

**KLASIFIKASI KARAKTER PLAT NOMOR KENDARAAN
MENGUNAKAN *FASTER REGION-BASED CONVOLUTIONAL
NEURAL NETWORK* (FASTER R-CNN)**

(Skripsi)

Oleh

**NUR MITA UTAMI
2017051058**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

**KLASIFIKASI KARAKTER PLAT NOMOR KENDARAAN
MENGUNAKAN *FASTER REGION-BASED CONVOLUTIONAL
NEURAL NETWORK* (FASTER R-CNN)**

Oleh

NUR MITA UTAMI

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
2024**

**Judul Skripsi : KLASIFIKASI KARAKTER PLAT NOMOR
KENDARAAN MENGGUNAKAN FASTER
REGION-BASED CONVOLUTIONAL NEURAL
NETWORK (FASTER R-CNN)**

Nama Mahasiswa : Nur Mita Utami

Nomor Pokok Mahasiswa : 2017051058

Program Studi : S1 Ilmu Komputer

Jurusan : Ilmu Komputer

Fakultas : Matematika dan Ilmu Pengetahuan Alam

MENYETUJUI

1. Komisi Pembimbing

Pembimbing Utama

Pembimbing Kedua

**Favorisen R. Lumbanraja, Ph.D.
NIP. 19830110 200812 1 002**

**Ridho Sholehurrohman, M.Mat.
NIP. 232111970128101**

2. Ketua Jurusan Ilmu Komputer


**Dwi Sakethi, S.Si., M.Kom.
NIP. 19680611 199802 1 001**

MENGESAHKAN

1. Tim Penguji

Ketua

: Favorisen R. Lumbanraja, Ph.D.




Sekretaris Penguji

: Ridho Sholehurrohman, M.Mat.




Penguji Utama

: Dr. rer. Nat. Akmal Junaidi, M. Sc.



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Heri Satria, S.Si., M.Si.
NIP. 19711001 200501 1 002

Tanggal Lulus Ujian Skripsi : 19 Desember 2024

RIWAYAT HIDUP



Penulis dilahirkan di Kabupaten Lampung Barat Kecamatan Air Hitam, Sumber Alam pada tanggal 07 Juni 2001, sebagai anak kedua dari 3 bersaudara, dari Bapak Mukhlisin dan Nur Khasanah. Penulis menyelesaikan pendidikan formal di SDN 01 Sumber Alam dan selesai pada tahun 2014. Kemudian pendidikan menengah pertama di SMPN 01 Air Hitam yang diselesaikan pada tahun 2017, lalu melanjutkan ke pendidikan menengah atas di SMAN 01 Way Tenong yang diselesaikan pada tahun 2020. Pada tahun 2020 penulis terdaftar sebagai mahasiswa Jurusan Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur SBMPTN. Selama menjadi mahasiswa, penulis melakukan beberapa kegiatan antara lain.

1. Menjadi anggota Bidang Keilmuan Himpunan Mahasiswa Jurusan Ilmu Komputer periode 2022/2023.
2. Melaksanakan Kerja Praktek pada bulan Juni 2022/2023 periode II di Biro Perencanaan dan Hubungan Masyarakat Universitas Lampung.
3. Melaksanakan Kuliah Kerja Nyata Desa Bumi Harjo, Kecamatan Buay Bahuga, Kabupaten Way Kanan pada tahun 2022/2023 periode 1 dengan program kerja Bimbingan Teknologi dan Sosialisasi Cerdas Teknologi Informasi kepada siswa/i SMPN 01 Bumi Harjo.

PERNYATAAN

Saya yang bertanda tangan di bawah ini :

Nama : Nur Mita Utami

NPM : 2017051058

Menyatakan bahwa skripsi saya yang berjudul “**Klasifikasi Karakter Plat Nomor Kendaraan Menggunakan Faster *Region-Based Convolutional Neural Network* (FASTER R-CNN)**” merupakan karya saya sendiri dan bukan karya orang lain. Semua 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, 02 Juni 2025

Penulis,



Nur Mita Utami

NPM. 2017051058

MOTO

“Sesungguhnya Allah tidak akan menyia-nyiakan pahala orang yang berbuat baik.”

(QS. Hud: 115)

“Barang siapa bersabar, maka Allah akan menjadikannya sabar.”

(HR. Bukhari & Muslim)

“Setiap kesulitan yang datang hari ini akan menjadi bagian dari kisah keberhasilan. Yang pernah sulit akan menjadi bukti bahwa kita mampu bertahan dan melangkah lebih jauh.”

(Mita)

PERSEMBAHAN

Alhamdulillahirobbilalamin

Puji dan Syukur tercurahkan kepada Allah Subhanahu Wa Ta'ala atas segala Rahmat dan Karunia-Nya sehingga saya dapat menyelesaikan skripsi ini. Shalawat serta salam selalu tercurahkan Kepada Nabi Muhammad SAW.

Kupersembahkan karya ini kepada:

Kedua orang tua penulis, dan seluruh keluarga besar penulis yang telah kebersamai serta membantu penulis untuk menyelesaikan skripsi ini, juga untuk diri saya pribadi yang telah berhasil menyelesaikan pendidikan di Ilmu Komputer Universitas Lampung.

SANWACANA

Syukur Alhamdulillah penulis panjatkan kepada Allah SWT atas limpahan berkah, rahmat, serta hidayah-Nya, dan juga atas tuntunan serta teladan dari Rasulullah Nabi Muhammad Sholallahu Alaihi Wasallam, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Klasifikasi Karakter Plat Nomor Kendaraan Menggunakan Faster *Region-Based Convolutional Neural Network* (FASTER R-CNN)” dengan baik dan lancar.

Dalam proses penelitian ini, sangat banyak orang-orang yang terlibat dalam pelaksanaannya. Oleh sebab itu, penulis mengucapkan terima kasih yang sebesar besarnya kepada:

1. Allah Subhanahu Wa Ta’ala yang telah memberikan nikmat kesehatan dan kemampuan untuk menyelesaikan skripsi ini.
2. Kedua orang tua serta adik dan kakak tercinta yang memberi dukungan, doa, semangat, motivasi dan kasih sayang yang tiada terhingga. Semua yang telah kalian berikan begitu berharga dan tak akan pernah bisa kubalas sepenuhnya. Semoga Allah SWT senantiasa melimpahkan kebahagiaan dan keberkahan dalam hidup kalian, baik di dunia maupun di akhirat.
3. Bapak Dr. Eng. Heri Satria, S.Si., M.Si., selaku Dekan FMIPA Universitas Lampung
4. Bapak Dwi Sakethi, S.Si., M.Kom. selaku ketua Jurusan Ilmu Komputer FMIPA Universitas Lampung.
5. Ibu Yunda Heningtyas, S.Kom., M.Kom. selaku Sekretaris Jurusan Ilmu Komputer FMIPA Universitas Lampung.

6. Bapak Favorisen R. Lumbanraja, Ph.D. sebagai Dosen Pembimbing Utama yang telah memberikan yang sangat bermanfaat dalam penyempurnaan skripsi ini.
7. Bapak Ridho Sholehurrohman, M.Mat. sebagai Dosen Pembimbing 2 yang telah memberikan arahan, ide, motivasi, kritik serta saran berharga, sehingga penulis dapat menyelesaikan skripsi ini dengan baik.
8. Bapak Dr. rer. Nat. Akmal Junaidi, M. Sc. sebagai Dosen Pembahas yang telah memberikan masukan penting dalam perbaikan skripsi ini, serta selaku Dosen Pembimbing Akademik penulis yang telah memberikan bimbingan dan arahan kepada penulis selama proses studi.
9. Ibu Ade Nora Maela, Mas Samanto dan Mas Naufal yang telah membantu segala urusan administrasi penulis di Jurusan Ilmu Komputer.
10. Bapak dan Ibu Dosen Jurusan Ilmu Komputer FMIPA Universitas Lampung yang telah memberikan ilmu dan pengalaman hidup untuk menjadi lebih baik.
11. Teman-teman saya yang selalu memberikan dukungan, semangat serta kebersamaan dan menjadi tempat bertukar pikiran.

Penulis menyadari bahwa skripsi ini masih memiliki kekurangan dan jauh dari kata sempurna. Namun, penulis berharap semoga karya ini dapat memberikan manfaat serta keberkahan bagi seluruh civitas Ilmu Komputer Universitas Lampung. Aamiin Ya Rabbal 'Aalamiin.

Bandar Lampung, 02 Juni 2025

Penulis,



Nur Mita Utami

NPM. 2017051058

ABSTRAK

KLASIFIKASI KARAKTER PLAT NOMOR KENDARAAN MENGUNAKAN *FASTER REGION-BASED CONVOLUTIONAL NEURAL NETWORK* (FASTER R-CNN)

Oleh

NUR MITA UTAMI

Kendaraan bermotor merupakan alat transportasi yang paling banyak digunakan di Indonesia. Seiring bertambahnya jumlah kendaraan di Indonesia, muncul tantangan baru seperti kecelakaan lalu lintas, pelanggaran lalu lintas, hingga kejahatan yang melibatkan kendaraan. Oleh Karena itu salah satu upaya penanganan masalah tersebut adalah membangun dan mengimplementasikan sistem transportasi cerdas atau sering disebut *Intelligent Transportation System* (ITS). Setiap kendaraan memiliki tanda nomor kendaraan bermotor (TNKB). Dengan memanfaatkan data plat nomor kendaraan, ITS digunakan untuk membantu mengidentifikasi informasi seseorang dari plat nomor kendaraannya. Berbagai teknik *Deep Learning* telah banyak diimplementasikan untuk meningkatkan keakuratan dan efisiensi teknologi *recognition plate*. Salah satu model dalam *Deep Learning* yang dikembangkan untuk klasifikasi objek pada citra adalah *Faster region-Based Convolutional Neural Network* (Faster R-CNN). Faster R-CNN terdiri dari dua modul utama, yaitu *Deep Fully Convolutional Network* yang mengandung *Region Proposal Network* (RPN) dan Fast R-CNN sebagai detektor. Penelitian ini mengimplemetasikan Faster R-CNN dengan fitur ekstraktor ResNet-50 untuk klasifikasi karakter pada citra plat nomor kendaraan. Informasi yang 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 5 wilayah kabupaten/kota. Hasil evaluasi menunjukkan hasil yang sangat baik dengan akurasi rata-rata dari kelima kelas sebesar sebesar 94,59%, diikuti *precision* sebesar 86,90%, *recall* 86,48%, dan *F1-score* 86,44%.

Kata kunci: *Deep Learning*, Faster R-CNN, Plat Nomor Kendaraan, ResNet50.

ABSTRACT

CLASSIFICATION OF VEHICLE NUMBER PLATE CHARACTERS USING FASTER REGION-BASED CONVOLUTIONAL NEURAL NETWORK (FASTER R-CNN)

By

NUR MITA UTAMI

Motor vehicles are the most widely used means of transportation in Indonesia. As the number of vehicles in Indonesia increases, new challenges emerge, such as traffic accidents, traffic violations and crimes involving vehicles. Therefore, one effort to deal with this problem is to build and implement an intelligent transportation system or often called an Intelligent Transportation System (ITS). Each vehicle has a motor vehicle registration number (TNKB). By utilizing vehicle number plate data, ITS is used to help identify a person's information from their vehicle number plate. Various Deep Learning techniques have been implemented to increase the accuracy and efficiency of plate recognition technology. One of the Deep Learning models developed for classifying objects in images is the Faster Region-Based Convolutional Neural Network (Faster R-CNN). Faster R-CNN consists of two main modules, namely Deep Fully Convolutional Network which contains Region Proposal Network (RPN) and Fast R-CNN as a detector. This research implements Faster R-CNN with the ResNet-50 feature extractor for character classification in vehicle number plate images. The information identified on the number plate includes the provincial area code, vehicle number plate serial number, city/district area code, as well as the month and year the vehicle number plate is valid, with an evaluation focus on 5 district/city areas. The evaluation results show very good results with an average accuracy of the five classes of 94.59%, followed by precision of 86.90%, recall of 86.48%, and F1-score of 86.44%.

Keywords: *Deep Learning, Faster R-CNN, Vehicle Number Plate, ResNet50.*

DAFTAR ISI

Halaman

DAFTAR ISI.....	v
DAFTAR GAMBAR.....	vii
DAFTAR TABEL	viii
DAFTAR KODE PROGRAM	ix
I. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah.....	4
1.4 Tujuan	4
1.5 Manfaat	5
II. TINJAUAN PUSTAKA	6
2.1 Penelitian Terdahulu	6
2.2 Plat Nomor Kendaraan.....	8
2.3 Pengolahan Citra Digital.....	8
2.4 Video Digital.....	10
2.5 <i>Resize Image</i>	10
2.6 <i>Artificial Intelligence (AI)</i>	11
2.7 <i>Machine Learning</i>	12
2.8 <i>Deep Learning</i>	12
2.9 Operasi Konvolusi.....	13
2.9 <i>Convolutional Neural Network (CNN)</i>	15
2.9.1 <i>Convolution Layer</i>	16
2.9.2 <i>Pooling Layer</i>	17
2.9.3 <i>Fully-Connected Layer</i>	18
2.10 <i>Faster Region-Based Convolutional Neural Network (Faster R-CNN)</i> 19	
2.10.1 <i>Region Proposal Network (RPN)</i>	21

2.10.2	<i>Region of Interest (RoI)</i>	22
2.11	<i>Residual Network (ResNet)</i>	23
2.12	<i>Confusion matrix</i>	24
III.	METODE PENELITIAN	28
3.1	Waktu dan Tempat	28
3.1.1	Tempat Penelitian	28
3.1.2	Waktu Penelitian.....	28
3.2	Alat Pendukung.....	29
3.2.1	Perangkat Keras (<i>Hardware</i>)	29
3.2.2	Perangkat Lunak (<i>Software</i>).....	29
3.3	Tahapan Penelitian	32
3.3.1	Pengumpulan Data	32
3.3.2	Anotasi Data.....	33
3.3.3	<i>Pre-Processing</i>	33
3.3.4	<i>Training Model</i>	34
3.3.5	<i>Plate Extraction</i>	35
3.3.6	<i>Group Contouring</i>	35
3.3.7	<i>Intersection over Union (IoU)</i>	36
3.3.8	<i>Classification</i>	36
3.3.9	Evaluasi.....	36
3.3.10	Analisis Kinerja Model	37
IV.	PEMBAHASAN	38
4.1	Desain Arsitektur Faster R-CNN-ResNet-50.....	38
4.2	Pengambilan Data	39
4.3	<i>Pre-processing</i>	42
4.3.1	<i>Cropping dan Resizing</i>	42
4.3.2	Anotasi Data.....	43
4.3.3	Pembagian Data	44
4.3.4	Augmentasi Data.....	45
4.4	<i>Hyperparameter Tuning</i>	47
4.5	<i>Training Model</i>	48
4.6	Hasil <i>Training Model</i>	49
4.6.1	Hasil <i>Training 1</i>	50

4.6.2	Hasil <i>Training</i> 2	51
4.6.3	Hasil <i>Training</i> 3	52
4.6.4	Hasil <i>Training</i> 4	53
4.6.5	Hasil <i>Training</i> 5	55
4.6.6	Hasil <i>Training</i> 6	56
4.6.7	Hasil <i>Training</i> 7	57
4.6.8	Hasil <i>Training</i> 8	58
4.6.9	Hasil <i>Training</i> 9	59
4.7	<i>Testing</i> Model	62
4.8	Evaluasi Model.....	64
4.8.1	Evaluasi Hasil Pengujian Deteksi	64
4.8.2	Evaluasi Hasil Pengujian Klasifikasi	68
4.9	Analisis Hasil	71
V.	KESIMPULAN	74
5.1	Simpulan	74
5.2	Saran.....	75
	DAFTAR PUSTAKA	76

DAFTAR GAMBAR

Gambar	Halaman
1. Representasi Citra (Hendrawaty dkk., 2021).	10
2. Representasi <i>Resize Image</i>	11
3. Keterkaitan AI, ML dan <i>Deep Learning</i> (Zaharchuk dkk., 2018).....	12
4. Lapisan <i>Deep Learning</i> (Kurniawan & Irfantoro, 2020).	13
5. Ilustrasi Operasi Konvolusi (Affifah dkk., 2022).	15
6. Arsitektur CNN (Alimin & Riyadi, 2019).	16
7. <i>Convolution Layer</i> (Muhammad & Wibowo, 2021).	17
8. <i>Pooling Layers</i> (Qorik dkk., 2020).	18
9. <i>Fully Connected Layer</i> (Sulistyo Budi et al., 2021).....	19
10. Arsitektur Faster R-CNN (Pardede & Hardiansah, 2022).....	21
11. Ilustrasi Letak Anchor (Octavia, 2020).	22
12. Arsitektur ResNet-50 (Berliani dkk., 2023).	23
13. Struktur Tahapan Penelitian.	32
14. Arsitektur Faster R-CNN-ResNet-50.	38
15. Ilustrasi Pengambilan Data 1.....	40
16. Ilustrasi Pengambilan Data 2.....	41
17. Ilustrasi Pengambilan Data 3.....	41
18. Contoh Citra Hasil <i>Cropping</i> dan <i>Resizing</i>	42
19. Pembuatan <i>Bounding box</i>	44
20. Citra Hasil Augmentasi rotasi 10°	46
21. Citra Hasil Augmentasi rotasi -10°	47
22. Grafik <i>Training Epoch 40 Learning rate 0,01</i>	50
23. Grafik <i>Training Epoch 40 Learning rate 0,001</i>	51
24. Grafik <i>Training Epoch 40 Learning rate 0,0001</i>	52
25. Grafik <i>Training Epoch 80 Learning rate 0,01</i>	54

26. Grafik <i>Training Epoch 80 Learning rate 0,001</i>	55
27. Grafik <i>Training Epoch 80 Learning rate 0,0001</i>	56
28. Grafik <i>Training Epoch 120 Learning rate 0,01</i>	57
29. Grafik <i>Training Epoch 120 Learning rate 0,001</i>	58
30. Grafik <i>Training Epoch 120 Learning rate 0,0001</i>	60
31. Hasil <i>Testing</i> Faster R-CNN-ResNet-50 Gambar 1.	63
32. Hasil <i>Testing</i> Faster R-CNN-ResNet-50 Gambar 2.	64
33. Visualisasi <i>Anchor Box</i> dan <i>Ground Truth</i>	65
34. Ilustrasi Perhitungan IoU.	66
35. Grafik Rata-Rata Nilai IoU.	66
36. <i>Confusion matrix</i> Evaluasi Klasifikasi.	68
37. Plat nomor Lampung Tengah Tulisan Buram.....	71
38. Plat nomor Lampung Timur Sudut Pengambilan Miring.....	72

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terdahulu Terkait Faster R-CNN.....	6
2. Contoh <i>Confusion matrix Multi-Class</i> (Grandini dkk., 2020).....	25
3. Alur Waktu Pelaksanaan Penelitian.	28
4. Alat Pendukung (Perangkat Keras).	29
5. Hasil Augmentasi.....	45
6. Nilai <i>Hyperparameter Tuning</i>	47
7. Hasil <i>Training</i> Faster R-CNN-ResNet-50	61
8. Hasil <i>Testing</i> Faster R-CNN-ResNet-50.....	69
9. Evaluasi Klasifikasi Faster R-CNN- ResNet-50.....	69

DAFTAR KODE PROGRAM

Kode Program	Halaman
1. <i>Cropping</i> dan <i>Resizing Image</i>	43
2. Augmentasi rotasi 10° dan -10°	46
3. <i>Training</i> Model.....	48
4. Evaluasi Model.....	49

I. PENDAHULUAN

1.1 Latar Belakang

Alat transportasi darat yang paling umum digunakan di Indonesia adalah kendaraan bermotor. Fenomena ini tergambar dari pertumbuhan jumlah kendaraan bermotor yang terus meningkat di kalangan masyarakat. Menurut data yang disajikan oleh Badan Pusat Statistik, jumlah kendaraan di Indonesia terus mengalami peningkatan setiap tahunnya. Pada tahun 2021, total kendaraan di Indonesia mencapai angka 141.992.573 unit kendaraan (BPS, 2021). Seiring dengan peningkatan ini, muncul pula tantangan baru terkait dengan kecelakaan lalu lintas, pelanggaran lalu lintas, hingga kejahatan yang melibatkan kendaraan. Diperlukan upaya berbasis ilmu pengetahuan yang memanfaatkan teknologi canggih untuk mengatasi permasalahan tersebut, salah satunya adalah dengan membangun serta mengimplementasikan sistem transportasi cerdas atau yang sering disebut dengan *Intelligent Transportation System* (ITS).

Setiap kendaraan memiliki tanda nomor kendaraan bermotor (TNKB). TNKB merupakan tanda registrasi kendaraan bermotor berupa plat nomor, yang dikeluarkan oleh Polri dengan spesifikasi tertentu. Plat nomor kendaraan memuat kode wilayah, nomor registrasi, dan masa berlaku yang dipasang pada kendaraan sebagai identitas serta bukti legalitas pengoperasiannya (Oeliga & Afita, 2021). Informasi pada plat nomor kendaraan dapat digunakan untuk mendukung optimalisasi ITS. Dengan memanfaatkan teknologi pengenalan karakter plat nomor, ITS dapat secara efisien melacak pergerakan kendaraan, memantau aktivitas transportasi, dan menganalisis pola-pola perjalanan.

Data yang diperoleh dari plat nomor kendaraan dapat digunakan untuk mengelola parkir, meningkatkan efisiensi operasional transportasi publik, bahkan dapat mendukung penegakan hukum dalam hal penemuan kendaraan yang dicuri atau terlibat dalam tindak kriminal. Dengan memanfaatkan potensi data plat nomor kendaraan, ITS dapat memberikan manfaat yang signifikan bagi masyarakat dan pemerintah dalam menghadapi tantangan transportasi di era modern. Oleh karena itu, teknologi dalam pengenalan karakter plat nomor kendaraan (*recognition plate*) memiliki peran penting dalam mengoperasikan berbagai aspek ITS.

Seiring dengan perkembangan teknologi, banyak sistem yang mulai menerapkan teknologi *recognition plate*, mulai dari sistem keamanan, identifikasi kendaraan, monitoring lalu lintas, hingga pembayaran tol dan parkir. Berbagai teknik *Deep Learning* telah banyak diimplementasikan untuk meningkatkan keakuratan dan efisiensi teknologi *recognition plate*. *Deep Learning* merupakan sub bidang dari kecerdasan buatan dan *Machine Learning* yang mengembangkan *neural network multiple layer* untuk meningkatkan akurasi tugas seperti deteksi objek, pengenalan suara, penerjemah bahasa dan lainnya (Raup dkk., 2022). Salah satu model dalam *Deep Learning* yang dikembangkan untuk klasifikasi objek pada citra adalah *Faster region-Based Convolutional Neural Network* (Faster R-CNN).

Faster R-CNN adalah algoritma pendeteksian objek dalam *computer vision* berbasis jaringan konvolusi, dan merupakan perkembangan dari algoritma CNN. Faster R-CNN terdiri dari dua modul utama, yaitu *Deep Fully Convolutional Network* yang mengandung *Region Proposal Network* (RPN) dan Fast R-CNN sebagai detektor (Ramadhani dkk., 2023). RPN memiliki peran menghasilkan *bounding boxes* yang memungkinkan klasifikasi objek lebih akurat. Sedangkan, Fast R-CNN bertanggung jawab mengambil *bounding boxes* dari RPN dan melakukan deteksi untuk mendapatkan klasifikasi objek dengan lebih mendetail. Gabungan kedua modul ini

menciptakan model yang dapat melakukan deteksi untuk klasifikasi objek dengan akurasi yang tinggi.

Pada penelitian oleh Yedidiya dkk. (2023), dilakukan perbandingan metode YOLO dan Faster R-CNN untuk deteksi dan pengenalan kendaraan, terbukti bahwa Faster R-CNN lebih unggul dalam hal akurasi dan prediksi. Faster R-CNN menghasilkan prediksi lebih tinggi karena mampu mendapatkan *region of interest* dengan lebih baik pada gambar yang akan diprediksi. Didapatkan akurasi prediksi rata-rata tertinggi Faster R-CNN 74,545% pada *epoch* 75. Sementara akurasi tertinggi YOLO hanya 43,887% pada *epoch* 50. Penelitian lain oleh Susanto dkk. (2019), yang menggunakan metode Faster R-CNN untuk pengenalan karakter pada plat nomor Indonesia. Hasil pengujian pada dataset peneliti mendapatkan akurasi deteksi karakter pada plat nomor sebesar 82,14%.

Selanjutnya, penelitian yang dilakukan oleh Omar dkk. (2020) menunjukkan bahwa metode deteksi plat nomor kendaraan menggunakan model gabungan Faster R-CNN dengan tiga model CNN yang telah dilatih sebelumnya, yaitu AlexNet, VGG16, dan VGG19. Pada penelitian ini, hasil dari setiap model digabungkan untuk memperbaiki akurasi deteksi. Dataset publik LPDatabase yang terdiri dari 502 gambar kendaraan dari berbagai kondisi lingkungan digunakan dalam penelitian. Hasil penelitian menunjukkan bahwa model gabungan mampu mencapai tingkat akurasi deteksi plat nomor sebesar 97%.

Berdasarkan pemaparan di atas, penelitian ini akan mengimplementasikan Faster R-CNN untuk melakukan klasifikasi karakter pada plat nomor kendaraan. Pada penelitian ini akan dilakukan evaluasi menyeluruh dan pengujian kinerja model Faster R-CNN dalam mengklasifikasi karakter pada plat nomor kendaraan. Evaluasi akan melibatkan metrik *accuracy*, *precision*, *recall*, dan *F1-Score*.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan sebelumnya, maka rumusan masalah yang menjadi fokus dalam penelitian ini adalah sebagai berikut :

1. Bagaimana mengimplementasikan Faster R-CNN untuk deteksi dan klasifikasi karakter pada plat nomor kendaraan?
2. Bagaimana analisis kinerja Faster R-CNN pada klasifikasi karakter plat nomor kendaraan?

1.3 Batasan Masalah

Adapun batasan masalah dari penelitian ini adalah sebagai berikut :

1. Penelitian ini akan menggunakan bahasa pemrograman python dengan mengimplementasikan Faster R-CNN.
2. Dalam penelitian ini data diambil pada siang hari dengan kondisi pencahayaan yang baik.
3. 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 5 wilayah kabupaten/kota.
4. Fokus penelitian ini adalah area parkir motor Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Universitas Lampung.
5. Penelitian ini mencakup plat nomor kendaraan dengan warna dasar hitam dan putih.

1.4 Tujuan

Adapun tujuan dari penelitian ini adalah :

1. Mengimplementasikan Faster R-CNN untuk klasifikasi karakter pada citra plat nomor kendaraan.

2. Melakukan evaluasi dan pengujian kinerja model Faster R-CNN dalam mengklasifikasikan karakter pada citra plat nomor kendaraan dilihat dari *accuracy, precision, recall* dan *F1-Score*.

1.5 Manfaat

Adapun manfaat yang diharapkan dari penelitian ini adalah :

1. Mengetahui hasil akurasi, evaluasi dan pengujian kinerja Faster R-CNN dalam mengklasifikasi karakter pada plat nomor kendaraan.
2. Penelitian ini diharapkan memberikan kontribusi dalam pengembangan model klasifikasi karakter pada plat nomor kendaraan yang lebih efisien.
3. Memberikan referensi untuk pengembangan sistem cerdas otomatis untuk mendukung *Intelligent Transportation System (ITS)*.
4. Sebagai rujukan aparat kepolisian guna meningkatkan efisiensi dalam mengungkap kejahatan dan kriminalitas yang melibatkan kendaraan.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Penelitian ini merujuk pada penelitian-penelitian sebelumnya yang bertujuan untuk mendukung penelitian ini. Tabel 1 berikut menunjukkan beberapa penelitian yang digunakan sebagai referensi dalam penelitian.

Tabel 1. Penelitian Terdahulu Terkait Faster R-CNN.

Judul Penelitian	Metode	Data	Hasil Akurasi
Pengenalan Karakter pada Plat Nomor Indonesia dengan <i>Tilt Correction</i> dan Metode Faster R-CNN (Susanto dkk., 2019)	<i>Canny Edge Detection</i> , <i>Planar Homography</i> , Faster R-CNN	535 gambar mobil dengan 36 kelas (A-Z, 0-9)	Akurasi rata-rata deteksi karakter pada plat nomor sebesar 82,14%
<i>Fused Faster RCNNs for efficient detection of the license plates</i> (Omar dkk., 2020)	Faster R-CNN (AlexNet, VGG16, dan VGG19)	Dataset mencakup 502 gambar kendaraan dari LPDatabase dengan satu kelas yaitu plat nomor	<i>Fused</i> model (AlexNet, VGG16, dan VGG19) didapatkan akurasi sebesar 97%

<i>Balinese Script Handwriting Recognition Using Faster R-CNN</i> (Pratama dkk., 2023)	Faster R-CNN (ResNet-50, ResNet-101, ResNet-152, dan Inception ResNet V2)	253 gambar tulisan tangan aksara bali dari 25 penulis, dengan 28 kelas (18 konsonan dan 10 digit)	mAP tertinggi 0,991 pada IoU 0,5 untuk model ResNet-50 dan Inception ResNet V2
<i>Deep Learning Based Moving Vehicle Classification And Counting Using Faster R-CNN Method</i> (Octavia, 2020)	Faster R-CNN dengan arsitektur Resnet50	3 video dengan 5 kelas yaitu <i>Car</i> , <i>Motorbike</i> , <i>Bus</i> , <i>Truk</i> , <i>Bicycle</i>	Klasifikasi rata-rata nilai akurasi sebesar 87,55% pada lalu lintas padat dan 90,85% untuk lalu lintas sedang

Penelitian-penelitian dalam Tabel 1 menunjukkan penggunaan metode *Deep Learning*, khususnya *Convolutional Neural Networks* (CNN) seperti Faster R-CNN, yang terbukti efektif untuk berbagai tugas klasifikasi dan pengenalan karakter. Penelitian oleh Susanto dkk. (2019) dan Pratama dkk. (2023) menggunakan Faster R-CNN untuk pengenalan karakter dan berhasil mencapai akurasi tinggi. Dalam tugas lain, seperti deteksi kendaraan dalam video, pada penelitian Octavia (2020) Faster R-CNN dengan arsitektur ResNet telah digunakan untuk mengklasifikasikan jenis kendaraan dalam berbagai kondisi lalu lintas, menunjukkan kemampuan model ini dalam menangani variasi sudut pandang. Penelitian ini, akan mengimplementasikan model Faster R-CNN untuk melakukan klasifikasi

karakter pada plat nomor kendaraan, Faster R-CNN dipilih berdasarkan kemampuannya yang andal dalam mendeteksi objek dan akurat dalam klasifikasi karakter.

2.2 Plat Nomor Kendaraan

Plat nomor kendaraan adalah sebuah identifikasi wajib yang harus digunakan pada setiap kendaraan bermotor. Penggunaan plat nomor kendaraan sudah ada sejak masa pemerintahan Hindia Belanda, dimana sistem tersebut didasarkan pada wilayah keresidenan. Plat kendaraan bermotor dipisahkan berdasarkan lokasi geografisnya, yakni kabupaten dan kota, serta diidentifikasi melalui penggunaan huruf *alphabet* yang terletak di bagian depan dan belakang plat nomor (Hanif dkk., 2023). Selain sebagai identifikasi, plat nomor kendaraan juga memiliki peranan penting dalam proses administrasi, penegakan hukum, dan pengamanan kendaraan.

2.3 Pengolahan Citra Digital

Citra atau gambar merupakan representasi objek visual dalam bentuk susunan dua dimensi yang terdiri dari sejumlah piksel. Piksel, sebagai elemen dasar dari citra, merupakan titik-titik kecil yang membentuk gambar digital. Setiap piksel pada citra memiliki informasi tentang warna (*hue*), intensitas warna (*saturation*) dan kecerahan (*brightness*), yang menghasilkan variasi warna dan kejelasan yang berbeda (Christian & Idrus, 2023). Proses pengolahan piksel pada citra digital disebut dengan pengolahan citra digital (*image processing*). Tujuan pengolahan citra digital adalah untuk mengubah atau meningkatkan kualitas citra guna melakukan pendeteksian objek yang menjadi *interest* dan pengekstraksi fitur-fiturnya dengan lebih mudah (Fitriyah & Wihandika, 2021).


Berdasarkan nilai pikselnya, citra digital terbagi menjadi tiga jenis (Sholehurrohman, 2021) :

1. Citra Biner : Citra yang hanya memiliki dua intensitas, yaitu hitam dan putih. Piksel hitam direpresentasikan dengan nilai 1, sementara piksel putih direpresentasikan dengan nilai 0.
2. Citra Grayscale : Citra yang nilai intensitas pikselnya berkisar dalam satu *layer* keabuan, dimana rentang nilai tersebut adalah 0 hingga 255. Pada skala ini, nilai 0 menunjukkan warna hitam, sementara nilai 255 mempresentasikan warna putih. Dengan rentang nilai ini, Citra Grayscale mampu merepresentasikan berbagai tingkat kecerahan dari warna abu-abu hingga hitam atau putih, dengan beragam tingkat keabuan.
3. Citra Warna (RGB) : Citra yang terdiri dari tiga *layer*, yaitu Red, Green, dan Blue. Setiap *layer* memiliki rentang nilai antara 0 hingga 255 (8-bit).

Suatu citra digital dengan ukuran matriks $M \times N$ dapat dinyatakan sebagai matriks berukuran $M-1 \times N-1$ yaitu (Sholehurrohman, 2021):

$$f(x, y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0, N-1) \\ f(1,0) & f(1,1) & \dots & f(1, N-1) \\ \vdots & \vdots & f(1 \dots, 1) & \vdots \\ f(M-1,0) & f(M-1,1) & \dots & f(M-1, N-1) \end{bmatrix}$$

$M \times N$ di atas menyatakan resolusi citra, M merupakan baris dan N adalah kolom. Nilai $f(x, y)$ menyatakan nilai intensitas pixel pada posisi (x, y) yang dinamakan dengan *graylevel* (derajat keabuan). Gambar 1 berikut adalah representasi citra digital berwarna yang terdiri dari komponen merah, hijau, dan biru dengan intensitas *pixel* pada setiap posisi.



Gambar 1. Representasi Citra (Hendrawaty dkk., 2021).


2.4 Video Digital

Video merupakan rangkaian *frame* citra (koordinat spasial 2 dimensi) yang direkam oleh sensor dalam jangka waktu tertentu. Biasanya, perekaman video dilakukan dengan kecepatan antara 25 hingga 30 *frame* per detik (*fps*). Terdapat dua jenis video, yaitu video analog dan video digital. Video digital adalah representasi informasi melalui rangkaian citra yang diakuisisi dan ditampilkan sesuai dengan ukuran *frame*, *frame rate*, serta sistem pemindaian yang digunakan. Hampir semua sistem video digital menggunakan representasi komponen sinyal warna. Sebagian besar kamera video berwarna menghasilkan *output* RGB (*Red*, *Green*, *Blue*), yang kemudian didigitalkan secara terpisah untuk setiap *channel* warnanya (Octavia, 2020).

2.5 *Resize Image*

Mengubah dimensi gambar merupakan langkah penting dalam pengolahan citra digital. *Resize image* merupakan proses yang melibatkan pengubahan ukuran citra menjadi lebih besar atau lebih kecil dari ukuran aslinya. Tujuannya adalah untuk mengurangi beban komputasi pada perangkat, terutama ketika metode deteksi objek yang digunakan sangat kompleks dan membutuhkan ruang penyimpanan yang besar (Mega Saraswati dkk.,


2023). *Resizing* bekerja dengan mengubah jumlah piksel dalam citra. Semakin sedikit piksel yang digunakan, semakin kecil ukuran file gambar, dan semakin cepat waktu yang dibutuhkan untuk memproses citra tersebut (Anggraeni & Widyassari, 2022). Representasi *resize image* terdapat pada Gambar 2 berikut.



Gambar 2. Representasi *Resize Image*.

2.6 Artificial Intelligence (AI)

Artificial Intelligence (AI) atau Kecerdasan Buatan adalah teknologi yang dirancang untuk memungkinkan sistem komputer meniru kemampuan intelektual manusia. *Artificial intelligence* memungkinkan komputer untuk mempelajari pengalaman, mengenali pola, mengambil keputusan, dan menyelesaikan tugas-tugas yang kompleks secara cepat dan efisien (Stinka dkk., 2023). *Artificial Intelligence* menggunakan kemampuan komputasi seperti *Machine Learning*, *Deep Learning*, dan pengolahan bahasa alami yang canggih untuk secara cerdas mengumpulkan, menganalisis, dan menginterpretasikan data (Nurkholis dkk., 2023). Gambar 3 berikut menggambarkan bagaimana keterkaitan antara AI, ML dan *Deep Learning*.



Gambar 3. Keterkaitan AI, ML dan *Deep Learning*
(Zaharchuk dkk., 2018).

2.7 *Machine Learning*


Machine Learning merupakan cabang ilmu dari *Artificial Intelligence* yang berfokus pada pembelajaran otomatis oleh komputer menggunakan data (Amrullah & Pane, 2023). *Machine Learning* melakukan penerapan komputer dan algoritma matematika yang menggunakan data sebagai dasar untuk memperoleh pembelajaran dan menghasilkan prediksi di masa mendatang. Proses pembelajaran ini melibatkan dua tahapan, yaitu pelatihan (*Training*) dan pengujian (*Testing*), yang memiliki tujuan untuk meningkatkan kecerdasan sistem (Roihan dkk., 2019).

Fokus utama dari *Machine Learning* adalah bagaimana algoritma atau mesin dapat secara otomatis mengidentifikasi pola yang kompleks dan membuat keputusan berdasarkan data yang telah dijadikan dasar pembelajaran sebelumnya. Arthur Samuel pada tahun 1959, mendefinisikan *Machine Learning* sebagai disiplin ilmu yang memungkinkan sistem untuk memperoleh kemampuan belajar tanpa memerlukan pemrograman secara eksplisit (H. Pratama dkk., 2020).

2.8 *Deep Learning*

Deep Learning merupakan cabang dari kecerdasan buatan dan *Machine Learning* yang merupakan evolusi dari *neural network multiple layer*, yang bertujuan untuk meningkatkan akurasi dalam deteksi objek, pengenalan

suara, penerjemah bahasa, dan sebagainya (Raup dkk., 2022). *Deep Learning* mengolah data kompleks secara bertingkat melalui banyak *layer*. Lapisan-lapisan tersembunyi (*hidden layer*) dalam model *Deep Learning* mirip dengan cara kerja *neuron* di otak manusia, yang mengolah data secara non-linear untuk mempelajari representasi data dari tingkat rendah hingga tingkat tinggi (konsep abstrak) secara otomatis, sehingga memungkinkan model untuk mempelajari pola-pola rumit dalam data tanpa diprogram secara spesifik tentang pola apa yang harus dicari (Megawati & Mulyana, 2023). Gambar 4 berikut adalah gambaran mengenai lapisan-lapisan dalam *Deep Learning*.



Gambar 4. Lapisan *Deep Learning* (Kurniawan & Irfantoro, 2020).

Dalam *Deep Learning*, jaringan syaraf memiliki tiga lapisan utama diantaranya *input layer* yang menerima data masukan, *beberapa hidden layer* untuk mengolah untuk mengolah dan mengekstraksi fitur-fitur penting, dan *output layer* yang menghasilkan prediksi atau hasil akhir.

2.9 Operasi Konvolusi

Operasi konvolusi adalah suatu operasi matematika yang mengkombinasikan dua fungsi untuk menghasilkan fungsi baru. Dalam pengolahan citra digital, operasi ini berlaku dalam bentuk diskrit karena nilai koordinat piksel citra digital bersifat diskrit atau terpisah. Konvolusi

diskrit melibatkan penggunaan dua fungsi, yaitu fungsi citra (*input*) dan fungsi kernel (*filter*) (Setiyono dkk., 2023).

Operasi konvolusi pada fungsi diskrit diilustrasikan dalam Persamaan (1) berikut (Setiyono dkk., 2023) :

$$h(x) = f(x) * g(x) = \sum_{a=-\infty}^{\infty} f(a)g(x-a) \quad (1)$$

Karena operasi konvolusi yang digunakan melibatkan dua peubah atau dimensi, maka bentuk persamaan operasi konvolusi diskritnya disesuaikan dengan melibatkan penjumlahan ganda terhadap dua indeks sebagaimana ditunjukkan pada Persamaan (2) berikut :

$$h(x) = f(x) * g(x) = f(x) = \sum_{a=-\infty}^{\infty} \sum_{b=-\infty}^{\infty} f(a,b)g(x-a,y-b) \quad (2)$$

Keterangan :

* = Operasi konvolusi


a, b = Peubah bantu (*dummy variable*)

$f(x)$ = Fungsi *input*

$g(x)$ = Fungsi kernel (*filter*)

$h(x)$ = Hasil operasi konvolusi

Operasi ini dilakukan untuk setiap piksel pada citra dengan menggeser kernel pada setiap titik piksel, sehingga menghasilkan citra baru yang telah dimodifikasi sesuai dengan tujuan pengolahan citra yang diinginkan. Ilustrasi operasi kovolusi terdapat pada Gambar 5 berikut.




Gambar 5. Ilustrasi Operasi Konvolusi (Affifah dkk., 2022).

2.9 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah sebuah metode pembelajaran dalam bidang kecerdasan yang dikhususkan untuk mengenali dan memproses data visual seperti gambar atau citra. CNN termasuk ke dalam kategori *deep feed-forward artificial neural network*, yang merupakan sebuah jaringan saraf tiruan (*artificial neural network*) dengan beberapa lapisan tersembunyi (*deep*) dan informasi yang mengalir hanya ke satu arah (*feed-forward*). CNN banyak digunakan untuk tugas-tugas yang melibatkan analisis citra, seperti pengenalan objek, deteksi wajah, atau klasifikasi gambar (Hibatullah & Maliki, 2019).

Dalam CNN, terdapat beberapa lapisan (*layer*) yang berfungsi sebagai *filter* untuk mengolah gambar atau citra selama proses pelatihan (*Training*). Proses *Training* ini terdiri dari tiga tahapan utama yaitu *Convolutional Layer*, *Pooling Layer*, dan *Fully Connected Layer* (Santoso & Ariyanto, 2018). Gambar 6 berikut menggambarkan proses dari *Convolutional Neural Network* (CNN).




Gambar 6. Arsitektur CNN (Alimin & Riyadi, 2019).

2.9.1 Convolution Layer

Convolution Layer atau lapisan konvolusi adalah tahap awal dalam proses *Convolutional Neural Network* (CNN). *Convolution Layer* merupakan salah satu operasi matematika yang digunakan dalam pengolahan citra atau gambar digital. Pada operasi ini, melibatkan proses matematika yang mengambil *input* berupa citra dan menghasilkan *output* yang disebut dengan *feature map*. *Input* dan *output* ini dapat dipandang sebagai dua argumen bernilai riil atau nilai nyata. (Gunawan dkk., 2024).

Dalam proses konvolusi, setiap data yang masuk ke lapisan konvolusional akan melewati serangkaian *filter* (*kernel size*). *Filter* ini memiliki panjang, tinggi (*pixels*) dan tebal yang menyesuaikan dengan data *input*. *Filter* akan bergeser secara bertahap di seluruh area data *input*, melakukan operasi “*dot product*” antara nilai *filter* dengan nilai-nilai di area data *input* tersebut. Hasilnya adalah *activation map* atau *feature map* yang merepresentasikan informasi penting seperti tepi, tekstur, dan bentuk pada gambar. (Santoso & Ariyanto, 2018). Proses *Convolution Layer* ditunjukkan pada Gambar 7 berikut.




Gambar 7. *Convolution Layer* (Muhammad & Wibowo, 2021).

2.9.2 *Pooling Layer*

Pooling Layer merupakan lapisan diantara *Convolution Layer* dalam arsitektur CNN. Pooling layer berfungsi mereduksi dimensi *output* pada *feature map* agar komputasi pada lapisan berikutnya berjalan lebih cepat (Denata dkk., 2021). *Pooling Layer* mengambil *feature map* sebagai *input* dan melakukan operasi statistik seperti *max pooling* atau *average pooling* pada piksel-piksel terdekat. *Pooling Layer* disisipkan secara berkala untuk mengurangi ukuran volume *output* pada *feature map*, mengurangi parameter dan komputasi, serta mencegah *overfitting*. (Mbaba dkk., 2022).

Pooling Layer menggunakan *filter* dengan ukuran dan *stride* tertentu yang bergeser pada seluruh *area feature map* atau *activation map*, di mana jumlah pergeseran ditentukan oleh nilai *stride*. Dalam praktiknya, dua jenis operasi *pooling* yang sering digunakan adalah *max pooling* dan *average pooling*. Sebagai contoh, apabila menggunakan *filter max pooling* berukuran 2×2 dengan *stride* 2, maka pada setiap pergeseran *filter*, nilai maksimum dalam area 2×2 tersebut akan diambil sebagai *output*, sedangkan untuk *average pooling*, nilai yang diambil adalah rata-rata dalam area 2×2 pada setiap pergeseran *filter* (Santoso & Ariyanto, 2018). Gambar 8 menunjukkan proses *Pooling Layer*, dengan *Max Pooling* yang


mengambil nilai maksimum dan *Average Pooling* yang mengambil rata-rata dari setiap *kernel* pada area data input.



Gambar 8 *Pooling Layers* (Qorik dkk., 2020).

2.9.3 *Fully-Connected Layer*

Fully-Connected Layer pada arsitektur CNN berfungsi sebagai penghubung neuron dari lapisan-lapisan sebelumnya dan bertujuan untuk melakukan transformasi dimensi data agar dapat diklasifikasikan secara linear atau dengan seoptimal mungkin (Sandi dkk., 2022). Perbedaan antara *Fully-Connected Layer* dan *Convolution Layer* biasa adalah bahwa neuron dalam *Convolution Layer* hanya terhubung ke wilayah tertentu, sementara dalam *Fully-Connected Layer*, neuron terhubung secara keseluruhan (Denata dkk., 2021). Ilustrasi arsitektur *Fully Connected Layer* dapat dilihat pada Gambar 9 berikut.



Gambar 9. *Fully Connected Layer* (Sulistyo Budi et al., 2021).

2.10 *Faster Region-Based Convolutional Neural Network (Faster R-CNN)*

Region-based Convolutional Neural Network (R-CNN) merupakan algoritma deteksi objek berbasis jaringan konvolusi yang dikembangkan di bidang *computer vision*. Pada awalnya, R-CNN diperkenalkan pada tahun 2015 sebagai algoritma yang mengombinasikan *Region Proposal Network* (RPN) dan CNN untuk mendeteksi objek. Seiring waktu, R-CNN terus disempurnakan guna meningkatkan performa, baik dari segi kecepatan maupun akurasi, dalam pendeteksian objek menjadi Fast R-CNN. Namun, R-CNN maupun Fast R-CNN masih mempunyai kekurangan, salah satunya adalah adanya *bottleneck*, yaitu kompleksitas perhitungan *region proposal* pada RPN yang tidak dapat menyamai kecepatan komputasi pada CNN (Megawan & Lestari, 2020).


Untuk mengatasi masalah *bottleneck* tersebut, dikembangkan *Faster Region-based Convolutional Neural Network* (Faster R-CNN) yang merupakan metode deteksi objek pada citra yang mengombinasikan Fast R-CNN dan RPN sebagai arsitektur utamanya. Berbeda dengan Fast R-CNN yang menggunakan *selective search* untuk mengusulkan *region*, Faster R-CNN menggantikan proses tersebut dengan *Region Proposal Network* (RPN) yang secara efisien mengusulkan *region* (Az zahra dkk., 2023). Menerapkan RPN sebagai pengganti *selective search* dapat

mengurangi beban komputasi secara signifikan dan memungkinkan pelatihan model secara *end-to-end* (Megawan & Lestari, 2020).

Faster R-CNN terdiri dari dua bagian penting (Khumaidi dkk., 2022):

1. *Region Proposal Network* (RPN) : RPN bertujuan untuk secara cepat mengeksplorasi kemungkinan lokasi objek dalam gambar yang dimasukkan. Lokasi objek yang dimasukkan memiliki batasan objek dari wilayah yang diidentifikasi yang disebut RoI. *Input* yang digunakan pada lapisan RoI adalah *feature map* yang merupakan *output* dari CNN dengan *multiple convolution* dan *max pooling*. Pada RPN, awalnya *input* diproses dalam *neural convolution* untuk menghasilkan *feature map* yang terdiri dari 6 bagian, yaitu penentuan objek dan bukan objek dengan nilai 0-1, koordinat nilai x dan y, serta nilai lebar dan tinggi *bounding box*. *Sliding window* dengan ukuran $N \times N$, ditempatkan pada setiap *feature map* sesuai dengan setiap *anchor sliding window* yang terbentuk. Setiap *anchor* memiliki titik pusat yang sama tetapi memiliki *aspect ratios* dan *scaling factor* yang berbeda.
2. *Classification* : *classification* digunakan untuk mengklasifikasikan RoI yang dideteksi oleh RPN ke dalam kelas objek yang sesuai, dengan menggunakan CNN.

Arsitektur Faster R-CNN yang terdiri dari *conv layers* hingga *classifier* ditunjukkan pada Gambar 11 berikut.




Gambar 10. Arsitektur Faster R-CNN (Pardede & Hardiansah, 2022).

2.10.1 Region Proposal Network (RPN)

Region Proposal Network (RPN) adalah sebuah pendekatan yang digunakan untuk mengidentifikasi area atau wilayah potensial yang mengandung objek dalam sebuah gambar dengan cara yang lebih efisien. Tujuan utama dari RPN adalah mengurangi kebutuhan komputasi yang berlebihan secara signifikan, sehingga memungkinkan proses deteksi objek dapat dilakukan secara end-to-end dalam satu model yang terintegrasi dan terlatih secara bersamaan (Nando dkk., 2021).

RPN terdiri dari *classifier* dan *regressor*. RPN memprediksi keberadaan objek pada setiap *anchor*, yang merupakan area dengan rasio dan skala tertentu (1:1, 2:1, 1:2, serta skala 128, 256, 512). Setiap titik di dalam matriks gambar bertindak sebagai pusat *anchor*. *Classifier* dan *regressor* pada RPN mengevaluasi sembilan kemungkinan proposal area dari setiap *anchor* untuk mendeteksi keberadaan objek (Ramdhan, 2021). Ilustrasi letak anchor dapat dilihat pada Gambar 12.



Gambar 11. Ilustrasi Letak Anchor (Octavia, 2020).

Pada Faster R-CNN, RPN menggantikan peran *selective search* yang digunakan pada Fast R-CNN. RPN memiliki dua fungsi utama. Pertama, mengidentifikasi *region* yang berpotensi mengandung objek dalam citra tanpa mempertimbangkan kelas objek tertentu. Kedua, menyesuaikan koordinat *bounding box* dengan posisi *anchor* agar lebih akurat dan sesuai dengan bentuk objek yang akan diprediksi (Ramdhan, 2021).


2.10.2 *Region of Interest (RoI)*

Region of Interest (RoI) adalah teknik yang memungkinkan pemrosesan citra terfokus hanya pada wilayah atau area yang dianggap penting, tanpa harus memproses keseluruhan gambar. Pendekatan ini memberikan beberapa manfaat, seperti mengurangi waktu komputasi, mengoptimalkan penyimpanan data, dan memfasilitasi pengambilan keputusan yang lebih akurat dengan memusatkan perhatian pada bagian citra yang relevan. RoI bekerja dalam pengkodean area tertentu dari citra digital secara berbeda, sehingga area penting akan memiliki kualitas yang lebih baik dibandingkan area sekitarnya (Pratomo dkk., 2020).

2.11 Residual Network (ResNet)

Residual Network (ResNet) adalah arsitektur jaringan saraf yang diperkenalkan oleh He dan rekan-rekannya pada tahun 2015 untuk mengatasi masalah *vanishing gradients*, di mana gradien menjadi terlalu kecil saat melewati banyak lapisan, sehingga jaringan sulit dilatih. ResNet menggunakan *skip connections*, yang memungkinkan beberapa lapisan dilewati, sehingga jaringan dapat belajar lebih baik dengan mempelajari selisih (residual) antara input dan output. Hal ini memungkinkan pelatihan jaringan yang jauh lebih dalam dengan kinerja yang lebih baik. Hasil eksperimen dengan dataset ImageNet menunjukkan bahwa semakin banyak lapisan dalam arsitektur ResNet, semakin rendah error selama pelatihan dan semakin tinggi akurasi yang dicapai (He dkk., 2016).

Penelitian He dkk menguji berbagai arsitektur ResNet pada dataset besar. Mereka menemukan beberapa model yang optimal, seperti ResNet-18, ResNet-34, ResNet-50, ResNet-101, dan ResNet-152, yang berbeda dalam jumlah *layer* (He dkk., 2016). Penelitian ini akan fokus pada implementasi ResNet-50. ResNet-50 merupakan jenis ResNet, yang terdiri dari 50 lapis neural. Model ini telah menjalani proses pembelajaran ekstensif menggunakan setidaknya satu juta citra dari repositori ImageNet. Strukturnya terdiri dari lima segmen utama, masing-masing mengandung blok konvolusional dan *identity block*. Blok konvolusional memiliki dua lapisan konvolusi, sedangkan *identity block* memiliki tiga konvolusi (Berliani dkk., 2023). Gambar 13 berikut merupakan arsitektur ResNet-50.



Gambar 12. Arsitektur ResNet-50 (Berliani dkk., 2023).

2.12 *Confusion matrix*

Confusion matrix adalah sebuah metode yang digunakan untuk mengevaluasi kinerja klasifikasi dengan cara menyajikan data dalam bentuk tabel. Tabel tersebut menampilkan jumlah data uji yang diklasifikasikan dengan benar dan salah, sehingga memudahkan dalam mengevaluasi akurasi suatu sistem klasifikasi. Dengan menggunakan *confusion matrix*, dapat dilihat dengan detail seberapa baik sistem klasifikasi bekerja serta di mana letak kesalahan klasifikasinya (Nurhidayat & Dewi, 2023).

Confusion matrix merupakan metode yang krusial dalam evaluasi klasifikasi multi-kelas, di mana matriks ini diperluas menjadi bentuk persegi dengan jumlah baris dan kolom sesuai dengan jumlah kelas dalam dataset. Empat istilah utama yang digunakan dalam *confusion matrix* adalah *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN). TP adalah kasus di mana prediksi model sesuai dengan kelas sebenarnya, FP terjadi ketika model memprediksi kelas salah sebagai benar, TN mencakup prediksi yang benar di mana sampel tidak termasuk dalam kelas yang dianalisis, sementara FN adalah kegagalan model memprediksi kelas yang benar (Grandini dkk., 2020). Contoh *confusion matrix* dalam klasifikasi multi-kelas terdapat pada Tabel 2 berikut.

Tabel 2. Contoh *Confusion matrix Multi-Class* (Grandini dkk., 2020).

		<i>Predicted</i>				
		<i>Class A</i>	<i>Class B</i>	<i>Class C</i>	<i>Class D</i>	Total
<i>Actual</i>	<i>Class A</i>	6	0	1	2	9
	<i>Class B</i>	3	9	1	1	14
	<i>Class C</i>	1	0	10	2	13
	<i>Class D</i>	1	2	1	12	16
	Total	11	11	13	17	52

Dalam contoh tabel di atas:

- *True Positive* (TP) untuk kelas A adalah 6, yaitu jumlah *instance* kelas A yang diprediksi dengan benar sebagai A.
- *False Positive* (FP) untuk kelas A adalah 5, yaitu jumlah *instance* dari kelas lain yang salah diprediksi sebagai A.
- *True Negative* (TN) mencakup semua *instance* yang bukan kelas A dan juga tidak diprediksi sebagai A.
- *False Negative* (FN) untuk kelas A adalah 3, yang berarti 3 *instance* dari kelas A salah diprediksi sebagai kelas lain.

Evaluasi model klasifikasi menggunakan *confusion matrix* memberikan informasi lebih lanjut mengenai kinerja klasifikasi, dengan menyajikan nilai-nilai seperti *accuracy*, *recall*, *precision*, dan *f1-score*. Dengan demikian, *confusion matrix* menjadi alat penting dalam menilai performa sistem klasifikasi, memungkinkan pemahaman yang lebih baik tentang seberapa baik model tersebut dapat mengklasifikasikan data (Afrillia dkk., 2022).

a. Akurasi

Akurasi adalah ukuran yang menggambarkan seberapa baik model atau algoritma dalam membuat prediksi yang benar, baik prediksi positif maupun negatif, berdasarkan keseluruhan data yang digunakan. Rentang akurasi berada antara 0 hingga 1, semakin tinggi nilai akurasi, semakin baik kinerja algoritma atau model yang digunakan dalam sistem (Sulistyo Budi dkk., 2021). Akurasi dinyatakan dalam Persamaan (3) berikut.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

b. Presisi

Presisi adalah rasio antara jumlah prediksi positif yang benar dengan total prediksi positif yang dilakukan oleh suatu model. Presisi mengindikasikan seberapa tepat model tersebut dalam memprediksi kejadian positif dari suatu rangkaian kegiatan prediksi (Sulistyo Budi dkk., 2021). Persamaan matematis untuk presisi dinyatakan dalam Persamaan (4) berikut.

$$Precision = \frac{TP}{TP+FP} \quad (4)$$

c. Recall

Recall, atau yang juga dikenal sebagai *True Positive* (TP), adalah ukuran yang digunakan untuk menggambarkan seberapa baik citra berhasil diidentifikasi dengan benar. *Recall* mengukur kemampuan model untuk mendeteksi semua kasus yang relevan atau benar, tanpa memperhatikan seberapa banyak hasil yang salah terdeteksi (Sulistyo Budi dkk., 2021) persamaan matematis untuk *recall* dinyatakan dalam Persamaan (5) berikut.

$$Recall = \frac{TP}{TP+FN} \quad (5)$$

d. *F1-Score*

F1-score adalah ukuran yang menggabungkan nilai *recall* dan *precision* menjadi satu variabel baru, mencerminkan keseimbangan antara kemampuan model dalam mendeteksi kasus yang relevan dan kemampuan dalam membuat prediksi yang tepat (Sulistyo Budi dkk., 2021). Persamaan *F1-score* ditunjukkan pada Persamaan (6) berikut.

$$F1-Score = 2 \times \frac{Recall \times Presisi}{Recall + Presisi} \quad (6)$$

III. METODE PENELITIAN

3.1 Waktu dan Tempat

3.1.1 Tempat Penelitian

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

3.1.2 Waktu Penelitian

Penelitian ini dilakukan pada awal semester genap sampai akhir semester genap dengan perkiraan waktu Bulan Februari 2024 hingga Bulan Juni 2024.

Tabel 3. Alur Waktu Pelaksanaan Penelitian.

[illegible]

3.2 Alat Pendukung

3.2.1 Perangkat Keras (*Hardware*)

Perangkat keras yang digunakan dalam penelitian ini ditunjukkan dalam Tabel 4 berikut.

Tabel 4. Alat Pendukung (Perangkat Keras).

No	Perangkat	Spesifikasi
1	Laptop	• Laptop: VivoBook • Processor: Intel® Core™ i5-1135G7 • Penyimpanan: SSD 512GB • RAM: 8 GB DDR4 • GPU: Intel Iris Xe Graphics
2	Smarttphone	• Penyimpanan internal : 64GB • Prosesor : <i>Chip A12 Bionic</i> • Kamera : 12 MP Wide • Format gambar : HEIF dan JPEG • Sistem fokus : Fokus otomatis dengan Focus Pixels

3.2.2 Perangkat Lunak (*Software*)

a. Sistem operasi *Windows 11 Home Single Language 64-bit*

Sebagai platform utama untuk menjalankan seluruh perangkat lunak yang diperlukan dalam penelitian. Sistem operasi ini menyediakan lingkungan yang diperlukan untuk mengeksekusi program-program yang digunakan dalam pengolahan data, pelatihan model, dan pengujian model (Widayati dkk., 2023).

b. *Visual Studio Code* versi 1.83.1

Editor kode sumber yang digunakan untuk menulis, mengedit, dan menjalankan kode program dalam penelitian. Editor ini memungkinkan untuk pengembangan dan modifikasi kode *Python* yang digunakan dalam implementasi Faster R-CNN (Hartati, 2020).

c. *Python* versi 3.9.0

Python adalah bahasa pemrograman yang digunakan dalam penelitian ini. Versi *Python* yang digunakan adalah 3.9.0. *Python* dipilih karena memiliki banyak perpustakaan yang mendukung pengembangan *Machine Learning* dan *Deep Learning*, yang diperlukan dalam implementasi model Faster R-CNN (Sambi dkk., 2023).

d. *Packages*

1) OpenCV 4.10.0

Perpustakaan (*library*) yang berfokus pada pengolahan citra dan visi komputer. OpenCV menyediakan beragam fungsi untuk menangani gambar dan video, seperti deteksi objek, pengenalan wajah, transformasi gambar, dan analisis video. Dalam penelitian ini, OpenCV digunakan untuk melakukan operasi pengolahan citra seperti *cropping* dan *resizing* (Muchtar & Apriadi, 2019).

2) EasyOCR 1.7.2

EasyOCR adalah *library* yang menyediakan OCR (*Optical Character Recognition*) *multilanguages*, yang merupakan teknologi pengenalan teks yang mampu mendeteksi dan

mengeksrak teks dari gambar atau dokumen dalam berbagai bahasa (Kholis dkk., 2022).

3) CRAFT

Craft merupakan *library* yang dapat melakukan *refining contouring* pada sebuah *text*. *Library* ini menggunakan *PyTorch* untuk mendeteksi fitur-fitur dari sebuah *text* kemudian melakukan meningkatkan kualitas *bounding box* dari *text* tersebut (Sugeng & Husaini, 2023).

4) Matplotlib 3.7.1

Matplotlib adalah *library* komprehensif untuk menciptakan visualisasi grafik yang interaktif pada bahasa pemrograman *python* (Kaestria dkk., 2024).

5) Numpy 1.26.4

Numpy merupakan *library* fundamental yang memudahkan bekerja dengan array. *Library* ini menyediakan kemudahan untuk membuat *multidimensional array object*, operasi statistik yang efisien (Putra dkk., 2023).

6) Sklearn 1.5.2

Sklearn adalah sebuah *module library python* yang dikhususkan untuk operasi *Machine Learning*. *Library* ini sangat membantu dalam operasi dasar seperti operasi *confusion matriks*, *accuracy*, *precision*, labelling dan sebagainya (Darmawan & Dianta, 2023).


7) Tensorflow versi 2.15

Tensorflow adalah *library* yang wajib digunakan dalam sebuah *project Machine Learning*. *Library* ini menyediakan

berbagai alat dan fungsi yang membantu pengembangan, pelatihan, dan evaluasi model *Machine Learning* dengan mudah (Nugroho dkk., 2020).

3.3 Tahapan Penelitian

Struktur metodologi penelitian Deteksi Karakter Plat Nomor Kendaraan Menggunakan *Faster Region-Based Convolutional Neural Network* (Faster R-CNN) ditunjukkan pada Gambar 14 berikut.



Gambar 13. Struktur Tahapan Penelitian.

3.3.1 Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah data primer berupa citra atau gambar plat nomor kendaraan. Citra atau gambar tersebut diambil secara langsung pada siang hari yang cerah dengan kondisi pencahayaan yang baik menggunakan kamera *smartphone*. Pengambilan gambar dilakukan di area parkir motor Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Universitas Lampung pada pukul 11.00 - 14.00 WIB. Data citra yang digunakan

memiliki ekstensi JPG atau JPEG (*Joint Photographic Experts Group*)

3.3.2 Anotasi Data

Untuk melakukan pelatihan model dengan menggunakan metode *Deep Learning* berbasis konvolusi, citra *Training* perlu dilabeli atau dianotasi. Pada tahap ini, setiap karakter pada plat nomor dalam citra diberi label dengan membuat kotak pembatas (*bounding box*) di sekitar karakter tersebut dan menandainya dengan label yang sesuai.

3.3.3 Pre-Processing

Pre-processing adalah tahap yang dikerjakan untuk mempersiapkan data agar klasifikasi karakter plat nomor kendaraan dapat berjalan secara optimal. Tahap ini terdiri dari tiga proses utama, yaitu *cropping* dan *resize image*, serta anotasi data.

a. *Cropping* dan *Resizing*

Cropping dan *resizing* dilakukan untuk menyesuaikan ukuran citra agar sesuai dengan persyaratan *input* model, menghasilkan dimensi yang seragam, dan memastikan sistem hanya memproses area yang relevan. Pada Faster R-CNN, pada citra akan di lakukan proses *cropping* dan *resizing* sehingga memiliki ukuran *input* 600×600 piksel.

b. Pembagian Dataset

Setelah proses anotasi, selanjutnya adalah membagi dataset tersebut menjadi tiga bagian dengan menggunakan teknik *simple random sampling*. Teknik ini akan membagi dataset secara acak, yaitu data latih (*Training dataset*), data validasi (*validation dataset*), dan data uji (*Testing dataset*) dengan pembagian

80:10:10. Data latih digunakan untuk melatih model, sementara data validasi digunakan untuk mengevaluasi performa model. Setelah model dianggap cukup baik berdasarkan evaluasi pada data validasi, model tersebut diuji lagi menggunakan data uji untuk mendapatkan evaluasi akhir terhadap performa model.

c. Augmentasi Data

Tahapan *pre-processing* yang selanjutnya adalah augmentasi data. Pada tahap ini, dilakukan penambahan variasi data secara buatan dengan tujuan meningkatkan jumlah dan keragaman dataset. Teknik augmentasi yang digunakan adalah rotasi 10° dan -10° . Dengan adanya augmentasi tersebut, diharapkan dapat meningkatkan kemampuan generalisasi model dengan baik.

3.3.4 Training Model

Tahapan *Training* merupakan proses di mana model mempelajari pola dari dataset yang diberikan untuk mengoptimalkan kemampuannya dalam mengklasifikasi dan mengenali karakter pada citra. Pada tahap *Training* model Faster R-CNN, data latih digunakan untuk melatih model, sementara data validasi digunakan untuk mengevaluasi kinerja model secara berkala selama pelatihan.

Model Faster R-CNN dilatih dengan menggunakan ResNet-50 sebagai *backbone* untuk ekstraksi fitur dari gambar plat nomor. Fitur yang diekstraksi ini kemudian dimasukkan ke dalam *Region Proposal Network* (RPN), yang bertugas mengidentifikasi wilayah potensial yang berisi objek (plat nomor). RPN mengusulkan beberapa wilayah yang diidentifikasi sebagai plat nomor, yang kemudian akan diproses lebih lanjut menggunakan RoI (*Region of Interest*) *Pooling*.

Output dari proses ini adalah prediksi koordinat *bounding box* yang menunjukkan lokasi plat nomor dalam gambar, serta klasifikasi yang menentukan area tersebut merupakan plat nomor atau bukan. Selama pelatihan, model dioptimasi menggunakan data latih, dan bobot yang dihasilkan dari pelatihan ini digunakan untuk mengklasifikasikan plat nomor pada data uji.

Dalam proses *Training* dan akurasi prediksi model dipengaruhi oleh *hyperparameter*. *Hyperparameter* ini adalah parameter yang mengendalikan proses pelatihan model dan memiliki pengaruh besar terhadap kinerja serta akurasi prediksi model.

3.3.5 *Plate Extraction*

Tahap *plate extraction* dimulai dengan memanfaatkan model Faster R-CNN yang telah dilatih sebelumnya, di mana bobot (*weight*) hasil pelatihan menjadi komponen utama. Data uji (*Testing data*) yang belum pernah dilihat oleh model sebelumnya digunakan sebagai *input*. Model yang telah dilatih kemudian diterapkan pada data uji ini melalui tahap *Testing* model. Dalam tahap ini, model Faster R-CNN dengan fitur ekstraktor ResNet-50 sebagai *backbone* melakukan deteksi terhadap plat nomor dalam citra.

3.3.6 *Group Contouring*

Setelah citra plat nomor berhasil diekstraksi, proses selanjutnya adalah *group contouring*. Pada tahap ini, setiap karakter yang terdapat pada plat nomor akan dikenali berdasarkan kontur dari citra yang telah dipotong menggunakan model CRAFT (*Character Region Awareness for Text Detection*). CRAFT bekerja dengan mendeteksi area teks dan mengidentifikasi wilayah-wilayah kecil di sekitar setiap karakter, sehingga kontur teks dapat dikenali. Setelah kontur karakter terdeteksi, karakter-karakter tersebut

dikelompokkan ke dalam beberapa kategori, yaitu grup provinsi, seri, kota, bulan, dan tahun.

3.3.7 *Intersection over Union (IoU)*

Tahap selanjutnya adalah menghitung *Intersection over Union* (IoU) untuk setiap grup karakter yang telah dikelompokkan. IoU digunakan untuk mengukur tingkat kesesuaian antara prediksi model dan *ground truth* dalam dataset. Proses ini dilakukan dengan cara membandingkan area yang diprediksi oleh model dengan area sebenarnya yang telah diberi label pada dataset. Nilai IoU dihitung untuk masing-masing grup, termasuk grup provinsi, seri, kota, bulan, dan tahun. Perhitungan IoU membantu menentukan tingkat akurasi deteksi model pada setiap kategori.

3.3.8 *Classification*

Pada tahap klasifikasi *city group*, karakter yang telah diidentifikasi diklasifikasikan menjadi lima kelas, yaitu Lampung Timur, Lampung Tengah, Pesawaran, Tulang Bawang dan Bandar Lampung. Model Faster R-CNN yang telah dilatih sebelumnya digunakan untuk melakukan klasifikasi. Proses klasifikasi melibatkan analisis fitur dari setiap karakter yang telah melalui tahap kontur, di mana model menentukan kelas yang paling sesuai berdasarkan karakteristik visual karakter tersebut.

3.3.9 *Evaluasi*

Langkah selanjutnya adalah melakukan evaluasi untuk mengukur performa model dalam melakukan deteksi dan klasifikasi karakter plat nomor kendaraan. Untuk mengukur tingkat keberhasilan deteksi dalam penelitian ini, digunakan metrik evaluasi IoU (*Intersection*

over Union), sedangkan untuk mengukur tingkat keberhasilan klasifikasi evaluasi dilakukan dengan menghitung beberapa metrik, yaitu *accuracy*, *precision*, *recall*, dan *f1-score*. *Accuracy* menunjukkan seberapa dekat prediksi model dengan nilai aktual, *precision* mengukur ketepatan identifikasi objek atau kelas yang benar, *recall* mengukur kelengkapan model dalam identifikasi, sementara *F1-score* menggabungkan *precision* dan *recall* menjadi satu nilai evaluasi untuk memberikan gambaran kinerja model secara keseluruhan. Metrik-metrik evaluasi ini dihitung secara matematis berdasarkan nilai *true positive*, *true negative*, *false positive*, dan *false negative* yang dihasilkan dari proses *Testing*.

3.3.10 Analisis Kinerja Model

Hasil evaluasi metrik seperti *accuracy*, *precision*, *recall*, dan *f1-score* akan diinterpretasikan dan dianalisis secara mendalam. Kekuatan dan kelemahan model dalam mengklasifikasikan berbagai jenis karakter atau kondisi plat nomor akan diidentifikasi, serta penyebab keberhasilan dan kegagalannya. Berdasarkan analisis tersebut, peluang perbaikan model akan diusulkan. Selain itu pada proses ini akan mengkaji mengenai kendala dan keterbatasan penelitian yang dapat memengaruhi kinerja model.

V. KESIMPULAN

5.1 Simpulan

Berdasarkan hasil penelitian dan evaluasi yang telah dilakukan, beberapa kesimpulan dapat diambil terkait kinerja model Faster R-CNN dengan fitur ekstraktor ResNet-50 dalam klasifikasi karakter pada plat nomor kendaraan adalah sebagai berikut :

1. Penelitian ini berhasil mengimplementasikan metode Faster R-CNN dengan fitur ekstraktor ResNet-50 untuk deteksi karakter pada plat nomor kendaraan, yang mencakup kelompok plat, provinsi, kabupaten, bulan, dan tahun. Selain itu, model juga berhasil melakukan klasifikasi grup karakter pada grup kabupaten dengan lima kelas, yaitu Lampung Timur, Lampung Tengah, Pesawaran, Tulang Bawang, dan Bandar Lampung.
2. Evaluasi kinerja model Faster R-CNN menunjukkan hasil yang baik pada metrik *accuracy* dengan nilai rata-rata mencapai 94,59%, *precision* 86,90%, *recall* 86,48%, dan *F1-score* 86,44%. Meskipun demikian, performa model menunjukkan variasi yang signifikan pada beberapa kelas, terutama pada kelas Lampung Tengah dan Lampung Timur, yang dipengaruhi oleh faktor kualitas visual data dan sudut pengambilan gambar. Hal ini mengindikasikan perlunya peningkatan kualitas data, untuk mengoptimalkan kinerja model pada kondisi serupa di masa yang akan datang.

5.2 Saran

Berdasarkan hasil penelitian ini, terdapat beberapa rekomendasi yang dapat diambil untuk pengembangan lebih lanjut.:

1. Menambahkan variasi dataset yang mencakup berbagai kondisi pencahayaan, sudut pengambilan gambar, jarak pengambilan data, dan jenis plat nomor kendaraan dari berbagai wilayah di Indonesia.
2. Menerapkan metode anotasi per karakter, yang akan memberikan detail lebih spesifik dan akurasi yang lebih baik dalam pendeteksian setiap karakter secara individual.
3. Mengembangkan sistem berbasis android yang mampu melakukan deteksi objek secara *real-time*.
4. Perlunya penelitian lebih lanjut untuk mengeksplorasi hubungan antara skor mAP (*mean Average Precision*) dan efektivitas dalam ekstraksi karakter pada plat nomor, guna meningkatkan akurasi deteksi model.

DAFTAR PUSTAKA

- Affifah, D. D., Permanasari, Y., Matematika, R. P., Matematika, F., Ilmu, D., & Alam, P. (2022). Teknik Konvolusi pada Deep Learning untuk Image Processing. *Bandung Conference Series: Mathematics* , 2(2), 103–112. <https://doi.org/10.29313/bcsm.v2i2.4527>
- Afrillia, Y., Rosnita, L., & Siska, D. (2022). Analisis Sentimen Ciutan Twitter Terkait Penerapan Permendikbudristek Nomor 30 Tahun 2021 Menggunakan TextBlob dan Support Vector Machine. *G-Tech: Jurnal Teknologi Terapan*, 6(2), 387–394. <https://doi.org/10.33379/gtech.v6i2.1778>
- Alimin, & Riyadi, S. (2019). Sistem Pengembangan Deteksi Kanker Prostat Berbasis Image Processing dengan Metode Convolutional Neural Network. *Jurnal Keilmuan dan Aplikasi Teknik Informatika*, 14(2), 52–63. <https://doi.org/10.35891/explorit>
- Amrullah, M. S., & Pane, S. F. (2023). Systematic Literature Review : Analisa Sentimen Masyarakat terhadap Penerapan Peraturan ETLE. *Journal of Applied Computer Science and Technology (JACOST)*, 4(1), 2723–1453. <https://doi.org/10.52158/jacost.493>
- Anggraeni, A., & Widyassari, A. P. (2022). Deteksi Plat Nomor Menggunakan Connected Components dan Pra-Pengolahan untuk Mempercepat Proses Deteksi. *Generation Journal*, 6(2), 2580–4952.
- Az zahra, S., Sarifah, W. N., Elfaris, F., Rustamto, D. F., & Rosyani, P. (2023). Kendaraan Deteksi Pengenalan Kendaraan Menggunakan Metode Fast R-CNN. *Jurnal Artificial Inteligent dan Sistem Penunjang Keputusan*, 1(2), 166–171. <https://jurnalmahasiswa.com/index.php/aidanspk>

- Berliani, T., Rahardja, E., & Septiana, L. (2023). Perbandingan Kemampuan Klasifikasi Citra X-ray Paru-paru menggunakan Transfer Learning ResNet-50 dan VGG-16. *Journal of Medicine and Health*, 5(2), 123–135. <https://doi.org/10.28932/jmh.v5i2.6116>
- BPS. (2021). *Perkembangan Jumlah Kendaraan Bermotor Menurut Jenis (Unit)*. Badan Pusat Statistik. <https://www.bps.go.id/id/statistics-table/2/NTcjMg==/number-of-motor-vehicle-by-type.html>
- Christian, J., & Idrus, S. I. Al. (2023). Introduction to Citrus Fruit Ripens Using the Deep Learning Convolutional Neural Network (CNN) Learning Method. *Asian Journal of Applied Education (AJAE)*, 2(3), 459–470. <https://doi.org/10.55927/ajae.v2i3.5003>
- Darmawan, Z. M. E., & Dianta, A. F. (2023). Implementasi Optimasi Hyperparameter GridSearchCV Pada Sistem Prediksi Serangan Jantung Menggunakan SVM. *Teknologi*, 13(1), 8–15. <https://doi.org/10.26594/teknologi.v13i1.3098>
- Denata, I., Rismawan, T., & Ruslianto, I. (2021). Implementation of Deep Learning for Classification Type of Orange Using The Method Convolutional Neural Network. *Jurnal Informatika dan Teknologi Informasi*, 18(3), 297–307. <https://doi.org/10.31515/telematika.v18i3.5541>
- Grandini, M., Bagli, E., & Visani, G. (2020). Metrics for Multi-Class Classification: an Overview. *International Journal of Data Mining & Knowledge Management Process (IJDKP)*, 5(2), 9–12.
- Gunawan, R., Hanafie, D. M. I., & Elanda, A. (2024). Klasifikasi Jenis Ras Kucing Dengan Gambar Menggunakan Convolutional Neural Network (CNN). *Jurnal Interkom: Jurnal Publikasi Ilmiah Bidang Teknologi Informasi dan Komunikasi*, 18(4), 1–8. <https://doi.org/10.35969/interkom.v18i4.318>
- 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), 109–116. <https://doi.org/10.23960/jitet.v11i1.2897>
- Hartati, S. (2020). Perancangan Sistem Informasi Inventaris Barang Pada Kantor Notaris dan PPAT R.A Lia Kholila, S.H Menggunakan Visual Studio Code. *Jurnal Siskomti*, 3(2), 37–47. <http://www.ejournal.lembahdempo.ac.id>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 7(1), 770–778.
- Hendrawaty, Toni, & Azhar. (2021). Rancang Bangun Aplikasi Kriptografi Untuk Pengamanan Citra RGB 24 Bit Menggunakan Algoritma Elgamal. *JESSI*, 02(2), 110–111. <https://ojs.unm.ac.id/JESSI/index>
- Hibatullah, A., & Maliki, I. (2019). Penerapan Metode Convolutional Neural Network Pada Pengenalan Pola Citra Sandi Rumput. *Journal of Informatics and Computer Science*, 7(2), 172–178. <http://elibrary.unikom.ac.id/id/eprint/1529>
- Kaestria, R., Himmah, E. F., & Irawan, R. (2024). Penerapan Matplotlib dalam Visualisasi Data untuk Analisis Hubungan Penggunaan Gadget dan Hasil Belajar. *Journal of Digital Business and Information Technology*, 1(1), 29–39. <https://doi.org/10.23971/jobit.v1i1.204>
- Khumaidi, A. K., Chandra, E. A., Darmajanti, P., Septiadi, I. A., & Sarena, S. T. (2022). Vehicle Safe Distance Detection System Based On Image Processing As Accident Prevention With Faster R-CNN Method. *Applied Technology and Computing Science Journal*, 5(2), 143–153. <https://doi.org/10.33086/atcsj.v5i2.3804>
- Kurniawan, D., & Irfantoro, I. (2020). Implementasi Deep Learning Untuk Mendeteksi Objek Secara Real Time Dengan Tensorflow Lite Berbasis Android Mobile. *jurnal.iaii.or.id*, 5(2), 237–243.

- Mbaba, P., Anwar, K., Rahayu, S., & Eka Kartawati, A. (2022). Penerapan Metode Convolution Neural Networks Untuk Mengidentifikasi Wajah Kelelahan. *Jurnal Nasional Teknologi Informasi dan Aplikasinya*, 1(1), 109–112.
- Mega Saraswati, N., Cipta Sigitta Hariyono, R., & Chandra, D. (2023). Face Recognition Menggunakan Metode HAAR Cascade Classifier dan Local Binary Pattern Histogram. *Jurnal Media Elektrik*, 20(3), 2721–9100. <https://doi.org/10.59562/metrik.v20i3.5546>
- Megawan, S., & Lestari, W. S. (2020). Deteksi Spoofing Wajah Menggunakan Faster R-CNN dengan Arsitektur Resnet50 pada Video (Face Spoofing Detection Using Faster R-CNN with Resnet50 Architecture on Video). *Jurnal Nasional Teknik Elektro dan Teknologi Informasi* |, 9(3), 2301–4156.
- Megawati, & Mulyana, D. I. (2023). Deteksi Wajah Hijab Menggunakan Data Augmentation dan Metode Convolutional Neural Network. *Journal of Science and Technology* , 3(2), 99–110.
- Muchtar, H., & Apriadi, R. (2019). Implementasi Pengenalan Wajah Pada Sistem Penguncian Rumah dengan Metode Template Matching Menggunakan Open Source Computer Vision Library (Opencv). *RESISTOR (Elektronika Kendali Telekomunikasi Tenaga Listrik Komputer)*, 2(1), 39–42.
- Muhammad, S., & Wibowo, A. T. (2021). Klasifikasi Tanaman Aglaonema Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network (CNN). *e-Proceeding of Engineering*, 8(5), 10621–10624.
- Nando, M., Setianingsih, C., & Hasibuan, F. C. (2021). Sistem Pengenalan Wajah Untuk Kendali Berbasis Perilaku Pengguna Pada Smart Home Dengan Algoritma Faster R-CNN. *e-Proceeding of Engineering*, 8(6), 12187–12188.
- Nugroho, P. A., Fenriana, I., & Arijianto, R. (2020). Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) Pada Ekspresi Manusia. *JURNAL ALGOR*, 2(1), 12–21. <https://jurnal.buddhidharma.ac.id/index.php/algor/index>

- Kholis, N., Endryansyah, & Baskoro, F. (2022). Rancang Bangun Sistem Deteksi Label Kardus Berbasis Model Kecerdasan Buatan YOLO dan EasyOCR serta ESP32-CAM. *Jurnal Teknik Elektro*, 11(02), 190–200.
- Nurhidayat, R., & Dewi, K. E. (2023). Penerapan Algoritma K-Nearest Neighbor dan Fitur Ekstraksi N-Gram Dalam Analisis Sentimen Berbasis Aspek. *KOMPUTA : Jurnal Ilmiah Komputer dan Informatika*, 12(1), 94–99.
- Nurkholis, A., Heidiani Ikasari, I., & Kunci, K. (2023). Peran Artificial Intelligence Dalam Sistem Informasi Manajemen. *Jurnal Artificial Intelligent dan Sistem Penunjang Keputusan*, 1(1), 41–47. <https://jurnalmahasiswa.com/index.php/aidanspk>
- Octavia, R. (2020). *Deep Learning Based Moving Vehicle Classification And Counting Using Faster R-CNN Method*. (Tesis, Institut Teknologi Sepuluh Nopember), 7–96.
- Oeliga, C., & Afita, Y. (2021). Penegakan Hukum Terhadap Tindak Pidana Pemalsuan Tanda Nomor Kendaraan Bermotor (TNKB). *Datin Law Jurnal*, 1(2), 57–65.
- Omar, N., Abdulazeez, A. M., Sengur, A., & Al-Ali, S. G. S. (2020). Fused Faster RCNNs for efficient detection of the license plates. *Indonesian Journal of Electrical Engineering and Computer Science*, 19(2), 974–982. <https://doi.org/10.11591/ijeecs.v19.i2.pp974-982>
- Pardede, J., & Hardiansah, H. (2022). Deteksi Objek Kereta Api menggunakan Metode Faster R-CNN dengan Arsitektur VGG 16. *MIND Journal*, 7(1), 21–36. <https://doi.org/10.26760/mindjournal.v7i1.21-36>
- Pratama, A., Sulistiyo, M. D., & Ihsan, A. F. (2023). Balinese Script Handwriting Recognition Using Faster R-CNN. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 7(6), 1268–1275. <https://doi.org/10.29207/resti.v7i6.5176>

- Pratama, H., Syahputra, L. A., Fauzan Albany, M., Abdullah, A., Kusuma, E., Astuti, W., Mujihardi, B., & Suhardja, S. K. (2020). Early Results of Comparison between K-Nearest Neighbor and Artificial Neural Network Method for Facies Estimation. *Jurnal Geofisika*, 18(01), 7–13.
- Pratomo, A. H., Kaswidjanti, W., & Mu'arifah, S. (2020). Implementation of Region of Interest (RoI) Algorithm to Improve Car Detection And Classification Algorithm. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 7(1), 155–162. <https://doi.org/10.25126/jtiik.202071718>
- Putra, I. N. T. A., Kartini, K. S., Suyitno, Y. K., & Sugiarta, I. M. (2023). Penerapan Library Tensorflow, Cvzone, dan Numpy pada Sistem Deteksi Bahasa Isyarat Secara Real Time. *Jurnal Krisnadana*, 2(3), 412–432. <https://ejournal.sidyanusa.org/index.php/jkdn>
- Qorik, G., Pratamasunu, O., Ilmandira, O., Farisi, R., & Jannah, M. (2020). *Pengenalan Wajah Mahasiswa Universitas Nurul Jadid Pada Video Menggunakan Metode Haar Cascade dan Deep Learning*. 1(1), 25–34. <http://ejournal.unuja.ac.id/index.php/core>
- Ramadhani, D., Kallista, M., & Setianingsih, C. (2023). Deteksi Social Distancing Dan Penggunaan Di Restoran Menggunakan Algoritma Faster RCNN. *e-Proceeding of Engineering*, 10(1), 279–283. <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/19325>
- Ramdhan, I. A. (2021). *Deteksi Pelanggaran Pada Rambu Larangan Lalu Lintas Dengan Menggunakan Rule-Based System Dan Faster R-Cnn*. (Tesis, Universitas Komputer Indonesia), 7–21. <https://elibrary.unikom.ac.id>
- Raup, A., Ridwan, W., Khoeriyah, Y., & Yulianti Zaqiah, Q. (2022). Deep Learning dan Penerapannya dalam Pembelajaran. *JIIIP (Jurnal Ilmiah Ilmu Pendidikan)*, 5(9), 3258–3267. <http://Jiip.stkipyapisdompu.ac.id>

- Roihan, A., Abas Sunarya, P., & Rafika, A. S. (2019). Pemanfaatan Machine Learning dalam Berbagai Bidang. *IJCIT (Indonesian Journal on Computer and Information Technology)*, 5(1), 75–82.
- Sandi, K. M., Prima Yudha, A., Dimas Aryanto, N., & Farabi, M. A. (2022). Klasifikasi sampah menggunakan Convolutional Neural Network. *Indonesian Journal of Data and Science (IJODAS)*, 3(2), 72–81.
- Santoso, A., & Ariyanto, G. (2018). Implementasi Deep Learning Berbasis Keras Untuk Pengenalan Wajah. *Jurnal Teknik Elektro*, 18(01), 1411–8890. <https://doi.org/10.23917/emit.v18i01.6235>
- Setiyono, B., Riv'an Arif, M., Aini, Q. Q., Soegianto, T. H., Ohanna, J., Andrean, R., Gunawan, F., & Rizkia, A. P. (2023). Identifikasi Tanaman Obat Indonesia Melalui Citra Daun Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 10(2), 385–392. <https://doi.org/10.25126/jtiik.2023106809>
- Sholehurrohman, R. (2021). *Improved Yolov3 With Feature Extraction Mobilenetv2 For Detection and Classification Moving Vehicle*. (Tesis, Institut Teknologi Sepuluh Nopember), 9–27.
- Stinka, E., Musthofa, G., Nicholas, J., Khuzaifi Nuraziz, M., & Zahra Khairunnisa, A. (2023). Pengetahuan dan Pemanfaatan Teknologi Artificial Intelligence pada Aplikasi Photoshop. *Jurnal Pengabdian kepada Masyarakat*, 1(3), 160–167. <https://jurnalmahasiswa.com/index.php/appa>
- Sugeng, W., & Husaini, R. (2023). Implementasi Convolutional Recurrent Neural Network untuk Identifikasi Plat Nomor Mobil pada Sistem Parkir Otomatis. *MIND (Multimedia Artificial Intelligent Networking Database) Journal*, 8(2), 142–157. <https://doi.org/10.26760/mindjournal.v8i2.142-157>
- Sulistyo Budi, R., Patmasari, R., & Saidah, S. (2021). Klasifikasi Cuaca Menggunakan Metode Convolutional Neural Network (CNN) Weather

- Classification Using Convolutional Neural Network (CNN) Method. *e-Proceeding of Engineering* , 8(5), 2355–9365.
- Susanto, K. N., Gunadi, K., & Setyati, E. (2019). Pengenalan Karakter pada Plat Nomor Indonesia dengan Tilt Correction dan Metode Faster R-CNN. *Jurnal Infra*, 10(2), 1–7. publication.petra.ac.id
- Sambi, A. M. T. I., Lestriani, D., Marpaung, E. S. K., Ong, J., Savinka, M., Nurhaliza, P., & Ningsih, R. Y. (2023). Penggunaan Bahasa Pemrograman Python Dalam Analisis Faktor Penyebab Kanker Paru-Paru. *Jurnal Publikasi Teknik Informatika*, 2(2), 88–99. <https://doi.org/10.55606/jupti.v2i2.1742>
- Widayati, S., Chandra, Y. I., & Putra, A. P. (2023). Perancangan Aplikasi Edukasi Mental Health “Kind Tomind” Menggunakan Model Agile Berbasis Web Mobile. *Seminar Nasional Teknologi Informasi dan Komunikasi STI&K (SeNTIK)*, 7(1), 191–197.
- Yedidiya, N., Mendrofa, S., Mahfuzie, A., Faisal, M., Haidar, A., & Rosyani, P. (2023). Perbandingan Metode Yolo dan Faster R-CNN Dalam Sistem Deteksi Pengenalan Kendaraan. *JRIIN : Jurnal Riset Informatika dan Inovasi*, 1(2), 431–436.
- Zaharchuk, G., Gong, E., Wintermark, M., Rubin, D., & Langlotz, P. (2018). Deep Learning in Neuroradiology. *American Journal of Neuroradiology*, 39(10), 1776–1784. <https://www.ajnr.org/content/ajnr/39/10/local/complete-issue.pdf>