

ANALISIS PENGARUH METODE *IMAGE ENHANCEMENT* KIND++ TERHADAP MODEL DETEKSI DAN *PROFILING* WAJAH PADA KONDISI *LOW-LIGHT*

Dewi Anggita Yulianti^{*1)}, Yana Aditia Gerhana²⁾, Gitarja Sandi³⁾

1. Teknik Informatika, Sains dan Teknologi, UIN Sunan Gunung Djati Bandung, Indonesia

2. Teknik Informatika, Sains dan Teknologi, UIN Sunan Gunung Djati Bandung, Indonesia

3. Teknik Informatika, Sains dan Teknologi, UIN Sunan Gunung Djati Bandung, Indonesia

Article Info

Kata Kunci: Deteksi Wajah; Peningkatan Citra; Pencahayaan Rendah; *Profiling* Wajah

Keywords: *Face Detection*; *Image Enhancement*; *Low-Light*; *Face Profiling*

Article history:

Received 10 June 2025

Revised 16 June 2025

Accepted 20 June 2025

Available online 1 September 2025

DOI :

<https://doi.org/10.29100/jupi.v10i3.8283>

* Corresponding author.

Dewi Anggita Yulianti

E-mail address:

dewianggitayulianti@gmail.com

ABSTRAK

Model deteksi dan *profiling* wajah menjadi salah satu teknologi pendukung dalam penanganan kasus kejahatan yang terus meningkat. Performa model deteksi dan *profiling* (estimasi usia, dan klasifikasi jenis kelamin) yang menurun secara signifikan dalam kondisi *low-light*, menjadi tantangan yang serius. Untuk mengatasi tantangan tersebut, penelitian ini menerapkan metode *image enhancement* berbasis *deep learning*, yaitu KinD++, sebagai tahap *preprocessing* sebelum gambar dianalisis oleh model. Proses *enhancement* berpotensi meningkatkan kualitas visual, namun juga memungkinkan terjadinya perubahan struktur wajah yang penting bagi proses analisis. Penelitian ini mengevaluasi pengaruh KinD++ terhadap performa ketiga model dalam kondisi *low-light*. Berdasarkan hasil penelitian, penerapan metode *enhancement* KinD++ terbukti memberikan dampak positif terhadap seluruh model yang diuji. Pada model deteksi wajah, nilai mAP@50-95 meningkat dari 0,24 menjadi 0,28. Pada model klasifikasi jenis kelamin, akurasi meningkat dari 0,80 menjadi 0,82. Sementara itu, MAE (*Mean Average Error*) model estimasi usia mengalami penurunan dari 15,2 menjadi 7,6. Hasil ini menunjukkan bahwa KinD++ membantu meningkatkan performa model yang menurun akibat kondisi *low-light*, walaupun perubahan visual yang ditimbulkan tetap berisiko mengganggu informasi penting pada wajah, sehingga hasilnya tidak sebaik performa model saat pencahayaan normal.

ABSTRACT

Face detection and profiling models are one of the supporting technologies in handling the increasing number of crime cases. A significant challenge is the substantial decrease in performance of face detection and profiling models (age estimation and gender classification) under low-light conditions. To overcome this challenge, this study applies a deep learning-based image enhancement method, KinD++, as a preprocessing step before images are analyzed by the models. While enhancement has the potential to improve visual quality, it can also lead to changes in facial structures that are important for the analysis process. This study evaluates the impact of KinD++ on the performance of all three models under low-light conditions. The results show that the application of the KinD++ enhancement method positively impacted all tested models. For the face detection model, the mAP@50-95 score increased from 0,24 to 0,28. In the gender classification model, accuracy improved from 0,80 to 0,82. Meanwhile, the MAE (Mean Average Error) of the age estimation model decreased from 15,2 to 7,6. These results indicate that KinD++ helps improve the performance of models degraded by low-light conditions, but the introduced visual changes can still disrupt important facial information, resulting in outcomes that are not as good as the models' performance under normal lighting.

I. PENDAHULUAN

SEBANYAK 35 dari 46 negara di Asia mengalami peningkatan angka kriminalitas pada periode 2021–2023. Indonesia menempati peringkat ke-8 dan termasuk negara yang mengalami peningkatan kriminalitas [1]. Kondisi ini mencerminkan bahwa isu keamanan publik masih menjadi tantangan. Sebagai upaya untuk

mengatasi tantangan tersebut, salah satu teknologi yang umum digunakan adalah kamera pengawas, yang berperan penting dalam merekam kejadian di ruang publik. Seiring kemajuan teknologi kecerdasan buatan, rekaman dari kamera pengawas kini dapat dimanfaatkan lebih lanjut sebagai data input untuk proses pengenalan wajah (*face recognition*) pelaku kejahatan melalui analisis wajah.

Berbagai metode pengenalan umumnya diawali dengan proses deteksi wajah [2]. Deteksi wajah mencakup proses menemukan dan menentukan lokasi wajah pada gambar atau video [3]. Salah satu bentuk pengenalan yang banyak digunakan adalah estimasi usia dan klasifikasi jenis kelamin, yang dalam hal ini bertujuan untuk menyaring dan mempersempit kandidat pelaku berdasarkan karakteristik dasar wajah, yang juga dikenal sebagai proses *profiling*. Estimasi usia merupakan proses prediksi usia seseorang dari gambar wajah yang umumnya diformulasikan sebagai masalah regresi *non-linear*, karena usia bersifat kontinu dan dipengaruhi oleh berbagai ciri visual pada wajah [4]. Sementara itu, klasifikasi jenis kelamin dilakukan dengan menganalisis karakteristik visual spesifik pada wajah, seperti struktur rahang, bentuk alis, dan proporsi wajah, yang umumnya berbeda antara laki-laki dan perempuan [5]. Performa dari model-model tersebut bergantung pada kualitas gambar inputnya. Gambar yang diambil dalam kondisi *low-light* mengalami berbagai jenis degradasi, seperti visibilitas rendah, *noise* yang tinggi, dan perubahan warna. Kondisi tersebut mempengaruhi kualitas visual yang berdampak pada kinerja model deteksi dan model *profiling*. Studi terdahulu menunjukkan bahwa model deteksi yang bekerja di lingkungan *low-light* mengalami penurunan performa yang signifikan [6], [7]. Perubahan detail yang terjadi akibat menurunnya visibilitas, dan peningkatan *noise*, dapat mengganggu model *profiling* yang sangat bergantung pada informasi wajah. Kondisi ini menjadi penting untuk diperhatikan mengingat data menunjukkan bahwa sebagian besar tindak kejahatan di Indonesia terjadi antara pukul 18.00 hingga 21.59 WIB [8].

Sebagai upaya mengatasi tantangan tersebut, *image enhancement* digunakan sebagai tahap *preprocessing* sebelum proses deteksi dilakukan. *Image enhancement* adalah teknik pengolahan gambar yang bertujuan meningkatkan kualitas visual, seperti kecerahan, ketajaman, dan keterbacaan gambar agar lebih optimal [9]. Metode *enhancement* tradisional terbukti cukup efektif dalam menangani kondisi *low-light* ringan, namun efektivitasnya menurun pada gambar dengan tingkat *noise* tinggi [10]. Untuk menjawab keterbatasan ini, berbagai pendekatan berbasis *deep learning* telah dikembangkan, menawarkan peningkatan visual yang lebih adaptif dan akurat [11], [12].

Berdasarkan paparan pada penelitian [13], metode *enhancement* KinD++ menunjukkan performa yang lebih baik dibanding metode *enhancement* berbasis *deep learning* lainnya, gambar hasil peningkatan metode ini memiliki warna yang lebih natural dan detail yang lebih banyak. Berbeda dengan metode *enhancement* lain yang melakukan peningkatan kecerahan secara langsung, KinD++ menerapkan pendekatan dekomposisi *layer* eksplisit dengan memisahkan gambar menjadi dua komponen: *reflectance* (R) yang merepresentasikan detail konten/tekstur, dan *illumination* (I) yang merepresentasikan pencahayaan. Strategi ini memungkinkan proses peningkatan pencahayaan dilakukan tanpa mengganggu detail visual penting. Selain itu, KinD++ dilengkapi dengan modul restorasi reflektansi berbasis *Multi-Scale Illumination Attention* (MSIA), yang mampu mengarahkan perhatian model pada area gambar yang mengalami degradasi paling parah, terutama akibat *noise* dan distorsi warna yang muncul di area gelap. MSIA ini merupakan bentuk peningkatan dari KinD versi pertama yang mengalami *oversmoothing* dan munculnya *noise* berlebih di bagian gambar yang sangat gelap.

Berbeda dengan penelitian-penelitian terdahulu yang berfokus pada peningkatan akurasi deteksi wajah pada kondisi *low-light* [14], [15], penelitian ini menganalisis lebih lanjut bagaimana proses *image enhancement* memengaruhi detail wajah yang krusial bagi model deteksi dan *profiling* wajah. Pada penelitian sebelumnya KinD++ hanya diterapkan pada gambar umum *non-wajah*, sedangkan pada penelitian ini kami menganalisis secara khusus penerapannya pada gambar wajah. Evaluasi dilakukan tidak hanya dengan membandingkan gambar *low-light* sebelum dan sesudah *enhancement*, tetapi juga dengan menilai gambar hasil *enhancement* terhadap gambar dengan pencahayaan normal. Pendekatan tiga arah ini diharapkan memperjelas peran KinD++ tidak sekadar meningkatkan visibilitas, melainkan juga menjaga kualitas informasi wajah pada sistem deteksi dan *profiling* yang beroperasi di lingkungan dengan pencahayaan rendah. Dengan demikian, penelitian ini menawarkan perspektif baru mengenai kontribusi *image enhancement* dalam domain pengenalan wajah.

II. METODE PENELITIAN


A. Dataset

Setiap tahap pelatihan model dalam penelitian ini menggunakan dataset yang berbeda. Pada tahap *image enhancement*, model yang digunakan merupakan model *pretrained* KinD++ sehingga tidak dilakukan pelatihan

ulang. Adapun dalam pengembangan model tersebut pada penelitian aslinya, proses pelatihan dilakukan menggunakan dataset LOL (*Low-Light dataset*) yang secara khusus dirancang untuk gambar dalam kondisi *low-light*.


Pelatihan model deteksi wajah dilakukan menggunakan dataset WIDER FACE [16], yang terdiri dari total 16.106 gambar pada bagian *train* dan *validation*. Karena bagian *test set* dari dataset ini tidak menyertakan anotasi secara publik, maka data *train* dan *validation* digabung, kemudian dibagi ulang dengan rasio 80:10:10 untuk keperluan pelatihan, validasi, dan pengujian. Dataset ini dipilih karena merupakan dataset yang komperhensif untuk tugas deteksi wajah dan memiliki cakupan gambar yang sangat bervariasi dalam hal skala, pose, dan kondisi pencahayaan. Hal ini membuat dataset WIDER FACE sangat representatif untuk dunia nyata.

Sementara itu, proses estimasi usia dan klasifikasi jenis kelamin dilakukan menggunakan dataset UTKFace [17], yang mencakup 23.708 gambar wajah dengan anotasi usia dan jenis kelamin. Rentang usia dalam dataset ini berkisar antara 1 hingga 116 tahun, sehingga usia di luar cakupan tersebut tidak termasuk dalam analisis. Dataset ini umum digunakan untuk tugas *profiling* berbasis wajah. Sama seperti pada tahap sebelumnya, data dibagi ke dalam rasio 80:10:10 untuk pelatihan, validasi, dan pengujian. Dataset ini dipilih karena selain menyediakan label usia dan jenis kelamin secara eksplisit, gambar-gambarnya telah terpotong dan berfokus langsung pada area wajah. Mengingat keterbatasan sumber daya, UTKFace yang berukuran sedang dinilai lebih sesuai dibandingkan dataset IMDB-WIKI yang jauh lebih besar.



Gambar. 1. Distribusi jenis kelamin pada dataset UTKFace

Distribusi jenis kelamin pada dataset UTKFace yang ditampilkan pada Gambar 1, menunjukkan ketidakseimbangan kecil antar kelas, dengan distribusi sekitar 52% laki-laki dan 48% perempuan. Meskipun selisih ini tidak terlalu besar dan diperkirakan tidak berdampak signifikan terhadap akurasi model, keberadaan bias minor ini tetap perlu diperhatikan untuk memastikan evaluasi model yang adil.



Gambar. 2. Distribusi usia pada dataset UTKFace

Histogram pada Gambar 2 menunjukkan distribusi usia yang tidak merata, dengan dua puncak utama pada usia sekitar 1 tahun dan 26 tahun. Jumlah gambar di usia muda dan dewasa awal jauh lebih dominan dibanding usia lanjut, yang hanya muncul dalam jumlah kecil. Pola ini mengindikasikan bias dataset terhadap kelompok usia muda, yang dapat memengaruhi akurasi model karena distribusi data yang tidak seimbang.

Meskipun dataset UTKFace menunjukkan ketidakseimbangan baik itu pada sebaran jenis kelamin maupun pada sebaran usia, penelitian ini belum menerapkan strategi mitigasi khusus terhadap kondisi tersebut. Potensi bias ini dapat diminimalkan dalam penelitian selanjutnya melalui penerapan strategi seperti pemberian bobot kelas (*class weighting*), *oversampling* data usia lanjut, atau augmentasi data kelompok minoritas untuk meningkatkan keadilan dan kemampuan generalisasi model terhadap distribusi usia yang lebih merata.

Data *low-light* yang digunakan untuk evaluasi model deteksi dan *profiling* wajah diperoleh melalui proses *preprocessing* menggunakan pustaka OpenCV. Setiap gambar terlebih dahulu dikonversi ke format RGB, kemudian dilakukan penurunan kecerahan dengan mengalikan nilai intensitas piksel dengan faktor 0,3, sehingga kecerahan berkurang sebesar 70%. Selanjutnya, diterapkan koreksi *gamma* dengan nilai $\gamma = 0,4$ menggunakan

metode *lookup table*, untuk menciptakan efek gelap dan memperkuat karakteristik visual *low-light*. Pada tahap akhir, gambar dikonversi ke ruang warna HSV untuk mengurangi saturasi warna sebesar 20%, yaitu dengan mengalikan nilai pada *channel* saturasi (S) dengan faktor 0,8. Setelah seluruh tahapan selesai, gambar dikonversi kembali ke format BGR untuk disimpan dan digunakan pada tahap evaluasi.

B. Model dan Konfigurasi

1) Model Deteksi Wajah

Penelitian ini menggunakan model YOLOv11n dari framework Ultralytics untuk melakukan deteksi wajah. YOLO adalah algoritma deteksi objek berbasis deep learning yang bekerja dengan pendekatan single-shot detection, artinya ia memproses gambar hanya satu kali untuk secara langsung memprediksi lokasi dan kelas objek. YOLO membagi gambar menjadi grid, dan setiap sel grid bertanggung jawab untuk memprediksi bounding box dan kelas objek jika pusat objek berada dalam sel tersebut. Setiap prediksi mencakup koordinat bounding box, confidence score, dan probabilitas kelas. Model YOLOv11n dipilih karena memiliki ukuran ringan namun tetap menunjukkan performa yang baik [18].

Pelatihan model deteksi wajah dilakukan menggunakan dataset WIDER FACE selama 100 epoch dengan konfigurasi default dari Ultralytics. Konfigurasi tersebut meliputi ukuran input gambar sebesar 640×640 piksel, *batch size* sebesar 16, *learning rate* awal sebesar 0.01 dengan *optimizer* SGD, *momentum* 0.937 dan *weight decay* sebesar 0.0005. *Batch size* adalah jumlah data yang diproses sekaligus dalam satu langkah pelatihan. *Learning rate* mengatur seberapa besar model belajar dari kesalahan di setiap langkah. *Momentum* membantu mempercepat pelatihan dengan mengingat arah pergerakan sebelumnya. Dan *weight decay* mencegah model terlalu menghafal data dengan memperkecil bobot secara bertahap.

Evaluasi performa deteksi dilakukan menggunakan metrik *precision*, *recall*, mAP@50, dan mAP@50:95. *Precision* mengukur proporsi prediksi positif yang benar, sedangkan *recall* mengukur proporsi objek wajah yang berhasil terdeteksi dari seluruh objek yang seharusnya terdeteksi. *Mean Average Precision* (mAP) merupakan metrik yang menghitung rata-rata nilai *precision* pada berbagai ambang batas *Intersection over Union* (IoU). Pada evaluasi mAP@50, prediksi dianggap benar jika $\text{IoU} \geq 0,5$, sedangkan pada mAP@50-95, nilai mAP dihitung berdasarkan rata-rata dari beberapa ambang IoU, mulai dari 0,50 hingga 0,95 dengan interval 0,05.

2) Model Estimasi Usia

Model estimasi usia menggunakan arsitektur VGG16 yang telah di-*pretrained* pada ImageNet, kemudian dilakukan *transfer learning* dan *fine-tuning* pada dataset UTKFace. VGG16 adalah arsitektur CNN yang memiliki 16 lapisan dengan bobot yang dapat dilatih, terdiri dari 13 lapisan konvolusi dan 3 lapisan *fully connected*. Model ini menggunakan filter konvolusi berukuran kecil (3×3) secara berulang, yang efektif untuk mengekstraksi informasi visual mulai dari tepi dan tekstur hingga pola dan bentuk objek yang kompleks. VGG16 mampu memperdalam representasi fitur tanpa menambah parameter secara berlebihan, yang menjadikan model ini efisien dan efektif dalam berbagai tugas pengenalan visual berskala besar [19].

Pada proses pelatihan, bobot *backbone* VGG16 dibekukan selama pelatihan, dan hanya bagian klasifikator akhir yang dilatih ulang. Pelatihan dilakukan selama 20 epoch dengan konfigurasi *learning rate* sebesar 0.0001, *batch size* 32, dan *optimizer* Adam. Model ini juga menggunakan *dropout* sebesar 0.4 untuk mencegah *overfitting*, serta fungsi *loss Mean Absolute Error* (MAE) sebagai metrik utama untuk mengevaluasi rata-rata deviasi antara usia prediksi dan usia sebenarnya. Mekanisme *early stopping* dengan *patience* 5 digunakan untuk menghentikan pelatihan jika tidak terjadi peningkatan performa pada data validasi.

3) Model Klasifikasi Jenis Kelamin

Klasifikasi jenis kelamin dilakukan menggunakan model ResNet152 yang juga menerapkan teknik *transfer learning* pada dataset UTKFace selama 20 epoch. ResNet152 merupakan salah satu arsitektur *Convolutional Neural Network* (CNN) yang memiliki kedalaman 152 lapisan. Model ini dirancang untuk mengatasi masalah pada pelatihan jaringan yang terlalu dalam seperti hilangnya informasi saat belajar (*vanishing gradient*), dengan menggunakan *residual block* dan *skip connection*. *Residual block* berfungsi untuk mempelajari perbedaan (residual) antara input dan output yang diharapkan, bukan output secara langsung. *Skip connection* menghubungkan input langsung ke output, membantu aliran informasi tetap lancar, menghindari *vanishing gradient*, dan membuat pelatihan jaringan dalam lebih stabil dan akurat [20].

Pelatihan dilakukan selama 20 epoch menggunakan konfigurasi *batch size* 32, *learning rate* 0.0001, dan *optimizer* Adam. Untuk mencegah *overfitting*, digunakan *dropout* sebesar 0.2 dan lapisan *GlobalAveragePooling2D* sebagai


pengganti lapisan flatten. Evaluasi dilakukan menggunakan metrik akurasi dan *binary crossentropy loss*. *Early stopping* juga diterapkan dengan *patience* 5, berdasarkan akurasi validasi. Arsitektur ResNet152V2 dipilih karena kemampuannya dalam menangkap pola visual kompleks secara mendalam melalui *residual block*, tanpa mengalami degradasi performa pada jaringan yang sangat dalam.

4) Lingkungan Pengembangan

Seluruh proses penelitian dilakukan menggunakan dua platform *cloud computing*, yaitu RunPod dan Google Colab, yang menyediakan fasilitas GPU untuk mempercepat proses pelatihan dan evaluasi model. Pelatihan model YOLOv11n, VGG16, dan ResNet152, dilakukan di RunPod dengan GPU NVIDIA RTX 4090, sedangkan proses evaluasi dan proses *enhancement* dilakukan di Google Colab yang menyediakan GPU seperti NVIDIA A100 atau setara.

Ketiga model tersebut dibangun dan dilatih menggunakan TensorFlow versi 2.19.0 dan Keras versi 3.9.2. Sementara itu, model untuk proses *enhancement* merupakan model pralatih (*pretrained*) yang diadopsi dari sumber eksternal tanpa dilakukan modifikasi arsitektur. Perbedaan versi pustaka yang digunakan (TensorFlow 2.15) menyebabkan kode untuk *enhancement* dijalankan secara terpisah dari proses pengujian visual guna menjaga kompatibilitas dan kestabilan lingkungan pengembangan.

5) Arsitektur Sistem



Gambar. 3. Arsitektur sistem deteksi dan *profiling* wajah dalam kondisi *low-light*

Arsitektur sistem deteksi dan *profiling* wajah yang ditunjukkan pada Gambar 3 menggambarkan alur utama dalam penelitian ini, sekaligus merepresentasikan proses yang digunakan dalam tahap pengujian sistem secara menyeluruh. Sistem dirancang untuk menerima input berupa gambar *low-light* yang disumsikan sebagai representasi frame dari rekaman kamera pengawas dalam kondisi tersebut.

Sebelum dilakukan proses deteksi wajah, gambar terlebih dahulu melalui tahap *image enhancement* untuk meningkatkan kualitas visual, khususnya dalam aspek pencahayaan. Setelah itu, proses deteksi wajah dilakukan, kemudian hasilnya disimpan dalam folder tertentu, dan wajah-wajah terdeteksi yang dinilai layak secara visual dipilih secara manual untuk dianalisis lebih lanjut menggunakan model estimasi usia dan klasifikasi jenis kelamin.

Proses ini tidak digunakan untuk evaluasi kuantitatif terhadap performa model, melainkan untuk keperluan evaluasi visual atau kualitatif guna melihat pengaruh model *enhancement* terhadap hasil pipeline secara menyeluruh. Evaluasi kuantitatif terhadap masing-masing model dilakukan secara terpisah menggunakan dataset yang telah ditentukan.

6) Skenario Pengujian

Fokus utama penelitian ini adalah mengevaluasi pengaruh kondisi *low-light* dan dampak penerapan *image enhancement* terhadap performa tiga model utama, yaitu model deteksi wajah (YOLOv11n), estimasi usia (VGG16), dan klasifikasi jenis kelamin (ResNet152). Seluruh model dilatih menggunakan data dengan pencahayaan normal.

Pengujian dilakukan melalui tiga skenario utama:

- Skenario 1 (Pencahayaannya normal): Pengujian dilakukan pada gambar dengan pencahayaan normal tanpa proses *enhancement*. Ini merepresentasikan kondisi ideal.
- Skenario 2 (*Low-Light* tanpa *enhancement*): Gambar diuji dalam kondisi *low-light* tanpa melalui proses *enhancement*, untuk mengetahui seberapa besar penurunan akurasi akibat gangguan pencahayaan.
- Skenario 3 (*Low-Light* dengan *enhancement*): Gambar *low-light* yang telah ditingkatkan kualitas pencahayaannya menggunakan metode *image enhancement* KinD++ diujikan untuk melihat apakah akurasi dapat dipulihkan atau mendekati skenario normal.

Tujuan dari pengujian ini adalah untuk menilai sejauh mana penerapan *image enhancement* dapat memperbaiki performa model dalam kondisi *low-light*, serta membandingkan hasilnya dengan gambar yang memiliki pencahayaan normal untuk melihat apakah kualitas dan struktur visual tetap terjaga.


Untuk mendukung analisis yang lebih menyeluruh, evaluasi dilakukan secara kuantitatif maupun kualitatif. Evaluasi kualitatif dilakukan secara visual untuk mengamati perbedaan output pada tiap skenario yang telah dirancang.

III. HASIL DAN PEMBAHASAN

Bagian hasil dan pembahasan memaparkan hasil evaluasi performa model YOLOv11n, VGG16, dan ResNet152 dalam tiga skenario pencahayaan, juga menganalisis perbedaan performa KinD++ dengan metode *enhancement* lain dalam proses pengenalan wajah. Tujuan utamanya adalah menilai pengaruh kondisi *low-light* dan metode *image enhancement* terhadap akurasi dan kinerja masing-masing model.

TABEL I
HASIL EVALUASI PERFORMA YOLOV11N

Skenario Pengujian	Precision ↑	Recall ↑	mAP@50 ↑	mAP@50-95 ↑
<i>Skenario 1</i>	0,82	0,57	0,65	0,35
<i>Skenario 2</i>	0,73	0,38	0,44	0,24
<i>Skenario 3</i>	0,77	0,46	0,53	0,28




Gambar. 4. Visualisasi hasil evaluasi performa YOLOv11n

Tabel I menyajikan hasil evaluasi performa model YOLOv11n pada tiga skenario pengujian yang telah dijelaskan pada bagian metode, yaitu: Skenario 1 (pencahayaan normal), Skenario 2 (*low-light* tanpa *enhancement*), dan Skenario 3 (*low-light* dengan *enhancement*). Visualisasi dari data tersebut ditampilkan pada Gambar 4.

Berdasarkan hasil tersebut, terlihat bahwa performa terbaik dicapai pada Skenario 1, dengan mAP 50 sebesar 0,65 dan mAP 50-95 sebesar 0,35. Pada Skenario 2, terjadi penurunan signifikan di seluruh metrik evaluasi. Sementara itu, penerapan image enhancement pada Skenario 3 menghasilkan peningkatan performa dibandingkan kondisi *low-light* tanpa *enhancement*, namun belum mampu mengembalikan akurasi ke tingkat optimal seperti pada kondisi pencahayaan normal. Hal ini menunjukkan bahwa meskipun *enhancement* membantu, efeknya belum sepenuhnya menetralkan dampak dari kondisi *low-light*.

TABEL II
 HASIL EVALUASI PERFORMA VGG16

Skenario Pengujian	MAE ↓
<i>Skenario 1</i>	5,4
<i>Skenario 2</i>	15,2
<i>Skenario 3</i>	7,6




Gambar. 5. Visualisasi hasil evaluasi performa VGG16

Tabel II menunjukkan bahwa kondisi *low-light* berdampak signifikan pada akurasi VGG16. MAE meningkat drastis dari 5,4 pada kondisi normal, menjadi 15,2 pada kondisi *low-light*, yang menunjukkan hilangnya detail penting untuk prediksi usia. Setelah *enhancement*, MAE menurun ke 7,6. Meski nilainya masih diatas MAE pada kondisi normal, hasil ini menunjukkan bahwa proses peningkatan pencahayaan berhasil memulihkan sebagian besar informasi yang hilang akibat kurangnya pencahayaan. Perubahan MAE pada ketiga skenario cukup signifikan. Perubahan tersebut dapat terlihat jelas pada visualisasinya di Gambar 5.

TABEL III
 HASIL EVALUASI PERFORMA RESNET152

Skenario Pengujian	Loss ↓	Akurasi ↑
<i>Skenario 1</i>	0,30	0,87
<i>Skenario 2</i>	0,43	0,80
<i>Skenario 3</i>	0,41	0,82





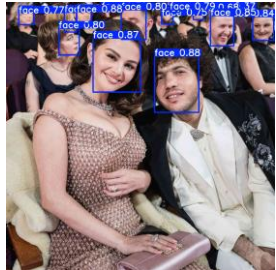




Gambar. 6. Visualisasi hasil evaluasi performa ResNet152

Hasil evaluasi model ResNet152 pada Tabel III menunjukan bahwa model mengalami penurunan akurasi dari 0,87 pada kondisi pencahayaan normal menjadi 0,80 pada kondisi *low-light*. Setelah dilakukan image enhancement,

akurasi meningkat menjadi 0,82. Meskipun hasilnya belum setara dengan pencahayaan normal, peningkatan ini menunjukkan bahwa *image enhancement* memberikan dampak positif terhadap performa model. Secara keseluruhan, klasifikasi jenis kelamin cenderung lebih stabil terhadap gangguan pencahayaan dibandingkan estimasi usia. Hal ini dapat dilihat pada grafik visualisasi hasil evaluasi ResNet152 pada Gambar 6, yang menunjukkan perubahan yang tidak terlalu signifikan.

Berikut adalah evaluasi secara kualitatif yang dilakukan secara visual untuk mengamati perbedaan output pada tiap skenario.

TABEL IV
HASIL EVALUASI KUALITATIF

	Skenario 1	Skenario 2	Skenario 3
Input			
Enhancement	-	-	
Deteksi Wajah			
Profiling			

Berdasarkan Tabel IV, setiap skenario menghasilkan performa yang berbeda dalam proses deteksi dan *profiling* wajah. Pada proses deteksi wajah, model YOLOv11n mendeteksi 14 wajah pada skenario 1, 13 wajah pada skenario 2, dan meningkat menjadi 15 wajah pada skenario 3. Penurunan pencahayaan pada skenario 2 menyebabkan hilangnya detail visual, sehingga mengurangi kemampuan model dalam mengenali wajah, terutama yang berukuran kecil atau samar. Sebaliknya, hasil *enhancement* pada skenario 3 justru meningkatkan jumlah deteksi karena peningkatan detail visual memungkinkan model mendeteksi wajah yang sebelumnya tidak terdeteksi.

Perbedaan performa juga terlihat jelas pada proses *profiling* wajah, khususnya estimasi usia. Gambar individu yang diuji memiliki usia asli 37 tahun. Pada skenario 1, model memprediksi usia dengan kesalahan prediksi sebesar

6 tahun. Namun, pada skenario 2, kesalahan meningkat menjadi 9 tahun. Hal ini dapat dijelaskan oleh kecenderungan model estimasi usia yang sangat bergantung pada detail struktur wajah seperti garis halus atau kerutan, yang memungkinkan hilang ataupun bertambah dalam kondisi *low-light*. Pada skenario 3, setelah dilakukan *enhancement*, kesalahan prediksi menurun menjadi 7 tahun. Meskipun hasilnya membaik dibandingkan kondisi *low-light*, prediksi cenderung lebih tinggi dari usia sebenarnya. Hal ini terjadi karena, proses *enhancement* meningkatkan ketajaman dan kontras secara berlebih, sehingga menampilkan detail wajah yang lebih menonjol dan berpotensi diasosiasikan dengan usia yang lebih tua.

Sementara itu, model klasifikasi jenis kelamin menunjukkan hasil yang konsisten di semua skenario. Hal ini mengindikasikan bahwa pada gambar ini klasifikasi jenis kelamin tidak terlalu terpengaruh oleh penurunan kualitas visual maupun proses *enhancement*. Namun perihal performa, kondisi *low-light* dan penerapan *enhancement* memberikan pengaruh yang sama seperti pada kedua model lainnya, meskipun perubahan tiap skenarionya cenderung stabil.

TABEL V
HASIL EVALUASI METODE ENHANCEMENT MENGGUNAKAN METRIK PSNR, SSIM, LOE, LOE_{ref} , NIQE, AND DELTA E


Metrik	Retinex-Net	KinD	KinD++
PSNR ↑	16.7740	20.7261	21.3003
SSIM ↑	0.5594	0.8103	0.8226
LOE ↓	1712.6	1056.4	849.6
LOE_{ref} ↓	2084.8	946.3	776.2
NIQE ↓	9.7289	4.1352	3.8807
DeltaE ↓	15.8936	9.8632	8.7425

Tabel V menyajikan hasil evaluasi kuantitatif dari beberapa metode *image enhancement* yang telah diuji pada penelitian [13]. Berdasarkan metrik yang digunakan, KinD++ menunjukkan performa terbaik dibandingkan metode lainnya. Dalam penelitian ini, dilakukan analisis perbandingan pengaruh penerapan metode KinD++, KinD [21], dan Retinex-Net [22] terhadap performa model deteksi dan *profiling* wajah, yang ditampilkan pada Tabel VI. Hasil analisis menunjukkan bahwa metode KinD menghasilkan peningkatan performa terbaik pada model deteksi dan *profiling* yang digunakan. Perbedaan performa antar metode tidak terlalu signifikan, kecuali pada model estimasi usia VGG16. Penurunan performa pada Retinex-Net disebabkan oleh peningkatan noise yang mengganggu detail wajah, sementara pada KinD++ disebabkan oleh penerapan komponen Multi-Scale Illumination Attention (MSIA), pembaruan dari versi sebelumnya. MSIA dirancang untuk mengatasi efek *oversmoothing* dan *noise* pada area gelap gambar, sehingga mampu menonjolkan struktur dan detail yang semula tidak terlihat. Meskipun efektif secara visual, perubahan struktur ini dapat berdampak negatif terhadap kinerja sistem deteksi dan *profiling* wajah, karena berpotensi mengganggu keakuratan informasi yang bersifat krusial dalam proses tersebut.

TABEL VI
PERBANDINGAN METODE ENHANCEMENT TERHADAP PERFORMA MODEL DETEKSI DAN PROFILING WAJAH

Metode Enhancement	YOLO				VGG16	ResNet152	
	Precision ↑	Recal ↑	mAP ₅₀ ↑	mAP ₅₀₋₉₅ ↑	MAE ↓	Loss ↓	Akurasi ↑
Retinex-Net	0,76	0,45	0,53	0,27	8,5	0,45	0,79
KinD	0,78	0,47	0,55	0,29	6,9	0,4	0,83
KinD++	0,77	0,46	0,54	0,28	7,6	0,42	0,82

Gambar 7 dan 8 memperlihatkan perbedaan visual dari gambar hasil *enhance* metode *enhancement* KinD++ [13], KinD [21], dan Retinex-Net [22].



Gambar 7. Perbandingan visual dengan metode *enhancement* lain.



Gambar 8. Perbandingan visual dengan metode *enhancement* lain.

Metode *enhancement* tidak hanya berfungsi untuk meningkatkan pencahayaan dan visibilitas, tetapi juga bisa memunculkan detail baru pada wajah, seperti garis-garis yang sebelumnya tidak terlalu terlihat. Peningkatan kontras dan ketajaman ini memang membantu sistem dalam mengenali wajah pada kondisi pencahayaan rendah. Namun, perubahan visual tersebut dapat memengaruhi akurasi pemrosesan wajah oleh model, terutama dalam analisis usia dan jenis kelamin. Dalam konteks estimasi usia, kehadiran detail tambahan seperti kerutan akibat proses *enhancement* dapat menyebabkan sistem memberikan prediksi usia yang lebih tua dari sebenarnya. Sebaliknya, ketika pencahayaan ditingkatkan secara berlebihan, beberapa bagian wajah dapat kehilangan ciri-ciri penting yang justru membuat model memperkirakan usia lebih muda. Begitu juga dalam klasifikasi jenis kelamin, hilangnya detail-detail tertentu dapat mempersulit model dalam mengenali perbedaan karakteristik antara wajah laki-laki dan perempuan. Maka, meskipun *enhancement* menawarkan manfaat dari segi visibilitas, dampaknya terhadap struktur visual wajah perlu diperhatikan karena berpotensi memengaruhi hasil *profiling*.

Hasil ini menunjukkan bahwa metode *enhancement* KinD++ dapat membantu memulihkan performa model pada kondisi *low-light*. Penerapan metode ini dalam sistem pengenalan wajah *real-time*, seperti pada sistem pengawasan atau aplikasi keamanan, memang menjanjikan untuk mengatasi keterbatasan visual akibat pencahayaan rendah. Namun, pada proses *profiling* seperti estimasi usia, model menunjukkan kecenderungan memprediksi usia lebih tua atau lebih muda dari sebenarnya setelah gambar ditingkatkan kualitasnya. Hal ini mengindikasikan bahwa proses *enhancement* berpotensi mengubah detail visual wajah seperti garis halus atau kontras kulit yang justru menjadi informasi penting dalam analisis usia.

Oleh karena itu, masih diperlukan pengembangan lebih lanjut terhadap metode *enhancement* agar mampu meningkatkan visibilitas tanpa mengganggu integritas informasi wajah yang penting dalam proses *profiling*. Pengembangan ini dapat difokuskan pada pencarian pendekatan *enhancement* yang lebih adaptif terhadap karakteristik wajah manusia, sehingga hasil peningkatan pencahayaan tidak menyebabkan perubahan struktur visual yang justru dibutuhkan untuk prediksi usia atau identifikasi individu. Evaluasi lanjutan juga diperlukan untuk menilai sejauh mana metode *enhancement* dapat dioptimalkan agar tetap memperbaiki kualitas visual pada gambar *low-light*, namun tetap mempertahankan detail-detail halus yang penting bagi akurasi sistem *profiling* wajah.

IV. KESIMPULAN

Penelitian ini menunjukkan bahwa kondisi *low-light* menyebabkan penurunan performa pada ketiga model yang diuji. Pada model deteksi wajah, mAP@50-95 turun dari 0,35 ke 0,24, akurasi model klasifikasi jenis kelamin menurun dari 0,87 ke 0,80, dan MAE (*Mean Average Error*) model estimasi usia meningkat dari 5,7 menjadi 15,2. Penerapan metode *enhancement* terbukti mampu meningkatkan performa masing-masing model. Model deteksi

wajah mengalami peningkatan nilai mAP@50-95 dari 0,24 menjadi 0,28. Model klasifikasi jenis kelamin mengalami peningkatan akurasi dari 0,80 menjadi 0,82, dan model estimasi usia menunjukkan penurunan MAE dari 15,2 menjadi 7,6. Meskipun peningkatan ini belum sepenuhnya menyamai hasil pada kondisi pencahayaan normal, hasilnya menunjukkan bahwa *enhancement* memberikan dampak positif dalam mengurangi gangguan akibat pencahayaan rendah. Perubahan performa yang tidak sepenuhnya pulih menunjukkan bahwa proses *enhancement* juga dapat memunculkan detail tambahan atau mengubah struktur visual wajah, yang berpotensi memengaruhi kinerja model. Temuan ini menunjukkan perlunya pengembangan metode *enhancement* yang dapat meningkatkan visibilitas gambar sekaligus menjaga bentuk serta detail wajah dalam tugas deteksi dan pengenalan wajah.

DAFTAR PUSTAKA

- [1] Global Initiative Against Transnational Organized Crime. (2023). Global Organized Crime Index 2023. *Global Initiative*. Geneva, Switzerland. Diakses 13 April 2025. [Online]. Tersedia: <https://globalinitiative.net/analysis/ocindex-2023/>
- [2] X. Wang, J. Peng, S. Zhang, B. Chen, Y. Wang, and Y. Guo. (Desember 2022). A Survey of Face Recognition. *arXiv preprint*. [Online] Tersedia: <https://doi.org/10.48550/arXiv.2212.13038>.
- [3] S. Hangaragi, T. Singh, dan N. Neelima. (Januari, 2023). Face detection and recognition using face mesh and deep neural network. *Procedia Comput. Sci.* [Online]. 218, hal. 741–749. Tersedia: <https://doi.org/10.1016/j.procs.2023.01.054>.
- [4] W. Shen, Y. Guo, Y. Wang, K. Zhao, B. Wang, and A. Yuille. (Juni, 2018). Deep Regression Forests for Age Estimation. Dipresentasikan di *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. [Online]. hal. 2304-2313. Tersedia: <https://doi.org/10.1109/CVPR.2018.00245>.
- [5] E. Brown dan D. I. Perrett. (Juli 1993). What gives a face its gender?. *Perception*. [Online]. 22(7), hal. 829–840. Tersedia: <https://doi.org/10.1068/p220829>.
- [6] W. Wang, W. Yang, and J. Liu. (2021). HLA-FACE: Joint high-low adaptation for low light face detection. Dipresentasikan di *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. [Online]. hal. 16190–16199. Tersedia: <https://doi.org/10.1109/CVPR46437.2021.01593>.
- [7] S. Rani, S. Pournima, A. Aram, V. Shanmuganeethi, P. Thiruselvan, N. Rufus. (April, 2024). Enhancing Facial Recognition Accuracy in Low-Light Conditions Using Convolutional Neural Networks. *J. Electr. Syst.* [Online]. 20(5s), hal. 2140–2148. Tersedia: <https://doi.org/10.52783/jes.2559>.
- [8] Pusiknas. (September, 2023). Ratusan Kejahatan Ditindak dalam Waktu 10 Jam. Pusiknas Bareskrim Polri. Diakses 13 April 2025 [Online]. Tersedia: https://pusiknas.polri.go.id/detail/artikel/ratusan_kejahatan_ditindak_dalam_waktu_10_jam.
- [9] Y. Qiu, Y. Shi, Y. Lin, Y. Hu, and Z. Zhou. (Januari, 2024). A Survey on Image Enhancement and Restoration Techniques. Dipresentasikan di *Proceedings of the 3rd International Conference on Internet Technology and Educational Informatization, ITEI 2023*. [Online]. hal. 24-26. Tersedia: <https://doi.org/10.4108/eai.24-11-2023.2343558>.
- [10] T. Muhammad. (Februari 2025). A Comprehensive Survey on Image Signal Processing Approaches for Low-Illumination Image Enhancement. *arXiv preprint*. [Online]. Tersedia: <https://doi.org/10.48550/arXiv.2502.05995>.
- [11] C. Guo et al.. (Januari 2020). “Zero-Reference Deep Curve Estimation for Low-Light Image Enhancement”. *arXiv preprint*. [Online]. Tersedia: <https://doi.org/10.48550/arXiv.2001.06826>.
- [12] Li, Pei. (Juli 2024). Multi-model fusion of DSFD and Zero-DCE for low-light face detection. *Applied and Computational Engineering*. [Online]. 86(0), hal. 108–115. Tersedia: <https://doi.org/10.54254/2755-2721/86/20241584>.
- [13] Y. Zhang, X. Guo, J. Ma, W. Liu, and J. Zhang. (April, 2021). Beyond Brightening Low-light Images. *Int J Comput Vis.* [Online]. 129(4), hal. 1013–1037. Tersedia: <https://doi.org/10.1007/s11263-020-01407-x>.
- [14] J. Yu, X. Hao and P. He. (2021). Single-stage Face Detection under Extremely Low-light Conditions. Dipresentasikan di *IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)*. [Online]. hal. 3516-3525. Tersedia: <https://doi.org/10.1109/ICCVW54120.2021.00392>.
- [15] J. Liang et al. (Maret, 2021). Recurrent Exposure Generation for Low-Light Face Detection. *IEEE Transactions on Multimedia*. [Online]. 24, hal. 1609–1621. Tersedia: <https://doi.org/10.1109/TMM.2021.3068840>.
- [16] S. Yang, P. Luo, C. C. Loy, and X. Tang. (2016). WIDER FACE: A Face Detection Benchmark. Dipresentasikan di *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [Online] Tersedia: <https://doi.org/10.1109/CVPR.2016.596>.
- [17] K. Simonyan and A. Zisserman. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint*. [Online]. hal. 1–14. Tersedia: <https://doi.org/10.48550/arXiv.1409.1556>.
- [18] J. Terven, D. M. Córdova-Esparza, and J. A. Romero-González. (November, 2023). A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction*. [Online]. 5(4), hal. 1680–1716. Tersedia: <https://doi.org/10.3390/make5040083>.
- [19] P. Deya, T. Mahmud, M. S. Chowdhury, M. S. Hossain, and K. Andersson. (Juli, 2024). Human Age and Gender Prediction from Facial Images Using Deep Learning Methods. *Procedia Computer Science*. [Online]. 238, hal. 314-321. Tersedia: <http://dx.doi.org/10.1016/j.procs.2024.06.030>.
- [20] P. S. Rajeev G. Vishwakarma. (April 2024). Detection of Gender in Crowds Using ResNet Model. *Journal of Electrical Systems*. [Online]. 20(2s), hal. 389–408. Tersedia: <https://doi.org/10.52783/jes.1151>.
- [21] Y. Zhang, J. Zhang, and X. Guo. (Oktober, 2019). Kindling the Darkness: A Practical Low-light Image Enhancer. *ACM International Conference on Multimedia*. [Online]. hal. 1632–1640. Tersedia: <https://doi.org/10.1145/3343031.3350926>.
- [22] C. Wei, W. Wang, W. Yang, and J. Liu. (Agustus 2018). Deep Retinex Decomposition for Low-Light Enhancement. *arXiv preprint*. [Online]. Tersedia: <https://doi.org/10.48550/arXiv.1808.04560>.