



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



**Pengenalan Atribut Manusia Beserta Warna
Secara *REAL-TIME* Dengan Pendekatan Multi-
Stage Approach Menggunakan Arsitektur
YOU ONLY LOOK ONCE dan Multilayer**

PERCEPTRON

SKRIPSI

DAVA ALIF RAHMAN DAVID

2107412042

**POLITEKNIK
NEGERI
JAKARTA**

PROGRAM STUDI TEKNIK INFORMATIKA

JURUSAN TEKNIK INFORMATIKA DAN KOMPUTER

POLITEKNIK NEGERI JAKARTA

DEPOK

2025



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



**Pengenalan Atribut Manusia Beserta Warna
Secara *REAL-TIME* Dengan Pendekatan Multi-
Stage Approach Menggunakan Arsitektur
YOU ONLY LOOK ONCE dan Multilayer
Perceptron**

SKRIPSI

**Dibuat untuk Melengkapi Syarat-Syarat yang diperlukan untuk Memperoleh
Diploma Empat Politeknik**

**POLITEKNIK
NEGERI
JAKARTA**

DAVA ALIF RAHMAN DAVID

2107412042

PROGRAM STUDI TEKNIK INFORMATIKA

JURUSAN TEKNIK INFORMATIKA DAN KOMPUTER

POLITEKNIK NEGERI JAKARTA

DEPOK

2025



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

SURAT PERNYATAAN BEBAS PLAGIARISME

Saya yang bertanda tangan di bawah ini:

Nama : Dava Alif Rahman David

NIM : 2107412042

urusan/Program Studi : T. Informatika dan Komputer / Teknik Informatika

Judul skripsi : PENGENALAN ATRIBUT MANUSIA BESERTA WARNA SECARA REAL-TIME DENGAN PENDEKATAN *MULTI-STAGE APPROACH* MENGGUNAKAN ARSITEKTUR *YOU ONLY LOOK ONCE* DAN *MULTILAYER PERCEPTRON*

Menyatakan dengan sebenarnya bahwa skripsi ini benar-benar merupakan hasil karya saya sendiri, bebas dari peniruan terhadap karya dari orang lain. Kutipan pendapat dan tulisan orang lain ditunjuk sesuai dengan cara-cara penulisan karya ilmiah yang berlaku. Apabila di kemudian hari terbukti atau dapat dibuktikan bahwa dalam skripsi ini terkandung ciri-ciri plagiat dan bentuk-bentuk peniruan lain yang dianggap melanggar peraturan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Jakarta, 11 Juni 2025

Yang membuat pernyataan



Dava Alif Rahman David

NIM. 2107412042



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

LEMBAR PENGESAHAN

Skripsi diajukan oleh:

Nama mahasiswa : Dava Alif Rahman David

Nomor Induk Mahasiswa : 2107412042

Program Studi : Teknik Informatika

Judul skripsi : PENGENALAN ATRIBUT MANUSIA BESERTA WARNA
SECARA REAL-TIME DENGAN PENDEKATAN *MULTI-STAGE APPROACH* MENGGUNAKAN ARSITEKTUR
YOU ONLY LOOK ONCE DAN *MULTILAYER PERCEPTRON*

Pada hari ini Jum'at Tanggal 4 bulan Juli tahun
..... 2025 , telah diadakan Sidang skripsi untuk saudara Dava Alif Rahman David dan
dinyatakan **LULUS**

Disahkan oleh:

Pembimbing I : Dr. Dewi Yanti Liliana S.Kom., M.Kom. Cat

Penguji I : Euis Oktavianti, S.Si., M.Ti. Euis

Penguji II : Rizki Elisa Nalawati, S.T., M.T. Rizki

Penguji III : Maria Agustin, S.Kom., M.Kom. Maria

Mengetahui:

Jurusan Teknik Informatika dan Komputer

Ketua



Dr. Anita Hidayati, S.Kom., M.Kom.

NIP.197908032003122003



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

KATA PENGANTAR

Dengan mengucapkan puji syukur kehadiran Allah Subhanahu Wa Ta'ala, atas segala rahmat dan hidayah-Nya, saya berhasil merampungkan penyusunan skripsi dengan judul “Pengenalan Atribut Manusia Beserta Warna Secara *Real-time* Dengan Pendekatan *Multi-Stage Aproach* Menggunakan Arsitektur *You Only Look Once* dan *Multi-layer Perceptron*”. Penyelesaian karya ilmiah ini merupakan buah dari dukungan banyak pihak yang tak ada henti-hentinya.

Penyelesaian skripsi ini tidak terlepas dari peran serta dan kontribusi berbagai pihak. Oleh karena itu, penulis ingin menyampaikan apresiasi dan ucapan terima kasih yang setinggi-tingginya kepada:

- a. Dr. Dewi Yanti Liliana S.Kom., M.Kom., selaku Dosen Pembimbing, atas dedikasi, waktu, pemikiran, dan tenaga yang telah dicurahkan dalam memberikan bimbingan, arahan, serta masukan yang esensial. Bimbingan tersebut sangat krusial dalam membantu penulis menghasilkan *minimum viable product* dan merampungkan laporan skripsi ini.
- b. Orang tua tercinta, atas dukungan material, moral, dan untaian doa yang tak henti-hentinya. Kasih sayang dan kesabaran yang senantiasa diberikan merupakan motivasi utama bagi penulis untuk menyelesaikan penyusunan skripsi ini.
- c. Seluruh keluarga besar, atas dukungan moral, semangat, dan doa yang selalu menyertai saya sepanjang proses penyusunan skripsi ini.
- d. Seluruh teman dan rekan, atas dukungan moral, semangat, dan motivasi dalam berbagai bentuk yang tak ternilai harganya selama penyelesaian skripsi ini.

Penulis menyadari bahwa laporan skripsi ini masih memiliki keterbatasan dan kekurangan. Oleh karena itu, kritik dan saran yang bersifat membangun sangat diharapkan demi penyempurnaan laporan ini. Besar harapan penulis, semoga laporan skripsi ini dapat memberikan manfaat, baik secara teoretis maupun praktis, bagi penulis pribadi dan pihak lain yang berkepentingan.

Jakarta, 11 Juni 2025

Dava Alif Rahman David



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

SURAT PERNYATAAN PERSETUJUAN PUBLIKASI SKRIPSI UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademik Politeknik Negeri Jakarta, saya bertanda tangan di bawah ini:

Nama : Dava Alif Rahman David

NIM : 2107412042

Jurusan/Program Studi : T.Informatika dan Komputer / T.Informatika

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Politeknik Negeri Jakarta Hak Bebas Royalti Non-Eksklusif atas karya ilmiah saya yang berjudul:

Pengenalan Atribut Manusia Beserta Warna Secara Real-Time Dengan Pendekatan *Multi-Stage Approach* Menggunakan Arsitektur *You Only Look Once* Dan *Multilayer Perceptron*

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Non-Eksklusif ini, Politeknik Negeri Jakarta berhak menyimpan, mengalihmediakan/formatkan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan mempublikasikan skripsi saya tanpa meminta izin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Depok, 11 Juni 2025

Yang menyatakan



Dava Alif Rahman David

NIM. 2107412042



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

PENGENALAN ATRIBUT MANUSIA BESERTA WARNA SECARA REAL-TIME DENGAN PENDEKATAN *MULTI-STAGE APPROACH* MENGGUNAKAN ARSITEKTUR *YOU ONLY LOOK ONCE* DAN *MULTILAYER PERCEPTRON*

ABSTRAK

Dalam upaya memanfaatkan kemajuan computer vision dan deep learning untuk industri Fashion, penelitian ini berhasil mengembangkan sistem multi-tahap yang secara real-time mengidentifikasi atribut dan warna pakaian serta aksesoris (headwear, eyewear, upperwear, bottomwear, footwear, dan bag). Sistem ini memadukan YOLOv8 untuk deteksi objek (mAP@0.5: 0.797, akurasi tinggi pada upperwear, bottomwear, dan eyewear), MobileNetV2 dalam CNN untuk klasifikasi sub-kategori atribut (akurasi rata-rata >91%), dan MLP untuk klasifikasi warna berbasis RGB (akurasi 87%, dengan beberapa tantangan pada warna ambigu). Hasil pengujian Black Box menunjukkan fungsionalitas sistem 100% dan stabil, sementara User Acceptance Test (UAT) mengonfirmasi penerimaan pengguna yang sangat positif (efektivitas 88.0%, efisiensi 98.3%, kepuasan 100%), menegaskan akurasi, fungsionalitas, kemudahan, dan intuitifnya sistem ini.

Kata Kunci: Computer Vision, Deep Learning, Deteksi Objek, Klasifikasi Pakaian, Pengenalan Atribut Pakaian, Fashion AI, YOLO, CNN, Klasifikasi Warna, Klasifikasi Multi-Kelas.ss



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

DAFTAR ISI

SURAT PERNYATAAN BEBAS PLAGIARISME	i
LEMBAR PENGESAHAN	ii
KATA PENGANTAR.....	iii
SURAT PERNYATAAN PERSETUJUAN PUBLIKASI SKRIPSI UNTUK KEPENTINGAN AKADEMIS.....	iv
ABSTRAK	v
DAFTAR ISI.....	vi
DAFTAR GAMBAR	ix
DAFTAR TABEL.....	xi
DAFTAR LAMPIRAN	xiii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah	3
1.3 Batasan Masalah.....	4
1.4 Tujuan dan Manfaat	4
1.4.1 Tujuan.....	4
1.4.2 Manfaat	5
1.5 Sistematika Penulisan	5
BAB II TINJAUAN PUSTAKA	7
2.1 Penelitian Terdahulu.....	7
2.2 Computer Vision	8
2.3 Deep Learning.....	9
2.4 Multi-Layer Perceptron (MLP).....	9
2.5 You-Only-Look-Once (YOLO).....	10



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

2.6	Convolutional Neural Network (CNN).....	11
2.7	Activation Function.....	12
2.7.1	Rectified Linear Unit (ReLU)	12
2.7.2	Sigmoid Function (Logistic)	13
2.7.3	Softmax Function	13
2.8	Matriks Evaluasi.....	13
2.8.1	Metrik Evaluasi untuk Model Klasifikasi	14
2.8.2	Metrik Evaluasi untuk Model Deteksi Objek.....	15
2.9	Python	16
2.10	OpenCV	16
BAB III PERENCANAAN DAN REALISASI.....		17
3.1	Rancangan Penelitian	17
3.2	Tahapan Penelitian	17
3.2.1	Identifikasi Kebutuhan	18
3.2.2	Pengumpulan Data	19
3.2.3	Pemrosesan Data	19
3.2.4	Pengembangan Model.....	20
3.2.5	Pengujian Model	20
3.2.6	Implementasi sistem.....	20
3.2.7	Evaluasi Kinerja Sistem	21
3.3	Objek Penelitian.....	21
BAB IV HASIL DAN PEMBAHASAN.....		22
4.1	Identifikasi Kebutuhan	22
4.1.1	Identifikasi Kebutuhan Pengembangan model.....	22
4.1.2	Identifikasi Kebutuhan Perangkat Keras.....	28
4.1.3	Identifikasi Kebutuhan Perangkat Lunak.....	30



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

4.1.4	Identifikasi Kebutuhan Library dan <i>Framework</i>	31
4.1.5	Identifikasi Kebutuhan Fungsional Sistem Multi-Stage	31
4.1.6	Identifikasi Kebutuhan Non-Fungsional Sistem Multi-Stage	33
4.2	Perancangan Sistem	34
4.2.1	Pengumpulan dan Pemrosesan Dataset.....	37
4.2.2	Perancangan Model <i>Deep Learning</i>	42
4.2.3	Perancangan Antarmuka Grafis.....	48
4.3	Implementasi Sistem	53
4.3.1	Implementasi Model.....	53
4.3.2	Implementasi Antarmuka Grafis	94
4.4	Pengujian Sistem.....	96
4.4.1	Analisis Hasil Pengujian Model.....	97
4.4.2	Analisis Hasil Pengujian Sistem	115
BAB V PENUTUP.....		133
5.1	Kesimpulan	133
5.2	Saran.....	133
DAFTAR PUSTAKA.....		135
DAFTAR RIWAYAT HIDUP PENULIS		139
LAMPIRAN.....		140



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

DAFTAR GAMBAR

Gambar 2. 1 Contoh Multi-Layer Perceptron(Le et al., 2021).....	10
Gambar 2. 2 Hasil Implementasi YOLO pada data lukisan dan data dari internet(Redmon et al., 2016).....	11
Gambar 3. 1 Flow Tahapan Penelitian	18
Gambar 4. 1. Machine learning development life-cycle	22
Gambar 4. 2 Alur Kerja Sistem Multi-Stage.....	35
Gambar 4. 3 Pengumpulan dan Pemrosesan Dataset Deteksi Atribut	38
Gambar 4. 4 Pengumpulan dan Pemrosesan Dataset Klasifikasi Jenis Atribut	40
Gambar 4. 5 Alur Pengumpulan dan Pemrosesan Dataset Klasifikasi Warna	41
Gambar 4. 6 Perancangan Model Deteksi Atribut	43
Gambar 4. 7 Alur Perancangan model klasifikasi atribut	45
Gambar 4. 8 Perancangan Model Klasifikasi Warna	46
Gambar 4. 9 Use Case Diagram	48
Gambar 4. 10 Activity Diagram Real-time Camera.....	50
Gambar 4. 11 Activity Diagram Image Analysis	51
Gambar 4. 12 Activity Diagram Video Analysis.....	52
Gambar 4. 13 visualisasi hasil dataset deteksi objek	57
Gambar 4. 14 Visualisasi hasil dataset headwear.....	59
Gambar 4. 15 Visualisasi hasil dataset eyewear.....	61
Gambar 4. 16 Visualisasi hasil dataset upperwear	62
Gambar 4. 17 Visualisasi hasil dataset bottomwear.....	64
Gambar 4. 18 Visualisasi hasil dataset footwear.....	66
Gambar 4. 19 Visualisasi hasil dataset bag	67
Gambar 4. 20 Hasil training model deep learning deteksi objek	72
Gambar 4. 21 Arsitektur model klasifikasi <i>headwear</i>	73
Gambar 4. 22 History <i>training</i> akurasi model klasifikasi <i>headwear</i>	74
Gambar 4. 23 History training loss model klasifikasi headwear	75
Gambar 4. 24 Arsitektur model klasifikasi <i>headwear</i>	76
Gambar 4. 25 History <i>training</i> accuracy model klasifikasi <i>eyewear</i>	77
Gambar 4. 26 History <i>training</i> loss model klasifikasi <i>eyewear</i>	78
Gambar 4. 27 Arsitektur model klasifikasi <i>upperwear</i>	79



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Gambar 4. 28 History <i>training</i> accuracy model klasifikasi <i>upperwear</i>	80
Gambar 4. 29 History <i>training</i> loss model klasifikasi <i>upperwear</i>	81
Gambar 4. 30 Arsitektur model klasifikasi <i>bottomwear</i>	82
Gambar 4. 31 History <i>training</i> accuracy model klasifikasi <i>bottomwear</i>	84
Gambar 4. 32 History <i>training</i> loss model klasifikasi <i>bottomwear</i>	84
Gambar 4. 33 Arsitektur model klasifikasi <i>footwear</i>	85
Gambar 4. 34 History <i>training</i> accuracy model klasifikasi <i>footwear</i>	87
Gambar 4. 35 History <i>training</i> loss model klasifikasi <i>footwear</i>	88
Gambar 4. 36 Arsitektur model klasifikasi <i>bag</i>	89
Gambar 4. 37 Histpry <i>training</i> model klasifikasi <i>bag</i>	90
Gambar 4. 38 History <i>training</i> loss model klasifikasi <i>bag</i>	91
Gambar 4. 39 Arsitektur model klasifikasi warna.....	92
Gambar 4. 40 History <i>training</i> accuracy model klasifikasi warna.....	93
Gambar 4. 41 History <i>training</i> loss model klasifikasi warna.....	94
Gambar 4. 42 Implementasi anatrmuka grafis <i>real-time</i> camera	95
Gambar 4. 43 Implementasi antarmuka grafis image analysis	95
Gambar 4. 44 Implementasi antarmuka grafis video analysis	96
Gambar 4. 45 Hasil visualisasi pengujian model deteksi objek pada dataset test secara langsung.	99
Gambar 4. 46 Hasil <i>confussion matrix</i> model klasifikasi <i>headwear</i>	100
Gambar 4. 47 Hasil visualisasi model klasifikasi <i>headwear</i> pengujian pada dataset <i>test</i> secara langsung.....	101
Gambar 4. 48 Hasil <i>confussion matrix</i> model klasifikasi <i>eyewear</i>	102
Gambar 4. 49 Hasil visualisasi pengujian model klasifikasi <i>eyewear</i> pada dataset <i>test</i> secara langsung.....	103
Gambar 4. 50 Hasil <i>confussion matrix</i> model klasifikasi <i>upperwear</i>	105
Gambar 4. 51 Hasil visualisasi pengujian model klasifikasi <i>upperwear</i> pada dataset <i>test</i> secara langsung.....	106
Gambar 4. 52 Hasil <i>confussion matrix</i> model klasifikasi <i>bottomwear</i>	107
Gambar 4. 53 Hasil visualisasi pengujian model klasifikasi <i>bottomwear</i> pada dataset <i>test</i> secara langsung.....	108
Gambar 4. 54 Hasil <i>confussion matrix</i> model klasifikasi <i>footwear</i>	109



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Gambar 4. 55 Hasil visualisasi pengujian model klasifikasi <i>footwear</i> pada dataset <i>test</i> secara langsung.....	110
Gambar 4. 56 Hasil <i>confussion matrix</i> model klasifikasi <i>bag</i>	111
Gambar 4. 57 Hasil visualisasi pengujian model klasifikasi <i>bag</i> pada dataset <i>test</i> secara langsung.	112
Gambar 4. 58 Hasil <i>Confussion matrix</i> model klasifikasi warna.....	114

DAFTAR TABEL

Tabel 1. 1 Contoh Implementasi Deep Learning pada teknologi Computer Vision(B. Liu et al., n.d.).	1
Tabel 2. 1 Penelitian Sejenis	7
Tabel 4. 1 Kebutuhan Dataset	23
Tabel 4. 2 Kebutuhan pre-trained Model.....	25
Tabel 4. 3 Kebutuhan model dan pre-trained model	26
Tabel 4. 4 Kebutuhan Perangkat Keras Deteksi Objek.....	28
Tabel 4. 5 Kebutuhan Perangkat Keras Klasifikasi.....	29
Tabel 4. 6 Kebutuhan perangkat lunak.....	30
Tabel 4. 7 Kebutuhan Library dan Framework.....	31
Tabel 4. 8 Kebutuhan Fungsional	32
Tabel 4. 9 Kebutuhan Non-Fungsional Sistem Multi-Stage	34
Tabel 4. 10 <i>Metadata dataset</i>	54
Tabel 4. 11 Distribusi subset platih dataset deteksi objek.....	55
Tabel 4. 12 Distribusi anotasi bounding box kategori	56
Tabel 4. 13 Distribusi dataset final deteksi objek.....	56
Tabel 4. 14 Distribusi kelas dataset headwear	58
Tabel 4. 15 Distribusi subset pelatihan model headwear.....	59
Tabel 4. 16 Distribusi kelas dataset eyewear.....	60
Tabel 4. 17 Distribusi subset pelatihan model eyewear	60
Tabel 4. 18 Distribusi kelas dataset upperwear	61
Tabel 4. 19 Distribusi subset pelatihan model upperwear.....	62
Tabel 4. 20 Distribusi kelas dataset bottomwear	63
Tabel 4. 21 Distribusi subset pelatihan model bottomwear.....	63



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Tabel 4. 22 Distribusi kelas dataset footwear	65
Tabel 4. 23 Distribusi subset pelatihan model footwear	65
Tabel 4. 24 Distribusi kelas dataset bag	66
Tabel 4. 25 Distribusi subset pelatihan model bag	67
Tabel 4. 26 Distribusi kelas dataset warna	68
Tabel 4. 27 Distribusi subset pelatihan dataset warna	69
Tabel 4. 28 Hyperparameter model deep learning deteksi objek	70
Tabel 4. 29 Hyperparameter klasifikasi <i>headwear</i>	73
Tabel 4. 30 Hyperparameter klasifikasi <i>eyewear</i>	76
Tabel 4. 31 Hyperparameter klasifikasi <i>upperwear</i>	79
Tabel 4. 32 Hyperparameter model klasifikasi <i>bottomwear</i>	83
Tabel 4. 33 Hyperparameter model klasifikasi <i>footwear</i>	86
Tabel 4. 34 Hyperparameter model klasifikasi <i>bag</i>	89
Tabel 4. 35 Hyperparameter model klasifikasi warna	92
Tabel 4. 36 Hasil pengujian model deteksi objek	98
Tabel 4. 37 Hasil evaluasi matriks model klasifikasi <i>headwear</i>	100
Tabel 4. 38 Hasil evaluasi matriks model klasifikasi <i>eyewear</i>	102
Tabel 4. 39 Hasil evaluasi matriks model klasifikasi <i>upperwear</i>	104
Tabel 4. 40 Hasil evaluasi matriks model klasifikasi <i>bottomwear</i>	106
Tabel 4. 41 Hasil evaluasi matriks model klasifikasi <i>footwear</i>	108
Tabel 4. 42 Hasil evaluasi matriks model klasifikasi <i>bag</i>	111
Tabel 4. 43 Hasil Evaluasi matriks model klasifikasi warna	113
Tabel 4. 44 Prosedur prosedur pengujian <i>Black Box Testing</i>	121
Tabel 4. 45 Hasil Pengujian Black Box Testing	123
Tabel 4. 46 Hasil pengujian <i>user acceptance test</i>	128



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

DAFTAR LAMPIRAN

Lampiran 1 Hasil pelaksanaan UAT	140
Lampiran 2 Lampiran Pelaksanaan UAT	142
Lampiran 3 Analisis Ketinggian Kamera Dan Jarak Kamera	143





Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

BAB I PENDAHULUAN

1.1 Latar Belakang

Perkembangan teknologi dalam bidang *computer vision* dan *deep learning* telah membuka berbagai peluang besar dalam analisis visual objek. Teknologi ini memungkinkan komputer untuk mengenali, mengklasifikasi, dan memahami objek visual secara otomatis. Implementasi *computer vision* dapat ditemukan di berbagai sektor, seperti kesehatan, keamanan, produksi, dan retail, yang semakin meningkatkan efisiensi dan akurasi dalam pengolahan data visual.

Pernyataan tersebut didukung oleh analisis implementasi *deep learning* pada *computer vision* yang terdapat pada penelitian “*Integration and Performance Analysis of Artificial Intelligence and Computer Vision Based on Deep Learning Algorithms*”(B. Liu et al., n.d.) hasil analisis implementasi dapat dilihat pada Tabel 1.1.

Tabel 1. 1 Contoh Implementasi *Deep Learning* pada teknologi *Computer Vision*(B. Liu et al., n.d.).

Sektor	Contoh Penerapan	Hasil
Kesehatan	Deteksi penyakit melalui analisis citra medis, untuk membantu pemilihan keputusan tenaga medis	Meningkatkan efisiensi dan membantu pemilihan keputusan tenaga medis
Keamanan	Sistem Keamanan Pintar, mendeteksi anomali dan kejadian yang terjadi.	Meningkatkan efisiensi keamanan dan memperkuat pemantauan keamanan
Industri	Deteksi cacat produk, untuk meningkatkan kontrol produk	Meningkatkan efisiensi produksi, mengurangi pengeluaran



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Dalam industri *fashion*, pemanfaatan teknologi pengenalan atribut pakaian dan aksesoris secara *real-time* memiliki potensi besar untuk meningkatkan pengalaman belanja *online*. Dengan sistem yang mampu mengenali jenis pakaian dan warnanya, pelanggan dapat lebih mudah mencari produk yang sesuai dengan preferensi mereka melalui pencarian berbasis gambar atau rekomendasi otomatis pada platform *e-commerce*. Selain itu, teknologi ini juga memungkinkan seorang personal dalam industri *fashion* dengan menganalisis pola pakaian yang sering dikenakan pengguna, sehingga sistem dapat memberikan rekomendasi pakaian atau aksesoris yang sesuai dengan gaya dan preferensi pelanggan.

Lebih lanjut, sistem pengenalan atribut pakaian juga dapat diterapkan dalam manajemen inventaris dan pemasaran di industri *fashion*. *Retailer* dapat menggunakan teknologi ini untuk mengelola stok secara lebih efisien dengan menganalisis pola permintaan produk dari citra pelanggan. Dalam pemasaran, sistem ini dapat secara otomatis mengidentifikasi tren mode berdasarkan gambar yang diunggah di media sosial atau platform digital, memungkinkan *brand* untuk memahami perubahan selera pasar secara lebih cepat dan akurat. Dengan demikian, deteksi tren *fashion* secara *real-time* dapat membantu perusahaan *fashion* dalam merancang koleksi baru yang lebih sesuai dengan preferensi konsumen terkini.

Penelitian ini memiliki fokus pada pengembangan sistem yang mampu mengenali atribut-atribut yang dikenakan oleh manusia secara langsung. Selain itu sistem ini memiliki batasan mengenali beberapa atribut, di antaranya *upperwear*, *bottomwear*, *headwear*, *eyewear*, *footwear* atau *bag*.

Selain itu, penelitian ini dilaksanakan dengan pendekatan multi tahap (*multi-stage approach*), mengombinasikan beberapa teknologi, seperti arsitektur *Convolutional Neural Network* (CNN), *You Only Look Once* (YOLO), dan *Multi Layer perceptron*. Penggunaan gabungan teknologi ini bertujuan untuk mencapai tujuan penelitian, YOLO diterapkan untuk mendeteksi objek secara *real-time* yang di dalamnya terdapat arsitektur CNN untuk melakukan klasifikasi terhadap objek, dan arsitektur *deep learning Multi Layer Perceptron* digunakan untuk mengklasifikasi warna pakaian. Proses klasifikasi warna dilakukan dengan melakukan ekstraksi parameter



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Red Greenn Blue (RGB) pada objek yang telah dikenali, kemudian melakukan klasifikasi warna berdasarkan ketiga parameter tersebut.

Penelitian pengenalan suatu objek secara *real-time* yang mengombinasikan deteksi sebuah objek visual beserta warnanya sebelumnya sudah pernah dilakukan dalam penelitian “*Color-Driven Object Recognition: A Novel Approach Combining Color Detection and Machine Learning Techniques*” (Nayyer et al., 2024) tetapi terdapat perbedaan antara penelitian penulis dan penelitian yang dilakukan (Nayyer et al.,) penelitian penulis memiliki fokus melakukan klasifikasi lebih dari satu objek sedangkan pada penelitian sebelumnya memiliki fokus hanya pada satu objek yakni kendaraan. Selain pada objek terdapat perbedaan juga pada proses klasifikasi warna yang dilakukan penelitian tersebut, pada penelitian ini penulis melakukan ekstraksi warna dari pixel *bounding box* sebuah objek. Dengan demikian, penelitian ini bertujuan untuk mengembangkan sistem yang dapat mengklasifikasi objek, mengekstraksi atributnya, dan melakukan klasifikasi warna secara otomatis dan akurat.

1.2 Perumusan Masalah

Perkembangan teknologi *computer vision* dan *deep learning* memungkinkan sistem untuk mengenali dan mengklasifikasikan objek secara otomatis. Namun, dalam implementasinya, masih terdapat beberapa tantangan, seperti:

1. *Bagaimana membangun sistem yang dapat mengenali atribut pakaian yang dikenakan manusia secara langsung?*
2. *Bagaimana menerapkan algoritma *Convolutional Neural Network* (CNN) dan *You Only Look Once* (YOLO) untuk mendeteksi dan mengklasifikasikan atribut pakaian?*
3. *Bagaimana melakukan klasifikasi warna pakaian menggunakan algoritma MLP berdasarkan parameter *Red-Greenn-Blue* (RGB) secara akurat?*
4. *Bagaimana Hasil yang diperoleh dari implementasi pengenalan atribut manusia dengan pendekatan multi tahap (multi-stage approach)?*



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

1.3 Batasan Masalah

Untuk menjaga fokus penelitian, terdapat beberapa batasan yang ditetapkan:

1. Atribut yang akan dikenali oleh sistem meliputi: *uppewear*, *bottomwear*, *headwear*, *eyewear*, *footwear* atau *bag*.
2. Kategori atribut yang diklasifikasi terdiri dari:
 - *Upperwear: T-shirts, Shirts, Sweater, Jackets, dan Dress.*
 - *Bottomwear: Pants, Shorts, dan Skirts.*
 - *Headwear: Cap, Hat.*
 - *Eyewear: Eyeglasses, Sunglasses*
 - *Bag: Handbag, Backpack, Clutch Bag*
 - *Footwear: Sandals, Shoes, Flip-flops.*
3. Deteksi dan klasifikasi objek dilakukan menggunakan *You Only Look Once* (YOLO) dan *Convolutional Neural Network* (CNN).
4. Klasifikasi warna pakaian dilakukan dengan mengekstraksi nilai RGB dari *bounding box* objek pakaian yang telah dikenali, dan cakupan klasifikasi hanya akan meliputi beberapa warna termasuk, merah, hijau, biru, coklat, merah muda, kuning, oranye, ungu, hitam, abu-abu, putih.
5. Data yang digunakan untuk pelatihan dan pengujian sistem berasal dari *dataset* yang telah tersedia dan data yang dikumpulkan sendiri.
6. Sistem tidak menangani identifikasi individu atau pengenalan wajah, hanya berfokus pada atribut pakaian.

1.4 Tujuan dan Manfaat

1.4.1 Tujuan

1. Mengembangkan sistem yang dapat mengenali atribut pakaian dan aksesoris manusia secara langsung menggunakan metode *computer vision*.
2. Mengimplementasikan YOLO dan CNN untuk deteksi objek secara *real-time* dan klasifikasi atribut yang dikenakan manusia.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

3. Mengembangkan metode klasifikasi warna pakaian dengan mengekstraksi nilai RGB dan melakukan klasifikasi menggunakan arsitektur deep learning *Multi Layer Perceptron* berdasarkan parameter tersebut.
4. Mengevaluasi kinerja sistem dalam mengenali atribut pakaian dan klasifikasi warnanya dengan mengukur tingkat akurasi.

1.4.2 Manfaat

1. Menghasilkan sistem yang dapat mengenali atribut pakaian secara otomatis, yang dapat diterapkan dalam bidang seperti *fashion analysis* atau *recommender system* berbasis kategori pada industri *fashion retail*.
2. Meningkatkan efisiensi dalam analisis visual objek manusia dibandingkan dengan metode manual.
3. Menambah wawasan dalam bidang computer vision, khususnya dalam deteksi objek dan klasifikasi atribut manusia.
4. Menjadi referensi bagi penelitian selanjutnya yang ingin mengembangkan sistem serupa dengan metode berbeda.

1.5 Sistematika Penulisan

Sistematika penulisan ini bertujuan untuk memudahkan penyusunan proposal skripsi agar tetap sesuai dengan *bagian-bagiannya*. Penulisan proposal ini dibagi ke dalam beberapa bab sebagai berikut:

BAB I PENDAHULUAN

Bab ini menjelaskan latar belakang masalah dari topik pengenalan atribut manusia beserta warna secara *real-time* dengan pendekatan *multi-stage approach* menggunakan arsitektur *You Only Look Once* dan *multi layer perceptron*.

Selain latar belakang pada bab 1 ini penulis menulis rumusan masalah dari topik tersebut, penulis juga menuliskan batasan masalah untuk membatasi hasil yang di dapatkan, penulis juga menuliskan tujuan yang ingin di dapatkan, dan manfaat yang diharapkan.



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

BAB II TINJAUAN PUSTAKA

Pada bab II penulis menguraikan teori-teori dasar dan teknologi yang digunakan dalam penelitian pengenalan atribut manusia beserta warna secara *real-time* dengan pendekatan *multi-stage approach* menggunakan arsitektur *You Only Look Once* dan *multi layer perceptron*.

BAB III METODE PENELITIAN

Pada bab III Penulis menguraikan metode yang digunakan termasuk rancangan penelitian, tahapan penelitian, dan objek penelitian.

BAB IV PEMBAHASAN

Pada bab IV penulis memaparkan hasil yang diperoleh dari penelitian pengenalan atribut manusia beserta warna secara *real-time* dengan pendekatan *multi-stage approach* menggunakan arsitektur *You Only Look Once* dan *multi layer perceptron*.

BAB V PENUTUP

Pada bab V penulis memberikan kesimpulan dari penelitian “pengenalan atribut manusia beserta warna secara *real-time* dengan pendekatan *multi-stage approach* menggunakan arsitektur *You Only Look Once* dan *multi layer perceptron*” beserta saran yang dapat membantu penelitian selanjutnya.

DAFTAR PUSTAKA

Bagian ini memuat referensi atau sumber-sumber yang digunakan dalam penelitian “pengenalan atribut manusia beserta warna secara *real-time* dengan pendekatan *multi-stage approach* menggunakan arsitektur *You Only Look Once* dan *multi layer perceptron*”.

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Penelitian mengenai pengenalan suatu objek bukanlah suatu hal yang baru dalam dunia sudah banyak implementasi yang dilakukan untuk memecahkan masalah atau meningkatkan efisiensi di berbagai sektor, pada tabel 2.1.1 penulis menjabarkan beberapa penelitian sejenis.

Tabel 2. 1 Penelitian Sejenis

Deskripsi	I	II	III
Judul	Deteksi Warna Manggis Menggunakan Pengolahan Citra dengan Python	Implementasi YOLOv5 Untuk Mengidentifikasi Kematangan Buah Tomat	<i>Multiple Colour Detection of RGB Images using Machine Learning Algorithm</i>
Penulis	Andrekhya, M. Zikri; Huda, Yasdinul	Rahman, Jalby	Awotunde, Joseph Bamidele; Misra, Sanjay; Obagwu, David; Florez, Hector
Metode	Penulis menggunakan warna HSV sebagai parameter kematangan buah manggis	Penulis menggunakan pengenalan objek sebagai penentu Kematangan buah tomat	Penulis menggunakan Algoritma <i>Machine Learning</i> K-NN sebagai untuk menentukan warna dari parameter RGB
Hasil	Penelitian ini berhasil membedakan tingkat kematangan buah manggis dengan	Penelitian ini berhasil membedakan tingkat kematangan buah tomat	Penelitian ini berhasil melakukan klasifikasi terhadap warna menggunakan algoritma <i>K-Nearest</i>



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

	memperhitungkan nilai dari HSV pada kulit buah manggis. (Andrekha & Huda, 2021)	menggunakan model YOLOv5. (Rahman, 2024)	<i>Neighbors</i> . (Awotunde et al., 2022)
--	---	--	--

Penelitian penulis memiliki perbedaan yang signifikan dibandingkan dengan ketiga penelitian terdahulu, meskipun tetap memiliki relevansi dengan beberapa aspek tertentu. Penelitian oleh Andrekha & Huda (2021) berfokus pada pembeda tingkat kematangan buah manggis berdasarkan analisis nilai HSV, sementara Rahman (2024) menggunakan model YOLOv5 untuk klasifikasi tingkat kematangan buah tomat, dan Awotunde et al. (2022) memanfaatkan algoritma *K-Nearest Neighbors* (KNN) untuk klasifikasi warna. Ketiga penelitian tersebut memiliki cakupan yang lebih sempit, baik dalam fokus objek maupun metode yang digunakan.

Relevansi dari penelitian terdahulu terhadap penelitian penulis terletak pada penggunaan atribut warna sebagai elemen penting (Andrekha & Huda, 2021), penerapan model deteksi objek berbasis deep learning untuk keperluan *real-time* (Rahman, 2024), dan dasar klasifikasi warna (Awotunde et al., 2022). Namun, rancangan penelitian penulis memberikan kontribusi yang lebih luas dengan menggabungkan pengenalan atribut dan klasifikasi warna dalam sistem yang komprehensif, sehingga menghasilkan solusi yang lebih kompleks dan aplikatif dibandingkan penelitian-penelitian sebelumnya.

2.2 Computer Vision

Computer vision adalah cabang dari kecerdasan buatan (*Artificial Intelligence*) yang memungkinkan komputer memahami data visual dari gambar atau video. Bidang ini berkembang dari pengolahan citra digital yang awalnya hanya berfokus pada manipulasi gambar, seperti peningkatan kualitas dan deteksi tepi, menjadi sistem yang lebih kompleks yang dapat mengenali pola, mendeteksi objek, dan menganalisis perilaku. Computer vision sering dikaitkan dengan teknik seperti *pattern recognition*, segmentasi gambar, serta integrasi dengan pembelajaran mesin untuk meningkatkan akurasi prediksi dan analisis objek. (Hussien et al., 2021)



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Dalam implementasinya, computer vision bergantung pada algoritma dan model berbasis data untuk mengekstrak informasi dari citra. Salah satu tantangan utama dalam bidang ini adalah akurasi dan efisiensi algoritma yang digunakan, karena sistem harus mampu mengenali objek dalam berbagai kondisi pencahayaan, sudut pandang, serta tingkat kompleksitas gambar yang tinggi. Selain itu, sensitivitas parameter dalam model computer vision juga menjadi faktor penting yang memengaruhi keakuratan deteksi dan klasifikasi objek. Oleh karena itu, penelitian dalam bidang ini terus berkembang untuk mengatasi keterbatasan sistem dan meningkatkan performa algoritma dalam memahami data visual.(Hussien et al., 2021)

2.3 Deep Learning

Deep learning adalah cabang dari pembelajaran mesin (*machine learning*) yang menggunakan jaringan saraf tiruan (*artificial neural networks*) dengan banyak lapisan untuk mengekstrak dan mempelajari pola dari data secara otomatis(Le et al., 2021). Berbeda dengan metode pembelajaran mesin konvensional yang memerlukan rekayasa fitur secara manual, deep learning memungkinkan sistem untuk belajar langsung dari data mentah, seperti *pixel* dalam gambar atau gelombang suara, dengan cara menyusun representasi hierarkis dari informasi tersebut.

Salah satu prinsip utama dalam deep learning adalah *representation learning*, yang memungkinkan mesin untuk membangun representasi internal dari data yang diberikan. Lapisan pertama dalam jaringan deep learning biasanya menangkap fitur dasar, seperti tepi atau pola tekstur dalam gambar. Lapisan berikutnya menyusun fitur-fitur ini menjadi pola yang lebih kompleks, seperti bentuk atau objek tertentu. Proses ini berlanjut hingga lapisan yang lebih tinggi mampu mengenali konsep yang lebih abstrak, seperti wajah manusia atau objek dalam lingkungan tertentu. Click or tap here to enter text.

2.4 Multi-Layer Perceptron (MLP)

Multi-Layer Perceptron (MLP) adalah jenis jaringan saraf tiruan yang terdiri dari tiga komponen utama: lapisan *input*, satu atau lebih lapisan tersembunyi, dan lapisan *output*. Setiap neuron dalam MLP menggunakan fungsi aktivasi non-linear,




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

seperti fungsi *sigmoid* atau *ReLU*, yang memungkinkan jaringan memodelkan hubungan yang kompleks dan menangani data yang tidak dapat dipisahkan secara linear (Lin et al., 2020).

Gambar 2.1 memperlihatkan contoh proses *Multi-Layer Perceptron*.



Gambar 2. 1 Contoh *Multi-Layer Perceptron* (Le et al., 2021)

Proses pembelajaran pada MLP dilakukan melalui algoritma *backpropagation*, yang menghitung gradien dari fungsi kesalahan untuk setiap bobot dalam jaringan. Dengan menggunakan metode optimasi seperti *gradient descent*, bobot-bobot ini diperbarui untuk meminimalkan kesalahan antara *output* yang dihasilkan dan target yang diharapkan. Proses ini diulang secara iteratif hingga jaringan mencapai tingkat akurasi yang diinginkan. (Lin et al., 2020)

2.5 You-Only-Look-Once (YOLO)

YOLO merupakan pendekatan baru dalam deteksi objek yang mengubah paradigma tradisional. Alih-alih menggunakan metode seperti *sliding window* atau region proposal seperti pada R-CNN dan Fast R-CNN, YOLO mendefinisikan deteksi objek sebagai masalah regresi yang memprediksi koordinat bounding box dan probabilitas kelas langsung dari gambar secara keseluruhan melalui satu evaluasi *Convolutional Neural Network* (CNN). Pendekatan ini memungkinkan optimalisasi *end-to-end* yang sederhana dan efisien. (Redmon et al., 2016)

Dalam arsitekturnya, YOLO membagi gambar *input* menjadi *grid* berukuran $S \times SS \times SS$. Setiap sel *grid* bertanggung jawab untuk memprediksi BBB bounding box, skor kepercayaan untuk tiap box, serta probabilitas dari CCC kelas. Hasil



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

prediksi ini direpresentasikan dalam *tensor* berukuran $S \times S \times (B \times 5 + C)S \times S \times (B \times 5 + C)$, di mana setiap bounding box memiliki lima atribut: koordinat pusat (x,y) , dimensi (w,h) , dan skor kepercayaan yang mencerminkan *Intersection over Union* (IoU) dengan *ground truth*. (Redmon et al., 2016) Karena YOLO menganalisis keseluruhan gambar sekaligus, pendekatan ini memungkinkan model memahami konteks global, sehingga mampu mengurangi *false positive* dari latar belakang dan meningkatkan generalisasi. Pada gambar 2.2 contoh hasil implementasi YOLO



Gambar 2. 2 Hasil Implementasi YOLO pada data lukisan dan data dari internet (Redmon et al., 2016).

2.6 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu arsitektur *deep learning* yang dirancang khusus untuk menangani data berbentuk gambar dan video. CNN bekerja dengan cara meniru cara kerja korteks visual manusia, yang mampu mengenali pola dan fitur dari gambar secara hierarkis. Algoritma ini menggunakan lapisan konvolusi untuk mengekstrak fitur dari gambar dengan menerapkan filter atau *kernel* yang bergerak melintasi gambar dan mendeteksi pola seperti tepi, tekstur, atau bentuk tertentu (Chauhan et al., 2018). Dalam penelitian deteksi penyakit pada daun padi, CNN digunakan sebagai metode klasifikasi dengan model arsitektur Inception V3. Model ini mengolah data citra daun padi yang telah mengalami *pre-processing*, seperti *resizing* ke ukuran 299x299 piksel dan augmentasi data citra. Hasil pelatihan menunjukkan bahwa metode CNN dengan Inception V3 mampu mencapai akurasi hingga 93,75%, menjadikannya model yang sangat efektif dalam mendeteksi penyakit tanaman padi (Sheila et al., n.d.)



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

CNN terdiri dari beberapa lapisan utama, yaitu lapisan konvolusi, lapisan aktivasi, lapisan *pooling*, dan lapisan *fully connected*. Lapisan konvolusi bertugas mengekstrak fitur dengan mengaplikasikan filter pada gambar *input*. Lapisan aktivasi, seperti ReLU (*Rectified Linear Unit*), membantu memperkenalkan non-linear ke dalam model, sehingga jaringan dapat menangkap hubungan kompleks dalam data. Lapisan *pooling*, seperti *max pooling*, bertanggung jawab untuk mengurangi dimensi fitur, meningkatkan efisiensi komputasi, serta mengurangi *overfitting*. Sementara itu, lapisan *fully connected* berfungsi sebagai pengklasifikasi yang menggabungkan semua fitur yang telah diekstrak dari gambar untuk menghasilkan prediksi akhir. (Chauhan et al., 2018)

2.7 Activation Function

Fungsi aktivasi adalah komponen fundamental dalam arsitektur jaringan saraf tiruan yang berfungsi untuk memperkenalkan non-linearitas ke dalam model. Tanpa fungsi aktivasi, sebuah jaringan saraf, tidak peduli seberapa dalam lapisannya, hanya akan mampu memodelkan transformasi linear, yang setara dengan model regresi linear tunggal. Dengan menerapkan fungsi non-linear, jaringan saraf mampu mempelajari pola dan hubungan yang jauh lebih kompleks dan rumit dari data, seperti fitur-fitur visual pada gambar (Nwankpa et al., 2018). Pemilihan fungsi aktivasi yang tepat pada lapisan tersembunyi (*hidden layer*) dan lapisan output (*output layer*) sangat krusial untuk memastikan proses pembelajaran yang efisien dan performa model yang optimal.

2.7.1 Rectified Linear Unit (ReLU)

Rectified Linear Unit (ReLU) adalah fungsi aktivasi yang paling umum digunakan pada lapisan tersembunyi (*hidden layers*) dalam model *deep learning* modern, termasuk pada arsitektur CNN seperti MobileNetV2. Keunggulan utama ReLU adalah kesederhanaan komputasinya yang membuatnya sangat efisien dan kemampuannya untuk mengatasi masalah gradien menghilang (*vanishing gradient*) yang sering terjadi pada fungsi aktivasi lain seperti Sigmoid atau Tanh (Nair & Hinton, 2010).

Fungsi ReLU didefinisikan secara matematis sebagai:

$$f(x) = \max(0, x)$$



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

2.7.2 Sigmoid Function (Logistic)

Fungsi Sigmoid, atau sering juga disebut fungsi logistik, adalah fungsi aktivasi yang menghasilkan output dalam rentang antara 0 dan 1. Fungsi ini memiliki kurva berbentuk "S" yang khas dan secara historis merupakan salah satu fungsi aktivasi yang paling populer.

Fungsi Sigmoid didefinisikan oleh rumus:

$$S(x) = \frac{1}{1 + e^{-x}}$$

2.7.3 Softmax Function

Berbeda dengan *Sigmoid* yang menangani probabilitas untuk setiap kelas secara independen, fungsi *Softmax* dirancang khusus untuk digunakan pada lapisan *output* dari sebuah model klasifikasi multi-kelas (*multi-class classification*) yang bersifat saling eksklusif (satu input hanya bisa menjadi satu kelas). Tujuannya adalah untuk mengubah vektor output dari lapisan sebelumnya (yang berisi nilai numerik mentah atau logits) menjadi sebuah distribusi probabilitas, di mana total dari semua probabilitas adalah 1 (Goodfellow et al., 2016).

Fungsi *Softmax* dihitung dengan rumus:

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \text{ untuk } i = 1, \dots, K$$

2.8 Matriks Evaluasi

Evaluasi model merupakan tahap krusial dalam penelitian berbasis *deep learning* untuk mengukur performa dan keandalan model yang telah dikembangkan secara kuantitatif. Tanpa evaluasi yang objektif, sulit untuk menentukan apakah sebuah model dapat digeneralisasi dengan baik pada data baru atau membandingkannya dengan metode lain. Dalam penelitian ini, digunakan dua set metrik evaluasi yang berbeda, disesuaikan dengan dua tugas utama: klasifikasi atribut/warna dan deteksi objek.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

2.8.1 Metrik Evaluasi untuk Model Klasifikasi

Untuk mengevaluasi kinerja model klasifikasi (seperti klasifikasi jenis pakaian, aksesoris, dan warna), digunakan metrik yang berasal dari *Confusion Matrix*. *Confusion Matrix* adalah sebuah tabel yang memvisualisasikan performa model dengan membandingkan kelas hasil prediksi dengan kelas aktual pada data uji. Matriks ini terdiri dari empat komponen utama: *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) (Hossin & Sulaiman, 2015).

Dari keempat komponen tersebut, beberapa metrik turunan digunakan untuk analisis yang lebih mendalam:

1. **Akurasi (Accuracy):** Metrik ini mengukur proporsi total prediksi yang benar (TP dan TN) dari keseluruhan data. Akurasi adalah metrik yang paling intuitif, namun bisa memberikan gambaran yang menyesatkan jika dataset tidak seimbang (*imbalanced*).

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN}$$

2. **Presisi (Precision):** Presisi mengukur tingkat ketepatan dari prediksi positif yang dibuat oleh model. Metrik ini menjawab pertanyaan: "Dari semua yang diprediksi sebagai kelas positif, berapa banyak yang benar-benar positif?". Presisi yang tinggi menunjukkan tingkat *false positive* yang rendah.

$$\text{Presisi} = \frac{TP}{TP + FP}$$

3. **Recall (Sensitivity):** Recall mengukur kemampuan model untuk menemukan semua sampel positif yang ada pada data. Metrik ini menjawab pertanyaan: "Dari semua kelas positif yang sebenarnya, berapa banyak yang berhasil dideteksi oleh model?". Recall yang tinggi menunjukkan tingkat *false negative* yang rendah (Grandini et al., 2020).

$$\text{Recall} = \frac{TP}{TP + FN}$$

4. **F1-Score:** Metrik ini adalah rata-rata harmonik dari Presisi dan Recall. F1-Score memberikan skor tunggal yang menyeimbangkan kedua metrik



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

tersebut, sehingga sangat berguna ketika terdapat trade-off antara Presisi dan Recall, atau ketika distribusi kelas tidak seimbang (Hossin & Sulaiman, 2015).

$$F1\text{-Score} = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}}$$

2.8.2 Metrik Evaluasi untuk Model Deteksi Objek

Tugas deteksi objek, seperti yang dilakukan oleh YOLO, memerlukan evaluasi yang lebih kompleks karena tidak hanya mengukur kebenaran klasifikasi, tetapi juga akurasi lokalisasi objek. Metrik utama yang digunakan adalah *mean Average Precision* (mAP).

1. **Intersection over Union (IoU):** IoU adalah metrik fundamental yang mengukur tingkat tumpang tindih antara *bounding box* hasil prediksi (B_p) dan *bounding box* ground truth (B_{gt}). Nilai IoU berkisar dari 0 hingga 1, di mana 1 berarti tumpang tindih sempurna. Sebuah prediksi dianggap sebagai *True Positive* (TP) jika nilai IoU-nya melebihi ambang batas tertentu (umumnya 0.5) dan kelasnya benar (Zou et al., 2023).

$$IoU = \frac{\text{Area}(B_p \cap B_{gt})}{\text{Area}(B_p \cup B_{gt})}$$

2. **mean Average Precision (mAP):** mAP adalah metrik standar emas untuk mengevaluasi performa model deteksi objek. Perhitungannya didasarkan pada kurva Presisi-Recall. *Average Precision* (AP) dihitung untuk setiap kelas sebagai area di bawah kurva Presisi-Recall. Kurva ini menggambarkan bagaimana presisi berubah seiring dengan perubahan recall pada berbagai tingkat kepercayaan (*confidence score*). Selanjutnya, mAP dihitung dengan merata-ratakan nilai AP dari seluruh kelas objek (Padilla et al., 2020).

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$

di mana N adalah jumlah total kelas. Terdapat beberapa varian mAP, seperti mAP@0.5 (mAP yang dihitung dengan ambang batas IoU tunggal 0.5) dan



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

mAP@0.5:0.95 (mAP yang dirata-ratakan pada berbagai ambang batas IoU dari 0.5 hingga 0.95 dengan interval 0.05), yang memberikan evaluasi yang lebih ketat dan komprehensif terhadap kemampuan lokalisasi model.

2.9 Python

Python adalah sebuah bahasa pemrograman tingkat tinggi yang bekerja secara interpretatif di mana kode di eksekusi secara langsung baris per baris tanpa harus dikompilasi terlebih dahulu.(Yamaganti & Siva, 2019) Bahasa pemrograman Python memiliki area implementasi yang luas di antaranya Python dapat melakukan pengembangan perangkat lunak, pengembangan model *machine learning* dan *deep learning*, analisis data, dan masih banyak lagi. Keunggulan utama bahasa pemrograman Python adalah dukungannya terhadap berbagai paradigma pemrograman, dan Python juga menyediakan fitur pustaka atau *library* yang dapat di kembangkan secara *open source*(Yamaganti & Siva, 2019). Fitur *library* atau pustaka memungkinkan berbagai operasi secara efisien, seperti manipulasi data (pandas, NumPy), pengolahan citra (OpenCV, PIL), pengembangan web (Django, Flask), komputasi ilmiah (SciPy), serta implementasi model *machine learning* dan *deep learning* (scikit-learn, TensorFlow, PyTorch).

2.10 OpenCV

OpenCV (*Open Source Computer Vision Library*) adalah pustaka perangkat lunak *open-source* yang digunakan untuk pemrosesan gambar dan video. Pustaka ini memungkinkan pengguna untuk mengekstraksi informasi dari citra atau video dengan cara yang efisien dan praktis. OpenCV pertama kali dikembangkan oleh Intel untuk mempermudah pemrograman yang berhubungan dengan citra, dan kini mendukung berbagai bahasa pemrograman seperti C, C++, Java, dan Python. OpenCV juga kompatibel dengan berbagai platform seperti Windows, Linux, Mac OS, iOS, dan Android(Andrekhya & Huda, 2021).

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

BAB III

PERENCANAAN DAN REALISASI

3.1 Rancangan Penelitian

Penelitian ini berfokus pada pengembangan sistem yang mampu mengenali atribut manusia beserta warnanya menggunakan pendekatan multi-tahap. Pendekatan ini terdiri dari tiga proses utama, pertama deteksi kategori objek seperti *upperwear*, *bottomwear*, *headwear*, *eyewear*, *footwear* atau *bag* menggunakan arsitektur YOLOv8, kedua klasifikasi atribut spesifik untuk setiap kategori yang terdeteksi menggunakan arsitektur CNN yang dikombinasikan menggunakan *pre-trained model* MobileNetV2, dan terakhir klasifikasi warna khusus untuk atribut pakaian menggunakan arsitektur MLP berdasarkan tiga parameter *Red*, *Green*, *Blue* (RGB) yang diekstraksi dari bounding box hasil deteksi atribut.

Pendekatan penelitian ini bersifat kuantitatif dan tergolong sebagai riset eksperimental. Kinerja model dievaluasi secara komprehensif: matriks evaluasi *mean Average Precision* (mAP) digunakan secara spesifik untuk menilai performa model deteksi objek (YOLOv8). Sementara itu, matriks akurasi, *presisi*, *recall*, dan F1-score digunakan untuk mengevaluasi semua model klasifikasi, baik untuk atribut spesifik maupun warna. Selain evaluasi performa model, penelitian ini juga mencakup evaluasi sistem secara holistik melalui pengujian Black Box untuk fungsionalitas dan *User Acceptance Test* (UAT) untuk validasi penerimaan pengguna.

Tujuan utama penelitian ini adalah mengembangkan sistem yang terintegrasi dan andal, yang mampu mengenali atribut manusia beserta warnanya secara real-time dengan pendekatan multi-tahap yang telah divalidasi secara kuantitatif dan fungsional.

3.2 Tahapan Penelitian

Tahapan penelitian untuk membangun sistem pengenalan atribut manusia ini dilakukan melalui serangkaian langkah yang sistematis dan berurutan, sebuah pendekatan yang krusial untuk mengelola kompleksitas dalam pengembangan sistem berbasis deep learning. Proses metodologis ini dirancang secara cermat



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

untuk memastikan seluruh pengembangan berjalan secara terstruktur, logis, dan dapat dilacak, sehingga hasil akhir yang diperoleh dapat dipertanggungjawabkan secara ilmiah. Keseluruhan alur kerja yang menggambarkan hubungan antar tahapan ini secara garis besar disajikan dalam diagram pada Gambar 3.1.



Gambar 3.1 Flow Tahapan Penelitian

3.2.1 Identifikasi Kebutuhan

Pada tahap awal penelitian, dilakukan perumusan kebutuhan sistem secara rinci untuk mendukung pendekatan *multi-stage* yang diusulkan. Proses ini mencakup penentuan atribut utama yang akan dikenali, yaitu *headwear*, *eyewear*, *upperwear*, *bottomwear*, *footwear*, dan *bag*, beserta sub-kategorinya. Selain itu, kebutuhan teknis untuk setiap tahapan juga ditetapkan, di mana arsitektur YOLOv8 akan digunakan untuk tahap deteksi objek. Untuk klasifikasi atribut yang lebih spesifik



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

digunakan arsitektur CNN yang dikombinasikan dengan *pre-trained* model MobileNetV2. Sementara itu, arsitektur *Multi-Layer Perceptron* (MLP) akan dimanfaatkan untuk klasifikasi warna berdasarkan ekstraksi nilai RGB. Di samping itu, metode evaluasi kinerja untuk setiap model juga ditentukan pada tahap ini: *mean Average Precision* (mAP) untuk mengukur performa model deteksi, serta metrik *precision*, *recall*, *F1-score*, dan akurasi untuk mengevaluasi semua model klasifikasi.

3.2.2 Pengumpulan Data

Tahap kedua berfokus pada pengumpulan dataset yang relevan dan beragam untuk melatih ketiga jenis model yang berbeda. Dataset untuk tugas deteksi objek dikumpulkan dari berbagai sumber publik, termasuk DeepFashion dan InFashAI, yang kemudian dianotasi secara manual dengan *bounding box* untuk menandai lokasi setiap atribut. Untuk kebutuhan klasifikasi atribut yang lebih spesifik, digunakan dataset publik seperti *Fashion Product Images Dataset* yang kemudian diperkaya dengan data tambahan yang diperoleh melalui teknik *web scraping*. Sementara itu, untuk melatih model klasifikasi warna, dikumpulkan dataset berbentuk tabular yang berisi data parameter Red, Green, dan Blue (RGB) beserta label warnanya dari berbagai platform data publik.

3.2.3 Pemrosesan Data

Setelah semua data mentah terkumpul, tahap selanjutnya adalah pemrosesan data untuk memastikan kualitas dan kesiapannya sebelum digunakan untuk pelatihan model. Pada tahap ini, data dibersihkan dari gambar-gambar yang tidak relevan atau berkualitas rendah. Selanjutnya, diterapkan teknik augmentasi data seperti rotasi, flipping, dan perubahan pencahayaan secara khusus pada data latih untuk meningkatkan variasi dan kemampuan generalisasi model terhadap kondisi dunia nyata. Terakhir, dataset dipersiapkan dalam format yang sesuai untuk setiap arsitektur: data dengan anotasi bounding box untuk input model YOLOv8, gambar yang ukurannya telah disesuaikan dan diberi padding untuk input arsitektur CNN yang dikombinasikan dengan *pre-trained* model MobileNetV2, serta data tabular RGB yang telah dinormalisasi untuk model MLP.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

3.2.4 Pengembangan Model

Pada tahap ini, pengembangan model dilakukan secara terpisah untuk setiap komponen dalam sistem *multi-stage*, sesuai dengan fungsi dan arsitektur yang telah ditentukan. Pertama, model deteksi objek YOLOv8 dilatih menggunakan dataset yang telah dianotasi, dan augmentasi untuk mampu mengenali kategori umum atribut manusia secara akurat. Kedua, model-model klasifikasi atribut menggunakan arsitektur CNN yang dikombinasikan dengan *pre-trained model* MobileNetV2 dilatih pada dataset-nya masing-masing untuk dapat mengenali sub-kategori spesifik dari setiap atribut yang berhasil dideteksi. Terakhir, model *Multi-Layer Perceptron* (MLP) dilatih menggunakan dataset tabular warna untuk melakukan klasifikasi yang presisi berdasarkan input nilai RGB.

3.2.5 Pengujian Model

Sebelum diintegrasikan ke dalam sistem utama, setiap model yang telah selesai dikembangkan harus melalui tahap pengujian kinerja secara individual. Pengujian ini dilakukan dengan menggunakan dataset test yang belum pernah dilihat oleh model selama proses pelatihan. Model deteksi YOLOv8 dievaluasi performanya menggunakan metrik *mean Average Precision* (mAP) untuk menilai keakuratan deteksi dan lokalisasi objek. Sementara itu, kinerja dari model-model klasifikasi, baik yang menggunakan arsitektur CNN yang dikombinasikan dengan *pre-trained model* MobileNetV2 maupun *model* MLP, diukur menggunakan metrik standar seperti akurasi, precision, recall, dan F1-score untuk memastikan keandalannya dalam melakukan klasifikasi sebelum digabungkan ke dalam sistem.

3.2.6 Implementasi sistem

Setelah semua komponen model lulus tahap pengujian individual, tahap selanjutnya adalah implementasi sistem, di mana semua model tersebut digabungkan menjadi satu alur kerja yang terintegrasi dan fungsional. Proses dalam sistem ini dimulai saat model YOLOv8 mendeteksi sebuah objek dan menghasilkan informasi bounding box. Hasil bounding box tersebut kemudian diteruskan ke *model* dengan arsitektur CNN yang dikombinasikan dengan *pre-trained model* MobileNetV2 yang sesuai untuk dilakukan klasifikasi atribut yang lebih spesifik. Setelah itu, parameter warna *Red*, *Green*, *Blue* (RGB) diekstraksi dari bounding box yang sama untuk kemudian diidentifikasi oleh model klasifikasi warna MLP. Tahapan ini



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

bertujuan untuk menyatukan semua komponen model menjadi satu sistem utuh yang dapat bekerja secara berurutan dan otomatis.

3.2.7 Evaluasi Kinerja Sistem

Pada tahap terakhir, sistem yang telah terintegrasi secara penuh dievaluasi secara menyeluruh untuk mengukur performa dan keandalannya. Sistem diuji dalam berbagai skenario *real-time* untuk menilai kinerjanya terhadap kondisi dunia nyata, seperti variasi pencahayaan, sudut pandang, dan keragaman objek. Pengujian ini bertujuan untuk mengidentifikasi potensi kekurangan atau area yang memerlukan perbaikan di masa mendatang. Selain pengujian performa, evaluasi juga mencakup pengujian fungsionalitas sistem melalui metode *Black Box Testing* serta validasi penerimaan dan kemudahan penggunaan dari sisi pengguna akhir melalui *User Acceptance Test* (UAT).

3.3 Objek Penelitian

Objek penelitian ini merupakan sebuah sistem pengenalan atribut manusia beserta warna yang dikembangkan menggunakan pendekatan multi-tahap (*multi-stage approach*). Atribut manusia yang menjadi fokus dalam penelitian ini meliputi *headwear*, *eyewear*, *upperwear*, *bottomwear*, *footwear*, dan *bag* beserta warna. Sistem ini dirancang untuk berfungsi secara *real-time* dengan mengintegrasikan beberapa arsitektur *deep learning* dalam tiga tahap utama. Pada tahap pertama, arsitektur YOLOv8 digunakan untuk mendeteksi kategori umum atribut manusia. Selanjutnya, pada tahap kedua, hasil deteksi tersebut diproses oleh serangkaian arsitektur CNN yang dipadukan dengan *pre-trained model* MobileNetV2 untuk melakukan klasifikasi atribut yang lebih spesifik, seperti membedakan antara kemeja, jaket, dan kaos. Pada tahap ketiga, sistem mengidentifikasi warna dengan mengekstraksi nilai *Red*, *Green*, *Blue* (RGB) dari *bounding box* yang telah dikenali dan menggunakan arsitektur *Multi-Layer Perceptron* (MLP) untuk menentukan warna dominan dari atribut tersebut. Dengan demikian, objek penelitian ini adalah sebuah sistem terpadu yang tidak hanya mendeteksi, tetapi juga mengklasifikasikan atribut dan warna secara berurutan dan otomatis.

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

BAB IV


HASIL DAN PEMBAHASAN

4.1 Identifikasi Kebutuhan

Berdasarkan hasil studi literatur, berdiskusi dengan dosen pembimbing, dan memosisikan diri sebagai salah satu target pengguna, penulis telah berhasil mengidentifikasi beberapa kebutuhan untuk melaksanakan penelitian ini. Kebutuhan tersebut termasuk kebutuhan perangkat keras, kebutuhan perangkat lunak, kebutuhan pengembangan model, kebutuhan menjalankan model. Semua kebutuhan yang telah disebutkan dibutuhkan untuk kelancaran penelitian ini.

4.1.1 Identifikasi Kebutuhan Pengembangan model

Dalam Proses pengembangan model *Artificial Intelligence* (AI), *Machine Learning* (ML), dan *Deep Learning* (DL) terdapat tahapan-tahapan demi mendapatkan hasil maksimal dalam pengembangan model. Tahapan ini adalah *Machine Learning development life-cycle*. *Machine Learning development life-cycle* adalah proses lengkap perancangan, pengembangan, penerapan, pemantauan, serta pemeliharaan model (Zeydan et al., 2024). Untuk proses lebih jelasnya dapat dilihat pada Gambar 4. 1.



Gambar 4. 1. *Machine learning development life-cycle*



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Secara umum, tahapan pengembangan model meliputi pemahaman masalah, pengumpulan dan pemrosesan data, pemilihan serta pengembangan model, evaluasi model, *deployment*, serta pemantauan performa model. Tahapan ini bersifat siklis, di mana proses pengembangan dapat dilakukan secara berulang untuk meningkatkan kualitas model (Gama et al., 2014).

Pada penelitian ini, pengembangan model dilakukan dengan mengikuti tahapan-tahapan tersebut secara adaptif, sesuai dengan karakteristik permasalahan dan data yang digunakan. Penelitian ini berfokus pada pengenalan atribut manusia beserta warna secara *real-time* dengan pendekatan multi-stage, yang menggabungkan arsitektur *You Only Look Once* (YOLO) untuk deteksi objek, *Convolutional Neural Network* (CNN) untuk klasifikasi atribut lebih mendalam, dan *Multi Layer Perceptron* (MLP) untuk klasifikasi warna pakaian. Penjelasan lebih rinci mengenai kebutuhan pengembangan model, mulai dari dataset, pemilihan *pre-trained* model, hingga pemilihan model dan evaluasi performa.

4.1.1.1 Kebutuhan Dataset

Setelah melakukan tahapan pemahaman masalah, proses dilanjutkan dengan pengumpulan data (*collecting data*). Pada tahap ini, dilakukan proses pengumpulan data yang relevan dan berkualitas tinggi, baik dari sumber internal maupun eksternal, yang akan digunakan sebagai bahan utama dalam proses pelatihan model (Kelleher et al., 2015). Pada penelitian ini kebutuhan dataset untuk membuat model yang dapat dikembangkan untuk sistem multi-stage yang dapat melakukan pengenalan atribut manusia mulai dari mendasar melalui deteksi objek, selanjutnya dilakukan klasifikasi dari hasil deteksi objek, dan melakukan klasifikasi warna, telah dirangkum dan dapat dilihat pada tabel 4.1.

Tabel 4. 1 Kebutuhan Dataset

Kode	Nama	Deskripsi
KD-1	Dataset Atribut Manusia	data manusia yang memuat berbagai atribut di dalamnya, termasuk <i>headwear</i> , <i>eyewear</i> , <i>upperwear</i> , <i>bottomwear</i> , <i>footwear</i> , dan <i>bag</i> .



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

KD-2	Dataset <i>Sub-class Headwear</i>	data <i>sub-class headwear</i> , yaitu <i>cap</i> dan <i>hat</i> . Setiap kelas harus memiliki jumlah sampel yang seimbang, dengan ukuran gambar 128 x 128 piksel.
KD-3	Dataset <i>Sub-class Eyewear</i>	data <i>sub-class eyewear</i> , yaitu <i>eyeglasses</i> dan <i>sunglasses</i> . Setiap kelas harus memiliki jumlah sampel yang seimbang, dengan ukuran gambar 128 x 128 piksel.
KD-4	Dataset <i>Sub-class Upperwear</i>	data <i>sub-class upperwear</i> , yaitu <i>t-shirt</i> , <i>shirt</i> , <i>sweater</i> , <i>jacket</i> , dan <i>dress</i> . Setiap kelas harus memiliki jumlah sampel yang seimbang, dengan ukuran gambar 224 x 224 piksel.
KD-5	Dataset <i>Sub-class Bottomwear</i>	data <i>sub-class bottomwear</i> , yaitu <i>pants</i> , <i>shorts</i> , dan <i>skirts</i> . Setiap kelas harus memiliki jumlah sampel yang seimbang, dengan ukuran gambar 224 x 224 piksel.
KD-6	Dataset <i>Sub-class Bag</i>	data <i>sub-class bag</i> , yaitu <i>handbag</i> , <i>backpack</i> , dan <i>clutch bag</i> . Setiap kelas harus memiliki jumlah sampel yang seimbang, dengan ukuran gambar 224 x 224 piksel.
KD-7	Dataset <i>Sub-class Footwear</i>	data <i>sub-class footwear</i> , yaitu <i>sandals</i> , <i>shoes</i> , dan <i>flip-flops</i> . Setiap kelas harus memiliki jumlah sampel yang seimbang, dengan ukuran gambar 128 x 128 piksel.
KD-8	Dataset Warna	dataset warna yang terdiri dari parameter <i>Red</i> , <i>Green</i> , dan <i>Blue</i> (RGB), serta label warna. Karena distribusi kombinasi RGB tidak selalu seimbang, maka kemungkinan besar akan ada <i>oversampling</i> dan <i>undersampling</i> pada dataset ini.

Dengan memenuhi kebutuhan dataset sesuai kriteria yang telah ditetapkan, diharapkan model yang dikembangkan dapat belajar secara optimal dan menghasilkan performa yang baik dalam proses pengenalan atribut manusia beserta warna secara *real-time*.

4.1.1.2 Kebutuhan *pre-trained* model

Penggunaan *pre-trained* model telah menjadi pendekatan yang umum dalam pengembangan sistem berbasis deep learning, khususnya pada tugas-tugas yang memerlukan efisiensi pelatihan dan performa yang tinggi. Model *pre-trained* memungkinkan pemanfaatan bobot dan representasi fitur yang telah dipelajari dari dataset berskala besar, sehingga dapat mempercepat proses pengembangan dan



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

meningkatkan kemampuan generalisasi model (Pan & Yang, 2010). Selain itu, pendekatan ini juga membantu mengurangi kebutuhan akan data pelatihan dalam domain target, yang sering kali terbatas dalam jumlah maupun keberagamannya (Zhuang et al., 2021).

Penggunaan *pre-trained* model merupakan strategi penting yang diterapkan dalam penelitian ini untuk mempercepat proses pengembangan model serta meningkatkan performa deteksi dan klasifikasi. Dengan memanfaatkan model *pre-trained*, proses pelatihan dapat dilakukan secara lebih efisien karena model telah mempelajari representasi fitur umum dari dataset berskala besar sebelumnya.

Kebutuhan *pre-trained model* sudah dirangkum dan dapat dilihat pada Tabel 4.2.

Tabel 4. 2 Kebutuhan *pre-trained* Model

Kode	Komponen Model	<i>Pre-trained</i> Model	Dataset <i>Pre-trained</i>	Tujuan Penggunaan
KPM-1	Deteksi Objek	YOLOv8l	COCO	Mendeteksi objek manusia dan atribut pada gambar secara <i>real-time</i> .
KPM-2	Klasifikasi Atribut Lebih Mendalam	MobileNetV2	ImageNet	Mengekstraksi dan mengklasifikasikan atribut manusia secara mendalam (<i>headwear, eyewear, upperwear, bottomwear, footwear, bag</i>).

Tabel 4.2 merangkum kebutuhan *pre-trained* model yang digunakan dalam penelitian ini. Pemilihan arsitektur model dilakukan secara cermat dengan mempertimbangkan karakteristik masing-masing tahapan dalam proses pengenalan atribut manusia beserta warna secara *real-time*.

Penggunaan YOLOv8l sebagai *pre-trained* model deteksi objek memungkinkan sistem untuk mendeteksi objek manusia dan berbagai atribut secara akurat dan cepat, sesuai dengan kebutuhan proses deteksi *real-time*.

Selanjutnya, MobileNetV2 digunakan untuk klasifikasi atribut manusia secara lebih mendalam. Model ini berperan dalam mengekstraksi dan mengklasifikasikan



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

atribut yang meliputi *headwear*, *eyewear*, *upperwear*, *bottomwear*, *footwear*, dan *bag*. Keunggulan arsitektur MobileNetV2 terletak pada kemampuannya menghasilkan representasi fitur yang efisien dengan beban komputasi yang rendah, sehingga sangat sesuai untuk sistem yang memerlukan kinerja *real-time*.

Dengan konfigurasi *pre-trained* model seperti yang disajikan pada Tabel 4.2, sistem diharapkan mampu memenuhi kebutuhan performa deteksi dan klasifikasi secara *real-time* serta menjaga akurasi yang tinggi dalam berbagai kondisi gambar.

4.1.1.3 Kebutuhan Model

Pengembangan model dalam penelitian ini disesuaikan dengan kebutuhan spesifik dari proses pengenalan atribut manusia beserta warna secara *real-time*. Model yang dibangun dirancang untuk mampu memproses data citra yang telah diklasifikasikan ke dalam berbagai atribut dan sub-kelas, sebagaimana dirumuskan dalam kebutuhan dataset KD-1 hingga KD-8.

Secara keseluruhan, arsitektur model dibangun dalam pendekatan multi-stage, yang terdiri atas:

3. Tahap deteksi atribut menggunakan arsitektur YOLO dan *pre-trained* model YOLOv8l untuk mendeteksi manusia dan atribut pada gambar secara *real-time*.
4. Tahap Klasifikasi Atribut Lebih Mendalam menggunakan arsitektur CNN dan *pre-trained* model MobileNetV2 untuk mengklasifikasikan sub-kelas atribut, yaitu *headwear*, *eyewear*, *upperwear*, *bottomwear*, *footwear*, dan *bag*, sesuai dengan kebutuhan KD-2 hingga KD-7.
5. Tahap Klasifikasi Warna Atribut menggunakan arsitektur *Multi Layer Perceptron* (MLP) untuk mengklasifikasikan warna atribut berdasarkan parameter RGB, sesuai dengan kebutuhan KD-8.

Kebutuhan model sudah dirangkum dan dapat dilihat pada Tabel 4.3.

Tabel 4. 3 Kebutuhan model dan *pre-trained* model

Kode	Komponen Model	Arsitektur dan <i>Pre-trained</i> Model	<i>Input</i> Dataset	Tujuan Penggunaan
------	----------------	---	----------------------	-------------------



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

KM-1	Deteksi Objek	YOLO - YOLOv8l	KD-1	Mendeteksi manusia dan atribut pada gambar secara <i>real-time</i> .
KM-2	Klasifikasi Atribut <i>Headwear</i>	CNN MobileNetV2	KD-2	Mendeteksi dan mengklasifikasikan sub-kelas <i>headwear (cap, hat)</i> .
KM-3	Klasifikasi Atribut <i>Eyewear</i>	CNN MobileNetV2	KD-3	Mendeteksi dan mengklasifikasikan sub-kelas <i>eyewear (eyeglasses, sunglasses)</i> .
KM-4	Klasifikasi Atribut <i>Upperwear</i>	CNN MobileNetV2	KD-4	Mendeteksi dan mengklasifikasikan sub-kelas <i>upperwear (t-shirt, shirt, sweater, jacket, dress)</i> .
KM-5	Klasifikasi Atribut <i>Bottomwear</i>	CNN MobileNetV2	KD-5	Mendeteksi dan mengklasifikasikan sub-kelas <i>bottomwear (pants, shorts, skirts)</i> .
KM-6	Klasifikasi Atribut <i>Bag</i>	CNN MobileNetV2	KD-6	Mendeteksi dan mengklasifikasikan sub-kelas <i>bag (handbag, backpack, clutch bag)</i> .
KM-7	Klasifikasi Atribut <i>Footwear</i>	CNN MobileNetV2	KD-7	Mendeteksi dan mengklasifikasikan sub-kelas <i>footwear (sandals, shoes, flip flops)</i> .
KM-8	Klasifikasi Warna Atribut	<i>Multi Layer Perceptron (MLP)</i>	KD-8	Mendeteksi dan mengklasifikasikan warna atribut berdasarkan parameter RGB.

Dengan kebutuhan model yang dirancang berdasarkan kebutuhan dataset KD-1 hingga KD-8, sistem diharapkan mampu melakukan proses pengenalan atribut manusia beserta warna secara *real-time* dengan akurasi dan efisiensi yang optimal.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

4.1.2 Identifikasi Kebutuhan Perangkat Keras

Dalam proses pengembangan model, diperlukan perangkat keras yang memadai untuk mendukung proses pelatihan dan pengujian. Pada penelitian ini, perangkat keras yang digunakan dibagi menjadi dua kategori, yaitu perangkat keras untuk pengembangan model deteksi objek, dan perangkat keras untuk pengembangan model klasifikasi atribut mendalam serta klasifikasi warna.

Perbedaan kebutuhan perangkat keras disebabkan oleh perbedaan tingkat kompleksitas proses pelatihan, pelatihan model deteksi objek memerlukan spesifikasi yang lebih tinggi dibandingkan model klasifikasi.

Kebutuhan perangkat keras untuk pelatihan model deteksi objek dirangkum pada Tabel 4.4.

Tabel 4. 4 Kebutuhan Perangkat Keras Deteksi Objek

Kode	Hardware	Spesifikasi
KPKOD-1	CPU	memiliki minimum 8 <i>core</i>
KPKOD-2	RAM	memiliki minimum 32GB
KPKOD-3	GPU	dapat menjalankan NVIDIA <i>cuda</i> dengan minimal VRAM 24GB

Pemilihan perangkat keras pada tabel 4.4 mulai dari CPU dengan minimum 8 *core* dilakukan untuk memastikan performa yang optimal dalam menjalankan Jupyter Notebook serta proses komputasi umum.

Pemilihan RAM dengan kapasitas minimum 32 GB bertujuan untuk mencegah terjadinya *Out-of-Memory Error* selama proses pelatihan model, serta memberikan fleksibilitas dalam penggunaan parameter *batch size* yang lebih besar.

Pemilihan GPU dengan kemampuan menjalankan NVIDIA CUDA dan VRAM minimum 24 GB dilakukan untuk mendukung proses pelatihan model *Deep Learning* secara efisien. Kapasitas VRAM yang besar juga membantu mengurangi



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

risiko *Out-of-Memory Error* saat melatih model deteksi objek dengan dataset berukuran besar.

Dengan spesifikasi perangkat keras yang telah dirangkum dalam Tabel 4.4, diharapkan proses pelatihan model deteksi objek dapat berjalan dengan lancar dan tanpa hambatan.

Kebutuhan perangkat keras untuk pelatihan model klasifikasi atribut mendalam, klasifikasi warna, serta sistem/aplikasi *interface* dirangkum pada Tabel 4.5.

Tabel 4. 5 Kebutuhan Perangkat Keras Klasifikasi

Kode	Hardware	Spesifikasi
KPKK-1	CPU	memiliki minimum 8 <i>core</i>
KPKK-2	RAM	memiliki minimum 16GB
KPKK-3	GPU	dapat menjalankan NVIDIA <i>cuda</i> dengan minimal VRAM 6GB

Pemilihan perangkat pada tabel 4.5, mulai dari CPU dengan minimum 8 *core* dilakukan untuk memastikan performa yang memadai dalam menjalankan *Integrated Development Environment* (IDE), Jupyter Notebook, serta proses pelatihan dan eksekusi model klasifikasi secara bergantian.

Pemilihan RAM dengan kapasitas minimum 16 GB dipilih karena sudah mencukupi untuk melatih model klasifikasi dengan beban data yang lebih ringan. Pada penelitian ini, jumlah gambar untuk pelatihan model klasifikasi maksimal sekitar 1.500 gambar (contohnya pada model KM-4 untuk sub-kelas *upperwear* dengan dataset KD-4). Selain itu, kapasitas ini juga memadai untuk menjalankan IDE, Jupyter Notebook, serta sistem/aplikasi *interface* multi-stage yang mengintegrasikan delapan model.

Pemilihan GPU dengan kemampuan menjalankan NVIDIA CUDA dan VRAM minimum 6 GB dinilai sudah cukup untuk melatih dan menjalankan model klasifikasi, serta mendukung proses eksekusi model deteksi objek secara terpisah.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Dengan spesifikasi perangkat keras yang telah dirangkum dalam Tabel 4.5, diharapkan proses pelatihan model klasifikasi atribut mendalam, klasifikasi warna, serta pengembangan dan eksekusi sistem/aplikasi *interface* dapat berjalan secara optimal dan tanpa hambatan.

4.1.3 Identifikasi Kebutuhan Perangkat Lunak

Dalam pengembangan model serta sistem yang mendukung, perangkat lunak memiliki peran penting untuk menyediakan lingkungan kerja yang stabil dan kompatibel. Perangkat lunak yang digunakan terdiri atas sistem operasi, bahasa pemrograman, dan aplikasi pendukung lainnya untuk pengembangan dan implementasi antarmuka.

Kebutuhan perangkat lunak yang digunakan dalam penelitian ini dirangkum pada Tabel 4.6.

Tabel 4. 6 Kebutuhan perangkat lunak

Kode	Perangkat Lunak	Keterangan
KPSW-1	Sistem Operasi (Ubuntu/Windows)	Sistem operasi untuk pengembangan dan <i>deployment</i> .
KPSW-2	Python	Bahasa pemrograman utama.
KPSW-3	PyCharm	<i>Integrated Development Environment</i> (IDE) utama.
KPSW-4	Jupyter Notebook	Lingkungan untuk eksperimen dan analisis interaktif.
KPSW-5	Tkinter	<i>Framework</i> untuk membangun antarmuka aplikasi.

Perangkat lunak pada tabel 4.6 dipilih untuk menjamin stabilitas dalam pengembangan model dan pembangunan aplikasi. Sistem operasi modern seperti Ubuntu atau Windows dipilih berdasarkan preferensi dan kompatibilitas dengan driver perangkat keras. PyCharm digunakan sebagai lingkungan pengembangan terintegrasi utama untuk penulisan dan pengelolaan kode. Untuk kebutuhan



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

eksperimen yang lebih interaktif dan eksplorasi data, Jupyter Notebook menjadi pilihan utama.

4.1.4 Identifikasi Kebutuhan Library dan Framework

Selain perangkat lunak utama, dibutuhkan juga berbagai library dan framework pendukung yang digunakan dalam proses pelatihan model, pengolahan data, dan pembangunan sistem aplikasi. Library dan framework yang digunakan dirangkum pada Tabel 4.7.

Tabel 4. 7 Kebutuhan Library dan Framework

Kode	Library / Framework	Keterangan
KPLF-1	torch	Framework utama untuk pelatihan model deep learning.
KPLF-2	ultralytics	Framework tingkat tinggi untuk deteksi objek berbasis YOLO.
KPLF-3	tensorflow	Framework alternatif untuk tugas machine learning.
KPLF-4	opencv-python	Pengolahan citra dan video secara <i>real-time</i> .
KPLF-5	numpy	Operasi numerik dan manipulasi array.
KPLF-6	pandas	Pengolahan dan analisis data tabular.
KPLF-7	pillow	Manipulasi dan pengolahan gambar.

Pemilihan library dan framework ini didasarkan pada fungsionalitas, kompatibilitas, dan dukungan komunitas yang kuat. PyTorch bersama Ultralytics menjadi tulang punggung untuk pelatihan dan implementasi model deteksi objek. OpenCV dan Pillow digunakan secara ekstensif untuk tugas pra-pemrosesan dan manipulasi gambar, sementara NumPy dan Pandas berfungsi sebagai fondasi untuk semua operasi terkait data..

4.1.5 Identifikasi Kebutuhan Fungsional Sistem Multi-Stage

Sistem yang dikembangkan pada penelitian ini merupakan implementasi dari kerangka kerja multi-stage yang menggabungkan delapan model deep learning untuk melakukan deteksi dan klasifikasi atribut manusia secara otomatis dan *real-*



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

time. Sistem ini dirancang untuk menangani berbagai jenis atribut pakaian dan aksesoris manusia seperti *uppewear*, *bottomwear*, *headwear*, *eyewear*, *footwear* dan *bag*, serta klasifikasi kategori pakaian dan warna secara berurutan.

Setiap tahapan dalam sistem memiliki fungsi spesifik yang membentuk satu alur kerja deteksi visual, mulai dari deteksi objek, klasifikasi sub-kategori, hingga klasifikasi warna. Sistem ini tidak berorientasi pada antarmuka pengguna, namun berfokus pada performa teknis dan akurasi klasifikasi atribut melalui pendekatan bertahap (*multi-stage pipeline*).

Kebutuhan fungsional dari sistem ini dirangkum pada Tabel 4.8.

Tabel 4. 8 Kebutuhan Fungsional

Kode	Kebutuhan Fungsional	Deskripsi
KF-1	<i>Input Real-time</i> /Gambar/Video	Sistem menerima <i>input</i> berupa gambar atau video, baik secara <i>real-time</i> maupun dari file.
KF-2	Deteksi Atribut Umum (YOLO)	Sistem mendeteksi keberadaan objek manusia dan atribut pakaian seperti <i>uppewear</i> , <i>bottomwear</i> , <i>headwear</i> , <i>eyewear</i> , <i>footwear</i> dan <i>bag</i> menggunakan model YOLO.
KF-3	Ekstraksi Citra Atribut	Sistem memotong dan menyimpan bagian citra yang terletak dalam bounding box berdasarkan hasil atribut sebagai <i>input</i> untuk model klasifikasi atribut dan warna.
KF-4	Klasifikasi Sub-Kategori Atribut (CNN)	Sistem mengklasifikasikan objek pakaian yang terdeteksi ke dalam sub-kategori seperti <i>t-shirt</i> , <i>dress</i> , <i>jacket</i> , <i>pants</i> , <i>skirt</i> , dll. menggunakan model CNN per atribut.
KF-5	Ekstraksi Nilai RGB	Sistem mengekstrak nilai warna RGB dari bounding box objek pakaian yang telah dikenali.
KF-6	Klasifikasi Warna (MLP)	Sistem mengklasifikasikan warna pakaian ke dalam 11 label warna (merah, hijau, biru, kuning, dll.) menggunakan Multi Layer Perceptron (MLP).
KF-7	Penggabungan <i>Output</i> Multi-Stage	Sistem menyatukan hasil deteksi, klasifikasi sub-kategori, dan klasifikasi warna menjadi satu keluaran akhir per objek.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

KF-8	Evaluasi Performa Sistem	Sistem menyimpan hasil klasifikasi untuk keperluan evaluasi metrik seperti akurasi, <i>precision</i> , <i>recall</i> , dan <i>F1-score</i> .
------	--------------------------	--

Tabel 4.8 di atas merangkum delapan kebutuhan utama yang menjadi landasan dari sistem multi-stage ini. Setiap kebutuhan fungsional merepresentasikan tahapan dalam alur kerja sistem, mulai dari akuisisi data masukan, proses deteksi awal, pemrosesan atribut visual, hingga klasifikasi dan evaluasi akhir. Keberadaan proses *ekstraksi citra atribut* yang berasal dari bounding box merupakan tahap krusial karena menjadi titik awal pemisahan objek untuk klasifikasi spesifik berdasarkan bentuk dan warna.

Kebutuhan ini juga mendukung sistem untuk bekerja secara modular, memungkinkan pengembangan lanjutan atau penggantian salah satu komponen model tanpa mengganggu keseluruhan arsitektur sistem. Penjelasan lebih rinci terkait alur dan integrasi antar komponen sistem dijabarkan pada sub-bab berikutnya 4.2 Perancangan Sistem yang membahas alur sistem multi-stage secara menyeluruh.

4.1.6 Identifikasi Kebutuhan Non-Fungsional Sistem Multi-Stage

Kebutuhan non-fungsional merupakan spesifikasi yang menjelaskan kriteria kualitas dari sistem yang dikembangkan. Berbeda dengan kebutuhan fungsional yang berfokus pada apa yang dilakukan sistem, kebutuhan non-fungsional berfokus pada *bagaimana* sistem bekerja agar dapat mencapai performa yang diharapkan, terutama dalam konteks efisiensi, kompatibilitas, dan kinerja waktu nyata (*real-time*). Kebutuhan ini penting untuk menjamin

bahwa sistem multi-stage dapat dijalankan secara optimal dan stabil dalam kondisi operasional yang ditentukan.

Kebutuhan non-fungsional dari sistem ini dirangkum pada Tabel 4.9.

Tabel 4. 9 Kebutuhan Non-Fungsional Sistem Multi-Stage

Kode	Kebutuhan Non-Fungsional	Deskripsi
KNF-1	Kinerja <i>Real-time</i>	Sistem mampu memproses minimal 10 frame per detik (FPS) agar dapat memberikan hasil deteksi dan klasifikasi secara langsung tanpa jeda signifikan.
KNF-2	Efisiensi Komputasi	Sistem dioptimalkan untuk menjalankan berbagai model deep learning secara paralel dengan efisien, di mana deteksi objek (YOLO) dijalankan pada GPU (VGA), sedangkan proses klasifikasi warna dan sub-kategori atribut dapat dijalankan pada CPU. Pemisahan beban ini ditujukan untuk mengurangi <i>bottleneck</i> dan meningkatkan stabilitas sistem.
KNF-3	Skalabilitas Modular	Arsitektur sistem dirancang secara modular agar tiap model (YOLO, CNN, MLP) dapat diganti atau ditingkatkan tanpa mengubah keseluruhan struktur sistem.

Tabel 4.9 menjelaskan empat kebutuhan non-fungsional utama yang menjadi acuan dalam pengembangan sistem multi-stage. Fokus pada kinerja *real-time* menjadi penting karena sistem dirancang untuk melakukan deteksi dan klasifikasi secara langsung. Kebutuhan akan efisiensi komputasi menekankan pengelolaan sumber daya perangkat keras, di mana model deteksi yang lebih berat dijalankan di GPU, sementara model yang lebih ringan tetap berjalan pada CPU. Pendekatan ini memungkinkan penggunaan perangkat keras yang lebih fleksibel dan terjangkau.

4.2 Perancangan Sistem

Setelah proses identifikasi masalah dilakukan, tahap selanjutnya dalam penelitian ini adalah perancangan sistem. Perancangan sistem bertujuan sebagai acuan dalam membangun dan mengembangkan solusi yang diusulkan secara terstruktur. Dalam penelitian ini, sistem yang dikembangkan terbagi menjadi dua *bagian* utama, yaitu perancangan model deep learning dan pengembangan aplikasi *interface*.

Alur kerja sistem secara keseluruhan telah dirangkum dalam diagram alur sistem dan dapat dilihat pada Gambar 4.2. Diagram tersebut menggambarkan hubungan



Hak Cipta :


1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

antar komponen serta urutan proses yang dilakukan sistem mulai dari *input* pengguna hingga *output* akhir yang ditampilkan.



Gambar 4. 2 Alur Kerja Sistem Multi-Stage

Berdasarkan Gambar 4.2, berikut adalah penjelasan alur kerja sistem:

1. **Deteksi Objek dengan YOLOv8:** Proses diawali dengan mendeteksi objek pada citra masukan menggunakan model deteksi YOLOv8. Tahap ini bertujuan untuk mengidentifikasi atribut-atribut umum yang dikenakan manusia dan menghasilkan informasi berupa koordinat *bounding box* serta label awal untuk setiap objek yang terdeteksi, seperti *headwear*, *eyewear*, *upperwear*, *bottomwear*, *footwear*, dan *bag*.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

2. **Klasifikasi Lanjutan:** Setelah mendapatkan hasil deteksi awal, sistem memasuki tahap klasifikasi lanjutan yang alurnya ditentukan oleh label objek.

- a. **Pemeriksaan Label Objek:** Sistem memeriksa label dari setiap objek yang dideteksi oleh YOLOv8 untuk memilih model klasifikasi yang spesifik.
- b. **Klasifikasi Jenis Atribut:** Sebelum diklasifikasikan, area citra (*Region of Interest* - RoI) diekstraksi berdasarkan *bounding box*. Kemudian, dilakukan pra-pemrosesan untuk menyesuaikan ukuran citra: untuk atribut *eyewear*, citra di-*stretch*, sementara untuk atribut lainnya, citra di-*resize* secara proporsional dengan *padding*. Selanjutnya, citra yang telah diproses dimasukkan ke dalam model klasifikasi yang telah dirancang khusus untuk setiap label (Gunakan Model *Headwear*, Gunakan Model *Upperwear*, dst.). Setiap model ini (berbasis CNN dengan *pre-trained* MobileNetV2) bertugas untuk mengenali sub-kategori yang lebih detail dari setiap atribut. Sebagai contoh, untuk label *upperwear*, model akan mengklasifikasikannya lebih lanjut menjadi jenis seperti *t-shirt*, *jacket*, atau *shirt*.
- c. **Klasifikasi Warna Atribut:** Setelah jenis atribut spesifik berhasil diidentifikasi, semua alur bertemu pada tahap klasifikasi warna. Sistem menerapkan dua pendekatan untuk ekstraksi warna. Untuk atribut seperti *bottomwear* dan *jacket*, warna dominan ditentukan dari sampel tiga titik (kiri, tengah, kanan) pada *bounding box*. Untuk atribut lainnya, nilai RGB diambil dari titik tengah *bounding box*. Nilai RGB ini kemudian diumpankan ke model *Multi Layer Perceptron* (MLP) untuk diklasifikasikan menjadi salah satu warna yang telah ditentukan.

1. **Gabungkan & Tampilkan Hasil Anotasi:** Pada tahap akhir, hasil dari klasifikasi jenis atribut (sub-kategori) dan klasifikasi warna digabungkan. Sistem kemudian menampilkan output akhir berupa anotasi lengkap pada citra (visual *bounding box* dengan label) serta dalam bentuk tabel klasifikasi.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumpulkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Secara keseluruhan, sistem ini dirancang untuk menghasilkan informasi yang lengkap mengenai atribut manusia, mencakup jenis atribut, sub-kategori atribut, dan warna dominan atribut.

4.2.1 Pengumpulan dan Pemrosesan Dataset

Pengumpulan dan pemrosesan dataset merupakan tahap fundamental dalam penelitian ini, karena kualitas dan kuantitas data akan secara langsung memengaruhi performa model yang akan dikembangkan. Tahap ini berfokus pada proses pengumpulan, pengorganisasian, dan pra-pemrosesan dataset yang akan digunakan untuk melatih, mengevaluasi, dan menguji tiga model utama dalam sistem multi-stage, yaitu model deteksi objek atribut, model klasifikasi atribut, dan model klasifikasi warna pakaian.

Dataset yang digunakan dalam penelitian ini diperoleh dari kombinasi beberapa sumber. Untuk pelatihan model deteksi objek, digunakan dataset publik seperti *DeepFashion* (Z. Liu et al., 2016) dan *InFashAI* (Hacheme & Sayouti, 2021), yang menyediakan anotasi bounding box dan informasi atribut pakaian. Sementara itu, model klasifikasi atribut yang lebih mendalam dilatih menggunakan *Fashion Product Images Dataset* (Aggarwal, 2019), yang menyajikan data gambar pakaian dengan label multi-kategori.

Untuk memperkaya dan menyeimbangkan distribusi kelas pada atribut tertentu yang kurang terwakili, dilakukan pengumpulan tambahan menggunakan teknik *web scraping* dari berbagai platform gambar di internet. Pendekatan gabungan ini bertujuan untuk memastikan keragaman data, mencakup berbagai variasi dalam hal pencahayaan, sudut pandang, pose, dan latar belakang sehingga model yang dihasilkan dapat lebih robust terhadap kondisi dunia nyata.


4.2.1.1 Alur Pengumpulan dan Pemrosesan Dataset Deteksi Objek

Proses pengumpulan dan pemrosesan dataset untuk deteksi objek atribut pakaian merupakan tahapan awal dalam pengembangan model. Tujuan utama dari proses ini adalah untuk menghasilkan data yang bersih, teranotasi dengan benar, serta siap digunakan dalam pelatihan model deteksi objek berbasis YOLOv8. Alur lengkap dari tahapan ini telah dirangkum dalam diagram dan dapat dilihat pada Gambar 4.3.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4. 3 Pengumpulan dan Pemrosesan Dataset Deteksi Atribut

Pada gambar 4.3, tahap pertama dimulai dengan proses pengumpulan data mentah dari dua sumber dataset, yaitu *DeepFashion* dan *InFashAI*. Kedua dataset ini dipilih karena memiliki karakteristik data yang relevan, seperti citra manusia dengan berbagai atribut pakaian yang umum ditemukan dalam konteks penggunaan sistem. Data dari kedua sumber kemudian dikonsolidasi ke dalam satu himpunan yang disebut Raw Dataset.

Setelah data terkumpul, tahap selanjutnya adalah Proses anotasi, proses ini dilakukan terhadap setiap gambar dalam Raw Dataset untuk memberikan informasi



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

berupa koordinat bounding box serta label atribut pakaian, seperti: *headwear*, *eyewear*, *upperwear*, *bottomwear*, *footwear*, dan *bag*.

Anotasi dilakukan secara semi-otomatis dengan urutan sebagai berikut:

- a. Gambar terlebih dahulu diunggah ke platform Roboflow, tempat proyek anotasi dibuat.
- b. Proses anotasi bounding box dilakukan secara otomatis menggunakan model Grounding DINO, yaitu model deteksi berbasis transformer yang dapat memberikan prediksi bounding box dan label dari prompt teks.
- c. Hasil anotasi otomatis kemudian dilakukan review dan koreksi manual untuk memastikan ketepatan lokasi bounding box dan kesesuaian label atribut, serta menghapus kesalahan anotasi.

Dataset yang telah dianotasi kemudian dibagi ke dalam tiga subset, yaitu:

- a. Train Dataset (80%): digunakan sebagai data utama dalam proses pelatihan model deteksi objek.
- b. Validation Dataset (15%): digunakan untuk mengevaluasi performa model selama proses pelatihan berlangsung, terutama dalam mendeteksi tanda-tanda overfitting.
- c. Test Dataset (5%): digunakan untuk mengukur performa akhir model setelah proses pelatihan selesai.

Agar model mampu mengenali atribut dengan lebih baik dalam kondisi pencahayaan dan tampilan yang bervariasi, dilakukan proses augmentasi pada data pelatihan. Proses ini bertujuan untuk meningkatkan keragaman data dan kemampuan generalisasi model. Beberapa teknik augmentasi yang digunakan adalah sebagai berikut:

- a. Horizontal flip: membalik gambar secara horizontal untuk menambah variasi sudut pandang.
- b. Penyesuaian brightness $\pm 15\%$: mengubah tingkat kecerahan gambar.
- c. Penyesuaian exposure $\pm 6\%$: mengatur eksposur untuk menciptakan simulasi kondisi pencahayaan yang berbeda.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta


- d. Penambahan noise 0.69%: menyisipkan noise ringan guna menguji ketahanan model terhadap gangguan visual.

Hasil dari proses augmentasi ini dikombinasikan kembali ke dalam Train Dataset untuk digunakan dalam pelatihan akhir model deteksi objek. Dengan demikian, model yang dilatih akan lebih robust terhadap variasi yang mungkin terjadi di lingkungan nyata.

4.2.1.2 Alur Pengumpulan dan Pemrosesan Dataset Klasifikasi Jenis Atribut

Pengumpulan dan pemrosesan dataset untuk kebutuhan klasifikasi jenis atribut merupakan tahap penting yang bertujuan untuk menyiapkan data *input* yang sesuai dengan arsitektur model klasifikasi yang digunakan. Dataset yang dikumpulkan digunakan untuk mengembangkan model klasifikasi pada enam kategori atribut utama, yaitu *headwear*, *eyewear*, *upperwear*, *bottomwear*, *footwear*, dan *bag*. Proses ini memastikan bahwa setiap data citra telah melalui tahap seleksi, standarisasi ukuran, dan penyesuaian format sebelum digunakan dalam proses pelatihan dan evaluasi model.

Alur lengkap dari tahapan ini telah dirangkum dalam diagram dan dapat dilihat pada Gambar 4.4.



Gambar 4. 4 Pengumpulan dan Pemrosesan Dataset Klasifikasi Jenis Atribut

Gambar 4.4 menjelaskan alur proses pengumpulan dan pemrosesan dataset klasifikasi jenis atribut. Pada tahap awal, data dikumpulkan melalui dua metode



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

utama, yaitu pengambilan data dari dataset publik seperti *Fashion Image Product Dataset*, serta pengambilan data melalui proses web *scraping* dari berbagai situs e-commerce yang menampilkan produk fesyen. Seluruh data yang diperoleh dari kedua sumber ini dikompilasi menjadi satu raw dataset.


Selanjutnya, raw dataset ini diproses melalui tahapan penyesuaian dimensi dan struktur gambar. Proses ini mencakup *resizing* gambar agar sesuai dengan ukuran yang ditentukan untuk masing-masing kategori atribut, yaitu 128×128 piksel atau 224×224 piksel, tergantung pada jenis atribut. Untuk menjaga aspek rasio gambar, dilakukan penambahan *padding* berwarna putih sehingga proporsi citra tetap konsisten dan berbentuk persegi (1:1).

Dataset yang telah diproses kemudian disimpan dalam bentuk siap pakai dan digunakan pada proses pelatihan dan evaluasi model klasifikasi jenis atribut. Penting untuk dicatat bahwa seluruh kategori atribut (KD-2 hingga KD-7) melalui alur proses yang sama sebagaimana ditunjukkan pada diagram di atas, sehingga alur yang ditampilkan bersifat representatif untuk keseluruhan proses pengumpulan dan pemrosesan data klasifikasi atribut.

4.2.1.3 Alur Pengumpulan dan Pemrosesan Dataset Klasifikasi Warna

Dataset klasifikasi warna dalam penelitian ini tidak diperoleh dalam bentuk citra visual, melainkan berupa nilai parameter warna dalam format RGB (*Red, Green, Blue*) yang disertai label warna dominan sebagai target klasifikasi. Dataset ini digunakan untuk melatih model klasifikasi warna yang bertugas mengidentifikasi warna dominan dari atribut pakaian yang telah terdeteksi sebelumnya oleh sistem.

Alur lengkap dari tahapan ini telah dirangkum dalam diagram dan dapat dilihat pada Gambar 4.5.



Gambar 4. 5 Alur Pengumpulan dan Pemrosesan Dataset Klasifikasi Warna



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Proses pada Gambar 4.5 dimulai dengan pengambilan dan pemilihan data publik yang memuat nilai parameter RGB dan label warna tanpa menyertakan citra visual. Dataset ini dipilih berdasarkan keberagaman nilai warna serta kejelasan kategorisasi label warna. Setiap entri data terdiri atas tiga nilai kanal warna (R, G, B) serta satu label warna dominan, yang akan digunakan sebagai target untuk pelatihan model klasifikasi.

Klasifikasi warna yang digunakan dalam sistem ini mencakup warna-warna dominan yang umum ditemukan pada atribut pakaian, yaitu: merah, hijau, biru, coklat, pink, kuning, oranye, ungu, hitam, abu-abu, dan putih. Model akan memetakan kombinasi nilai RGB ke dalam salah satu dari sebelas kelas warna tersebut.

Berbeda dari proses klasifikasi berbasis citra, pengambilan nilai RGB dalam sistem ini dilakukan secara langsung dari hasil ekstraksi bounding box atribut pakaian, yang telah dijelaskan pada sub-bab perancangan sistem. Nilai RGB diambil dari titik pusat bounding box, atau dari beberapa titik horizontal tergantung pada jenis atribut, dan kemudian digunakan sebagai *input* untuk model klasifikasi warna.

Distribusi nilai RGB pada dataset memiliki keragaman yang tinggi, sehingga berpotensi menyebabkan ketidakseimbangan jumlah sampel per kelas warna.

Secara keseluruhan, alur ini memastikan bahwa data warna yang digunakan bersifat representatif dan dapat digunakan secara efektif dalam proses klasifikasi warna atribut.

4.2.2 Perancangan Model *Deep Learning*

Perancangan model *deep learning* merupakan tahap krusial dalam sistem pengenalan atribut manusia, karena kualitas rancangan model akan menentukan akurasi dan keandalan sistem secara keseluruhan. Pada tahap ini, dilakukan perancangan arsitektur dan strategi pelatihan model untuk masing-masing tugas klasifikasi, seperti deteksi objek, klasifikasi jenis atribut, dan klasifikasi warna. Model yang digunakan pada penelitian ini mengandalkan arsitektur *Convolutional Neural Network* (CNN) untuk deteksi atribut dan klasifikasi atribut yang telah terbukti efektif dalam pemrosesan citra, dan arsitektur *Multi-Layer Perceptron*



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta


(MLP) untuk fungsi prediktif sederhana . Setiap model dirancang dan dilatih menggunakan dataset yang telah disiapkan pada tahap sebelumnya, dengan mempertimbangkan teknik augmentasi, parameter pelatihan, serta metode evaluasi kinerja.

4.2.2.1 Alur Perancangan Model Deteksi Atribut

Pada sub-bab ini, dijelaskan mengenai alur pengembangan model deep learning untuk tugas deteksi atribut manusia. Tahapan ini merupakan kelanjutan dari proses pengumpulan dan pemrosesan dataset yang telah dijelaskan sebelumnya pada Gambar 4.3. Model deteksi yang digunakan berbasis arsitektur YOLOv8 yang berikan bobot (*pre-trained*) mode YOLOv8l, dengan harapan mampu mengidentifikasi keberadaan dan lokasi atribut seperti *headwear*, *eyewear*, *upperwear*, *bottomwear*, *bag*, dan *footwear* secara presisi melalui bounding box.

Proses ini mencakup beberapa langkah utama, yaitu pengambilan dataset yang sebelumnya telah dibagi ke dalam tiga subset (*train*, *validation*, dan *test*), dilanjutkan dengan pemuatan bobot *pre-trained* model YOLOv8l yang telah dilatih sebelumnya, dan dilanjutkan ke dalam proses pelatihan model dengan arsitektur YOLOv8 menggunakan dataset pelatihan, serta evaluasi performa model berdasarkan dataset validasi, serta melakukan *test* secara langsung menggunakan subset *test*.

Alur lengkap dari tahapan ini telah dirangkum dalam diagram dan dapat dilihat pada Gambar 4.6.



Gambar 4. 6 Perancangan Model Deteksi Atribut



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Gambar 4.6 menggambarkan keseluruhan proses dalam pengembangan model deteksi atribut. Proses dimulai dari tahap pengambilan dataset yang sebelumnya telah dibagi ke dalam tiga *bagian*, yaitu *train*, *validation*, dan *test*. Dataset ini merupakan hasil dari proses anotasi dan augmentasi data seperti yang ditunjukkan pada Gambar 4.3. Dataset pelatihan kemudian digunakan untuk melatih model deteksi berbasis YOLOv8 yang sebelumnya telah dimuat menggunakan bobot *pre-trained*.

Setelah proses pelatihan selesai, model yang telah terlatih dievaluasi menggunakan dataset validasi dan *test* untuk memperoleh metrik performa seperti *precision*, *recall*, dan mAP (*mean Average Precision*). Hasil evaluasi inilah yang menjadi acuan utama dalam menilai seberapa baik model mampu melakukan deteksi atribut pada data yang belum pernah dilihat sebelumnya.

Dengan alur ini, sistem deteksi atribut diharapkan memiliki kemampuan generalisasi yang baik untuk diterapkan pada skenario yang diinginkan.

4.2.2.2 Alur Perancangan Model Klasifikasi Atribut

Tahapan perancangan model klasifikasi atribut bertujuan untuk membangun sistem yang mampu mengenali jenis sub-kategori dari atribut fesyen yang telah dideteksi sebelumnya. Model yang digunakan untuk klasifikasi atribut dalam penelitian ini adalah *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2, yang dipilih karena efisiensi parameter serta kinerjanya yang baik dalam pengolahan citra berukuran kecil hingga menengah.


Setiap atribut utama yang telah didefinisikan pada tahap deteksi (KD-2 hingga KD-7) akan memiliki model klasifikasi masing-masing (KM-2 hingga KM-7), yang bertugas untuk mengklasifikasikan sub-kelas dari atribut tersebut. Misalnya, KM-2 bertugas mengklasifikasikan *headwear* menjadi *cap* dan *hat*, KM-4 mengklasifikasikan *upperwear* menjadi *t-shirt*, *shirt*, *sweater*, *jacket*, dan *dress*, dan seterusnya.

Alur lengkap dari tahapan ini telah dirangkum dalam diagram dan dapat dilihat pada Gambar 4.7



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4. 7 Alur Perancangan model klasifikasi atribut

Gambar 4.7 menjelaskan tahapan yang dimulai dari pembagian dataset hasil preprocessing menjadi *train* dataset (80%), *validation* dataset (15%), dan *test* dataset (5%). Dataset ini sebelumnya telah diproses dan disesuaikan ukurannya pada tahap pengumpulan dan pemrosesan data (lihat Gambar 4.4).

Sebelum proses pelatihan, data pada *train* dataset akan melalui tahap pra-pemrosesan tambahan yang mencakup augmentasi horizontal flip, random zoom, dan random rotation untuk *train* dataset. Selanjutnya, bobot model MobileNetV2 yang telah dilatih sebelumnya (*pre-trained* pada ImageNet) di-load untuk mempercepat konvergensi dan meningkatkan akurasi klasifikasi.

Model kemudian dilatih menggunakan *train* dataset dan divalidasi dengan *validation* dataset untuk menghindari overfitting. Setelah proses pelatihan selesai, model dievaluasi menggunakan *test* dataset untuk mengukur performa aktual dari model.

Untuk mengukur kinerja model secara kuantitatif, digunakan beberapa metrik evaluasi, yaitu:

- a. *Precision*, untuk mengukur seberapa akurat prediksi positif yang dilakukan model terhadap kelas tertentu.
- b. *Recall*, untuk menilai sejauh mana model mampu menangkap seluruh data positif dari suatu kelas.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta


- c. *F1-score*, yaitu rata-rata harmonis antara *precision* dan *recall*, berguna ketika data tidak seimbang antar kelas.
- d. Confusion matrix, digunakan untuk memvisualisasikan jumlah prediksi benar dan salah dalam tiap kelas, serta membantu mengidentifikasi pola kesalahan klasifikasi.

Keempat metrik ini digunakan pada seluruh model klasifikasi atribut (KM-2 hingga KM-7) untuk memberikan gambaran yang menyeluruh terhadap kemampuan model dalam mengenali dan membedakan tiap sub-kategori atribut fesyen.

4.2.2.3 Alur Perancangan Model Klasifikasi Warna

Setelah data warna dikumpulkan dalam bentuk nilai RGB yang disertai label warna dominan, langkah selanjutnya adalah merancang arsitektur dan proses pelatihan model klasifikasi warna. Proses ini mencakup tahap *pre-processing* data, pembagian dataset, pelatihan model menggunakan algoritma klasifikasi berbasis deep learning, serta evaluasi performa model dengan sejumlah metrik evaluasi.

Alur lengkap dari tahapan ini telah dirangkum dalam diagram dan dapat dilihat pada Gambar 4.8



Gambar 4. 8 Perancangan Model Klasifikasi Warna



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Gambar 4.8 menggambarkan proses pengembangan model klasifikasi warna yang dimulai dari pemrosesan dataset. Dataset yang berisi nilai RGB dan label warna dominan pertama-tama dipecah menjadi dua *bagian* utama: dependent (X) dan independent (y). Data dependent kemudian dinormalisasi untuk menyamakan skala nilai RGB, sementara data independent dikodekan ke dalam bentuk numerik menggunakan teknik label encoding.

Setelah melalui tahap praproses, data dibagi ke dalam tiga subset: *training* dataset (80%), *validation* dataset (15%), dan *test* dataset (5%). Dataset *training* digunakan untuk proses pembelajaran model, dataset validasi digunakan untuk mengatur parameter model dan mencegah overfitting, sedangkan dataset pengujian digunakan untuk mengukur performa akhir model.

Model klasifikasi warna dilatih menggunakan arsitektur jaringan saraf sederhana (*Multi-Layer Perceptron*) yang disesuaikan untuk *input* numerik berupa RGB. Setelah pelatihan selesai, model diuji dan dievaluasi menggunakan beberapa metrik evaluasi utama, yaitu:

- a. *Precision*: Mengukur seberapa tepat model dalam mengklasifikasikan warna dengan benar dari semua prediksi yang dibuat.
- b. *Recall*: Menunjukkan seberapa banyak kasus warna sebenarnya yang berhasil dikenali oleh model.
- c. *F1-score*: Rata-rata harmonis dari *precision* dan *recall* yang memberikan keseimbangan antara keduanya.
- d. Confusion Matrix: Matriks visualisasi yang menampilkan perbandingan antara label aktual dan label prediksi pada setiap kelas warna.

Evaluasi ini bertujuan untuk memastikan bahwa model klasifikasi warna dapat bekerja secara akurat dalam mengidentifikasi warna dominan dari atribut pakaian berdasarkan nilai RGB yang diambil dari sistem deteksi objek.

Dengan alur perancangan ini, seluruh proses klasifikasi warna dapat dilakukan secara sistematis dan terukur, memungkinkan model untuk memberikan hasil prediksi warna yang andal dalam sistem pengenalan atribut pakaian yang dikembangkan.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta


4.2.3 Perancangan Antarmuka Grafis

Sistem multi-stage yang dikembangkan dalam penelitian ini dilengkapi dengan antarmuka grafis (GUI) yang bertujuan untuk memudahkan pengguna dalam menjalankan sistem, baik untuk menganalisis gambar, video, maupun *input* kamera secara *real-time*. Antarmuka ini memungkinkan pengguna untuk melakukan konfigurasi model, seperti mengaktifkan atau menonaktifkan model klasifikasi atribut, sesuai kebutuhan. Desain GUI disusun agar intuitif dan responsif, mendukung fleksibilitas pemrosesan dengan tetap mempertahankan performa sistem yang optimal.

4.2.3.1 Use Case Diagram

Sebagaimana telah dijelaskan pada Subbab 4.3 sebelumnya, sistem antarmuka pengguna (GUI) dirancang untuk memberikan kemudahan dalam menjalankan dan mengelola proses analisis visual menggunakan pendekatan multi-stage. Untuk memberikan gambaran yang lebih komprehensif mengenai fungsi-fungsi yang dapat diakses oleh pengguna serta interaksi yang terjadi dalam sistem, use-case diagram digunakan sebagai alat bantu perancangan.

Alur lengkap dari tahapan interaksi pengguna dengan sistem ini telah dirangkum dalam diagram dan dapat dilihat pada Gambar 4.9.



Gambar 4. 9 Use Case Diagram



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Gambar 4.9. menggambarkan tiga skenario utama yang dapat dijalankan oleh pengguna, yaitu menganalisis gambar, video, dan *input* kamera secara *real-time*. Setiap proses analisis akan selalu mencakup tindakan untuk Melihat Hasil Deteksi, sebagaimana ditunjukkan oleh relasi <<include>>, karena proses ini merupakan bagian tak terpisahkan dari *output* sistem. Di sisi lain, sistem memberikan fleksibilitas kepada pengguna untuk mengaktifkan atau menonaktifkan klasifikasi tahap kedua melalui proses Mengonfigurasi Deteksi, yang dihubungkan dengan relasi <<extend>>. Ini mencerminkan sifat modular dan adaptif dari sistem, di mana pengguna memiliki kontrol atas kompleksitas pemrosesan sesuai kebutuhan dan sumber daya perangkat yang digunakan.

4.2.3.2 Activity Daigram

Untuk memberikan pemahaman yang lebih jelas mengenai alur aktivitas pengguna dalam berinteraksi dengan sistem, sub-bab ini menyajikan activity diagram untuk masing-masing fitur utama pada aplikasi antarmuka sistem multi-stage, yaitu analisis gambar, analisis video, dan kamera *real-time*. Diagram ini menggambarkan urutan proses dari masukan pengguna hingga sistem menampilkan hasil deteksi. Seluruh proses mencerminkan tahapan kerja dari sistem multi-stage yang telah menggabungkan model deteksi atribut, klasifikasi atribut, dan klasifikasi warna.


4.2.3.2.1 Activity Diagram *Real-time* Camera

Fitur *Real-time* Camera memungkinkan pengguna melakukan deteksi atribut pakaian dan aksesoris secara langsung melalui kamera yang terhubung ke perangkat. Sistem akan secara otomatis mengenali kamera yang tersedia dan menjalankan proses deteksi, klasifikasi atribut, serta klasifikasi warna secara *real-time* berdasarkan konfigurasi sistem multi-stage. Alur aktivitas dari fitur ini dapat dilihat pada Gambar 4.10.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4. 10 Activity Diagram Real-time Camera

Diagram aktivitas Gambar 4.10 ini menggambarkan alur interaksi antara pengguna dan sistem saat menggunakan fitur *Real-time Camera* pada aplikasi sistem multi-stage.

Alur dimulai ketika pengguna membuka halaman *Real-time Camera*, yang kemudian akan direspons oleh sistem dengan menampilkan halaman yang dimaksud. Selanjutnya, pengguna melakukan seleksi atribut yang ingin diklasifikasikan lebih dalam, dan akan diproses oleh sistem.

Setelah konfigurasi selesai, pengguna akan menekan tombol start camera. Sistem kemudian akan mendeteksi kamera yang tersedia secara otomatis, dan mulai menjalankan proses analisis secara *real-time*. Proses ini mencakup deteksi objek, klasifikasi atribut, dan klasifikasi warna berdasarkan model-model yang diaktifkan sebelumnya oleh pengguna.

Akhir dari aktivitas ini adalah ketika sistem memproses dan menampilkan hasil deteksi secara langsung kepada pengguna melalui antarmuka visual, memungkinkan pengguna untuk melihat hasil sistem multi-stage.




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

4.2.3.2.2 Activity Diagram Image Analysis

Fitur Image Analysis dirancang untuk menganalisis gambar statis yang diunggah oleh pengguna. Setelah gambar dipilih, sistem akan menjalankan proses deteksi objek dan, jika diaktifkan, melanjutkan ke tahap klasifikasi atribut dan klasifikasi warna. Proses ini mengikuti struktur sistem multi-stage yang telah dibangun. Alur aktivitas dari fitur ini dirangkum dalam Gambar 4.11.



Gambar 4. 11 Activity Diagram Image Analysis

Diagram aktivitas Gambar 4.11 ini menjelaskan alur interaksi pengguna dan sistem saat menggunakan fitur Image Analysis pada sistem multi-stage.

Proses dimulai ketika pengguna membuka halaman Image Analysis, kemudian sistem merespons dengan menampilkan halaman analisis gambar. Setelah halaman terbuka, pengguna dapat melakukan seleksi atribut yang ingin diklasifikasikan lebih dalam, seperti memilih jenis atribut manusia yang akan diproses oleh sistem.

Selanjutnya, pengguna akan menekan tombol upload image dan memilih gambar dari perangkat lokal. Setelah gambar dipilih, sistem akan menjalankan proses analisis terhadap gambar tersebut, mencakup proses deteksi objek, klasifikasi atribut, dan klasifikasi warna berdasarkan konfigurasi model yang diaktifkan pengguna.




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Terakhir, hasil analisis ditampilkan kepada pengguna dalam bentuk visualisasi bounding box dan label atribut, memberikan informasi yang dihasilkan oleh sistem multi-stage secara menyeluruh terhadap gambar yang diunggah.

4.2.3.2.3 Activity Diagram Video Analysis

Fitur Video Analysis memungkinkan pengguna mengunggah video untuk dianalisis oleh sistem secara otomatis. Proses analisis dilakukan pada setiap frame video, dimulai dari deteksi objek hingga klasifikasi atribut dan warna jika model terkait diaktifkan. Hasil akhir analisis ditampilkan sesuai dengan konfigurasi sistem multi-stage. Alur lengkap dari fitur ini disajikan dalam Gambar 4.12.



Gambar 4. 12 Activity Diagram Video Analysis

Diagram ini menjelaskan urutan aktivitas antara pengguna dan sistem ketika menggunakan fitur Video Analysis dalam sistem multi-stage.

Langkah pertama dimulai saat pengguna membuka halaman Video Analysis, yang akan direspons oleh sistem dengan menampilkan halaman tersebut. Setelah halaman tampil, pengguna dapat melakukan seleksi atribut yang ingin diklasifikasikan lebih lanjut oleh sistem.

Setelah konfigurasi selesai, pengguna kemudian menekan tombol upload video, memilih file video dari perangkatnya, dan melanjutkan dengan menekan tombol start processing. Tindakan ini akan menginisiasi pemrosesan oleh sistem.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumpulkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Sistem kemudian akan memproses setiap frame dari file video yang telah dipilih, dan menjalankan sistem deteksi objek, klasifikasi atribut, serta klasifikasi warna sesuai konfigurasi aktif. Hasil dari analisis tersebut akan ditampilkan kepada pengguna secara menyeluruh, baik dalam bentuk visualisasi maupun informasi atribut yang terdeteksi oleh sistem multi-stage.

4.3 Implementasi Sistem

Serangkaian rancangan yang telah disusun pada bab perancangan sistem diwujudkan pada tahap penelitian implementasi sistem ini, implementasi sistem dibagi menjadi dua fase utama yakni implementasi model deep learning, dan implementasi antarmuka grafis. Pemisahan ini dilakukan karena pengembangan aplikasi antarmuka hanya dapat dilakukan setelah semua model telah selesai dikembangkan. Dengan pemisahan ini dapat dipastikan bahwa model yang digunakan untuk implementasi web adalah model yang terbaik.

4.3.1 Implementasi Model

Tahap implementasi model merupakan proses lanjutan dari perancangan sistem yang telah dijabarkan pada bab sebelumnya. Pada tahap ini, seluruh model deep learning yang telah dirancang, baik untuk deteksi objek, klasifikasi jenis atribut, maupun klasifikasi warna, mulai diimplementasikan dan diuji menggunakan dataset yang telah dipersiapkan sebelumnya.

Model-model ini dikembangkan secara terpisah berdasarkan kebutuhan spesifik dari setiap jenis tugas klasifikasi dan deteksi. Setiap model dilatih menggunakan dataset yang telah diproses dan disesuaikan, dengan mempertimbangkan parameter seperti ukuran gambar, format *input*, dan distribusi kelas. Hasil dari proses pelatihan ini akan menjadi dasar dalam pemilihan model terbaik yang nantinya akan diintegrasikan ke dalam sistem antarmuka grafis pada tahap selanjutnya.

Bagian ini juga memuat deskripsi hasil pengumpulan dan pemrosesan dataset yang digunakan sebagai *input* dalam pelatihan model. Dataset tersebut disusun berdasarkan kategori tugas yang telah ditentukan, mencakup atribut *headwear*, *eyewear*, *upperwear*, *bottomwear*, *footwear*, *bag*, serta klasifikasi warna.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

4.3.1.1 Implementasi Dataset

Sebelum melanjutkan ke proses pelatihan model deep learning, dibutuhkan dataset sebagai fondasi utama untuk melatih seluruh model yang telah dirancang dalam tahap perancangan sistem. Dataset yang digunakan dalam tahap ini diperoleh melalui proses pengumpulan dan pemrosesan yang telah dijelaskan pada sub-bab sebelumnya, mulai dari KD-1 (Deteksi Objek), KD-2 hingga KD-7(klasifikasi jenis atribut), dan KD-8 (Klasifikasi Warna).

Metadata dataset sudah dirangkum dan dapat dilihat pada Tabel 4. 10

Tabel 4. 10 Metadata dataset

Nama Dataset	Jumlah Sampel	Format Data	Ukuran Gambar	Jumlah Kelas	Jenis Data	Target Label	/ Distribusi Kelas
Dataset Atribut Manusia	2160	Gambar (Image)	512 × 1024 px	6 atribut (<i>headwear</i> , dll)	Gambar	Kategori atribut	Tidak seimbang
Dataset Sub-class Headwear	460	Gambar (Image)	128 × 128 px	2 (<i>cap</i> , <i>hat</i>)	Gambar	Jenis <i>headwear</i>	Seimbang
Dataset Sub-class Eyewear	500	Gambar (Image)	128 × 128 px	2 (<i>eyeglasses</i> , <i>sunglasses</i>)	Gambar	Jenis <i>eyewear</i>	Seimbang
Dataset Sub-class Upperwear	1250	Gambar (Image)	224 × 224 px	5 (<i>t-shirt</i> , <i>shirt</i> , dll)	Gambar	Jenis <i>upperwear</i>	Seimbang
Dataset Sub-class Bottomwear	750	Gambar (Image)	224 × 224 px	3 (<i>pants</i> , <i>shorts</i> , <i>skirts</i>)	Gambar	Jenis <i>bottomwear</i>	Seimbang
Dataset Sub-class Bag	750	Gambar (Image)	224 × 224 px	3 (<i>handbag</i> , <i>backpack</i> , <i>clutch</i>)	Gambar	Jenis tas	Seimbang
Dataset Sub-class Footwear	750	Gambar (Image)	128 × 128 px	3 (<i>sandals</i> , <i>shoes</i> , <i>flip-flops</i>)	Gambar	Jenis alas kaki	Seimbang
Dataset Warna	5052	Tabular (CSV)	-	Banyak (kategori warna)	Tabular	Kategori warna	Tidak seimbang



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Pada tabel 4.10 setiap dataset dikumpulkan dan disesuaikan dengan kebutuhan masing-masing model, baik dari segi dimensi gambar, format *input*, maupun distribusi kelas. Untuk memastikan performa model optimal, seluruh dataset telah melalui proses standarisasi ukuran, *padding*, dan penyesuaian rasio aspek sesuai dengan rancangan awal.

4.3.1.1.1 Dataset Deteksi Objek

Dataset deteksi objek digunakan dalam pengembangan model yang bertugas mengenali keberadaan atribut manusia dalam citra, seperti *headwear*, *eyewear*, *upperwear*, dan atribut lainnya. Dataset ini disusun dari gambar-gambar yang menampilkan objek manusia dalam beragam tampilan dan kondisi visual.

Tahapan pengumpulan, anotasi, dan augmentasi dataset telah dirancang sebelumnya pada Sub-Bab 4.2.1. Pada tahap implementasi ini, proses tersebut direalisasikan untuk menghasilkan dataset yang siap digunakan dalam pelatihan model. Proses pengumpulan data dilakukan dengan melakukan kompilasi pada beberapa gambar dari dua sumber utama, yaitu *DeepFashion* (Z. Liu et al., 2016) *InFashion* (Hacheme & Sayouti, 2021), Hasilnya, terkumpul sebanyak 2.160 gambar mentah yang kemudian diproses lebih lanjut.

Seluruh citra dianotasi secara semi-otomatis menggunakan bounding box untuk menandai letak atribut manusia. Proses anotasi ini krusial karena kualitas hasil anotasi akan sangat memengaruhi akurasi model deteksi.

Hasil distribusi dataset mentah telah dirangkum dan dapat dilihat pada Tabel 4.10

Tabel 4. 11 Distribusi subset platiham dataset deteksi objek

Subset	Jumlah Gambar	Persentase data
Train	1.705	80%
Validation	351	15%
Test	104	5%



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Distribusi anotasi objek dalam dataset juga dicatat untuk mengetahui proporsi masing-masing kategori atribut. Rinciannya ditampilkan dalam Tabel 4.11:

Hasil distribusi anotasi dataset telah dirangkum dan dapat di lihat pada Tabel 4.11.

Tabel 4. 12 Distribusi anotasi bounding box kategori

Kategori Atribut	Jumlah Anotasi
<i>Footwear</i>	4.098
<i>Upperwear</i>	2.157
<i>Bottomwear</i>	1.629
<i>Eyewear</i>	363
<i>Headwear</i>	294
<i>Bag</i>	272

Untuk meningkatkan kemampuan generalisasi model terhadap variasi pencahayaan dan tampilan, dilakukan proses augmentasi pada subset data pelatihan menggunakan teknik-teknik sebagai berikut:

- a. Horizontal Flip
- b. Brightness Adjustment ($\pm 15\%$)
- c. Exposure Adjustment ($\pm 6\%$)
- d. Noise (0.69%)

Setelah augmentasi, jumlah data pada subset pelatihan meningkat signifikan. Perbandingan jumlah gambar sebelum dan sesudah augmentasi ditampilkan pada Tabel 4.12:

Hasil distribusi dataset final telah dirangkum dan dapat di lihat pada Tabel 4.12

Tabel 4. 13 Distribusi dataset final deteksi objek

Subset	Sebelum augmentasi	Pasca augmentasi
Train	1.705	6820




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Validation	351	351
Test	104	104

Tabel 4.12 Memberi hasil distribusi dataset final yang sudah dilakuakn augmentasi, terlihat dari penambahan dataset *train* yang sebelumnya berjumlah 1705 menjadi 6820. Sedangkan tidak ada perubahan untuk dataset *validation* dan *test* karena kedua dataset tersebut tidak masuk dalam proses augmentasi.

Visualisasi hasil dari dataset mentah, hasil anotasi, hingga augmentasi ditampilkan pada Gambar 4.13.



Gambar 4. 13 visualisasi hasil dataset deteksi objek

Visualisasi Gambar 4. 13 secara keseluruhan menggambarkan alur transformasi data dari kondisi awal hingga menjadi *input* yang siap digunakan untuk pelatihan model deteksi objek. Keberadaan anotasi dan augmentasi sangat penting untuk meningkatkan akurasi dan daya generalisasi model dalam berbagai kondisi pencitraan.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumpulkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

4.3.1.1.2 Dataset Klasifikasi Atribut

Pengumpulan dan pemrosesan dataset untuk kebutuhan klasifikasi atribut jenis pakaian merupakan tahap penting dalam pengembangan model klasifikasi. Dataset yang dikembangkan mencakup enam kategori utama, yaitu: *headwear*, *eyewear*, *upperwear*, *bottomwear*, *footwear*, dan *bag*.

Seluruh data dikumpulkan dari kombinasi dataset *Fashion Product Images Dataset* (Aggarwal, 2019) dan web *scraping* dari situs e-commerce, kemudian melalui tahap pra-pemrosesan seperti *resizing*, *padding* untuk menjaga aspek rasio, serta konversi format sesuai dengan *input* arsitektur model.

2. Dataset Headwear

Kategori *headwear* mencakup kategori atau kelas seperti *cap*, dan *hat*. Gambar dirubah ukuran menjadi 128×128 piksel, dengan *padding* putih agar rasio tetap proporsional. Karena hanya ada dua kelas pada dataset *headwear* label dirubah menjadi tipe binary untuk *cap* (1), dan untuk *hat* (0).

Distribusi kelas *Headwear* telah dirangkum dan dapat dilihat pada Tabel 4.14.

Tabel 4. 14 Distribusi kelas dataset *headwear*

Kelas	Jumlah Gambar
<i>cap</i> (1)	230
<i>hat</i> (0)	230

Tabel 4.14 memberikan gambaran bahwa masing-masing kelas memiliki jumlah distribusi data seimbang, dengan jumlah data sebanyak 460. Tahap selanjutnya merupakan pembagian jumlah data ke-subset *train*, *validation*, dan *test* untuk proses pelatihan dataset.

Hasil Distribusi dataset untuk pelatihan model *headwear* telah dirangkum dan dapat dilihat pada Tabel 4.15.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Tabel 4. 15 Distribusi subset pelatihan model *headwear*

Subset	Jumlah Gambar	Persentase data
Train	368	80%
Validation	69	15%
Test	23	5%

Tabel 4.15 memberikan gambaran bahwa untuk distribusi subset dataset pelatihan telah dibagi menjadi tiga bagian yakni *train*, *validation*, dan *test*.

Visualisasi hasil dari dataset mentah, menjadi dataset yang telah dirubah ukuran menjadi 128x128 yang tetap mempertahankan rasio dengan menambahkan *padding* putih pada sisi yang lebih kecil pada Gambar 4.14.



Gambar 4. 14 Visualisasi hasil dataset *headwear*

Visualisasi Gambar 4. 14 secara keseluruhan menggambarkan alur transformasi data dari kondisi awal hingga menjadi *input* yang siap digunakan untuk pelatihan model klasifikasi *headwear*. Dapat dilihat bahwa dataset telah dirubah ukurannya menjadi 128x128 pixel dan tetap mempertahankan rasio gambar.

3. Dataset Eyewear



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Kategori *eyewear* mencakup kategori atau kelas seperti *eyeglasses*, dan *sunglasses*. Gambar diubah ukuran menjadi 128×128 piksel, dengan *padding* putih agar rasio tetap proporsional. Karena hanya ada dua kelas pada dataset *eyewear* label diubah menjadi tipe binary untuk *eyeglasses* (1), dan untuk *sunglasses* (0).

Distribusi kelas *eyewear* telah dirangkum dan dapat dilihat pada Tabel 4.16.

Tabel 4. 16 Distribusi kelas dataset *eyewear*

Kelas	Jumlah Gambar
<i>eyeglasses</i> (1)	250
<i>sunglasses</i> (0)	250

Tabel 4.16 memberikan gambaran bahwa masing-masing kelas memiliki jumlah distribusi data seimbang, dengan jumlah data sebanyak 500. Tahap selanjutnya merupakan pembagian jumlah data ke-subset *train*, *validation*, dan *test* untuk proses pelatihan dataset.

Hasil Distribusi dataset untuk pelatihan model *headwear* telah dirangkum dan dapat dilihat pada Tabel 4.17.

Tabel 4. 17 Distribusi subset pelatihan model *eyewear*


Subset	Jumlah Gambar	Persentase data
Train	400	80%
Validation	75	15%
Test	25	5%

Tabel 4.17 memberikan gambaran bahwa untuk distribusi subset dataset pelatihan telah dibagi menjadi tiga bagian yakni *train*, *validation*, dan *test*.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4. 15 Visualisasi hasil dataset *eyewear*

Visualisasi Gambar 4. 15 secara keseluruhan menggambarkan alur transformasi data dari kondisi awal hingga menjadi *input* yang siap digunakan untuk pelatihan model klasifikasi *eyewear*. Dapat dilihat bahwa dataset telah dirubah ukurannya menjadi 128x128 pixel dan tetap mempertahankan rasio gambar.

4. Dataset Upperwear

Kategori *upperwear* mencakup kategori atau kelas seperti *t-shirt*, *sweater*, *jacket*, *shirt*, *dress*. Gambar dirubah ukuran menjadi 224×224 piksel, dengan *padding* putih agar rasio tetap proporsional.

Distribusi kelas *upperwear* telah dirangkum dan dapat dilihat pada Tabel 4.18.

Tabel 4. 18 Distribusi kelas dataset *upperwear*

Kelas	Jumlah Gambar
<i>t-shirt</i>	250
<i>sweater</i>	250
<i>jacket</i>	250
<i>shirt</i>	250



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

dress	250
-------	-----

Tabel 4.18 memberikan gambaran bahwa masing-masing kelas memiliki jumlah distribusi data seimbang, dengan jumlah data sebanyak 1250. Tahap selanjutnya merupakan pembagian jumlah data ke-subset *train*, *validation*, dan *test* untuk proses pelatihan dataset.


Hasil Distribusi dataset untuk pelatihan model *headwear* telah dirangkum dan dapat dilihat pada Tabel 4.19.

Tabel 4. 19 Distribusi subset pelatihan model *upperwear*

Subset	Jumlah Gambar	Persentase data
Train	1000	80%
Validation	187	15%
Test	63	5%

Tabel 4.19 memberikan gambaran bahwa untuk distribusi subset dataset pelatihan telah dibagi menjadi tiga *bagian* yakni *train*, *validation*, dan *test*.

Visualisasi hasil dari dataset mentah, menjadi dataset yang telah dirubah ukuran menjadi 224x224 yang tetap mempertahankan rasio dengan menambahkan *padding* putih pada sisi yang lebih kecil pada Gambar 4.16.



Gambar 4. 16 Visualisasi hasil dataset *upperwear*



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Visualisasi Gambar 4. 16 secara keseluruhan menggambarkan alur transformasi data dari kondisi awal hingga menjadi *input* yang siap digunakan untuk pelatihan model klasifikasi *upperwear*. Dapat dilihat bahwa dataset telah dirubah ukurannya menjadi 128x128 pixel dan tetap mempertahankan rasio gambar.

5. Dataset Bottomwear

Kategori *bottomwear* mencakup kategori atau kelas seperti shorts, pants, dan skirt. Gambar dirubah ukuran menjadi 224×224 piksel, dengan *padding* putih agar rasio tetap proporsional.

Distribusi kelas *bottomwear* telah dirangkum dan dapat dilihat pada Tabel 4.20.

Tabel 4. 20 Distribusi kelas dataset *bottomwear*

Kelas	Jumlah Gambar
shorts	250
pants	250
skirts	250

Tabel 4.20 memberikan gambaran bahwa masing-masing kelas memiliki jumlah distribusi data seimbang, dan dengan jumlah data sebanyak 750. Tahap selanjutnya merupakan pembagian jumlah data ke-subset *train*, *validation*, dan *test* untuk proses pelatihan dataset.

Hasil Distribusi dataset untuk pelatihan model *headwear* telah dirangkum dan dapat dilihat pada Tabel 4.21.

Tabel 4. 21 Distribusi subset pelatihan model *bottomwear*

Subset	Jumlah Gambar	Persentase data
Train	600	80%
Validation	112	15%
Test	38	5%



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Tabel 4.21 memberikan gambaran bahwa untuk distribusi subset dataset pelatihan telah dibagi menjadi tiga bagian yakni *train*, *validation*, dan *test*.

Visualisasi hasil dari dataset mentah, menjadi dataset yang telah dirubah ukuran menjadi 224x224 yang tetap mempertahankan rasio dengan menambahkan *padding* putih pada sisi yang lebih kecil pada Gambar 4.17.



Gambar 4. 17 Visualisasi hasil dataset *bottomwear*

Visualisasi Gambar 4. 17 secara keseluruhan menggambarkan alur transformasi data dari kondisi awal hingga menjadi *input* yang siap digunakan untuk pelatihan model klasifikasi *bottomwear*. Dapat dilihat bahwa dataset telah dirubah ukurannya menjadi 224x224 pixel dan tetap mempertahankan rasio gambar.

6. Dataset Footwear

Kategori *upperwear* mencakup kategori atau kelas seperti *flop_flops*, *sandals*, dan *shoes*. Gambar dirubah ukuran menjadi 128x128 piksel, dengan *padding* putih agar rasio tetap proporsional.

Distribusi kelas *footwear* telah dirangkum dan dapat dilihat pada Tabel 4.22.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Tabel 4. 22 Distribusi kelas dataset *footwear*

Kelas	Jumlah Gambar
Flip_flops	250
<i>sandals</i>	250
<i>shoes</i>	250

Tabel 4.22 memberikan gambaran bahwa masing-masing kelas memiliki jumlah distribusi data seimbang, dengan jumlah data sebanyak 750. Tahap selanjutnya merupakan *pembagian* jumlah data ke-subset *train*, *validation*, dan *test* untuk proses pelatihan dataset.

Hasil Distribusi dataset untuk pelatihan model *headwear* telah dirangkum dan dapat dilihat pada Tabel 4.23.

Tabel 4. 23 Distribusi subset pelatihan model *footwear*

Subset	Jumlah Gambar	Persentase data
Train	600	80%
Validation	112	15%
Test	38	5%


Tabel 4.23 memberikan gambaran bahwa untuk distribusi subset dataset pelatihan telah dibagi menjadi tiga *bagian* yakni *train*, *validation*, dan *test*.

Visualisasi hasil dari dataset mentah, menjadi dataset yang telah dirubah ukuran menjadi 128x128 yang tetap mempertahankan rasio dengan menambahkan *padding* putih pada sisi yang lebih kecil pada Gambar 4.18.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4. 18 Visualisasi hasil dataset *footwear*

Visualisasi Gambar 4. 18 secara keseluruhan menggambarkan alur transformasi data dari kondisi awal hingga menjadi *input* yang siap digunakan untuk pelatihan model klasifikasi *footwear*. Dapat dilihat bahwa dataset telah dirubah ukurannya menjadi 128x128 pixel dan tetap mempertahankan rasio gambar.

7. *Dataset Bag*

Kategori *bag* mencakup kategori atau kelas seperti *handbag*, *backpack*, dan *clutchbag*. Gambar dirubah ukuran menjadi 224x224 piksel, dengan *padding* putih agar rasio tetap proporsional.

Distribusi kelas *bag* telah dirangkum dan dapat dilihat pada Tabel 4.24.

Tabel 4. 24 Distribusi kelas dataset *bag*

Kelas	Jumlah Gambar
<i>handabag</i>	250
<i>backpack</i>	250
<i>clutchbag</i>	250



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Tabel 4.24 memberikan gambaran bahwa masing-masing kelas memiliki jumlah distribusi data seimbang, dan dengan jumlah data sebanyak 750. Tahap selanjutnya merupakan pembagian jumlah data ke-subset *train*, *validation*, dan *test* untuk proses pelatihan dataset.


Hasil Distribusi dataset untuk pelatihan model *headwear* telah dirangkum dan dapat dilihat pada Tabel 4.25.

Tabel 4. 25 Distribusi subset pelatihan model *bag*

Subset	Jumlah Gambar	Persentase data
Train	600	80%
Validation	112	15%
Test	38	5%

Tabel 4.25 memberikan gambaran bahwa untuk distribusi subset dataset pelatihan telah dibagi menjadi tiga *bagian* yakni *train*, *validation*, dan *test*.

Visualisasi hasil dari dataset mentah, menjadi dataset yang telah dirubah ukuran menjadi 224x224 yang tetap mempertahankan rasio dengan menambahkan *padding* putih pada sisi yang lebih kecil pada Gambar 4.19.



Gambar 4. 19 Visualisasi hasil dataset *bag*



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Visualisasi Gambar 4. 15 secara keseluruhan menggambarkan alur transformasi data dari kondisi awal hingga menjadi *input* yang siap digunakan untuk pelatihan model klasifikasi *bag*. Dapat dilihat bahwa dataset telah dirubah ukurannya menjadi 224x224 pixel dan tetap mempertahankan rasio gambar.

4.3.1.1.3 Dataset Klasifikasi Warna

Dataset klasifikasi warna terdiri atas tiga fitur numerik utama, yaitu R (*Red*), G (*Green*), dan B (*Blue*), yang merepresentasikan intensitas warna pada tiap sampel. Ketiga fitur ini digunakan sebagai parameter independen, sedangkan label warna digunakan sebagai parameter dependen yang akan diprediksi oleh model.

Label warna yang tersedia dalam dataset mencakup 11 kelas, antara lain: *Green*, *Blue*, *Pink*, *Purple*, *Brown*, *Yellow*, *Red*, *Orange*, *Grey*, *Black*, dan *White*. Distribusi jumlah data per kelas dapat dilihat pada Tabel 4.26.

Tabel 4. 26 Distribusi kelas dataset warna

Kelas	Jumlah Data
<i>Green</i>	1.457
<i>Blue</i>	1.107
<i>Pink</i>	579
<i>Purple</i>	553
<i>Brown</i>	376
<i>Yellow</i>	285
<i>Red</i>	236
<i>Orange</i>	205
<i>Grey</i>	174
<i>Black</i>	51
<i>White</i>	29



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Tabel 4.26 menunjukkan bahwa dataset memiliki distribusi kelas yang tidak seimbang, dengan kelas *Greenn* sebagai kelas terbanyak dan *White* sebagai kelas paling sedikit. Total data keseluruhan berjumlah 5.092 sampel.

Selanjutnya, dataset dibagi menjadi tiga subset, yaitu *train*, *validation*, dan *test*, dengan proporsi masing-masing 80%, 15%, dan 5% dari total data. Distribusi pembagian ini dirangkum pada Tabel 4.27.

Tabel 4. 27 Distribusi subset pelatihan dataset warna

Subset	Jumlah Data	Persentase Data
Train	4.073	80%
Validation	764	15%
Test	255	5%

Tabel 4.27 memberikan gambaran bahwa pembagian dataset dilakukan secara proporsional terhadap keseluruhan data, untuk memastikan bahwa model mendapatkan data pelatihan yang mencukupi, sekaligus dapat diuji dan divalidasi terhadap data yang belum pernah dilihat sebelumnya. Pembagian ini penting dalam proses pelatihan model klasifikasi warna berbasis data numerik RGB.

4.3.1.2 Implementasi Model *Deep Learning*

Pada tahap ini, dilakukan proses implementasi model deep learning untuk menyelesaikan permasalahan klasifikasi berdasarkan data yang telah dikumpulkan dan diproses sebelumnya. Model dikembangkan dengan memanfaatkan arsitektur yang sesuai dengan karakteristik data dan tujuan klasifikasi. Proses implementasi mencakup pemilihan arsitektur model, konfigurasi hyperparameter, proses pelatihan, serta evaluasi performa model terhadap data uji. Seluruh tahapan dirancang untuk menghasilkan model yang mampu melakukan prediksi secara akurat dan efisien terhadap data baru.

4.3.1.2.1 Implementasi Model *Deep Learning* Deteksi Objek

Tahap ini merupakan realisasi dari perancangan sistem deteksi objek yang difokuskan pada pengenalan atribut manusia dalam citra, seperti *headwear*,



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

eyewear, upperwear, bottomwear, bag, dan footwear. Untuk mencapai performa yang optimal dalam mendeteksi berbagai atribut tersebut, digunakan arsitektur YOLOv8 (*You Only Look Once* version 8), yang dikenal luas karena kemampuannya dalam mendeteksi objek secara cepat dan akurat dalam berbagai konteks visual.

Model ini menggunakan bobot awal dari YOLOv8l (YOLOv8-large) yang telah melalui proses *pre-training* pada dataset COCO (Common Objects in Context). Penggunaan bobot awal ini dimaksudkan untuk mempercepat konvergensi pelatihan dan meningkatkan generalisasi model terhadap data baru (Jocher et al., 2023). Implementasi dilakukan dengan memuat dataset yang telah melalui proses anotasi dan dibagi menjadi tiga subset: *train*, *validation*, dan *test*. Dataset pelatihan juga dilengkapi dengan teknik augmentasi untuk meningkatkan keberagaman data dan ketahanan model terhadap variasi pencitraan.

Proses pelatihan model mencakup beberapa tahapan penting:

- a. Pemuatan data teranotasi
- b. Fine-tuning model YOLOv8 dengan konfigurasi hyperparameter tertentu
- c. Evaluasi performa model menggunakan metrik seperti *Precision*, *Recall*, dan *mean Average Precision* (mAP)

Konfigurasi hyperparameter utama yang digunakan ditunjukkan pada Tabel 4.28 berikut.

Tabel 4. 28 Hyperparameter model deep learning deteksi objek

Hyperparameter	Nilai
Epoch	100
Batch Size	32
Learning Rate	0.0001
Momentum	0.937
Weight Decay	0.0005



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Pemilihan hyperparameter dalam Tabel 4. 28 untuk pelatihan model deteksi objek menggunakan YOLOv8 dilakukan dengan mempertimbangkan stabilitas pelatihan, kapasitas komputasi, serta praktik terbaik yang telah diterapkan dalam studi sebelumnya. Jumlah epoch ditetapkan sebanyak 100, dengan pertimbangan bahwa jumlah ini memberikan waktu pelatihan yang memadai agar model dapat mempelajari fitur penting dari data tanpa mengalami overfitting secara signifikan. Nilai ini juga mengacu pada rekomendasi dari dokumentasi resmi Ultralytics dan berbagai studi pelatihan model YOLO yang menyarankan penggunaan 50–300 epoch tergantung pada kompleksitas data.

Ukuran *batch* ditentukan sebesar 32, yang merupakan kompromi antara efisiensi pemrosesan data dan kestabilan gradien saat pelatihan. Nilai ini juga sesuai dengan kapasitas umum GPU kelas menengah, serta sering digunakan dalam pelatihan model deteksi berbasis YOLO karena dianggap cukup untuk memberikan generalisasi yang baik.


Learning rate ditetapkan pada nilai 0.0001, yaitu nilai yang relatif kecil dan cocok digunakan pada proses fine-tuning dari model *pre-trained* seperti YOLOv8. Nilai ini bertujuan untuk menghindari perubahan bobot yang terlalu drastis, menjaga konvergensi pelatihan agar berjalan stabil dan tidak melompat ke minimum lokal yang buruk. Momentum disetel pada 0.937 dan weight decay pada 0.0005, yang merupakan konfigurasi default dari YOLOv8 berdasarkan eksperimen internal Ultralytics. Nilai momentum yang tinggi membantu mempertahankan arah gradien yang stabil dari iterasi sebelumnya, sedangkan weight decay berfungsi sebagai regularisasi untuk mencegah model belajar secara berlebihan terhadap data pelatihan (overfitting).

Hasil *training* model deep learning deteksi objek dapat dilihat pada Gambar 4. 20.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4. 20 Hasil *training* model deep learning deteksi objek

Berdasarkan grafik hasil pelatihan model deteksi objek menggunakan YOLOv8 , proses pelatihan menunjukkan konvergensi yang baik. Kurva *train* box loss, classification loss, dan DFL loss pada data pelatihan menunjukkan penurunan konsisten dari awal hingga akhir epoch, menandakan bahwa model secara bertahap belajar merepresentasikan pola dari data. Nilai *train* box loss turun dari sekitar 0.8 menjadi kurang dari 0.2, classification loss dari sekitar 1.2 menjadi di bawah 0.4, dan DFL loss dari lebih dari 1.1 menjadi di bawah 0.5.

Pada data validasi, nilai loss juga cenderung menurun, meskipun terdapat sedikit fluktuasi di awal pelatihan. Validation box loss dan classification loss menurun hingga mencapai stabilisasi mendekati epoch ke-50. Namun, val DFL loss mulai menunjukkan kecenderungan naik setelah pertengahan epoch, mengindikasikan potensi gejala overfitting ringan. Meskipun begitu, metrik performa seperti *precision*, *recall*, mAP@0.5, dan mAP@0.5:0.95 pada data validasi tetap meningkat dan relatif stabil hingga akhir epoch. Nilai mAP@0.5 mencapai lebih dari 0.79, sementara mAP@0.5:0.95 mendekati 0.68.

4.3.1.2.2 Implementasi Model *Deep Learning* Klasifikasi Atribut *Headwear*

Tahap ini merupakan implementasi dari model klasifikasi deep learning untuk mengklasifikasi atribut *headwear* pada objek manusia dalam citra. Implementasi ini bertujuan untuk mengklasifikasikan apakah seseorang pada citra memakai




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

headwear atau tidak. Model yang digunakan dibangun dengan memanfaatkan arsitektur MobileNetV2 sebagai feature extractor, yang kemudian diikuti dengan beberapa lapisan *fully connected* dan dropout untuk klasifikasi biner.

Arsitektur Model Klasifikasi *Headwear* sudah dirangkum dan dapat dilihat pada Gambar 4. 21.



Gambar 4. 21 Arsitektur model klasifikasi *headwear*

Arsitektur pada Gambar 4. 21. ini memanfaatkan bobot awal dari MobileNetV2 yang telah di *pre-trained* (*pre-trained weights*) pada ImageNet. Lapisan average pooling digunakan untuk menyaring fitur, diikuti oleh proses flattening, serta tiga lapisan dense dengan ukuran 256, 128, dan 64 neuron, masing-masing menggunakan aktivasi ReLU. Beberapa lapisan dropout (dengan rasio 0.5 dan 0.3) digunakan untuk mencegah overfitting. *Output layer* menggunakan satu neuron dengan aktivasi sigmoid untuk klasifikasi biner (memakai/tidak memakai *headwear*).

Hyperparameter model klasifikasi *Headwear* sudah dirangkum dan dapat dilihat pada Tabel 4. 29.

Tabel 4. 29 Hyperparameter klasifikasi *headwear*

Hyperparameter	Nilai
Optimizer	Adam
Learning Rate	0.0001




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Loss Function	Binary Crossentropy
Epochs	20
Metrics	Accuracy
Patience (Early Stop)	5
Restore Best Weights	Ya

Pada Tabel 4. 29, pemilihan *optimizer* Adam dilakukan karena kemampuannya menyesuaikan learning rate selama pelatihan, yang terbukti efektif dalam berbagai tugas klasifikasi gambar (Kingma & Ba, 2014). Learning rate sebesar 0.0001 digunakan agar pembelajaran berlangsung secara stabil dan menghindari osilasi pada fungsi loss, sesuai anjuran dari studi-studi terdahulu dalam fine-tuning MobileNetV2 (Sandler et al., 2018). Loss function binary crossentropy dipilih karena tugas klasifikasi ini bersifat biner. Mekanisme early stopping dengan patience 5 digunakan untuk menghentikan pelatihan lebih awal saat tidak terjadi peningkatan akurasi validasi guna menghindari overfitting, serta pengembalian bobot terbaik (restore best weights) memastikan hasil optimal.



Gambar 4. 22 History *training* akurasi model klasifikasi *headwear*


Dari grafik Gambar 4. 22, terlihat bahwa akurasi validasi terus meningkat dan stabil di atas 90% setelah epoch ke-10, yang mengindikasikan bahwa model berhasil



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

belajar pola klasifikasi dengan baik. Perbedaan antara akurasi pelatihan dan validasi masih dalam batas wajar, meskipun terdapat indikasi bahwa model berisiko mengalami overfitting minor.



Gambar 4. 23 History training loss model klasifikasi *headwear*

Grafik pada Gambar 4. 23, menunjukkan bahwa loss pelatihan dan validasi secara konsisten menurun, menandakan proses pembelajaran yang stabil. Penurunan nilai loss validasi yang terus terjadi tanpa lonjakan signifikan juga mendukung bahwa model tidak mengalami overfitting yang serius dan mampu mempelajari pola data secara efektif.

4.3.1.2.3 Implementasi Model *Deep Learning* Klasifikasi Atribut *Eyewear*


Tahap ini merupakan implementasi dari model klasifikasi deep learning untuk mengklasifikasikan atribut *eyewear* pada objek manusia dalam citra. *Eyewear* dalam konteks ini mencakup *eyeglasses* dan *sunglasses*. Tujuan implementasi ini adalah untuk mengidentifikasi apakah seseorang dalam citra mengenakan *eyewear* atau tidak. Model yang digunakan memanfaatkan arsitektur MobileNetV2 sebagai feature extractor, yang kemudian dilanjutkan dengan beberapa lapisan *fully connected* dan dropout untuk menangani proses klasifikasi biner.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Arsitektur Model Klasifikasi *eyewear* sudah dirangkum dan dapat dilihat pada Gambar 4. 24.



Gambar 4. 24 Arsitektur model klasifikasi *headwear*

Arsitektur pada Gambar 4.24 memanfaatkan bobot awal dari MobileNetV2 yang telah dilatih sebelumnya (*pre-trained*) pada dataset ImageNet. Fitur yang dihasilkan dari backbone ini diproses melalui lapisan average pooling, kemudian flatten layer untuk menyusun ulang dimensi *output*. Selanjutnya terdapat tiga dense layer masing-masing berukuran 256, 128, dan 64 neuron dengan fungsi aktivasi ReLU. Untuk mencegah overfitting, digunakan lapisan dropout dengan nilai 0.5 setelah dua dense layer pertama dan 0.3 sebelum *output* layer. Lapisan *output* menggunakan 1 neuron dengan aktivasi sigmoid karena tugas klasifikasi ini bersifat biner.

Hyperparameter model klasifikasi *eyewear* sudah dirangkum dan dapat dilihat pada Tabel 4. 30.

Tabel 4. 30 Hyperparameter klasifikasi *eyewear*

Hyperparameter	Nilai
Optimizer	Adam
Learning Rate	0.0001




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Loss Function	Binary Crossentropy
Epochs	20
Metrics	Accuracy
Patience (Early Stop)	5
Restore Best Weights	Ya

Pada Tabel 4. 30, pemilihan *optimizer* Adam didasarkan pada kemampuannya dalam menyesuaikan laju pembelajaran secara adaptif, sebagaimana dijelaskan oleh (Kingma & Ba, 2014). Learning rate sebesar 0.0001 dipilih untuk menjaga stabilitas proses pembelajaran serta telah terbukti efektif dalam berbagai penelitian fine-tuning arsitektur MobileNetV2 seperti pada (Sandler et al., 2018). Binary crossentropy digunakan sebagai fungsi loss karena tugas klasifikasi ini bersifat biner. Strategi early stopping dengan patience 5 dan pengaktifan restore best weights diterapkan untuk menghentikan pelatihan lebih awal saat performa validasi tidak meningkat, sehingga hasil model tetap optimal.

Hasil dari akurasi pelatihan model klasifikasi *eyewear* dapat dilihat pada Gambar 4. 25.



Gambar 4. 25 History *training* accuracy model klasifikasi *eyewear*

Pada Gambar 4. 25 akurasi pelatihan dan validasi, terlihat adanya peningkatan yang konsisten dari epoch ke epoch. Akurasi validasi mencapai lebih dari 98% hanya




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

dalam beberapa epoch awal dan cenderung stabil mendekati 97-98% hingga akhir pelatihan, menandakan bahwa model mampu melakukan generalisasi dengan baik terhadap data validasi. Akurasi pelatihan juga meningkat secara bertahap hingga mencapai nilai mendekati 95%, menunjukkan bahwa model belajar secara efektif terhadap pola dalam data.

Hasil dari loss pelatihan model klasifikasi *eyewear* dapat dilihat pada Gambar 4. 26.



Gambar 4. 26 History *training loss* model klasifikasi *eyewear*

Grafik loss menunjukkan penurunan yang stabil baik pada data pelatihan maupun validasi. Training loss mengalami penurunan tajam pada epoch awal, kemudian melambat setelah mencapai titik stabil. Validation loss juga menunjukkan penurunan yang serupa dan tetap rendah, menandakan tidak adanya gejala overfitting yang signifikan. Hal ini memperkuat kesimpulan bahwa arsitektur model dan pemilihan hyperparameter yang digunakan telah sesuai dengan kompleksitas data.

4.3.1.2.4 Implementasi Model *Deep Learning* Klasifikasi Atribut *Upperwear*

Implementasi klasifikasi atribut *upperwear* merupakan salah satu komponen penting karena mencakup beragam kelas seperti *t-shirt*, *shirt*, *sweater*, *jacket*, dan *dress*. Oleh karena itu, model yang digunakan perlu mampu membedakan berbagai pola dan tekstur dari pakaian *bagian atas*. Berdasarkan rancangan sebelumnya,




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

model MobileNetV2 dilatih pada data *upperwear* yang telah melalui tahap augmentasi serta dibagi ke dalam subset *train*, *validation*, dan *test*, untuk menjamin evaluasi yang adil dan akurat.

Arsitektur Model Klasifikasi *Upperwear* sudah dirangkum dan dapat dilihat pada Gambar 4. 27.



Gambar 4. 27 Arsitektur model klasifikasi *upperwear*

Pada Gambar 4. 27, arsitektur model dimulai dari *Input Layer* yang menerima citra masukan dan diteruskan ke MobileNetV2 untuk mengekstraksi fitur penting dari citra. Selanjutnya, lapisan *Average Pooling 2D* digunakan untuk meReduksi dimensi spasial fitur. Hasil pooling kemudian diproses oleh *Flatten Layer* agar dapat digunakan pada lapisan *fully connected*. Jaringan *fully connected* terdiri dari tiga lapisan dense berukuran 256, 128, dan 64 neuron, masing-masing menggunakan fungsi aktivasi ReLU. Untuk mencegah overfitting, model menyisipkan beberapa lapisan *Dropout* dengan rasio 0.5 dan 0.3. Akhirnya, *Output Layer* menggunakan 5 neuron dengan fungsi aktivasi *Softmax* untuk mengklasifikasikan ke dalam lima kelas *upperwear* secara multi-kelas.

Hyperparameter model klasifikasi *upperwear* sudah dirangkum dan dapat dilihat pada Tabel 4. 31.

Tabel 4. 31 Hyperparameter klasifikasi *upperwear*




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Hyperparameter	Nilai
Optimizer	Adam
Learning Rate	0.0001
Loss Function	categorical_crossentropy
Epochs	50
Metrics	Accuracy
Patience (Early Stop)	5
Restore Best Weights	Ya

Pemilihan *optimizer* Adam didasarkan pada kemampuannya menyesuaikan learning rate secara adaptif, yang terbukti efektif untuk berbagai tugas klasifikasi gambar. Learning rate yang kecil sebesar 0.0001 digunakan agar proses pelatihan berjalan stabil. Karena model melakukan klasifikasi multi-kelas terhadap lima label, digunakan fungsi loss categorical crossentropy. Early stopping dengan patience sebanyak 5 digunakan untuk menghentikan pelatihan jika tidak terjadi peningkatan akurasi validasi, serta pengembalian bobot terbaik digunakan untuk menjaga hasil optimal.

Hasil dari akurasi pelatihan model klasifikasi *upperwear* dapat dilihat pada Gambar 4. 28.



Gambar 4. 28 History training accuracy model klasifikasi *upperwear*




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Grafik akurasi pada Gambar 4. 28, terlihat bahwa akurasi pelatihan meningkat secara konsisten hingga mendekati 90% pada epoch ke-35. Akurasi validasi pun stabil dan berada pada kisaran 85–90% selama pelatihan, menunjukkan bahwa model memiliki generalisasi yang baik terhadap data yang tidak terlihat selama pelatihan.

Hasil dari loss pelatihan model klasifikasi *upperwear* dapat dilihat pada Gambar 4. 29.



Gambar 4. 29 History *training loss* model klasifikasi *upperwear*

Grafik loss pada Gambar 4. 29, menunjukkan penurunan yang signifikan dari awal pelatihan hingga epoch akhir. Training loss dan *validation loss* keduanya menurun dengan pola yang stabil, tanpa indikasi overfitting yang kuat. Hal ini menunjukkan bahwa model mampu belajar dengan baik dan menjaga keseimbangan antara akurasi pelatihan dan validasi.

4.3.1.2.5 Implementasi Model *Deep Learning* Klasifikasi Atribut *Bottomwear*


Tahap ini merupakan implementasi dari model deep learning untuk klasifikasi atribut *bottomwear* pada objek manusia dalam citra. Atribut *bottomwear* yang diklasifikasikan terdiri dari tiga jenis pakaian, yaitu pants, shorts, dan skirts. Model ini dirancang untuk secara otomatis mengenali jenis pakaian bagian bawah yang dikenakan oleh seseorang dalam gambar, sebagai bagian dari sistem klasifikasi atribut manusia secara keseluruhan.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Dalam pengembangannya, model ini memanfaatkan arsitektur MobileNetV2 sebagai feature extractor yang telah dilatih sebelumnya (*pre-trained*) menggunakan dataset ImageNet. Arsitektur ini dipilih karena efisiensinya dalam hal jumlah parameter dan kemampuannya menghasilkan representasi fitur yang berkualitas tinggi. Setelah fitur diekstraksi oleh MobileNetV2, jaringan dilanjutkan dengan beberapa lapisan *fully connected* yang terdiri dari lapisan dense dan dropout, yang berfungsi sebagai klasifikator akhir untuk membedakan tiga kategori *bottomwear*. Arsitektur Model Klasifikasi *Headwear* sudah dirangkum dan dapat dilihat pada Gambar 4. 30.



Gambar 4. 30 Arsitektur model klasifikasi *bottomwear*

Pada Gambar 4. 30, arsitektur model dimulai dari *Input Layer* yang menerima citra masukan, kemudian dilanjutkan ke *bagian utama* berupa MobileNetV2 yang digunakan sebagai backbone untuk mengekstraksi fitur dari gambar. Fitur yang dihasilkan oleh MobileNetV2 selanjutnya direduksi dimensinya menggunakan Average Pooling 2D. Hasil dari proses pooling kemudian diproses oleh Flatten Layer yang bertugas mengubah data tensor menjadi bentuk vektor satu dimensi agar dapat digunakan pada lapisan *fully connected*.

Setelah proses flattening, jaringan berlanjut pada dua lapisan Dense Layer dengan jumlah neuron masing-masing sebanyak 256 dan 128 unit, keduanya menggunakan fungsi aktivasi ReLU. Untuk mencegah overfitting, disisipkan dua lapisan Dropout, masing-masing dengan rasio 0.5 dan 0.3 setelah Dense Layer pertama dan kedua. Terakhir, model memiliki *Output Layer* yang terdiri dari 3 neuron dan



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

menggunakan fungsi aktivasi Softmax, yang bertugas memberikan probabilitas untuk masing-masing kelas *bottomwear*.

Hyperparameter model klasifikasi *bottomwear* sudah dirangkum dan dapat dilihat pada Tabel 4. 32.

Tabel 4. 32 Hyperparameter model klasifikasi *bottomwear*

Hyperparameter	Nilai
Optimizer	Adam
Learning Rate	0.0001
Loss Function	categorical_crossentropy
Epochs	30
Metrics	Accuracy
Patience (Early Stop)	10
Restore Best Weights	Ya

Pada Tabel 4. 32, pemilihan *optimizer* Adam didasarkan pada kemampuannya melakukan optimisasi dengan adaptasi learning rate yang dinamis, sehingga mempercepat proses konvergensi. Nilai learning rate yang digunakan adalah 0.0001 agar pelatihan berjalan stabil dan menghindari lonjakan nilai loss yang tajam. Karena klasifikasi dilakukan terhadap tiga kategori, digunakan fungsi loss categorical crossentropy yang sesuai untuk multi-class classification. Strategi early stopping dengan patience sebesar 10 diterapkan untuk menghentikan proses pelatihan ketika tidak ada peningkatan akurasi validasi selama 10 epoch berturut-turut, serta opsi restore best weights diaktifkan untuk memastikan model mengembalikan bobot terbaik yang dicapai selama pelatihan.

Hasil dari akurasi pelatihan model klasifikasi *bottomwear* dapat dilihat pada Gambar 4. 31.



Hak Cipta :


1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4. 31 History *training* accuracy model klasifikasi *bottomwear*

Evaluasi performa model dilakukan melalui visualisasi akurasi pelatihan dan validasi sepanjang epoch. Grafik 4. 31, menunjukkan bahwa akurasi pelatihan meningkat secara signifikan dari epoch awal hingga akhir, dengan nilai akhir mendekati 97%. Di sisi lain, akurasi validasi stabil dan sangat tinggi, berada di kisaran 97–99% sepanjang proses pelatihan. Hal ini menunjukkan bahwa model memiliki kemampuan generalisasi yang sangat baik terhadap data yang tidak terlihat sebelumnya.

Hasil dari loss pelatihan model klasifikasi *bottomwear* dapat dilihat pada Gambar 4. 32.



Gambar 4. 32 History *training* loss model klasifikasi *bottomwear*



Hak Cipta :


1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Grafik pada Gambar 4. 32, loss memperkuat indikasi bahwa model berhasil belajar secara efektif tanpa mengalami overfitting. Loss pelatihan menunjukkan penurunan tajam di awal pelatihan dan terus menurun secara konsisten hingga mencapai nilai yang sangat rendah. Sementara itu, loss validasi juga menunjukkan tren penurunan dan stabil mendekati nilai minimum sejak pertengahan pelatihan. Tidak terdapat jarak signifikan antara loss pelatihan dan validasi, yang menandakan bahwa model memiliki stabilitas dalam pembelajaran serta tidak overfit terhadap data pelatihan.

4.3.1.2.6 Implementasi Model *Deep Learning* Klasifikasi Atribut *Footwear*

Tahap ini merupakan implementasi dari model klasifikasi berbasis deep learning untuk mengklasifikasikan atribut *footwear* pada objek manusia dalam citra. Tujuan dari implementasi ini adalah untuk mengidentifikasi jenis alas kaki yang dikenakan oleh individu pada citra, yang terbagi ke dalam tiga kelas berbeda. Model klasifikasi ini dikembangkan dengan memanfaatkan arsitektur MobileNetV2 sebagai feature extractor, kemudian dilanjutkan dengan beberapa lapisan *fully connected* dan dropout untuk menyempurnakan proses klasifikasi multiklas.

Arsitektur Model Klasifikasi *Headwear* sudah dirangkum dan dapat dilihat pada Gambar 4. 34.



Gambar 4. 33 Arsitektur model klasifikasi *footwear*

Arsitektur pada Gambar 4.33 memanfaatkan bobot awal dari MobileNetV2 yang telah melalui proses *pre-training* pada dataset ImageNet. Model ini hanya menggunakan *bagian* konvolusional dari MobileNetV2, tanpa melibatkan lapisan klasifikasinya. *Output* dari MobileNetV2 kemudian diproses melalui lapisan



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Average Pooling 2D untuk meReduksi dimensi fitur yang dihasilkan, dilanjutkan dengan proses flattening agar dapat digunakan dalam lapisan dense.

Setelah proses flattening, model menerapkan dua buah lapisan dense, masing-masing dengan 256 dan 128 neuron, yang keduanya menggunakan fungsi aktivasi ReLU. Di antara kedua lapisan ini disisipkan mekanisme regularisasi berupa dropout dengan rasio 0.5 guna mengurangi risiko overfitting. *Output* dari lapisan dense terakhir kemudian diarahkan ke *output* layer yang terdiri dari 3 neuron dengan fungsi aktivasi softmax untuk mengklasifikasikan citra ke dalam salah satu dari tiga kategori *footwear*.

Hyperparameter model klasifikasi *footwear* sudah dirangkum dan dapat dilihat pada Tabel 4. 33.

Tabel 4. 33 Hyperparameter model klasifikasi *footwear*

Hyperparameter	Nilai
Optimizer	Adam
Learning Rate	0.0001
Loss Function	categorical_crossentropy
Epochs	30
Metrics	Accuracy
Patience (Early Stop)	10
Restore Best Weights	Ya

Pada Tabel 4. 33, dipilihnya *optimizer* Adam didasarkan pada kemampuannya dalam menyesuaikan learning rate secara adaptif selama proses pelatihan, yang terbukti efisien dalam berbagai penelitian klasifikasi citra (Kingma & Ba, 2014). Learning rate sebesar 0.0001 digunakan untuk memastikan pembelajaran berlangsung secara stabil tanpa fluktuasi ekstrem pada nilai loss. Fungsi loss categorical crossentropy digunakan karena tugas klasifikasi ini bersifat multiklas. Untuk mencegah overfitting, diterapkan mekanisme early stopping dengan patience sebanyak 10 epoch. Selain itu, konfigurasi pelatihan juga diatur agar bobot terbaik



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

model selama pelatihan disimpan (restore best weights), sehingga model akhir merupakan model dengan performa validasi terbaik.

Hasil dari akurasi pelatihan model klasifikasi *footwear* dapat dilihat pada Gambar 4. 34.



Gambar 4. 34 History *training* accuracy model klasifikasi *footwear*


Berdasarkan grafik yang ditampilkan pada Gambar 4.34, terlihat bahwa akurasi pelatihan dan validasi mengalami peningkatan yang signifikan sejak awal pelatihan. Akurasi validasi secara konsisten lebih tinggi daripada akurasi pelatihan, dengan nilai yang stabil di atas 90% setelah sekitar epoch ke-20. Hal ini menunjukkan bahwa model berhasil mempelajari pola-pola fitur yang relevan untuk klasifikasi *footwear* secara efektif. Meskipun terdapat sedikit gap antara kurva akurasi pelatihan dan validasi, perbedaan tersebut masih dalam batas wajar dan tidak mengindikasikan overfitting yang parah.

Hasil dari loss pelatihan model klasifikasi *footwear* dapat dilihat pada Gambar 4. 35.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4. 35 History training loss model klasifikasi footwear

Gambar 4.35 menunjukkan bahwa nilai loss pelatihan dan validasi cenderung menurun secara stabil sepanjang proses pelatihan. Tidak terdapat fluktuasi ekstrem atau kenaikan mendadak pada loss validasi, yang mengindikasikan bahwa proses pelatihan berlangsung dengan baik dan model tidak mengalami degradasi performa akibat overfitting. Penurunan loss yang konsisten baik pada data pelatihan maupun validasi menjadi indikator bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya.

4.3.1.2.7 Implementasi Model *Deep Learning* Klasifikasi Atribut *Bag*


Tahap ini merupakan proses implementasi dari model klasifikasi deep learning yang dirancang untuk mengidentifikasi atribut *bag* pada objek manusia dalam citra. Implementasi ini bertujuan untuk mendeteksi dan mengklasifikasikan apakah seseorang dalam citra membawa tas dan menentukan jenisnya. Model klasifikasi ini menggunakan arsitektur MobileNetV2 sebagai feature extractor yang kemudian dilanjutkan dengan beberapa lapisan *fully connected* (dense) dan dropout guna meningkatkan performa klasifikasi serta mengurangi risiko overfitting.

Arsitektur Model Klasifikasi *Headwear* sudah dirangkum dan dapat dilihat pada Gambar 4. 36.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4. 36 Arsitektur model klasifikasi *bag*

Pada Gambar 4.36, arsitektur model memanfaatkan bobot awal dari MobileNetV2 yang telah dilatih sebelumnya pada dataset ImageNet (*pre-trained weights*). Lapisan awal model terdiri dari average pooling 2D untuk menyaring fitur penting, diikuti dengan proses flattening untuk mengubah *output* menjadi satu dimensi. Selanjutnya, terdapat tiga lapisan dense dengan jumlah neuron 256, 128, dan 64 yang semuanya menggunakan fungsi aktivasi ReLU. Untuk mencegah overfitting, diterapkan lapisan dropout dengan rasio 0.5 setelah dense layer pertama dan kedua, serta dropout 0.3 sebelum lapisan *output*. *Output* layer menggunakan 3 neuron dengan aktivasi softmax yang disesuaikan untuk klasifikasi multi-kelas, yaitu tiga kategori dari atribut tas.

Hyperparameter model klasifikasi *bag* sudah dirangkum dan dapat dilihat pada Tabel 4. 34.

Tabel 4. 34 Hyperparameter model klasifikasi *bag*

Hyperparameter	Nilai
Optimizer	Adam
Learning Rate	0.0001
Loss Function	categorical_crossentropy
Epochs	30
Metrics	Accuracy



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Patience (Early Stop)	5
Restore Best Weights	Ya

Pemilihan *optimizer* Adam didasarkan pada keunggulannya dalam menyesuaikan learning rate secara adaptif selama proses pelatihan, yang terbukti efektif dalam tugas-tugas klasifikasi gambar (Kingma & Ba, 2014). Learning rate yang rendah yaitu 0.0001 dipilih untuk menjaga stabilitas proses pembelajaran dan menghindari fluktuasi besar dalam fungsi loss. Karena klasifikasi yang dilakukan bersifat multi-kelas, digunakan loss function categorical crossentropy. Proses pelatihan menggunakan mekanisme early stopping dengan patience sebanyak 5 epoch untuk mencegah overfitting, serta pengaktifan opsi "restore best weights" memastikan model menyimpan bobot terbaik dari hasil pelatihan.

Hasil dari akurasi pelatihan model klasifikasi *bag* dapat dilihat pada Gambar 4. 33.



Gambar 4. 37 Histpry *training* model klasifikasi *bag*


Dari Gambar 4.37, terlihat bahwa akurasi pelatihan meningkat secara signifikan dari awal hingga sekitar epoch ke-20, kemudian mulai stabil mendekati akurasi validasi. Akurasi validasi sendiri mencapai nilai di atas 90% sejak epoch awal dan cenderung stabil hingga akhir pelatihan. Hal ini mengindikasikan bahwa model berhasil mengenali pola dengan baik dan generalisasi terhadap data validasi cukup optimal.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Hasil dari loss pelatihan model klasifikasi *eyewear* dapat dilihat pada Gambar 4. 38.



Gambar 4. 38 History *training* loss model klasifikasi *bag*

Gambar 4.38 menunjukkan penurunan yang konsisten pada nilai loss baik untuk data pelatihan maupun validasi. Nilai loss validasi menurun tajam hingga sekitar epoch ke-10 dan terus mengalami penyempurnaan meskipun secara bertahap. Tidak terdapat lonjakan drastis pada loss validasi, sehingga dapat disimpulkan bahwa model tidak mengalami overfitting yang signifikan dan mampu mempelajari distribusi data dengan baik.

4.3.1.2.8 Implementasi Model *Deep Learning* Klasifikasi Warna


Tahap ini merupakan implementasi dari model klasifikasi berbasis deep learning yang dirancang untuk mengklasifikasikan nama warna berdasarkan *input* nilai RGB. Tujuan utama dari implementasi ini adalah untuk mengidentifikasi nama warna dari nilai RGB yang diberikan, yang terdiri atas 11 kelas warna berbeda. Model ini dikembangkan menggunakan arsitektur jaringan neural sederhana yang terdiri atas beberapa lapisan dense, dropout, dan softmax sebagai *output* layer.

Arsitektur Model Klasifikasi Warna sudah dirangkum dan dapat dilihat pada Gambar 4. 39.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4. 39 Arsitektur model klasifikasi warna

Arsitektur pada Gambar 4. 39, dimulai dengan sebuah lapisan *input* (*input layer*) yang menerima nilai RGB sebagai vektor berdimensi tiga (3 fitur). Lapisan ini diikuti oleh dua buah Dense Layer masing-masing dengan 128 dan 64 unit neuron yang menggunakan fungsi aktivasi ReLU. Untuk mengurangi risiko overfitting, sebuah lapisan Dropout dengan rasio 0.3 disisipkan setelah dense layer kedua. Lapisan terakhir adalah *Output Layer* yang terdiri dari 11 neuron (sesuai jumlah kelas warna) dan menggunakan fungsi aktivasi Softmax untuk melakukan klasifikasi multikelas.

Proses pelatihan model didahului oleh tahap praproses data, di mana data RGB dinormalisasi ke dalam rentang $[0, 1]$ dan label warna dikodekan menggunakan label encoder serta diubah menjadi bentuk one-hot encoding. Dataset kemudian dibagi ke dalam tiga bagian: 80% untuk pelatihan, 15% untuk validasi, dan 5% untuk pengujian.

Hyperparameter model klasifikasi warna sudah dirangkum dan dapat dilihat pada Tabel 4. 35.

Tabel 4. 35 Hyperparameter model klasifikasi warna

Hyperparameter	Nilai
Optimizer	Adam
Learning Rate	0.0001
Loss Function	categorical_crossentropy
Epochs	100



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Metrics	Accuracy
---------	----------

Pada Tabel 4.35, pemilihan *optimizer* Adam dilakukan karena algoritma ini memiliki keunggulan dalam hal adaptivitas terhadap learning rate selama proses pelatihan, yang membuatnya cocok untuk pelatihan jaringan neural pada dataset yang relatif kecil dan memiliki dimensi fitur rendah. Nilai learning rate sebesar 0.0001 dipilih agar proses pelatihan berlangsung stabil tanpa menyebabkan perubahan parameter yang drastis. Fungsi loss categorical crossentropy digunakan karena tugas klasifikasi ini bersifat multikelas, sedangkan akurasi digunakan sebagai metrik evaluasi kinerja model.

Hasil dari accuracy pelatihan model klasifikasi warna dapat dilihat pada Gambar 4.41.




Gambar 4.40 History *training* accuracy model klasifikasi warna

Pada Gambar 4.40, terlihat bahwa kurva akurasi pelatihan dan validasi mengalami peningkatan yang konsisten seiring bertambahnya jumlah epoch. Akurasi validasi mencapai nilai di atas 87% dan menunjukkan performa yang stabil sejak pertengahan proses pelatihan. Meskipun terdapat sedikit perbedaan antara kurva akurasi pelatihan dan validasi, hal tersebut masih tergolong wajar dan tidak mengindikasikan adanya overfitting yang signifikan.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4. 41 History *training loss* model klasifikasi warna


Gambar 4. 41, menampilkan kurva loss untuk data pelatihan dan validasi. Nilai loss pada kedua jenis data menunjukkan penurunan yang konsisten sepanjang 100 epoch, tanpa adanya fluktuasi ekstrem atau kenaikan tiba-tiba pada loss validasi. Hal ini menunjukkan bahwa model berhasil melakukan pembelajaran secara optimal dan memiliki kemampuan generalisasi yang baik terhadap data yang tidak dikenali sebelumnya.

4.3.2 Implementasi Antarmuka Grafis

Implementasi antarmuka grafis (GUI) dirancang untuk memfasilitasi interaksi antara pengguna dan sistem deteksi *fashion* yang dibangun. Antarmuka ini, menu terbagi menjadi tiga area fungsional utama: panel kontrol untuk pemilihan mode *input*, panel *output* visual untuk menampilkan gambar atau video yang dianalisis, dan panel samping yang berisi konfigurasi serta tabulasi hasil deteksi secara terstruktur.




4.3.2.1 Implementasi Antarmuka Grafis *Real-time Camera*



Gambar 4. 42 Implementasi antarmuka grafis *real-time camera*

Gambar 4. 42, menunjukkan pengujian sistem pada mode *Real-time Camera*. Antarmuka mengonfirmasi bahwa aplikasi sedang berjalan aktif, dan secara fungsional berhasil mendeteksi serta melacak berbagai atribut *fashion* pada subjek secara langsung. Meskipun deteksi kategori utama akurat, hasil analisis menyoroti tantangan pada klasifikasi detail, di mana terjadi inkonsistensi pada deteksi warna untuk *headwear* dan *upperwear*, serta perbedaan klasifikasi pada *eyewear*. Hasil ini memvalidasi fungsionalitas mode *real-time* sekaligus mengidentifikasi perlunya peningkatan akurasi pada model klasifikasi sekunder.

4.3.2.2 Implementasi Antarmuka Grafis Image Analysis



Gambar 4. 43 Implementasi antarmuka grafis image analysis

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Pengujian pada mode "Image Analysis", seperti ditunjukkan pada Gambar 4. 43, menunjukkan sistem berhasil mengidentifikasi setelan jas hitam dengan tepat sebagai *jacket* dan *pants*. Titik evaluasi utama muncul pada *footwear*, di mana sepatu hitam diklasifikasikan dengan warna yang tidak konsisten (Black dan Brown). Hasil ini memvalidasi fungsionalitas analisis gambar statis sekaligus mengungkap sensitivitas model warna terhadap refleksi cahaya pada permukaan material, yang menjadi catatan penting untuk pengembangan selanjutnya.

4.3.2.3 Implementasi Antarmuka Grafis *Real-time Video Analysis*



Gambar 4. 44 Implementasi antarmuka grafis video analysis

Mode "Video File Analysis" memungkinkan pengguna untuk melakukan analisis pada file video yang sudah ada. Seperti yang terilustrasi pada Gambar 4. 44, setelah pengguna memilih file video dan memulai proses, aplikasi akan memproses klip tersebut frame-by-frame. Panel *output* visual menampilkan pemutaran video beserta anotasi deteksi yang diperbarui sesuai dengan konten pada setiap frame. Contoh pada gambar menunjukkan sistem berhasil mengidentifikasi berbagai item seperti *jacket*, *pants*, *shoes*, *cap*, dan *eyewear* secara bersamaan, dengan rincian lengkap untuk setiap objek yang disajikan secara terstruktur pada tabel hasil di sebelah kanan.

4.4 Pengujian Sistem

Pada tahap penelitian ini sistem yang berhasil dikembangkan sampai menjadi minimum valuable product (MVP), dilakukan pengujian untuk melakukan evaluasi



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

kinerja pada sistem apakah sistem telah berjalan sesuai dengan kebutuhan fungsional dan kebutuhan non-fungsional yang telah ditulis pada sub-bab identifikasi kebutuhan. Pengujian ini bertujuan untuk mengidentifikasi kekurangan-kekurangan pada sistem, sehingga dapat menjadi kebutuhan pengembangan kedepannya atau versi beta dari sistem yang dikembangkan.

4.4.1 Analisis Hasil Pengujian Model

Pada tahap ini, penulis melakukan analisis terhadap seluruh model yang telah dikembangkan dalam sistem, mulai dari model deteksi objek hingga model klasifikasi atribut dan warna pakaian. Tujuan dari analisis ini adalah untuk mengevaluasi performa masing-masing model terhadap data uji dan validasi guna memastikan bahwa sistem mampu melakukan identifikasi objek serta klasifikasi atribut dan warna dengan akurat dan andal. Pengujian dilakukan menggunakan metrik yang relevan seperti akurasi, loss, *precision*, *recall*, dan *F1-score*, yang dipantau selama proses pelatihan dan divalidasi menggunakan data yang tidak digunakan dalam proses *training*.

Model deteksi objek dikembangkan menggunakan arsitektur YOLOv8 yang dilatih pada dataset hasil anotasi khusus untuk mendeteksi enam sub-kategori pakaian, yaitu *upperwear*, *bottomwear*, *headwear*, *footwear*, *eyewear*, dan *bag*. Evaluasi model deteksi dilakukan menggunakan metrik seperti *mean Average Precision* (mAP) dan *Intersection over Union* (IoU) untuk mengukur sejauh mana model mampu mengenali objek pada gambar secara tepat.

Setelah objek berhasil dideteksi, hasil bounding box tersebut digunakan sebagai *input* untuk model klasifikasi atribut. Setiap sub-kategori memiliki model klasifikasi atribut yang dikembangkan secara terpisah menggunakan arsitektur MobileNetV2 yang telah dimodifikasi pada *bagian dense layer*-nya. Model ini meliputi klasifikasi untuk jenis pakaian seperti *T-shirts*, *Shirts*, *Jackets*, *Pants*, *Skirts*, dan sebagainya. Evaluasi terhadap model atribut dilakukan dengan melihat performa pelatihan dan validasi serta visualisasi akurasi dan loss untuk mengetahui kestabilan dan kemampuan generalisasi dari model.

Selain itu, dikembangkan pula model klasifikasi warna yang berfungsi untuk mengidentifikasi warna dominan pada objek pakaian yang telah terdeteksi. Model



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

ini juga menggunakan arsitektur MobileNetV2 dan telah dilatih untuk membedakan berbagai warna umum seperti hitam, putih, merah, biru, dan lain sebagainya. Evaluasi dilakukan menggunakan data uji yang telah diberi label warna untuk melihat seberapa baik model mengenali warna berdasarkan potongan gambar dari hasil bounding box.

Melalui proses analisis ini, penulis dapat mengidentifikasi kelebihan dan kekurangan dari setiap model serta potensi pengembangan di masa depan, baik dari sisi performa akurasi maupun efisiensi komputasi yang diperlukan untuk implementasi sistem secara *real-time*. Penilaian performa ini juga digunakan untuk menilai sejauh mana sistem telah memenuhi kebutuhan fungsional dan non-fungsional yang telah ditetapkan pada tahap analisis kebutuhan sebelumnya.

4.4.1.1 Analisis Hasil Pengujian Model Deteksi Objek

Hasil evaluasi matrix pengujian model deteksi objek sudah dirangkum dan dapat dilihat pada Tabel 4. 35

Tabel 4. 36 Hasil pengujian model deteksi objek

Kelas	Jumlah Gambar	Jumlah Instance	<i>Precision</i>	<i>Recall</i>	mAP@0.5	mAP@0.5:0.95
All	351	1333	0.802	0.764	0.797	0.681
Bag	54	63	0.731	0.389	0.515	0.436
Bottomwear	179	180	0.816	0.917	0.919	0.835
Eyewear	48	48	0.911	0.917	0.933	0.779
Footwear	339	659	0.814	0.780	0.835	0.693
Headwear	32	33	0.642	0.636	0.628	0.541
Upperwear	349	350	0.900	0.946	0.953	0.802

Hasil evaluasi model deteksi objek pada Tabel 4. 35, menunjukkan performa yang baik, dengan nilai mAP@0.5 sebesar 0.797 dan mAP@0.5:0.95 sebesar 0.681. Kelas *upperwear* menjadi yang paling akurat, dengan *precision* 0.900, *recall* 0.946, dan mAP@0.5 0.953. Diikuti oleh *bottomwear* dan *eyewear*, yang juga mencatat



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

nilai mAP tinggi, masing-masing 0.919 dan 0.933. *Footwear* tampil stabil dengan mAP@0.5 0.835. Sebaliknya, *bag* dan *headwear* menunjukkan performa rendah, diduga akibat jumlah data yang terbatas dan keragaman visual tinggi. Secara keseluruhan, model cukup andal dalam mengenali atribut utama manusia, dengan potensi peningkatan pada kelas-kelas minor.

Hasil pengujian pada dataset *validation* secara langsung dapat dilihat pada Gambar 4. 46.



Gambar 4. 45 Hasil visualisasi pengujian model deteksi objek pada dataset *test* secara langsung.

Visualisasi Gambar 4.45 menunjukkan bahwa model deteksi objek bekerja sangat baik, terutama untuk atribut mayor seperti *upperwear*, *bottomwear*, dan *footwear*, dengan skor prediksi tinggi antara 0.9–1.0. Atribut minor seperti *bag*, *eyewear*, dan *headwear* juga berhasil terdeteksi, meskipun dengan akurasi lebih rendah akibat keterbatasan data pelatihan. Kualitas bounding box umumnya akurat dan mendekati label asli, meskipun masih ditemukan prediksi ganda dan beberapa false positive. Secara keseluruhan, hasil visual mendukung evaluasi kuantitatif sebelumnya dan menunjukkan bahwa model layak untuk diterapkan pada bentuk minimum valuable product (MVP) deteksi atribut manusia secara *real-time*.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

4.4.1.2 Analisis Hasil Pengujian Model Klasifikasi *Headwear*


Hasil evaluasi matriks pengujian model klasifikasi *headwear* sudah dirangkum dan dapat dilihat pada Tabel 4. 36

Tabel 4. 37 Hasil evaluasi matriks model klasifikasi *headwear*

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	Support
<i>hat</i>	0.91	1.00	0.95	10
<i>cap</i>	1.00	0.92	0.96	13
Accuracy			0.96	23

Hasil evaluasi matrix klasifikasi *headwear* pada Tabel 4.36 menunjukkan performa tinggi dengan akurasi keseluruhan sebesar 0.96. Kelas *hat* memiliki *recall* sempurna (1.00), sementara kelas *cap* mencatat *precision* sempurna (1.00). Kesalahan klasifikasi hanya terjadi satu kali, berdampak pada *precision hat* (0.91) dan *recall cap* (0.92). Secara keseluruhan, model sangat andal membedakan *hat* dan *cap*, dengan *F1-score* di atas 0.95, menandakan performa yang seimbang dan efektif.

Hasil *confussion matrix* pengujian model klasifikasi *headwear* dapat dilihat pada Gambar 4. 46



Gambar 4. 46 Hasil *confussion matrix* model klasifikasi *headwear*




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Gambar 4. 46, menampilkan confusion matrix yang memvisualisasikan performa model dengan membandingkan label aktual dan label prediksi. Dari total 23 data uji, model menunjukkan performa yang sangat akurat. Matriks menunjukkan 10 data *hat* dan 12 data *cap* berhasil diklasifikasikan dengan benar (True Positives). Teridentifikasi hanya ada satu kesalahan tunggal, di mana satu data dengan label aktual *cap* salah diklasifikasikan sebagai *hat* (False Negative untuk *cap* dan False Positive untuk *hat*). Tidak ada kesalahan klasifikasi untuk data *hat* yang diprediksi sebagai *cap*. Visualisasi ini menegaskan bahwa tingkat kesalahan model sangat rendah, dengan hanya satu dari 23 data yang salah diklasifikasikan.

Hasil pengujian model klasifikasi *headwear* secara langsung pada dataset *test* dapat dilihat pada Gambar 4. 47



Gambar 4. 47 Hasil visualisasi model klasifikasi *headwear* pengujian pada dataset *test* secara langsung.

Gambar 4.47 menampilkan hasil prediksi model pada data individual yang sebagian besar sesuai antara label aktual dan prediksi, mencerminkan akurasi tinggi. Satu kesalahan klasifikasi terlihat pada baris kedua, gambar keempat, di mana topi bisbol (*cap*) salah diprediksi sebagai *hat*. Visualisasi ini memperkuat hasil evaluasi kuantitatif dan membantu mengidentifikasi tantangan visual yang dihadapi model.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

4.4.1.3 Analisis Hasil Pengujian Model Klasifikasi *Eyewear*


Hasil evaluasi matriks pengujian model klasifikasi *eyewear* sudah dirangkum dan dapat dilihat pada Tabel 4. 37

Tabel 4. 38 Hasil evaluasi matriks model klasifikasi *eyewear*

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	Support
<i>sunglasses</i>	1.00	0.94	0.97	18
<i>eyeglasses</i>	0.88	1.00	0.93	7
Accuracy			0.96	25

Hasil evaluasi matriks klasifikasi *eyewear* pada Tabel 4. 37, menunjukkan performa tinggi dengan akurasi keseluruhan sebesar 0.96. Kelas *eyeglasses* memiliki *recall* sempurna (1.00), sementara kelas *sunglasses* mencatat *precision* sempurna (1.00). Kesalahan klasifikasi hanya terjadi satu kali, berdampak pada *recall sunglasses* (0.94) dan *precision eyeglasses* (0.88). Secara keseluruhan, model sangat andal membedakan *sunglasses* dan *eyeglasses*, dengan *F1-score* di atas 0.90, menandakan performa yang seimbang dan efektif.

Hasil *confussion matrix* pengujian model klasifikasi *eyewear* dapat dilihat pada Gambar 4. 48



Gambar 4. 48 Hasil *confussion matrix* model klasifikasi *eyewear*




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Gambar 4.48, confusion matrix memvisualisasikan performa model dengan membandingkan label aktual dan label prediksi. Dari total 25 data uji, model menunjukkan performa yang sangat akurat. Matriks menunjukkan 17 data *sunglasses* dan 7 data *eyeglasses* berhasil diklasifikasikan dengan benar (True Positives). Teridentifikasi hanya ada satu kesalahan tunggal, di mana satu data dengan label aktual *sunglasses* salah diklasifikasikan sebagai *eyeglasses* (False Negative untuk *sunglasses* dan False Positive untuk *eyeglasses*). Tidak ada kesalahan klasifikasi untuk data *eyeglasses* yang diprediksi sebagai *sunglasses*. Visualisasi ini menegaskan bahwa tingkat kesalahan model sangat rendah, dengan hanya satu dari 25 data yang salah diklasifikasikan.

Hasil pengujian model klasifikasi *eyewear* secara langsung pada dataset *test* dapat dilihat pada Gambar 4. 49



Gambar 4. 49 Hasil visualisasi pengujian model klasifikasi *eyewear* pada dataset *test* secara langsung.

Gambar 4.49, menampilkan hasil prediksi model pada data individual menunjukkan bahwa sebagian besar prediksi sesuai antara label aktual dan prediksi, yang mencerminkan akurasi tinggi. Satu kesalahan klasifikasi terlihat pada baris pertama, gambar kedua, di mana kacamata hitam (*sunglasses*) salah diprediksi sebagai



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

kacamata biasa (*eyeglasses*). Visualisasi ini memperkuat hasil evaluasi kuantitatif dan membantu mengidentifikasi tantangan visual yang dihadapi model.

4.4.1.4 Analisis Hasil Pengujian Model Klasifikasi *Upperwear*

Hasil evaluasi matriks pengujian model klasifikasi *upperwear* sudah dirangkum dan dapat dilihat pada Tabel 4. 38

Tabel 4. 39 Hasil evaluasi matriks model klasifikasi *upperwear*

Kelas	Precision	Recall	F1-Score	Support
dress	0.83	0.83	0.83	6
jacket	1.00	0.67	0.80	3
shirt	0.88	0.88	0.88	8
sweater	0.91	1.00	0.95	10
t-shirt	1.00	1.00	1.00	5
Accuracy			0.91	32


Hasil evaluasi matriks klasifikasi *upperwear* pada Tabel 4. 38, menunjukkan performa yang baik dengan akurasi keseluruhan sebesar 0.91. Performa tertinggi ditunjukkan oleh kelas t-shirt yang mencapai nilai *precision* dan *recall* sempurna (1.00), diikuti oleh kelas sweater dengan *recall* sempurna (1.00) dan jacket dengan *precision* sempurna (1.00). Beberapa kesalahan klasifikasi terjadi, terutama pada kelas jacket yang hanya mencapai *recall* 0.67. Meskipun demikian, model menunjukkan performa yang andal pada kelas dengan data terbanyak seperti sweater (F1-Score 0.95) dan shirt (F1-Score 0.88), menandakan kapabilitas yang baik secara umum.

Hasil *confussion matrix* pengujian model klasifikasi *upperwear* dapat dilihat pada Gambar 4. 50



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4. 50 Hasil *confusion matrix* model klasifikasi *upperwear*

Gambar 4. 50, *confusion matrix* memvisualisasikan performa model dengan membandingkan label aktual dan label prediksi. Dari total 32 data uji, model menunjukkan performa yang baik. Matriks menunjukkan 5 data dress, 2 data jacket, 7 data shirt, 10 data sweater, dan 5 data t-shirt berhasil diklasifikasikan dengan benar (*True Positives*). Teridentifikasi tiga kesalahan klasifikasi antar kelas, yaitu satu dress diprediksi sebagai shirt, satu jacket sebagai sweater, dan satu shirt sebagai dress. Kelas sweater dan t-shirt tidak memiliki kesalahan dalam hal identifikasi (*recall* 1.00). Visualisasi ini menegaskan bahwa tingkat kesalahan model tergolong rendah, dengan mayoritas prediksi akurat di seluruh kelas.

Hasil pengujian model klasifikasi *upperwear* secara langsung pada dataset *test* dapat dilihat pada Gambar 4. 51



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4. 51 Hasil visualisasi pengujian model klasifikasi *upperwear* pada dataset *test* secara langsung.

Gambar hasil prediksi model pada data individual menunjukkan bahwa sebagian besar prediksi sesuai antara label aktual dan prediksi, yang mencerminkan akurasi model secara umum. Beberapa contoh kesalahan klasifikasi yang sesuai dengan confusion matrix dapat diamati, seperti pada baris kedua, gambar pertama, di mana sebuah dress salah diprediksi sebagai shirt. Contoh lain terlihat pada baris kelima, gambar keempat, di mana sebuah jacket keliru diklasifikasikan sebagai sweater. Visualisasi ini memperkuat hasil evaluasi kuantitatif dan membantu mengidentifikasi tantangan visual yang dihadapi model, seperti kemiripan fitur antar kelas pakaian.

4.4.1.5 Analisis Hasil Pengujian Model Klasifikasi *Bottomwear*

Hasil evaluasi matriks pengujian model klasifikasi *bottomwear* sudah dirangkum dan dapat dilihat pada Tabel 4. 40.

Tabel 4. 40 Hasil evaluasi matriks model klasifikasi *bottomwear*

Kelas	Precision	Recall	F1-Score	Support
pants	1.00	1.00	1.00	10
shorts	1.00	0.91	0.95	11




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

skirts	0.92	1.00	0.96	11
Accuracy			0.97	32

Hasil evaluasi matriks klasifikasi *bottomwear* pada Tabel 4. 40, menunjukkan performa sangat tinggi dengan akurasi keseluruhan sebesar **0.97**. Kelas pants mencapai performa sempurna dengan *precision* dan *recall* 1.00, sementara kelas skirts mencatat *recall* sempurna (1.00) dan shorts mencatat *precision* sempurna (1.00). Kesalahan klasifikasi hanya terjadi satu kali, yang berdampak pada *recall* kelas shorts (0.91) dan *precision* kelas skirts (0.92). Secara keseluruhan, model sangat andal dalam membedakan ketiga jenis pakaian, dengan F1-Score di atas 0.95 untuk semua kelas, menandakan performa yang sangat seimbang dan efektif.

Hasil *confussion matrix* pengujian model klasifikasi *bottomwear* dapat dilihat pada Gambar 4. 52



Gambar 4. 52 Hasil *confussion matrix* model klasifikasi *bottomwear*

Gambar 4. 52, *confusion matrix* memvisualisasikan performa model dengan membandingkan label aktual dan label prediksi. Dari total 32 data uji, model menunjukkan performa yang sangat akurat. Matriks menunjukkan 10 data pants, 10 data shorts, dan 11 data skirts berhasil diklasifikasikan dengan benar (*True Positives*). Teridentifikasi hanya ada satu kesalahan tunggal, di mana satu data dengan label aktual shorts salah diklasifikasikan sebagai skirts (*False Negative* untuk shorts* dan **False Positive** untukskirts*). Tidak ada kesalahan klasifikasi



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

pada identifikasi data pants dan skirts. Visualisasi ini menegaskan bahwa tingkat kesalahan model sangat rendah, dengan hanya satu dari 32 data yang salah diklasifikasikan.

Hasil pengujian model klasifikasi *bottomwear* secara langsung pada dataset *test* dapat dilihat pada Gambar 4. 53



Gambar 4. 53 Hasil visualisasi pengujian model klasifikasi *bottomwear* pada dataset *test* secara langsung.

Gambar 4. 53, hasil prediksi model pada data individual menunjukkan bahwa sebagian besar prediksi sesuai antara label aktual dan prediksi, yang mencerminkan akurasi tinggi. Satu kesalahan klasifikasi yang tercatat terlihat pada baris kelima, gambar kedua, di mana celana pendek (*shorts*) salah diprediksi sebagai rok (*skirts*). Visualisasi ini memperkuat hasil evaluasi kuantitatif dan membantu mengidentifikasi tantangan visual yang dihadapi model, seperti kemungkinan adanya kemiripan siluet atau motif antar jenis pakaian.

4.4.1.6 Analisis Hasil Pengujian Model Klasifikasi *Footwear*

Hasil evaluasi matriks pengujian model klasifikasi *footwear* sudah dirangkum dan dapat dilihat pada Tabel 4. 41

Tabel 4. 41 Hasil evaluasi matriks model klasifikasi *footwear*




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Kelas	Precision	Recall	F1-Score	Support
flip_flops	1.00	1.00	1.00	10
sandals	0.80	0.80	0.80	10
shoes	0.83	0.83	0.83	12
Accuracy			0.88	32

Hasil evaluasi matriks klasifikasi *footwear* pada Tabel 4.41, menunjukkan performa yang baik dengan akurasi keseluruhan sebesar 0.88. Kelas *flip_flops* mencapai performa sempurna dengan nilai *precision* dan *recall* sebesar 1.00. Performa yang lebih rendah tercatat pada kelas *sandals* dan *shoes*, yang keduanya memiliki nilai *precision* dan *recall* di sekitar 0.80-0.83. Hal ini mengindikasikan adanya beberapa kesalahan klasifikasi antara kedua kelas tersebut. Secara keseluruhan, model cukup andal dalam membedakan jenis-jenis alas kaki, dengan performa terbaik pada kelas yang paling spesifik (*flip_flops*).

Hasil *confussion matrix* pengujian model klasifikasi *footwear* dapat dilihat pada Gambar 4. 54



Gambar 4. 54 Hasil *confussion matrix* model klasifikasi *footwear*

Gambar 4.54 *confusion matrix* memvisualisasikan performa model dengan membandingkan label aktual dan label prediksi. Dari total 32 data uji, matriks menunjukkan 10 data *flip_flops*, 8 data *sandals*, dan 10 data *shoes* berhasil diklasifikasikan dengan benar (*True Positives*). Teridentifikasi adanya kesalahan




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

klasifikasi resiprokal antara dua kelas, di mana 2 data *sandals* salah diklasifikasikan sebagai *shoes*, dan 2 data *shoes* salah diklasifikasikan sebagai *sandals*. Kelas *flip_flops* tidak memiliki kesalahan sama sekali. Visualisasi ini menegaskan bahwa tantangan utama model terletak pada perbedaan antara *sandals* dan *shoes* yang seringkali memiliki kemiripan visual.

Hasil pengujian model klasifikasi *footwear* secara langsung pada dataset *test* dapat dilihat pada Gambar 4. 55



Gambar 4. 55 Hasil visualisasi pengujian model klasifikasi *footwear* pada dataset *test* secara langsung.

Gambar 4. 55, hasil prediksi model pada data individual menunjukkan bahwa sebagian besar prediksi sesuai antara label aktual dan prediksi, yang mencerminkan performa model secara umum. Contoh kesalahan klasifikasi dapat diamati, seperti pada baris ketiga, gambar kedua, di mana *sandals* (Real) salah diprediksi sebagai *shoes* (Pred). Sebaliknya, pada baris kelima, gambar keempat, sebuah *shoes* (Real) keliru diklasifikasikan sebagai *sandals* (Pred). Visualisasi ini memperkuat hasil evaluasi kuantitatif dan membantu mengidentifikasi tantangan visual yang dihadapi model, seperti pada alas kaki dengan desain hybrid yang menyulitkan klasifikasi.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

4.4.1.7 Analisis Hasil Pengujian Model Klasifikasi *Bag*


Hasil evaluasi matriks pengujian model klasifikasi *bag* sudah dirangkum dan dapat dilihat pada Tabel 4. 42

Tabel 4. 42 Hasil evaluasi matriks model klasifikasi *bag*

Kelas	Precision	Recall	F1-Score	Support
backpack	1.00	1.00	1.00	10
clutchbag	0.88	1.00	0.93	7
handbag	1.00	0.93	0.97	15
Accuracy			0.97	32

Hasil evaluasi matriks klasifikasi *bag* pada Tabel 4. 42, menunjukkan performa sangat tinggi dengan akurasi keseluruhan sebesar **0.97**. Kelas backpack mencapai performa sempurna, sementara kelas *clutchbag* memiliki *recall* sempurna (1.00) dan kelas *handbag* mencatat *precision* sempurna (1.00). Kesalahan klasifikasi hanya terjadi satu kali, yang berdampak pada *recall* kelas *handbag* (0.93) dan *precision* kelas *clutchbag* (0.88). Secara keseluruhan, model sangat andal membedakan berbagai jenis tas, dengan F1-Score di atas 0.93 untuk semua kelas, menandakan performa yang sangat seimbang dan efektif.

Hasil *confussion matrix* pengujian model klasifikasi *bag* dapat dilihat pada Gambar 4. 56



Gambar 4. 56 Hasil *confussion matrix* model klasifikasi *bag*




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Gambar 4. 56, *confusion matrix* memvisualisasikan performa model dengan membandingkan label aktual dan label prediksi. Dari total 32 data uji, model menunjukkan performa yang sangat akurat. Matriks menunjukkan 10 data backpack, 7 data *clutchbag*, dan 14 data *handbag* berhasil diklasifikasikan dengan benar (*True Positives*). Teridentifikasi hanya ada satu kesalahan tunggal, di mana satu data dengan label aktual *handbag* salah diklasifikasikan sebagai *clutchbag* (*False Negative* untuk *handbag* dan *False Positive* untuk *clutchbag**). Tidak ada kesalahan identifikasi pada data backpack dan *clutchbag*. Visualisasi ini menegaskan bahwa tingkat kesalahan model sangat rendah, dengan hanya satu dari 32 data yang salah diklasifikasikan.

Hasil pengujian model klasifikasi *bag* secara langsung pada dataset *test* dapat dilihat pada Gambar 4. 57



Gambar 4. 57 Hasil visualisasi pengujian model klasifikasi *bag* pada dataset *test* secara langsung.

Gambar 4. 57, hasil prediksi model pada data individual menunjukkan bahwa sebagian besar prediksi sesuai antara label aktual dan prediksi, yang mencerminkan akurasi tinggi. Satu kesalahan klasifikasi yang tercatat dapat terlihat pada baris ketiga, gambar kelima, di mana sebuah *handbag* (tas tangan) berukuran kecil salah



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

diprediksi sebagai *clutchbag*. Visualisasi ini memperkuat hasil evaluasi kuantitatif dan membantu mengidentifikasi tantangan visual yang dihadapi model, yaitu kemiripan bentuk antara *handbag* berukuran kecil dan *clutchbag*.

4.4.1.8 Hasil dan analisis pengujian model klasifikasi warna

Hasil evaluasi matriks pengujian model klasifikasi *bag* sudah dirangkum dan dapat dilihat pada Tabel 4. 43

Tabel 4. 43 Hasil Evaluasi matriks model klasifikasi warna

Kelas	Precision	Recall	F1-Score	Support
Black	1.00	1.00	1.00	2
Blue	0.93	0.93	0.93	59
Brown	0.77	0.59	0.67	17
Green	0.90	0.94	0.92	84
Grey	0.80	0.40	0.53	10
Orange	0.75	0.90	0.82	10
Pink	0.78	0.90	0.84	20
Purple	0.87	0.91	0.89	22
Red	0.83	0.77	0.80	13
White	1.00	1.00	1.00	2
Yellow	0.79	0.79	0.79	14
Accuracy			0.87	253

Hasil evaluasi matriks klasifikasi warna pada Tabel 4. 43, menunjukkan performa baik dengan akurasi keseluruhan sebesar 0.87. Performa sempurna (1.00) dicapai oleh kelas Black dan White, meskipun dengan jumlah data yang sedikit. Kelas dengan dukungan data tinggi seperti Blue dan Green juga menunjukkan performa solid dengan F1-score di atas 0.92. Tantangan utama model terlihat pada kelas Brown dan Grey, yang mencatat nilai *recall* rendah, masing-masing 0.59 dan 0.40,




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

menandakan kesulitan dalam mengidentifikasi kedua warna tersebut secara konsisten. Secara keseluruhan, model andal dalam mengenali warna-warna dominan, namun memerlukan peningkatan untuk warna yang lebih ambigu.

Hasil *confussion matrix* pengujian model klasifikasi warna dapat dilihat pada Gambar 4. 56



Gambar 4. 58 Hasil *Confussion matrix* model klasifikasi warna

Gambar 4.58, *confussion matrix* memvisualisasikan performa model dengan membandingkan warna aktual dan warna prediksi. Dari total 253 data uji, matriks menyoroti nilai *True Positive* yang tinggi untuk warna mayoritas seperti Blue (55), Green (79), dan Purple (20). Namun, terdapat beberapa area kebingungan yang signifikan. Kelas Brown paling banyak salah diklasifikasikan menjadi berbagai warna lain. Demikian pula, kelas Grey sering keliru diidentifikasi, terutama sebagai Green dan Blue. Visualisasi ini menegaskan bahwa kesalahan model terkonsentrasi pada warna-warna yang secara visual mirip atau ambigu seperti Brown dan Grey.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

4.4.2 Analisis Hasil Pengujian Sistem

4.4.2.1 Analisis Hasil Deteksi dan Klasifikasi Atribut Pakaian

Analisis ini menguraikan hasil dari sistem identifikasi atribut pakaian otomatis. Sistem ini menggunakan pendekatan multi-tahap untuk mendeteksi objek, mengklasifikasikan jenis, dan mengekstraksi warna pakaian dari gambar. Seluruh hasil divisualisasikan secara langsung pada gambar studi kasus untuk memberikan pemahaman yang jelas mengenai proses dan akurasi sistem.

4.4.2.1.1 Proses Identifikasi Atribut Multi-Tahap

Sistem beroperasi melalui tiga tahapan utama yang saling berurutan untuk mencapai hasil akhir yang detail.

1. Deteksi Objek dengan YOLOv8

Langkah pertama adalah mendeteksi keberadaan dan lokasi objek pakaian menggunakan model YOLOv8. Proses ini menghasilkan kotak pembatas (*bounding box*) berwarna hijau di sekitar setiap objek yang teridentifikasi, beserta label kategori dasarnya, seperti *upperwear*, *bottomwear*, dan *footwear*.

2. Klasifikasi Subclass dengan CNN

Setiap objek yang terdeteksi kemudian dianalisis lebih lanjut oleh model Convolutional Neural Network (CNN) yang spesifik untuk setiap kategori. Tahap ini bertujuan untuk mengidentifikasi jenis atau *subclass* yang lebih spesifik, misalnya mengubah label *upperwear* menjadi *upperwear: jacket*.

3. Ekstraksi Warna dan Strategi Sampling

Tahap krusial terakhir adalah menentukan warna dominan. Untuk memastikan akurasi, sistem menerapkan strategi sampling adaptif yang divisualisasikan melalui titik kuning sebagai penanda lokasi pengambilan sampel warna.

- Metode Titik Tunggal: Satu titik di pusat objek digunakan untuk item yang cenderung solid dan seragam seperti headwear dan footwear.
- Metode Tiga Titik: Tiga titik horizontal digunakan untuk upperwear (jaket) dan bottomwear (celana). Strategi ini dirancang cerdas untuk menangkap warna kain utama secara akurat, sekaligus menghindari




Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

potensi kesalahan pembacaan akibat adanya lapisan pakaian dalam (kemeja), ritsleting, atau logo di bagian tengah.

4.4.2.1.2 Analisis Visual Pada Gambar

Berdasarkan tahapan pada sub-bab 4.4.2.1.1 di atas, berikut adalah analisis mendalam dari hasil yang ditampilkan pada kedua gambar yakni gambar 4. 59.



Gambar 4. 59 Contoh Hasil Analisis Multi-tahap

Gambar 4. 59 posisi kiri, sistem berhasil mengidentifikasi empat atribut pakaian pada subjek pertama dengan akurasi tinggi.

- a. headwear: hat (Black): Deteksi topi dan klasifikasinya sebagai "hat" sudah tepat. Warna "Black" ditentukan melalui metode titik tunggal yang representatif.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

- b. upperwear: jacket (Orange): Jaket berhasil diidentifikasi. Penggunaan strategi tiga titik terbukti efektif dalam menangkap warna "Orange" dari jaket secara dominan.
- c. bottomwear: pants (Black): Celana terdeteksi dengan benar. Tiga titik sampling memastikan warna "Black" yang konsisten diambil dari kain celana.
- d. footwear: shoes (Grey): Sepatu terdeteksi dengan akurat. Warna "Grey" berhasil diekstrak melalui metode titik tunggal.

Gambar 4.59 posisi kanan, pada subjek kedua, sistem kembali menunjukkan keandalannya, terutama dalam menangani kondisi yang lebih kompleks.

- a. upperwear: jacket (Brown): Ini adalah contoh keberhasilan utama dari strategi tiga titik. Sistem mampu mengidentifikasi warna "Brown" dari jaket dan secara cerdas mengabaikan kemeja putih yang terlihat di belakangnya. Jika hanya menggunakan satu titik pusat, ada kemungkinan besar sistem akan salah mendeteksi warna putih.
- b. bottomwear: pants (Black): Sama seperti kasus pertama, deteksi dan ekstraksi warna untuk celana berjalan dengan baik.
- c. footwear: shoes (Black): Deteksi sepatu dan penentuan warna hitamnya sudah akurat menggunakan metode titik tunggal.

Secara keseluruhan, sistem menunjukkan kinerja yang sangat baik dalam mengidentifikasi atribut pakaian secara hierarkis. Penggunaan model yang berbeda untuk setiap tugas (deteksi, klasifikasi, warna) memungkinkan hasil yang detail dan akurat.

4.4.2.1.3 Analisis Ketinggian Kamera dan Jarak Kamera Sistem

Dalam proses akuisisi citra untuk keperluan pengenalan objek atau klasifikasi berbasis computer vision, penempatan kamera yang tepat sangat krusial untuk memastikan hasil gambar yang optimal. Dua parameter penting dalam pengaturan ini adalah ketinggian kamera dari permukaan tanah serta diameter antara kamera dan objek.



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Objek yang diamati dalam analisis ini adalah manusia dengan rentang tinggi badan antara 166 cm hingga 191 cm. Tinggi ini mencerminkan variasi umum dari populasi dewasa.

Kamera diposisikan pada ketinggian 1 meter (100 cm) dari permukaan tanah. Dengan demikian, kamera berada pada ketinggian yang lebih rendah dari tinggi rata-rata badan spesimen. Ini berarti kamera perlu diarahkan ke bawah untuk menangkap keseluruhan tubuh, dari kepala hingga kaki.

Ditetapkan bahwa diameter antara kamera dan objek yang optimal berada dalam kisaran 200 cm hingga 230 cm. Diameter ini mempertimbangkan beberapa aspek berikut:

- a. Field of View (FOV): Diameter ini cukup untuk memungkinkan kamera menangkap seluruh tubuh spesimen dari kepala hingga kaki dalam satu frame.
- b. Minimnya distorsi perspektif: Dengan diameter ini, distorsi yang timbul akibat sudut pengambilan gambar dapat dikurangi, sehingga proporsi tubuh tetap terlihat alami.
- c. Keseimbangan antara resolusi dan detail: Semakin dekat kamera ke objek, semakin tinggi detail yang dapat ditangkap. Namun, jika terlalu dekat, sebagian tubuh (misalnya kaki atau kepala) dapat terpotong dari frame, sehingga hasil analisis menjadi tidak menyeluruh. Diameter 200–230 cm memberikan keseimbangan yang baik.

Dengan kamera setinggi 100 cm dan objek setinggi 166–191 cm, maka bagian tengah tubuh (sekitar perut atau dada bawah) akan sejajar dengan garis pandang horizontal kamera. Oleh karena itu:

- a. Kamera perlu dimiringkan ke bawah dengan sudut tertentu (tergantung tinggi objek dan diameter kamera terhadap objek) untuk memastikan seluruh tubuh masuk dalam bidang pandang.
- b. Sudut elevasi kamera harus disesuaikan secara dinamis jika tinggi spesimen bervariasi secara signifikan, agar kepala tidak terpotong dari frame.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

- c. Pengaturan sudut dan diameter yang kurang tepat dapat menyebabkan distorsi perspektif, seperti atribut tubuh tidak terdeteksi secara utuh, atau objek tampak lebih kecil dari ukuran sebenarnya sehingga memengaruhi hasil klasifikasi.

Ilustrasi pengujian jarak optimal kamera dapat dilihat pada gambar 4.60.



Gambar 4. 60 Ilustrasi pengujian jarak optimal kamera

Pada Gambar 4. 60 posisi kiri, pada gambar ini, kamera diposisikan pada ketinggian 100 cm dari permukaan tanah dan jarak horizontal terhadap objek berada dalam rentang optimal, yaitu sekitar 200–230 cm. Konfigurasi ini menghasilkan akuisisi citra yang baik, di mana seluruh tubuh objek (dari kepala hingga kaki) berhasil tertangkap utuh dengan proporsi yang alami.

Deteksi atribut:



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

- a. *headwear*: hat
- b. *eyewear*: eyeglasses
- c. *upperwear*: jacket
- d. *bottomwear*: pants
- e. *footwear*: shoes

Analisis visual:

- a. Seluruh tubuh terlihat utuh dalam frame tanpa bagian yang terpotong.
- b. Kamera tampak diarahkan sedikit ke bawah, yang sesuai dengan perbedaan tinggi kamera dari tanah 100 cm dan objek memiliki tinggi sekitar 166–191 cm.
- c. Proporsi tubuh tampak natural tanpa distorsi mencolok.
- d. Klasifikasi objek berjalan lengkap dan akurat, menunjukkan bahwa konfigurasi jarak dan sudut kamera berada dalam kondisi optimal.

Pada Gambar 4. 60 posisi kanan, objek secara sengaja mendekat ke kamera, sementara ketinggian kamera tetap 100 cm. Akibat perubahan jarak ini, terjadi pergeseran komposisi visual dan hasil klasifikasi.

Deteksi objek meliputi:

- a. *upperwear*: jacket
- b. *bottomwear*: pants
- c. *footwear*: shoes

Analisis visual:

- a. Bagian kepala tidak terdeteksi, karena objek berada terlalu dekat ke kamera, sehingga bagian atas tubuh keluar dari frame.
- b. Hal ini terjadi bukan karena kesalahan sudut elevasi kamera, tetapi karena jarak yang terlalu dekat mengurangi ruang pandang vertikal, sehingga sistem tidak mampu mencakup seluruh tinggi objek.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

- c. Bila sudut kamera diarahkan lebih ke atas atau ke bawah, bagian lain dari tubuh justru akan terpotong, misalnya kaki atau kepala, yang artinya hasil tetap tidak utuh.
- d. Solusi utama bukan mengatur sudut kamera, tetapi menjaga objek tetap berada dalam rentang jarak optimal, agar seluruh tubuh dapat masuk ke dalam bidang pandang tanpa kehilangan bagian penting.

4.4.2.2 Analisis Hasil Pengujian *Black Box Testing*

1. Prosedur pengujian *Black Box Testing*

Prosedur pengujian *Black Box Testing* sudah dirangkum dan dapat dilihat pada Tabel 4. 44

Tabel 4. 44 Prosedur prosedur pengujian *Black Box Testing*

ID Kasus Uji	Fitur yang Diuji	Skenario Pengujian
BB-GUI-01	Antarmuka Pengguna	Menjalankan aplikasi
BB-GUI-02	Antarmuka Pengguna	Menutup aplikasi
BB-GUI-03	Navigasi Tab	Berpindah antar semua tab
BB-RTC-01	Fitur Utama	Memulai dan menghentikan kamera
BB-RTC-02	Kontrol Deteksi ("Select")	Menonaktifkan dan mengaktifkan klasifikasi sub-kategori
BB-RTC-03	Penanganan Error	Memulai webcam tanpa ada kamera terhubung
BB-IMG-01	Fungsi Utama	Menganalisis gambar standar
BB-IMG-02	Tombol Kontrol	Membersihkan hasil analisis
BB-IMG-03	Penanganan Error	Mengunggah file yang bukan gambar
BB-VID-01	Fungsi Inti Video	Menganalisis file video standar



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

BB-VID-02	Fitur Unggulan	Menganalisis file video vertikal
BB-VID-03	Tombol Kontrol	Menghentikan proses di tengah jalan
BB-LOG-01	Klasifikasi Sigmoid	Menguji deteksi kacamata (bukan kacamata hitam)
BB-LOG-02	Deteksi Warna 3-Titik	Menguji deteksi warna pada jaket dan celana
BB-LOG-03	Robustness Model	Menguji gambar tanpa objek fashion
BB-LOG-04	Kondisi Pencahayaan	Menguji gambar dengan bayangan/gelap
BB-ERR-01	Integritas File Model	Menjalankan aplikasi dengan file model yang hilang

Tabel 4. 44 prosedur pengujian di atas menyajikan daftar skenario pengujian sistem yang digunakan dalam pengujian black box. Setiap baris merepresentasikan satu kasus uji dengan tiga komponen utama: ID Kasus Uji, Fitur yang Diuji, dan Skenario Pengujian.

Kolom ID Kasus Uji menunjukkan kode unik yang mengidentifikasi setiap pengujian secara sistematis berdasarkan kategori fungsionalitas aplikasi. Kolom Fitur yang Diuji menjelaskan bagian atau komponen aplikasi yang menjadi fokus pengujian, seperti antarmuka pengguna, webcam, analisis gambar, video, hingga pengujian logika sistem. Sementara itu, kolom Skenario Pengujian menjabarkan tindakan atau kondisi yang dilakukan untuk menguji fitur tersebut, seperti menjalankan aplikasi, memulai webcam, mengunggah file non-gambar, atau menguji ketahanan sistem terhadap pencahayaan gelap.

Dengan pendekatan black box testing, pengujian ini tidak melihat struktur internal kode, melainkan berfokus pada apakah sistem memberikan output yang sesuai dengan ekspektasi dari input tertentu. Tabel ini penting untuk menjamin seluruh fitur utama dan skenario ekstrem telah diuji, serta



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

memastikan aplikasi berjalan stabil, fungsional, dan responsif terhadap kemungkinan kesalahan pengguna.

2. Analisis dan Hasil *Black Box Testing*

Hasil pengujian *Black Box Testing* sudah dirangkum dan dapat dilihat pada Tabel 4. 45

Tabel 4. 45 Hasil Pengujian Black Box Testing

ID Kasus Uji	Fitur yang Diuji	Skenario Pengujian	Hasil yang Diharapkan	Hasil Pengujian
BB-GUI-01	Antarmuka Pengguna	Menjalankan aplikasi	Aplikasi terbuka tanpa <i>error</i> .	Berhasil
BB-GUI-02	Antarmuka Pengguna	Menutup aplikasi	Aplikasi tertutup dengan bersih.	Berhasil
BB-GUI-03	Navigasi Tab	Berpindah antar semua tab	Tampilan konten berubah sesuai dengan tab yang aktif. Tidak ada <i>error</i> yang terjadi.	Berhasil
BB-RTC-01	Fungsi Inti Webcam	Memulai dan menghentikan kamera	Umpan video dari webcam muncul. Deteksi berjalan. Umpan video berhenti. Tombol berganti status.	Berhasil
BB-RTC-02	Kontrol Deteksi ("Select")	Menonaktifkan dan mengaktifkan klasifikasi sub-kategori	Label deteksi berubah menjadi umum, lalu kembali detail.	Berhasil
BB-RTC-03	Penanganan Error	Memulai webcam tanpa	Muncul pesan <i>error</i> jelas.	Berhasil



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

		ada kamera terhubung	Aplikasi tidak crash.	
BB-IMG-01	Fungsi Inti Gambar	Menganalisis gambar standar	Gambar tampil dengan anotasi dan tabel hasil terisi.	Berhasil
BB-IMG-02	Tombol Kontrol	Membersihkan hasil analisis	Gambar dan tabel hasil menjadi kosong/reset.	Berhasil
BB-IMG-03	Penanganan Error	Mengunggah file yang bukan gambar	Pesan <i>error</i> tampil dan aplikasi tidak crash.	Berhasil
BB-VID-01	Fungsi Inti Video	Menganalisis file video standar	Video diputar dan diproses frame-by-frame, hasil tampil di anotasi dan tabel.	Berhasil
BB-VID-02	Fitur Unggulan	Menganalisis file video vertikal	Video tampil dan diproses dalam orientasi vertikal yang benar.	Berhasil
BB-VID-03	Tombol Kontrol	Menghentikan proses di tengah jalan	Proses berhenti aman, aplikasi kembali siaga, tombol normal.	Berhasil
BB-LOG-01	Klasifikasi Sigmoid	Menguji deteksi kacamata (bukan kacamata hitam)	Label deteksi muncul sebagai 'eyeglasses'.	Berhasil
BB-LOG-02	Deteksi Warna Titik	Menguji deteksi warna pada jaket dengan logo	Warna utama terdeteksi 'Blue', bukan 'White'.	Berhasil



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

BB-LOG-03	Robustness Model	Menguji gambar tanpa objek fashion	Tidak ada objek fashion yang terdeteksi.	Berhasil
BB-LOG-04	Kondisi Pencahayaan	Menguji gambar dengan bayangan/gelap	Deteksi tetap akurat, misalnya biru tua tidak diklasifikasi sebagai hitam.	Berhasil
BB-ERR-01	Integritas File Model	Menjalankan aplikasi dengan file model yang hilang	Pesan <i>error</i> muncul, aplikasi tertutup dengan aman.	Berhasil

Setelah dilakukan pengujian Black box, langkah selanjutnya adalah menghitung tingkat keberhasilan pengujian dalam bentuk persentase. Pada tahap ini, perhitungan persentase keberhasilan dilakukan dengan menggunakan rumus sebagai berikut:

$$\text{Persentase Keberhasilan} = \frac{\text{Jumlah Skenario Uji Berhasil}}{\text{Total Skenario Uji}} \times 100\%$$

Pengujian memiliki 17 skenario uji, berikut jumlah persentase hasil pengujian:

$$\text{Persentase Keberhasilan} = \frac{17}{17} \times 100\% = 100\%$$

Berdasarkan hasil tersebut dapat disimpulkan bahwa aplikasi telah berjalan dengan baik secara fungsional sesuai dengan kebutuhan dan memenuhi seluruh 17 skenario uji yang dirancang.

4.4.2.3 Analisis Hasil Pengujian User Acceptance Test

1. Pengujian *User Acceptance Test*

Prosedur pengujian *User Acceptance Test* sudah dirangkum dan dapat dilihat pada Tabel 4. 46



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

No.	Pertanyaan	Skala				
		1	2	3	4	5
1	Seberapa mudah Anda memahami cara kerja aplikasi ini saat pertama kali menggunakannya.					
2	Seberapa jelas dan mudah dimengerti tampilan antarmuka aplikasi ini menurut Anda.					
3	Seberapa mudah dan intuitif navigasi menggunakan tombol dan menu pada aplikasi ini.					
4	Seberapa akurat aplikasi dalam mengenali kategori utama (atasan, bawahan, kacamata, dsb.).					
5	Seberapa baik aplikasi dalam mengenali sub-kategori (misal: 'jaket', 'kaos', 'kemeja').					
6	Seberapa akurat deteksi warna yang dilakukan aplikasi menurut Anda.					
7	Dibandingkan metode 1 titik, seberapa besar peningkatan akurasi yang diberikan metode 3 titik.					
8	Seberapa berguna aplikasi ini dalam konteks profesional (e-commerce, analisis tren).					
9	Seberapa penting menurut Anda untuk menambahkan fitur seperti rekomendasi palet warna.					



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

10	Jika aplikasi ini memiliki akurasi 95%, seberapa besar kepercayaan Anda untuk menggunakannya.					
11	Seberapa Anda menyukai fitur real-time dalam mengklasifikasikan pakaian.					
12	Seberapa besar keinginan Anda agar aplikasi ini dikembangkan lebih detail.					

Tabel 4.46 di atas adalah instrumen pengujian UAT yang dirancang khusus untuk mengevaluasi aplikasi klasifikasi objek (pakaian). Tujuan dari kuesioner ini adalah untuk mengumpulkan data kuantitatif dari pengguna akhir mengenai aspek-aspek kunci dari aplikasi untuk memvalidasi fungsionalitas dan penerimaannya.

Pertanyaan-pertanyaan ini secara strategis dikelompokkan untuk mengukur beberapa dimensi utama:

- a. **Kemudahan Penggunaan (Usability):** Pertanyaan 1-3 mengevaluasi pengalaman awal pengguna, mulai dari pemahaman cara kerja, kejelasan antarmuka, hingga kemudahan navigasi.
- b. **Akurasi Fungsionalitas Inti:** Pertanyaan 4-7 berfokus pada validasi teknis dari fitur utama aplikasi, yaitu akurasi dalam mengenali kategori, sub-kategori, warna, serta efektivitas metode deteksi yang digunakan.
- c. **Kegunaan dan Konteks Profesional:** Pertanyaan 8 dan 10 mengukur persepsi pengguna tentang relevansi dan kegunaan aplikasi di dunia kerja (seperti e-commerce) serta tingkat kepercayaan untuk mengandalkannya dalam tugas sehari-hari.
- d. **Kepuasan dan Kebutuhan Pengembangan:** Pertanyaan 9, 11, dan 12 menggali tingkat kepuasan terhadap fitur spesifik (seperti *real-time*) dan mengidentifikasi keinginan pengguna untuk pengembangan



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

fitur di masa mendatang (seperti detail kategori dan rekomendasi warna).

Data yang terkumpul dari tabel ini akan menjadi dasar untuk menilai keberhasilan aplikasi dan merumuskan rekomendasi untuk perbaikan atau pengembangan selanjutnya.

2. Analisis dan Hasil *User Acceptance Test*

Hasil pengujian *User Acceptance Test* sudah dirangkum dan dapat dilihat pada Tabel 4. 46.

Tabel 4. 46 Hasil pengujian *user acceptance test*

No.	Pertanyaan	Skala				
		1	2	3	4	5
1	Seberapa mudah Anda memahami cara kerja aplikasi ini saat pertama kali menggunakannya.	0	0	0	0	3
2	Seberapa jelas dan mudah dimengerti tampilan antarmuka aplikasi ini menurut anda.	0	0	0	1	2
3	Seberapa mudah dan intuitif navigasi menggunakan tombol dan menu pada aplikasi ini.	0	0	0	0	3
4	Seberapa akurat aplikasi dalam mengenali kategori utama (atasan, bawahan, kacamata, dsb.).	0	0	0	2	1
5	Seberapa baik aplikasi dalam mengenali sub-kategori (misal: 'jaket', 'kaos', 'kemeja').	0	0	0	2	1
6	Seberapa akurat deteksi warna yang dilakukan aplikasi menurut Anda.	0	0	0	2	1



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

7	Dibandingkan metode 1 titik, seberapa besar peningkatan akurasi yang diberikan metode 3 titik.	0	0	0	2	1
8	Seberapa berguna aplikasi ini dalam konteks profesional (e-commerce, analisis tren).	0	0	0	0	3
9	Seberapa penting menurut Anda untuk menambahkan fitur seperti rekomendasi palet warna.	0	0	0	0	3
10	Jika aplikasi ini memiliki akurasi 95%, seberapa besar kepercayaan Anda untuk menggunakannya.	0	0	0	1	2
11	Seberapa Anda menyukai fitur real-time dalam mengklasifikasikan pakaian.	0	0	0	0	3
12	Seberapa besar keinginan Anda agar aplikasi ini dikembangkan lebih detail.	0	0	0	0	3

Analisis Tabel 4. 46 menyajikan hasil evaluasi *usability* aplikasi berdasarkan data yang diperoleh dari kuesioner *User Acceptance Testing* (UAT) yang diisi oleh 3 (tiga) orang responden. Kerangka kerja yang digunakan untuk evaluasi ini mengacu pada standar internasional ISO 9241-11, yang mengukur *usability* melalui tiga komponen utama: Efektivitas, Efisiensi, dan Kepuasan.

Analisis data dilakukan secara kuantitatif dengan menghitung Indeks Persentase untuk setiap komponen *usability*. Indeks ini diperoleh dengan membandingkan skor total aktual yang diberikan responden dengan skor total ideal atau skor maksimal yang mungkin dicapai.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Rumus umum yang digunakan adalah:

$$P = \frac{\sum S_{\text{aktual}}}{\sum S_{\text{ideal}}} \times 100\%$$

di mana:

P = Indeks Persentase

$\sum S_{\text{aktual}}$ = Jumlah skor total yang diberikan responden untuk semua pertanyaan dalam satu komponen.

$\sum S_{\text{ideal}}$ = Jumlah skor maksimal yang mungkin diperoleh untuk semua pertanyaan dalam satu komponen. (Jumlah Pertanyaan $\times$ Jumlah Responden $\times$ 5).

Berikut adalah perhitungan untuk setiap komponen:

a. Perhitungan Efektivitas (*Effectiveness*)

Komponen ini diukur melalui pertanyaan No. 4, 5, 6, 7, dan 10.

$$S_{\text{aktual}} = (2 \times 4 + 1 \times 5) + (2 \times 4 + 1 \times 5) + (2 \times 4 + 1 \times 5) + (2 \times 4 + 1 \times 5) + (1 \times 4 + 2 \times 5)$$

$$S_{\text{aktual}} = 13 + 13 + 13 + 13 + 14 = 66$$

$$S_{\text{ideal}} = 5 \text{ pertanyaan} \times 3 \text{ responden} \times 5 = 75$$

$$P_{\text{efektivitas}} = \frac{66}{75} \times 100\% = 88.0\%$$

b. Perhitungan Efisiensi (*Efficiency*)

Komponen ini diukur melalui pertanyaan No. 1, 2, 3, dan 11.

$$S_{\text{aktual}} = (3 \times 5) + (1 \times 4 + 2 \times 5) + (3 \times 5) + (3 \times 5)$$

$$S_{\text{aktual}} = 15 + 14 + 15 + 15 = 59$$

$$S_{\text{ideal}} = 4 \text{ pertanyaan} \times 3 \text{ responden} \times 5 = 60$$

$$P_{\text{efisiensi}} = \frac{59}{60} \times 100\% = 98.3\%$$



c. Perhitungan Kepuasan (*Satisfaction*)

Komponen ini diukur melalui pertanyaan No. 8, 9, dan 12.

$$S_{\text{aktual}} = (3 \times 5) + (3 \times 5) + (3 \times 5)$$

$$S_{\text{aktual}} = 15 + 15 + 15 = 45$$

$$S_{\text{ideal}} = 3 \text{ pertanyaan} \times 3 \text{ responden} \times 5 = 45$$

$$P_{\text{kepuasan}} = \frac{45}{45} \times 100\% = 100\%$$

Berdasarkan perhitungan di atas, tingkat efektivitas aplikasi dinilai Sangat Baik dengan mencapai indeks persentase sebesar 88.0%. Hasil ini mengindikasikan bahwa pengguna memandang aplikasi memiliki akurasi yang tinggi dan dapat diandalkan untuk mencapai tujuan fungsionalnya. Meskipun skornya sangat tinggi, data menunjukkan bahwa mayoritas responden memberikan nilai 4 (Baik) daripada 5 (Sangat Baik) pada aspek akurasi, yang menyiratkan bahwa fungsionalitas inti aplikasi bekerja dengan sangat baik namun belum dianggap sempurna oleh pengguna.

Komponen efisiensi menunjukkan hasil yang paling tinggi di antara ketiganya, dengan indeks persentase mencapai 98.3% (Sangat Baik). Skor yang mendekati sempurna ini menegaskan bahwa pengguna merasakan kemudahan yang luar biasa dalam menggunakan aplikasi. Proses untuk memahami cara kerja, menavigasi menu, dan menggunakan fitur-fitur utama seperti fungsi real-time dianggap sangat cepat dan intuitif, sehingga pengguna dapat menyelesaikan tugas dengan usaha dan waktu yang minimal.

Untuk komponen kepuasan, aplikasi berhasil mencapai skor ideal dengan indeks persentase 100% (Sangat Baik). Hal ini menunjukkan tingkat kepuasan pengguna yang absolut. Para responden tidak hanya merasa aplikasi ini berguna untuk kebutuhan profesional mereka, tetapi juga menunjukkan antusiasme dan keinginan yang sangat kuat agar aplikasi terus dikembangkan lebih lanjut. Ini menandakan bahwa aplikasi berhasil memberikan pengalaman pengguna yang sangat positif dan memuaskan.

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



© Hak Cipta milik Politeknik Negeri Jakarta

Secara keseluruhan, hasil analisis usability menunjukkan bahwa aplikasi ini diterima dengan sangat positif oleh pengguna. Kekuatan terbesarnya terletak pada tingkat efisiensi dan kepuasan pengguna yang mendekati sempurna. Sementara itu, efektivitas aplikasi yang sudah sangat baik tetap menjadi area utama yang dapat ditingkatkan lebih lanjut untuk mencapai keunggulan produk secara menyeluruh.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

BAB V

PENUTUP

5.1 Kesimpulan

Penelitian ini telah berhasil mencapai seluruh tujuan yang ditetapkan dengan mengembangkan sebuah sistem multi-tahap yang fungsional untuk mengenali atribut pakaian dan aksesori manusia secara real-time. Implementasi arsitektur YOLOv8 untuk deteksi objek dan MobileNetV2 untuk klasifikasi atribut terbukti sangat efektif. Model deteksi objek menunjukkan performa yang baik dengan nilai mAP@0.5 mencapai 0.797, dengan akurasi yang sangat tinggi pada kategori utama seperti *upperwear*, *bottomwear*, dan *eyewear*. Demikian pula, model-model klasifikasi atribut spesifik menunjukkan kinerja yang sangat andal, dengan akurasi rata-rata di atas 91% untuk semua kategori.

Metode klasifikasi warna yang dikembangkan menggunakan ekstraksi parameter RGB dan model deep learning juga berhasil diimplementasikan, dengan akurasi keseluruhan mencapai 87%. Meskipun model ini sangat baik dalam mengenali warna-warna primer, teridentifikasi adanya tantangan dalam membedakan warna-warna yang lebih ambigu seperti coklat dan abu-abu. Namun, secara fungsionalitas, sistem ini terbukti solid dan matang.

Validasi sistem secara menyeluruh memberikan hasil yang sangat memuaskan. Pengujian Black Box menunjukkan tingkat keberhasilan 100% pada 17 skenario uji, yang mengonfirmasi bahwa aplikasi stabil, bebas dari *error* fungsional, dan mampu menangani input yang tidak sesuai. Lebih lanjut, hasil *User Acceptance Test* (UAT) menegaskan penerimaan pengguna yang luar biasa, dengan skor Efektivitas 88.0%, Efisiensi 98.3%, dan Kepuasan 100%. Angka-angka ini menunjukkan bahwa sistem tidak hanya akurat dan berfungsi sesuai tujuan, tetapi juga sangat mudah digunakan, intuitif, dan memberikan pengalaman yang memuaskan bagi pengguna akhir.

5.2 Saran

Berdasarkan hasil analisis, beberapa saran dapat diajukan untuk penyempurnaan di masa depan. Pertama, untuk meningkatkan performa model, disarankan untuk



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

melakukan penambahan dan diversifikasi data latih. Ini sangat penting untuk kategori deteksi objek dengan performa lebih rendah seperti *bag* dan *headwear*, serta untuk mengatasi kebingungan pada klasifikasi atribut yang visualnya mirip, seperti *sandals* dan *shoes*. Dengan data yang lebih kaya, kemampuan generalisasi model akan meningkat secara signifikan.

Untuk mengatasi kelemahan pada model klasifikasi warna, terutama dalam mengenali warna ambigu, disarankan untuk melakukan eksplorasi di luar ruang warna RGB. Penggunaan ruang warna seperti HSV (*Hue, Saturation, Value*) atau LAB, yang memisahkan komponen warna dari intensitas cahaya, berpotensi besar meningkatkan akurasi dan ketahanan model terhadap kondisi pencahayaan yang bervariasi. Selain itu, metode ekstraksi fitur warna bisa ditingkatkan dari sekadar nilai rata-rata menjadi algoritma yang lebih canggih untuk menemukan warna dominan.

Melihat antusiasme dan kepuasan pengguna yang tinggi dari hasil UAT, pengembangan fitur lanjutan menjadi langkah strategis berikutnya. Penambahan fungsionalitas bernilai tambah seperti rekomendasi palet warna, saran padu padan busana, atau perluasan klasifikasi ke sub-kategori yang lebih detail (misalnya, *sneakers*, *boots*, *denim jacket*) akan sangat meningkatkan nilai guna aplikasi. Terakhir, untuk kesiapan implementasi skala besar, perlu dilakukan optimalisasi model melalui teknik seperti *quantization* atau *pruning* untuk memastikan efisiensi komputasi pada berbagai perangkat, serta menguji ketahanan sistem dalam skenario dunia nyata yang lebih kompleks.

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

DAFTAR PUSTAKA

- Aggarwal, P. (2019). *Fashion Product Images Dataset*. Kaggle. <https://doi.org/10.34740/KAGGLE/DS/139630>
- Andrekhya, M. Z., & Huda, Y. (2021). *Deteksi Warna Manggis Menggunakan Pengolahan Citra dengan Opencv Python*. <http://ejournal.unp.ac.id/index.php/voteknika/index>
- Awotunde, J. B., Misra, S., Obagwu, D., & Florez, H. (2022). Multiple Colour Detection of RGB Images Using Machine Learning Algorithm. *Communications in Computer and Information Science*, 1643 CCIS, 60–74. https://doi.org/10.1007/978-3-031-19647-8_5
- Chauhan, R., Ghanshala, K. K., & Joshi, R. C. (2018). *Convolutional Neural Network (CNN) for Image Detection and Recognition*. Institute of Electrical and Electronics Engineers.
- Gama, J., Žliobaitundefined, I., Bifet, A., Pechenizkiy, M., & Bouchachia, A. (2014). A survey on concept drift adaptation. *ACM Comput. Surv.*, 46(4). <https://doi.org/10.1145/2523813>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>
- Grandini, M., Bagli, E., & Visani, G. (2020). A Survey, a Taxonomy and a Comparison of Metrics for Unbalanced Classification. *Proceedings of the 1st International Conference on Information Technology and Applications*, 2713, 1–12.
- Hacheme, G., & Sayouti, N. (2021). *Neural Fashion Image Captioning: Accounting for Data Diversity*.
- Hossin, M., & Sulaiman, M. N. (2015). A Review on Evaluation Metrics for Data Classification Evaluations. *International Journal of Data Mining & Knowledge Management Process*, 5(2), 1–11.



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Hussien, R. M., Al-Jubouri, K. Q., Gburi, M. Al, Hussein Qahtan, A. G., & Duaa Jaafar, A. H. (2021). Computer Vision and Image Processing the Challenges and Opportunities for new technologies approach: A paper review. *Journal of Physics: Conference Series*, 1973(1). <https://doi.org/10.1088/1742-6596/1973/1/012002>

Kelleher, J. D., Namee, B. Mac, & D'Arcy, A. (2015). *Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples, and Case Studies*. The MIT Press.

Kingma, D. P., & Ba, J. (2014). *Adam: A Method for Stochastic Optimization*.

Le, N., Rathour, V. S., Yamazaki, K., Luu, K., & Savvides, M. (2021). *Deep Reinforcement Learning in Computer Vision: A Comprehensive Survey*. <http://arxiv.org/abs/2108.11510>

Lin, R., Zhou, Z., You, S., Rao, R., & Kuo, C.-C. J. (2020). *From Two-Class Linear Discriminant Analysis to Interpretable Multilayer Perceptron Design*. <http://arxiv.org/abs/2009.04442>

Liu, B., Che, C., Hu, H., Yu, L., Lin, Q., & Zhao, X. (n.d.). *Integration and Performance Analysis of Artificial Intelligence and Computer Vision Based on Deep Learning Algorithms*.

Liu, Z., Luo, P., Qiu, S., Wang, X., & Tang, X. (2016). DeepFashion: Powering Robust Clothes Recognition and Retrieval with Rich Annotations. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1096–1104. <https://doi.org/10.1109/CVPR.2016.124>

Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. *Proceedings of the 27th International Conference on Machine Learning (ICML-10)*, 807–814.

Nayyer, A., Kumar, A., Rajput, A., Patil, S., Kamat, P., Wagle, S., & Choudhury, T. (2024). Color-Driven Object Recognition: A Novel Approach Combining Color Detection and Machine Learning



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Techniques. *EAI Endorsed Transactions on Internet of Things*, 10. <https://doi.org/10.4108/eetiot.5495>

Nwankpa, C., Ijomah, W., Gachagan, A., & Marshall, S. (2018). Activation functions: Comparison of trends in practice and research for deep learning. *ArXiv Preprint ArXiv:1811.03378*.

Padilla, R., Netto, S. L., & da Silva, E. A. B. (2020). A Survey on Performance Metrics for Object-Detection Algorithms. *2020 International Conference on Systems, Signals and Image Processing (IWSSIP)*, 237–242.

Pan, S. J., & Yang, Q. (2010). A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359. <https://doi.org/10.1109/TKDE.2009.191>

Rahman, J. (2024). *IMPLEMENTASI YOLOv5 UNTUK MENGIDENTIFIKASI KEMATANGAN BUAH TOMAT TUGAS AKHIR*.

Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016-December, 779–788. <https://doi.org/10.1109/CVPR.2016.91>

Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 4510–4520. <https://doi.org/10.1109/CVPR.2018.00474>

Sheila, S., Kharil Anwar, M., Saputra, A. B., Pujianto, R., & Sari, I. P. (n.d.). *Deteksi Penyakit pada Daun Padi Berbasis Pengolahan Citra Menggunakan Metode Convolutional Neural Network (CNN)*. <https://www.kaggle.com/datasets/tedisetiady/leaf->



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Yamaganti, R., & Siva, P. N. (2019). *A Review on Python for Data Science, Machine Learning and IOT*.
<https://doi.org/10.13140/RG.2.2.18708.48000>

Zeydan, E., Arslan, S. S., & Liyanage, M. (2024). Managing Distributed Machine Learning Lifecycle for Healthcare Data in the Cloud. *IEEE Access*, 12, 115750–115774.
<https://doi.org/10.1109/ACCESS.2024.3443520>

Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., & He, Q. (2021). A Comprehensive Survey on Transfer Learning. *Proceedings of the IEEE*, 109(1), 43–76. <https://doi.org/10.1109/JPROC.2020.3004555>

Zou, Z., Shi, Z., Guo, Y., & Ye, J. (2023). Object Detection in 20 Years: A Survey. *Proceedings of the IEEE*, 111(3), 257–276.

POLITEKNIK
NEGERI
JAKARTA



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

DAFTAR RIWAYAT HIDUP PENULIS



Dava Alif Rahman David

Lahir di Sleman pada 13 Oktober 2003, kemudian lulus dari SDS Trisula Perwari 3, SMPN 232 Jakarta dan SMKN 7 Jakarta dan sekarang sedang menempuh pendidikan D4 Teknik Informatika di Politeknik Negeri Jakarta.




LAMPIRAN

Lampiran 1 Hasil pelaksanaan UAT

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta






© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta







© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Lampiran 2 Lampiran Pelaksanaan UAT





© Hak Cipta milik Politeknik Negeri Jakarta

Lampiran 3 Analisis Ketinggian Kamera Dan Jarak Kamera



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



TEKNIK
ERI
ARTA



© Hak Cipta milik Politeknik Negeri Jakarta



POLITEKNIK
NEGERI
JAKARTA

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta