

Optimasi Model YOLOv8n Menggunakan Augmentasi Data Untuk Peningkatan Akurasi Sistem *Dress-Code Surveillance*

Sherla Dian Mutia¹, Rina Firliana^{2*}, Arie Nugroho^{3,*}

¹ Teknik dan Ilmu Komputer, Sistem Informasi, Universitas Nusantara PGRI Kediri, Kediri, Indonesia

Email: ¹sherla.mutial@gmail.com, ^{2,*}rina@unpkediri.ac.id, ^{3,*}arienugroho@unpkediri.ac.id

Abstrak- Pengawasan manual terhadap kepatuhan aturan berpakaian (*dress-code*) mahasiswa di lingkungan kampus sering kali tidak efisien, subjektif, dan terkendala oleh keterbatasan fisik serta kelelahan petugas keamanan. Penelitian ini bertujuan untuk mengotomatiskan sistem pengawasan tersebut dengan mengoptimalkan model *Deep Learning* YOLOv8 varian Nano (YOLOv8n) berbasis *Computer Vision*. Masalah utama yang dihadapi dalam deteksi objek secara *real-time* adalah keterbatasan jumlah dataset dan keragaman kondisi visual di lapangan yang berisiko memicu terjadinya *overfitting*. Solusi yang diterapkan untuk mengatasi masalah tersebut adalah implementasi strategi augmentasi data dinamis yang komprehensif, meliputi manipulasi *Hue*, *Saturation*, *Value* (HSV), *Horizontal Flipping*, dan *Mosaic Augmentation*. Melalui pendekatan metodologi CRISP-DM, teknik ini berhasil melipatgandakan jumlah dataset dari 5.000 citra awal menjadi 9.742 citra latih. Hasil akhir pengujian empiris menunjukkan bahwa model YOLOv8n yang dioptimasi sukses meningkatkan akurasi secara signifikan sebesar 43,5% dibandingkan dengan model *baseline*. Model terbaik ini berhasil mencapai nilai *Mean Average Precision* (mAP@0.5) sebesar 95,3%, dengan tingkat *Precision* 93,1%, *Recall* 91,1%, serta skor F1 mencapai 0,92. Angka-angka tersebut membuktikan keandalan sistem dalam mereduksi *false positive* saat beroperasi di situasi dunia nyata yang padat. Sistem pengawasan otomatis ini sangat layak diintegrasikan langsung pada infrastruktur kamera CCTV kampus berbasis *edge computing* untuk mendukung stabilitas dan kedisiplinan institusi secara objektif.

Kata Kunci: Augmentasi Data; Computer Vision; Dress-Code Surveillance; Deep Learning; YOLOv8n

Abstract- Manual surveillance of student dress-code compliance on campus is often inefficient, subjective, and constrained by the physical fatigue of security personnel. This study aims to automate the surveillance system by optimizing the Nano variant of the YOLOv8 (YOLOv8n) Deep Learning model based on Computer Vision. The main challenge in real-time object detection is limited datasets and visual diversity, which increases the risk of overfitting. The solution applied to address this issue is the implementation of comprehensive dynamic data augmentation strategies, including Hue, Saturation, Value (HSV) manipulation, Horizontal Flipping, and Mosaic Augmentation. Utilizing the CRISP-DM methodology, this technique expanded the dataset from 5,000 initial images to 9,742 training images. The empirical test results show that the optimized YOLOv8n model significantly improved accuracy by 43,5% compared to the baseline model. The best-performing model achieved a Mean Average Precision (mAP@0.5) of 95.3%, with a Precision of 93.1%, Recall of 91.1%, and an F1-score of 0.92. These metrics demonstrate the reliability of the system in reducing false positives while operating in crowded real-world environments. This automated surveillance system is highly feasible for direct integration into campus CCTV infrastructure using edge computing to objectively support institutional discipline.

Keywords: Data Augmentation; Computer Vision; Dress-Code Surveillance; Deep Learning; YOLOv8n

1. PENDAHULUAN

Visi komputer (computer vision) merupakan pilar utama kecerdasan buatan yang memungkinkan analisis otomatis dan mendalam terhadap representasi visual citra digital [1]. Didorong oleh teknik pembelajaran mendalam (deep learning) yang mengekstraksi fitur kompleks secara berlapis [2], teknologi ini menjadi motor penggerak utama dalam memperkuat keandalan sistem pengawasan video (surveillance technology) [3]. Di ranah institusi pendidikan tinggi, integrasi prinsip rekayasa perangkat lunak dan visi komputer sangat krusial untuk melakukan penguatan sistem informasi guna memantau aktivitas serta penegakan aturan di lingkungan civitas akademika [4].

Implementasi deep learning di area kampus telah sukses diterapkan untuk mendeteksi objek guna memetakan tingkat kerumunan mahasiswa [5]. Kendati demikian, pemantauan terhadap regulasi tata tertib berpakaian (*dress-code*) mahasiswa mayoritas masih dilakukan secara manual oleh petugas keamanan, sehingga rentan terhadap kelelahan fisik dan bias penilaian subjektif. Oleh sebab itu, efisiensi penegakan aturan berpakaian memerlukan otomatisasi berbasis visi komputer yang terintegrasi dengan umpan kamera langsung (live camera feeds) di lingkungan komputasi awan [6].

Riset otomatisasi *dress-code* sebelumnya berhasil menerapkan jaringan saraf konvolusional ringan (lightweight) untuk mendeteksi pakaian pelindung khusus secara *real-time* pada perangkat tertanam [7]. Pada sektor pendidikan, pemanfaatan algoritma You Only Look Once versi 8 (YOLOv8) terbukti andal dalam memantau kepatuhan aturan pakaian siswa secara akurat [8], serta mengenali pelanggaran kode etik berpakaian di area kampus secara presisi [9]. Pemilihan arsitektur YOLOv8 menjadi sangat strategis karena sistem pengawasan di area kampus menuntut performa pelacakan objek yang cepat dan responsif secara *real-time* [10].

Keandalan model YOLO didasarkan pada evolusi arsitekturnya, dimulai dari penetapan standar kecepatan dan akurasi pada YOLOv4 [11], hingga optimalisasi YOLOv8 untuk deteksi responsivitas tinggi seperti pada pemakaian masker wajah [12]. Fleksibilitas ekstraksi fitur berbasis konvolusi (CNN) ini juga sukses diadopsi pada berbagai kasus spesifik, mulai dari klasifikasi citra mammogram menggunakan model Mobile NASNet [13] hingga klasifikasi objek biner pada citra anjing dan kucing [14].

Meskipun tangguh, penerapan model berskala kompak seperti YOLOv8 varian Nano (YOLOv8n) pada sistem dress-code surveillance kerap terkendala oleh risiko overfitting akibat keterbatasan jumlah dataset serta oklusi di lapangan. Untuk mengatasinya, diperlukan strategi optimasi fitur melalui teknik augmentasi data dinamis [15], di mana rekayasa citra latih sintetis terbukti mampu mengatasi ketidakseimbangan kelas tanpa biaya anotasi manual yang besar [16]. Selain itu, penggunaan dataset lokal sangat menentukan keberhasilan implementasi AI agar model mampu mengenali atribut pakaian yang relevan dengan regulasi wilayah tertentu [17]. Optimasi ini juga wajib disempurnakan melalui penataan komponen hyperparameter jaringan saraf (seperti learning rate dan weight decay) agar model berskala nano dapat bergeneralisasi secara optimal [18]. Berdasarkan hal tersebut, penelitian ini berfokus pada optimasi model YOLOv8n menggunakan strategi augmentasi data dinamis (HSV manipulation, Horizontal Flipping, dan Mosaic Augmentation) untuk meningkatkan akurasi sistem pengawasan pakaian (dress-code surveillance) mahasiswa di Universitas Nusantara PGRI Kediri..

2. METODOLOGI PENELITIAN

2.1 Tahap Penelitian

Penelitian ini mengadopsi kerangka kerja standar industri Cross-Industry Standard Process for Data Mining (CRISP-DM) yang terbukti efektif menjembatani analisis data teknis dengan tujuan fungsional sistem, sebagaimana sukses diterapkan pada riset pemodelan operasional konveksi pakaian [19]. Metodologi ini mencakup enam tahapan utama: Business Understanding (analisis kebutuhan tata tertib kampus), Data Understanding (pengumpulan 5.000 citra awal), Data Preparation (anotasi dan implementasi augmentasi data dinamis menjadi 9.742 citra latih), Modeling (pelatihan model YOLOv8n), Evaluation (analisis metrik akurasi mAP), dan Deployment. Untuk mengonseptualisasikan alur penyajian data deteksi kepada otoritas kampus, penelitian ini juga mengacu pada prinsip arsitektur sistem informasi pemantauan terintegrasi yang mampu mencatat records secara berkala dan menyajikan laporan analisis secara real-time [20]. Melalui integrasi metodologi CRISP-DM dan teknik augmentasi data dinamis ini, peningkatan akurasi model YOLOv8n dalam sistem pengawasan pakaian dapat diukur secara empiris dan sistematis.. Alur tahapan penelitian ini ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian Menggunakan CRISP-DM

Tahapan tersebut digunakan untuk memastikan bahwa proses penelitian dilakukan secara sistematis, mulai dari pemahaman masalah hingga pengujian hasil mode

2.2 Business Understanding

Tahap ini bertujuan mengidentifikasi masalah utama berupa ketidakefisienan pengawasan dress-code mahasiswa yang masih dilakukan secara manual dan rentan terhadap kelelahan serta subjektivitas petugas. Penelitian ini bertujuan mengembangkan sistem deteksi otomatis berbasis Artificial Intelligence menggunakan YOLOv8n dan teknik augmentasi data untuk menghasilkan sistem pengawasan yang objektif, efisien, dan mampu bekerja secara real-time.

2.3 Data Understanding

Tahap ini berfokus pada pengumpulan dan pemahaman data citra yang berasal dari pengambilan data lapangan dan dataset publik dari Roboflow. Sebanyak 5.000 citra berhasil dikumpulkan dengan variasi sudut kamera, jarak objek, dan

kondisi latar belakang. Data tersebut mencakup berbagai atribut pakaian yang relevan dan dianalisis untuk memastikan distribusi data tetap seimbang..

2.4 Data Preparation

Tahap ini bertujuan mengubah data mentah menjadi data siap latih (training-ready) melalui pelabelan bounding box dan augmentasi data untuk mengurangi overfitting. Teknik yang digunakan meliputi Mosaic Augmentation, Horizontal Flip, dan optimasi HSV untuk menambah variasi data. Penerapan metode ini berhasil meningkatkan jumlah dataset dari 5.000 menjadi 9.742 citra.

Tabel 1. Distribusi Dataset Sebelum dan Sesudah Augmentasi

Kondisi Data	Training (70%)	Validation (20%)	Testing (10%)
Data Awal	3.500	1.000	500
Pasca Augmentasi	6.820	1.948	974

Tabel 1 menunjukkan lonjakan volume data yang signifikan guna memperkuat kemampuan generalisasi model terhadap kondisi lingkungan yang dinamis.

2.5 Modeling

Pada tahap permodelan, algoritma yang diimplementasikan adalah YOLOv8 varian Nano (YOLOv8n). Pemilihan model ini didasarkan pada keunggulannya dalam kecepatan inferensi pada perangkat surveilans *edge*. Proses pelatihan dilakukan menggunakan infrastruktur *cloud* Google Colab Pro dengan dukungan akselerasi hardware GPU NVIDIA A100 (40GB VRAM). Penggunaan kartu grafis kelas atas ini menjamin efisiensi waktu pelatihan dan stabilitas komputasi pada dataset skala besar. Spesifikasi lengkap lingkungan pengembangan yang digunakan dalam penelitian ini dijabarkan pada Tabel 2.

Tabel 2. Spesifikasi Lingkungan Pengembangan

Komponen	Spesifikasi
GPU	NVIDIA A100-SXM4 (40GM VRAM)
Platform	Google Colab Pro
Library Utama	Ultralytics YOLOv8, PyTorch, OpenCv
Bahasa	Python 3.10+

Data pada Tabel 2 menegaskan penggunaan infrastruktur komputasi kelas atas untuk menjamin stabilitas selama proses pelatihan.

Proses pelatihan melibatkan pengaturan *hyperparameters* yang presisi guna mencapai titik konvergensi yang optimal dalam 100 *epoch*. Konfigurasi parameter kunci yang diterapkan dijabarkan dalam tabel di bawah ini.

Tabel 3. Konfigurasi Hyperparameters Pelatihan

Parameter	Nilai / Deskripsi
Epoch	100
Image Size	640 x 640
hsv_h / hsv_s / hsv_v	0.015 / 0.7 / 0.4
Optimizer	SGD (Stochastic Gradient Descent)
Learning Rate	0.01

Tabel 3 menyajikan parameter teknis yang digunakan untuk menjaga akurasi model selama proses iterasi pelatihan.

2.6 Evaluation

Tahap evaluasi dilakukan untuk mengukur kinerja model menggunakan metrik Precision, Recall, dan mAP@0.5, serta Confusion Matrix untuk mengidentifikasi kesalahan klasifikasi pada kategori pakaian yang memiliki kemiripan fitur. Evaluasi ini bertujuan memastikan model akurat dan andal pada kondisi nyata, dengan hasil prediksi ditampilkan melalui visualisasi data validasi. Selanjutnya, model YOLOv8n yang telah dioptimasi menggunakan augmentasi dan HSV dirancang untuk diintegrasikan ke sistem kamera surveilans kampus guna melakukan monitoring dress-code mahasiswa secara otomatis, memberikan peringatan real-time, serta menyediakan data statistik kepatuhan untuk evaluasi kebijakan kampus.

3. HASIL DAN PEMBAHASAN

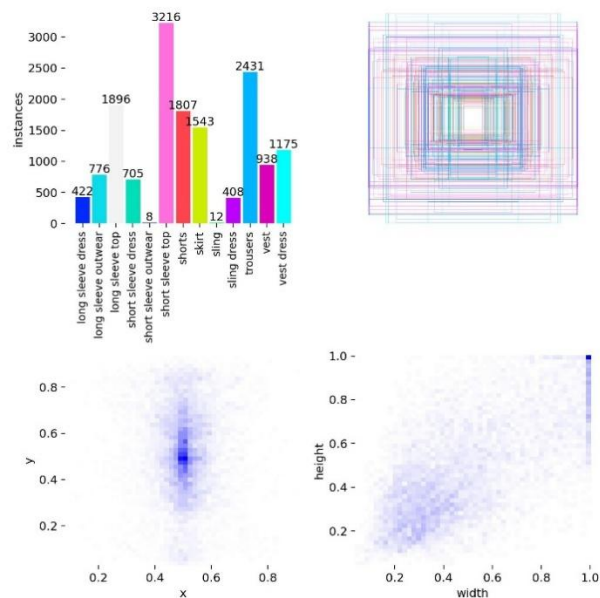
Bagian ini membahas hasil implementasi optimasi YOLOv8n dalam mendeteksi kepatuhan *dress-code* mahasiswa menggunakan kerangka CRISP-DM. Pembahasan mencakup analisis data, pengaruh augmentasi, evaluasi performa *real-time*, serta perbandingan dengan penelitian sebelumnya untuk menilai akurasi, generalisasi, dan kelayakan sistem pengawasan otomatis di lingkungan akademik.

3.1 Implementasi dan Pengujian

Fase implementasi dan pengujian berfokus pada evaluasi kinerja YOLOv8 Nano (YOLOv8n) untuk deteksi *dress-code* mahasiswa. Proses dilakukan menggunakan Google Colab Pro dengan GPU NVIDIA A100 40 GB guna memastikan pelatihan berjalan stabil dan efisien, serta dievaluasi dari tahap pengolahan data hingga hasil performa akhir model.

3.1.1 Hasil Eksplorasi Data (*Data Understanding*)

Langkah fundamental sebelum menetapkan parameter pelatihan model adalah melakukan eksplorasi data secara ekstensif guna memetakan karakteristik intrinsik dari dataset yang digunakan. Dataset utama dalam penelitian ini diperoleh dari platform publik Roboflow (DeepFashion3) yang terdiri dari 5.000 citra asli. Pemahaman terhadap distribusi data sangat krusial untuk mengidentifikasi potensi bias yang dapat mendegradasi kemampuan generalisasi model.




Gambar 2. Labels


Gambar tersebut menunjukkan hasil analisis distribusi dataset anotasi objek yang digunakan pada model deteksi. Grafik batang pada bagian kiri atas memperlihatkan jumlah instance pada setiap kelas, di mana kelas short sleeve top memiliki jumlah data terbanyak sebanyak 3216 instance, sedangkan kelas short sleeve outerwear dan sling memiliki jumlah yang sangat sedikit, yaitu 8 dan 12 instance. Hal ini menunjukkan bahwa distribusi data antar kelas masih tidak seimbang (*imbalanced*). Pada bagian kanan atas, visualisasi *bounding box* menunjukkan bahwa sebagian besar objek terkonsentrasi di area tengah gambar. Hal ini diperkuat oleh *heatmap* di kiri bawah yang memperlihatkan titik pusat objek (x, y) dominan berada di sekitar koordinat (0,5; 0,5). Sementara itu, *heatmap* kanan bawah menunjukkan distribusi ukuran objek berdasarkan lebar dan tinggi *bounding box*, di mana mayoritas objek memiliki ukuran sedang dengan variasi ukuran yang cukup beragam. Secara keseluruhan, dataset memiliki pola objek yang cenderung berada di bagian tengah gambar, namun ketidakseimbangan jumlah data antar kelas berpotensi memengaruhi kinerja model deteksi.

3.1.2 Proses Transformasi Data (Normalisasi dan Augmentasi)

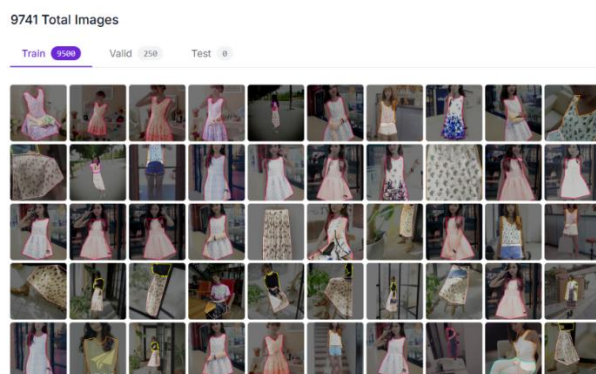
Untuk mengatasi masalah *imbalanced dataset* dan meningkatkan metrik *Mean Average Precision* (mAP), dilakukan proses transformasi data melalui teknik augmentasi sintetik. Tahapan ini bertujuan untuk memperkaya variabilitas visual tanpa harus melakukan pengambilan data lapangan secara manual. Eksperimen transformasi ini dibagi ke dalam beberapa skenario untuk mengukur efektivitas setiap teknik augmentasi.

**Gambar 3.** Kondisi Dataset Baseline (Tanpa Augmentasi)

Gambar 9 mencerminkan visualisasi struktur dataset pada tahap awal atau kondisi *baseline*. Tercatat 5.000 citra murni didistribusikan secara masif dengan 4.750 gambar untuk data pelatihan (*train*) dan sisanya untuk validasi. Secara karakteristik, dataset ini memiliki konsistensi pencahayaan dan komposisi visual yang sangat statis. Keteraturan visual yang terlampaui tinggi ini berpotensi memicu *viewpoint dependency*, di mana model hanya menghafal pola orientasi tertentu dan rentan mengalami kegagalan deteksi jika dihadapkan pada pergeseran sudut kamera yang ekstrem di lapangan.


**Gambar 4.** Dataset dengan Augmentasi Flipping dan Mosaic

Sebagai langkah intervensi pertama, Gambar 10 menyajikan visualisasi dataset yang telah dioptimasi menggunakan teknik *Horizontal Flipping* dan *Mosaic Augmentation*, yang menghasilkan ekspansi data menjadi 7.398 gambar. Teknik *Flipping* menciptakan variasi posisi objek pakaian secara lateral untuk mencegah bias orientasi arah hadap subjek. Secara bersamaan, teknik *Mosaic* menggabungkan beberapa sampel gambar ke dalam satu bingkai kerja untuk melatih sistem dalam skenario deteksi multi-skala (*multi-scale detection*). Hal ini memaksa model untuk mengenali atribut pakaian meskipun berada dalam kerumunan atau saling tumpang tindih.

**Gambar 5.** Dataset dengan Augmentasi HSV dan Mosaic

Skenario berikutnya pada Gambar 11 berfokus pada ketahanan model terhadap variasi iluminasi cahaya melalui manipulasi *Hue*, *Saturation*, *Value* (HSV) yang dikombinasikan dengan *Mosaic*. Kombinasi ini meningkatkan jumlah data latih menjadi 9.741 gambar. Dengan memanipulasi komponen *Hue* (warna), *Saturation* (intensitas), dan *Value* (kecerahan), model dilatih untuk membedakan tekstur dan bentuk pakaian secara independen dari kondisi cahaya

lingkungan. Hal ini sangat esensial agar sistem tetap presisi baik di ruangan yang redup maupun area *outdoor* yang terpapar cahaya matahari secara kontras.



Gambar 6. Dataset dengan Kombinasi Augmentasi Komprehensif

Skenario final dan paling komprehensif divisualisasikan pada Gambar 12 di mana seluruh teknik augmentasi tingkat lanjut digabungkan, menghasilkan lonjakan kuantitas data dari 5.000 menjadi **9.742 gambar**. Peningkatan ini bukan sekadar replikasi, melainkan penciptaan variasi sintetik yang merepresentasikan kompleksitas dunia nyata secara utuh. Model YOLOv8 dilatih untuk mengenali asimetri orientasi sekaligus distorsi atmosfer cahaya secara bersamaan. Seluruh dataset akhir ini dinormalisasi ke resolusi 640x640 piksel dan dikonversi menjadi format representasi tensor untuk diolah oleh GPU A100.

Tabel 4. Perbandingan Performa Model YOLOv8n Berdasarkan Variasi Skenario Augmentasi Data

Aspek Perbandingan	Skenario 1	Skenario 2	Skenario 3	Skenario 4	Metrik Pengukuran Riil
Ketahanan & Akurasi Utama	0.9387	0.9354	0.9463	0.9529 (Tertinggi)	$mAP@50$
Ketahanan Detail & Sudut Pandang	0.8335	0.8348	0.8450	0.9529 (Tertinggi)	$mAP@50 - 95$
Deteksi dalam Kerumunan	0.8747	0.8706	0.8450	0.8458 (Tertinggi)	\$Recall\$ (Mencegah objek terlewat)
Ketepatan Prediksi	0.9186	0.9219	0.9392 (Tertinggi)	0.9311	$\$Precision\$$ (Mencegah salah deteksi)
Risiko Overfitting	0.4823 (Terendah)	0.6159 (Sangat Tinggi)	0.5295 (Rendah)	0.5662 (Sedang)	$\Delta Loss (Val - Train)$
Total Training Loss	1.5767	1.4747	1.4395	1.4427	Box + Cls + Dfl Loss
Total Validation Loss	2.0591	2.0906	1.9690	2.0089	Box + Cls + Dfl Loss

Berdasarkan Tabel 3.1, dapat ditarik konklusi bahwa Skenario 4 (kombinasi HSV, *Flipping*, dan *Mosaic*) merupakan pendekatan yang paling efisien dan superior. Walaupun membutuhkan beban komputasi pelatihan yang lebih tinggi, skenario ini menjamin terciptanya bobot model (*model weights*) yang memiliki tingkat ketangguhan maksimal terhadap gangguan geometri dan distorsi iluminasi, menjadikannya fondasi yang kokoh untuk sistem surveilans jangka panjang

3.1.3 Hasil Pelatihan Model (*Modeling*)

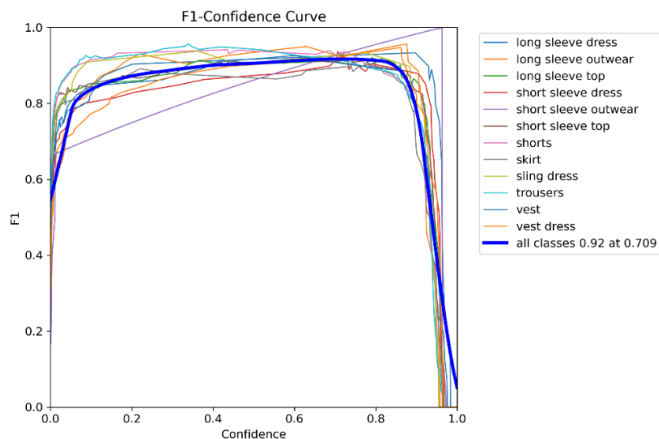
Tahap pelatihan (*training*) dijalankan menggunakan arsitektur YOLOv8n selama 100 *epoch* dengan konfigurasi parameter optimasi otomatis dan ukuran *batch* 16. Pengujian ini dipantau secara ketat untuk mengevaluasi tingkat konvergensi algoritma.

```
Validating /content/runs/detect/train/weights/best.pt...
Ultralytics 8.4.41 Python-3.12.13 torch-2.10.0+cu128 CUDA:0 (NVIDIA A100-SXM4-40GB, 40441MiB)
Model summary (fused): 73 layers, 3,008,183 parameters, 0 gradients, 8.1 GFLOPs
Class      Images  Instances  Box(P)   R      mAP50  mAP50-95): 100% 8/8 4.4it/s 1.8s
all         250     414        0.937   0.906  0.954  0.859
long sleeve dress      15      15        0.918   0.933  0.963  0.944
long sleeve outfit    20      20        0.947   0.902  0.986  0.895
long sleeve top       38      38        0.877   0.941  0.961  0.863
short sleeve dress    23      23        0.916   0.951  0.946  0.835
short sleeve outfit    1       1         0.866   1      0.995  0.995
short sleeve top      85      87        0.967   0.862  0.965  0.844
shorts                47      50        0.965   0.9    0.946  0.815
skirt                 40      40        0.915   0.875  0.945  0.792
sling dress           16      16        0.986   0.875  0.931  0.824
trousers              72      72        0.843   0.843  0.953  0.805
vest                  28      29        0.829   0.899  0.899  0.798
vest dress            23      23        0.886   0.957  0.965  0.9

Speed: 0.1ms preprocess, 0.4ms inference, 0.0ms loss, 1.2ms postprocess per image
Results saved to /content/runs/detect/train
```


Gambar 7 Log Pelatihan - Epoch 1 hingga 100

Dokumentasi log pelatihan pada Gambar 4.9 (*results.csv*) menunjukkan pencapaian yang sangat impresif. Pada akhir iterasi ke-100, model YOLOv8n berhasil membukukan nilai *Mean Average Precision* pada ambang batas IoU 50% ($mAP@0.5$) sebesar 0.953 (95,3%). Pada aspek spesifisitas, ketepatan prediksi (*Precision*) mencapai 0.931 (93,1%), sementara sensitivitas pendeteksian (*Recall*) tercatat sebesar 0.911 (91,1%).



Gambar 8 Grafik F1-Confidence Curve

Keseimbangan harmonik antara tingkat *Precision* dan *Recall* divisualisasikan melalui kurva F1-Confidence pada Gambar 4.10. Garis biru tebal yang merepresentasikan performa agregat dari seluruh kelas pakaian menunjukkan skor F1 maksimal sebesar **0.92** yang dicapai pada tingkat kepercayaan (*confidence threshold*) **0.709**. Hal ini mengindikasikan bahwa model beroperasi pada titik keseimbangan optimum; model tidak terlalu longgar sehingga memicu kesalahan deteksi, namun juga tidak terlalu ketat sehingga mengabaikan objek yang valid. Penurunan kurva yang terjadi saat nilai kepercayaan mendekati 1.0 merupakan perilaku algoritma yang wajar dan sesuai dengan teori probabilitas pada jaringan saraf tiruan.




Gambar 9 Ringkasan Grafik Loss dan Metrics Hasil Pelatihan

Grafik penurunan nilai kerugian (*loss*) pada Gambar 4.11 menjadi bukti tak terbantahkan atas keberhasilan fase pelatihan. Parameter *box_loss* (kesalahan lokalisasi kotak pembatas), *cls_loss* (kesalahan klasifikasi kategori), dan *dfl_loss* (kesalahan distribusi fokus) secara konsisten menunjukkan tren penurunan yang parabolik baik pada data *train* maupun *val*. Sinkronisasi tren penurunan antara data pelatihan dan validasi ini merupakan indikator utama bahwa model terhindar dari fenomena *overfitting*. Di sisi lain, grafik metrik akurasi menunjukkan tren asimtotik yang stabil di atas batas 0.9, mengonfirmasi bahwa proses ekstraksi fitur telah berjalan secara holistik dan sempurna.

3.2 Pembahasan

Analisis komprehensif terhadap performa arsitektur YOLOv8n pasca-optimasi ini bertujuan untuk mengevaluasi tingkat reliabilitas sistem jika dihadapkan pada skenario dunia nyata yang fluktuatif. Tinjauan mendalam dilakukan untuk mengukur korelasi antara kualitas data sintetik yang dihasilkan pada fase augmentasi dengan peningkatan ketajaman inferensi model saat mengeleminasi gangguan visual latar belakang di lingkungan kampus Analisis Model Paling Optimal dan Alasan Teknis



Gambar 10 Matriks Kebingungan Normalisasi - Confusion Matrix Normalized

Berdasarkan hasil Confusion Matrix pada Gambar 4.12, model YOLOv8n dengan dataset 9.742 citra menjadi model paling optimal dengan nilai mAP 95,3%. Kinerja tinggi ini didukung arsitektur YOLOv8 Nano yang ringan sehingga mampu berjalan real-time dengan penggunaan memori yang efisien. Tingkat akurasi yang mendekati sempurna pada beberapa kategori, termasuk kelas minoritas, menunjukkan bahwa augmentasi adaptif berhasil membantu model mengenali pola data secara merata. Selain itu, penggunaan GPU A100 turut mendukung proses pelatihan agar lebih stabil dan presisi.

Evaluasi Terhadap Tujuan Bisnis dan Validitas Generalisasi Nilai Precision di atas 93% menunjukkan sistem layak diterapkan karena dapat mengurangi kesalahan deteksi (*false positive*) sehingga meminimalkan alarm yang tidak diperlukan. Hasil ini mendukung tujuan penelitian dalam menggantikan pengawasan manual dengan sistem yang lebih objektif dan konsisten. Validitas model juga diperkuat oleh rendahnya nilai *loss* dan perbedaan kecil antara data latih dan data uji, yang menandakan model mampu melakukan generalisasi dengan baik. Augmentasi HSV turut membantu model tetap akurat pada kondisi pencahayaan CCTV yang berubah-ubah.

Rekomendasi Penerapan Model Model YOLOv8 Nano direkomendasikan untuk diterapkan dalam sistem informasi universitas karena ringan dan tidak membutuhkan infrastruktur komputasi tinggi. Model dapat dijalankan pada perangkat *edge computing* atau komputer dengan spesifikasi menengah. Untuk pengembangan selanjutnya, sistem dapat diintegrasikan dengan *early warning system* agar pelanggaran *dress-code* dapat dideteksi, didokumentasikan, dan dikirimkan secara otomatis kepada pihak terkait melalui API.

4. KESIMPULAN

Penelitian ini berhasil mengatasi inefisiensi pengawasan tata tertib berpakaian (*dress-code*) mahasiswa melalui pengembangan sistem deteksi otomatis berbasis *computer vision* menggunakan kerangka kerja CRISP-DM. Melalui penerapan arsitektur YOLOv8 varian Nano (YOLOv8n), strategi augmentasi data dinamis yang komprehensif—mencakup manipulasi *Hue*, *Saturation*, *Value* (HSV), *Horizontal Flipping*, dan *Mosaic Augmentation*—terbukti efektif melipatgandakan dataset dari 5.000 menjadi 9.742 citra latih. Hasil pengujian empiris menunjukkan model hasil optimasi sukses mencapai nilai *Mean Average Precision* (mAP@0.5) sebesar 95,3%, tingkat *Precision* 93,1%, *Recall* 91,1%, dan skor F1 0,92. Peningkatan akurasi yang signifikan sebesar 43,5% dibandingkan model *baseline* ini menegaskan bahwa sistem mampu beroperasi secara *real-time* dengan presisi tinggi. Keandalan ini efektif mereduksi peringatan palsu (*false positive*), sehingga sangat layak diaplikasikan sebagai instrumen pengawasan objektif untuk menggantikan metode manual. Meskipun menunjukkan tingkat generalisasi yang unggul, penelitian ini masih memiliki keterbatasan teknis. Analisis matriks kebingungan menyingkap adanya kebocoran fitur (*leakage*) minor sekitar sepuluh persen, khususnya pada kesalahan klasifikasi antara kelas rompi (*vest*) dengan latar belakang lingkungan luar ruangan kampus. Distorsi ini dipicu oleh kemiripan spektrum warna atribut pakaian dengan infrastruktur statis, serta kondisi oklusi parsial di tengah kerumunan. Oleh karena itu, penelitian selanjutnya disarankan untuk memperkaya dataset lapangan pada kelas minoritas dan mengeksplorasi teknik augmentasi geometri lanjutan seperti *shearing* dan *scaling*. Dari aspek operasional, model terbaik ini direkomendasikan untuk diintegrasikan secara langsung ke dalam infrastruktur kamera *Closed-Circuit Television* (CCTV) kampus menggunakan komputasi tepi (*edge computing*). Integrasi tersebut perlu disempurnakan dengan sistem peringatan dini (*early warning system*) untuk memberikan notifikasi pelanggaran secara instan kepada otoritas berwenang.

REFERENCES

- [1] R. Szeliski, *Texts in Computer Science: Computer Vision Algorithms and Applications Second Edition*, no. January. 2022.
- [2] R. Delussu, L. Putzu, and G. Fumera, "Synthetic Data for Video Surveillance Applications of Computer Vision: A Review," *Int. J. Comput. Vis.*, vol. 132, no. 10, pp. 4473–4509, Oct. 2024, doi: 10.1007/s11263-024-02102-x.
- [3] P. R. Kalluri, W. Agnew, M. Cheng, K. Owens, L. Soldaini, and A. Birhane, "Computer-vision research powers surveillance technology," *Nature*, vol. 643, no. 8070, pp. 73–79, Jul. 2025, doi: 10.1038/s41586-025-08972-6.
- [4] D. Triyanto, M. Zidan, M. Wahyudi, L. Pujiastuti, U. Bina Sarana Informatika, and S. Antar Bangsa, "Pengembangan Sistem Deteksi Objek Botol Real-Time dengan YOLOv8 untuk Aplikasi Vision," *Journal Computer Science*, vol. 3, no. 1, 2024.
- [5] N. Wakhidah, P. T. Pungkasanti, and A. P. R. Pinem, "Deteksi Objek menggunakan Deep Learning untuk Mengetahui Tingkat Kerumunan Mahasiswa," *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, vol. 9, no. 3, 2023, doi: 10.26418/jp.v9i3.70132.
- [6] M. R. Karthikeyan, "EFFICIENT MONITORING OF DRESS CODE ADHERENCE USING AI AND LIVE CAMERA FEEDS IN CLOUD COMPUTING ENVIRONMENTS," 2025.
- [7] J. W. Qi Li, "Lightweight Real-time Detection Method for Dress Code of Anti-static Equipment," *Academic Journal of Computing & Information Science*, vol. 6, no. 10, pp. 7–17, 2023, doi: 10.25236/ajcis.2023.061002.
- [8] Geraldo Tan, Agung Saputra, Richardo Renzo Chandra, Radja Ardjuna Rithaudin Pua, and Muhammad Akbar Maulana, "YOLOV8 DETECTION FOR STUDENT DRESS CODE COMPLIANCE USING COMPUTER VISION," *JURTEKSI (Jurnal Teknologi dan Sistem Informasi)*, vol. 12, no. 1, pp. 199–206, Dec. 2025, doi: 10.33330/jurteksi.v12i1.4350.
- [9] A. R. Firdaus, O. B. Kharisma, E. Ismaredah, and Abdillah, "Deteksi Kode Etik Berpakaian pada Area Kampus Menggunakan YoloV8," *Journal of Information System Research*, vol. 5, pp. 450–458, Jan. 2024.
- [10] T. Taufiqurrahman, A. P. Hadi, and R. E. Siregar, "Evaluasi Performa YOLOv8 Dalam Deteksi Objek Di Depan Kendaraan Dengan Variasi Kondisi Lingkungan," *Jurnal Minfo Polgan*, vol. 13, no. 2, pp. 1755–1773, Nov. 2024, doi: 10.33395/jmp.v13i2.14228.
- [11] A. Bochkovskiy, C.-Y. Wang, and H.-Y. M. Liao, "YOLOv4: Optimal Speed and Accuracy of Object Detection," Apr. 2020, [Online]. Available: <http://arxiv.org/abs/2004.10934>
- [12] Y. Yanto, F. Aziz, and I. Irmawati, "YOLO-V8 PENINGKATAN ALGORITMA UNTUK DETEKSI PEMAKAIAN MASKER WAJAH," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 3, 2023, doi: 10.36040/jati.v7i3.7047.
- [13] A. Latifah and Y. Fendriani, "KLASIFIKASI PENYAKIT KANKER PAYUDARA PADA CITRA MAMMOGRAM MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN) DAN RANDOM FOREST," *JoP*, vol. 10, no. 3, pp. 95–103, 2025, [Online]. Available: <https://www.kaggle.com/datasets/hayder17>
- [14] T. Adriyanto, R. A. Ramadhani, R. Helilintar, and A. Ristyawan, "Classification of Dog and Cat Images using the CNN Method," *ILKOM Jurnal Ilmiah*, vol. 14, no. 3, 2022, doi: 10.33096/ilkom.v14i3.1116.203-208.
- [15] D. Tsalsabila Rhamadiyahanti, "Analisa Performa Convolutional Neural Network dalam Klasifikasi Citra Apel dengan Data Augmentasi," *Media Online*, vol. 5, no. 1, pp. 154–162, 2024, doi: 10.30865/klik.v5i1.2023.
- [16] R. Delussu, L. Putzu, and G. Fumera, "Synthetic Data for Video Surveillance Applications of Computer Vision: A Review," *Int. J. Comput. Vis.*, vol. 132, no. 10, pp. 4473–4509, Oct. 2024, doi: 10.1007/s11263-024-02102-x.

- [17] T. Bayu Sasongko and A. Amrullah, “ANALISIS EFEK AUGMENTASI DATASET DAN FINE TUNE PADA ALGORITMA PRE-TRAINED CONVOLUTIONAL NEURAL NETWORK (CNN),” vol. 10, no. 4, pp. 763–768, 2023, doi: 10.25126/jtiik.2023106583.
- [18] L. N. Smith, “A disciplined approach to neural network hyper-parameters: Part 1 -- learning rate, batch size, momentum, and weight decay,” Apr. 2018, [Online]. Available: <http://arxiv.org/abs/1803.09820>
- [19] E. Daniati, R. Firliana, A. Imron, and M. F. Aditya Mufid, “ANALISIS DATA PENJUALAN PADA UMKM KONVEKSI MENGGUNAKAN METODE K-MEANS CLUSTERING DENGAN MENERAPKAN CRISP-DM,” *Prosiding Seminar Nasional Teknologi dan Sistem Informasi*, vol. 5, no. 1, 2025, doi: 10.33005/sitasi.v5i1.2542.
- [20] A. N. Fadhila, R. Firliana, and A. Ristyawan, “Monitoring Information System of Supplementary Feeding Program for Stunted Toddlers at Posyandu Matahari,” 2025.