutnya diproses melalui tahap *group contouring* untuk menyusun struktur informasi plat nomor sesuai dengan format yang berlaku. Kode wilayah yang berhasil diidentifikasi dari hasil pembacaan karakter digunakan sebagai dasar pemetaan ke dalam kelas wilayah administratif di Provinsi Lampung. Setiap plat nomor yang terdeteksi dan dikenali dihitung sebagai satu data hasil klasifikasi wilayah. Proses ini menghasilkan data jumlah plat nomor yang berhasil diidentifikasi beserta distribusinya berdasarkan kabupaten/kota di Provinsi Lampung.

3.3.11 Analisis Kinerja Model

Analisis kinerja model menyoroti kualitas data, sudut kamera, dan ketepatan anotasi. YOLOv12 mendeteksi plat nomor dengan presisi tinggi meskipun menurun pada pencahayaan rendah dan sudut tidak ideal, sedangkan OCR *Engine* mengenali karakter alfanumerik tergantung kualitas citra. Evaluasi mencakup klasifikasi hasil ekstraksi karakter ke wilayah administratif di Provinsi Lampung. Hasil analisis menjadi dasar penyesuaian parameter pelatihan, peningkatan kualitas dataset, dan pengembangan metode pemrosesan citra agar sistem bekerja akurat, efisien, dan sesuai aturan administrasi kendaraan. Analisis ini juga memberikan gambaran mengenai keterbatasan model sekaligus potensi peningkatan kinerjanya.

V. SIMPULAN DAN SARAN

5.1 Kesimpulan

Penelitian yang telah dilakukan diperoleh beberapa kesimpulan terkait proses identifikasi multi-informasi pada plat nomor kendaraan bermotor dengan memanfaatkan model YOLOv12 dan metode *Optical Character Recognition* pada plat wilayah Provinsi Lampung. Kesimpulan penelitian meliputi kemampuan model YOLOv12 dalam menentukan area plat nomor kendaraan secara tepat, penerapan metode OCR dalam mengenali karakter dan informasi plat, serta hasil evaluasi kinerja sistem yang mengintegrasikan YOLOv12 dan OCR dalam mengidentifikasi informasi kendaraan secara menyeluruh, sebagai berikut:

1. Penelitian ini berhasil mengimplementasikan model YOLOv12 untuk mendeteksi dan melokalisasi area plat nomor kendaraan secara otomatis pada citra nomor kendaraan. Hasil pelatihan pada konfigurasi 100 *epoch* dengan *Learning rate* 0,001 menghasilkan nilai mAP sebesar 0,99477, dengan *precision* 0,98681, *recall* 0,99122, dan *F1-score* 0,98901.
2. Penerapan teknologi *Optical Character Recognition* menggunakan *EasyOCR* juga dapat berjalan dengan baik dalam membaca karakter alfanumerik pada plat nomor yang telah terdeteksi. Berdasarkan pembacaan kode wilayah, sistem dapat mengelompokkan kendaraan ke dalam 15 kabupaten atau kota di Provinsi Lampung, yaitu Bandar Lampung, Metro, Lampung Selatan, Lampung Tengah, Lampung Utara, Lampung Barat, Lampung Timur, Tulang Bawang, Tulang Bawang Barat, Tanggamus, Way Kanan,

Pesawaran, Pringsewu, Mesuji, dan Pesisir Barat. Hal ini menunjukkan bahwa plat nomor dapat diidentifikasi sesuai dengan struktur yang berlaku.

3. Integrasi YOLOv12 dan OCR menghasilkan sistem identifikasi plat nomor yang stabil pada data uji. Model deteksi mencapai $mAP@0,5$ 0,99356 dengan rata-rata IoU 0,96803, sedangkan pengenalan karakter mencapai akurasi 98,90% pada skema *best frame*. Evaluasi klasifikasi wilayah menunjukkan rata-rata *accuracy* 98,99%, dengan *precision* 89,20%, *recall* 91,76%, dan *F1-score* 89,33%, yang menunjukkan sistem mampu mengenali karakter dan mengklasifikasikan wilayah kendaraan di Provinsi Lampung secara konsisten, meskipun masih terdapat kesalahan pada beberapa kelas akibat ketidaktepatan pembacaan karakter.

5.2 Saran

Rekomendasi penelitian disusun berdasarkan hasil yang diperoleh dari penelitian untuk mendukung pengembangan penelitian lebih lanjut, sebagai berikut:

1. Variasi dataset perlu ditingkatkan dengan menambah sampel yang mencakup berbagai kondisi pencahayaan, jarak pengambilan gambar, sudut kamera, serta jenis plat nomor kendaraan dari berbagai wilayah di Indonesia untuk membantu meningkatkan akurasi pembacaan karakter terhadap perbedaan kondisi visual di dunia nyata.
2. Pengujian model pada situasi lalu lintas padat dengan tingkat tumpang tindih antarkendaraan yang tinggi perlu dilakukan untuk mengetahui kemampuan sistem dalam menghadapi kondisi yang lebih kompleks dan mendekati situasi nyata.
3. Ruang lingkup penelitian dapat diperluas melalui penambahan klasifikasi jenis kendaraan serta integrasi informasi tambahan yang terdapat pada plat nomor, sehingga sistem mampu menghasilkan

identifikasi kendaraan yang lebih lengkap dan bermanfaat untuk berbagai kebutuhan pengawasan lalu lintas.

4. Perbandingan performa dengan metode OCR lain guna mengevaluasi efektivitas pendekatan yang digunakan. Pengujian dapat dilakukan dengan membandingkan *EasyOCR* dengan *PaddleOCR*, *Tesseract OCR*, maupun model OCR berbasis *deep learning* lainnya agar diperoleh analisis kinerja yang lebih menyeluruh.

DAFTAR PUSTAKA

- Abba, S., Bizi, A. M., Lee, J. A., Bakouri, S., & Crespo, M. L. (2024). *Real-time object detection, tracking, and monitoring framework for security surveillance systems*. *Heliyon*, *10*(15), 1. <https://doi.org/10.1016/j.heliyon.2024.e34922>
- Ali, M. L., & Zhang, Z. (2024). The YOLO Framework: A Comprehensive Review of Evolution, Applications, and Benchmarks in Object Detection. In *Computers* (Vol. 13, Number 12). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/computers13120336>
- Alif, M. A. R., & Hussain, M. (2025). YOLOv12: A Breakdown of the Key Architectural Features. 1–9. <http://arxiv.org/abs/2502.14740>
- Almuqati, M. T., Sidi, F., Nurulain, S., Rum, M., Zolkepli, M., & Ishak, I. (2024). Challenges in Supervised and Unsupervised Learning: A Comprehensive Overview. *International Journal on Advanced Science, Engineering and Information Technology (IJASEIT)*, *14*(4), 1449–1455.
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, *8*(1), 1–74. <https://doi.org/10.1186/s40537-021-00444-8>
- Amyrulloh, B., & Samuji. (2024). Analisis Penyebab Pelanggaran Lalu Lintas oleh Pengendara Kendaraan Bermotor. *Jurnal Ilmu Sosial dan Humaniora*, 81–103. <http://jurnal.kolibi.org/index.php/kultura>

- Anthony, Herman, & Yulianto, A. (2024). Pengembangan Sistem Pengenalan Plat Nomor Indonesia Menggunakan YOLOv8 dan EasyOCR. *Jurnal Ilmiah Komputasi*, 23(4). <https://doi.org/10.32409/jikstik.23.4.3659>
- Aprilino, A., & Al Amin, I. H. (2022). Implementasi Algoritma Yolo Dan Tesseract OCR Pada Sistem Deteksi Plat Nomor Otomatis. *Jurnal TEKNOINFO*, 14(1), 54–59. <https://doi.org/10.33365/jti.v16i1.1522>
- Archana, R., & Jeevaraj, P. S. E. (2024). Deep *learning* models for digital image processing: a review. *Artificial Intelligence Review*, 57(1), 1–33. <https://doi.org/10.1007/s10462-023-10631-z>
- Auni, A. R., & Sugiharti, E. (2025). Optimization of Mango Plant Leaf Disease Classification Using Concatenation Method of MobileNetV2 and DenseNet201 CNN Architectures. *Scientific Journal of Informatics*, 11(4), 1023–1034. <https://doi.org/10.15294/sji.v11i4.15169>
- Badan Pusat Statistik Provinsi Lampung. (2024). *Jumlah kendaraan bermotor menurut kabupaten/kota dan jenis kendaraan di Provinsi Lampung (unit)*. <https://lampung.bps.go.id/id/statistics-table/3/VjJ3NGRGa3dkRk5MTIU1bVNFOTVVbmQyVURSTVVFUMDkjMw==/jumlah-kendaraan-bermotor-menurut-kabupaten-kota-dan-jenis-kendaraan-di-provinsi-lampung--unit---2023.html?year=2024>
- Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). *YOLOv4: Optimal Speed and Accuracy of Object Detection*. <http://arxiv.org/abs/2004.10934>
- Buleu, B., Robu, R., & Filip, I. (2025). A Deep *Learning*-Based System for Automatic License Plate Recognition Using YOLOv12 and PaddleOCR. *Applied Sciences (Switzerland)*, 15(14), 1. <https://doi.org/10.3390/app15147833>
- Cai, D., Zhang, Z., & Zhang, Z. (2023). Corner-Point and Foreground-Area IoU Loss: Better Localization of Small Objects in *Bounding box* Regression. *Sensors*, 23(10), 1–17. <https://doi.org/10.3390/s23104961>

- Cao, J., Peng, B., Gao, M., Hao, H., Li, X., & Mou, H. (2025). Object Detection Based on CNN and Vision-Transformer: A Survey. *IET Computer Vision*, 19(2), 1–30. <https://doi.org/10.1049/cvi2.70028>
- Deshmukh, C. N., & Tantarale, S. S. (2020). Study on Process of Digital Image Processing. *IOSR Journal of Engineering (IOSRJEN) Www.Iosrjen.Org ISSN*, 10(1), 55–60. http://iosrjen.org/Papers/vol10_issue1/Series-1/J1001015560.pdf
- Dinas Komunikasi, Informatika, dan Statistik Provinsi Lampung. (2025, April 29). *Lampung luncurkan Samsat Digital Drive Thru, Gubernur Mirza: “Pelayanan sekarang gak pakai drama.”* <https://diskominfotik.lampungprov.go.id/detail-post/lampung-luncurkan-samsat-digital-drive-thru-gubernur-mirza-pelayanan-sekarang-gak-pakai-drama>
- Diwan, T., Anirudh, G., & Tembhurne, J. V. (2023). Object detection using YOLO: challenges, architectural successors, datasets and applications. *Multimedia Tools and Applications*, 82(6), 9243–9275. <https://doi.org/10.1007/s11042-022-13644-y>
- Du, Y., Li, C., Guo, R., Yin, X., Liu, W., Zhou, J., Bai, Y., Yu, Z., Yang, Y., Dang, Q., & Wang, H. (2020). *PP-OCR: A Practical Ultra Lightweight OCR System*. <http://arxiv.org/abs/2009.09941>
- El Akrouchi, M., Mhada, M., Gracia, D. R., Hawkesford, M. J., & Gérard, B. (2025). Optimizing Mask R-CNN for enhanced quinoa panicle detection and segmentation in precision agriculture. *Frontiers in Plant Science*, 16, 1–9. <https://doi.org/10.3389/fpls.2025.1472688>
- Fadliya, Sofi, I., Nugraha P, G., Ferayanti, T.C., Pandiangan, O. S. G., Santoso, A., Idris, A. A., Simanjuntak, P. D. L., Purba, A. D., Irzan, A., & Christyana, L. K. (2025). *Modul PDRD: OPSEN PAJAK DAERAH (Edisi Revisi)* (Edisi Revisi). Direktorat Jenderal Perimbangan Keuangan.

- Fauziah, Avrilia Lantana, D., Diana Sholihati, I., Titi Komala Sari, R., & Hendrik, B. (2023). An Extensive Analysis of Digital Image Compression Techniques Using Different Image Files and Color Formats. *International Journal on Advanced Science, Engineering and Information Technology (IJASEIT)*, 13(5), 1971–1977. <https://doi.org/10.18517/ijaseit.13.5.19319>
- Gandor, T., & Nalepa, J. (2022). First Gradually, Then Suddenly: Understanding the Impact of Image Compression on Object Detection Using Deep Learning. *Sensors*, 22(3). <https://doi.org/10.3390/s22031104>
- Guan, Z., Wang, Z., Zhang, G., Li, L., Zhang, M., Shi, Z., & Jiang, N. (2025). Multi-object tracking review: retrospective and emerging trend. *Artificial Intelligence Review*, 58(8), 1–46. <https://doi.org/10.1007/s10462-025-11212-y>
- Gubernur Lampung. (2024). *Peraturan Gubernur Lampung Nomor 17 Tahun 2024 tentang Keringanan Pajak Kendaraan Bermotor dan Bea Balik Nama Kendaraan Bermotor Tahun 2024*. <https://peraturan.bpk.go.id/Details/310345/pergub-prov-lampung-no-17-tahun-2024>
- Gupta, A., Agrawal, N., & Agrawal, H. (2025). Machine Learning and Deep Learning: A Comprehensive Overview. *International Journal for Research in Applied Science and Engineering Technology*, 13(6), 1620–1626. <https://doi.org/10.22214/ijraset.2025.72470>
- Handono, M. B., & Sudiro, A. (2025). Penegakan Hukum Terhadap Penyalahgunaan Tanda Nomor Kendaraan Roda Dua Dalam Kasus Tilang Elektronik. *R2J*, 7(2), 808–818. <https://doi.org/10.38035/rrj.v7i2>
- Hanif, A. R., Nasrullah, E., & Setyawan, F. X. A. (2023). Deteksi karakter plat nomor kendaraan dengan menggunakan metode optical character recognition (OCR). *Jurnal Informatika Dan Teknik Elektro Terapan*, 11(1), 109–117. <https://doi.org/10.23960/jitet.v11i1.2897>

- Herman, Kaimuddin Haris, O., Hidayat, S., Nur, F., & Rizky, A. (2024). Perlindungan Hukum bagi Pemilik Kendaraan yang Nomor Plat Kendaraannya Dipakai oleh Orang Lain yang Melanggar Lalu Lintas Berbasis E-TLE (Electronic Traffic Law Enforcement). *Halu Oleo Legal Research*, 6(1), 58–71. <https://journal.uho.ac.id/index.php/holresch/>
- Huang, L., Qin, J., Zhou, Y., Zhu, F., Liu, L., & Shao, L. (2020). *Normalization Techniques in Training DNNs: Methodology, Analysis and Application*. 1–20. <http://arxiv.org/abs/2009.12836>
- Indolia, S., Goswami, A. K., Mishra, S. P., & Asopa, P. (2018). Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach. *Procedia Computer Science*, 132, 679–688. <https://doi.org/10.1016/j.procs.2018.05.069>
- ISO/IEC. (2020). *Information Technology — Coding of Audio-Visual Objects — Part 14: MP4 File Format (ISO/IEC 14496-14:2020)*.
- Jia, W., Xu, S., Liang, Z., Zhao, Y., Min, H., Li, S., & Yu, Y. (2021). Real-time automatic helmet detection of motorcyclists in urban traffic using improved YOLOv5 detector. *IET Image Processing*, 15(14), 3623–3637. <https://doi.org/10.1049/ipr2.12295>
- Jin, L., Huang, W., & Zhao, J. (2022). *Research on the Theory of Artificial Intelligence Recognition Technology*. 5, 15. <https://doi.org/10.23977/jaip.2022.050403>
- Karadag, F., Kutan, F., & Bozkir, A. S. (2025). Reading Between the Blurs: A Comparative Analysis of Motion Deblurring Methods for Vehicle License Plate OCR. *Procedia Computer Science*, 269, 1712–1722. <https://doi.org/10.1016/j.procs.2025.09.114>
- Kepolisian Daerah Lampung. (2019). *Peraturan KapoLDa Lampung Nomor KEP/752/XII/2019 tentang Nomor Registrasi Kendaraan Bermotor (NRKB) Kepolisian Daerah Lampung*.

- Kepolisian Negara Republik Indonesia. (2021). *Peraturan Kepolisian Negara Republik Indonesia Nomor 7 Tahun 2021 tentang Registrasi dan Identifikasi Kendaraan Bermotor*. <https://peraturan.bpk.go.id/Details/177206/perpol-no-7-tahun-2021>
- Khan, I. R., Ali, S. T. A., Siddiq, A., Khan, M. M., Ilyas, M. U., Alshomrani, S., & Rahardja, S. (2022). Automatic License Plate Recognition in Real-World Traffic Videos Captured in Unconstrained Environment by a Mobile Camera. *Electronics (Switzerland)*, *11*(9), 1–20. <https://doi.org/10.3390/electronics11091408>
- Kothai, G., Povammal, E., Amutha, S., & Deepa, V. (2024). An Efficient Deep Learning Approach for Automatic License Plate Detection with Novel Feature Extraction. *Procedia Computer Science*, *235*, 2822–2832. <https://doi.org/10.1016/j.procs.2024.04.267>
- Kotthapalli, M., Ravipati, D., & Bhatia, R. (2025). YOLOv1 to YOLOv11: A Comprehensive Survey of Real-time Object Detection Innovations and Challenges. 1–13. <http://arxiv.org/abs/2508.02067>
- Krichen, M. (2023). Convolutional Neural Networks: A Survey. *Computers*, *12*(8), 1–41. <https://doi.org/10.3390/computers12080151>
- Li, Z. (2024). Advances in Deep Reinforcement Learning for Computer Vision Applications. *Journal of Industrial Engineering and Applied Science*, *2*(6), 16–26. <https://doi.org/10.70393/6a69656173.323234>
- Liu, Y., Xue, J., Li, D., Zhang, W., Chiew, T. K., & Xu, Z. (2024). Image recognition based on lightweight convolutional neural network: Recent advances. *Image and Vision Computing*, *146*, 2–15. <https://doi.org/10.1016/j.imavis.2024.105037>
- Malik, & Kavita. (2020). A REVIEW ON DIGITAL IMAGE PROCESSING. *UGC Care Journal*, *43*, 53–56. <https://www.researchgate.net/publication/350545269>

- Mandal, V., Mussah, A. R., Jin, P., & Adu-Gyamfi, Y. (2020). *Artificial Intelligence Enabled Traffic Monitoring System*. <https://doi.org/10.20944/preprints202009.0725.v1>
- Mienye, I. D., & Swart, T. G. (2024). A Comprehensive Review of Deep *Learning*: Architectures, Recent Advances, and Applications. *Information (Switzerland)*, *15*(12), 1–45. <https://doi.org/10.3390/info15120755>
- Moussaoui, H., Akkad, N. El, Benslimane, M., El-Shafai, W., Baihan, A., Hewage, C., & Rathore, R. S. (2024). Enhancing automated vehicle identification by integrating YOLO v8 and OCR techniques for high-precision license plate detection and recognition. *Scientific Reports*, *14*(1). <https://doi.org/10.1038/s41598-024-65272-1>
- Nguyen, H. D., Cai, R., Zhao, H., Kot, A. C., & Wen, B. (2022). Towards More Efficient Security Inspection via Deep Learning: A Task-Driven X-ray Image *Cropping* Scheme. *Micromachines*, *13*(4). <https://doi.org/10.3390/mi13040565>
- Padilla, R., Netto, S. L., Da Silva, E. A. B., & Netto, S. L. (2020). *A Survey on Performance Metrics for Object-Detection Algorithms*. 1–7. <https://doi.org/10.1109/IWSSIP48289.2020>
- Patsanis, A., Sunoqrot, M. R. S., Bathen, T. F., & Elschot, M. (2023). CROPro: a tool for automated *Cropping* of prostate magnetic resonance images. *Journal of Medical Imaging*, *10*(02). <https://doi.org/10.1117/1.jmi.10.2.024004>
- Peng, S., Yan, Y., Shuai, Q., Bao, H., & Zhou, X. (2023). *Representing Volumetric Videos as Dynamic MLP MAPs*. <http://arxiv.org/abs/2304.06717>
- Presiden Republik Indonesia. (2022). *Undang-Undang Republik Indonesia Nomor 1 Tahun 2022 tentang Hubungan Keuangan antara Pemerintah Pusat dan Pemerintahan Daerah*. <https://peraturan.bpk.go.id/Details/208833/uu-no-1-tahun-2022>

- Purwono, Ma'arif, A., Rahmaniari, W., Fathurrahman, H. I. K., Frisky, A. Z. K., & Haq, Q. M. U. (2022). Understanding of Convolutional Neural Network (CNN): A Review. *International Journal of Robotics and Control Systems*, 2(4), 739–748. <https://doi.org/10.31763/ijrcs.v2i4.888>
- Raiaan, M. A. K., Sakib, S., Fahad, N. M., Mamun, A. Al, Rahman, M. A., Shatabda, S., & Mukta, M. S. H. (2024). A systematic review of hyperparameter optimization techniques in Convolutional Neural Networks. In *Decision Analytics Journal* (Vol. 11). Elsevier Inc. <https://doi.org/10.1016/j.dajour.2024.100470>
- Rainio, O., Teuho, J., & Klén, R. (2024). Evaluation metrics and statistical tests for machine learning. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-56706-x>
- Ramadhan, M., Putra Urip, T., & Purwadi, M. A. (2021). Analisis Tingkat Kepatuhan Wajib Pajak Kendaraan Bermotor di Kabupaten Jayapura. *Jurnal Kajian Ekonomi Dan Studi Pembangunan*, VIII(1). <https://doi.org/10.56076/jkesp.v8i1.2100>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). *You Only Look Once: Unified, Real-time Object Detection*. 1–10. <http://arxiv.org/abs/1506.02640>
- Rezatofighi, H., Tsoi, N., Gwak, J., Sadeghian, A., Reid, I., & Savarese, S. (2019). *Generalized Intersection over Union: A Metric and A Loss for Bounding box Regression*. 1–9. <http://arxiv.org/abs/1902.09630>
- Ristantyo, L. P., Nugroho, H., & Pramudito, W. A. (2022). *Sistem Identifikasi Tanda Nomor Kendaraan Bermotor Indonesia Berbasis Artificial Neural Network*. 11(2), 149–157. <https://doi.org/10.33322/kilat.v11i2.1647>
- Rota, C., Buzzelli, M., Bianco, S., & Schettini, R. (2022). Video restoration based on deep learning: a comprehensive survey. *Artificial Intelligence Review*, 56(6), 5317–5364. <https://doi.org/10.1007/s10462-022-10302-5>

- Russell, S. J., & Norvig, P. (2020). *Artificial Intelligence: A Modern Approach* (4th Edition). Pearson.
- Saha, S., & Gokhale, T. (2024). *Improving Shift Invariance in Convolutional Neural Networks with Translation Invariant Polyphase Sampling*. 1–18. <http://arxiv.org/abs/2404.07410>
- Sainui, J., Chusuwan, P., & Thepporn, C. (2024). *Thai License Plate Recognition using SSD MobileNet and EasyOCR*. 36–41. <https://doi.org/10.1145/3645259.3645266>
- Salehin, I., & Kang, D.-K. (2023). A Review on Dropout Regularization Approaches for Deep Neural Networks within the Scholarly Domain. *Electronics (Switzerland)*, *12*(13), 1–23. <https://doi.org/10.3390/electronics12143106>
- Salimah, U., Maharani, V., & Nursyanti, R. (2021). Automatic License Plate Recognition Using Optical Character Recognition. *IOP Conference Series: Materials Science and Engineering*, *1115*(1), 012023. <https://doi.org/10.1088/1757-899x/1115/1/012023>
- Salsabila, N., & Sriani, S. (2024). Enhancing Automated Vehicle License Plate Recognition with YOLOv8 and EasyOCR. *Journal of Information Systems and Informatics*, *6*(3), 1577–1597. <https://doi.org/10.51519/journalisi.v6i3.848>
- Sapkota, R., Flores-Calero, M., Qureshi, R., Badgajar, C., Nepal, U., Poulouse, A., Zeno, P., Vaddevolu, U. B. P., Khan, S., Shoman, M., Yan, H., & Karkee, M. (2025). YOLO advances to its genesis: a decadal and comprehensive review of the You Only Look Once (YOLO) series. *Artificial Intelligence Review*, *58*(9), 1–83. <https://doi.org/10.1007/s10462-025-11253-3>
- Saponara, S., & Elhanashi, A. (2022). Impact of Image Resizing on Deep Learning Detectors for Training Time and Model Performance. *Lecture Notes in*

Electrical Engineering, 866 LNEE, 10–17. https://doi.org/10.1007/978-3-030-95498-7_2

Sarhan, A., Abdel-Rahem, R., Darwish, B., Abou-Attia, A., Sneed, A., Hatem, S., Badran, A., & Ramadan, M. (2024). Egyptian car plate recognition based on YOLOv8, Easy-OCR, and CNN. *Journal of Electrical Systems and Information Technology*, 11(1), 1–27. <https://doi.org/10.1186/s43067-024-00156-y>

Sathyanarayanan, S. (2024). Confusion Matrix-Based Performance Evaluation Metrics. *African Journal of Biomedical Research*, 4023–4031. <https://doi.org/10.53555/ajbr.v27i4s.4345>

Satya, B., Manongga, D., Hendry, & Aminuddin, A. (2025). Optimized YOLOv8 for Automatic License Plate Recognition on Resource Constrained Devices. *Engineering, Technology and Applied Science Research*, 15(2), 21976–21981. <https://doi.org/10.48084/etasr.9983>

Selmi, Z., Halima, M. Ben, Pal, U., & Alimi, M. A. (2019). DELP-DAR System for License Plate Detection and Recognition. *Pattern Recognition Letters*, 1–13. <https://doi.org/10.1016/j.patrec.2019.07.018>

Shi, X., Huang, Z., Bian, W., Li, D., Zhang, M., Cheung, K. C., See, S., Qin, H., Dai, J., & Li, H. (2023). *VideoFlow: Exploiting Temporal Cues for Multi-frame Optical Flow Estimation*. <http://arxiv.org/abs/2303.08340>

Srivastava, S., Divekar, A. V., Anilkumar, C., Naik, I., Kulkarni, V., & Pattabiraman, V. (2021). Comparative analysis of deep learning image detection algorithms. *Journal of Big Data*, 8(1). <https://doi.org/10.1186/s40537-021-00434-w>

Su, K., Cao, L., Zhao, B., Li, N., Wu, D., & Han, X. (2023). N-IoU: better IoU-based bounding box regression loss for object detection. *Neural Computing and Applications*, 36(6), 3049–3063. <https://doi.org/10.1007/s00521-023-09133-4>

- Sun, Y., Sun, Z., & Chen, W. (2024). The evolution of object detection methods. *Engineering Applications of Artificial Intelligence*, 133, 1. <https://doi.org/10.1016/j.engappai.2024.108458>
- Szeliski, R. (2021). *Computer Vision: Algorithms and Applications* (2nd Edition). Springer. <https://szeliski.org/Book>
- Talebi, H., & Milanfar, P. (2021). *Learning to Resize Images for Computer Vision Tasks*. 497–506. <https://doi.org/10.48550/arXiv.2103.09950>
- term7. (2021). *FFmpeg: A short guide + examples + scripts*. GitHub. <https://github.com/term7/FFmpeg-A-short-Guide>
- Tian, Y., Ye, Q., & Doermann, D. (2025). YOLOv12: Attention-Centric Real-time Object Detectors. <http://arxiv.org/abs/2502.12524>
- Tong, Z., Chen, Y., Xu, Z., & Yu, R. (2023). Wise-IoU: Bounding box Regression Loss with Dynamic Focusing Mechanism. <http://arxiv.org/abs/2301.10051>
- Ultralytics Team. (2025, February 26). YOLO12 explained: Real-world applications and use cases. Retrieved September 16, 2025, from <https://www.ultralytics.com/blog/yolo12-explained-real-world-applications-and-use-cases>
- Utami, N. M. (2024). *Klasifikasi karakter plat nomor kendaraan menggunakan faster region-based convolutional neural network (Faster R-CNN)* [Skripsi]. Universitas Lampung.
- Valente, J., António, J., Mora, C., & Jardim, S. (2023). Developments in Image Processing Using Deep Learning and Reinforcement Learning. In *Journal of Imaging* (Vol. 9, Number 10). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/jimaging9100207>
- Valero-Carreras, D., Alcaraz, J., & Landete, M. (2023). Comparing two SVM models through different metrics based on the confusion matrix. *Computers*

- and Operations Research*, 152, 1–12.
<https://doi.org/10.1016/j.cor.2022.106131>
- Wang, C.-Y., Bochkovskiy, A., & Liao, H.-Y. M. (2022). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. 1–15.
<http://arxiv.org/abs/2207.02696>
- Xu, R., Razavi, S., & Zheng, R. (2023). *Edge Video Analytics: A Survey on Applications, Systems and Enabling Techniques*.
<https://doi.org/10.1109/COMST.2023.3232091>
- Yang, L., & Shami, A. (2022). *On Hyperparameter Optimization of Machine Learning Algorithms: Theory and Practice*.
<https://doi.org/10.1016/j.neucom.2020.07.061>
- Zhao, L., & Zhang, Z. (2024). A improved pooling method for convolutional neural networks. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-51258-6>
- Zhao, X., Wang, L., Zhang, Y., Han, X., Deveci, M., & Parmar, M. (2024). A review of convolutional neural networks in computer vision. *Artificial Intelligence Review*, 57(4), 1–43. <https://doi.org/10.1007/s10462-024-10721-6>
- Zhao, Y., Lv, W., Xu, S., Wei, J., Wang, G., Dang, Q., Liu, Y., & Chen, J. (2024). *DETRs Beat YOLOs on Real-time Object Detection*. <https://zhao-yian.github.io/RTDETR>
- Zhou, S., Jiang, X., Tan, W., He, R., & Yan, B. (2023). MVFlow: Deep Optical Flow Estimation of Compressed Videos with Motion Vector Prior. *MM 2023 - Proceedings of the 31st ACM International Conference on Multimedia*, 1964–1974. <https://doi.org/10.1145/3581783.3611750>