

## SURAT KETERANGAN BEBAS PLAGIARISME



**Universitas Nusantara PGRI Kediri**  
**UPT. PERPUSTAKAAN, PUBLIKASI DAN INOVASI**  
Alamat: Kampus 1, Jl. KH. Ahmad Dahlan No.76 Kota Kediri 64112  
Telp. (0354) 771576, (0354) 771503, (0354) 771495, Fax. (0354) 771576  
Website: <http://ppi.unpkediri.ac.id/> Email: [perpustakaan@unpkediri.ac.id](mailto:perpustakaan@unpkediri.ac.id)

---

SURAT KETERANGAN BEBAS SIMILARITY

---

Ketua UPT Perpustakaan, Publikasi dan Inovasi Universitas Nusantara PGRI Kediri menerangkan bahwa mahasiswa dengan identitas berikut:

Nama Mahasiswa : Sherla Dian Mutia  
NPM : 2213030011  
Program Studi : S1-Sistem Informasi

Judul Karya Ilmiah:

“OPTIMASI MODEL YOLOV8N MENGGUNAKAN AUGMENTASI DATA UNTUK PENINGKATAN AKURASI SISTEM DRESS-CODE SURVEILLANCE”

Dinyatakan sudah memenuhi syarat batas maksimal 30% *similarity* sesuai dengan ketentuan yang berlaku pada setiap subbab naskah Laporan **Tugas Akhir/Skripsi/Tesis** yang disusun.

Demikian Surat Keterangan ini kami berikan untuk dapat dipergunakan seperlunya.



Kediri, 18 Juni 2026  
Ka UPT PPI,



Dr. Abdul Aziz Hunaifi, M.A

# Turnitin LLCC

## 2213030011\_Sherla Dian Mutia.docx

 SI-14

---

### Document Details

**Submission ID**

trn:oid::2945:394013295

**Submission Date**

Jun 18, 2026, 12:11 PM GMT+7

**Download Date**

Jun 18, 2026, 12:13 PM GMT+7

**File Name**

2213030011\_Sherla Dian Mutia.docx.pdf

**File Size**

2.8 MB

75 Pages

13,966 Words

93,329 Characters

# 19% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

## Filtered from the Report

- Bibliography

## Top Sources

- 7%  Internet sources
- 7%  Publications
- 18%  Submitted works (Student Papers)

## Integrity Flags

0 Integrity Flags for Review

Our system's algorithms look deeply at a document for any inconsistencies that would set it apart from a normal submission. If we notice something strange, we flag it for you to review.

A Flag is not necessarily an indicator of a problem. However, we'd recommend you focus your attention there for further review.

## Top Sources

- 7% Internet sources
- 7% Publications
- 18% Submitted works (Student Papers)

## Top Sources

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

|    |                |                                                       |     |
|----|----------------|-------------------------------------------------------|-----|
| 1  | Student papers | UPN Veteran Yogyakarta on 2026-05-25                  | <1% |
| 2  | Student papers | Universitas Dian Nuswantoro on 2026-01-09             | <1% |
| 3  | Student papers | UPN Veteran Yogyakarta on 2026-06-04                  | <1% |
| 4  | Student papers | Perpustakaan on 2025-08-07                            | <1% |
| 5  | Student papers | Universitas Islam Indonesia on 2026-06-15             | <1% |
| 6  | Student papers | UPN Veteran Yogyakarta on 2026-04-22                  | <1% |
| 7  | Student papers | UPN Veteran Yogyakarta on 2026-05-05                  | <1% |
| 8  | Student papers | Universitas Islam Riau on 2026-05-13                  | <1% |
| 9  | Student papers | Universitas Islam Negeri Sumatera Utara on 2026-06-18 | <1% |
| 10 | Student papers | Universitas Islam Indonesia on 2026-04-20             | <1% |
| 11 | Student papers | Perpustakaan on 2025-08-06                            | <1% |

|    |                |                                                                                   |     |
|----|----------------|-----------------------------------------------------------------------------------|-----|
| 12 | Student papers | Fakultas Teknik on 2025-08-05                                                     | <1% |
| 13 | Publication    | Devi Fajar Wati, Lila Setiyani, Deden Moch Alfiansyah, M. Jembar Jomantara, De... | <1% |
| 14 | Student papers | Universitas Islam Riau on 2026-06-10                                              | <1% |
| 15 | Student papers | Universitas Muhammadiyah Makassar on 2026-05-11                                   | <1% |
| 16 | Student papers | UNIVERSITAS BUDI LUHUR on 2025-08-19                                              | <1% |
| 17 | Internet       | ejurnal.stmik-budidarma.ac.id                                                     | <1% |
| 18 | Student papers | Universitas Islam Sumatera Utara on 2026-04-20                                    | <1% |
| 19 | Internet       | repository.uin-suska.ac.id                                                        | <1% |
| 20 | Internet       | repository.uinsaizu.ac.id                                                         | <1% |
| 21 | Student papers | UPN Veteran Yogyakarta on 2026-05-04                                              | <1% |
| 22 | Student papers | Universitas Tarumanagara on 2025-12-23                                            | <1% |
| 23 | Student papers | Institut Pertanian Bogor on 2026-01-19                                            | <1% |
| 24 | Student papers | Perpustakaan on 2025-08-07                                                        | <1% |
| 25 | Student papers | Universitas Khairun on 2026-05-11                                                 | <1% |

|    |                |                                                                                  |     |
|----|----------------|----------------------------------------------------------------------------------|-----|
| 26 | Internet       | etheses.uin-malang.ac.id                                                         | <1% |
| 27 | Student papers | Universitas Jember on 2025-12-08                                                 | <1% |
| 28 | Student papers | College of Banking and Financial Studies on 2026-03-04                           | <1% |
| 29 | Publication    | Tri Ahmad Jabar JABAR, Rudi Heriansyah, Evi Purnamasari. "Pengenalan Pola Hur... | <1% |
| 30 | Internet       | jurnal.polibatam.ac.id                                                           | <1% |
| 31 | Internet       | repository.umsu.ac.id                                                            | <1% |
| 32 | Student papers | UPN Veteran Yogyakarta on 2026-05-29                                             | <1% |
| 33 | Internet       | www.journal.lembagakita.org                                                      | <1% |
| 34 | Student papers | Universitas Tarumanagara on 2025-12-24                                           | <1% |
| 35 | Publication    | Ainunnisa Indah Rizqya, Nanda Martyan Anggadimas, Muhammad Misdram. "Ski...      | <1% |
| 36 | Student papers | Universitas Pamulang on 2026-05-02                                               | <1% |
| 37 | Student papers | Universitas Putera Batam on 2026-02-03                                           | <1% |
| 38 | Internet       | jurnal.univrab.ac.id                                                             | <1% |
| 39 | Publication    | Eko Fuji Pangestu -, Bambang Irawan -. "KLASIFIKASI PENYAKIT TANAMAN PADI ...    | <1% |

|    |                |                                                                                |     |
|----|----------------|--------------------------------------------------------------------------------|-----|
| 40 | Student papers | Universitas Islam Indonesia on 2026-05-12                                      | <1% |
| 41 | Student papers | Universitas Pamulang on 2026-04-21                                             | <1% |
| 42 | Student papers | Universitas Singaperbangsa Karawang on 2025-12-14                              | <1% |
| 43 | Internet       | journal.trunojoyo.ac.id                                                        | <1% |
| 44 | Student papers | Universitas Gunadarma on 2025-09-25                                            | <1% |
| 45 | Student papers | Universitas Maritim Raja Ali Haji on 2025-04-21                                | <1% |
| 46 | Student papers | Universitas Sultan Ageng Tirtayasa on 2025-04-08                               | <1% |
| 47 | Internet       | docobook.com                                                                   | <1% |
| 48 | Internet       | repository.its.ac.id                                                           | <1% |
| 49 | Student papers | Fakultas Teknik on 2025-08-07                                                  | <1% |
| 50 | Publication    | Nadlif, Muhammad Naufal. "Model Penurunan Niat Pindah Kerja Berbasis Beban ... | <1% |
| 51 | Student papers | UNIVERSITAS BUDI LUHUR on 2025-07-24                                           | <1% |
| 52 | Student papers | UPN Veteran Jakarta on 2025-12-19                                              | <1% |
| 53 | Student papers | Universitas Muhammadiyah Purwokerto on 2025-11-13                              | <1% |

|    |                |                                                                                      |     |
|----|----------------|--------------------------------------------------------------------------------------|-----|
| 54 | Student papers | Universitas Pancasila on 2025-08-07                                                  | <1% |
| 55 | Student papers | Universitas Tarumanagara on 2025-12-11                                               | <1% |
| 56 | Publication    | Ahmad Rizki Saputra, Rina - Wati, Tri - Susilowati. "KLASIFIKASI STATUS KELAYAKA...  | <1% |
| 57 | Student papers | Universitas Islam Riau on 2025-10-08                                                 | <1% |
| 58 | Internet       | ejurnal.umri.ac.id                                                                   | <1% |
| 59 | Student papers | UPN Veteran Yogyakarta on 2026-05-29                                                 | <1% |
| 60 | Student papers | Universitas Sumatera Utara on 2026-05-21                                             | <1% |
| 61 | Student papers | Universitas Tarumanagara on 2025-12-19                                               | <1% |
| 62 | Publication    | Ananda Rizki Dani, Irma Handayani. "Classification of Yogyakarta Batik Motifs Usi... | <1% |
| 63 | Publication    | Aprilian Gevindo, Syafri Arlis. "Smoker Detection Using the You Only Look Once (Y... | <1% |
| 64 | Student papers | Institut Bisnis dan Teknologi Indonesia (INSTIKI) on 2025-06-29                      | <1% |
| 65 | Publication    | Muhammad Fadli Setiawan. "IMPLEMENTASI ALGORITMA CONVOLUTIONAL NEU...                | <1% |
| 66 | Student papers | Perpustakaan on 2025-08-08                                                           | <1% |
| 67 | Student papers | UPN Veteran Yogyakarta on 2026-05-29                                                 | <1% |



|    |                |                                                                                  |     |
|----|----------------|----------------------------------------------------------------------------------|-----|
| 68 | Publication    | Ulya, Ukhti Karimatul. "Efektivitas Program Pesantren Madrasah Dalam Memben...   | <1% |
| 69 | Student papers | Universitas Sebelas Maret on 2019-05-23                                          | <1% |
| 70 | Internet       | cdn.juris.id                                                                     | <1% |
| 71 | Internet       | dspace.uui.ac.id                                                                 | <1% |
| 72 | Publication    | Achmad Hakim Qoirul Haq, Harminto Mulyo, Adi Sucipto. "Optimasi Kinerja Algor... | <1% |
| 73 | Student papers | Sriwijaya University on 2023-07-21                                               | <1% |
| 74 | Student papers | Universitas Budi Luhur on 2026-01-31                                             | <1% |
| 75 | Student papers | Universitas Katolik Widya Mandala Surabaya on 2025-12-19                         | <1% |
| 76 | Internet       | abs.firat.edu.tr                                                                 | <1% |
| 77 | Internet       | ejournal.unhasy.ac.id                                                            | <1% |
| 78 | Internet       | ijai.iaescore.com                                                                | <1% |
| 79 | Internet       | jurnal.itpln.ac.id                                                               | <1% |
| 80 | Internet       | repository.ipb.ac.id:8080                                                        | <1% |
| 81 | Publication    | Juanto Simangunsong, Nurmala Dewi Simanjuntak, Aprima Anugerah Matondan...       | <1% |

|    |                |                                                                                      |     |
|----|----------------|--------------------------------------------------------------------------------------|-----|
| 82 | Publication    | Noorman Rinanto, Aldi Febriansyah -, Adianto -, Muhammad Khoirul Hasin -, Putri...   | <1% |
| 83 | Student papers | Program Pascasarjana Universitas Negeri Yogyakarta on 2015-10-02                     | <1% |
| 84 | Student papers | Universitas Negeri Medan on 2026-06-17                                               | <1% |
| 85 | Student papers | Universitas Pancasila on 2025-08-10                                                  | <1% |
| 86 | Internet       | docplayer.info                                                                       | <1% |
| 87 | Internet       | ejurnal.seminar-id.com                                                               | <1% |
| 88 | Internet       | repository.telkomuniversity.ac.id                                                    | <1% |
| 89 | Internet       | repository.um-surabaya.ac.id                                                         | <1% |
| 90 | Publication    | Desi Permata Sari, Bambang Irawan. "Implementasi CNN Mobilenetv2 untuk Klas...       | <1% |
| 91 | Publication    | Dita Septyana, Budi Andresi, Nadine Sandra Agustina. "Penerapan GeoAI Berbasi...     | <1% |
| 92 | Publication    | I Gusti Agung Putu Mahendra, Afis Julianto, Agus Tedyyana. "Klasifikasi Citra Top... | <1% |
| 93 | Student papers | Universitas Khairun on 2026-05-04                                                    | <1% |
| 94 | Internet       | digilib.uinsgd.ac.id                                                                 | <1% |
| 95 | Internet       | ejournal.unira.ac.id                                                                 | <1% |

|     |                |                                                                                    |     |
|-----|----------------|------------------------------------------------------------------------------------|-----|
| 96  | Publication    | Evita Evita. "IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK BERBASIS MOB...            | <1% |
| 97  | Student papers | Sekolah Teknik Elektro & Informatika on 2026-01-09                                 | <1% |
| 98  | Student papers | Universitas Gunadarma on 2025-10-14                                                | <1% |
| 99  | Student papers | Universitas Sumatera Utara on 2026-06-04                                           | <1% |
| 100 | Publication    | Wulandari Juslan, Alva Hendi Muhammad. "Evaluasi Kinerja Metode Peningkatan ...    | <1% |
| 101 | Internet       | digilib.unila.ac.id                                                                | <1% |
| 102 | Internet       | eprints.walisongo.ac.id                                                            | <1% |
| 103 | Internet       | epubl.ktu.edu                                                                      | <1% |
| 104 | Student papers | poltekssn on 2025-07-16                                                            | <1% |
| 105 | Internet       | 123dok.com                                                                         | <1% |
| 106 | Student papers | Admin Turnitin UISI on 2025-07-31                                                  | <1% |
| 107 | Publication    | I Dewa Gede Mahesta Parawangsa, Gede Surya Mahendra, Rama Ngurah Putera ...        | <1% |
| 108 | Publication    | Ilham Ismail, Fauzi Nur Maqi, Nur Hidayah. "PC Component Classification Using C... | <1% |
| 109 | Publication    | Muhammad Mauladi, Dedy Hermanto. "Klasifikasi Motif Kain Jumputan Palemba...       | <1% |

|     |                |                                                                             |     |
|-----|----------------|-----------------------------------------------------------------------------|-----|
| 110 | Publication    | Najwa Meyda, Muhammad Tafarel Akbar, Muhamad Nurdin, Septian Handita Sur... | <1% |
| 111 | Student papers | Perpustakaan on 2025-08-26                                                  | <1% |
| 112 | Student papers | Politeknik Negeri Bandung on 2021-08-01                                     | <1% |
| 113 | Student papers | UPN Veteran Yogyakarta on 2026-01-06                                        | <1% |
| 114 | Student papers | Universitas Brawijaya on 2018-08-01                                         | <1% |
| 115 | Student papers | Universitas Brawijaya on 2020-08-31                                         | <1% |
| 116 | Student papers | Universitas Gunadarma on 2025-10-14                                         | <1% |
| 117 | Student papers | Universitas Islam Indonesia on 2025-09-17                                   | <1% |
| 118 | Student papers | Universitas Islam Riau on 2025-12-10                                        | <1% |
| 119 | Student papers | Universitas Jember on 2025-06-04                                            | <1% |
| 120 | Student papers | Universitas Maritim Raja Ali Haji on 2025-01-12                             | <1% |
| 121 | Student papers | Universitas Muhammadiyah Palembang on 2026-06-10                            | <1% |
| 122 | Student papers | Universitas Pamulang on 2025-07-12                                          | <1% |
| 123 | Student papers | Universitas Pamulang on 2026-05-04                                          | <1% |

|     |                |                                          |     |
|-----|----------------|------------------------------------------|-----|
| 124 | Student papers | Universitas Sumatera Utara on 2025-05-23 | <1% |
| 125 | Student papers | Universitas Tarumanagara on 2025-12-11   | <1% |
| 126 | Internet       | digilib.uin-suka.ac.id                   | <1% |
| 127 | Internet       | doku.pub                                 | <1% |
| 128 | Internet       | ejournal.uigm.ac.id                      | <1% |
| 129 | Internet       | ejurnal.lkpkaryaprima.id                 | <1% |
| 130 | Internet       | id.123dok.com                            | <1% |
| 131 | Internet       | joiv.org                                 | <1% |
| 132 | Internet       | journal.pusmedia.com                     | <1% |
| 133 | Internet       | jutif.if.unsoed.ac.id                    | <1% |
| 134 | Internet       | pt.scribd.com                            | <1% |
| 135 | Internet       | repository.uigm.ac.id                    | <1% |
| 136 | Internet       | repository.upstegal.ac.id                | <1% |
| 137 | Internet       | www.scribd.com                           | <1% |

|     |                |                                                                                    |     |
|-----|----------------|------------------------------------------------------------------------------------|-----|
| 138 | Publication    | Benjamin Jason Tantra, Moeljono Widjaja. "Automatic detection of dress-code sur... | <1% |
| 139 | Student papers | FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM on 2026-01-06                        | <1% |
| 140 | Student papers | Institut Teknologi Sumatera on 2025-09-22                                          | <1% |
| 141 | Publication    | Reyga Ferdiansyah Putra, Dadang Iskandar Mulyana. "Optimasi Deteksi Objek De...    | <1% |
| 142 | Student papers | UPN Veteran Yogyakarta on 2025-10-28                                               | <1% |
| 143 | Student papers | UPN Veteran Yogyakarta on 2026-01-06                                               | <1% |
| 144 | Student papers | Universitas Pamulang on 2026-06-08                                                 | <1% |
| 145 | Student papers | Universitas Tarumanagara on 2025-12-21                                             | <1% |
| 146 | Student papers | Christian University of Maranatha on 2025-01-11                                    | <1% |
| 147 | Publication    | Mochammad Fatha Mudzhaffar, Martanto, Arif Rinaldi Dikananda, Ahmad Rifai. "...    | <1% |
| 148 | Student papers | Perpustakaan on 2025-08-06                                                         | <1% |
| 149 | Student papers | Perpustakaan on 2025-09-02                                                         | <1% |
| 150 | Publication    | Poonam Nandal, Tapas Kumar, Meeta Singh, Mamta Dahiya. "Progressive Compu...       | <1% |
| 151 | Student papers | Sekolah Teknik Elektro & Informatika on 2025-07-21                                 | <1% |

|                                      |                |     |
|--------------------------------------|----------------|-----|
| 152                                  | Student papers |     |
| Telkom University on 2026-04-15      |                | <1% |
| 153                                  | Student papers |     |
| UPN Veteran Yogyakarta on 2026-01-30 |                | <1% |
| 154                                  | Student papers |     |
| Universitas Bengkulu on 2025-07-22   |                | <1% |
| 155                                  | Student papers |     |
| Universitas Jember on 2026-01-12     |                | <1% |
| 156                                  | Student papers |     |
| Universitas Pamulang on 2026-05-04   |                | <1% |

26

## BAB I PENDAHULUAN

### Latar Belakang

68

Pendidikan tinggi merupakan fase krusial di mana mahasiswa tidak hanya ditempa secara intelektual, tetapi juga dibentuk etika dan profesionalismenya sebagai persiapan menghadapi dunia kerja yang penuh tantangan. Salah satu bentuk penegakan etika dan disiplin yang paling mendasar di lingkungan akademik adalah penerapan aturan berpakaian (*dress code*). Pakaian yang rapi dan sesuai dengan norma akademik bukan sekadar urusan estetika, melainkan simbol penghormatan terhadap institusi serta mencerminkan kesiapan mahasiswa dalam bersikap profesional. Oleh karena itu, aturan mengenai tata tertib berpakaian selalu dicantumkan dalam pedoman akademik di hampir seluruh perguruan tinggi.

Namun, pada kenyataannya, memastikan ribuan mahasiswa mematuhi aturan tersebut setiap harinya bukanlah tugas yang mudah bagi pihak pengelola institusi. Selama ini, mekanisme pengawasan kepatuhan *dress code* masih dilakukan secara konvensional, di mana personel keamanan atau staf administratif harus berjaga secara fisik di titik-titik masuk utama. Metode manual seperti ini sangat bergantung pada stamina dan konsentrasi manusia yang memiliki ambang batas tertentu. Ketika petugas mengalami kelelahan setelah berjaga berjam-jam, tingkat ketelitian mereka pasti akan menurun, sehingga banyak pelanggaran yang tetap bisa terjadi tanpa mendapatkan teguran yang semestinya.

Masalah lain yang muncul dari pengawasan manual adalah adanya unsur subjektivitas yang sering kali sulit dihindari. Setiap petugas mungkin memiliki interpretasi yang berbeda-beda mengenai kriteria pakaian yang dianggap melanggar aturan, seperti batas kesopanan jenis kain atau potongan pakaian tertentu. Ketidakkonsistenan dalam penegakan aturan ini sering kali memicu keraguan atau rasa tidak adil di kalangan mahasiswa, yang pada akhirnya justru melemahkan wibawa dari peraturan itu sendiri.



Jika standar penilaian berubah-ubah tergantung siapa yang berjaga, maka budaya disiplin yang ingin dibangun tidak akan pernah bisa berjalan dengan efektif dan seragam.

Seiring dengan berkembangnya infrastruktur pendidikan, jumlah kamera pengawas atau CCTV sebenarnya sudah tersebar luas di berbagai titik strategis. Namun, fungsi CCTV tersebut selama ini hanya sebatas alat rekam pasif yang bersifat *post-mortem*, artinya data rekaman baru akan dibuka dan diperiksa jika sudah terjadi insiden keamanan atau pelanggaran berat saja. Potensi besar dari data visual yang dihasilkan oleh kamera-kamera tersebut belum dimanfaatkan secara optimal untuk mendukung fungsi pengawasan yang bersifat preventif dan *real-time*. Padahal, dengan volume data yang begitu besar, sangatlah disayangkan jika teknologi tersebut tidak diberdayakan untuk membantu tugas-tugas administratif rutin seperti pemantauan kedisiplinan.

Oleh karena itu, diperlukan sebuah solusi inovatif yang mampu mentransformasi fungsi pengawasan dari manual menjadi otomatis melalui integrasi teknologi *Computer Vision*. Diperlukan sebuah sistem cerdas yang mampu bertindak sebagai "mata digital" yang bekerja secara kontinu tanpa rasa lelah dan memiliki standar penilaian yang baku berdasarkan algoritma. Dengan membangun sistem *surveillance* yang mampu mendeteksi dan mengklasifikasikan pakaian secara otomatis, institusi dapat menjamin bahwa setiap individu yang masuk ke lingkungan akademik telah memenuhi kriteria yang ditetapkan, sehingga efektivitas pengawasan dapat meningkat drastis tanpa harus menambah beban kerja personel secara fisik.

Urgensi dari penelitian ini berakar pada kebutuhan mendesak akan efisiensi manajerial dalam pengelolaan operasional lingkungan pendidikan di era digital. Pihak institusi tidak bisa lagi hanya mengandalkan penambahan sumber daya manusia secara linier seiring bertambahnya jumlah populasi mahasiswa, karena hal tersebut akan membebani anggaran operasional secara signifikan. Digitalisasi sistem pengawasan melalui

teknologi deteksi objek menjadi langkah strategis untuk menciptakan tata kelola yang lebih ramping, cepat, dan responsif. Otomatisasi ini memungkinkan penegakan aturan tetap berjalan maksimal tanpa perlu kehadiran fisik petugas di setiap titik, sehingga sumber daya yang ada bisa dialokasikan untuk tugas-tugas lain yang lebih strategis.

Dalam pemilihan arsitektur teknologinya, penggunaan model YOLOv8n (*You Only Look Once* versi 8 Nano) menjadi sangat krusial karena tuntutan akan kecepatan proses di lapangan. Dalam skenario pengawasan di gerbang masuk, sistem tidak boleh memiliki jeda atau *delay* yang lama dalam memproses aliran video, karena hal tersebut akan menghambat mobilitas orang yang sedang bergerak cepat. YOLOv8n merupakan model terbaru yang menawarkan efisiensi luar biasa, di mana ia mampu melakukan ekstraksi fitur dan klasifikasi objek dalam satu tahap proses saja. Dengan model yang ringan ini, sistem dapat dijalankan pada perangkat keras yang ekonomis namun tetap mampu memberikan hasil deteksi yang akurat dalam hitungan milidetik secara *real-time*.

Selain aspek kecepatan, penelitian ini mendesak untuk dilakukan guna mengatasi kendala variasi lingkungan yang sering kali menjadi hambatan bagi kecerdasan buatan. Model AI standar sering kali gagal mengenali objek dengan benar jika kondisi pencahayaan berubah, misalnya saat kondisi cuaca mendung atau saat cahaya matahari terlalu terik yang menciptakan bayangan pada objek. Tanpa adanya intervensi berupa optimasi model, sistem deteksi otomatis akan sering menghasilkan kesalahan yang justru akan menambah pekerjaan baru untuk melakukan verifikasi ulang. Oleh sebab itu, optimasi melalui teknik augmentasi data menjadi kunci utama untuk memberikan "ketahanan" pada model agar tetap handal dalam segala kondisi lingkungan.

Secara lebih luas, keberhasilan penelitian ini akan menjadi bukti nyata implementasi konsep teknologi cerdas dalam lingkungan organisasi. Transformasi digital tidak boleh hanya berhenti pada sistem administrasi

online saja, tetapi juga harus menyentuh aspek keamanan dan ketertiban. Dengan adanya sistem yang mampu memantau kepatuhan secara otomatis dan objektif, institusi dapat memberikan standar pelayanan yang lebih modern dan profesional. Penelitian ini bukan sekadar tugas akhir, melainkan sebuah kontribusi nyata dalam mengembangkan sistem keamanan digital yang cerdas dan transparan untuk mendukung efektivitas operasional di masa depan.

Jika meninjau beberapa studi terdahulu yang berkaitan dengan deteksi pakaian, terlihat jelas bahwa teknologi ini masih memiliki ruang besar untuk dikembangkan. Sebagai referensi utama, penelitian yang dilakukan oleh (Tantra & Widjaja, 2025) telah mencoba mengimplementasikan model YOLOv8n untuk pengenalan objek pakaian, namun hasil yang didapatkan menunjukkan performa yang masih terbatas. Nilai *f1-score* yang hanya mencapai 48.6% serta mAP sebesar 51.8% menjadi bukti kuat bahwa model tersebut masih sering mengalami kesalahan dalam mengenali atau membedakan kategori pakaian. Angka-angka ini menunjukkan bahwa masih ada ketidakpastian yang tinggi dalam prediksi sistem, yang tentu saja akan sangat berisiko jika langsung diimplementasikan pada sistem pengawasan nyata.

Kesenjangan atau *research gap* yang sangat menonjol dari penelitian-penelitian sebelumnya adalah kurangnya robustitas model terhadap data yang tidak seimbang serta variasi visual yang kompleks. Banyak model AI dikembangkan menggunakan dataset yang bersifat ideal dan diambil dalam kondisi yang terkontrol. Namun, sebagaimana dijelaskan oleh (Nugroho et al., 2023), masalah *class imbalance* dan kurangnya teknik pengolahan data awal seringkali menjadi penyebab utama kegagalan sistem dalam mengenali objek pada skenario dunia nyata. Tanpa strategi *oversampling* atau augmentasi yang tepat, model cenderung hanya pintar mengenali jenis pakaian yang datanya banyak, namun gagal saat mendeteksi jenis pakaian yang variasi datanya sedikit.

Selain itu, penelitian oleh (Rebekah et al., 2020) mengenai *dress code surveillance* menunjukkan bahwa penggunaan algoritma *deep learning* sering kali terjebak dalam dilema antara akurasi dan kecepatan. Model yang sangat akurat cenderung terlalu berat dan lambat untuk diproses secara *real-time* menggunakan komputer standar, sedangkan model yang ringan sering kali memiliki tingkat akurasi yang rendah. Ada kebutuhan yang belum terjawab mengenai bagaimana cara memaksimalkan kemampuan model yang ringan agar bisa memiliki tingkat akurasi yang setara dengan model yang lebih kompleks. Celah inilah yang ingin dijawab oleh penelitian ini dengan memberikan fokus pada kekuatan pengolahan data melalui teknik augmentasi.

Oleh karena itu, penelitian ini dirancang untuk mengatasi kelemahan-kelemahan tersebut dengan berfokus pada optimasi dataset melalui teknik augmentasi data. Penelitian ini mengeksplorasi manipulasi parameter HSV, flipping, dan mosaic augmentation untuk memperkaya variasi data pelatihan serta meningkatkan kemampuan generalisasi model. Tujuannya adalah untuk menutupi celah performa yang ditemukan pada penelitian sebelumnya. Dengan memperbaiki kualitas data yang dipelajari oleh model, diharapkan masalah rendahnya nilai *f1-score* dapat diatasi secara signifikan, sehingga sistem deteksi objek tidak hanya menjadi sekadar eksperimen, melainkan solusi yang benar-benar handal.

Berdasarkan analisis mendalam terhadap keterbatasan sistem pengawasan manual dan adanya kesenjangan performa pada penelitian-penelitian terdahulu, maka penelitian dengan judul "**Optimasi Model YOLOv8n Menggunakan Augmentasi Data untuk Peningkatan Akurasi Sistem Dress-Code Surveillance**" menjadi sangat krusial untuk dilaksanakan. Penelitian ini hadir sebagai jawaban atas tantangan teknis mengenai bagaimana cara meningkatkan performa deteksi otomatis tanpa harus mengorbankan kecepatan proses. Fokus utama pada tahap augmentasi data merupakan strategi yang paling efisien untuk melatih kecerdasan

buatan agar lebih adaptif terhadap keragaman pakaian dan kondisi lingkungan yang tidak menentu.

Secara teknis, hasil penelitian ini diharapkan dapat memberikan kontribusi signifikan bagi pengembangan sistem informasi, khususnya dalam bidang keamanan digital dan pengawasan otomatis. Dibutuhkan sebuah sistem yang memiliki tingkat presisi tinggi sehingga tidak terjadi kesalahan dalam proses klasifikasi. Melalui optimasi yang dilakukan, sistem ini akan menjadi instrumen penegak disiplin yang sangat objektif karena bekerja berdasarkan parameter data yang telah diuji secara ilmiah, bukan lagi berdasarkan penilaian subjektif yang bisa berubah-ubah setiap saat.

Sebagai penegasan akhir, penelitian ini merupakan langkah nyata dalam mengaplikasikan ilmu sistem informasi untuk memberikan solusi praktis bagi permasalahan pengawasan visual. Dengan tercapainya peningkatan akurasi melalui teknik augmentasi, penelitian ini akan membuktikan bahwa model YOLOv8n tetap bisa menjadi detektor yang sangat handal meskipun dijalankan pada infrastruktur komputasi yang terbatas. Keberhasilan penelitian ini nantinya tidak hanya bermanfaat secara akademik bagi penulis, tetapi juga memberikan landasan teknologi untuk terus berinovasi dalam menciptakan lingkungan yang tertib, disiplin, dan berbasis pada kecanggihan teknologi masa depan.

## B. Batasan Masalah

Penelitian ini hanya berfokus pada pendeteksian kepatuhan *dress-code* di lingkungan kampus, bukan untuk keperluan *surveillance* lainnya.

1. Data citra yang digunakan dalam penelitian ini bersumber dari dataset DeepFashion3 yang diperoleh melalui platform Roboflow (<https://app.roboflow.com/sherla/deepfashion3/4>) dan telah difilter sesuai dengan kelas pakaian yang relevan.
2. Model yang digunakan adalah YOLOv8n dengan optimasi augmentasi data, dan hasilnya dibandingkan dengan *baseline* model dari penelitian sebelumnya.

88

3. Evaluasi performa model menggunakan metrik Precision, Recall, F1-Score, mAP50, dan mAP50-95.
4. Implementasi dilakukan pada lingkungan perangkat lunak (*software*) menggunakan webcam dan gambar statis, belum diintegrasikan dengan sistem CCTV kampus secara langsung.

### C. Rumusan Masalah

27

1. Seberapa akurasi dan performa model YOLOv8n yang dioptimasi dengan augmentasi data dalam mendeteksi kepatuhan *dress-code* dibandingkan dengan baseline model penelitian sebelumnya ?
2. Seberapa efektif penerapan augmentasi data intensif pada model YOLOv8n dalam mengurangi kesalahan klasifikasi antara kelas pakaian yang memiliki kemiripan visual, khususnya *tops* dan *outerwear*, pada berbagai kondisi pencahayaan dan sudut pengambilan gambar?

### D. Tujuan Penelitian

35

27

1. Meningkatkan akurasi YOLOv8n yang dioptimasi dengan augmentasi data dalam mendeteksi kepatuhan *dress-code* serta membandingkannya dengan baseline model penelitian sebelumnya.
2. Menganalisis efektivitas penerapan augmentasi data intensif pada model YOLOv8n dalam mengurangi kesalahan klasifikasi antar kelas pakaian yang memiliki kemiripan visual, khususnya antara *tops* dan *outerwear*, serta menilai konsistensi performa deteksi pada berbagai kondisi pencahayaan dan sudut pengambilan gambar.

15

### E. Manfaat Penelitian

4

Penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam pengembangan bidang *deep learning* dan *Computer Vision* melalui optimasi model YOLOv8n yang mampu mendeteksi kepatuhan *dress-code* secara lebih akurat dan andal. Dengan menerapkan teknik augmentasi data intensif, penelitian ini diharapkan menjadi acuan ilmiah dalam meningkatkan kemampuan model mengenali variasi objek pakaian,

39 khususnya dalam mengurangi kesalahan klasifikasi pada kelas yang  
149 memiliki kemiripan visual serta menjaga konsistensi deteksi pada berbagai  
47 kondisi pencahayaan dan sudut pandang kamera. Hasil perbandingan  
kinerja dengan *baseline model* dari penelitian sebelumnya diharapkan  
dapat menjadi referensi bagi para peneliti lain dalam mengembangkan  
model deteksi objek yang ringan namun tetap memiliki performa optimal  
dan *robust*.

Selain penguatan secara keilmuan, hasil penelitian ini berpotensi  
besar untuk mendukung implementasi sistem pengawasan tata tertib secara  
otomatis, cepat, dan konsisten di lingkungan institusi. Penerapan teknologi  
ini bertujuan untuk membantu meringankan beban kerja operasional  
petugas, meminimalkan subjektivitas manusia dalam penilaian  
pelanggaran, serta menyediakan standar pengawasan yang lebih objektif.  
21 Pada akhirnya, penelitian ini diharapkan dapat menjadi panduan praktis  
81 bagi pengembang sistem dalam membangun teknologi *surveillance*  
berbasis citra yang efisien dan hemat sumber daya komputasi, sehingga  
sangat aplikatif untuk diterapkan sebagai solusi nyata dalam mendukung  
83 ketertiban di lingkungan pendidikan.

## BAB II

### KAJIAN PUSTAKA

#### A. Kajian Teori

##### 1. *Computer Vision* untuk Surveillance

Teknologi *computer vision* dalam ranah pengawasan (*surveillance*) telah bertransformasi menjadi fondasi utama dalam pengembangan sistem keamanan cerdas dan kendaraan otonom melalui kemampuan deteksi objek yang presisi. Integrasi teknik penglihatan komputer tingkat lanjut memungkinkan sistem untuk melakukan segmentasi dan pelacakan subjek secara *real-time*, mengatasi keterbatasan pemantauan manual yang bergantung pada operator manusia (Kalluri et al., 2025). Kemampuan ini sangat krusial dalam mengenali serta menghubungkan subjek di berbagai sudut pandang dan waktu yang berbeda, sehingga memberikan informasi semantik yang lebih mendalam untuk tugas-tugas analisis gambar yang kompleks.

Dalam implementasinya, efektivitas sistem pengawasan sangat bergantung pada performa model deteksi objek seperti YOLO (*You Only Look Once*), terutama saat menghadapi tantangan kondisi pencahayaan rendah pada malam hari. Penelitian terbaru menunjukkan bahwa evolusi model dari YOLOv8 hingga YOLO-NAS difokuskan pada peningkatan akurasi deteksi manusia di bawah iluminasi ambien yang minimal, yang merupakan kebutuhan vital bagi sistem pengawasan nokturnal dan navigasi otomatis (Hendrawan et al., 2023). Optimalisasi pada aspek resolusi spasial dan pemrosesan gambar menjadi kunci dalam mengatasi hambatan teknis yang muncul pada kondisi akuisisi citra yang tidak terkendali.

Pemanfaatan data sintetik kini menjadi strategi krusial dalam melatih model *deep learning* untuk pengawasan video guna mengatasi kendala keterbatasan data riil, seperti bias data dan kesulitan anotasi manual. Penggunaan data buatan ini memungkinkan pengembangan sistem yang lebih tangguh dalam menangani skenario lintas adegan



(*cross-scene*), mulai dari penghitungan kerumunan (*crowd counting*) hingga

pengenalan wajah, tanpa melanggar batasan privasi yang ketat (Delussu et al., 2024). Selain itu, penggunaan wahana tanpa awak (*drone*) sebagai sistem siber-fisik (*Cyber-Physical Systems*) semakin memperluas jangkauan pengawasan berbasis *computer vision*, memberikan mobilitas tinggi untuk pemantauan lingkungan dan infrastruktur secara otomatis (Fawzy et al., 2025).

Meskipun menawarkan efisiensi tinggi, penerapan *computer vision* dalam pengawasan, khususnya di lingkungan kerja, membawa implikasi etis yang signifikan terkait privasi dan kenyamanan individu. Berbeda dengan pengawasan elektronik tradisional, sistem berbasis penglihatan komputer mampu menangkap detail visual yang sangat intim seperti bahasa tubuh dan keadaan emosional, sehingga memerlukan kerangka kerja etis yang mengedepankan transparansi dan keadilan (Sebastian et al., 2025). Di sisi lain, prinsip pengawasan digital ini juga mulai diadopsi dalam sektor layanan masyarakat, seperti sistem pemantauan gizi yang mengintegrasikan data antropometri secara *real-time* untuk memastikan intervensi kesehatan yang lebih sistematis dan terukur (Fadhila et al., 2025).

## 2. Dress-Code Surveillance

Sistem pengawasan aturan berpakaian atau dress-code surveillance merupakan integrasi teknologi pemantauan otomatis yang dirancang untuk memastikan setiap individu mematuhi standar pakaian yang ditetapkan di area tertentu. Pentingnya sistem ini mencakup berbagai sektor, mulai dari keselamatan kerja di area konstruksi yang mewajibkan penggunaan Alat Pelindung Diri (APD) seperti helm dan rompi reflektif (Lyu et al., 2024), hingga lingkungan akademik yang menekankan kedisiplinan dan etika berpakaian mahasiswa (Karthikeyan, 2025). Selain itu, di sektor industri khusus seperti bengkel bersih (*clean workshops*), pengawasan ini krusial untuk

mendeteksi penggunaan peralatan anti-statis guna mencegah kerusakan teknis pada perangkat elektronik akibat listrik statis (Qi Li, 2023).

Secara tradisional, pengawasan aturan berpakaian dilakukan secara konvensional oleh petugas keamanan atau staf administrasi, namun metode ini dinilai memiliki keterbatasan signifikan. Menurut (Tan et al., 2025), pemantauan manual memerlukan intensitas tenaga kerja yang tinggi, memakan banyak waktu, dan sering kali bersifat subjektif sehingga menimbulkan ketidakkonsistenan dalam penegakan aturan. Selain itu, faktor kelelahan manusia menyebabkan kerentanan terhadap kelalaian dalam mendeteksi pelanggaran, terutama di area dengan mobilitas massa yang tinggi seperti pintu masuk kampus atau lokasi proyek yang luas (Basha & Ahamed, 2024).

Untuk mengatasi kelemahan tersebut, perkembangan computer vision dan deep learning menjadi landasan utama dalam otomatisasi sistem pengawasan. Algoritma object detection seperti YOLO (You Only Look Once) dari berbagai versi (v4, v5, hingga v8) menjadi pilihan populer karena kemampuannya dalam memproses data visual secara real-time dengan akurasi yang tinggi (Basha & Ahamed, 2024) (Firdaus et al., 2024a). Di sisi lain, pendekatan menggunakan sensor warna berbasis mikrokontroler seperti Arduino Nano juga dikembangkan oleh (Monye et al., 2025) sebagai solusi perangkat keras yang lebih sederhana untuk mendeteksi warna spesifik pada seragam di titik-titik akses tertentu.

Implementasi sistem ini juga mengedepankan aspek efisiensi dan interpretabilitas melalui arsitektur model yang ringan namun kuat. Penggunaan tulang punggung (backbone) seperti MobileNetV2 dan MobileNetV3 memungkinkan sistem dijalankan pada perangkat tertanam (embedded systems) dengan penggunaan daya yang minimal (Abubakar et al., 2025). Selain itu, penerapan teknologi Explainable Artificial Intelligence (XAI) melalui metode SHAP (SHapley Additive exPlanations) membantu pengguna memahami alasan model

mengklasifikasikan pakaian tertentu sebagai pelanggaran, sehingga transparansi sistem tetap terjaga (Abubakar et al., 2025).


Secara keseluruhan, integrasi infrastruktur CCTV yang sudah ada dengan model AI seperti Temporal Convolutional Networks (TCN) atau YOLOv8 telah terbukti meningkatkan efektivitas pengawasan secara drastis (Karthikeyan et al., 2024; Tan dkk., 2025). Hasil penelitian menunjukkan bahwa sistem otomatis mampu mencapai tingkat presisi yang sangat baik dan secara signifikan mengurangi beban kerja manusia. Dengan adanya mekanisme peringatan instan melalui SMS, email, atau alarm suara, sistem pengawasan ini tidak hanya berfungsi sebagai alat deteksi, tetapi juga sebagai instrumen penegak disiplin dan keselamatan yang lebih objektif dan konsisten (Karthikeyan et al., 2024; Monye et al., 2025).

### 3. Convolutional Neural Network (CNN)

*Convolutional Neural Network* (CNN) merupakan arsitektur jaringan saraf tiruan canggih yang dirancang khusus untuk memproses data dengan struktur grid dua dimensi seperti gambar digital. Berbeda dengan Jaringan Saraf Tiruan (JST) tradisional yang menyusun neuron secara vertikal satu dimensi, CNN menyusun lapisannya secara tiga dimensi yang mencakup dimensi lebar (*width*), tinggi (*height*), dan kedalaman (*depth*). Hal ini memungkinkan model untuk mempertahankan informasi spasial sehingga hubungan antar piksel yang berdekatan tetap terjaga selama proses pembelajaran berlangsung (Adriyanto et al., 2022). Secara fundamental, CNN bekerja dengan meniru cara kerja jaringan saraf biologis manusia untuk mengenali objek secara hierarkis, menjadikannya sangat efektif dalam berbagai aplikasi mulai dari klasifikasi gambar hewan hingga deteksi medis kritis (Wahed et al., 2025).

Proses utama dalam CNN terbagi menjadi dua fase krusial, yaitu fase ekstraksi fitur dan fase klasifikasi. Pada fase ekstraksi fitur, lapisan konvolusi menggunakan filter atau kernel untuk melakukan operasi perkalian matriks yang menghasilkan *feature maps* guna mengenali

pola dari tepi sederhana hingga tekstur kompleks. Setelah itu, lapisan *pooling* (seperti *max-pooling*) bertugas mereduksi dimensi spasial untuk menjaga efisiensi komputasi dan mencegah *overfitting* tanpa kehilangan informasi penting. Selanjutnya, pada fase klasifikasi, *feature map* diubah menjadi vektor linear melalui proses *flattening* untuk dimasukkan ke dalam lapisan terhubung penuh (*fully connected layer*). Di sini, setiap koneksi neuron diberi bobot (*weights*) dan bias guna menentukan keputusan akhir atau label kategori dari citra input (Boudjadar et al., 2025).



Gambar 2. 1 Arsitektur CNN

a. Fase Ekstraksi Fitur (*Feature Extraction*)

Pada fase ini, jaringan bekerja secara otomatis untuk mengenali karakteristik unik dari gambar input melalui dua operasi utama:

- 1) Lapisan Konvolusi (*Convolution*): Tahap awal di mana citra input diproses menggunakan filter (kernel) melalui operasi perkalian matriks. Proses ini menghasilkan *feature maps* yang merepresentasikan atribut gambar, mulai dari deteksi tepi sederhana hingga pola tekstur yang kompleks.
- 2) Lapisan Pooling (*Pooling*): Berfungsi untuk mereduksi dimensi spasial dari *feature maps* guna menjaga efisiensi komputasi dan mencegah pemborosan memori. Teknik ini

75

efektif dalam mencegah terjadinya overfitting, di mana model terlalu menghafal data latih namun gagal dalam menggeneralisasi data baru.

*b. Fase Klasifikasi (Classification)*

Setelah fitur penting berhasil diekstraksi, data masuk ke tahap pengambilan keputusan:


- 1) Lapisan Terhubung Penuh (*Fully Connected*): Sebelum klasifikasi, feature map diubah menjadi vektor linear (flattening) agar dapat dimasukkan ke dalam jaringan saraf. Di sini, sistem membuat keputusan klasifikasi berdasarkan representasi fitur yang telah dipelajari secara hierarkis.
- 2) *Output*: Tahap akhir yang menentukan label kelas atau kategori dari citra input setelah melalui berbagai tahapan abstraksi.

Keberhasilan dan kinerja model CNN sangat bergantung pada pengaturan hyperparameter serta strategi pelatihan yang tepat. Beberapa parameter krusial meliputi jumlah epoch, ukuran filter, fungsi aktivasi seperti ReLU, dan penggunaan dropout untuk meningkatkan stabilitas jaringan. Proses pelatihan melibatkan pembagian data menjadi data latih (training), validasi, dan pengujian untuk memastikan model dapat menggeneralisasi data baru dengan akurat. Selain itu, pengembangan terbaru memungkinkan CNN untuk memiliki kemampuan adaptasi perangkat lunak dengan rekonfigurabilitas perangkat keras, sehingga struktur jaringan dan nilai parameternya dapat disesuaikan saat runtime untuk mengoptimalkan beban komputasi dan akurasi sesuai dengan kebutuhan lingkungan embedded AI (Boudjadar et al., 2025)..

104

#### 4. YOLOv8

YOLOv8 merupakan generasi terbaru dari keluarga algoritma *You Only Look Once* (YOLO) yang dikembangkan oleh Ultralytics, yang menetapkan standar baru dalam hal akurasi dan kecepatan untuk deteksi objek secara *real-time*. Algoritma ini dirancang dengan arsitektur *anchor-free*, yang memungkinkan model untuk memprediksi pusat objek secara langsung tanpa bergantung pada kotak referensi (*anchor boxes*) yang kaku, sehingga meningkatkan efisiensi proses pelatihan dan inferensi (Chen et al., 2024). YOLOv8 memperkenalkan komponen *backbone* baru yang menggunakan struktur C2f (*Cross-Stage Partial Network with 2 Convolutions*) untuk ekstraksi fitur yang lebih kaya, serta mekanisme SPPF (*Spatial Pyramid Pooling - Fast*) untuk memperluas bidang pandang model tanpa mengorbankan kecepatan (Wakhidah et al., 2023).



Gambar 2. 2 Arsitektur YOLOv8

57 Dalam penerapannya, YOLOv8 tersedia dalam berbagai varian skala, di mana YOLOv8n (Nano) menjadi model yang paling efisien untuk perangkat dengan sumber daya komputasi terbatas seperti sistem seluler atau *edge devices* (Andaru & Fudholi, 2024). Meskipun memiliki jumlah parameter yang paling sedikit, varian Nano tetap mampu mempertahankan tingkat presisi yang kompetitif berkat penggunaan *Decoupled Head*. Komponen ini memisahkan tugas klasifikasi dan lokalisasi secara independen, yang terbukti efektif dalam memproses dataset kompleks seperti deteksi sampah di lingkungan perairan (Yanto et al., 2023) maupun pemantauan etika berpakaian di area kampus (Firdaus et al., 2024b).

Efektivitas YOLOv8 juga terlihat pada kemampuannya dalam menangani variasi kondisi lingkungan, termasuk tingkat pencahayaan yang berbeda dan kepadatan objek yang tinggi. Penelitian menunjukkan bahwa optimasi algoritma ini mampu menghasilkan nilai *precision* dan *recall* yang signifikan pada berbagai kasus penggunaan, seperti deteksi masker wajah yang mencapai akurasi hingga 94% (Yanto et al., 2023). Dengan integrasi fungsi aktivasi seperti *Softplus* dan peningkatan pada struktur *neck*, YOLOv8n terus dikembangkan untuk meminimalkan kompleksitas komputasi sekaligus meningkatkan stabilitas pelatihan dalam mendeteksi objek dengan berbagai ukuran (Chen et al., 2024).

## 18 5. Evaluasi Kinerja Model

Evaluasi kinerja model merupakan tahapan penting dalam penelitian berbasis *object detection* untuk mengetahui kemampuan model dalam mendeteksi objek secara akurat. Menurut Alzahrani dkk. (2024), evaluasi model YOLOv8 umumnya dilakukan menggunakan beberapa metrik, yaitu *Precision*, *Recall*, *F1-Score*, *Mean Average Precision* (mAP), dan *Confusion Matrix*. Penggunaan berbagai metrik tersebut bertujuan untuk memberikan gambaran yang lebih komprehensif mengenai performa model, baik dari aspek ketepatan deteksi, kemampuan menemukan seluruh objek target, maupun kualitas lokalisasi objek yang dihasilkan melalui *bounding box*. Oleh karena itu,

29

72

9

metrik evaluasi menjadi komponen penting dalam menentukan tingkat keberhasilan model yang dikembangkan.

a. Precision

Precision merupakan metrik yang digunakan untuk mengukur tingkat ketepatan prediksi model terhadap objek yang berhasil dideteksi. Nilai precision menunjukkan proporsi prediksi positif yang benar dibandingkan dengan seluruh prediksi positif yang dihasilkan model. Semakin tinggi nilai precision, semakin sedikit objek yang salah terdeteksi sebagai target (False Positive). Precision dapat dihitung menggunakan Persamaan berikut:

$$Precision = \frac{TP}{TP+FP} \quad 1$$

Keterangan:

TP (True Positive) = objek yang berhasil dideteksi dengan benar.

FP (False Positive) = objek yang terdeteksi tetapi sebenarnya bukan objek target.

b. Recall

Recall digunakan untuk mengukur kemampuan model dalam menemukan seluruh objek target yang terdapat pada data pengujian. Menurut penelitian yang dipublikasikan dalam jurnal *Sensors* tahun 2025, recall merupakan perbandingan antara jumlah objek yang berhasil dideteksi dengan benar (*True Positive*) terhadap jumlah seluruh objek target yang sebenarnya ada, yaitu gabungan antara *True Positive* dan *False Negative*. Nilai recall yang tinggi menunjukkan bahwa model mampu mendeteksi sebagian besar objek target dan meminimalkan jumlah objek yang terlewatkan selama proses deteksi. Oleh karena itu, metrik ini penting untuk menilai tingkat kelengkapan deteksi yang dihasilkan model.

$$Recall = \frac{TP}{TP+FN} \quad 2$$



Keterangan:

TP (True Positive) = objek yang berhasil dideteksi dengan benar.

FN (False Negative) = objek target yang gagal dideteksi oleh model.

#### c. F1-Score

*F1-Score* merupakan metrik yang menggabungkan nilai *precision* dan *recall* dalam satu ukuran evaluasi. Menurut penelitian Deep Learning-Based Detection of Power Transmission Lines Using YOLOv4 and YOLOv8 (2025), *F1-Score* merupakan rata-rata harmonik dari *precision* dan *recall* yang digunakan untuk mengukur keseimbangan antara ketepatan dan kelengkapan deteksi. Nilai *F1-Score* yang tinggi menunjukkan bahwa model tidak hanya mampu menghasilkan prediksi yang akurat, tetapi juga mampu mendeteksi sebagian besar objek target yang terdapat pada data. Oleh karena itu, metrik ini sering digunakan sebagai indikator keseluruhan performa model dalam tugas deteksi objek.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad 3$$

#### d. mAP50

*Mean Average Precision* pada ambang *Intersection over Union* (IoU) sebesar 0,50 atau mAP50 merupakan salah satu metrik utama dalam evaluasi model deteksi objek. Menurut Alzahrani dkk. (2024), mAP50 diperoleh dari rata-rata nilai *Average Precision* pada seluruh kelas objek dengan menggunakan ambang IoU sebesar 0,50. Pada metrik ini, suatu prediksi dianggap benar apabila area *bounding box* hasil prediksi memiliki tingkat tumpang tindih minimal 50% terhadap *ground truth*. Semakin tinggi nilai mAP50 yang diperoleh, semakin baik kemampuan model dalam mendeteksi dan mengidentifikasi objek yang menjadi target deteksi.

#### e. mAP50-95

mAP50-95 atau  $mAP@[0.5:0.95]$  merupakan metrik evaluasi yang lebih ketat dibandingkan mAP50 karena menggunakan

beberapa ambang IoU mulai dari 0,50 hingga 0,95 dengan interval 0,05. Menurut Alzahrani dkk. (2024), nilai mAP50-95 dihitung dengan merata-ratakan nilai *Average Precision* pada seluruh rentang IoU tersebut sehingga dapat memberikan gambaran yang lebih komprehensif mengenai kemampuan model dalam melakukan lokalisasi objek secara akurat. Metrik ini banyak digunakan sebagai standar evaluasi modern pada penelitian berbasis YOLO karena mampu menilai tidak hanya keberhasilan deteksi objek, tetapi juga ketepatan posisi *bounding box* yang dihasilkan model.

f. Confusion Matrix

*Confusion Matrix* merupakan metode evaluasi yang digunakan untuk menggambarkan hubungan antara hasil prediksi model dengan label sebenarnya dalam bentuk matriks. Menurut penelitian mengenai evaluasi performa YOLOv8 pada deteksi kendaraan secara *real-time*, *Confusion Matrix* dapat digunakan untuk menganalisis jumlah *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) yang dihasilkan model selama proses pengujian. Melalui visualisasi ini, peneliti dapat mengidentifikasi kelas objek yang sering mengalami kesalahan klasifikasi maupun objek yang sulit dideteksi oleh model. Semakin besar nilai yang berada pada diagonal utama matriks, semakin baik kemampuan model dalam melakukan klasifikasi dan deteksi objek secara tepat. Berdasarkan metrik-metrik tersebut, performa model dapat dievaluasi secara menyeluruh baik dari aspek ketepatan klasifikasi maupun kualitas lokalisasi objek.

6. HSV (Hue, Saturation, Value)

Model ruang warna Hue, Saturation, Value (HSV) menawarkan pendekatan yang lebih intuitif dalam pemrosesan citra digital karena strukturnya yang memisahkan elemen kromatik dari intensitas cahaya. Berbeda dengan model RGB yang sangat sensitif terhadap perubahan pencahayaan, HSV mendefinisikan warna melalui tiga parameter independen: *Hue* sebagai representasi jenis warna dalam derajat

lingkaran ( $0^{\circ}$  hingga  $360^{\circ}$ ), *Saturation* sebagai tingkat kemurnian warna, dan *Value* sebagai tingkat kecerahan. Menurut (Kurniastuti et al., 2022), ekstraksi fitur warna berbasis HSV ini memberikan keunggulan signifikan dalam mengenali detail morfologi pada citra yang sangat kompleks, seperti citra histologi ginjal, di mana perbedaan saturasi dan nilai kecerahan menjadi kunci dalam identifikasi struktur jaringan secara akurat.

Dalam aplikasinya pada keamanan informasi, stabilitas kanal *Hue* dan *Saturation* menjadi fondasi penting untuk meminimalkan distorsi visual. Hal ini dimanfaatkan dalam teknik *data hiding* atau penyembunyian data rahasia ke dalam citra digital. Penelitian oleh (Hassan & Gutub, 2022) menunjukkan bahwa dengan mengeksploitasi karakteristik komponen *Hue*, informasi dapat disisipkan dengan tingkat transparansi yang tinggi. Karena persepsi manusia cenderung lebih toleran terhadap perubahan kecil pada kanal warna tertentu di ruang HSV, kualitas visual citra tetap terjaga meskipun telah ditanami data, sehingga mempersulit deteksi oleh pihak yang tidak berwenang.

Fleksibilitas ruang warna HSV menjadikannya parameter input yang sangat handal untuk sistem pengambilan keputusan otomatis berbasis visi komputer. Kemampuannya dalam menangkap esensi warna tanpa terganggu oleh bayangan atau variasi cahaya di lapangan sangat efektif untuk sektor agrikultur. Sebagai contoh, (Sari et al., 2020) mengimplementasikan penggabungan fitur HSV dengan logika *fuzzy* untuk menganalisis kondisi kesehatan daun padi. Dengan memetakan nilai *Hue* dan *Saturation* dari permukaan daun, sistem dapat mengklasifikasikan status nutrisi tanaman secara objektif, yang kemudian digunakan sebagai dasar penentuan dosis pemupukan secara presisi dan efisien..

## 7. *Flipping* (Geometris)

Transformasi geometri dalam domain pengolahan citra digital merupakan fondasi utama dalam manipulasi spasial yang bertujuan

untuk mengoptimalkan representasi visual suatu objek. Menurut (Syahrin et al., 2025), analisis geometri melalui teknik refleksi atau flipping memungkinkan dilakukannya perbaikan terhadap distorsi spasial, deformasi, maupun kesalahan orientasi pada citra. Secara fundamental, proses ini melibatkan pemetaan ulang koordinat piksel berdasarkan sumbu refleksi tertentu, baik secara horizontal maupun vertikal, guna menghasilkan struktur citra yang simetris tanpa mendegradasi integritas informasi warna yang terkandung di dalamnya.

62 Dalam implementasi kecerdasan buatan, teknik flipping memegang peranan krusial sebagai strategi augmentasi data untuk memperkuat performa model klasifikasi. (Mega Nugraha et al., 2025) menegaskan bahwa pada pengenalan pola visual yang kompleks, seperti motif batik, keterbatasan dataset dapat dimitigasi melalui pendekatan augmentasi geometris. Dengan menerapkan teknik pencerminan, model dipaksa untuk mengekstraksi fitur objek dari perspektif spasial yang berbeda, sehingga meningkatkan ketangguhan (robustness) serta kemampuan generalisasi algoritma dalam menghadapi variasi data riil yang dinamis.

45 Signifikansi teknik flipping dalam meningkatkan akurasi diagnosis medis juga teruji secara empiris, khususnya pada identifikasi patologi tumor otak melalui citra MRI. Penelitian (Husen et al., 2024) mengungkapkan bahwa integrasi teknik flip vertikal dan horizontal dalam fase pelatihan model Convolutional Neural Network (CNN) mampu menghasilkan peningkatan akurasi yang substansial, bahkan mencapai performa maksimal pada tingkat konvergensi tertentu. Hal ini mengindikasikan bahwa variasi geometris yang dihasilkan melalui pencerminan mampu memperkaya representasi fitur fitopatologis yang esensial bagi ketajaman analisis model deep learning.

Penerapan transformasi geometris ini memiliki relevansi tinggi dalam sektor pertanian presisi, terutama pada sistem identifikasi penyakit tanaman berbasis visi komputer. (Agustina et al., 2024)

mengintegrasikan teknik augmentasi ini untuk melatih arsitektur DenseNet-121 dalam mengklasifikasikan penyakit pada tanaman padi. Penggunaan flipping memastikan model memiliki sifat invarian terhadap perubahan posisi dan sudut pandang pengambilan gambar di lapangan, sehingga sistem tetap mampu mempertahankan presisi deteksi meskipun objek daun mengalami rotasi atau pencerminan secara alami di lingkungan terbuka.

Sebagai sintesis, efektivitas sistem pengolahan citra, baik untuk klasifikasi objek budaya maupun sistem temu kembali citra (image retrieval), sangat bergantung pada konsistensi ekstraksi fitur bentuk. (Fernanda Wirayudha et al., 2025) menekankan bahwa stabilitas fitur geometri menjadi prasyarat utama dalam klasifikasi objek tradisional, sementara (Tena et al., 2024) memanfaatkan prinsip serupa untuk mengoptimalkan sistem pencarian citra cepat berbasis Locality Sensitive Hashing. Melalui pemanfaatan flipping sebagai instrumen prapemrosesan, sistem visi komputer dapat memastikan bahwa nilai kemiripan visual tetap terjaga secara konsisten, meskipun terjadi perubahan orientasi geometris pada objek sasaran.

## 8. Mosaic

Augmentasi Mosaic merupakan salah satu teknik manipulasi data tingkat lanjut (advanced data augmentation) yang dirancang khusus untuk memperkuat model deteksi objek satu tahap, seperti keluarga algoritma YOLO (You Only Look Once). Berbeda dengan metode augmentasi tradisional yang hanya memodifikasi satu citra tunggal, Mosaic bekerja dengan cara menggabungkan empat gambar pelatihan yang berbeda secara acak ke dalam satu bingkai baru. Menurut (Febriyanti Puspita et al., 2025), mekanisme ini secara otomatis menciptakan variasi skala dan konteks objek yang lebih kaya, karena gambar asli sering kali harus melalui proses pemotongan (cropping) atau penskalaan ulang agar pas dalam satu komposisi. Hal ini memaksa model untuk mempelajari fitur objek dalam lingkungan yang lebih padat

dan bervariasi, yang secara teori meningkatkan ketangguhan model terhadap perubahan posisi objek di dunia nyata.

Dalam implementasi praktisnya, penggunaan augmentasi Mosaic terbukti memberikan dampak signifikan terhadap performa deteksi, terutama dalam mengatasi masalah ketidakseimbangan dataset dan kesulitan mendeteksi objek berukuran kecil. Penelitian oleh (Topan Adib Amrulloh et al., 2024) menunjukkan bahwa penambahan teknik augmentasi pada YOLOv8, termasuk variasi skala dan posisi, mampu meningkatkan efisiensi model dalam mendeteksi gejala penyakit pada tanaman meskipun dengan data yang terbatas. Sejalan dengan hal tersebut, Puspita et al. (2025) mencatat adanya peningkatan skor mAP@50 yang sangat drastis, yakni dari 74,9% menjadi 81,4% pada deteksi objek olahraga. Peningkatan ini terjadi karena teknik Mosaic memungkinkan model untuk berlatih mengenali objek dalam berbagai ukuran kecil yang menyerupai perspektif jarak jauh, sehingga meminimalkan kegagalan deteksi pada objek yang kurang dominan dalam citra.

Teknik Mosaic menjadikannya parameter input yang sangat handal untuk optimasi sistem visi komputer di bawah kondisi lingkungan yang ekstrem. (Homepage & Alfath Zulkarnain, 2025) menyoroti bahwa pada model YOLOv11 yang dioptimasi untuk deteksi kendaraan di malam hari, augmentasi Mosaic membantu model mengekstrak fitur morfologi secara lebih stabil meskipun terdapat gangguan cahaya lampu dan kontras yang rendah. Di sisi lain, penggunaan augmentasi dalam deteksi penyakit tanaman seperti pada porang juga krusial untuk memperluas keberagaman data visual tanpa harus menambah sampel fisik secara manual. (Zuhan & Kristian, 2023) menegaskan bahwa melalui penggabungan data asli dan augmented, model deep learning mampu mencapai akurasi tinggi dalam mengklasifikasikan patogen karena sistem telah terpapar pada ribuan variasi citra yang mensimulasikan kompleksitas kondisi di lapangan.

## B. Kajian Hasil Penelitian Terdahulu

Penelitian oleh (Tantra & Widjaja, 2025) berjudul “Automatic detection of dress-code surveillance in a university using YOLO algorithm” menggunakan algoritma YOLO untuk melakukan pengawasan otomatis terhadap kepatuhan standar berpakaian di lingkungan universitas. Fokus penelitian tersebut terletak pada efisiensi penggunaan sistem pemantauan otomatis untuk menggantikan pengawasan manual, dengan mengandalkan kemampuan dasar model YOLO dalam mengenali atribut pakaian yang sesuai dengan regulasi kampus. Penelitian ini sangat relevan karena memiliki kesamaan domain aplikasi, yakni lingkungan universitas, serta menggunakan keluarga algoritma yang sama untuk mengatasi masalah pengawasan visual.

Namun, penelitian saya memberikan pengembangan yang lebih lanjut dan spesifik dalam hal teknik optimasi akurasi dan granularitas objek. Jika Tantra dan Widjaja lebih berfokus pada deteksi kepatuhan secara umum, penelitian saya melakukan diferensiasi yang lebih detail antara kategori tops dan outerwear, yang merupakan aspek krusial dalam identifikasi pakaian yang berlapis. Selain itu, penelitian saya menerapkan arsitektur YOLOv8n yang diintegrasikan dengan teknik augmentasi Mosaic untuk memperkuat deteksi objek dalam berbagai skala, serta augmentasi HSV dan geometris (flipping) untuk meningkatkan ketahanan model terhadap variasi pencahayaan dan posisi subjek. Pendekatan ini dirancang untuk menghasilkan tingkat presisi yang lebih tinggi dalam mengenali detail pakaian dibandingkan dengan implementasi YOLO standar yang diusulkan oleh Tantra dan Widjaja.

Penelitian oleh (Maliana et al., 2025) berjudul “Real-Time Clothing Detection System Using Optimized YOLOv7 Architecture” menggunakan arsitektur YOLOv7 yang telah dioptimasi untuk mendeteksi berbagai jenis pakaian dalam waktu nyata. Hasilnya menunjukkan bahwa optimasi pada struktur YOLOv7 mampu memberikan keseimbangan yang baik antara kecepatan deteksi dan presisi, khususnya pada dataset pakaian yang beragam. Penelitian ini

sangat relevan karena membahas mengenai efisiensi komputasi dan optimasi model deteksi objek yang merupakan aspek krusial dalam sistem pengawasan otomatis berbasis visi komputer.

Namun, penelitian saya memberikan pembaruan dengan beralih ke arsitektur yang lebih mutakhir, yakni YOLOv8n, yang secara desain lebih ringan dan efisien dibandingkan YOLOv7 untuk penggunaan pada perangkat dengan sumber daya terbatas. Perbedaan utama terletak pada fokus klasifikasi yang lebih tajam, di mana penelitian saya mampu membedakan secara spesifik antara tops (atasan) dan outerwear (pakaian luar). Selain itu, untuk meningkatkan akurasi secara signifikan, saya menerapkan strategi augmentasi data yang lebih kompleks melalui Mosaic untuk pengenalan objek dalam berbagai skala, serta kombinasi HSV dan geometris (flipping) untuk memperkuat ketahanan model terhadap perubahan warna dan orientasi. Pendekatan ini memastikan sistem tetap akurat dalam mengenali jenis lapisan pakaian meskipun dalam kondisi lingkungan yang dinamis, melampaui kemampuan deteksi pakaian umum yang diusulkan pada penelitian sebelumnya.

Penelitian oleh (Firdaus et al., 2024b) berjudul “Deteksi Kode Etik Berpakaian pada Area Kampus Menggunakan YOLOv8” menggunakan arsitektur YOLOv8 untuk memantau kepatuhan berpakaian mahasiswa sesuai dengan regulasi kampus. Hasil penelitian tersebut menunjukkan bahwa penggunaan model YOLOv8 secara standar sudah mampu memberikan performa yang baik dalam mendeteksi atribut pakaian pada area kampus secara *real-time*. Penelitian ini sangat relevan karena menggunakan basis arsitektur model yang sama dengan penelitian saya dan berfokus pada domain pengawasan kode etik berpakaian di lingkungan akademik.

Namun, penelitian saya memberikan kontribusi lebih spesifik pada tahap pra-pemrosesan dan detail klasifikasi objek yang lebih mendalam. Jika Firdaus et al. berfokus pada deteksi kepatuhan secara umum, penelitian saya melakukan diferensiasi yang lebih tajam



untuk membedakan antara kategori tops dan outerwear, yang seringkali menjadi tantangan dalam pengenalan pakaian berlapis. Selain itu, penelitian saya mengoptimasi akurasi melalui penerapan skenario augmentasi yang lebih kompleks, yaitu menggabungkan Mosaic, HSV, dan geometris (flipping) untuk memperkuat sensitivitas model terhadap tekstur, warna, dan variasi skala objek. Penggunaan augmentasi HSV secara khusus bertujuan untuk menangkap fitur warna yang lebih konsisten pada kain meskipun terjadi perubahan intensitas cahaya di lingkungan luar ruangan, sehingga menghasilkan tingkat akurasi yang lebih presisi dibandingkan penggunaan model YOLOv8 tanpa optimasi augmentasi khusus.

Penelitian oleh (Danyalson et al., 2024) berjudul “Perbandingan Arsitektur YOLOv7 dan YOLOv8 untuk Mendeteksi Kerah Baju” melakukan studi komparatif untuk mengevaluasi performa dua arsitektur *deep learning* dalam mengenali detail spesifik pada pakaian, yaitu kerah baju. Hasil penelitian tersebut menyimpulkan bahwa YOLOv8 memiliki keunggulan dalam hal kecepatan dan akurasi rata-rata dibandingkan pendahulunya, YOLOv7, saat menangani objek kecil seperti detail kerah. Penelitian ini memiliki relevansi yang sangat tinggi karena secara teknis menguji efektivitas arsitektur YOLOv8 dalam ranah klasifikasi atribut busana yang membutuhkan ketelitian tinggi.

Namun, penelitian saya memberikan pengembangan yang lebih luas melalui penerapan skenario augmentasi data yang lebih kompleks dan cakupan klasifikasi yang berbeda. Jika Lumentut dan Brave berfokus pada fitur mikro berupa kerah baju, penelitian saya berfokus pada diferensiasi makro antara tops dan outerwear, yang menuntut model untuk memahami batas-batas objek pakaian yang lebih besar namun seringkali tumpang tindih. Peningkatan akurasi dalam penelitian saya tidak hanya bergantung pada keunggulan bawaan arsitektur YOLOv8n, tetapi dioptimasi secara khusus melalui teknik augmentasi Mosaic untuk memperkuat pemahaman spasial, serta kombinasi HSV dan geometris (flipping) untuk memperkaya variasi fitur

warna dan posisi. Langkah ini diambil untuk memastikan model tetap tangguh terhadap tantangan visual seperti pencahayaan yang tidak menentu dan kemiripan tekstur antara atasan dan pakaian luar, yang merupakan pengembangan lebih lanjut dari penggunaan YOLOv8 standar.

Penelitian oleh (Hamidi et al., 2025) berjudul “Comparative Analysis of YOLOv5n and YOLOv8n for Precision Detection” berfokus pada evaluasi performa antara dua generasi model YOLO versi *nano* untuk mengetahui tingkat presisi dalam deteksi objek secara umum. Hasil penelitian tersebut menunjukkan bahwa YOLOv8n memiliki keunggulan performa yang lebih stabil dan efisiensi parameter yang lebih baik dibandingkan YOLOv5n, menjadikannya pilihan ideal untuk aplikasi yang membutuhkan kecepatan tinggi tanpa mengorbankan presisi. Penelitian ini sangat relevan karena memberikan validasi teknis mengenai pemilihan arsitektur YOLOv8n sebagai basis model yang unggul dalam hal efisiensi komputasi untuk deteksi objek presisi.

Namun, penelitian saya melangkah lebih jauh dengan mengimplementasikan strategi optimasi data yang lebih spesifik untuk domain pakaian, yaitu dengan membedakan kategori tops dan outerwear. Jika Hamidi et al. lebih berfokus pada perbandingan *benchmark* antar arsitektur, penelitian saya menguji ketahanan model melalui penerapan skenario augmentasi Mosaic, HSV, dan geometris (flipping) untuk meningkatkan akurasi pada kondisi lingkungan yang menantang. Penggunaan augmentasi HSV dalam penelitian saya secara khusus ditujukan untuk mempertajam perbedaan fitur warna dan bayangan antara lapisan pakaian atasan dan luaran, yang didukung oleh teknik Mosaic untuk meningkatkan kemampuan model dalam mengenali objek dalam berbagai skala kepadatan. Hal ini menghasilkan sistem deteksi yang tidak hanya memiliki dasar arsitektur yang kuat, tetapi juga memiliki spesialisasi fitur yang lebih tajam dibandingkan pengujian model YOLOv8n standar yang dilakukan oleh Putra et al.

Penelitian oleh (Mulyana & Ferdiansyah Putra, 2024) dalam jurnal yang berjudul “Optimasi Deteksi Objek Dengan Segmentasi dan Data Augmentasi Pada Hewan Siput Beracun Menggunakan Algoritma You Only Look Once (YOLO)” berfokus pada peningkatan kinerja model deteksi melalui integrasi teknik instance segmentation dan berbagai metode augmentasi data untuk memperkuat pemahaman model terhadap batas-batas objek 10 jenis siput beracun. Hasil penelitian tersebut menunjukkan bahwa penggunaan augmentasi yang tepat, seperti flip (horizontal dan vertikal) serta rotasi 90 derajat (clockwise, counter-clockwise, dan upside down), secara signifikan meningkatkan keragaman data pelatihan dan menghasilkan model dengan akurasi tinggi, mencapai nilai  $mAP@0.5$  sebesar 0.987. Penelitian ini sangat relevan karena memberikan bukti empiris mengenai peran krusial manipulasi data dalam proses pelatihan model berbasis YOLOv8 untuk mencapai optimasi deteksi dan segmentasi yang akurat.


Namun, penelitian saya memberikan fokus yang lebih spesifik pada implementasi arsitektur YOLOv8n dan diferensiasi objek pakaian yang lebih detail, yaitu antara kategori tops dan outerwear. Jika Mulyana & Putra membahas optimasi objek melalui segmentasi pada domain biologi (siput), penelitian saya lebih menitikberatkan pada optimasi fitur visual melalui kombinasi spesifik augmentasi Mosaic, HSV, dan geometris (flipping) untuk meningkatkan akurasi deteksi pada variasi pencahayaan dan posisi di industri fesyen. Penggunaan augmentasi HSV dalam penelitian saya secara khusus dirancang untuk menangkap kontras warna dan tekstur yang membedakan antara atasan dan pakaian luar, sementara teknik Mosaic digunakan untuk memperkaya konteks spasial objek. Hal ini menghasilkan sistem yang tidak hanya teroptimasi secara general, tetapi juga memiliki akurasi yang lebih tajam dalam mengenali detail lapisan pakaian dibandingkan dengan pendekatan augmentasi standar (seperti rotasi dan flip saja) yang dibahas dalam penelitian Mulyana & Putra.

Penelitian oleh (Ehineni et al., 2024) berjudul “Fake Clothing Detection Using Deep Learning Method” berfokus pada penggunaan metode *deep learning* untuk mendeteksi pakaian palsu atau imitasi melalui analisis fitur visual. Hasil penelitian tersebut menekankan pada kemampuan model untuk mengenali perbedaan tekstur dan detail halus yang menjadi ciri khas produk pakaian tertentu guna keperluan autentikasi. Penelitian ini memiliki relevansi dalam hal penggunaan visi komputer untuk menganalisis material busana, namun cakupannya lebih ditekankan pada aspek keamanan dan perlindungan merek melalui identifikasi keaslian barang.

Namun, penelitian saya memberikan kontribusi yang berbeda dengan berfokus pada fungsi pengawasan dan klasifikasi struktural pakaian menggunakan arsitektur YOLOv8n. Jika Ahmad dan Sani berkonsentrasi pada deteksi keaslian produk, penelitian saya lebih menitikberatkan pada kemampuan model dalam membedakan kategori fungsional antara tops dan outerwear untuk kebutuhan monitoring. Selain itu, peningkatan akurasi dalam penelitian saya dilakukan melalui skenario augmentasi yang sangat spesifik, yaitu Mosaic untuk pengenalan dalam berbagai skala kepadatan, serta HSV dan geometris (flipping) untuk memperkuat ketahanan model terhadap perubahan warna dan posisi subjek. Penggunaan augmentasi HSV dalam penelitian saya menjadi kunci untuk mengekstraksi fitur pencahayaan yang membedakan lapisan pakaian, sehingga menghasilkan sistem yang lebih unggul dalam pengenalan jenis busana dibandingkan dengan metode deteksi pakaian yang difokuskan pada autentikasi merek seperti yang dilakukan oleh Ahmad dan Sani.

102

### C. Kerangka Berpikir



Gambar 2. 3 Kerangka Berpikir

Penelitian ini secara mendasar bertitik tolak dari adanya urgensi untuk mengatasi inefisiensi pada sistem pengawasan tata tertib mahasiswa, khususnya mengenai kepatuhan *dress-code*. Selama ini, pengawasan dilakukan sepenuhnya secara manual oleh personel keamanan, yang dalam implementasinya menghadapi dua kendala utama: keterbatasan fisik manusia dalam memantau secara terus-menerus (*human fatigue*) dan adanya subjektivitas penilaian yang menyebabkan penegakan aturan menjadi tidak konsisten. Secara teknis, pengawasan manual juga sangat rentan terhadap kesalahan klasifikasi saat menghadapi item pakaian yang memiliki karakteristik visual serupa, seperti perbedaan tipis antara atasan biasa (*tops*) dan pakaian luar (*outerwear*). Kondisi ini mempertegas perlunya sebuah inovasi teknologi berupa sistem deteksi otomatis yang tidak hanya cepat dalam memproses data, tetapi juga memiliki akurasi tinggi serta mampu beroperasi dengan stabil di lingkungan kampus yang memiliki latar belakang visual yang kompleks.

Dalam upaya mencari solusi teknologi tersebut, tinjauan terhadap berbagai studi terdahulu menunjukkan bahwa algoritma berbasis

106

80

*Convolutional Neural Network* (CNN) dan *You Only Look Once* (YOLO) telah mulai diterapkan untuk identifikasi pakaian. Namun, ditemukan sebuah celah besar (*research gap*) dalam hal performa model saat dihadapkan pada skenario dunia nyata. Merujuk pada penelitian Tantra dan Widjaja (2025), penggunaan model YOLOv8n masih menghasilkan nilai *f1-score* yang rendah yaitu 45% dan mAP sebesar 51,8%. Hal ini disebabkan oleh keterbatasan model dalam mengenali objek pada variasi lingkungan yang dinamis serta kegagalan dalam melakukan diskriminasi fitur pada pakaian yang mirip. Sementara itu, pendekatan berbasis CNN murni hanya terbatas pada klasifikasi gambar secara global tanpa kemampuan lokalisasi objek secara spasial, sehingga tidak mampu memenuhi kebutuhan sistem pengawasan *real-time* yang memerlukan informasi posisi dan jenis pelanggaran secara simultan.

15

Menyikapi keterbatasan tersebut, penelitian ini mengajukan strategi optimasi pada arsitektur YOLOv8n melalui penerapan teknik augmentasi data intensif. Pemilihan strategi ini didasarkan pada hipotesis bahwa pengayaan dataset melalui manipulasi Hue, Saturation, Value (HSV), flipping, dan mosaic augmentation secara sistematis akan meningkatkan keberagaman fitur yang dipelajari oleh model. Melalui augmentasi yang variatif, model dilatih untuk memiliki *robustness* atau ketahanan yang lebih baik terhadap gangguan pencahayaan, perbedaan sudut pandang kamera CCTV, serta gangguan latar belakang (*cluttered background*). Hal ini menjadi kunci utama untuk meningkatkan kemampuan generalisasi model sehingga kesalahan klasifikasi yang dialami pada penelitian-penelitian sebelumnya dapat diminimalisir secara signifikan.

Secara metodologis, alur penelitian ini disusun secara sistematis mulai dari tahap persiapan dataset menggunakan DeepFashion3 yang telah difilter agar sesuai dengan konteks *dress-code* kampus. Langkah selanjutnya meliputi anotasi *bounding box* yang presisi, diikuti dengan implementasi skenario augmentasi data intensif sebelum memasuki tahap

42

pelatihan model YOLOv8n yang dioptimasi. Untuk menjamin kualitas hasil, evaluasi model dilakukan secara komprehensif menggunakan metrik standar industri seperti *precision*, *recall*, *mAP50*, dan *mAP50-95*. Hasil akhir dari pelatihan ini kemudian dikomparasikan secara langsung dengan *baseline model* dari studi terdahulu untuk mengukur sejauh mana intervensi pada tahap augmentasi data mampu mendongkrak performa deteksi.


96

Melalui seluruh kerangka berpikir ini, dapat disimpulkan bahwa optimasi YOLOv8n merupakan langkah strategis yang didasarkan pada kebutuhan nyata akan sistem deteksi yang akurat dan *robust*. Dengan mengintegrasikan kekuatan arsitektur YOLO yang cepat dan teknik pengolahan data yang dioptimasi, penelitian ini diharapkan mampu menghasilkan sistem *dress-code surveillance* yang konsisten dan andal. Hasil akhir dari penelitian ini tidak hanya berhenti pada peningkatan metrik akurasi di atas kertas, tetapi juga bertujuan menghasilkan solusi teknologi yang siap diterapkan secara *real-time* untuk mendukung penegakan disiplin dan profesionalisme di lingkungan institusi pendidikan secara modern.

### BAB III

#### METODE PENELITIAN

Metodologi yang diimplementasikan dalam penelitian ini mengadopsi standar industri CRISP-DM (*Cross-Industry Standard Process for Data Mining*). Penggunaan kerangka kerja ini bertujuan untuk menjamin alur penelitian yang sistematis, mulai dari identifikasi kebutuhan institusional hingga validasi model deteksi objek secara empiris.



Gambar 3. 1 Alur Penelitian

#### A. Business Understanding

##### 1. Latar Belakang Masalah Bisnis

Efektivitas penegakan disiplin *dress-code* di lingkungan universitas saat ini masih terkendala oleh keterbatasan sumber daya manusia dan tingginya tingkat subjektivitas pengawasan manual. Ketidakmampuan petugas dalam menjaga konsistensi pengawasan selama jam operasional penuh menyebabkan perlunya transformasi menuju sistem pengawasan digital yang objektif dan kontinu.



## 2. Tujuan Bisnis

Tujuan utama dari inisiatif ini adalah mengotomasi proses pemantauan kepatuhan atribut pakaian mahasiswa melalui integrasi teknologi *Computer Vision*. Hal ini diharapkan dapat mereduksi beban kerja operasional personel keamanan serta menyediakan basis data kepatuhan yang lebih akurat untuk mendukung pengambilan kebijakan kedisiplinan oleh pihak dekanat atau rektorat.

## 3. Kriteria Keberhasilan Proyek

Proyek ini dinyatakan berhasil apabila model mampu melampaui metrik performa penelitian sebelumnya, dengan target nilai  $mAP@0.5$  yang signifikan (berdasarkan data eksperimen mencapai 0.954) serta mampu meminimalisir misklasifikasi pada kelas-kelas yang memiliki kemiripan fitur visual tinggi.

# B. Data Understanding

## 1. Pengumpulan Data

Dataset primer diperoleh melalui repositori DeepFashion3 via platform Roboflow. Penggunaan dataset ini didasarkan pada kekayaan anotasi dan variasi gaya busana yang mencakup ribuan sampel citra dunia nyata.

## 2. Deskripsi Data

Data terdiri dari citra digital multispektra dengan label kategori pakaian yang beragam. Berdasarkan kurva evaluasi, kelas yang diidentifikasi mencakup *long/short sleeve dress*, *long/short sleeve top*, *outerwear*, *trousers*, hingga *vest*. Setiap sampel data memiliki anotasi *bounding box* yang mendefinisikan lokasi spasial objek dalam frame gambar.

## 3. Eksplorasi Data Awal

Analisis awal menunjukkan adanya tantangan pada kelas-kelas dengan fitur tumpang tindih, seperti *long sleeve top* dan *long sleeve outerwear*. Melalui kurva *Confusion Matrix*, ditemukan bahwa tingkat pengenalan pada beberapa kelas seperti *long sleeve top* mencapai akurasi 89%, namun masih terdapat potensi misklasifikasi dengan latar belakang (*background*) sebesar 15%.

## 4. Verifikasi Kualitas Data



Dilakukan audit kualitas citra untuk memastikan tidak ada redundansi data dan memastikan label sesuai dengan standar pakaian akademik. Data divalidasi terhadap variasi pencahayaan dan sudut pandang guna menjamin model yang dihasilkan bersifat *robust*.

### C. Data Preparation

#### 1. Seleksi Data

Proses filtrasi dilakukan untuk memilih kelas pakaian yang relevan dengan aturan *dress-code* kampus Kediri, dengan fokus pada pakaian formal dan semi-formal.

#### 2. Pembersihan Data (Cleaning)

Dilakukan penyesuaian label (*re-labeling*) pada citra yang memiliki ambiguitas tinggi guna memastikan proses pembelajaran mesin memiliki dasar kebenaran (*ground truth*) yang presisi.

#### 3. Transformasi Data (Augmentasi Data Intensif)

Penelitian ini menerapkan skenario augmentasi agresif untuk memperkaya variasi *dataset* secara artifisial tanpa kehilangan informasi fitur inti. Berdasarkan parameter konfigurasi train, teknik yang diterapkan meliputi:

- a. Mosaic Augmentation: Ditetapkan pada nilai 1.0 untuk menggabungkan empat citra pelatihan, meningkatkan kemampuan model mendeteksi objek dalam konteks ruang yang padat.
- b. HSV Manipulation: Modifikasi *Hue* (0.015), *Saturation* (0.7), dan *Brightness/Value* (0.4) untuk mensimulasikan perubahan kondisi cuaca di lapangan.
- c. Geometric Transformation: Penerapan *horizontal flipping* (0,5) guna meningkatkan kemampuan model dalam mengenali objek pakaian pada berbagai orientasi dan posisi pengambilan gambar. Teknik ini membantu model menjadi lebih robust terhadap perubahan sudut pandang kamera tanpa mengubah karakteristik utama objek yang dideteksi.

#### 4. Pembuatan Data Set Modeling

Data dipartisi menjadi sub-himpunan *training*, *validation*, dan *testing* dengan input resolusi gambar sebesar 640x640 piksel untuk menjaga keseimbangan antara detail fitur dan beban komputasi.

### D. Modeling

#### 1. Pemilihan Teknik Model

Dipilih arsitektur YOLOv8n (*Nano*) yang merupakan model *state-of-the-art* dalam deteksi objek real-time. Model ini dipilih karena efisiensi parameternya yang memungkinkan inferensi cepat pada perangkat dengan sumber daya terbatas.

#### 2. Desain dan Pengujian Model

Pelatihan dijalankan selama 100 epoch menggunakan *optimizer* otomatis dengan ukuran *batch* sebesar 16. Eksperimen dilakukan pada lingkungan Google Colab dengan dukungan akselerator GPU A100 yang memiliki RAM GPU sebesar 40.0 GB untuk memastikan stabilitas proses pelatihan skala besar.

#### 3. Evaluasi Parameter Model

Konfigurasi teknis mencakup penggunaan *Initial Learning Rate* ( $lr_0$ ) sebesar 0.01 dan *IoU Threshold* sebesar 0.7 untuk memastikan kotak pembatas (*bounding box*) yang dihasilkan memiliki presisi tinggi terhadap objek asli.

#### 4. Interpretasi Hasil Modeling

Interpretasi hasil modeling dilakukan melalui analisis metrik evaluasi seperti Precision, Recall, F1-Score, mAP50, dan mAP50-95. Selain itu, digunakan visualisasi berupa grafik hasil pelatihan (*results curve*), *F1-Confidence Curve*, dan *Confusion Matrix* untuk mengidentifikasi performa model dalam mendeteksi setiap kategori pakaian.

### E. Evaluation

#### 1. Evaluasi Model Terbaik

Evaluasi model dilakukan menggunakan metrik Precision, Recall, F1-Score, mAP50, dan mAP50-95. Selain itu, digunakan visualisasi berupa Precision-Recall Curve, F1-Confidence Curve, dan Confusion Matrix untuk menilai kemampuan model dalam mendeteksi setiap kategori pakaian secara akurat.

## 2. Validasi Model terhadap Tujuan Bisnis

Validasi model dilakukan dengan membandingkan hasil evaluasi teknis terhadap tujuan bisnis penelitian, yaitu menghasilkan sistem pengawasan dress-code yang mampu mendeteksi kategori pakaian secara otomatis, objektif, dan konsisten pada berbagai kondisi pengambilan gambar.

## 3. Tinjauan Ulang Proses CRISP-DM

Tahap ini dilakukan untuk meninjau kembali seluruh proses CRISP-DM yang telah diterapkan, mulai dari Business Understanding hingga Modeling. Tinjauan dilakukan untuk mengidentifikasi potensi perbaikan pada kualitas data, proses pelatihan model, maupun strategi augmentasi yang digunakan.

# F. Deployment

## 1. Rencana Penerapan Hasil

Model yang telah dilatih (*best.pt*) akan diintegrasikan ke dalam sistem *monitoring* berbasis Python untuk pengujian *real-time* di lingkungan kampus.

## 2. Implementasi Model

Implementasi model direncanakan menggunakan input webcam sebagai sumber data visual. Model yang telah dilatih akan digunakan untuk mendeteksi kategori pakaian secara real-time melalui proses inferensi menggunakan file model terbaik (*best.pt*).

## 3. Dokumentasi dan Pelaporan

Seluruh hasil pelatihan dan evaluasi model didokumentasikan dalam bentuk grafik performa, confusion matrix, file konfigurasi pelatihan, serta model hasil training. Dokumentasi tersebut digunakan sebagai dasar analisis dan pelaporan hasil penelitian pada tahap selanjutnya.

## BAB IV

### HASIL DAN PEMBAHASAN

#### A. Data Hasil Penelitian

##### 1. Hasil Eksplorasi Data

Dataset yang digunakan dalam penelitian ini berasal dari DeepFashion3 yang diperoleh melalui platform Roboflow. Dataset tersebut dipilih karena memiliki variasi kategori pakaian yang cukup beragam serta sesuai dengan kebutuhan penelitian dalam pengembangan sistem *dress-code surveillance*. Selain menyediakan berbagai jenis pakaian dengan karakteristik visual yang berbeda, dataset ini juga telah dilengkapi dengan anotasi yang memungkinkan model mempelajari bentuk, posisi, dan karakteristik objek secara lebih detail. Seluruh data pada dataset telah melalui proses anotasi menggunakan metode *instance segmentation*, sehingga setiap objek pakaian memiliki batas area yang jelas dan presisi. Metode anotasi ini dipilih karena mampu memberikan informasi spasial yang lebih lengkap dibandingkan anotasi berbasis *bounding box*, terutama dalam membedakan kategori pakaian yang memiliki kemiripan visual seperti *tops* dan *outerwear*.

Berdasarkan hasil analisis dataset pada platform Roboflow, dataset yang digunakan terdiri dari 5.000 citra dengan total 8.088 anotasi objek pakaian yang tersebar ke dalam 13 kelas. Jumlah anotasi yang lebih besar dibandingkan jumlah citra menunjukkan bahwa dalam satu gambar dapat terdapat lebih dari satu objek pakaian yang dianotasi. Kondisi ini memberikan keuntungan dalam proses pelatihan karena model dapat mempelajari berbagai kombinasi objek pakaian yang muncul secara bersamaan dalam satu citra. Selain itu, keberagaman objek pada dataset juga memungkinkan model untuk mengenali berbagai bentuk, ukuran, tekstur, serta posisi pakaian yang berbeda-beda.

Hasil analisis lebih lanjut menunjukkan bahwa rata-rata jumlah objek pada setiap citra adalah 1,6 objek per gambar. Nilai tersebut mengindikasikan bahwa sebagian besar citra tidak hanya memuat satu objek pakaian, tetapi juga mengandung beberapa objek yang dapat muncul secara bersamaan. Keberagaman ini menjadi salah satu faktor yang mendukung proses pembelajaran model karena mampu meningkatkan variasi data yang diterima selama pelatihan. Dengan demikian, model diharapkan dapat memiliki kemampuan generalisasi yang lebih baik ketika dihadapkan pada data baru yang belum pernah dilihat sebelumnya.


Dari sisi kualitas data, hasil analisis Roboflow menunjukkan bahwa dataset tidak memiliki missing annotation maupun null example. Hal ini menandakan bahwa seluruh citra telah memiliki anotasi yang lengkap dan tidak terdapat data kosong yang berpotensi mengganggu proses pelatihan model. Kualitas anotasi yang baik sangat penting dalam penelitian berbasis *deep learning* karena secara langsung memengaruhi kemampuan model dalam mempelajari pola dan karakteristik objek yang terdapat pada dataset. Oleh karena itu, dataset DeepFashion3 yang digunakan dalam penelitian ini dinilai telah memenuhi kebutuhan dasar untuk proses pelatihan dan evaluasi model YOLOv8n.

Selain informasi jumlah data dan anotasi, hasil analisis juga menunjukkan bahwa dataset memiliki variasi ukuran dan resolusi gambar yang cukup beragam dengan rata-rata resolusi sekitar 0,39 megapiksel. Variasi tersebut memberikan keuntungan bagi model untuk mempelajari objek pakaian pada berbagai kondisi visual, sehingga model tidak hanya bergantung pada satu ukuran atau kualitas gambar tertentu. Ringkasan karakteristik dataset yang digunakan dalam penelitian ini dapat dilihat pada Gambar 4.1.

## Dataset Analytics

Generated on May 15, 2026 at 2:26 pm [Regenerate](#)

|                                                                                    |                                                                                                 |                                                                           |                                                         |
|------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------|---------------------------------------------------------|
| <b>Number of Images</b><br><b>5000</b><br>0 missing annotations<br>0 null examples | <b>Number of Annotations</b><br><b>8088</b><br>1.6 per image (average)<br></> Across 13 classes | <b>Average Image Size</b><br><b>0.39 mp</b><br>from 0.01 mp<br>to 1.29 mp | <b>Median Image Ratio</b><br><b>640x702</b><br>4:3 tall |
|------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------|---------------------------------------------------------|



Gambar 4. 1 Dataset Analytics DeepFashion3

Berdasarkan Gambar 4.1, dapat diketahui bahwa dataset tidak memiliki missing annotation maupun null example, yang menunjukkan bahwa seluruh data telah memiliki anotasi yang lengkap dan siap digunakan dalam proses pelatihan. Selain itu, dataset memiliki rata-rata resolusi sebesar 0,39 megapiksel dengan ukuran gambar yang bervariasi. Keberagaman ukuran dan kualitas gambar tersebut memungkinkan model untuk mempelajari objek pakaian dalam berbagai kondisi visual sehingga diharapkan mampu meningkatkan kemampuan generalisasi model ketika dihadapkan pada data baru yang belum pernah dilihat sebelumnya.

Selanjutnya dilakukan analisis terhadap distribusi kelas untuk mengetahui sebaran jumlah objek pada masing-masing kategori pakaian



yang digunakan dalam penelitian. Distribusi kelas dataset ditunjukkan pada Tabel 4.1

Tabel 4. 1 Distribusi Kelas Dataset DeepFashion3

| No           | Kelas                  | Jumlah Objek |
|--------------|------------------------|--------------|
| 1            | Long Sleeve Dress      | 226          |
| 2            | Long Sleeve Outerwear  | 409          |
| 3            | Long Sleeve Top        | 987          |
| 4            | Short Sleeve Dress     | 376          |
| 5            | Short Sleeve Outerwear | 5            |
| 6            | Short Sleeve Top       | 1.695        |
| 7            | Shorts                 | 954          |
| 8            | Skirt                  | 812          |
| 9            | Sling                  | 6            |
| 10           | Sling Dress            | 220          |
| 11           | Trousers               | 1.289        |
| 12           | Vest                   | 498          |
| 13           | Vest Dress             | 611          |
| <b>Total</b> |                        | <b>8.088</b> |

Berdasarkan Tabel 4.1, dapat diketahui bahwa distribusi data pada setiap kelas tidak sepenuhnya seimbang (*class imbalance*). Kelas Short Sleeve Top merupakan kelas dengan jumlah anotasi terbanyak yaitu sebanyak 1.695 objek, diikuti oleh kelas Trousers sebanyak 1.289 objek dan Long Sleeve Top sebanyak 987 objek. Sebaliknya, kelas Short Sleeve Outerwear dan Sling memiliki jumlah anotasi yang sangat sedikit, masing-masing hanya sebanyak 5 dan 6 objek. Perbedaan distribusi yang cukup besar ini berpotensi menyebabkan model lebih mudah mempelajari karakteristik kelas mayoritas dibandingkan kelas minoritas. Oleh karena itu, penelitian ini menerapkan teknik augmentasi data untuk meningkatkan variasi data pelatihan dan membantu model mengenali karakteristik objek secara lebih baik.

Visualisasi distribusi jumlah anotasi pada setiap kelas dapat dilihat pada Gambar 4.2. Gambar tersebut menunjukkan bahwa kelas Short Sleeve Top, Trousers, dan Long Sleeve Top mendominasi dataset, sedangkan beberapa kelas lain memiliki jumlah anotasi yang relatif sedikit. Kondisi ini menjadi salah satu alasan penting dilakukannya optimasi dataset melalui teknik augmentasi agar model mampu melakukan generalisasi secara lebih baik terhadap seluruh kelas yang tersedia.



Gambar 4. 2 Distribusi Kelas Dataset

Selain distribusi kelas, pembagian dataset juga menjadi faktor penting dalam proses pelatihan model. Dataset pada penelitian ini dibagi menjadi data pelatihan (*training set*) dan data validasi (*validation set*). Pembagian dataset dilakukan secara otomatis melalui platform Roboflow dengan komposisi sebagaimana ditunjukkan pada Tabel 4.2

Tabel 4. 2 Pembagian Dataset


| Dataset    | Jumlah Gambar | Persentase |
|------------|---------------|------------|
| Training   | 4.750         | 95%        |
| Validation | 250           | 5%         |
| Test       | 0             | 0%         |
| Total      | 5.000         | 100%       |

Berdasarkan Tabel 4.2 dan Gambar 4.3, sebanyak **4.750 gambar (95%)** digunakan sebagai data pelatihan (*training set*), sedangkan **250 gambar (5%)** digunakan sebagai data validasi (*validation set*). Penelitian ini tidak menggunakan data *test* pada Roboflow karena proses pengujian akhir dilakukan secara terpisah menggunakan data inferensi eksternal berupa citra independen yang tidak pernah digunakan selama proses pelatihan maupun validasi. Pendekatan tersebut dipilih untuk memperoleh evaluasi yang lebih objektif terhadap kemampuan

109

generalisasi model dalam mengenali objek pakaian pada kondisi yang berbeda dengan data pelatihan.

Tahap eksplorasi dataset diakhiri dengan melakukan peninjauan terhadap hasil anotasi yang digunakan dalam penelitian. Anotasi dilakukan menggunakan metode *polygon segmentation* sehingga setiap objek pakaian dapat ditandai mengikuti bentuk aslinya secara lebih detail dibandingkan anotasi berbasis *bounding box*.



Gambar 4. 3 Contoh Anotasi Dataset

Menggunakan Polygon Segmentation

Berdasarkan Gambar 4.3, setiap objek pakaian pada dataset telah dianotasi menggunakan metode *polygon segmentation* melalui platform

Roboflow. Anotasi dilakukan dengan mengikuti kontur atau batas sebenarnya dari objek pakaian sehingga menghasilkan representasi objek yang lebih detail dibandingkan anotasi berbasis *bounding box*. Pada gambar terlihat beberapa kategori pakaian yang digunakan dalam penelitian, seperti long sleeve outerwear, short sleeve outerwear, long sleeve top, short sleeve top, dan skirt. Setiap objek diberi area segmentasi yang berbeda untuk memisahkan objek pakaian dari latar belakang maupun objek lain yang berada di sekitarnya.


Penggunaan metode *polygon segmentation* memungkinkan model YOLOv8n mempelajari bentuk dan karakteristik visual objek secara lebih akurat. Informasi detail mengenai batas objek menjadi penting terutama pada kelas pakaian yang memiliki kemiripan visual, seperti tops dan outerwear, yang sering kali sulit dibedakan hanya berdasarkan bentuk umum objek. Dengan adanya anotasi segmentasi yang presisi, model dapat memahami karakteristik masing-masing kelas secara lebih baik sehingga diharapkan mampu meningkatkan akurasi deteksi dan klasifikasi pada tahap pengujian.

Selain itu, variasi objek yang ditampilkan pada Gambar 4.4 menunjukkan bahwa dataset memiliki keragaman bentuk, ukuran, pose, dan kondisi lingkungan yang berbeda-beda. Keberagaman tersebut memberikan informasi yang lebih kaya selama proses pelatihan sehingga membantu model dalam meningkatkan kemampuan generalisasi ketika dihadapkan pada citra baru yang tidak terdapat pada dataset pelatihan.

## 2. Implementasi Teknik Augmentasi Data


Proses augmentasi data dilakukan untuk meningkatkan keragaman dataset sekaligus memperkuat kemampuan generalisasi model YOLOv8n dalam mendeteksi kepatuhan *dress-code* pada berbagai kondisi lingkungan. Strategi ini diterapkan berdasarkan temuan penelitian terdahulu yang menunjukkan bahwa meskipun YOLOv8n mampu melakukan deteksi objek secara *real-time*, performanya masih belum optimal dengan nilai *F1-Score* sebesar 45% dan *mean Average*

*Precision* (mAP) sebesar 51,8%. Rendahnya performa tersebut mengindikasikan bahwa model masih mengalami kesulitan dalam membedakan kategori pakaian yang memiliki kemiripan visual tinggi, seperti *tops* dan *outerwear*, serta belum mampu beradaptasi secara optimal terhadap variasi pencahayaan, sudut pengambilan gambar, dan kondisi lingkungan yang kompleks. Oleh karena itu, penelitian ini menerapkan beberapa skenario augmentasi secara bertahap untuk menguji sejauh mana peningkatan variasi data mampu memperbaiki kemampuan deteksi model.




Gambar 4. 4 Dataset Tanpa HSV Flipping Mosaic

Tahap pertama merupakan skenario *baseline* atau kondisi dasar tanpa penerapan augmentasi, yaitu menggunakan 5.000 gambar asli yang diperoleh dari dataset DeepFashion3 melalui platform Roboflow. Pada tahap ini, seluruh data digunakan dalam kondisi asli sehingga model hanya mempelajari karakteristik visual yang tersedia pada dataset tanpa tambahan variasi buatan. Dataset ini menjadi acuan utama (*ground truth*) untuk mengevaluasi pengaruh setiap teknik augmentasi yang diterapkan pada tahap berikutnya. Melalui skenario ini, model belajar mengenali bentuk dasar pakaian, tekstur kain, warna, serta batas antar objek pakaian dalam kondisi yang relatif normal. Hasil yang diperoleh dari model *baseline* kemudian digunakan sebagai pembandingan terhadap seluruh skenario optimasi yang dikembangkan dalam penelitian ini.



Gambar 4. 5 Dataset Flipping Mosaic


Tahap kedua menerapkan kombinasi augmentasi *Horizontal Flipping* dan *Mosaic* sehingga jumlah dataset meningkat menjadi 7.398 gambar. Teknik *Horizontal Flipping* menghasilkan citra baru melalui proses pencerminan objek secara horizontal sehingga model dapat mempelajari bahwa suatu jenis pakaian tetap memiliki identitas yang sama meskipun orientasi objek berubah. Sementara itu, teknik *Mosaic* menggabungkan beberapa citra ke dalam satu frame baru sehingga model dihadapkan pada kondisi visual yang lebih kompleks dengan banyak objek dalam satu gambar. Kombinasi kedua teknik tersebut bertujuan untuk meningkatkan kemampuan model dalam memahami hubungan spasial objek, mengenali pakaian pada berbagai posisi, serta mempertahankan akurasi deteksi ketika objek berada pada kondisi yang saling berdekatan atau bertumpang tindih. Dengan kata lain, model tidak hanya belajar mengenali pakaian secara individual, tetapi juga dilatih untuk tetap konsisten mendeteksi objek pada lingkungan yang menyerupai kondisi nyata dengan tingkat kepadatan visual yang tinggi.



Gambar 4. 6 Dataset HSV Mosaic

Tahap ketiga menggunakan kombinasi augmentasi HSV (*Hue*, *Saturation*, *Value*) dan *Mosaic* sehingga jumlah dataset bertambah menjadi 9.741 gambar. Pada tahap ini, fokus optimasi diarahkan pada peningkatan ketahanan model terhadap perubahan pencahayaan dan warna. Transformasi HSV memungkinkan variasi pada komponen warna, tingkat kejenuhan, dan tingkat kecerahan citra sehingga menghasilkan simulasi berbagai kondisi lingkungan, mulai dari cahaya terang, redup, hingga kondisi dengan bayangan yang cukup dominan. Melalui pendekatan ini, model dilatih untuk lebih fokus pada karakteristik bentuk dan struktur pakaian daripada bergantung sepenuhnya pada warna asli objek. Penggunaan *Mosaic* tetap dipertahankan untuk memastikan model mampu mengenali objek dalam berbagai ukuran dan posisi secara bersamaan. Tahap ini sangat penting karena pada implementasi sistem pengawasan kampus, kondisi pencahayaan tidak selalu ideal dan dapat berubah sesuai waktu maupun lokasi pengambilan gambar.





Gambar 4. 7 Dataset HSV Flip Mosaic

Tahap keempat merupakan skenario optimasi tertinggi dengan menggabungkan seluruh teknik augmentasi, yaitu HSV, *Horizontal Flipping*, dan *Mosaic*. Kombinasi tersebut menghasilkan total 9.742 gambar yang memiliki tingkat variasi visual paling tinggi dibandingkan seluruh skenario sebelumnya. Pada tahap ini, model secara bersamaan dihadapkan pada perubahan orientasi objek, variasi pencahayaan, perbedaan warna, variasi ukuran objek, serta kondisi kepadatan visual yang kompleks. Dengan kata lain, seluruh tantangan yang mungkin muncul pada lingkungan nyata disimulasikan ke dalam data pelatihan. Pendekatan ini dirancang untuk membentuk model yang lebih *robust*, adaptif, dan mampu melakukan generalisasi dengan baik ketika diterapkan pada data yang belum pernah dilihat sebelumnya.

Secara keseluruhan, penerapan augmentasi secara bertahap dalam penelitian ini bertujuan untuk meningkatkan akurasi YOLOv8n dalam mendeteksi kepatuhan *dress-code* serta membandingkan hasilnya dengan model *baseline* dan penelitian terdahulu. Selain itu, penelitian ini juga menganalisis efektivitas augmentasi data intensif dalam mengurangi kesalahan klasifikasi antar kelas pakaian yang memiliki kemiripan visual, khususnya antara kategori *tops* dan *outerwear*. Melalui peningkatan variasi data yang sistematis, model diharapkan mampu mempertahankan performa deteksi yang konsisten pada berbagai kondisi pencahayaan, sudut pengambilan gambar, dan kompleksitas lingkungan



sehingga menghasilkan sistem *dress-code surveillance* yang lebih akurat, objektif, dan siap diterapkan secara real-time di lingkungan kampus.

Tabel 4. 3 Tabel Parameter Augmentasi

| Skenario   | Augmentasi Dataset pada Roboflow | Parameter Augmentasi                                                                         | Mosaic saat Training YOLOv8 | Jumlah Gambar | Tujuan Pengujian                                                                 |
|------------|----------------------------------|----------------------------------------------------------------------------------------------|-----------------------------|---------------|----------------------------------------------------------------------------------|
| Skenario 1 | Tanpa augmentasi                 | Tidak ada augmentasi yang diterapkan pada dataset                                            | Tidak Aktif                 | 5.000         | Mengetahui performa dasar model YOLOv8n tanpa augmentasi dataset.                |
| Skenario 2 | Horizontal Flipping              | Flip Horizontal                                                                              | Aktif (mosaic=1.0)          | 7.398         | Mengetahui pengaruh pembalikan citra secara horizontal terhadap akurasi deteksi. |
| Skenario 3 | HSV                              | Hue $\pm 15^\circ$ ,<br>Saturation $\pm 15\%$ ,<br>Brightness $\pm 15\%$                     | Aktif (mosaic=1.0)          | 9.741         | Mengetahui pengaruh variasi warna dan pencahayaan terhadap performa model.       |
| Skenario 4 | HSV + Horizontal Flipping        | Flip Horizontal,<br>Hue $\pm 15^\circ$ ,<br>Saturation $\pm 15\%$ ,<br>Brightness $\pm 15\%$ | Aktif (mosaic=1.0)          | 9.741         | Mengetahui pengaruh kombinasi augmentasi HSV dan Horizontal Flipping             |

| Skenario | Augmentasi Dataset pada Roboflow | Parameter Augmentasi | Mosaic saat Training YOLOv8 | Jumlah Gambar | Tujuan Pengujian         |
|----------|----------------------------------|----------------------|-----------------------------|---------------|--------------------------|
|          |                                  |                      |                             |               | terhadap performa model. |

Berdasarkan Tabel parameter augmentasi yang telah disajikan, setiap skenario pelatihan menggunakan konfigurasi augmentasi yang berbeda untuk menghasilkan tingkat variasi data yang beragam. Skenario tanpa augmentasi digunakan sebagai acuan dasar untuk mengukur performa model tanpa penambahan variasi citra, sedangkan skenario augmentasi ringan, sedang, dan tinggi menerapkan peningkatan nilai parameter secara bertahap. Perbedaan konfigurasi tersebut diharapkan dapat meningkatkan kemampuan model dalam mengenali objek pakaian pada berbagai kondisi, seperti perubahan posisi, sudut pandang, pencahayaan, maupun skala objek. Selanjutnya, masing-masing skenario akan digunakan dalam proses pelatihan dan dievaluasi untuk mengetahui pengaruh augmentasi data terhadap performa deteksi model YOLOv8n.

Selain evaluasi menggunakan data validasi, penelitian ini juga melakukan pengujian inferensi eksternal untuk mengukur kemampuan generalisasi model pada data yang belum pernah digunakan selama proses pelatihan. Pengujian inferensi eksternal dilakukan menggunakan kumpulan gambar independen yang diperoleh dari sumber di luar platform Roboflow, sehingga gambar tersebut tidak termasuk dalam data latih maupun data validasi yang digunakan pada penelitian. Pendekatan ini bertujuan untuk mengetahui sejauh mana model mampu mendeteksi objek pakaian pada kondisi nyata dengan karakteristik gambar yang lebih beragam dibandingkan dataset yang digunakan selama proses pelatihan.



Gambar 4. 8 Dataset Inferensi Eksternal

Gambar-gambar inferensi eksternal yang ditunjukkan pada gambar di atas merepresentasikan berbagai kondisi yang dapat ditemui saat pengujian, seperti perbedaan jenis pakaian, pose objek, latar belakang, pencahayaan, dan sudut pengambilan gambar. Gambar tersebut berasal dari sumber di luar dataset Roboflow sehingga tidak pernah digunakan selama proses pelatihan maupun validasi. Penggunaan gambar independen ini bertujuan untuk memberikan evaluasi yang lebih objektif terhadap kemampuan model dalam mendeteksi kategori pakaian pada data baru yang memiliki karakteristik berbeda dari data pelatihan.

Melalui pengujian inferensi eksternal, penelitian ini dapat menilai kemampuan generalisasi model YOLOv8n dalam menghadapi kondisi yang mendekati penggunaan di dunia nyata. Hasil pengujian tidak hanya digunakan untuk membandingkan performa model pada setiap skenario augmentasi data, tetapi juga untuk menentukan konfigurasi augmentasi

yang paling efektif dalam meningkatkan akurasi dan kestabilan deteksi pada sistem dress-code surveillance.

### 3. Hasil Modeling


Pada penelitian ini dilakukan empat skenario pelatihan model YOLOv8n untuk mengetahui pengaruh penerapan augmentasi data terhadap performa sistem *dress-code surveillance*. Skenario pertama menggunakan dataset tanpa augmentasi sebagai model baseline. Skenario kedua menerapkan kombinasi Horizontal Flipping dan Mosaic. Skenario ketiga menggunakan kombinasi HSV dan Mosaic. Skenario keempat menerapkan kombinasi HSV, Horizontal Flipping, dan Mosaic. Evaluasi model dilakukan menggunakan metrik Precision, Recall, mAP50, mAP50-95, F1-Score, serta analisis Confusion Matrix.

#### a. Hasil Pemeodelan Tanpa Augmentasi

Tabel 4. 4 Hasil Evaluasi Model Tanpa Augmentasi


| Metrik    | Nilai |
|-----------|-------|
| Precision | 0,897 |
| Recall    | 0,905 |
| mAP50     | 0,943 |
| mAP50-95  | 0,839 |

Berdasarkan Tabel 4.4, model YOLOv8n tanpa augmentasi menghasilkan nilai precision sebesar 89,7%, recall sebesar 90,5%, mAP50 sebesar 94,3%, dan mAP50-95 sebesar 83,9%. Hasil tersebut menunjukkan bahwa model mampu mengenali objek pakaian dengan tingkat akurasi yang cukup tinggi meskipun belum diberikan variasi tambahan melalui proses augmentasi data. Oleh karena itu, model ini digunakan sebagai baseline untuk membandingkan pengaruh penerapan augmentasi pada skenario berikutnya.




Gambar 4. 9 Results Curve

Berdasarkan Gambar 4.9, nilai train box loss, train classification loss, dan train DFL loss mengalami penurunan secara konsisten selama proses pelatihan. Hal yang sama juga terjadi pada validation loss yang menunjukkan tren menurun hingga akhir epoch. Sementara itu, nilai precision, recall, mAP50, dan mAP50-95 mengalami peningkatan secara bertahap hingga mencapai nilai terbaik pada akhir proses pelatihan. Hasil tersebut menunjukkan bahwa model berhasil mempelajari karakteristik objek pada dataset tanpa mengalami overfitting yang signifikan.



Gambar 4. 10 F1-Confidence Curve

Berdasarkan Gambar 4.10, model memperoleh nilai F1-score terbaik sebesar 0,90 pada confidence threshold 0,503. Nilai tersebut menunjukkan keseimbangan yang baik antara precision dan recall sehingga model mampu memberikan hasil deteksi yang optimal pada tingkat confidence tersebut.



Gambar 4. 11 Confusion Matrix Normalized


Berdasarkan confusion matrix, sebagian besar kategori pakaian berhasil dikenali dengan baik. Kelas *long sleeve dress* mencapai tingkat klasifikasi benar sebesar 100%, sedangkan kelas *long sleeve top*, *short sleeve top*, dan *trousers* menunjukkan tingkat akurasi di atas 90%. Namun demikian, masih terdapat kesalahan klasifikasi pada kelas *sling dress* dan *skirt* yang memiliki karakteristik visual yang mirip dengan kategori lainnya.

## b. Hasil Pemodelan Horizontal Flipping dan Mosaic

Tabel 4. 5 Hasil Evaluasi Model Horizontal

| Metrik    | Nilai |
|-----------|-------|
| Precision | 0,909 |
| Recall    | 0,891 |
| mAP50     | 0,941 |
| mAP50-95  | 0,841 |

Penerapan Horizontal Flipping dan Mosaic meningkatkan precision menjadi 90,9% serta mAP50-95 menjadi 84,1%. Namun recall mengalami sedikit penurunan menjadi 89,1%. Hasil tersebut menunjukkan bahwa augmentasi mampu meningkatkan ketepatan deteksi objek, tetapi belum memberikan peningkatan yang signifikan terhadap kemampuan model dalam menemukan seluruh objek yang ada pada citra.




Gambar 4. 12 Results Curve

Grafik hasil pelatihan menunjukkan penurunan loss yang stabil serta peningkatan metrik evaluasi hingga akhir pelatihan. Hal ini menunjukkan bahwa model mampu memanfaatkan variasi data yang




dihasilkan oleh teknik Horizontal Flipping dan Mosaic untuk meningkatkan proses pembelajaran.



Gambar 4. 13 F1-Confidence Curve

Model memperoleh nilai F1-score sebesar 0,89 pada confidence threshold 0,608. Nilai tersebut sedikit lebih rendah dibandingkan model baseline, yang menunjukkan bahwa peningkatan precision belum sepenuhnya diikuti oleh peningkatan recall.



Gambar 4. 14 Confusion Matrix Normalized

Confusion matrix menunjukkan peningkatan akurasi pada kelas *long sleeve outfit* dan *long sleeve top*. Namun masih terdapat kesalahan klasifikasi pada kelas *skirt* dan *sling dress*. Secara umum,



3

model menunjukkan kemampuan klasifikasi yang lebih baik dibandingkan model tanpa augmentasi.


### c. Hasil Pemodelan HSV dan Mosaic

Tabel 4. 6 Hasil Evaluasi Model HSV dan Mosaic

| Metrik    | Nilai |
|-----------|-------|
| Precision | 0,920 |
| Recall    | 0,906 |
| mAP50     | 0,946 |
| mAP50-95  | 0,853 |

2


Kombinasi HSV dan Mosaic menghasilkan peningkatan performa dibandingkan dua skenario sebelumnya. Precision meningkat menjadi 92,0%, recall mencapai 90,6%, mAP50 sebesar 94,6%, dan mAP50-95 sebesar 85,3%. Hasil tersebut menunjukkan bahwa variasi warna dan pencahayaan yang diberikan oleh augmentasi HSV membantu model mengenali objek pada berbagai kondisi visual.



Tabel 4. 7 Results Curve

3

Nilai loss mengalami penurunan yang konsisten sedangkan seluruh metrik evaluasi menunjukkan peningkatan hingga akhir pelatihan. Hal tersebut menunjukkan bahwa model mampu mempelajari karakteristik objek secara lebih efektif dibandingkan skenario sebelumnya.




Gambar 4. 15 F1-Confidence Curve

73

1

52

Model memperoleh nilai F1-score sebesar 0,91 pada confidence threshold 0,658. Nilai tersebut menunjukkan peningkatan keseimbangan antara precision dan recall dibandingkan skenario sebelumnya.



Gambar 4. 16 Confusion Matrix Normalized

1


Berdasarkan confusion matrix, kelas *short sleeve dress*, *shorts*, dan *skirt* menunjukkan peningkatan tingkat klasifikasi yang cukup signifikan. Hal ini menunjukkan bahwa augmentasi HSV mampu membantu model mengenali objek dengan variasi warna dan pencahayaan yang berbeda

#### d. Hasil Pemodelan HSV, Horizontal Flipping, dan Mosaic

Tabel 4. 8 Hasil Evaluasi Model HSV, Horizontal Flipping, dan Mosaic


| Metrik    | Nilai |
|-----------|-------|
| Precision | 0,937 |
| Recall    | 0,906 |
| mAP50     | 0,954 |
| mAP50-95  | 0,859 |

Kombinasi HSV, Horizontal Flipping, dan Mosaic menghasilkan performa terbaik dengan nilai precision sebesar 93,7%, recall sebesar 90,6%, mAP50 sebesar 95,4%, dan mAP50-95 sebesar 85,9%. Hasil tersebut menunjukkan bahwa kombinasi ketiga teknik augmentasi mampu meningkatkan kemampuan model dalam mengenali objek secara lebih akurat.




Gambar 4. 17 Results Curve

Seluruh nilai loss menunjukkan tren penurunan yang stabil, sedangkan precision, recall, mAP50, dan mAP50-95 meningkat hingga mencapai nilai tertinggi dibandingkan seluruh skenario yang diuji.



Gambar 4. 18 F1-Confidence Curve

Model memperoleh nilai F1-score tertinggi sebesar 0,92 pada confidence threshold 0,709. Hasil tersebut menunjukkan bahwa model memiliki keseimbangan terbaik antara precision dan recall.



Gambar 4. 19 Confusion Matrix Normalized

Confusion matrix menunjukkan peningkatan akurasi pada kelas *sling dress*, *shorts*, dan *skirt*. Selain itu, sebagian besar kategori pakaian memiliki tingkat klasifikasi benar di atas 90%, yang menunjukkan kemampuan generalisasi model yang sangat baik.

#### e. Perbandingan Antar Skenario

Tabel 4. 9 Perbandingan Performa Model

YOLOv8n Berdasarkan Variasi Skenario Augmentasi Data

| No. Skenario | Konfigurasi Augmentasi             | Precision | Recall | mAP50 | mAP50-95 | F1-Score |
|--------------|------------------------------------|-----------|--------|-------|----------|----------|
| 1            | Tanpa Augmentasi                   | 0,897     | 0,905  | 0,943 | 0,839    | 0,90     |
| 2            | Horizontal Flipping + Mosaic       | 0,909     | 0,891  | 0,941 | 0,841    | 0,89     |
| 3            | HSV + Mosaic                       | 0,920     | 0,906  | 0,946 | 0,853    | 0,91     |
| 4            | HSV + Horizontal Flipping + Mosaic | 0,937     | 0,906  | 0,954 | 0,859    | 0,92     |

Berdasarkan Tabel 4.9, setiap skenario augmentasi memberikan pengaruh yang berbeda terhadap performa model YOLOv8n. Skenario 1 (tanpa augmentasi) menghasilkan nilai precision sebesar 89,7%, recall sebesar 90,5%, mAP50 sebesar 94,3%, mAP50-95 sebesar 83,9%, dan F1-score sebesar 0,90. Hasil tersebut menunjukkan bahwa model telah mampu melakukan deteksi objek dengan baik meskipun belum diberikan variasi data tambahan selama proses pelatihan.


Pada Skenario 2, penerapan augmentasi Horizontal Flipping dan Mosaic menghasilkan peningkatan nilai precision menjadi 90,9% dan mAP50-95 menjadi 84,1%. Namun, nilai recall dan mAP50

mengalami sedikit penurunan dibandingkan Skenario 1. Hal ini menunjukkan bahwa variasi orientasi dan komposisi objek yang dihasilkan oleh kedua teknik augmentasi tersebut belum mampu meningkatkan seluruh metrik evaluasi secara optimal.

Skenario 3 yang mengombinasikan HSV dan Mosaic menunjukkan peningkatan performa yang lebih baik dibandingkan dua skenario sebelumnya. Nilai precision meningkat menjadi 92,0%, recall mencapai 90,6%, mAP50 sebesar 94,6%, mAP50-95 sebesar 85,3%, dan F1-score sebesar 0,91. Hasil ini menunjukkan bahwa augmentasi HSV membantu model beradaptasi terhadap variasi warna dan pencahayaan sehingga kemampuan deteksi objek menjadi lebih stabil.

Performa terbaik diperoleh pada Skenario 4 yang mengombinasikan HSV, Horizontal Flipping, dan Mosaic. Skenario ini menghasilkan nilai precision sebesar 93,7%, recall sebesar 90,6%, mAP50 sebesar 95,4%, mAP50-95 sebesar 85,9%, dan F1-score sebesar 0,92. Nilai tersebut merupakan yang tertinggi dibandingkan seluruh skenario yang diuji. Hasil ini menunjukkan bahwa kombinasi ketiga teknik augmentasi mampu memberikan variasi data yang lebih beragam sehingga model dapat mempelajari karakteristik objek pakaian secara lebih optimal.

Berdasarkan seluruh hasil pengujian, Skenario 4 dipilih sebagai model terbaik karena mampu menghasilkan performa paling tinggi dan paling seimbang pada seluruh metrik evaluasi. Oleh karena itu, model dengan kombinasi augmentasi HSV, Horizontal Flipping, dan Mosaic digunakan sebagai model utama untuk tahap evaluasi dan pembahasan lebih lanjut pada penelitian ini.



Gambar 4. 20 Grafik Perbandingan F1-Score  
Antar Skenario

Berdasarkan Gambar 4.21, nilai F1-score tertinggi diperoleh pada skenario HSV, Horizontal Flipping, dan Mosaic dengan nilai sebesar 0,92. Sementara itu, skenario HSV dan Mosaic memperoleh nilai F1-score sebesar 0,91, model tanpa augmentasi memperoleh nilai 0,90, dan skenario Horizontal Flipping serta Mosaic memperoleh nilai 0,89. Hasil tersebut menunjukkan bahwa penambahan augmentasi HSV memberikan kontribusi yang lebih besar terhadap peningkatan performa model dibandingkan penggunaan Horizontal Flipping dan Mosaic saja. Selain itu, kombinasi ketiga teknik augmentasi menghasilkan variasi data yang lebih beragam sehingga model mampu mengenali karakteristik objek pakaian secara lebih optimal.

#### f. Kesimpulan Hasil Pemodelan

Berdasarkan hasil pengujian empat skenario pelatihan, penerapan augmentasi data terbukti memberikan pengaruh positif terhadap performa model YOLOv8n dalam mendeteksi kategori pakaian pada sistem dress-code surveillance. Setiap skenario menunjukkan karakteristik performa yang berbeda, di mana penggunaan augmentasi mampu meningkatkan kemampuan model

13 dalam mengenali objek pada berbagai kondisi visual dibandingkan model tanpa augmentasi.

155 Hasil evaluasi menunjukkan bahwa skenario kombinasi HSV, Horizontal Flipping, dan Mosaic menghasilkan performa terbaik dibandingkan skenario lainnya dengan nilai precision sebesar 93,7%, recall sebesar 90,6%, mAP50 sebesar 95,4%, mAP50-95 sebesar 85,9%, dan F1-score sebesar 0,92. Peningkatan tersebut menunjukkan bahwa kombinasi augmentasi warna, orientasi, dan komposisi citra mampu memperkaya variasi data pelatihan sehingga model memiliki kemampuan generalisasi yang lebih baik dalam mengenali karakteristik objek pakaian.

Dengan demikian, kombinasi HSV, Horizontal Flipping, dan Mosaic ditetapkan sebagai konfigurasi augmentasi terbaik pada penelitian ini dan selanjutnya digunakan sebagai model utama untuk dibandingkan dengan penelitian terdahulu pada tahap perbandingan model.

#### 4. Perbandingan Model

136 Dalam penelitian ini, perbandingan model dilakukan antara hasil penelitian terdahulu yang dilakukan oleh Tantra dan Widjaja (2025) dengan model YOLOv8n yang dioptimasi menggunakan teknik augmentasi data pada penelitian ini. Perbandingan dilakukan menggunakan metrik precision, recall, F1-score, dan mAP@50 untuk mengetahui sejauh mana penerapan augmentasi data mampu meningkatkan performa model dalam mendeteksi kategori pakaian pada sistem dress-code surveillance. Hasil perbandingan tersebut disajikan pada Tabel 4.10



Tabel 4. 10 Perbandingan Performa Model Yolov8n

| Metrik Evaluasi | Model Baseline (Tantra & Widjaja, 2025) | Model Optimasi (Penelitian Ini) | Selisih peningkatan |
|-----------------|-----------------------------------------|---------------------------------|---------------------|
| Precision (P)   | 0.535 (53,5%)                           | 0.931 (93,1%)                   | + 39,6%             |
| Recall (R)      | 0.446 (44,6%)                           | 0.911 (91,1%)                   | + 46,5%             |
| F1-Score        | 0.486 (48,6%)                           | 0.920 (92,0%)                   | + 43,4%             |
| mAP@50          | 0.518 (51,8%)                           | 0.953 (95,3%)                   | + 43,5%             |

Berdasarkan Tabel 4.10, dapat dilakukan analisis mendalam mengenai peningkatan performa model sebagai berikut:

- Peningkatan Skor mAP@50: Model optimasi berhasil mencapai nilai *mean Average Precision* (mAP@50) sebesar 95,3%, yang menunjukkan kenaikan signifikan sebesar 43,5% dibandingkan hasil penelitian Tantra dan Widjaja yang hanya mencapai 51,8%. Hal ini menunjukkan bahwa model dalam penelitian ini jauh lebih akurat dalam mengenali berbagai atribut pakaian secara serentak.
- Keseimbangan Precision dan Recall: Nilai *Precision* sebesar 93,1% dan *Recall* 91,1% menghasilkan skor F1 sebesar 0,92 (92,0%) pada tingkat kepercayaan 0,709. Peningkatan skor F1 sebesar 43,4% dari model *baseline* membuktikan bahwa teknik augmentasi data intensif berhasil mengatasi masalah ketidakseimbangan data (*class imbalance*) dan misklasifikasi yang dialami penelitian sebelumnya.
- Efektivitas Augmentasi Data: Keunggulan model ini terletak pada penerapan teknik *Mosaic Augmentation* dan manipulasi HSV (*Hue, Saturation, Value*). Jika pada penelitian sebelumnya model masih sering keliru membedakan antara *tops* dan *outerwear*, penggunaan

augmentasi cahaya dan posisi dalam penelitian ini memberikan model "ketahanan" lebih tinggi terhadap variasi visual di lapangan kampus.

- d. Optimalitas Arsitektur Nano: Hasil ini mempertegas bahwa meskipun menggunakan arsitektur YOLOv8n yang paling ringan, optimasi pada tahap pra-pemrosesan data dapat menghasilkan performa yang setara dengan model yang lebih besar, namun tetap mempertahankan kecepatan inferensi tinggi untuk kebutuhan *real-time surveillance*.

Berdasarkan hasil perbandingan tersebut, penelitian ini berhasil menunjukkan bahwa penerapan augmentasi data mampu meningkatkan performa model YOLOv8n dibandingkan penelitian Tantra dan Widjaja (2025). Peningkatan terjadi pada seluruh metrik evaluasi, yaitu precision, recall, F1-score, dan mAP@50. Hasil tersebut menunjukkan bahwa strategi augmentasi yang diterapkan berhasil meningkatkan kemampuan model dalam melakukan deteksi dan klasifikasi pakaian pada berbagai kondisi visual yang berbeda. Dengan demikian, tujuan penelitian untuk meningkatkan akurasi sistem dress-code surveillance menggunakan YOLOv8n melalui augmentasi data dapat dinyatakan tercapai.

## B. Pembahasan

Hasil penelitian yang telah disajikan pada bagian sebelumnya menunjukkan pengaruh penerapan berbagai teknik augmentasi data terhadap performa model YOLOv8n dalam mendeteksi kategori pakaian. Perbedaan nilai precision, recall, F1-score, mAP50, dan mAP50-95 pada setiap skenario menunjukkan bahwa pemilihan teknik augmentasi memiliki peran penting dalam meningkatkan kemampuan model untuk mengenali objek secara akurat.

Berdasarkan hasil tersebut, diperlukan pembahasan lebih lanjut untuk menginterpretasikan performa model yang diperoleh, mengidentifikasi faktor-faktor yang memengaruhi peningkatan akurasi, serta mengevaluasi keterkaitan hasil penelitian dengan tujuan bisnis yang telah ditetapkan pada tahap Business Understanding. Selain itu, pembahasan ini juga bertujuan untuk menilai validitas hasil penelitian,

kemampuan generalisasi model, serta potensi implementasinya pada sistem dress-code surveillance di lingkungan kampus.

### 1. Model Paling Optimal dan Alasan Teknis

Berdasarkan hasil perbandingan seluruh skenario augmentasi yang telah dilakukan, model terbaik diperoleh pada skenario kombinasi HSV, Horizontal Flipping, dan Mosaic. Model tersebut menghasilkan nilai precision sebesar 93,7%, recall sebesar 90,6%, mAP50 sebesar 95,4%, mAP50-95 sebesar 85,9%, dan F1-score sebesar 0,92. Nilai tersebut merupakan performa tertinggi dibandingkan dengan seluruh skenario yang diuji sehingga dipilih sebagai model paling optimal dalam penelitian ini.

Secara teknis, peningkatan performa tersebut dipengaruhi oleh kombinasi tiga teknik augmentasi yang saling melengkapi. Augmentasi HSV membantu model mengenali objek pakaian pada berbagai kondisi pencahayaan dan variasi warna yang berbeda. Horizontal Flipping memperkaya variasi orientasi objek sehingga model menjadi lebih robust terhadap perubahan posisi dan sudut pengambilan gambar. Sementara itu, Mosaic memungkinkan model mempelajari objek dengan ukuran, posisi, dan latar belakang yang lebih beragam karena beberapa citra digabungkan dalam satu proses pelatihan.

Hasil evaluasi menunjukkan bahwa kombinasi augmentasi tersebut mampu mengurangi kesalahan klasifikasi antar kategori pakaian yang memiliki kemiripan visual, khususnya antara kelas tops dan outerwear. Kemampuan model dalam membedakan karakteristik masing-masing kategori pakaian meningkat dibandingkan model tanpa augmentasi sehingga menghasilkan deteksi yang lebih akurat dan konsisten.

Selain memiliki tingkat akurasi yang tinggi, penggunaan YOLOv8n juga memberikan keuntungan dari sisi efisiensi komputasi

karena model ini memiliki ukuran yang relatif ringan dibandingkan model YOLO lainnya. Dengan demikian, model yang dihasilkan tidak hanya memiliki performa yang baik tetapi juga berpotensi diterapkan pada sistem surveillance yang membutuhkan proses deteksi secara real-time.

## 2. Evaluasi Hasil Modeling Terhadap Tujuan Bisnis

Tabel 4. 11 Evaluasi Pencapaian Tujuan Bisnis

| Tujuan Bisnis                            | Indikator Keberhasilan                             | Hasil Penelitian                       | Status   |
|------------------------------------------|----------------------------------------------------|----------------------------------------|----------|
| Meningkatkan akurasi deteksi pakaian     | mAP50 lebih tinggi dibanding penelitian sebelumnya | mAP50 mencapai 95,4%                   | Tercapai |
| Mengurangi kesalahan klasifikasi pakaian | Penurunan misklasifikasi antar kelas               | Kesalahan tops dan outerwear berkurang | Tercapai |
| Mendukung pengawasan otomatis            | Deteksi pakaian dilakukan secara otomatis          | Seluruh kategori berhasil dideteksi    | Tercapai |
| Menjaga efisiensi sistem                 | Menggunakan model ringan dengan performa tinggi    | YOLOv8n berjalan optimal               | Tercapai |

Berdasarkan Tabel 4.11, seluruh tujuan bisnis yang ditetapkan pada tahap Business Understanding berhasil dicapai. Tujuan utama penelitian yaitu meningkatkan akurasi sistem dress-code surveillance berhasil diwujudkan melalui penerapan augmentasi data yang menghasilkan nilai mAP50 sebesar 95,4%. Nilai tersebut menunjukkan peningkatan yang signifikan dibandingkan penelitian sebelumnya yang hanya memperoleh nilai mAP50 sebesar 51,8%.

Selain meningkatkan akurasi, model juga mampu mengurangi kesalahan klasifikasi pada kategori pakaian yang memiliki kemiripan visual. Hasil ini menunjukkan bahwa teknik augmentasi yang diterapkan berhasil meningkatkan kemampuan model dalam mengenali karakteristik objek secara lebih detail sehingga proses deteksi menjadi lebih akurat dan konsisten.

### 3. Kesesuaian dengan Ekspektasi Business Understanding

Tabel 4. 12 Kesesuaian Hasil Penelitian dengan  
Business Understanding

| Ekspektasi Awal                                        | Hasil yang Diperoleh                                          | Keterangan          |
|--------------------------------------------------------|---------------------------------------------------------------|---------------------|
| Sistem mampu mendeteksi kategori pakaian               | Seluruh kategori pakaian berhasil dideteksi                   | Sesuai              |
| Sistem mampu bekerja pada berbagai kondisi pencahayaan | Model mampu mendeteksi objek pada variasi pencahayaan berbeda | Sesuai              |
| Sistem mampu mengurangi subjektivitas pengawasan       | Deteksi dilakukan secara otomatis oleh model                  | Sesuai              |
| Sistem memiliki akurasi tinggi                         | mAP50 mencapai 95,4%                                          | Melebihi ekspektasi |

Berdasarkan Tabel 4.12, hasil penelitian menunjukkan kesesuaian yang tinggi dengan kebutuhan bisnis yang telah diidentifikasi pada tahap Business Understanding. Sistem yang dikembangkan berhasil melakukan deteksi kategori pakaian secara otomatis sehingga dapat mengurangi ketergantungan terhadap proses pengawasan manual yang selama ini rentan terhadap subjektivitas dan kesalahan manusia.

Selain itu, penggunaan augmentasi data terbukti mampu meningkatkan ketahanan model terhadap berbagai kondisi lingkungan yang berbeda. Hasil tersebut menunjukkan bahwa model yang dikembangkan telah memenuhi kebutuhan dasar sistem dress-code surveillance yang membutuhkan tingkat akurasi tinggi, konsistensi deteksi, dan kemampuan beradaptasi terhadap variasi kondisi pengambilan gambar.

#### 4. Validitas dan Generalisasi Hasil

Validitas penelitian didukung oleh penggunaan dataset DeepFashion yang telah memiliki anotasi bounding box dan banyak digunakan dalam penelitian deteksi pakaian. Selain itu, proses evaluasi dilakukan menggunakan metrik standar pada bidang object detection yaitu precision, recall, F1-score, mAP50, dan mAP50-95 sehingga hasil yang diperoleh dapat diukur secara objektif dan dibandingkan dengan penelitian lain yang sejenis.

Kemampuan generalisasi model ditunjukkan melalui penerapan teknik augmentasi data yang menghasilkan variasi citra lebih beragam selama proses pelatihan. Variasi tersebut mencakup perubahan warna, pencahayaan, posisi objek, dan komposisi gambar sehingga model tidak hanya mempelajari karakteristik data pelatihan tetapi juga mampu mengenali objek pada kondisi yang berbeda.

Hasil pengujian menunjukkan bahwa model tetap mampu mendeteksi kategori pakaian dengan baik meskipun terdapat variasi kondisi visual pada data. Hal ini menunjukkan bahwa model memiliki kemampuan generalisasi yang cukup baik dan berpotensi diterapkan pada lingkungan nyata yang memiliki karakteristik berbeda dengan data pelatihan.

#### 5. Rekomendasi Penerapan Model

Tabel 4. 13 Rekomendasi Penerapan Model YOLOv8n

| Aspek                    | Rekomendasi                                                    |
|--------------------------|----------------------------------------------------------------|
| Lingkungan Penggunaan    | Sistem dress-code surveillance pada area kampus                |
| Sumber Input             | Webcam atau kamera pengawas (CCTV)                             |
| Fungsi Utama             | Deteksi otomatis kategori pakaian mahasiswa                    |
| Model yang Digunakan     | YOLOv8n dengan augmentasi HSV, Horizontal Flipping, dan Mosaic |
| Pengembangan Selanjutnya | Integrasi dengan video real-time dan sistem monitoring         |

130

5

Berdasarkan hasil penelitian yang telah dilakukan, model YOLOv8n dengan kombinasi augmentasi HSV, Horizontal Flipping, dan Mosaic memiliki potensi untuk diterapkan pada sistem *dress-code surveillance*. Nilai mAP50 sebesar 95,4% menunjukkan bahwa model mampu mendeteksi kategori pakaian dengan tingkat akurasi yang tinggi sehingga dapat digunakan sebagai pendukung proses pengawasan kepatuhan berpakaian secara otomatis.

Pada implementasinya, model dapat diintegrasikan dengan sumber video seperti webcam maupun CCTV untuk melakukan deteksi kategori pakaian secara real-time. Proses deteksi dilakukan dengan mengidentifikasi kategori pakaian yang dikenakan objek berdasarkan model hasil pelatihan sehingga dapat membantu proses monitoring yang sebelumnya dilakukan secara manual.

28

8

Meskipun penelitian ini masih berfokus pada tahap pengembangan dan evaluasi model, hasil yang diperoleh menunjukkan bahwa model memiliki potensi untuk diterapkan pada lingkungan nyata. Pengembangan lebih lanjut dapat dilakukan melalui integrasi dengan sistem monitoring berbasis video real-time serta pengujian pada kondisi lingkungan yang lebih beragam untuk meningkatkan keandalan sistem dalam penggunaan sehari-hari.

## A. Kesimpulan

B

A

B

V

P

E

N

U

T

U

P

Berdasarkan hasil penelitian mengenai optimasi model YOLOv8n menggunakan augmentasi data untuk peningkatan akurasi sistem *dress-code surveillance*, maka dapat disimpulkan sebagai berikut:

1. Model YOLOv8n yang dioptimasi menggunakan augmentasi data berhasil meningkatkan akurasi dan performa deteksi dibandingkan dengan *baseline model* penelitian sebelumnya. Hasil pengujian menunjukkan bahwa model terbaik diperoleh pada skenario kombinasi HSV, Horizontal Flipping, dan Mosaic dengan nilai *precision* sebesar 93,7%, *recall* sebesar 90,6%, *mAP@50* sebesar 95,4%, *mAP@50-95* sebesar 85,9%, dan *F1-score* sebesar 0,92. Dibandingkan dengan *baseline model* penelitian Tantra dan Widjaja (2025) yang memperoleh *precision* sebesar 53,5%, *recall* sebesar 44,6%, *F1-score* sebesar 48,6%, dan *mAP@50* sebesar 51,8%, model yang dikembangkan pada penelitian ini menunjukkan peningkatan performa yang signifikan pada seluruh metrik evaluasi. Dengan demikian, optimasi melalui augmentasi data terbukti mampu meningkatkan kemampuan model YOLOv8n dalam mendeteksi kepatuhan *dress-code* secara lebih akurat dan andal.
2. Penerapan augmentasi data intensif terbukti efektif dalam mengurangi kesalahan klasifikasi antara kelas pakaian yang memiliki kemiripan visual, khususnya kategori *tops* dan *outerwear*, pada berbagai kondisi pencahayaan dan sudut pengambilan gambar. Kombinasi augmentasi HSV, Horizontal Flipping, dan Mosaic mampu memperkaya variasi data pelatihan sehingga model dapat mempelajari karakteristik objek pakaian secara lebih baik. Hasil evaluasi menunjukkan bahwa model memiliki kemampuan



103

generalisasi yang lebih tinggi dibandingkan model tanpa augmentasi, ditunjukkan oleh peningkatan nilai *precision*, *recall*, *F1-score*, *mAP@50*, dan *mAP@50-95*. Selain itu, model mampu

72

mempertahankan performa deteksi yang stabil pada variasi pencahayaan, orientasi objek, dan latar belakang yang berbeda sehingga kesalahan klasifikasi antar kategori pakaian dapat diminimalkan.

## B. Saran

Berdasarkan hasil penelitian yang telah dilakukan, beberapa saran yang dapat diberikan untuk pengembangan penelitian selanjutnya adalah sebagai berikut:

1. Penelitian selanjutnya dapat menambahkan jumlah dan variasi dataset pakaian untuk meningkatkan kemampuan generalisasi model.
2. Penelitian selanjutnya dapat menguji teknik augmentasi lain seperti Rotation, MixUp, atau Copy-Paste untuk mengetahui pengaruhnya terhadap performa model.
3. Penelitian selanjutnya dapat membandingkan performa YOLOv8n dengan arsitektur deteksi objek lainnya untuk memperoleh konfigurasi yang lebih optimal.
4. Penelitian selanjutnya dapat mengimplementasikan model pada sistem *dress-code surveillance* berbasis video atau CCTV *real-time* untuk mengevaluasi performa model pada kondisi operasional yang sebenarnya.