

**KLASIFIKASI WAJAH PADA PENGENDARA SEPEDA MOTOR RODA
DUA MENGGUNAKAN *FASTER REGION-BASED CONVOLUTIONAL
NEURAL NETWORK* (FASTER R-CNN)**

(Skripsi)

Oleh

**AZZAHRA NABILA WIBIRASYA
2057051020**



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

**KLASIFIKASI WAJAH PADA PENGENDARA SEPEDA MOTOR RODA
DUA MENGGUNAKAN *FASTER REGION-BASED CONVOLUTIONAL
NEURAL NETWORK* (FASTER R-CNN)**

Oleh

AZZAHRA NABILA WIBIRASYA

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**

ABSTRAK

KLASIFIKASI WAJAH PADA PENGENDARA SEPEDA MOTOR RODA DUA MENGGUNAKAN *FASTER REGION-BASED CONVOLUTIONAL NEURAL NETWORK* (FASTER R-CNN)

Oleh

AZZAHRA NABILA WIBIRAYA

Di Indonesia, kriminalitas telah menjadi masalah sosial yang cukup serius beberapa dekade terakhir. Sebagian besar kejahatan terutama kejahatan dijalanan, melibatkan pelaku yang berusaha menyembunyikan identitas mereka, salah satunya dengan menggunakan helm. Oleh karena itu, penting untuk memiliki teknologi yang dapat mengidentifikasi wajah pengendara yang menggunakan helm. Salah satu pendekatan deteksi objek berbasis wilayah yang efisien dalam proses deteksi adalah Faster R-CNN. Penelitian ini mengimplementasikan Faster R-CNN untuk klasifikasi wajah pengendara sepeda motor, khususnya pada data asli dan data yang telah diaugmentasi dengan rotasi 10° , dan rotasi -10° . Model ini menggabungkan deep fully convolutional network (FCN), region proposal network (RPN), dan Fast R-CNN, serta memanfaatkan transfer learning dengan model ResNet-50 sebagai ekstraktor fitur. Pengujian dilakukan pada beberapa kategori, seperti pengendara tanpa helm, pengendara dengan helm double visor (tertutup penuh, sebagian, atau dengan masker). Hasil menunjukkan kinerja yang unggul dengan presisi 96,34% recall 91,55%, dan F1-score 93,82%. Evaluasi juga menggunakan confusion matrix untuk memastikan akurasi model dalam mengenali wajah pengendara di berbagai kondisi.

Kata kunci : *Faster R-CNN*, Pengenalan Wajah, *ResNet50*.

ABSTRACT

FACE CLASSIFICATION ON TWO-WHEELED MOTORCYCLISTS USING FASTER REGION-BASED CONVOLUTIONAL (FASTER R-CNN)

By

AZZAHRA NABILA WIBIRAYA

In Indonesia, crime has become a serious social problem in recent decades. Most crimes, especially street crimes, involve perpetrators trying to hide their identity, one of which is by wearing a helmet. Therefore, it is important to have a technology that can identify the faces of riders wearing helmets. One of the efficient region-based object detection approaches in the detection process is Faster R-CNN. This research implements Faster R-CNN for motorcyclist face classification, specifically on the original data and data that has been augmented with 10° rotation, and -10° rotation. This model combines deep fully convolutional network (FCN), region proposal network (RPN), and Fast R-CNN, and utilizes transfer learning with ResNet-50 model as a feature extractor. Tests were conducted on several categories, such as riders without helmets, riders with double visor helmets (fully, partially, or with masks). Results show superior performance with 96.34% precision 91.55% recall, and 93.82% F1-score. The evaluation also uses confusion matrix to ensure the accuracy of the model in recognizing the rider's face in various conditions.

Keywords: *Faster R-CNN, Face recognition, ResNet50.*

Judul Skripsi

: **KLASIFIKASI WAJAH PADA PENGENDARA
SEPEDA MOTOR RODA DUA
MENGUNAKAN *FASTER REGION-BASED
CONVOLUTIONAL NEURAL NETWORK*
(FASTER R-CNN)**

Nama Mahasiswa

: **Aezahra Nabila Wibirasya**

Nomor Pokok Mahasiswa

: **2057051020**

Program Studi

: **S1 Ilmu Komputer**

Jurusan

: **Ilmu Komputer**

Fakultas

: **Matematika dan Ilmu Pengetahuan Alam**



1. **Komisi Pembimbing**

Pembimbing Utama

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

Pembimbing Kedua

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

PERNYATAAN

Saya yang bertanda tangan di bawah ini :

Nama : Azzahra Nabila Wibirasya

NPM : 2057051020

Menyatakan bahwa skripsi saya yang berjudul "**Klasifikasi Wajah Pada Pengendara Sepeda Motor Roda Dua 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,



Azzahra Nabila Wibirasya

NPM. 2057051020

RIWAYAT HIDUP



Penulis dilahirkan di Kota Bandar Lampung pada tanggal 09 Mei 2001, sebagai anak pertama dari 3 bersaudara, dari Bapak Bobi Aprilia dan Ibu Dewi Rudyanti. Penulis menyelesaikan pendidikan formal di SDS Lazuardi Haura GCS dan selesai pada tahun 2013. Kemudian pendidikan menengah pertama di SMP IT Ar - Raihan yang diselesaikan pada tahun 2016, lalu melanjutkan ke pendidikan menengah atas di SMAN 02 Bandar Lampung yang diselesaikan pada tahun 2019. Pada tahun 2020 penulis terdaftar sebagai mahasiswa Jurusan Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur SMMPTN. Selama menjadi mahasiswa, penulis melakukan beberapa kegiatan antara lain.

1. Melaksanakan Program *Short Course* Desain Interaksi Untuk UI/UX Designer Pemula Kredensial Mikro Mahasiswa Indonesia (KMMI) di Jurusan Ilmu Komputer Fakultas MIPA Unila periode 2021/2022.
2. Melaksanakan Kerja Praktek pada bulan Desember – Februari 2022/2023 periode I di Astra Credit Companies (ACC) Lampung.
3. Melaksanakan Kuliah Kerja Nyata di Desa Munca, Kecamatan Teluk Pandan, Kabupaten Pesawaran pada tahun 2022/2023.

MOTO

“Allah tidak mengatakan hidup ini mudah, tetapi Allah berjanji bahwa sesungguhnya bersama kesulitan ada kemudahan.”

(QS: Al-Insyirah’ ayat 5-6)

“Jika kamu berbuat baik kepada orang lain (berarti) kamu berbuat baik pada dirimu sendiri.”

(QS: Al-Isra’ ayat 7)

“Hatiku tenang mengetahui apa yang melewatkanmu tidak akan pernah menjadi takdirku, dan apa yang ditakdirkan untukku tidak akan pernah melewatkanmu.”

(Umar bin Khattab)

“Orang lain gak akan paham struggle dan masa sulitnya kita, yang mereka ingin tahu hanya bagian success stories nya saja. Jadi berjuanglah untuk diri sendiri meskipun gak akan ada yang tepuk tangan. Kelak diri kita di masa depanlah yang akan sangat bangga dengan apa yang kita perjuangkan hari ini.”

(Azzahra Nabila Wibirasya)

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:

Keluarga Tercinta

Ayah, Ibu, dan Adik

Yang senantiasa memberikan yang terbaik dan melantunkan do'a yang selalu Menyertaiku. Kuucapkan pula terimakasih sebesar-besarnya kepada Ayah dan Ibu karena telah mendidik dan membesarkanku dengan cara yang dipenuhi kasih sayang, dukungan, dan pengorbanan. Kupersembahkan semua ini untuk kalian, Tanpa kalian, semua ini tidak akan mungkin terwujud. Setiap langkah yang kuambil adalah hasil dari cinta dan kerja keras kalian.

Seluruh Keluarga Besar Ilmu Komputer 2020

Yang selalu memberikan semangat dan dukungan.

Almamater Tercinta, Universitas Lampung dan Jurusan Ilmu Komputer

Tempat menimba ilmu, untuk menjadi bekal hidup dunia dan akhirat.

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 Wajah Pada Pengendara Sepeda Motor Roda Dua 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. Ayah, Ibu, dan Adik tercinta, serta Keluarga besar yang selalu memberikan do'a dan dukungan.
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 meluangkan tenaga, waktu, dan pikirannya dalam memberikan arahan, ide, motivasi, kritik serta saran kepada penulis sehingga dapat menyelesaikan skripsi ini dengan baik.
7. Bapak Ridho Sholehurrohman, M.Mat. sebagai Dosen Pembimbing 2 yang telah meluangkan tenaga, waktu, dan pikirannya dalam memberikan arahan,


ide, motivasi, kritik serta saran kepada penulis sehingga dapat menyelesaikan skripsi ini dengan baik.

8. Bapak Dr. rer. Nat. Akmal Junaidi, M. Sc. sebagai Dosen Pembahas serta Dosen Pembimbing Akademik yang telah memberikan bimbingan dan arahan kepada penulis selama proses studi dan memberikan masukan penting dalam perbaikan skripsi ini.
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. Thalia Gemi Innaya dan Aullya Hanan Wulandari yang telah kebersamai penulis terimakasih atas dukungan, semangat, motivasi serta bantuan yang diberikan kepada penulis.
12. Nur Mita Utami yang telah kebersamai penulis sebagai sahabat dan partner skripsian, tiada hentinya saling memberikan semangat, motivasi, dan berjuang agar siap menghadapi ujian sidang skripsi secara bersama.
13. Keluarga Besar Ilmu Komputer 2020 yang tidak bisa penulis sebutkan satu persatu.
14. Dan yang terakhir, kepada diri saya sendiri. Azzahra Nabila Wibirasya. Terima kasih sudah bertahan sejauh ini. Terima kasih tetap memilih berusaha dan merayakan dirimu sendiri sampai di titik ini, walau sering kali merasa putus asa apa yang diusahakan dan belum berhasil, namun terima kasih tetap menjadi manusia yang selalu mau berusaha dan tidak lelah mencoba. Terima kasih karena memutuskan tidak menyerah sesulit apapun proses penyusunan skripsi ini dan telah menyelesaikannya sebaik dan semaksimal mungkin, ini merupakan pencapaian yang patut dirayakan untuk diri sendiri. Berbahagialah selalu dimanapun berada, Jara. Apapun kurang dan lebihmu mari merayakan diri sendiri.

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,



Azzahra Nabila Wibirasya

NPM. 2057051020

DAFTAR ISI	1
DAFTAR GAMBAR	1
DAFTAR TABEL	1
DAFTAR KODE PROGRAM	1
1. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	2
1.3 Tujuan Penelitian	2
1.4 Manfaat Penelitian	2
1.5 Metode Penelitian	2
II. TINJAUAN PUSTAKA	3
2.1 Konsep Jaringan	3
2.2 Topologi	3
2.3 Perangkat Jaringan	3
2.4 Protokol Jaringan	3
2.5 Analisis Jaringan	3
2.6 Mekanisme Jaringan	3
2.7 Data Jaringan	3
2.8 Sistem Jaringan	3
2.9 Komunikasi Jaringan	3
2.10 Keamanan Jaringan	3
2.11 Jaringan Lokal	3
2.12 Jaringan Global	3

DAFTAR ISI

	Halaman
DAFTAR ISI	iii
DAFTAR GAMBAR	vii
DAFTAR TABEL	viii
DAFTAR KODE PROGRAM	ix
I. PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah	5
1.3 Batasan Masalah	5
1.4 Tujuan Penelitian	5
1.5 Manfaat Penelitian.....	6
II. TINJAUAN PUSTAKA	7
2.1 Penelitian Terdahulu	7
2.2 Wajah	9
2.3 Pengolahan Citra Digital	10
2.4 <i>Resize Image</i>	12
2.5 <i>Artificial Intelligence (AI)</i>	12
2.6 <i>Machine Learning</i>	13
2.7 <i>Deep Learning</i>	14
2.8 Operasi Konvolusi.....	14
2.9 <i>Convolutional Neural Network (CNN)</i>	15
2.9.1 <i>Convolutional Layer</i>	17
2.9.2 <i>Pooling Layer</i>	18
2.9.3 <i>Fully Connected Layer</i>	19

2.9.4	<i>Rectified Linear Units (ReLU)</i>	20
2.10	<i>Faster Region-Based Convolutional Neural Network (Faster R-CNN)</i> 20	
2.10.1	<i>Region Proposal Network (RPN)</i>	22
2.10.2	<i>Region of Interest (RoI) of Faster R-CNN</i>	23
2.11	<i>Residual Network (ResNet-50)</i>	24
2.12	<i>Confusion Matrix</i>	26
III.	METODE PENELITIAN	29
3.1	Waktu dan Tempat Penelitian.....	29
3.1.1	Tempat Peneltian.....	29
3.1.2	Waktu Penelitian	29
3.2	Alat Pendukung	30
3.2.1	Perangkat Keras (<i>Hardware</i>).....	30
3.2.2	Perangkat Lunak (<i>Software</i>).....	31
3.3	Tahapan Penelitian.....	33
3.3.1	Pengumpulan Dataset	33
3.3.2	Anotasi Data	34
3.3.3	<i>Pre-processing</i>	34
3.3.4	<i>Training Model</i>	36
3.3.5	<i>Testing Model</i>	37
3.3.6	<i>Intersection over Union (IoU)</i>	38
3.3.7	<i>Classification</i>	38
3.3.8	Evaluasi	39
3.3.9	Analisis Kinerja Model.....	39
IV.	PEMBAHASAN	41
4.1	Desain Arsitektur Faster R-CNN dengan Fitur Ekstraktor ResNet-50....	41
4.2	Pengambilan Data.....	43
4.3	Pre-processing	46
4.3.1	<i>Cropping dan Resizing</i>	46
4.3.2	Anotasi Data	48
4.3.3	Pembagian Dataset	49
4.3.4	Augmentasi Data	49
4.4	<i>Hyperparameter Tuning</i>	52

4.5	<i>Training Model</i>	53
4.5	Hasil <i>Training Model</i>	55
4.6	<i>Testing Model</i>	69
4.7	Evaluasi Model	76
4.7.1	Evaluasi Hasil Pengujian Deteksi	76
4.7.2	Evaluasi Model Hasil Pengujian Klasifikasi	79
4.8	Analisis Hasil	84
V.	KESIMPULAN DAN SARAN	87
5.1	Kesimpulan	87
5.2	Saran	88
	DAFTAR PUSTAKA	89

DAFTAR GAMBAR

Gambar	Halaman
1. Ilustrasi Wajah.....	10
2. Ilustrasi Representasi Citra (Sholehurrohman, 2021).	11
3. Ilustrasi <i>Resize Image</i>	12
4. Keterkaitan AI, ML dan DL (G.Zaharchuk dkk., 2018).....	13
5. Arsitektur <i>Deep Learning</i> (Octavia, 2020).	14
6. Ilustrasi Operasi Konvolusi (Mustofa & Winarno, 2023).	15
7. Arsitektur CNN (Husna dkk., 2022).	17
8. <i>Convolution Layer</i> (Sandi dkk., 2022).	18
9. <i>Pooling Layer</i> (Husna dkk., 2022).	19
10. <i>Fully Connected Layer</i> (Sari, 2022).	19
11. <i>ReLu Activation Function</i> (Husna dkk., 2022).	20
12. Model Faster R-CNN (Fahriska, 2022).	21
13. <i>Region Proposal Network</i> (RPN) (Octavia 2020).	23
14. Residual Blok (Octavia, 2020).	25
15. Arsitektur ResNet-50 (Octavia, 2020).	25
16. Alur Metodologi Penelitian.....	33
17. Desain Arsitektur Faster R-CNN - ResNet-50.	41
18. Ilustrasi Pengambilan Data 1.	44
19. Ilustrasi Pengambilan Data 2.	45
20. Ilustrasi Pengambilan Data 3.	45
21. Citra Hasil <i>Cropping</i> Dan <i>Resizing</i>	46
22. Pembuatan <i>Bounding Box</i> Pada Kategori 1 Pengendara Tanpa Helm	48
23. Citra Hasil Augmentasi Rotasi 10°.	52
24. Citra Hasil Augmentasi Rotasi -10°.	52

25. Grafik <i>Training Learning Rate</i> 0,01 <i>Epoch</i> 40.	56
26. Grafik <i>Training Learning Rate</i> 0,001 <i>Epoch</i> 40.	57
27. Grafik <i>Training Learning Rate</i> 0,0001 <i>Epoch</i> 40.	58
28. Grafik <i>Training Learning Rate</i> 0,01 <i>Epoch</i> 80.	60
29. Grafik <i>Training Learning Rate</i> 0,001 <i>Epoch</i> 80.	61
30. Grafik <i>Training Learning Rate</i> 0,0001 <i>Epoch</i> 80.	62
31. Grafik <i>Training Learning Rate</i> 0,01 <i>Epoch</i> 120.	64
32. Grafik <i>Training Learning Rate</i> 0,001 <i>Epoch</i> 120.	65
33. Grafik <i>Training Learning Rate</i> 0,0001 <i>Epoch</i> 120.	66
34. Hasil <i>Testing</i> Kondisi 1 Gambar 1.	70
35. Hasil <i>Testing</i> Kondisi 2 Gambar 1.	71
36. Hasil <i>Testing</i> Kondisi 3 Gambar 1.	72
37. Hasil <i>Testing</i> Kondisi 1 Gambar 2.	73
38. Hasil <i>Testing</i> Kondisi 2 Gambar 2.	74
39. Hasil <i>Testing</i> Kondisi 3 Gambar 2.	75
40. Ilustrasi Perhitungan IoU	77
41. Ilustrasi <i>Anchor Box</i> dan <i>Ground Truth</i>	77
42. Grafik Rata-Rata Nilai IoU.	78
43. <i>Confusion Matrix</i> Evaluasi.....	80
44. Hasil TP, FP, TN, FN.....	81
45. Analisis 1 Hasil Evaluasi.	84
46. Analisis 2 Hasil Evaluasi.	85

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terdahulu.....	7
2. Prediksi <i>Confusion Matrix</i>	26
3. Alur Waktu Pelaksanaan Kegiatan.	30
4. Perangkat Keras.	30
5. Keterangan Jumlah Data.	50
6. <i>Hyperparameter Tuning</i>	53
7. Tabel Hasil <i>Training</i>	67
8. Kondisi dan Lokasi.	69

DAFTAR KODE PROGRAM

Kode Program	Halaman
1. Ilustrasi <i>Cropping</i> dan <i>Resizing</i> Citra.	47
2. Ilustrasi Augmentasi Rotasi 10° dan -10°	51
3. <i>Training</i> Model.....	54
4. Proses Evaluasi Model.	54

I. PENDAHULUAN

1.1 Latar Belakang

Secara sosiologis, kejahatan dapat diartikan sebagai tindakan yang melanggar norma-norma atau kaidah-kaidah yang berlaku dalam masyarakat, termasuk norma hukum, agama, adat, dan sosial (Rajamudin, 2019). Pelanggaran terhadap norma-norma masyarakat ini kemudian dikenal sebagai kriminalitas. Di Indonesia, kriminalitas telah menjadi masalah sosial yang cukup serius beberapa dekade terakhir. Tingginya angka kriminalitas menunjukkan bahwa banyak individu yang melanggar norma dan aturan hukum yang berlaku. Kriminalitas merupakan tindakan yang melanggar peraturan perundang-undangan dan menimbulkan kerugian bagi individu maupun masyarakat secara luas. Hal ini meliputi beragam jenis pelanggaran yang dianggap ilegal, antara lain pencurian, tindak kekerasan, penipuan, hingga peredaran gelap narkoba. Badan Pusat Statistik mengindikasikan laju kriminalitas di wilayah Indonesia berkisar 90 kasus per 100.000 orang pada tahun 2021 (Rosiana dkk., 2023).

Terdapat beberapa faktor yang dapat memengaruhi individu untuk melakukan kejahatan. Salah satu faktornya adalah lingkungan, di mana tekanan dari lingkungan sekitar dapat mendorong individu untuk melakukan kejahatan. Selain itu, faktor ekonomi juga dapat mempengaruhi individu, karena kebutuhan hidup yang harus dipenuhi dapat menjadi pemicu untuk melakukan kejahatan (Faniyah & Yahya, 2023). Maraknya pelaku kejahatan

kriminal menjadi isu yang signifikan di berbagai daerah. Tingkat kriminalitas di Indonesia telah menjadi perhatian serius dalam beberapa dekade terakhir.

Kriminalitas tidak hanya melanggar norma-norma sosial, tetapi juga mengancam keamanan masyarakat dan stabilitas sosial. Sebagian besar kejahatan terutama kejahatan dijalanan, melibatkan pelaku yang berusaha menyembunyikan identitas mereka, salah satunya dengan menggunakan helm saat melakukan tindak kriminal. Penggunaan helm untuk menyamarkan identitas pelaku kriminal menjadi tantangan dalam upaya penegakan hukum dan keamanan masyarakat. Banyak kejadian kriminal dijalanan, pelaku kejahatan menggunakan sepeda motor sebagai alat transportasi utama mereka. Sepeda motor memberikan keleluasaan dan kecepatan dalam melarikan diri, serta kemudahan akses ke lokasi kejahatan.

Namun, yang lebih menonjol adalah penggunaan helm sebagai upaya untuk menyembunyikan identitas mereka saat melakukan kejahatan. Penggunaan helm oleh pelaku kejahatan menjadi kendala serius bagi penegakan hukum. Identifikasi pelaku kriminal menjadi sulit ketika wajah mereka tersembunyi di balik helm. Oleh karena itu, penting untuk memiliki teknologi yang dapat mendeteksi dan mengklasifikasi agar dapat mengidentifikasi wajah pengendara yang menggunakan helm. Dengan teknologi yang mampu mendeteksi dan mengklasifikasi wajah meskipun tersamar helm, penyelidikan terhadap kasus kriminal dapat menjadi lebih efektif dan efisien.

Pengenalan wajah (*face recognition*) adalah evolusi dari teknologi deteksi wajah yang mampu menghasilkan/*generate* gambar wajah dari gambar yang diambil oleh kamera dan melakukan deteksi persamaan wajah tersebut dengan data wajah yang telah dikenali oleh komputer, memungkinkan komputer untuk mengidentifikasi individu atau mengetahui keberadaan seseorang (Ramdhon & Febriya, 2021). Meskipun pelaku kriminalitas mencoba untuk menyembunyikan identitas mereka dengan mengenakan helm, pengenalan wajah ini mampu memindai dan mengidentifikasi ciri-ciri unik pada wajah

seseorang, termasuk mata, hidung, dan bentuk wajah secara keseluruhan. Pengenalan wajah menjadi krusial dalam mengidentifikasi pelaku kriminal, terutama dalam kasus pengendara sepeda motor yang memakai helm untuk menyembunyikan identitas mereka. Identifikasi pelaku kriminal dapat membantu penyelidikan dan penegakan hukum, serta mencegah kejahatan lebih lanjut.

Dalam proses pengenalan objek oleh komputer, tahap pendeteksian menjadi langkah *pre-processing* yang krusial untuk mengenali keberadaan dan posisi objek (Wati dkk., 2023). Perkembangan era digital telah meningkatkan pemanfaatan citra digital, termasuk dalam deteksi objek menggunakan kecerdasan buatan. *Deep Learning* merupakan sub bidang dari kecerdasan buatan dan *machine learning* yang mengembangkan *neural network multiple layer* untuk meningkatkan akurasi tugas seperti deteksi objek (Raup dkk., 2022). Model ini merupakan pendekatan deteksi objek berbasis wilayah R-CNN yang lebih efisien dalam proses deteksi. Faster R-CNN memanfaatkan struktur arsitektur utama yang tetap menggabungkan *Convolutional Neural Network* (CNN) dan *Region Proposal Network* (RPN) (Megawan, Lestari, dan Halim 2022).

Penelitian sebelumnya telah banyak membahas penggunaan metode *Deep Learning* untuk klasifikasi objek, khususnya menggunakan Faster R-CNN dan arsitektur lainnya. Salah satunya adalah penelitian yang dilakukan oleh (Megawan & Lestari, 2020), yang menggunakan metode Faster R-CNN dengan arsitektur ResNet50 untuk mendeteksi wajah *spoofing* pada video. Penelitian ini menggunakan dataset *Replay-Attack* yang berisi 1.300 video klip dari 50 klien dengan berbagai kondisi pencahayaan. Hasil evaluasi menunjukkan bahwa Faster R-CNN mampu mendeteksi dan membedakan wajah *spoofing* dan *non-spoofing* dengan akurasi rata-rata *training* sebesar 97,07%.

Penelitian lainnya oleh (Megawan dkk., 2022), menggunakan Faster R-CNN untuk mendeteksi wajah *non-spoofing* secara *real-time* dengan implementasi

pada Raspberry Pi. Pengujian dilakukan menggunakan 4 video, dan hasilnya menunjukkan bahwa model ini memiliki akurasi sebesar 92% untuk deteksi wajah *non-spoofing* dan 96% untuk deteksi wajah *spoofing*. Selain itu, penelitian oleh (Sari, 2022) menggunakan metode *Convolutional Neural Network* (CNN) untuk klasifikasi jenis kelamin berdasarkan gambar wajah manusia. Penelitian ini menggunakan 600 gambar, terdiri dari 300 gambar laki-laki dan 300 gambar perempuan, dengan hasil akurasi tertinggi mencapai 91,02% setelah pelatihan menggunakan tujuh *convolutional layer* dan tiga *fully connected layer*.

Penelitian lainnya yang dilakukan oleh (Alamsyah dkk., 2019) menggunakan Faster R-CNN dengan arsitektur *Inception v2* untuk mendeteksi ujung jari pada citra tangan. Dataset yang digunakan terdiri dari 40 gambar telapak tangan, dan pengujian dilakukan pada citra dengan *noise* dan tanpa *noise*. Hasilnya menunjukkan bahwa citra tanpa *noise* menghasilkan akurasi tertinggi sebesar 91%.

Berdasarkan dengan penjelasan di atas, penelitian ini bertujuan untuk mengimplementasikan Faster R-CNN untuk mengklasifikasi wajah pengendara sepeda motor roda dua, karena Faster R-CNN sesuai dan akurat dalam mengklasifikasikan serta mengenali objek, terutama dengan tingkat akurasi yang lebih tinggi untuk objek kecil seperti mata, hidung, dan mulut. Penelitian ini tidak hanya berfokus pada hasil akhirnya, namun menjelaskan secara mendalam mengenai bagaimana Faster R-CNN bekerja. Dalam Faster R-CNN itu sendiri terdapat *deep fully convolutional network* (FCN) dengan *region proposal network* (RPN) dan *Fast R-CNN* sebagai detektor. Faster R-CNN adalah pengembangan dari RCNN dan *Fast RCNN* yang menggunakan metode *transfer learning* dengan *pre trained CNN* seperti ResNet, VGG, *InceptionV2*, *MobileNet*, dan sebagainya untuk meningkatkan kinerja objek. Pada penelitian ini, akan dilakukan pengujian model menggunakan *confusion matrix*.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dijabarkan di atas, maka didapat rumusan masalah pada penelitian ini yaitu :

1. Bagaimana mengklasifikasikan wajah pada pengendara sepeda motor roda dua menggunakan Faster R-CNN ?
2. Bagaimana analisis kinerja Faster R-CNN pada klasifikasi wajah pengendara sepeda motor ?

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 dataset diambil pada siang hari dengan kondisi pencahayaan yang baik.
3. Dataset yang digunakan adalah pengendara tunggal sepeda motor roda dua yang menggunakan *clear visor helmet* (helm dengan kaca bening) .
4. Lokasi penelitian ini berfokus pada area parkir motor Fakultas Matematika Dan Ilmu Pengetahuan Alam (FMIPA) Universitas Lampung.
5. Penelitian ini mencakup beberapa kategori helm yaitu, pengendara tanpa helm, pengendara dengan helm *double visor* dan seluruh kaca tertutup, pengendara dengan helm yang hanya *double visor* tertutup, pengendara dengan helm tertutup dan memakai masker, dan pengendara dengan masker yang memakai helm *double visor* tertutup.

1.4 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah:

1. Mengimplementasikan Faster R-CNN dalam mengklasifikasi citra pada wajah pengendara sepeda motor roda dua.

2. Menganalisis dan mengevaluasi tingkat akurasi Faster R-CNN dalam mengklasifikasi citra wajah pengendara sepeda motor roda dua dilihat dari akurasi, presisi, *recall*, dan *f1-score*.

1.5 Manfaat Penelitian

Adapun manfaat dari penelitian ini adalah:

1. Mengetahui hasil akurasi, evaluasi dan performansi kinerja Faster R-CNN.
2. Dapat membantu mengidentifikasi individu yang masuk atau keluar di area parkir Fakultas Matematika Dan Ilmu Pengetahuan Alam (FMIPA) Universitas Lampung.
3. Dapat digunakan sebagai referensi bagi penelitian lanjutan di bidang klasifikasi wajah pada situasi dan konteks yang spesifik.
4. Sebagai rujukan aparat kepolisian dalam mengungkap kejahatan dan kriminalitas yang terjadi dijalanan.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Dalam penelitian ini mengacu pada penelitian-penelitian sebelumnya yang bertujuan untuk mendukung landasan penelitian ini seperti pada Tabel 1.

Tabel 1. Penelitian Terdahulu.

Judul Penelitian	Metode	Data	Hasil
Deteksi <i>Spoofing</i> Wajah Menggunakan Faster R-CNN dengan Arsitektur ResNet-50 pada Video (Megawan & Lestari, 2020).	Faster R-CNN.	Data yang digunakan adalah data sekunder yang dapat diakses pada link https://www.idiap.ch/dataset/replayattack . <i>Replay-Attack Database</i> berisi 1.300 video klip dari foto dan video yang direkam dengan berbagai <i>lighting</i> yang berbeda dari 50 klien.	Faster R-CNN dapat mendeteksi wajah dan membedakan wajah <i>spoof</i> dan <i>non-spoof</i> dengan rata-rata akurasi <i>training</i> sebesar 97,07%.

Deteksi Non-Spoofing Wajah Pada Video Secara Real Time Menggunakan Faster R-CNN (Megawan dkk., 2022).	Faster R-CNN.	Sketsa wajah, foto wajah, video wajah dan masker 3D dari wajah.	Hasil akurasi menggunakan Raspberry Pi sebanyak 4 video, menunjukkan hasil akurasi 92% untuk deteksi wajah <i>non-spoofing</i> dan 96% untuk wajah <i>spoofing</i> .
Klasifikasi Jenis Kelamin Menggunakan Metode Convolutional Neural Network (CNN) Dengan Data Wajah Manusia (Sari, 2022).	<i>Convolutional Neural Network</i> (CNN).	Data yang digunakan dalam penelitian ini sebanyak 600 gambar yang terbagi menjadi 300 citra gambar laki-laki dan 300 citra gambar perempuan.	Nilai akurasi data yang diperoleh menggunakan tujuh <i>convolutional layer</i> dan tiga <i>fully connected layer</i> menghasilkan akurasi tertinggi sebesar 91,02%, <i>recall</i> sebesar 53,5%, <i>precision</i> sebesar 57,66%, dan <i>f1 score</i> sebesar 51,25% dengan menggunakan 60 <i>epoch</i> .
Deteksi Ujung Jari Menggunakan Faster-R-CNN Dengan Arsitektur Inception v2 Pada Citra Derau (Alamsyah dkk., 2019).	Faster R-CNN, Arsitektur <i>Inception v2</i> .	Dataset berupa 40 gambar telapak tangan.	Pengujian dilakukan pada citra tanpa <i>noise</i> dan citra dengan berbagai jenis <i>noise</i> (Gaussian, Salt, and Pepper, Poisson, Speckle), dan hasil akurasi tertinggi adalah citra tanpa <i>noise</i> dengan 91%.

Penelitian sebelumnya telah menggunakan Metode Faster R-CNN dalam berbagai konteks untuk mengklasifikasi dan mengenali objek pada gambar, dan hasilnya menunjukkan bahwa Metode Faster R-CNN memiliki tingkat akurasi yang memuaskan. Penelitian ini akan mengimplementasikan model Faster R-CNN untuk mengklasifikasi wajah pada pengendara sepeda motor roda dua. Pemilihan Faster R-CNN didasarkan pada kinerja akuratnya yang terbukti dalam penelitian sebelumnya dan kemampuannya yang unggul dalam mengklasifikasikan objek yang kecil.


2.2 Wajah

Wajah merupakan bagian penting dari tubuh manusia. Umumnya wajah digunakan untuk mengenali rupa seseorang atau untuk mengetahui ekspresi emosi yang sedang dirasakan. Selain itu, wajah juga berperan sebagai alat identifikasi dalam pembuatan sistem absensi, sistem pencatatan penduduk, dan sistem keamanan, seperti pengaman pintu dan pengaman komputer. *Identifier* atau pendeteksi adalah alat yang digunakan untuk mengklasifikasikan suatu objek (Devi dkk., 2023).

Selain itu wajah mempunyai karakteristik yang kompleks untuk dikenali oleh komputer seperti mata, alis, hidung, mulut, telinga, dahi, pipi, dan dagu. Mata menjadi fokus utama karena menjadi titik fokus ekspresi wajah dan dapat memberikan informasi penting tentang identitas dan emosi individu. Alis juga memiliki peran penting dalam menentukan ekspresi wajah secara keseluruhan. Hidung merupakan ciri yang signifikan karena berkontribusi pada identifikasi individu dan memberikan tambahan informasi tentang karakteristik fisik.

Begitupun juga dahi yang memiliki peran penting dalam analisis wajah karena bentuk dan ekspresinya dapat mengungkapkan berbagai emosi. Seluruh bagian dari wajah ini penting dalam klasifikasi wajah

menggunakan metode Faster R-CNN, karena metode tersebut memungkinkan mengklasifikasi objek dengan cepat dan akurasi yang baik khususnya pada pengendara sepeda motor roda dua. Pada Gambar 1 menunjukkan struktur gambar bagian dari wajah.



Gambar 1. Ilustrasi Wajah.

2.3 Pengolahan Citra Digital

Gambar atau citra merupakan representasi *visual* dalam format dua dimensi yang terbentuk dari sejumlah besar piksel. Piksel, sebagai unit dasar dari citra, adalah titik-titik kecil yang menyusun gambar digital. Jumlah piksel dalam suatu citra dapat mencapai jumlah yang sangat besar, tergantung pada resolusi gambar yang dihasilkan. Setiap piksel dalam gambar membawa data tentang warna (*hue*), tingkat kejenuhan warna (*saturation*), dan kecerahan warna (*brightness*), sehingga menciptakan variasi warna dan intensitas yang berbeda di setiap piksel (Christian & Idrus, 2023). Proses pengolahan piksel dalam gambar atau citra digital dikenal sebagai pengolahan citra digital.


Citra digital dapat dikelompokkan menjadi tiga jenis berdasarkan nilai pikselnya sebagai berikut (Sholehurrohman, 2021):

1. Citra Biner adalah citra yang hanya memiliki nilai intensitas hitam dan putih. Warna hitam direpresentasikan oleh piksel dengan nilai 1, sedangkan warna putih direpresentasikan oleh piksel dengan nilai 0.
2. Citra *Grayscale* adalah citra yang nilai intensitas pikselnya berada dalam satu lapisan keabuan, dengan rentang nilai antara 0 hingga 255.
3. Citra warna (RGB) adalah citra yang terdiri dari tiga lapisan, yaitu Merah (*Red*), Hijau (*Green*), dan Biru (*Blue*), di mana masing-masing lapisan memiliki rentang nilai antara 0 hingga 255.

Sebuah citra dengan ukuran matriks tertentu dapat dijelaskan sebagai matriks berukuran $M - 1 \times N - 1$ yaitu (Sholehurrohman, 2021)

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


$M \times N$ mengindikasikan resolusi citra, dengan M mewakili jumlah baris dan N melambangkan jumlah kolom. Nilai $f(x,y)$ menunjukkan intensitas piksel pada koordinat (x,y) , yang sering disebut sebagai tingkat keabuan (*graylevel*) seperti yang ditunjukkan pada Gambar 2.



Gambar 2. Ilustrasi Representasi Citra (Sholehurrohman, 2021).

2.4 *Resize Image*

Resize Image adalah langkah dimana citra diubah menjadi ukuran yang lebih besar atau lebih kecil dari ukuran aslinya sesuai dengan ukuran yang telah ditentukan sebelumnya (Ilyas, 2020). Proses ini bertujuan untuk mengurangi beban perangkat karena metode klasifikasi objek yang sangat kompleks dan membutuhkan ruang penyimpanan yang besar. Proses tersebut dapat dilakukan secara *online* menggunakan berbagai perangkat lunak atau aplikasi. *Resizing* mempermudah pengguna untuk mengubah dimensi lebar, tinggi, atau diagonal gambar, serta mengubah rasio aspeknya. Tujuan umum dari proses *resizing* mencakup pengurangan ukuran gambar dan peningkatan optimasi resolusi, rasio aspek, dan ukuran file gambar yang dapat dilihat pada Gambar 3.




Gambar 3. Ilustrasi *Resize Image*.

2.5 *Artificial Intelligence (AI)*

Kecerdasan buatan (*Artificial Intelligence*) adalah jenis kecerdasan yang ditunjukkan oleh mesin. Saat ini, kemampuan kecerdasan buatan telah berkembang hingga mampu memahami bahasa manusia, bersaing dalam permainan dengan tingkat kesulitan tinggi, mengembangkan teknologi *self-driving*, serta mengolah data yang kompleks. Kecerdasan buatan dapat dianggap sebagai otak buatan yang mampu memproses informasi dari

berbagai sumber, seperti gambar, video, suara dari mikrofon, atau data lainnya untuk menentukan tindakan selanjutnya. Bentuk kecerdasan buatan dapat berupa kumpulan program yang ditulis dalam berbagai bahasa pemrograman. Mirip dengan manusia, kecerdasan buatan mampu memproses informasi yang diterima melalui panca indera untuk menentukan langkah selanjutnya (Assidiqi, 2023). Keterkaitan tentang AI, ML, dan DL dapat dilihat pada Gambar 4.




Gambar 4. Keterkaitan AI, ML dan DL (G.Zaharchuk dkk., 2018).

2.6 *Machine Learning*

Machine learning merupakan penerapan komputer dan algoritma matematika yang menggunakan pembelajaran dari data untuk memprediksi kejadian di masa mendatang. Proses pembelajaran ini melibatkan dua tahap utama: pelatihan (*training*) dan pengujian (*testing*). Pelatihan melibatkan penggunaan data untuk mengajar model atau algoritma agar dapat mengenali pola dan hubungan dalam data. Setelah dilatih, model diuji dengan menggunakan data yang tidak terlibat dalam pelatihan untuk mengevaluasi kinerjanya. Ini merupakan upaya untuk memperoleh kecerdasan dari pengalaman dan data yang dimiliki (Roihan dkk., 2019).

2.7 Deep Learning

Deep Learning merupakan suatu algoritma dalam jaringan saraf tiruan yang memiliki tingkat keakuratan yang lebih tinggi daripada metode mesin lainnya. Algoritma ini memanfaatkan data sebagai *input* dan diolah melalui beberapa lapisan tersembunyi (Sari, 2022). *Deep Learning* adalah salah satu teknik penerapan *machine learning* yang menggunakan jaringan saraf tiruan (*artificial neural network*) untuk meniru cara kerja otak manusia. Berbagai algoritma berfungsi sebagai neuron yang telah diprogram dengan kemampuan yang lebih kompleks untuk berkolaborasi dalam mempelajari, menganalisis, dan mengekstraksi karakteristik dari sekumpulan data. *Deep Learning* memungkinkan pembentukan model komputasi yang terdiri dari banyak lapisan pemrosesan, yang bertujuan untuk memahami representasi data dengan tingkat abstraksi yang bervariasi. *Deep Learning* terdiri dari tiga komponen utama, yaitu lapisan *input*, beberapa lapisan tersembunyi (*hidden layer*), dan lapisan *output*. Seperti yang diperlihatkan dalam Gambar 5, lapisan-lapisan ini saling terhubung melalui simpul-simpul (*nodes*). Pada lapisan tersembunyi, keluaran dari lapisan sebelumnya menjadi masukan untuk lapisan berikutnya (Octavia 2020).



Gambar 5. Arsitektur *Deep Learning*(Octavia, 2020).


2.8 Operasi Konvolusi

Operasi konvolusi melibatkan dua matriks, yaitu matriks piksel dari sebuah gambar dan matriks kernel. Proses konvolusi mencakup perkalian,

penjumlahan, serta pergeseran matriks kernel piksel demi piksel dengan mengacu pada titik pusatnya. Penggunaan konvolusi umumnya bertujuan untuk meningkatkan kualitas citra, mengurangi *noise*, meratakan citra, atau mendeteksi tepi. Konvolusi antara dua nilai diskrit dapat direpresentasikan dengan notasi berikut (Mustofa & Winarno, 2023). Persamaan dapat dilihat pada Persamaan 1.

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

Citra hasil yang disimbolkan dengan $h(x)$, dipengaruhi oleh citra asalnya yaitu $f(x)$, dan matriks kernel yang disimbolkan dengan $g(x)$. Kemudian simbol (*) menunjukkan operasi konvolusi, dan variabel a yang digunakan sebagai pembantu dalam perhitungan. Proses konvolusi dapat dijelaskan dengan langkah-langkah yang ditunjukkan dalam Gambar 6.



Gambar 6. Ilustrasi Operasi Konvolusi (Mustofa & Winarno, 2023).

2.9 Convolutional Neural Network (CNN)


Convolutional Neural Network (CNN) adalah evolusi dari *Multi Layer Perceptron* (MLP) yang sering digunakan dalam tugas-tugas seperti klasifikasi gambar, pengenalan gambar, dan deteksi objek. Seperti halnya dalam *Neural Network*, CNN juga terdiri dari neuron yang memiliki bobot

(w) dan bias (b). Arsitektur CNN terdiri dari lapisan *input*, lapisan tersembunyi, dan lapisan *output*, dimana setiap lapisan secara umum terdiri dari operasi konvolusi, aktivasi, dan pengelompokan (*pooling*) (Saputra dkk., 2022). Menurut konsep CNN, *Convolutional Neural Network* (CNN) adalah bentuk khusus dari *Multi Layer Perceptron* (MLP) yang dipersiapkan secara spesifik untuk mengidentifikasi gambar dua dimensi.

Dengan cara ini, CNN meniru cara kerja otak manusia dalam mengenali objek yang dilihatnya. Dengan bantuan CNN, komputer mampu "melihat" dan "mengenali" berbagai objek, sebuah kemampuan yang dikenal sebagai pengenalan gambar. CNN adalah sebuah teknik klasifikasi dalam bidang *Deep Learning* yang memanfaatkan lapisan konvolusi untuk memproses *input* dengan filter. Secara keseluruhan, CNN tidak jauh berbeda dengan jaringan saraf biasa yang terdiri dari neuron-neuron yang memiliki bobot, bias, dan fungsi aktivasi. Proses CNN terdiri dari dua tahap utama, yaitu pembelajaran (*training*) yang menggunakan metode *backpropagation*, dan tahap klasifikasi yang memanfaatkan *forward propagation*.

Menurut (Ramadhani dkk., 2023) *Convolutional Neural Network* (CNN) adalah jaringan saraf yang umum digunakan dalam analisis gambar untuk mengidentifikasi objek. CNN dirancang khusus untuk memproses gambar dalam format *array*, seperti gambar berwarna yang terdiri dari tiga *array* 2D mewakili intensitas piksel dalam tiga saluran warna. CNN memanfaatkan sifat-sifat alami sinyal seperti koneksi lokal, pembagian parameter, *pooling*, dan lapisan berlapis. Proses pengolahan citra melibatkan empat model utama: *Convolution Layer*, *Pooling Layer*, *Dropout Layer*, dan *Fully Connected Layer*. Data pelatihan yang baik diperlukan untuk hasil klasifikasi yang akurat.

CNN terdiri dari beberapa lapisan, termasuk *Convolutional Layer*, di mana filter digunakan untuk mendeteksi karakteristik objek atau citra. *Stride* dan *padding* adalah parameter yang dapat dimodifikasi untuk mengontrol pergeseran dan informasi yang hilang pada data *input*. Lapisan ReLu memperkenalkan *nonlinearitas*, sedangkan lapisan *pooling* mengurangi dimensi fitur dengan menggabungkan data. *Fully Connected Layer* memanfaatkan koneksi penuh antara neuron pada lapisan sebelumnya. Gambar 7 berikut menggambarkan proses dari *Convolutional Neural Network* (CNN).




Gambar 7. Arsitektur CNN (Husna dkk., 2022).

2.9.1 *Convolutional Layer*

Convolutional Layer adalah salah satu proses dari dua fungsi yang memiliki nilai riil. Lapisan ini menghasilkan fungsi *output* sebagai representasi fitur atau peta fitur dari nilai *input* dari citra. *Input* dan *output* ini berperan sebagai argumen yang memiliki nilai riil (Husna et al., 2022). *Convolutional Layer* melibatkan operasi konvolusi terhadap *output* dari lapisan sebelumnya, yang merupakan elemen utama yang mendasari arsitektur CNN dan menjadi lapisan inti dalam sistem yang digunakan dalam CNN. Konvolusi adalah sebuah konsep matematis yang digunakan untuk memproses citra dengan menerapkan kernel, yang sering disebut sebagai kotak kuning, ke suatu *offset* yang ditentukan pada citra, seperti yang dijelaskan dalam gambar.

Kotak kuning, atau kernel, bergerak dari sudut kiri atas ke sudut kanan bawah pada citra yang berwarna hijau secara keseluruhan. Proses ini menghasilkan konvolusi dari citra, yang ditampilkan dalam gambar di sebelah kanan. Tujuan dari proses ini adalah untuk mengekstraksi fitur dari citra *input*. Konvolusi menghasilkan transformasi linier dari data *input* sesuai dengan konfigurasi sistem yang telah ditetapkan (Sandi dkk., 2022). Ilustrasi Proses *Convolution Layer* ditunjukkan pada Gambar 8.




Gambar 8. *Convolution Layer* (Sandi dkk., 2022).

2.9.2 Pooling Layer

Pooling layer adalah lapisan di mana terjadi pengurangan ukuran citra setelah melalui lapisan konvolusi. Terdapat dua jenis *layer pooling*, yaitu *maximum pooling layer* dan *average pooling layer*. Pada *maximum pooling layer*, citra keluaran dari jaringan konvolusional dibagi menjadi beberapa *grid* kecil, di mana nilai maksimum dari setiap *grid* akan disimpan ke dalam matriks citra yang telah direduksi oleh *pooling layer* (Husna dkk., 2022). Berikut


merupakan contoh dari *operasi max* dan *average pooling layer* yang ditunjukkan pada Gambar 9.



Gambar 9. *Pooling Layer* (Husna dkk., 2022).

2.9.3 Fully Connected Layer


Fully-connected layer adalah bagian akhir dari jaringan yang berfungsi sebagai penghubung antara neuron-neuron dari lapisan-lapisan sebelumnya. Lapisan ini sering digunakan dalam jaringan saraf *multilayer perceptron* (MLP) dengan tujuan mengubah dimensi data agar bisa diklasifikasikan secara linear atau semaksimal mungkin (Sandi dkk., 2022). Ketika proses tersebut dijalankan maka akan menjadikan informasi data spasialnya akan hilang dan tidak dapat dikembalikan, *fully-connected layer* dapat diimplementasikan hanya di akhir neuron (Megawati & Iskandar Mulyana, 2023). Seperti yang terlihat pada Gambar 10.



Gambar 10. *Fully Connected Layer* (Sari, 2022).

2.9.4 *Rectified Linear Units (ReLU)*

ReLU adalah fungsi aktivasi yang bertujuan untuk membatasi keluaran yang dihasilkan dari *layer pooling*. Fungsinya adalah untuk mempercepat proses pelatihan dengan mengubah nilai negatif menjadi nol dan menjaga nilai positif pada ReLU (Husna dkk., 2022). Dengan menggunakan ReLU, proses maju dan mundur dapat dilakukan hanya dengan menggunakan kondisi *if*. Jika nilai elemennya negatif, maka nilai tersebut dapat diset atau dikembalikan menjadi 0, tanpa adanya operasi perkalian atau pembagian seperti yang terjadi pada operasi eksponensial. Persamaan rumus fungsi aktivasi *Rectified Linear Unit* (ReLU) dapat dilihat pada Gambar 11.



Gambar 11. *ReLu Activation Function* (Husna dkk., 2022).


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

Convolutional Neural Network (CNN) adalah model *Deep Learning* yang dirancang untuk memproses data berbentuk *grid*, seperti gambar, dan sangat efektif dalam tugas-tugas pengenalan pola visual. CNN bekerja dengan memanfaatkan lapisan konvolusi yang berfungsi untuk mengekstraksi fitur-fitur penting dari gambar, yang kemudian diklasifikasikan dalam lapisan *fully connected*. Model CNN dasar telah menjadi fondasi bagi berbagai teknik pengenalan objek.

Namun seiring dengan meningkatnya kebutuhan deteksi dan klasifikasi objek yang lebih cepat dan efisien terbentuklah Fast R-CNN. Fast R-CNN

adalah pengembangan dari CNN yang memperbaiki efisiensi dalam deteksi dan klasifikasi objek. Dalam Fast R-CNN, algoritma menggunakan *selective search* untuk menghasilkan "*region proposals*" atau wilayah yang mungkin mengandung objek. Wilayah-wilayah ini kemudian diproses oleh CNN untuk menghasilkan peta fitur, yang akan digunakan untuk klasifikasi dan regresi *bounding box*. Dengan menggabungkan deteksi objek dan klasifikasi dalam satu jaringan tunggal, Fast R-CNN mengurangi waktu komputasi dibandingkan metode klasifikasi objek tradisional.

Meskipun lebih cepat, *selective search* masih tergolong lambat dan menjadi hambatan kinerja. Untuk mengatasi hal ini, Faster R-CNN diperkenalkan dengan inovasi *Region Proposal Network* (RPN) yang secara otomatis menghasilkan *region proposals*, sehingga memungkinkan klasifikasi objek lebih cepat dan efisien dalam pelatihan *end-to-end*. Faster R-CNN menjadi tonggak penting dalam pengembangan model klasifikasi objek berbasis *Deep Learning*.



Gambar 12. Model Faster R-CNN (Fahriska, 2022).

Gambar 12 menunjukkan model Faster R-CNN yang terdiri dari empat langkah berikut.


1. Lapisan konvolusi membuat dan mengirimkan *feature map* kepada RPN
2. RPN memproses *feature map* yang ada dan membuat *region proposal* serta membuat *bounding box* yang kemungkinan terdapat objek
3. Lapisan *RoI pooling* diaplikasikan pada proposal ini untuk mengubah semua proposal ke ukuran yang sama.
4. Lapisan *classifier* (Faster R-CNN) melakukan klasifikasi terhadap proposal yang telah dibuat RPN dengan memberikan label kelas objek pada proposal dan menentukan koordinat *bounding box* dari objek tersebut (Fahriska, 2022).

2.10.1 Region Proposal Network (RPN)

Region Proposal Network (RPN) adalah perkembangan dari metode proposal wilayah yang telah dioptimalkan untuk menghasilkan proposal wilayah dengan kualitas tinggi. RPN dapat menerima *input* dengan berbagai ukuran karena memiliki tiga rasio ukuran, yaitu 1:1, 1:2, dan 2:1, serta tiga skala ukuran, yaitu 128, 256, dan 512, menghasilkan sembilan jenis *Region of Interest* (RoI) atau *anchor*. *Anchor* merupakan wilayah yang dievaluasi untuk menentukan apakah terdapat objek di dalamnya atau tidak. RPN menghasilkan beberapa kotak pembatas (*bounding box*), masing-masing dengan probabilitas terdapatnya objek di dalam wilayah tersebut.

Hanya sebagian proposal wilayah yang berisi objek yang diambil, sementara yang lainnya tidak berisi objek untuk digunakan sebagai peta fitur. Kemudian, peta fitur ini dihubungkan ke lapisan terhubung penuh (*fully connected layer*) untuk menentukan

probabilitas masing-masing proposal wilayah mengandung objek atau tidak, serta menghasilkan penyesuaian kotaknya (*box regressor*) (Octavia, 2020).



Gambar 13. *Region Proposal Network* (RPN) (Octavia 2020).

Gambar 13 menunjukkan hasil prediksi dari proses RPN akan dibandingkan dengan *ground truth* untuk menghasilkan selisih atau error, yang diperkecil dengan meminimumkan fungsi objektif menggunakan fungsi kerugian (*loss function*) (Octavia, 2020).

2.10.2 *Region of Interest* (RoI) of Faster R-CNN


Region of Interest (RoI) adalah fitur yang bertujuan untuk menemukan dan memilih area tertentu pada citra digital untuk dilakukan analisis tekstur citra. Ross Girshick memperkenalkan RoI pada tahun 2015 sebagai metode pendekatan dalam mengklasifikasi objek menggunakan *Deep Learning*. *Input* yang dimasukkan ke dalam lapisan RoI adalah peta fitur yang dihasilkan oleh CNN dengan *multiple convolution layers* dan *max pooling layers*. Sebuah matriks berukuran $N \times N$ dibuat dengan membagi wilayah peta fitur menjadi RoI (Megawan dkk., 2022). RoI memungkinkan penerapan pengkodean yang berbeda pada area yang dipilih dari citra digital, sehingga menghasilkan kualitas yang lebih baik dibandingkan

dengan area sekitarnya. Fitur ini menjadi penting ketika terdapat bagian tertentu dari citra digital yang memiliki signifikansi yang tinggi (Asmara dkk., 2023).

2.11 *Residual Network (ResNet-50)*

Residual Network (ResNet-50) adalah arsitektur jaringan saraf yang diperkenalkan oleh Kaiming He dan rekan-rekannya pada tahun 2015. ResNet dirancang untuk mengatasi masalah *vanishing gradients* yang sering terjadi pada jaringan saraf dengan banyak lapisan tersembunyi. Masalah ini muncul ketika ukuran gradien menjadi sangat kecil saat melewati jaringan, sehingga menyulitkan proses pelatihan. ResNet mengatasi masalah ini dengan memperkenalkan *skip connections*, yang memungkinkan gradien untuk melewati lapisan tertentu tanpa harus melalui proses yang ada di lapisan tersebut. Dengan adanya *skip connections*, ResNet dapat mempelajari pemetaan residual antara *input* dan *output* di setiap lapisan.


Dalam percobaan yang dilakukan menggunakan dataset ImageNet, arsitektur ResNet menunjukkan bahwa semakin banyak lapisan yang dimiliki, semakin rendah kesalahan pelatihan dan semakin tinggi akurasi (He dkk., 2016). Dalam penelitiannya, He dan timnya menguji berbagai jenis arsitektur ResNet pada dataset ImageNet, CIFAR-10, dan MS-COCO. Mereka menemukan bahwa beberapa arsitektur ResNet seperti ResNet18, ResNet34, ResNet50, ResNet101, dan ResNet152 memiliki performa yang cukup optimal. Perbedaan antara setiap arsitektur ResNet terletak pada jumlah lapisan yang digunakan. ResNet memperkenalkan konsep melewati blok *convolutional layer* dengan memanfaatkan *shortcut* (pintasan), yang membentuk blok yang disebut *residual block* (Octavia, 2020), seperti yang ditunjukkan pada Gambar 14.



Gambar 14. *Residual* Blok (Octavia, 2020).

Pintasan ini umumnya berupa fungsi identitas atau *convolutional layer* sederhana saat diperlukan kompatibilitas dimensi. Tujuan dari pintasan tersebut adalah mempercepat proses pembelajaran dalam pemetaan dengan mengganggu *input x*, sehingga pembelajaran dimulai dari titik yang paling dekat dengan fungsi identitas (Octavia, 2020).

Penelitian ini menggunakan ResNet-50 yang berarti memiliki 50 *layer* seperti pada Gambar 15.



Gambar 15. Arsitektur ResNet-50 (Octavia, 2020).

2.12 *Confusion Matrix*

Confusion matrix adalah suatu matriks yang digunakan untuk mengevaluasi kinerja suatu klasifikasi dengan membandingkan prediksi yang benar atau salah terhadap objek. Matriks ini menyediakan informasi tentang nilai yang benar dan prediksi pada suatu klasifikasi. *Confusion matrix* terdiri dari empat sel yang merepresentasikan jumlah prediksi yang benar dan prediksi yang salah. Ini adalah representasi tabular dari prediksi yang akan dibandingkan dengan kelas asli dari *input*, yang mengandung informasi nilai aktual dan prediksi pada klasifikasi.

Confusion matrix digunakan untuk menilai kinerja model klasifikasi yang menggunakan data dengan jawaban yang benar (supervisi). Dari matriks ini, berbagai metrik seperti akurasi, *recall*, presisi, *f1-score*, dan banyak lagi dapat dihitung untuk model klasifikasi yang bersangkutan, tergantung pada kondisi data yang diprediksi atau diklasifikasikan. Prediksi *Confusion Matrix* dapat dilihat pada Tabel 2.

Tabel 2. Prediksi *Confusion Matrix*.

Aktual \ Prediksi	Prediksi	
	Positive	Negative
Positive	True Positive	False Positive
Negative	False Negative	True Negative

Isi dari tabel *confusion matrix* ada 4, yaitu:

- a. *True Positive* (TP), kondisi dimana model mengklasifikasikan data sebagai ya (*TRUE*) dan jawaban aktualnya adalah ya (*TRUE*).

- b. *True Negative* (TN), kondisi dimana model mengklasifikasikan data sebagai tidak (*FALSE*) dan jawaban aktualnya adalah tidak (*FALSE*).
- c. *False Positive* (FP), kondisi dimana model mengklasifikasikan data sebagai ya (*TRUE*) dan jawaban aktualnya adalah tidak (*FALSE*).
- d. *False Negative* (FN), kondisi dimana model mengklasifikasikan data sebagai tidak (*FALSE*) dan jawaban aktualnya adalah ya (*TRUE*)

Penentuan metrik yang digunakan, berdasarkan data dari matriks kebingungan, mencakup akurasi, presisi, *recall*, dan *f1-score* (Shianto et al. n.d.). Akurasi mengevaluasi tingkat kebenaran keseluruhan dalam pengklasifikasian model. Persamaan (2) dapat digunakan untuk menghitung akurasi.

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

Presisi adalah rasio antara jumlah data yang secara tepat diklasifikasikan sebagai positif oleh model dan total data yang diklasifikasikan sebagai positif. Persamaan (3) dapat digunakan untuk menghitung presisi.

$$\text{Presisi} = \frac{TP}{TP+FP} \quad (3)$$

Recall merupakan pengukuran untuk data dengan klasifikasi positif yang benar oleh model. *Recall* dapat dihitung menggunakan Persamaan (4).

$$\text{Recall} = \frac{TP}{TP+FN} \quad (4)$$

Tujuan dari *F1-Score* adalah untuk menggabungkan presisi dan *recall* dalam sebuah metrik tunggal. *F1-Score* menghitung rata-

rata harmonik dari presisi dan *recall*. Persamaan (5) dapat digunakan untuk menghitung *F1-Score*.

$$F1-Score = 2 \times \frac{Recall \times Presisi}{Recall + Presisi} \quad (5)$$

Dengan *confusion matrix* dapat menghitung matriks evaluasi model klasifikasi seperti akurasi, presisi, *recall*, *f1-score* dan lainnya (Pratiwi, 2023).

III. METODE PENELITIAN

3.1 Waktu dan Tempat Penelitian

3.1.1 Tempat Penelitian

Penelitian ini dilaksanakan di Lab. Komputasi Dasar Jurusan 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 Kegiatan.

Kegiatan Penelitian	2024																			
	Februari				Maret				April				Mei				Juni			
	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
Identifikasi Masalah																				
Pengumpulan Dataset																				
Implementasi Model																				
Pelatihan Model																				
Pengujian Model																				
Evaluasi																				
Analisis																				

3.2 Alat Pendukung

Alat pendukung yang digunakan dalam penelitian ini, yaitu :

3.2.1 Perangkat Keras (*Hardware*)

Perangkat keras yang digunakan ditunjukkan pada Tabel 4 dibawah ini.

Tabel 4. Perangkat Keras.

No	Perangkat	Spesifikasi
1	Laptop	- Laptop : ASUS Vivobook 14 K413 - Processor : Intel® Core™ i5-1135G7 - Penyimpanan : SSD 512GB - RAM : 8 GB DDR4

		• GPU : Intel Iris Xe Graphics
2	<i>Smartphone</i>	• 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	Tripot	• Tinggi 135cm

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 ini untuk menjalankan semua perangkat lunak yang dibutuhkan dalam riset, sistem operasi ini menyediakan lingkungan yang diperlukan untuk melaksanakan program-program yang digunakan dalam proses pengolahan data, pelatihan model, dan pengujian model (Widayati dkk., 2023).

b. ***Python* versi 3.9.0**

Bahasa pemrograman yang dipakai dalam penelitian ini adalah *Python*. Versi *Python* yang digunakan adalah 3.9.0. Alasan pemilihan *Python* adalah karena tersedia banyak pustaka yang mendukung pengembangan *machine learning* dan *Deep Learning*, seperti *TensorFlow* dan pustaka-pustaka terkait lainnya yang diperlukan dalam menerapkan model Faster R-CNN (Sambi dkk., 2023).

c. ***Packages***

1. *OpenCV 4.10.0*

Perpustakaan library ini digunakan untuk pra-pemrosesan citra yang dapat membantu meningkatkan kualitas citra sebelum diterapkan pada model Faster R-CNN, Contohnya untuk melakukan cropping, resize image dalam proses *pre-processing* data citra. Perpustakaan ini digunakan untuk memperkaya dataset pelatihan dan menguji performa model (Muchtar & Apriadi, 2019)

2. *Matplotlib versi 3.7.1*

Matplotlib adalah *library* komprehensif untuk menciptakan visualisasi grafik yang interaktif pada bahasa pemrograman python. *Matplotlib* memudahkan pengguna untuk membuat berbagai jenis grafik dan plot, seperti grafik garis, batang, dan banyak lagi. Versi 3.7.1 mencakup sejumlah pembaruan dan perbaikan dari versi sebelumnya, yang meningkatkan stabilitas, kompatibilitas, serta fitur tambahan dalam visualisasi (Kaestria dkk., 2024).

3. *Numpy versi 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).

4. *Sklearn versi 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*, akurasi, presisi, *labelling* dan sebagainya (Trihardianingsih & Lasatira, 2024).

5. *Tensorflow* versi 2.15

Tensorflow adalah *library* yang wajib digunakan dalam sebuah *project machine learning*. *Library* ini menyediakan semua alat dan fungsi yang dibutuhkan untuk melakukan pelatihan dan evaluasi model pada *machine learning* (Nugroho dkk., 2020).

3.3 Tahapan Penelitian

Dapat dilihat pada Gambar 16 berikut merupakan alur metodologi penelitian.



Gambar 16. Alur Metodologi Penelitian

3.3.1 Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini adalah data primer berupa citra atau gambar wajah pengendara sepeda motor yang tidak mengenakan helm, pengendara dengan helm *double visor* dan seluruh kaca tertutup, pengendara dengan helm yang hanya *double*

visor tertutup, pengendara dengan helm tertutup dan memakai masker, dan pengendara dengan masker yang memakai helm *double visor* tertutup. Dataset diambil secara langsung di area parkir motor mahasiswa Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Universitas Lampung pada siang hari pukul 10.00 – 14.00 dengan kondisi pencahayaan yang baik menggunakan *smartphone*. Data gambar yang digunakan berformat JPG atau JPEG (*Joint Photographic Experts Group*).

3.3.2 Anotasi Data

Pada proses ini citra *training* akan dilabeli atau dianotasi. Anotasi data mencakup pemberian koordinat kotak pembatas (*bounding box*), kelas, dan ukuran kotak pembatas pada wajah pengendara sepeda motor yang mengenakan dan tidak mengenakan helm. Data anotasi gambar yang dihasilkan akan digunakan dalam proses *training*.

3.3.3 Pre-processing

Dalam melakukan *pre-processing* pada penelitian ini, akan dilakukan beberapa tahapan yaitu, *cropping* dan *resize image*, anotasi data, serta augmentasi data.

a. Cropping dan Resizing

Pada tahapan ini *cropping* dilakukan untuk membuang bagian-bagian yang tidak relevan dari citra keseluruhan, terfokus pada area wajah agar model hanya memproses area yang ingin di klasifikasi. Pemotongan ini tidak hanya membantu mengurangi beban komputasi karena jumlah data yang diproses lebih sedikit, tetapi juga meningkatkan akurasi model dengan menghilangkan

gangguan dari bagian gambar yang tidak relevan. Pada Faster R-CNN, gambar akan melalui proses pemotongan dan perubahan ukuran sehingga memiliki dimensi *input* sebesar 600×600 piksel.

b. Pembagian Dataset

Setelah proses anotasi data selesai, dataset akan dipartisi menjadi tiga bagian: data pelatihan (*training* dataset), data validasi (*validation* dataset), dan data pengujian (*testing* dataset), menggunakan teknik *random sampling* dengan pembagian 70:10:20. Data pelatihan (*training*) adalah data yang digunakan untuk melatih model, data latih yang digunakan pada penelitian ini diambil secara acak dari dataset utama sebanyak 80% dari total keseluruhan dataset. Data validasi adalah data yang digunakan pada tahap *training* model untuk melakukan validasi terhadap hasil *training* pada setiap iterasi dan dilakukan untuk mencegah *overfitting*. Data validasi yang digunakan pada penelitian ini sebanyak 10% dari dataset utama. Setelah melalui proses validasi, model akan diuji pada tahap pengujian (*testing*). Data pengujian merupakan data yang digunakan dalam tahap pengujian pada model. Data uji yang digunakan pada penelitian ini sebanyak 20% dari total dataset utama untuk mendapatkan evaluasi akhir.

c. Augmentasi Data

Selanjutnya proses augmentasi data, pada proses augmentasi data dilakukan 2 x augmentasi dari data asli yaitu dengan teknik augmentasi rotasi 10° dan -10° . Augmentasi merupakan teknik yang digunakan untuk memperbanyak variasi data pelatihan tanpa perlu mengumpulkan data baru. Teknik tersebut membantu

memperkaya dataset dan membuat model lebih fleksibel serta mampu mengenali objek dalam berbagai orientasi.

3.3.4 *Training Model*

Proses *training* dilakukan untuk meningkatkan kemampuan model dalam mengklasifikasi untuk mengenali wajah pada pengendara sepeda motor roda dua secara akurat. *Input* yang digunakan dalam proses pelatihan ini adalah data primer berupa gambar yang menggambarkan wajah yang mengenakan dan tidak mengenakan helm dalam berbagai situasi, termasuk perbedaan sudut dan jarak pengambilan gambar. Hasil dari tahap pelatihan ini adalah bobot yang telah terlatih (*trained weight*) dan *file* konfigurasi yang akan digunakan dalam tahap *testing* berikutnya.

Pelatihan dilakukan menggunakan arsitektur ResNet-50 dan pengaturan *hyperparameter* yang disesuaikan dengan kebutuhan. Fitur yang telah diekstraksi kemudian dikirim ke dalam *Region Proposal Network* (RPN), yang bertugas mengidentifikasi area-area potensial yang mengandung objek (wajah pengendara). RPN mengusulkan beberapa area yang terdeteksi sebagai wajah pengendara, dan area tersebut kemudian diproses lebih lanjut menggunakan RoI (*Region of Interest pooling*). Tujuan dari RoI *pooling* adalah untuk menstandarkan ukuran objek yang diusulkan sehingga model dapat memproses setiap area secara konsisten.

Output dari proses ini adalah prediksi koordinat *bounding box* yang menunjukkan posisi wajah pengendara dalam gambar, serta klasifikasi yang menentukan bahwa bagian tersebut merupakan wajah pengendara atau bukan. Selama proses pelatihan, model dioptimalkan menggunakan data latih, dan bobot yang dihasilkan digunakan untuk mendeteksi wajah pengendara pada data uji.

Dalam proses pelatihan, akurasi prediksi model sangat dipengaruhi oleh *hyperparameter*. *Hyperparameter* ini berfungsi sebagai pengatur proses pelatihan model dan memiliki dampak signifikan terhadap kinerja serta ketepatan prediksi model.

3.3.5 *Testing Model*

Pada tahap ini adalah pengujian model yang telah dilatih dengan menggunakan data uji (test data) dan bobot yang diperoleh dari hasil pelatihan, berikut adalah tahapannya:

Model Faster R-CNN yang sudah dilatih akan memproses data uji dan menghasilkan prediksi yang terdiri dari beberapa informasi penting, yaitu kelas objek yang terdeteksi (*class*), posisi kotak pembatas objek (*bounding box* atau *bbox*), serta nilai *confident score*, yang mengindikasikan seberapa yakin model terhadap prediksinya.

Selanjutnya model akan melakukan proses *filtering* atau penyaringan berdasarkan nilai *confident score*. Proses ini bertujuan untuk memilih prediksi yang memiliki tingkat keyakinan tertinggi di antara berbagai prediksi yang mungkin muncul dari data yang sama. Dengan cara ini, prediksi dengan nilai *confident score* terbesar akan diambil untuk klasifikasi akhir.

Setelah melalui proses *filtering*, prediksi akhir berupa informasi kelas dan *bounding box* yang memiliki nilai *confident score* tertinggi akan diproses lebih lanjut. *Bounding box* yang dihasilkan kemudian diverifikasi kembali untuk memastikan bahwa posisi dan ukuran kotak pembatas sudah sesuai dengan objek sebenarnya di dalam gambar uji. Langkah ini penting untuk meningkatkan akurasi deteksi dan mengurangi kemungkinan adanya prediksi yang salah.

3.3.6 *Intersection over Union (IoU)*

Tahap selanjutnya adalah menghitung Intersection over Union (IoU) untuk setiap deteksi wajah pengendara. IoU digunakan untuk mengukur tingkat kesesuaian antara prediksi model dan ground truth dalam dataset. Proses ini dilakukan dengan cara membandingkan area wajah yang diprediksi oleh model dengan area sebenarnya yang telah diberi label pada dataset. Nilai IoU ini membantu menentukan tingkat akurasi deteksi model dalam mengenali wajah pengendara secara keseluruhan.

3.3.7 *Classification*

Pada tahap klasifikasi wajah pengendara, model Faster R-CNN yang telah dilatih digunakan untuk mengidentifikasi beberapa kategori helm, yaitu pengendara tanpa helm, pengendara dengan helm *double visor* dan seluruh kaca tertutup, pengendara dengan helm yang hanya *double visor* tertutup, pengendara dengan helm tertutup dan memakai masker, dan pengendara dengan masker yang memakai helm *double visor* tertutup.

Proses ini dimulai dengan deteksi wajah dari gambar yang telah melalui tahap *pre-processing*. Model kemudian menganalisis fitur visual dan menentukan kategori objek berdasarkan posisi kotak pembatas (*bounding box*) dan nilai *confident score*, di mana prediksi dengan nilai keyakinan tertinggi diambil sebagai hasil akhir.

3.3.8 Evaluasi

Evaluasi ini bertujuan untuk menilai kinerja model yang telah dikembangkan dalam tugas mengklasifikasi wajah pada pengendara sepeda motor roda dua yang mengenakan ataupun tidak mengenakan helm. Evaluasi dilakukan dengan memperhatikan beberapa metrik penting seperti akurasi, *recall*, presisi, *f1-score*, dan IoU yang akan menjadi indikator seberapa baik model tersebut dalam melakukan klasifikasi objek. Metrik-metrik evaluasi ini dihitung secara matematis berdasarkan hasil *true positive*, *true negative*, *false positive*, dan *false negative* yang dihasilkan selama proses pengujian.

Akurasi mengindikasikan seberapa tepat prediksi model terhadap nilai aktual, presisi mengevaluasi keakuratan dalam mengenali objek atau kelas yang benar, *recall* mengukur sejauh mana model dalam mengidentifikasi secara lengkap, sementara *f1-score* mengintegrasikan presisi dan *recall* menjadi satu nilai evaluasi untuk memberikan gambaran keseluruhan tentang kinerja model.

Selain itu, IoU (*Intersection over Union*) juga dihitung untuk mengevaluasi seberapa baik posisi dan ukuran kotak pembatas (*bounding box*) yang dihasilkan oleh model dibandingkan dengan kotak pembatas sebenarnya. IoU dihitung dengan membagi area tumpang tindih antara prediksi dan nilai aktual dengan total area gabungan keduanya. Semakin tinggi nilai IoU, semakin baik akurasi posisi dan ukuran kotak pembatas yang dihasilkan.

3.3.9 Analisis Kinerja Model

Evaluasi metrik seperti akurasi, presisi, *recall*, dan *f1-score* akan dianalisis secara rinci. Kekuatan dan kelemahan model dalam mengklasifikasikan wajah dengan berbagai kelas yang berbeda untuk diidentifikasi, serta alasan di balik keberhasilan dan

kegagalan tersebut. Berdasarkan hasil analisis, beberapa rekomendasi perbaikan model akan diajukan , seperti modifikasi arsitektur atau perluasan dataset, dengan tetap mempertimbangkan berbagai kendala dan keterbatasan penelitian.

V. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Kesimpulan dari penelitian yang telah dilakukan sebagai berikut:

1. Penelitian ini berhasil melakukan klasifikasi wajah pada pengendara sepeda motor roda dua menggunakan model Faster R-CNN dengan ekstraktor fitur ResNet-50, yang diuji pada tiga kondisi berbeda. Terdapat 3 kondisi yang diuji yaitu: data asli, data augmentasi rotasi 10° , dan rotasi -10° . Juga dengan beberapa kategori yaitu: pengendara tanpa helm, pengendara dengan helm *double visor* dan seluruh kaca tertutup, pengendara dengan helm yang hanya *double visor* tertutup, pengendara dengan helm tertutup dan memakai masker, dan pengendara dengan masker yang memakai helm *double visor* tertutup.
2. Hasil evaluasi menunjukkan presisi yang tinggi (96,34%), mencerminkan kemampuan model untuk menghindari positif palsu, serta recall yang tinggi (91,55%), yang menunjukkan kemampuan mendeteksi hampir semua objek target dengan benar. Dengan F1-score sebesar 93,82%, model menunjukkan keseimbangan yang sangat baik antara presisi dan recall, yang secara keseluruhan mencerminkan kemampuan model untuk mengenali dan mengklasifikasikan wajah pengendara secara akurat, bahkan dalam berbagai kondisi

5.2 Saran

Saran yang dapat diberikan untuk melanjutkan penelitian ini sebagai berikut:

1. Penelitian selanjutnya sebaiknya dilakukan dengan memperluas jumlah dataset baik dalam hal jumlah sampel maupun variasi data, termasuk kondisi pencahayaan, sudut pandang, dan atribut pengendara.
2. Melanjutkan pengembangan model Faster R-CNN dengan fitur ekstraktor lainnya seperti VGG-16, ResNet101, dll.
3. Mengembangkan kamera berbasis *Internet of Things* untuk sistem presensi otomatis di area kampus melalui portal masuk FMIPA Universitas Lampung.
4. Mengembangkan sistem berbasis android untuk klasifikasi objek secara *real-time*.

DAFTAR PUSTAKA

- Asmara, B. D. Y., Wulaningrum, R., & Helilintar, R. (2023). Implementasi Region of Interest (ROI) Untuk Segmentasi Citra Tanda Tangan. *Agustus*, 7, 2549–7952. <https://proceeding.unpkediri.ac.id/index.php/inotek/>
- Assidiqi, M. R. (2023). *Rancang Bangun Sistem Pendeteksi Dan Penghitung Jumlah Pengunjung Di Museum Lampung Menggunakan Webcam Berbasis Algoritma Yolov5 (You Only Look Once Versi Lima)*. .(Skripsi Universitas Lampung), 10.
- 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>
- Devi, D. T., Santos, V. A., & Rosyani, P. (2023). *Analisa Penggunaan Metode Faster R-CNN dalam Pengenalan Wajah*. <https://jurnalmahasiswa.com/index.php/biikma>
- Fahriska, R. (2022). *Modifikasi Anchor Pada Metode Faster Region Based Convolutional Neural Network Untuk Deteksi Objek Pada Citra Leukosit Manusia*. .(Skripsi UIN Syarif Hidayatullah Jakarta), 15–16.
- Faniyah, I., & Yahya, H. (2023). Pengaruh Pandemi Covid-19 Terhadap Meningkatnya Kejahatan Konvensional Perspektif Politik Kriminal. *UNES Law Review*, 5(3), 628–638. <https://doi.org/10.31933/unesrev.v5i3.400>
- G.Zaharchuk, E.Gong, M.Wintermark, D.Rubin, & P.Langlotz. (2018). *Deep learning In Neuroradiology*. 10, 1776–1784.

- He, K., Zhang, X., Ren, S., & Sun, J. (2016). *Deep Residual Learning for Image Recognition*. <https://doi.org/https://doi.org/10.1109/CVPR.2016.90>
- Husna, N. I., Ulum, M., Kurniawan Saputro, A., Haryanto, Laksono, T. D., & Purnamasari, D. N. (2022). Rancang Bangun Sistem Deteksi Dan Perhitungan Jumlah Orang Menggunakan Metode Convolutional Neural Network (CNN). *Seminar Nasional Fortei Regional*, 7, 2–3.
- Ilyas, M. (2020). *Deteksi Pelanggaran Berkendara Dengan Metode Yolo (You Only Look Once)*. (Skripsi Universitas Komputer Indonesia), 11.
- 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), 261–267. <https://www.idiap.ch/dataset/replayattack>.
- Megawan, S., Lestari, W. S., & Halim, A. (2022). Deteksi Non-Spoofing Wajah pada Video secara Real Time Menggunakan Faster R-CNN. *Journal of Information System Research (JOSH)*, 3(3), 291–299. <https://doi.org/10.47065/josh.v3i3.1519>
- Megawati, & Iskandar Mulyana, D. (2023). Deteksi Wajah Hijab Menggunakan Data Augmentation dan Metode Convolutional Neural Network Hijab Face Detection Using Data Augmentation and Convolutional Neural Network Methods. *Journal of Science and Technology Naskah*, 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)*. 2(1)(1), 39–42.
- Mustofa, I. H., & Winarno, E. (2023). Sistem Pengenalan Wajah Bermasker dengan Metode Convolutional Neural Network. *Jurnal Grafis Komputer*, 16(1), 55–66. <https://doi.org/10.51903/pixel.v16i1.1062>

- Nugroho, P. A., Fenriana, I., & Arijanto, R. (2020). IMPLEMENTASI DEEP LEARNING MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) PADA EKSPRESI MANUSIA. *JURNAL ALGOR*, 2(1)(1), 12–21. <https://jurnal.buddhidharma.ac.id/index.php/algor/index>
- Putra, I. N. T. A., Kartini, K. S., Suyitno, Y. K., Sugiarta, I. M., & Puspita, N. K. E. (2023). *Penerapan Library Tensorflow, Cvzone, dan Numpy pada Sistem Deteksi Bahasa Isyarat Secara Real Time*. 2(3)(3), 412–432. <https://ejournal.sidyanusa.org/index.php/jkdn>
- Octavia, R. (2020). *Deep Learning Based Moving Vehicle Classification And Counting Using Faster R-CNN*. (Tesis, Institut Teknologi Sepuluh Nopember), 10–21.
- Pratiwi, A. O. C. (2023). Klasifikasi Jenis Anggur Berdasarkan Bentuk Daun Menggunakan Convolutional Neural Network Dan K-Nearest Neighbor. *Jurnal Ilmiah Teknik Informatika dan Komunikasi*, 3(2), 201–224. <https://doi.org/10.55606/juitik.v3i2.535>
- Rajamudin. (2019). Tinjauan Kriminologi Terhadap Timbulnya Kejahatan Yang Diakibatkan Oleh Pengaruh Minuman Keras Di Kota Makassar. *Jurnal Midwifery*, 1(1), 58–67.
- Ramadhani, F., Satria, A., & Salamah. (2023). Implementasi Algoritma Convolutional Neural Network dalam Mengidentifikasi Dini Penyakit pada Mata Katarak. *sudo Jurnal Teknik Informatika*, 2(4), 167–175. <https://doi.org/10.56211/sudo.v2i4.408>
- Ramdhon, A. N., & Febriya, F. (2021). Penerapan Face Recognition Pada Sistem Presensi. *Journal of Applied Computer Science and Technology*, 2(1), 12–17. <https://doi.org/10.52158/jacost.v2i1.121>
- Raup, A., Ridwan, W., Khoeriyah, Y., & Zaqiah, Q. Y. (2022). *Deep Learning dan Penerapannya dalam Pembelajaran*. 5, 3256–3267. <http://jiip.stkipyapisdompu.ac.id>

- Roihan, A., Sunarya, P. A., & Rafika, A. S. (2019). Pemanfaatan Machine Learning dalam Berbagai Bidang: Review paper. *IJCIT (Indonesian Journal on Computer and Information Technology)*, 5(1), 75–82.
- Kaestria, R., Himmah Elok Faiqotul, & Irawan Rio. (2024). Penerapan Matplotlib dalam Visualisasi Data untuk Analisis Hubungan Penggunaan Gadget dan Hasil Belajar. *Journal of Digital Business and Information Technology*, 1(1)(1), 29–39. <https://doi.org/10.23971/jobit.v1i1.204>
- Rosiana, P. S., Mohsa, A. A., Fadila, M. A., & Jaman, J. H. (2023). Visualisasi Data Tindak Kejahatan Berdasarkan Jenis Kriminalitas Di Kabupaten Karawang Dengan Menggunakan Algoritma Clustering K-Means. *Jurnal Informatika dan Teknik Elektro Terapan*, 11(3s1). <https://doi.org/10.23960/jitet.v1i3s1.3347>
- Sambi, U. A. M. T. I., Marpaung, E. S. K., Ong, J., Nurhaliza Putri, & Ningsih Rahmi Yulia. (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>
- Sandi, K. M., Yudha, A. P., Aryanto, N. D., & Farabi, M. A. (2022). Klasifikasi sampah menggunakan Convolutional Neural Network. *Indonesian Journal of Data and Science (IJODAS)*, 3(2), 72–81.
- Saputra, R. A., Reskal, & Wahyuni, F. M. (2022). Segmentasi Pada Plat Kendaraan Dinas Menggunakan deteksi Tepi Canny, Prewitt, Sobel, & Roberts. *Jurnal Sains Komputer & Informatika (J-SAKTI)*, 6(1), 328–339.
- Sari, Y. (2022). *Klasifikasi Jenis Kelamin Menggunakan Metode Convolutional Neural Network (CNN) Dengan Data Wajah Manusia*. (Skripsi Universitas Lampung), 1–50.
- Shianto, K. A., Gunadi, K., & Setyati, E. (t.t.). *Deteksi Jenis Mobil Menggunakan Metode YOLO Dan Faster R-CNN*. 7, 3.

- Sholehurrohman, R. (2021). *Pengembangan Yolov3 Dengan Fitur Ekstraktor MobileNetv2 Untuk Deteksi Dan Klasifikasi Kendaraan Bergerak*. (Tesis Institut Teknologi Sepuluh Nopember Surabaya), 9.
- Trihardianingsih, L., & Lasatira, G. S. (2024). Optimasi Hyperparameter GridSearchCV pada Klasifikasi Kualitas Udara menggunakan Support Vector Machine. *Jurnal Informasi dan Teknologi*, 1(2), 40–47. <https://data.jakarta.go.id/>.
- Wati, V., Yuliana, Setyowati, N. Y., & Qulub, M. (2023). Deteksi Wajah Menggunakan Algoritma Viola Jones Berbasis Android. *TEKNIMEDIA: Teknologi Informasi dan Multimedia*, 4(1), 30–37. <https://doi.org/10.46764/teknimedia.v4i1.92>
- Widayati, S., Chandra, Y. I., & Putra, A. P. (2023). PERANCANGAN APLIKASI EDUKASI MENTAL HEALTH “KIND TO MIND” MENGGUNAKAN MODEL AGILE BERBASIS WEB MOBILE. *Seminar Nasional Teknologi Informasi dan Komunikasi STI&K (SeNTIK)*, 7(1), 191–197.