



# Komparasi Deteksi Single Shot Detector (SSD) Dengan YouLook (Yolov8) Menggunakan GhostFaceNet Untuk Pengenalan Wajah Pada Dataset Terbatas

Pramesya Mutia Salsabila, Ardytha Luthfiarta\*, Adhitya Nugraha, Almas Najib Imam Muttaqin, Yasmine Zarifa

Fakultas Ilmu Komputer, Teknik Informatika, Universitas Dian Nuswantoro, Semarang, Indonesia  
Email: <sup>1</sup>1112113875@mhs.dinus.ac.id, <sup>2,\*</sup>ardytha.luthfiarta@dinus.ac.id, <sup>3</sup>ardytha.luthfiarta@dsn.dinus.ac.id,

<sup>4</sup>1112113644@mhs.dinus.ac.id, <sup>5</sup>1112113698@mhs.dinus.ac.id

Email Penulis Korespondensi: ardytha.luthfiarta@dinus.ac.id

Submitted: 08/11/2024; Accepted: 19/12/2024; Published: 23/12/2024

**Abstrak**—Pengenalan wajah kini menjadi topik penting dalam pengolahan citra dan visi komputer, terutama di lingkungan universitas. Penelitian ini membahas penggunaan model *GhostFaceNet* dan *YOLOv8* untuk mengatasi masalah pengenalan wajah dengan dataset terbatas, yaitu satu foto formal per individu. Dengan menerapkan teknik augmentasi gambar, kami berhasil meningkatkan akurasi sistem hingga 85%. *GhostFaceNet* unggul dalam menghasilkan gambar wajah yang akurat dan detail, yang sangat diperlukan untuk pengenalan yang tepat. Di sisi lain, *YOLOv8* lebih cepat dalam mendeteksi wajah di berbagai kondisi pencahayaan dan sudut pandang. Hasil perbandingan menunjukkan bahwa akurasi *YOLOv8* mencapai 81%, sementara *SSD* hanya 76%. Meskipun ada tantangan terkait kualitas gambar asli yang rendah, hasil penelitian ini menunjukkan potensi besar untuk penerapan sistem pengenalan wajah berbasis *deep learning*. Penelitian ini bertujuan untuk membandingkan deteksi *SSD* dan *YOLOv8* dengan menggunakan model *GhostFaceNet* dan memberikan kontribusi pada pengembangan metode pengenalan wajah yang lebih efektif dan dapat diandalkan di lingkungan akademik.

**Kata Kunci:** Deep Learning; GhostFaceNet; Pengenalan Wajah; SSD; YOLOv8

**Abstract**—Face recognition has become a crucial topic in image processing and computer vision, particularly in university environments. This study explores the use of *GhostFaceNet* and *YOLOv8* models to address the challenges of face recognition with a limited dataset, consisting of only one formal photo per individual. By applying image augmentation techniques, we improved the system's accuracy to 85%. *GhostFaceNet* excels in generating precise and detailed face embeddings, which are essential for accurate recognition. Meanwhile, *YOLOv8* demonstrates superior speed in detecting faces under various lighting conditions and angles. Comparative results reveal that *YOLOv8* achieves an accuracy of 81%, outperforming *SSD*, which only reaches 76%. Despite challenges related to the low quality of original images, the findings highlight the significant potential of deep learning-based face recognition systems. This research aims to compare *SSD* and *YOLOv8* detection models using *GhostFaceNet* and contribute to the development of more effective and reliable face recognition methods in academic settings.

**Keywords:** Deep Learning; Face Recognition; GhostFaceNet; SSD; YOLOv8

## 1. PENDAHULUAN

Universitas adalah tempat yang ramai dengan berbagai pengguna, seperti mahasiswa, staf, dan pengunjung, yang memanfaatkan layanan akademik. Banyaknya pengguna ini menimbulkan tantangan dalam hal keamanan dan pengelolaan akses, terutama terkait privasi data pribadi dan akademik. Dalam situasi ini, sistem login yang aman dan efisien menjadi sangat penting guna melindungi informasi sensitif dan menjaga kenyamanan akses ke berbagai layanan kampus. Salah satu solusi yang muncul untuk menghadapi tantangan ini adalah teknologi pengenalan wajah, yang menawarkan autentikasi yang lebih aman dan cepat dibandingkan metode tradisional seperti kata sandi atau PIN [1] [2].

Teknologi pengenalan wajah memanfaatkan fitur unik wajah pengguna untuk memverifikasi identitas mereka dengan akurasi tinggi [3]. Hal ini tidak hanya membuat akses ke layanan kampus seperti perpustakaan, laboratorium, dan sistem informasi akademik menjadi lebih mudah dan efisien, tetapi juga mengurangi risiko pencurian identitas dan akses ilegal. Selain aspek keamanan, teknologi ini juga memudahkan pengguna dalam hal kenyamanan, terutama dalam mengatasi masalah umum yang dihadapi oleh mahasiswa dan staf terkait kesulitan mengingat kata sandi untuk berbagai layanan [4]. Dengan pengenalan wajah, pengguna hanya perlu menunjukkan wajah mereka untuk mendapatkan akses, tanpa perlu menghafal dan memasukkan kata sandi berulang kali. Hal ini tidak hanya lebih praktis, tetapi juga mengurangi kesalahan akibat salah memasukkan kata sandi, sehingga keamanan dan kemudahan akses di lingkungan kampus menjadi lebih terjamin [5].

Secara teknis, pengenalan wajah menggunakan teknologi biometrik yang mengidentifikasi individu berdasarkan fitur wajah. Kemajuan dalam bidang deep learning membuat teknologi ini semakin akurat dan efisien, dan telah diadopsi di berbagai sektor, termasuk institusi Pendidikan [6]. Di universitas, sistem ini memberikan solusi autentikasi modern yang mampu memperkuat keamanan dan meningkatkan efisiensi layanan pendidikan bagi seluruh pengguna [2].

Namun, penerapan teknologi pengenalan wajah di kampus bukan tanpa tantangan. Salah satu kendala utama adalah keterbatasan dataset, di mana universitas hanya memiliki satu foto per mahasiswa, yang diambil pada tahun pertama perkuliahan. Hal ini dapat mengurangi kemampuan model untuk mengenali perubahan wajah yang terjadi seiring waktu, seperti perbedaan ekspresi atau kualitas foto yang mungkin tidak konsisten karena variasi dalam

penggunaan kamera. Kondisi pencahayaan juga mempengaruhi akurasi sistem, terutama pada gambar dengan pencahayaan yang terlalu terang atau terlalu redup. Selain itu, perubahan fisik yang terjadi selama kurun waktu tiga tahun sejak foto pertama diambil menambah tantangan dalam mengenali wajah mahasiswa. Untuk mengatasi keterbatasan ini, diperlukan pendekatan tambahan, seperti menambah data, menggunakan teknik augmentasi data, atau memilih model yang lebih tangguh dalam menghadapi variasi wajah [7].

Dalam konteks keterbatasan dataset dan tantangan teknis lainnya, sistem pengenalan wajah di kampus perlu dirancang agar efisien dalam hal waktu pelatihan dan penggunaan penyimpanan, sekaligus mampu mempertahankan akurasi dalam berbagai kondisi [8]. Pada dasarnya, sistem pengenalan wajah melibatkan dua tahap utama: deteksi wajah dan identifikasi wajah. Pertama, detektor wajah bekerja untuk mendeteksi keberadaan wajah dalam gambar, lalu model pengenalan wajah akan mengidentifikasi identitas pengguna berdasarkan fitur unik pada wajah tersebut [9].

Dalam penelitian ini, digunakan dua model deteksi wajah, yaitu *Single Shot MultiBox Detector (SSD)* dan *YOLOv8*, untuk mendukung tahap deteksi wajah. *SSD* adalah algoritma yang efisien karena dapat mendeteksi objek dalam satu langkah, menjadikannya cocok untuk aplikasi real-time yang membutuhkan kecepatan tinggi [10] [11]. Di sisi lain, *YOLOv8*, versi terbaru dari model *You Only Look Once (YOLO)*, menawarkan akurasi yang lebih baik dan mampu bekerja dalam berbagai kondisi pencahayaan serta sudut pandang, menjadikannya pilihan andal untuk deteksi wajah di lingkungan kampus [12].

Setelah tahap deteksi, model *GhostFaceNet* digunakan untuk tahap identifikasi wajah. *GhostFaceNet* dipilih karena merupakan model yang ringan namun akurat, dirancang khusus untuk aplikasi dengan keterbatasan sumber daya dan kondisi pencahayaan yang mungkin kurang ideal. Dengan kombinasi *SSD* atau *YOLOv8* sebagai detektor dan *GhostFaceNet* sebagai pengenalan wajah, diharapkan sistem ini dapat menghadapi berbagai tantangan di lingkungan kampus, mulai dari variasi ekspresi hingga perubahan pencahayaan, sambil tetap mempertahankan efisiensi dan akurasi [13] [14].

Meskipun teknologi pengenalan wajah sudah banyak digunakan di berbagai bidang, penerapannya di lingkungan kampus memiliki tantangan tersendiri. Sebagian besar universitas hanya memiliki satu foto per mahasiswa yang diambil di tahun pertama, dan foto ini mungkin tidak mencerminkan perubahan wajah mahasiswa seiring waktu, seperti ekspresi yang berbeda, kondisi pencahayaan, atau perubahan fisik. Akibatnya, model pengenalan wajah mungkin kesulitan mengenali mahasiswa dengan akurat di situasi nyata.

Untuk menangani keterbatasan data yang bersumber dari satu foto per mahasiswa yang diambil di awal semester, beberapa teknik augmentasi data akan diterapkan. Teknik augmentasi ini akan membantu memperluas variasi data dengan menciptakan gambar tambahan melalui modifikasi pada gambar asli, seperti rotasi, perubahan pencahayaan, penambahan kebisingan, dan perubahan kontras. Dengan cara ini, model pengenalan wajah dapat dilatih untuk lebih tangguh terhadap variasi tampilan wajah pengguna seiring waktu, sehingga meningkatkan akurasi dan keandalannya.

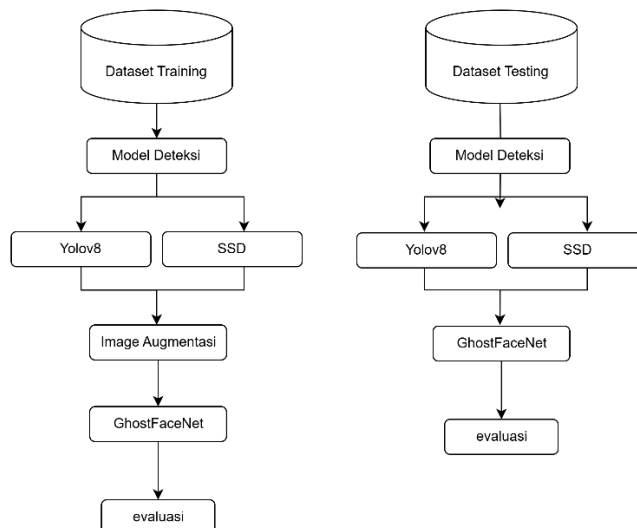
Penelitian terkait menunjukkan bahwa model *YOLOv8* dan *GhostFaceNets*, yang dirancang untuk efisiensi komputasi, sangat cocok untuk sistem autentikasi di kampus karena ringan dan cepat, memungkinkan deteksi wajah dalam kondisi real-time dan perangkat terbatas [13] [15] [16]. Selain itu, algoritma *SSD* telah berhasil digunakan dalam sistem absensi berbasis pengenalan wajah yang akurat pada pencahayaan cukup, mempercepat proses deteksi wajah dalam berbagai kondisi lingkungan. Integrasi teknik-teknik ini menunjukkan potensi besar untuk menciptakan sistem pengenalan wajah kampus yang efisien dan andal [11].

Penelitian ini bertujuan untuk mengevaluasi keandalan dan akurasi detektor wajah *SSD* dan *YOLOv8* dalam mendukung *GhostFaceNet* untuk mengenali wajah di lingkungan kampus. Model-model ini akan diuji dalam berbagai kondisi, baik ideal maupun menantang, termasuk variasi pencahayaan dan perubahan ekspresi. Diharapkan hasil penelitian ini dapat berkontribusi pada pengembangan sistem autentikasi berbasis wajah yang aman, mudah digunakan, dan efektif untuk diterapkan di universitas, sehingga dapat melindungi data pribadi dan meningkatkan pengalaman pengguna dalam mengakses layanan akademik [13].

Dengan pendekatan yang efisien dan responsif ini, serta dukungan teknik augmentasi untuk mengatasi keterbatasan data, sistem login berbasis pengenalan wajah menawarkan solusi autentikasi modern yang sesuai untuk komunitas kampus, memberikan keamanan yang lebih baik dan kenyamanan akses bagi seluruh pengguna [6].

## 2. METODOLOGI PENELITIAN

Metodologi penelitian merujuk pada langkah-langkah yang diambil oleh peneliti dalam suatu studi. Ini menjelaskan urutan kegiatan penelitian yang dilakukan, dengan tahapan-tahapan yang diterapkan dalam penelitian ini dapat dilihat pada Gambar 1. Pada Gambar 1, dibagi menjadi dua tahapan yaitu training dan testing. Pada training ini menggunakan dataset training yang akan di deteksi dengan *YOLOv8* dan *SSD*, setelah di deteksi akan dilakukan image augmentasi pada data yang menggunakan beberapa teknik augmentasi. Data yang telah di augmentasi kemudian diekstraksi fiturnya menggunakan *GhostFaceNet*. Selanjutnya, model di evaluasi menggunakan metrik akurasi, *presisi*, *recall*, dan *F1-score*. Proses yang sama diulangi pada Dataset Testing, namun tanpa augmentasi, untuk memastikan model yang telah dilatih mampu mengenali wajah dalam kondisi nyata.



**Gambar 1.** Alur Penelitian

## 2.1 Dataset

Pertama adalah mengumpulkan data yang akan digunakan untuk proses pelatihan dan pengujian model. Data dibagi menjadi Dataset Training untuk melatih model dan Dataset Testing untuk menguji kinerja model yang telah dilatih.

## 2.2 Model Deteksi

Setelah melalui tahap pre-processing, wajah dideteksi menggunakan model *SSD* atau *YOLOv8*, masing-masing memiliki cara kerja dan keunggulan tersendiri. *Model SSD (Single Shot Detector)* membagi gambar menjadi beberapa grid dan setiap grid berfungsi untuk mendeteksi area wajah. Ini membuat *SSD* bekerja dengan cepat, meskipun kadang-kadang kurang akurat jika wajah berada di posisi yang sulit atau terhalang [10] [11].

Sementara itu, *YOLOv8 (You Only Look Once)* dikenal karena kemampuannya mendeteksi wajah langsung dari latar belakang dalam satu langkah [15]. Model ini memproses seluruh gambar sekaligus, sehingga bisa mendeteksi semua objek, termasuk wajah, dengan lebih tepat. Dengan cara ini, *YOLOv8* tidak hanya cepat, tetapi juga lebih akurat karena mempertimbangkan konteks gambar secara keseluruhan [16].

Kedua metode ini membantu mengisolasi area wajah dari latar belakang, sehingga data yang dihasilkan menjadi lebih bersih dan siap untuk tahap pengenalan berikutnya. Setelah wajah terdeteksi, langkah selanjutnya adalah melakukan *cropping* pada area wajah tersebut menjadi ukuran 128x128 piksel dan mengubahnya menjadi *grayscale*. Dengan wajah yang terdeteksi dengan baik dan diproses menjadi format yang konsisten, model seperti *GhostFaceNet* dapat bekerja lebih efisien, mengenali fitur unik dari wajah tersebut, dan menghasilkan hasil yang lebih akurat. Proses ini sangat penting dalam aplikasi seperti verifikasi identitas, di mana kecepatan dan ketepatan sangat dibutuhkan.

## 2.3 Augmentasi Gambar

Augmentasi gambar adalah teknik yang digunakan untuk meningkatkan variasi data pelatihan tanpa menambah jumlah data asli. Proses ini melibatkan beberapa transformasi, seperti rotasi, yang memutar gambar pada sudut tertentu untuk membantu model mengenali wajah dari berbagai sudut pandang. Perubahan skala juga diterapkan untuk mengubah ukuran gambar, sehingga model dapat mengenali wajah yang lebih dekat atau lebih jauh. Penyesuaian kecerahan dan kontras digunakan untuk mensimulasikan berbagai kondisi pencahayaan, dengan mengubah tingkat kecerahan dan perbedaan antara area terang dan gelap, sehingga membantu model memahami detail wajah. Selain itu, *flipping* dan *cropping* digunakan untuk membalik gambar secara horizontal atau memotong sebagian gambar, menciptakan variasi baru. Dengan menggunakan augmentasi gambar, model menjadi lebih robust dan mampu mengenali wajah dalam beragam kondisi, meningkatkan akurasi dan generalisasi saat dihadapkan pada data nyata [17].

## 2.4 Model Pengenalan

Dalam penelitian ini, digunakan model pengenalan wajah *GhostFaceNet*, yang dirancang untuk beroperasi cepat dan efisien, bahkan di perangkat dengan keterbatasan memori dan daya komputasi. *GhostFaceNet* mengimplementasikan *Ghost modules*, sebuah metode yang sederhana namun efektif untuk meningkatkan informasi dari gambar wajah tanpa memerlukan banyak daya, sehingga mampu mengenali wajah dengan lebih baik. Selain itu, model ini menggunakan fungsi aktivasi *PReLU* dan menambahkan modul *SE (Squeeze-and-Excitation)* untuk meningkatkan kemampuan dalam membedakan antara wajah yang berbeda. Desain ini menjadikannya sangat cocok untuk digunakan pada perangkat khusus seperti *FPGA* dan efisien untuk verifikasi wajah di perangkat bergerak [13].

Sehingga Ketika digunakan bersama model deteksi objek seperti *YOLOv8* dan *Single Shot Detector (SSD)*, *GhostFaceNet* dapat meningkatkan alur kerja deteksi wajah dengan lebih cepat dan akurat. *YOLOv8* dan *SSD*

berfungsi untuk mendeteksi keberadaan wajah secara cepat, sementara *GhostFaceNet* fokus pada pengenalan detail wajah dengan akurat. Kombinasi ini menciptakan sistem yang optimal untuk aplikasi keamanan atau verifikasi identitas secara *real-time*, meningkatkan efektivitas dan responsivitas dalam situasi yang membutuhkan pengenalan wajah cepat.

## 2.5 Evaluasi

Setelah proses pelatihan model selesai, tahap evaluasi dilakukan untuk menilai kinerja model. Metode evaluasi meliputi pengukuran metrik seperti akurasi, *precision*, *recall*, dan *F1-score* yang dihitung berdasarkan hasil prediksi pada dataset pengujian [18]. Evaluasi ini bertujuan untuk menentukan seberapa efektif model pengenalan wajah dalam mengenali dan mengidentifikasi wajah dalam berbagai kondisi yang mungkin ditemui di lingkungan universitas.

Dalam mengevaluasi kinerja model pengenalan wajah, terdapat empat metrik utama yang sering digunakan seperti akurasi, *precision*, *recall*, dan *F1-score*. Akurasi menunjukkan persentase prediksi yang benar dibandingkan dengan total gambar yang diuji, memberikan gambaran umum tentang performa model, meskipun kurang efektif jika dataset memiliki ketidakseimbangan (1). *Precision* mengukur ketepatan model dalam menghasilkan prediksi positif, yang menjadi krusial ketika kesalahan positif memiliki dampak signifikan (2), sedangkan *recall* mengevaluasi kemampuan model untuk mendeteksi semua wajah yang seharusnya dikenali (3). *F1 score* mengintegrasikan *precision* dan *recall*, menyeimbangkan kebutuhan untuk menghindari kesalahan positif dengan akurasi dalam mendeteksi wajah (4).

$$Akurasi = \frac{Jumlah\ Prediksi\ Benar}{Total\ Gambar} \tag{1}$$

$$Precision = \frac{TP}{TP+FP} \tag{2}$$

$$Recall = \frac{TP}{TP+FN} \tag{3}$$

$$F1\ Score = \frac{2 \times Precision \times Recall}{Precision+Recall} \tag{4}$$

Dalam proses evaluasi, *True Positive (TP)* mencerminkan prediksi yang benar, *True Negative (TN)* menunjukkan saat model dengan tepat tidak mengenali objek bukan wajah, *False Positive (FP)* terjadi saat model keliru mengidentifikasi objek bukan wajah sebagai wajah yang valid, dan *False Negative (FN)* muncul ketika model gagal mendeteksi wajah yang ada. Kombinasi metrik ini memberikan pemahaman menyeluruh tentang kemampuan model, yang memungkinkan pengembang untuk mengidentifikasi kekuatan dan kelemahan serta melakukan perbaikan yang diperlukan.

## 3. HASIL DAN PEMBAHASAN

Pada penelitian ini menggunakan *GhostFaceNet* sebagai model utama untuk pengenalan wajah, dengan model deteksi wajah dilakukan menggunakan *YOLOv8* yang fokus pada akurasi deteksi wajah [16]. Ukuran gambar yang diproses adalah 128x128 piksel, sementara pengenalan wajah didasarkan pada metrik *Cosine Similarity*, dirumuskan sebagai:

$$Cosine = \frac{x \cdot y}{\|x\| \|y\|} \tag{5}$$

Di mana  $x$  dan  $y$  adalah vektor representasi dua wajah yang dibandingkan. *Threshold* ditetapkan pada 0,75, nilai *Cosine Similarity* (5) di bawah threshold ini mengindikasikan wajah yang dikenali, sedangkan nilai di atasnya mengindikasikan wajah yang tidak dikenali [19].

### 3.1 Dataset Training

Dataset yang didapatkan dari Universitas Dian Nuswantoro berjumlah 10 foto mahasiswa yang berbeda, diambil di tahun pertama mahasiswa masuk. Dataset ini diambil dengan izin dari pihak yang bersangkutan.



**Gambar 2.** Foto formal mahasiswa Dian Nuswantoro

Pada Gambar 2, foto formal mahasiswa memiliki resolusi yang bervariasi, dengan beberapa menampilkan detail yang sangat tajam, sementara yang lain kurang jelas. Variasi ini dipengaruhi oleh kondisi pencahayaan saat pengambilan gambar yang berbeda, di mana ada foto yang diambil dalam pencahayaan terang, sementara lainnya dalam pencahayaan rendah. Kondisi ini dapat memengaruhi kemampuan model dalam mengenali fitur wajah. Selain itu, jarak pengambilan gambar juga bervariasi yang diambil dari jarak dekat dan yang lain dari jarak jauh, yang berpengaruh pada ukuran dan detail fitur wajah yang terlihat.


### 3.2 Dataset Testing

Data testing adalah komponen kunci dalam mengevaluasi model pengenalan wajah karena berfungsi untuk menilai performa model dengan data baru yang belum pernah dilihat sebelumnya. Pada gambar sebelumnya, dataset testing berisi 100 foto, dengan setiap mahasiswa memiliki 10 foto yang bervariasi dalam pose, efek, pencahayaan, dan sudut pengambilan. Semua foto telah diberi label untuk digunakan pada tahap evaluasi. Foto-foto dalam dataset testing ini juga diambil pada tahun yang berbeda dari dataset pelatihan, sehingga model diuji dalam kondisi yang lebih beragam.



**Gambar 3.** Contoh Foto Testing Arley

Pada Gambar 3, contoh data testing ini menunjukkan sepuluh foto seseorang dengan label "arley" dan nomor dari 1 hingga 10. Setiap foto menampilkan variasi pencahayaan, latar belakang, serta posisi wajah, seperti pencahayaan terang dan redup, jarak dekat dan jauh, dan orientasi wajah yang berbeda-beda. Variasi ini bertujuan untuk menguji ketahanan model dalam mengenali wajah di berbagai kondisi nyata, memastikan bahwa model dapat menggeneralisasi dengan baik saat digunakan dalam aplikasi autentikasi wajah di dunia nyata.



**Gambar 4.** Pengenalan Wajah Arley

Pada Gambar 4, merupakan visualisasi hasil pengenalan wajah menggunakan *GhostFaceNet* dengan sampel data wajah Arley, setelah diterapkan proses augmentasi. Proses ekstraksi fitur dari gambar mahasiswa yang diekstraksi menjadi vektor *embedding* membantu model dalam melakukan prediksi dengan berbagai tingkat augmentasi yang diuji.

### 3.3 Augmentasi Gambar

Dataset training yang terdiri dari 10 gambar untuk setiap mahasiswa, kemudian diperbanyak menjadi 15, 30, dan 45 gambar untuk setiap individu. Proses ini menjadi dasar pelatihan model pengenalan wajah. Dengan memperbanyak jumlah gambar, variasi gambar juga meningkat. Dataset ini diaugmentasi menggunakan beberapa teknik, seperti yang dijelaskan dalam Tabel 1. Dalam proses augmentasi berbagai teknik digunakan untuk memperkaya variasi data latih

dan meningkatkan ketahanan model terhadap kondisi beragam yang bisa ditemui di dunia nyata, seperti perbedaan pencahayaan, posisi, orientasi, dan skala objek. Tujuan dari augmentasi ini adalah memperkuat kemampuan generalisasi model, dan meningkatkan variasi model terutama pada data latih yang terbatas.

**Tabel 1.** Penerapan Augmentasi

Teknik Augmentasi		
Jenis	Nilai	Efek
<i>Noise Poison</i>	Intensitas: 0 - 10	Menambah noise acak untuk mensimulasikan efek noise pada gambar
Rotasi	Sudut: -10 hingga 10	Mengubah orientasi gambar
Skala	Faktor Skala:0.5-1.0	Mengubah ukuran objek dalam gambar, mensimulasikan variasi jarak subjek terhadap kamera.
Shear	-16 hingga 16	Memanipulasi dan menganalisis wajah dalam gambar, memperluas dataset pelatihan dengan mengubah orientasi dan bentuk gambar wajah.
Translasi	Persentase Translasi: $x = -0.1$ hingga $0.1$ , $y = -0.1$ hingga $0.1$	Menggeser posisi objek dalam gambar, membantu model mengenali objek di posisi berbeda.
Penambahan Detail	Diterapkan	Meningkatkan kontras mikro, menonjolkan fitur-fitur kecil seperti tekstur atau garis halus
Flip Horizontal	Diterapkan	Membalik gambar secara horizontal
Kontras Gamma	Nilai Gamma 0.5-1.5	Mengubah kontras gambar
<i>Blur Gaussian</i>	Sigma : 0.5 - 1.5	Membuat efek blur pada gambar
Perubahan Intensitas	Faktor:0.5-1.5	Mengubah kecerahan gambar, mensimulasikan variasi pencahayaan.
Penajaman Gambar	Alpha 0.0, Tingkat Kecerahan:0.5-1.5	Mempertajam detail gambar

Pada Tabel 1, salah satu teknik yang digunakan adalah penambahan *noise Poisson* dengan intensitas antara 0 hingga 10, untuk meniru efek noise pada gambar, yang membuat model lebih tahan terhadap gangguan acak. Rotasi gambar juga diterapkan pada sudut -10 hingga 10 derajat agar model bisa mengenali objek meskipun orientasinya sedikit berubah.

Skala gambar diterapkan dalam rentang 0.5 hingga 1.0 untuk mensimulasikan variasi jarak subjek dengan kamera, membuat model lebih adaptif terhadap objek dalam berbagai ukuran. Teknik shear juga diterapkan dengan sudut -16 hingga 16 derajat untuk mengubah bentuk dan orientasi gambar wajah, sehingga model dilatih dengan variasi yang lebih luas.

Translasi gambar dilakukan dengan menggeser objek dalam rentang -10% hingga 10% dari lebar dan tinggi asli, melatih model agar tetap mengenali objek meskipun posisinya tidak berada di tengah. Penambahan detail pada gambar meningkatkan kontras mikro, memperjelas fitur kecil seperti tekstur dan garis halus, sehingga model dapat mendeteksi fitur dengan lebih baik.

Pembalikan gambar horizontal melatih model untuk mengenali objek dari kedua sisi, meningkatkan adaptabilitas terhadap perubahan orientasi. Perubahan kontras gamma diterapkan dengan nilai antara 0.5 hingga 1.5, membantu model mengenali objek dalam kondisi pencahayaan yang beragam.

Selain itu, *blur Gaussian* diterapkan dengan tingkat antara 0.5 hingga 1.5, meniru kondisi gambar buram sehingga model tetap bisa mendeteksi objek meskipun kualitas gambar rendah. Perubahan intensitas piksel antara 0.5 hingga 1.5 mensimulasikan variasi pencahayaan, membantu model beradaptasi dengan perubahan pencahayaan yang bisa terjadi. Penajaman gambar dengan tingkat kecerahan antara 0.5 hingga 1.5 memperjelas detail dalam gambar, mendukung model untuk mendeteksi fitur objek secara lebih akurat.

Secara keseluruhan, teknik augmentasi ini membuat model lebih siap untuk mengenali objek dalam berbagai kondisi gambar di dunia nyata. Dengan beragam variasi dalam data latih, model memiliki daya tahan lebih tinggi dalam mengenali objek dalam berbagai situasi.

Dalam proses augmentasi pada Gambar 5, merupakan yang sudah digenerate sebanyak 45 kali dan menerapkan Teknik augmentasi pada table 1 sehingga menciptakan berbagai variasi gambar wajah. Proses ini bertujuan agar model dapat mengenali pola dalam gambar, sehingga dapat meningkatkan performa model saat di aplikasikan pada data nyata.



Gambar 5. Foto Setelah di Augmentasi

### 3.4 Hasil Pengujian

Pada Tabel 2, penelitian ini menghasilkan hasil perbandingan antara *SSD* dan *YOLOv8* dengan menggunakan model *GhostFaceNet* seperti berikut

Table 2. Hasil Perbandingan *SSD* vs *YOLOv8*

Model Jumlah Augmentasi	SSD					YOLOv8				
	time	akurasi	Precision	recall	f1 score	time	akurasi	Precision	recall	f1 score
0	3s	0.76	0.99	0.77	0.86	4s	0.74	0.90	0.80	0.85
15	1m3	0.73	0.74	0.97	0.84	1m2	0.81	0.82	0.99	0.90
30	2m52s	0.73	0.74	0.90	0.84	2m5s	0.82	0.82	1.00	0.90
45	5m5s	0.69	0.69	1.00	0.82	2m52s	0.85	0.86	0.99	0.92

Pada jumlah augmentasi 0 di tabel 2 *SSD* memiliki akurasi 0,76 dengan waktu proses cepat, hanya 3 detik. Model ini sangat tepat dalam mendeteksi objek dengan precision 0,99, tapi belum bisa mendeteksi semua objek karena recall-nya hanya 0,77. *F1-Score*-nya berada di 0,86, yang menunjukkan keseimbangan cukup baik. *YOLOv8* di level ini membutuhkan sedikit lebih lama, yaitu 4 detik, dengan akurasi 0,74. *Precision YOLOv8* sebesar 0,90 dan *recall*-nya 0,80, menghasilkan *F1-Score* 0,85, sedikit di bawah *SSD*, namun performanya tetap mirip.

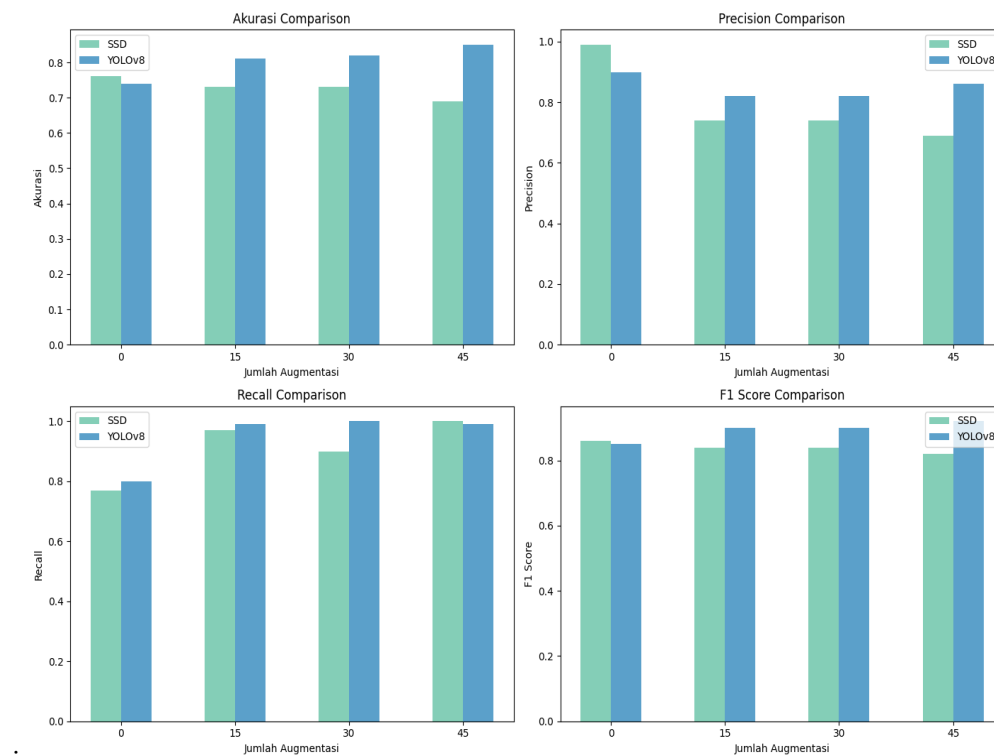
Pada augmentasi 15, *SSD* mulai butuh waktu lebih lama yaitu 1 menit 3 detik, dan akurasinya turun ke 0,73. *Precision SSD* juga turun ke 0,74, tetapi *recall*-nya naik signifikan menjadi 0,97, yang artinya hampir semua objek terdeteksi. *F1-Score SSD* turun sedikit menjadi 0,84. Sementara itu, *YOLOv8* tampil lebih baik dengan akurasi 0,81 dalam waktu lebih singkat, 1 menit 2 detik. *Precision YOLOv8* mencapai 0,82 dan *recall*-nya 0,99, menunjukkan performa yang hampir sempurna dalam mendeteksi objek, dengan *F1-Score* sebesar 0,90.

Augmentasi 30, *SSD* membutuhkan waktu 2 menit 52 detik dengan akurasi tetap di 0,73. *Precision*-nya tidak berubah, tetapi *recall* turun sedikit ke 0,90, dan *F1-Score* tetap stabil di 0,84. Di sisi lain, *YOLOv8* makin unggul dengan akurasi meningkat menjadi 0,82 dalam waktu lebih cepat, 2 menit 5 detik. *Precision YOLOv8* tetap di 0,82, dan *recall*-nya sempurna di 1,00, menunjukkan bahwa semua objek berhasil terdeteksi. *F1-Score YOLOv8* tetap di 0,90, menunjukkan performa yang stabil dan unggul.

Sedangkan augmentasi 45, *SSD* perlu waktu paling lama, yaitu 5 menit 5 detik, dan akurasinya turun lagi ke 0,69. *Precision SSD* juga turun menjadi 0,69, meskipun *recall* tetap tinggi di 1,00, artinya semua objek terdeteksi, tetapi ketepatannya rendah. *F1 Score SSD* turun ke 0,82. Sementara itu, *YOLOv8* menunjukkan hasil terbaik dengan akurasi mencapai 0,85 dalam waktu yang jauh lebih cepat, yaitu 2 menit 52 detik. *Precision YOLOv8* meningkat menjadi 0,86 dan *recall* tetap tinggi di 0,99, menghasilkan *F1-Score* 0,92, menunjukkan keseimbangan optimal dalam mendeteksi objek secara lengkap dan tepat.

Dalam perbandingan antara *SSD* dan *YOLOv8*, *SSD* menunjukkan kecepatan yang lebih baik pada tingkat augmentasi yang rendah, tetapi kinerjanya cenderung menurun dengan augmentasi yang lebih tinggi. Di sisi lain, *YOLOv8* konsisten dan lebih unggul dalam akurasi serta *precision*, terutama pada augmentasi yang lebih tinggi. Meskipun *SSD* dapat mendeteksi hampir semua objek di tingkat augmentasi tinggi, *precision*-nya menurun, sedangkan *YOLOv8* mampu mempertahankan kemampuan mendeteksi semua objek dengan *precision* yang lebih baik. Selain itu,

*YOLOv8* mencatat *F1-Score* yang lebih tinggi, menunjukkan keseimbangan yang optimal antara ketepatan dan jumlah objek yang terdeteksi. Berikut adalah diagram batang perbandingan dua deteksi *YOLOv8* dan *SSD* dari segi akurasi, *precision*, *recall* dan *F1-score*[20]



**Gambar 6.** Diagram perbandingan

Ketika augmentasi diterapkan pada satu gambar per mahasiswa, dapat dilihat pada gambar 6 akurasi model *SSD* mengalami penurunan hingga menjadi 69%, disertai dengan penurunan *precision* yang juga mencapai 69%. Meskipun *recall* tetap 100%, *F1-score* menurun menjadi 82%. Penurunan akurasi ini dapat dikaitkan dengan meningkatnya variasi yang dihasilkan dari proses augmentasi, yang menciptakan tantangan baru bagi model dalam mengenali pola-pola wajah.

Variasi ini memerlukan model untuk melakukan penyesuaian lebih banyak dalam mempelajari dan memahami fitur-fitur baru yang muncul dari gambar-gambar yang telah diaugmentasi. Ketidakmampuan model untuk menangkap pola yang lebih kompleks akibat dari augmentasi ini dapat menyebabkan kesulitan dalam klasifikasi yang akurat. Oleh karena itu, meskipun augmentasi dapat meningkatkan keragaman data, penting untuk menemukan keseimbangan yang tepat agar model dapat beradaptasi tanpa mengorbankan kinerja keseluruhan, khususnya dalam konteks deteksi wajah yang memerlukan tingkat akurasi yang tinggi [21].

## 4. KESIMPULAN

Penelitian ini menunjukkan bahwa augmentasi gambar efektif dalam meningkatkan akurasi model deteksi wajah, terutama dengan menambahkan 45 gambar augmentasi untuk setiap data asli. Dalam uji coba, model *YOLOv8* menunjukkan kinerja yang lebih unggul dibandingkan *SSD*, baik dari segi akurasi maupun *F1-score*, khususnya dalam menghadapi variasi kondisi seperti pencahayaan, posisi, dan orientasi wajah. Hasil terbaik dicapai dengan akurasi 85% menggunakan *YOLOv8*, sementara *SSD* mengalami penurunan akurasi hingga 69% pada jumlah augmentasi gambar yang sama. Dengan performa yang lebih stabil, penerapan *YOLOv8* dalam sistem login universitas berpotensi meningkatkan keamanan dan kenyamanan proses autentikasi bagi mahasiswa. Model ini memungkinkan deteksi wajah yang lebih cepat dan akurat, mendukung autentikasi yang efisien dan aman di lingkungan akademik. Secara keseluruhan, penelitian ini berhasil mencapai tujuan untuk menyediakan sistem autentikasi yang lebih baik, sekaligus mengurangi kesalahan deteksi atau pengenalan wajah yang mungkin kurang akurat.

## REFERENCES

- [1] J. Deng, J. Guo, D. Zhang, Y. Deng, X. Lu, and S. Shi, "Lightweight Face Recognition Challenge," in *2019 IEEE/CVF International Conference on Computer Vision Workshop (ICCVW)*, Seoul, Korea (South): IEEE, Oct. 2019, pp. 2638–2646. doi: 10.1109/ICCVW.2019.00322.



- [2] A. Setiawan, R. Sigit, and R. Rokhana, “Face Recognition Using Convolution Neural Network Method with Discrete Cosine Transform Image for Login System,” *JOIV: Int. J. Inform. Visualization*, vol. 7, no. 2, p. 502, May 2023, doi: 10.30630/joiv.7.2.1546.
- [3] L. Li, X. Mu, S. Li, and H. Peng, “A Review of Face Recognition Technology,” *IEEE Access*, vol. 8, pp. 139110–139120, 2020, doi: 10.1109/ACCESS.2020.3011028.
- [4] Thakur Polytechnic and Mr. K. Shaikh, “Criminal Investigation with the Help of Face Recognition,” *IJSREM*, vol. 08, no. 02, pp. 1–13, Feb. 2024, doi: 10.55041/IJSREM28671.
- [5] D. Y. Ardhito, D. Susilo, D. Ruswanti, and D. Retnoningsih, “Optimasi Face Recognition Untuk Presensi Pegawai,” *Technical and Vocational Education International Journal (TAVEIJ)*, vol. 3, no. 2, Art. no. 2, Aug. 2023, doi: 10.556442/taveij.v3i2.306.
- [6] N. Dewi and F. Ismawan, “IMPLEMENTASI DEEP LEARNING MENGGUNAKAN CNN UNTUK SISTEM PENGENALAN WAJAH,” *FaktorExacta*, vol. 14, no. 1, p. 34, Mar. 2021, doi: 10.30998/faktorexacta.v14i1.8989.
- [7] M. Kim, A. K. Jain, and X. Liu, “AdaFace: Quality Adaptive Margin for Face Recognition,” Feb. 16, 2023, *arXiv: arXiv:2204.00964*. doi: 10.48550/arXiv.2204.00964.
- [8] F. Boutros, N. Damer, M. Fang, F. Kirchbuchner, and A. Kuijper, “MixFaceNets: Extremely Efficient Face Recognition Networks,” Jul. 27, 2021, *arXiv: arXiv:2107.13046*. doi: 10.48550/arXiv.2107.13046.
- [9] H. Kim, H. Choi, and Y. Kwak, “Federated Learning for Face Recognition via Intra-subject Self-supervised Learning,” Jul. 23, 2024, *arXiv: arXiv:2407.16289*. doi: 10.48550/arXiv.2407.16289.
- [10] N. I. Burhanudin, A. D. Laksito, A. Sidauruk, M. R. A. Yudianto, and A. N. Rahmi, “Object Recognition with SSD MobileNet Pre-Trained Model in the Cashier Application,” *SISFOKOM*, vol. 12, no. 2, pp. 265–270, Jul. 2023, doi: 10.32736/sisfokom.v12i2.1659.
- [11] R. D. Djohari, H. R. Ngemba, S. Hendra, D. S. Angraeni, N. T. Lapatta, and D. W. Nugraha, “Employee Attendance System with Facial Recognition Technology Using a Single Shot Detector (SSD) Algorithm,” *JITE*, vol. 7, no. 2, pp. 424–434, Jan. 2024, doi: 10.31289/jite.v7i2.10869.
- [12] Q. Xu, Z. Zhu, H. Ge, Z. Zhang, and X. Zang, “Effective Face Detector Based on YOLOv5 and Superresolution Reconstruction,” *Computational and Mathematical Methods in Medicine*, vol. 2021, pp. 1–9, Nov. 2021, doi: 10.1155/2021/7748350.
- [13] M. Alansari, O. A. Hay, S. Javed, A. Shoufan, Y. Zweiri, and N. Werghi, “GhostFaceNets: Lightweight Face Recognition Model From Cheap Operations,” *IEEE Access*, vol. 11, pp. 35429–35446, 2023, doi: 10.1109/ACCESS.2023.3266068.
- [14] Muhammad Indra Ardiawan and Gede Putra Kusuma Negarara, “Comparative Analysis of FaceNet, VGGFace, and GhostFaceNets Face Recognition Algorithms For Potential Criminal Suspect Identification,” *J. Appl. Artif. Intell.*, vol. 5, no. 2, pp. 34–49, Sep. 2024, doi: 10.48185/jaai.v5i2.1237.
- [15] C. Fang and X. Yang, “Lightweight YOLOv8 for Wheat Head Detection,” *IEEE Access*, vol. 12, pp. 66214–66222, 2024, doi: 10.1109/ACCESS.2024.3397556.
- [16] Y. Wang, K. Zhang, L. Wang, and L. Wu, “An Improved YOLOv8 Algorithm for Rail Surface Defect Detection,” *IEEE Access*, vol. 12, pp. 44984–44997, 2024, doi: 10.1109/ACCESS.2024.3380009.
- [17] S. Porcu, A. Floris, and L. Atzori, “Evaluation of Data Augmentation Techniques for Facial Expression Recognition Systems,” *Electronics*, vol. 9, no. 11, p. 1892, Nov. 2020, doi: 10.3390/electronics9111892.
- [18] Fernando Situmorang, Gilbert and R. Purba, “Deteksi Potensi Depresi dari Unggahan Media Sosial X Menggunakan Teknik NLP dan Model IndoBERT,” *Technology and Science (BITS)*, vol. 6, no. 2, 2024, doi: 10.47065/bits.v6i2.5496.
- [19] N. Mardiana, R. D. Dana, Faisal, I. Farida, A. G. Azwar, and Nurwathi, “Similarity Measures Implementation on Face Authentication using Indonesian Citizen ID Card,” in *2023 17th International Conference on Telecommunication Systems, Services, and Applications (TSSA)*, Lombok, Indonesia: IEEE, Oct. 2023, pp. 1–5. doi: 10.1109/TSSA59948.2023.10366880.
- [20] K. Han, Y. Wang, Q. Tian, J. Guo, C. Xu, and C. Xu, “GhostNet: More Features from Cheap Operations,” Mar. 13, 2020, *arXiv: arXiv:1911.11907*. doi: 10.48550/arXiv.1911.11907.
- [21] C. Oinar, B. M. Le, and S. S. Woo, “KappaFace: Adaptive Additive Angular Margin Loss for Deep Face Recognition,” *IEEE Access*, vol. 11, pp. 137138–137150, 2023, doi: 10.1109/ACCESS.2023.3338648.