

Pengembangan Sistem *Enhancement* Selektif dengan Fine-tuning Retinex-Net untuk Peningkatan Kinerja Sistem Pengenalan Wajah pada Kondisi Cahaya Rendah

Muhammad Habibi Husni

Program Studi Teknik Informatika

Sekolah Teknik Elektro dan Informatika

Institut Teknologi Bandung, Jl. Ganesha 10 Bandung 40132

habibihusni18@gmail.com

Rinaldi Munir

Program Studi Teknik Informatika

Sekolah Teknik Elektro dan Informatika

Institut Teknologi Bandung, Jl. Ganesha 10 Bandung 40132

rinaldi@staff.stei.itb.ac.id

Abstrak—Pengenalan wajah merupakan salah satu teknologi biometrik yang banyak diterapkan dalam berbagai sistem keamanan. Namun, kinerja sistem pengenalan wajah dapat menurun secara signifikan pada kondisi cahaya rendah karena hilangnya informasi visual penting wajah. Oleh karena itu, diperlukan metode peningkatan kualitas citra (*image enhancement*) yang efektif untuk mengatasi tantangan ini. Solusi yang diajukan adalah dengan mengembangkan sistem *enhancement* selektif berbasis model Retinex-Net yang di-*fine-tune* secara khusus pada data citra wajah dengan kondisi pencahayaan rendah merata. Sistem memiliki sebuah modul yang mengklasifikasikan kecukupan pencahayaan pada citra wajah, dan mengaplikasikan *enhancement* jika diperlukan. Model dilatih pada *dataset* LFW dengan cahaya rendah sintetik melalui pemrosesan citra. Hasil pengujian menunjukkan sistem dapat meningkatkan kinerja sistem pengenalan wajah tanpa merusak akurasi pada pencahayaan cukup. Modul pengklasifikasian cahaya dapat mengklasifikasikan tingkat pencahayaan dengan akurasi cukup tinggi yaitu 0.89. Modul Retinex-Net hasil *fine-tuning* memberikan kinerja yang lebih baik dibandingkan model prelatih pada metrik PSNR dan SSIM, namun menurun berdasarkan metrik NIQE. Selain itu modul ini dapat menjaga kinerjanya pada citra luar *dataset*, namun mengalami kekurangan terhadap citra beresolusi lebih tinggi dan citra cahaya rendah nyata.

Keywords— *image enhancement*; *cahaya rendah*; *pengenalan wajah*; *Retinex-Net*

I. PENDAHULUAN

Teknologi pengenalan wajah (*face recognition*) merupakan salah satu teknologi biometrik yang populer dengan aplikasi luas, seperti kontrol akses, pengawasan, hiburan, dan penegakan hukum [1]. Selain itu, teknologi pengenalan wajah juga digunakan pada perangkat pintar. Pengaplikasian teknologi ini memerlukan keandalan dan akurasi pada berbagai kondisi, terutama pada kondisi cahaya rendah yang dapat dilihat pada Gambar 1.

Pada kondisi cahaya rendah, model pengenalan wajah mengalami penurunan kinerja yang cukup signifikan. Model

ArcFace dan FaceNet mengalami penurunan kinerja menjadi 66-68% pada kondisi cahaya rendah [2]. Hal ini disebabkan oleh karakteristik pada citra cahaya rendah yaitu derau yang tinggi, kontras yang rendah, dan distorsi warna yang dapat merusak kejelasan fitur wajah. Kondisi pencahayaan beragam seperti pencahayaan rendah merupakan salah satu tantangan utama dalam pengenalan wajah [1]. Oleh karena itu, diperlukan sebuah metode yang dapat meningkatkan kualitas citra wajah cahaya rendah.



Gambar. 1. Citra wajah cahaya rendah.

Beberapa metode peningkatan kualitas citra (*image enhancement*) konvensional telah dikembangkan, seperti *histogram equalization* (HE), *adaptive histogram equalization* (CLAHE), dan *gamma correction*. Metode-metode ini memiliki kemampuan yang cukup baik dalam meningkatkan kualitas citra cahaya rendah secara keseluruhan, namun memiliki kekurangan dalam adaptabilitas menangani pencahayaan tidak merata serta adanya kemungkinan memunculkan derau tambahan [3].

Dengan melakukan pendekatan melalui data, berbagai metode peningkatan kualitas citra cahaya rendah berbasis pembelajaran mendalam juga dikembangkan. EnlightenGAN memanfaatkan jaringan *Generative Adversarial Network* (GAN) untuk menghasilkan citra hasil peningkatan yang lebih mendekati citra natural [4]. Keunikan EnlightenGAN adalah model pembelajarannya yang bersifat *unsupervised learning*, yaitu tidak membutuhkan pasangan citra cahaya rendah dan citra normal secara langsung. Zero-CDE merupakan arsitektur *Convolutional Neural Network* sederhana yang melakukan

peningkatan kualitas citra melalui pendekatan berbasis kurva pemetaan nilai *pixel* bernama LE-Curve [5]. Dengan pendekatan ini, Zero-CDE merupakan model *zero-reference learning* yang tidak membutuhkan citra cahaya normal sama sekali dalam tahap pembelajarannya. Retinex-Net merupakan model peningkatan kualitas citra berbasis teori retinex dan bersifat *supervised learning* [6]. Model ini bekerja dengan melakukan dekomposisi citra masukan menjadi komponen *reflectance* dan *illumination* dan lalu meningkatkan kualitas pencahayaan pada peta *illumination* secara terpisah. Model ini merupakan salah satu model terbaik dalam mendukung tugas mendeteksi wajah [7]. Dibandingkan dua model sebelumnya, model ini bersifat *supervised learning* sehingga model ini lebih mudah untuk disesuaikan secara khusus untuk domain citra wajah cahaya rendah melalui data secara implisit, tanpa perlu melakukan modifikasi terhadap arsitektur model.

Meskipun metode berbasis pembelajaran mendalam mampu menghasilkan peningkatan kualitas citra yang lebih natural dibandingkan metode konvensional, sebagian besar model hanya dilatih menggunakan data citra dengan pencahayaan rendah. Hal ini menyebabkan model dapat menghasilkan peningkatan yang tidak diinginkan ketika diaplikasikan pada citra dengan pencahayaan normal, seperti munculnya artefak atau perubahan warna yang tidak diperlukan yang dapat merusak fitur wajah pada citra.


Untuk mengatasi kekurangan pada penelitian sebelumnya, penelitian ini mengusulkan sebuah sistem peningkatan citra wajah cahaya rendah yang dapat mengaplikasikan peningkatan kualitas citra secara selektif terhadap citra wajah yang membutuhkan saja. Pada penelitian ini, Retinex-Net dipilih sebagai metode peningkatan kualitas citra wajah berdasarkan keunggulan model ini dibandingkan EnlightenGAN dan Zero-CDE. Penelitian ini difokuskan pada citra wajah tunggal dengan asumsi pencahayaan merata pada area wajah, sehingga kasus dengan lebih dari satu wajah atau variasi pencahayaan ekstrem tidak dibahas secara eksplisit. Selain itu, pengaplikasian sistem akan diuji pada sistem pengenalan wajah dengan RetinaFace untuk pendeteksian wajah, sedangkan ArcFace, FaceNet, dan VGG-Face untuk ekstraksi fitur wajah.

II. STUDI LITERATUR

A. Citra Cahaya Rendah

Citra cahaya rendah adalah gambar yang diambil pada kondisi pencahayaan yang sangat minim, yaitu gambar dengan tingkat iluminasi yang tidak standar. Citra yang ditangkap pada lingkungan ini sering kali ditandai dengan kecerahan yang rendah, kontras yang buruk, dan banyak derau [3]. Hal ini menyebabkan detail pada gambar sulit untuk dikenali dan dapat merusak kemampuan sistem visual untuk memproses citra tersebut.

Berdasarkan analisis terhadap histogram persebaran nilai *gray value* pada Gambar 2, dapat diambil dua karakteristik utama yaitu persebaran nilai yang cenderung di nilai yang rendah dan bentuk persebaran yang sempit.



Gambar. 2. Grafik histogram citra cahaya rendah [3].

B. Teori Retinex


Teori retinex menjelaskan bagaimana mata manusia masih dapat memersepsikan warna yang sama meski dalam pencahayaan yang berbeda-beda [8]. Dalam pemrosesan citra, teori retinex mengasumsikan bahwa citra merupakan hasil penggabungan dari komponen *reflectance* dan *illumination* [10]. Secara umum, citra dapat dideskripsikan dengan persamaan berikut.

$$I(x, y) = R(x, y) \cdot L(x, y), \quad (1)$$

dengan $I(x, y)$ adalah citra awal; $R(x, y)$ adalah komponen *reflectance*, yaitu komponen yang menunjukkan tingkat reflektif suatu permukaan objek; dan $L(x, y)$ adalah komponen *illumination*, yaitu tingkat kecerahan yang mempengaruhi suatu titik. Nilai komponen R , L , dan I berada pada rentang $[0, 1]$.

C. Retinex-Net

Retinex-Net adalah model peningkatan kualitas citra cahaya rendah berbasis teori retinex dan pembelajaran mendalam [6]. Model ini bekerja dengan mendekomposisi citra menjadi komponen *reflectance* dan *illumination*, lalu meningkatkan kualitas komponen *illumination* agar lebih merata pada seluruh area citra. Dapat dilihat pada Gambar 3, model ini terdiri dari tiga komponen, yaitu Decom-Net yang berfungsi untuk mendekomposisi citra menjadi komponen *reflectance* dan *illumination*, Enhance-Net yang berfungsi untuk meningkatkan kualitas pencahayaan pada komponen *illumination*, dan komponen tambahan *Denoising Operation* yang akan melakukan pengurangan derau pada komponen *reflectance*.



Gambar. 3. Arsitektur Retinex-Net [6].

D. RetinaFace

RetinaFace adalah model pendeteksi wajah *single-stage* berbasis pembelajaran mendalam yang melakukan pelokalan wajah secara *pixel* pada berbagai skala wajah dengan memanfaatkan pembelajaran *multi-task* yang menggabungkan supervisi tambahan melalui *landmark* wajah dan *self-supervision* [9]. RetinaFace menunjukkan kinerja deteksi yang sangat baik pada kondisi dengan berbagai gangguan, seperti pose ekstrem, ukuran kecil, dan pencahayaan buruk. RetinaFace mampu mencapai akurasi 91.4% pada kategori *hard* di *dataset* Wider-Face [10].

E. FaceNet

FaceNet merupakan model pengenalan wajah yang melakukan pembelajaran mendalam terhadap pemetaan wajah ke ruang Euclidean berdasarkan *triplet loss* [11]. Jarak antara vektor wajah menunjukkan kemiripan antar wajah. Model ini dibangun di atas arsitektur GoogleNet atau Inception-V1 yang memiliki sekitar 5 juta parameter [12]. Model ini meraih akurasi sebesar 99.63% pada *dataset* LFW dan 95.12% pada *dataset* Youtube Faces DB.

F. ArcFace


ArcFace adalah model pengenalan wajah yang mengenalkan konsep *additive margin loss*, yaitu pendekatan berbasis margin sudut untuk menghasilkan representasi wajah yang lebih diskriminatif dalam ruang vektor dan memanfaatkan besar sudut antar vektor untuk mendeskripsikan kemiripan wajah [13]. Model ini dibangun di atas arsitektur ResNet-100 yang memiliki sekitar 45 juta parameter [12]. Model ini mampu meraih akurasi sebesar 99.82% pada *dataset* LFW.

G. VGG-Face

VGG-Face adalah model pengenalan wajah yang dibangun dengan arsitektur VGGNet [14]. VGGNet sendiri adalah model pengklasifikasian objek yang memiliki sekitar 138 juta parameter [12]. Arsitektur ini lalu dimodifikasi untuk *task* pengklasifikasian wajah ke 2622 identitas berbasis *softmax loss*. Untuk tugas verifikasi wajah, representasi fitur diekstraksi dari layer sebelum *output* dan dibandingkan menggunakan jarak Euclidean. Model ini mampu mencapai akurasi sebesar 98.95% pada *dataset* LFW.

III. RANCANGAN SOLUSI

Gambar 4 mengilustrasikan proses sistem *enhancement* selektif menggunakan model pengklasifikasian dan Retinex-Net. Sistem yang diusulkan terdiri dari dua komponen, yaitu modul pengklasifikasian cahaya dan Retinex-Net. Secara umum, modul pengklasifikasian cahaya melakukan klasifikasi kecukupan pencahayaan pada citra masukan untuk dilakukan pengenalan wajah. Sedangkan Retinex-Net berfungsi untuk meningkatkan kualitas dari citra wajah dengan pencahayaan rendah yang telah diklasifikasi oleh modul pengklasifikasian cahaya. Hasil proses sistem *enhancement* ini akan dijadikan masukan untuk sistem pengenalan wajah sebagai evaluasi.



Gambar. 4. Diagram alir gamabaran umum solusi.

A. Perolehan Dataset

Dataset yang digunakan adalah *dataset* citra wajah cahaya rendah sintetik yang dibuat dari *dataset* LFW. *Dataset* LFW digunakan karena umum digunakan sebagai *benchmark* kinerja model pengenalan wajah yang menjadi tujuan evaluasi pada penelitian ini. *Dataset* dibuat dengan mengambil 500 citra wajah sebagai data pelatihan dan 100 citra wajah sebagai data uji, lalu dilakukan pemrosesan citra untuk membentuk citra cahaya rendah dengan berbagai tingkat kecerahan. Metode pemrosesan citra yang dilakukan adalah dengan melakukan *blending* antara warna *pixel* pada citra dengan warna hitam berdasarkan skala tertentu dari 1-100%. Skala ini lalu didefinisikan sebagai tingkat kecerahan. Pada penelitian ini, variasi citra cahaya rendah yang dibentuk adalah sebanyak 14 kelas, terdiri dari tingkat kecerahan 1%, 2%, 3%, 4%, 5%, 6%, 7%, 8%, 9%, 10%, 20%, 30%, 40%, dan 50% yang dapat dilihat pada Gambar 5 secara berurutan. Tingkat kecerahan 50% dipilih sebagai tingkat kecerahan tertinggi karena berdasarkan observasi subyektif, tingkat kecerahan di atas 50% memiliki pencahayaan wajah yang cukup terang untuk dilihat dengan mata telanjang. Berdasarkan variasi ini, data uji terdiri dari 7000 citra, dan data latih terdiri dari 1400 citra.



Gambar. 5. Variasi citra gelap beserta citra normalnya.

B. Modul Pengklasifikasian Cahaya

Modul pengklasifikasian cahaya diimplementasikan menggunakan klasifikasi biner melalui algoritma pembelajaran mesin. Proses dari modul ini dapat dilihat pada Gambar 6.



Gambar. 6. Proses modul pengklasifikasian cahaya.


Klasifikasi yang dilakukan adalah kecukupan pencahayaan pada citra wajah yang didefinisikan sebagai kecukupan tingkat kecerahan dalam melakukan pengenalan wajah dengan kelas target *too_dark*. Proses *labelling* dari definisi sebelumnya perlu dilakukan, dengan metode pengujian verifikasi antara pasangan citra wajah gelap dan normal melalui model pengenalan wajah. Ketika mayoritas model pengenalan wajah mengalami kegagalan dalam verifikasi, maka akan diasumsikan citra tersebut memiliki pencahayaan yang minim sehingga perlu dilakukan *enhancement*. Untuk fitur yang akan diambil adalah rata-rata dan standar deviasi dari nilai keabu-abuan pada seluruh area citra. Pendekatan ini mengikuti karakteristik *histogram* persebaran nilai keabu-abuan pada citra cahaya rendah. Normalisasi fitur dilakukan sebelum klasifikasi, dengan menggunakan *z-score normalization* yang cocok digunakan untuk *dataset* dengan rasio *imbalance* yang kecil [15]. Untuk proses klasifikasi, dibandingkan beberapa model *classifier* (*logistic regression*, *decision tree*, *random forest*, SVM, KNN, *Naive Baiyes*) pada hasil *labelling* sebelumnya. Setelah dilakukan *hyperparameter tuning*, SVM meraih akurasi terbaik yaitu 89.1% pada data latih.

C. Modul Retinex-Net

Modul Retinex-Net berfungsi untuk meningkatkan kualitas pencahayaan pada citra wajah dengan pencahayaan yang minim. Pada solusi yang diajukan, arsitektur dari Retinex-Net tidak akan dimodifikasi, namun hanya dilakukan *fine-tuning* melalui pelatihan pada citra wajah cahaya rendah sintetik dan *hyperparameter tuning*. Pembuatan citra wajah cahaya rendah sintetik dilakukan melalui pemrosesan citra dengan melakukan modifikasi *brightness* yang lebih rendah secara merata pada seluruh area citra. *Fine-tuning* juga dilakukan hanya pada potongan citra wajah (*cropped face image*) dengan klasifikasi pencahayaan yang terlalu rendah yang di-label pada tahap sebelumnya, sehingga model dapat lebih optimal dalam meningkatkan kontras fitur wajah pada citra yang membutuhkan. Dengan pendekatan *fine-tuning* ini, modul Retinex-Net akan memiliki kinerja yang lebih efektif dalam meningkatkan kejelasan fitur wajah dari citra cahaya rendah.

Fine-tuning dilakukan dengan melakukan *freezing* pada beberapa *layer* pertama pada arsitektur Retinex-Net yang dapat dilihat pada Gambar 7. Pembekuan ini dilakukan untuk menjaga pembelajaran fitur dasar (*low-level features*) seperti tepi, tekstur, dan pola pencahayaan umum yang sudah dipelajari oleh Retinex-Net pada *dataset* aslinya. Dengan demikian, proses pelatihan akan lebih berfokus pada penyesuaian lapisan-lapisan selanjutnya yang bertanggung jawab terhadap representasi tingkat menengah hingga tinggi, sehingga model dapat lebih adaptif dalam mengenali dan memperbaiki karakteristik khusus

dari citra wajah dengan pencahayaan rendah. Selain itu, pembekuan ini juga mempercepat proses pelatihan hingga konvergen terhadap konfigurasi parameter yang optimal. Hal ini disebabkan karena jumlah parameter yang perlu diperbarui menjadi lebih sedikit, sehingga proses optimisasi berjalan lebih efisien tanpa mengorbankan kualitas representasi fitur dasar yang sudah dimiliki oleh model.



Gambar. 7. Desain perencanaan *fine-tuning* Retinex-Net.

IV. PENGUJIAN DAN HASIL

Pengujian terhadap sistem *enhancement* selektif dilakukan untuk mengevaluasi kinerja sistem terhadap peningkatan kinerja sistem pengenalan wajah pada kondisi cahaya rendah. Selain itu, pengujian terhadap masing-masing komponen juga dilakukan untuk menguji kinerja komponen terhadap tugasnya. Khusus untuk modul Retinex-Net, juga diuji kemampuan generalisasinya dalam mengatasi citra wajah cahaya rendah di luar karakteristik data pelatihan.

A. Pengujian Modul Pengklasifikasian Cahaya

Pengujian dilakukan terhadap 1400 citra uji yang telah dibentuk sebelumnya. Hasil yang diperoleh dapat dilihat pada Tabel 1. Berdasarkan hasil klasifikasi tersebut, didapat akurasi yang cukup baik yaitu 0.89, dengan *precision* sebesar 0.85, *recall* sebesar 0.99, dan *f1-score* sebesar 0.92. Nilai *recall* yang hampir mendekati 1 menunjukkan bahwa model cukup sensitif untuk mengklasifikasikan seluruh citra cahaya terlalu rendah secara tepat. Namun, berdasarkan nilai *precision*, didapat bahwa kasus *false negative* jauh lebih banyak dibandingkan kasus *false positive*.


TABEL I. HASIL PENGUJIAN MODUL PENGKLASIFIKASIAN CAHAYA

	Kelas Positif Prediksi	Kelas Negatif Prediksi
Kelas Positif Sebenarnya	TP = 392	FN = 4
Kelas Negatif Sebenarnya	FP = 152	TN = 852

Kasus *false positive* dan *false negative* dapat dilihat pada Gambar 8. *False positive* menunjukkan citra dengan wajah yang sudah cukup terang, namun diklasifikasikan sebagai citra gelap, dan begitu sebaliknya untuk kasus *false negative*. Kasus-kasus ini umumnya terjadi ketika pencahayaan yang tidak merata antara latar belakang dan wajah. Karena latar belakang merupakan bagian terbesar pada citra, hasil klasifikasi yang mengambil fitur dari rata-rata dan standar deviasi seluruh area citra dapat salah mengklasifikasikan citra wajah yang kecerahan wajahnya berbeda dari latar belakang. Hal ini menunjukkan kekurangan modul dalam menangani citra wajah dengan pencahayaan yang tidak merata. Beberapa kasus khusus seperti kasus (d), terjadi dikarenakan adanya aksesoris seperti kacamata pada wajah. Meskipun wajah cukup terang pada citra cahaya rendahnya, namun kontras antara kacamata dan wajah menjadi berkurang dan mengakibatkan kesalahan verifikasi.

B. Pengujian Modul Retinex-Net

Pengujian modul Retinex-Net dilakukan dengan menguji modul pada data uji dengan klasifikasi *too dark* sebanyak 856 citra, dan dibandingkan hasilnya dengan model pralatih. Pengujian dilakukan terhadap metrik PSNR, SSIM dan NIQE. Semakin tinggi nilai PSNR, maka semakin mirip hasil *enhancement* terhadap citra normalnya. Sedangkan semakin tingginya SSIM, maka semakin dekat kualitas struktural citra terhadap citra normalnya. NIQE merupakan metrik tanpa referensi, semakin kecilnya nilai NIQE maka semakin natural citra tersebut berdasarkan metrik ini.



Gambar. 8. Sampel citra dengan hasil klasifikasi yang salah.

Berdasarkan hasil eksperimen, ditemukan bahwa *hyperparameter* terbaik adalah *epoch* 30, *learning rate* 0.001, *batch size* 16, dan *patch size* 96 dengan nilai *loss* terkecil pada *set* validasi. Pengujian lalu dilakukan dan dibandingkan dengan model pralatih dengan hasil yang dapat dilihat pada Tabel II. Berdasarkan metrik PSNR dan SSIM, model *fine-tuning* memberikan hasil yang lebih baik dibandingkan model pralatih. Kasus ini dapat dilihat pada kasus nomor 1 pada Tabel 3. Dapat dilihat bahwa model hasil *fine-tuning* dapat memberikan hasil dengan fitur wajah yang lebih kontras dibandingkan model pralatih. Namun, berdasarkan metrik NIQE, kualitas citra hasil *enhancement* justru menurun. Hal ini menunjukkan bahwa citra hasil *fine-tuning* lebih tidak natural dibandingkan model pralatih. Kasus ini dapat dilihat pada kasus 2 dan 3 pada Tabel

III. Pada kecerahan rendah ekstrem, kecerahan beberapa bagian wajah ditingkatkan dengan tidak natural. Sedangkan pada kasus kecerahan yang lebih tinggi, terjadi *over-enhancement* pada bagian wajah yang lebih terang yang berubah menjadi warna abu-abu. Namun, kenaikan berdasarkan metrik PSNR dan SSIM menunjukkan hasil yang positif, karena kejelasan fitur wajah lebih penting dalam pengenalan wajah.

TABEL II. HASIL PENGUJIAN RETINEX-NET

Model	PSNR↑	SSIM↑	NIQE↓
Pralatih	14.523	0.639	5.037
<i>Fine-tune</i>	18.891	0.758	5.296

TABEL III. SAMPEL CITRA HASIL PENGUJIAN RETINEX-NET

No	Tingkat Kecerahan (%)	Citra Asli	Citra Input	Model Pralatih	Model <i>Fine-tune</i>
1	5				
2	3				
3	10				

C. Pengujian Generalisasi Retinex-Net


Pengujian generalisasi Retinex-Net ditujukan untuk mengevaluasi kinerja model terhadap citra di luar karakteristik data pelatihan, seperti citra pada *dataset* berbeda atau citra cahaya rendah nyata. Pengujian dilakukan terhadap citra cahaya rendah dengan metode sintetik yang sama dengan variasi terhadap ukuran resolusi citra, yaitu ukuran 114x114 *pixel* yang sesuai dengan *preprocessing* data latih, dan ukuran 250x250 *pixel*. Sebanyak 4 citra wajah diambil melalui *dataset* Human Faces [16] dan 1 citra wajah diambil secara pribadi. Lalu dibentuk citra cahaya rendahnya dengan variasi kecerahan 1-10%. Selain itu model juga diuji terhadap citra cahaya rendah nyata yang diambil melalui kamera. Pengambilan citra cahaya rendah dilakukan dengan melakukan penangkapan gambar dengan *exposure value* rendah. Proses pengambilan pasangan citra normal dan cahaya rendah mengacu pada metode pengambilan *dataset* Retinex-Net pralatih [6]. Sebanyak 5 citra wajah diambil melalui metode tersebut.

Berdasarkan hasil pengujian yang dapat dilihat pada Tabel IV, kinerja model masih cukup baik pada kasus resolusi yang sama, dengan sedikit pengurangan kualitas pada keempat metrik. Namun, pada kasus resolusi yang lebih tinggi, kualitas citra hasil *enhancement* jauh memburuk. Perbandingan hasil ini dapat dilihat pada Gambar 9. Pada resolusi yang lebih tinggi, derau pada wajah menjadi lebih jelas. Karena model dilatih pada resolusi yang lebih rendah, maka model meng-*enhance* derau tersebut secara berlebihan. Sedangkan pada kasus citra cahaya rendah nyata, kualitas citra hasil menurun secara signifikan. Kasus ini dapat dilihat pada Tabel V. Dapat dilihat bahwa

karakteristik citra cahaya rendah nyata adalah adanya derau-derau yang muncul dari sensor kamera. Pada bagian wajah yang lebih gelap, derau ini menjadi lebih jelas. Karena model tidak dilatih pada data citra cahaya rendah dengan derau, maka kinerja model tidak optimal pada kasus ini. Hasil pengujian ini menunjukkan bahwa model memiliki kemampuan generalisasi yang cukup baik dengan *preprocessing* yang sama, namun memiliki kekurangan dalam menangi citra cahaya rendah nyata.

TABEL IV. HASIL PENGUJIAN GENERALISASI RETINEX-NET

Dataset	PSNR↑	SSIM↑	NIQE↓
LFW	18.891	0.758	5.296
Eksternal (114x114 px)	17.634	0.753	5.274
Eksternal (250x250 px)	16.735	0.683	7.179
Kamera	14.883	0.436	8.017



Gambar. 9. Perbandingan hasil *enhancement* pada berbagai ukuran input (tingkat kecerahan 3%).

TABEL V. HASIL ENHANCEMENT PADA CITRA GELAP NYATA

No	Ground-truth	Citra Input	Hasil
1			
2			

D. Pengujian Sistem *Enhancement* Selektif

Pengujian sistem *enhancement* selektif dilakukan untuk mengevaluasi dampak pengaplikasian sistem *enhancement* sebagai tahap *preprocessing* dalam sistem pengenalan wajah. Pengujian pengenalan wajah yang dilakukan adalah tugas verifikasi. Tugas verifikasi menguji kemampuan sistem dalam menentukan apakah dua citra wajah yang diberikan berasal dari individu yang sama atau berbeda. Pada proses ini, sistem akan menghitung tingkat kemiripan melalui *cosine similarity* antara vektor *embedding* dua citra wajah yang diperoleh dari model pengenalan wajah. Tingkat kemiripan kemudian dibandingkan dengan ambang batas (*threshold*) tertentu untuk memutuskan

apakah pasangan citra wajah tersebut diverifikasi sebagai "*match*" (sama) atau "*mismatch*" (berbeda).

Untuk data uji pasangan *match* dan *mismatch*, dibentuk dari *dataset* LFW secara *random* dengan membatasi banyak identitas yang muncul. Sebanyak 50 pasang pengujian dipilih untuk masing-masing pasangan *match* dan *mismatch*, lalu dibentuk 28 kombinasi pengujian dari 14 kelas tingkat kecerahan citra cahaya rendah yang telah dibentuk dengan memvariasikan pengujian antara citra cahaya rendah dengan citra normal, sehingga menghasilkan 1400 pasang pengujian untuk masing-masing pasangan *match* dan *mismatch*. Sistem pengenalan wajah disimulasikan dengan menggunakan model pralatih siap pakai dari pustaka *DeepFace* tanpa modifikasi metode verifikasi. RetinaFace digunakan sebagai model pendeteksian wajah, sedangkan FaceNet, ArcFace, dan VGG-Net sebagai model pengenalan wajah.

Berdasarkan hasil pengujian pada Tabel VII, dapat dilihat bahwa terjadinya peningkatan kinerja pengenalan wajah secara umum. Angka kegagalan deteksi menurun secara signifikan. Model FaceNet memiliki kinerja terburuk dalam kondisi pencahayaan rendah, namun kinerjanya dapat ditingkatkan melalui pengaplikasian sistem *enhancement*. Hal serupa juga ditemui pada model ArcFace dengan kenaikan yang serupa. Sedangkan pada model VGG-Face, kinerja model tidak mengalami degradasi yang signifikan pada kondisi cahaya rendah, ditunjukkan dengan akurasi di atas 0.90. Namun, setelah sistem *enhancement* selektif diaplikasikan, kinerja VGG-Face mengalami sedikit penurunan. Hal ini mungkin disebabkan oleh hasil *enhancement* Retinex-Net hasil *fine-tuning* yang kurang natural. Selain itu, kemampuan model pengenalan wajah pada kondisi cahaya rendah berkorelasi dengan jumlah parameter arsitekturnya, dengan VGG-Face memiliki kinerja terbaik dengan jumlah parameter 138 juta, diikuti dengan Arcface dengan jumlah parameter 45 juta, dan FaceNet dengan jumlah parameter 5 juta.

Namun, dengan melihat hasil pengujian yang lebih detail pada Tabel VI, terdapat beberapa kekurangan sistem. Pada kasus tingkat kecerahan 30-50%, FaceNet tidak mengalami kenaikan akurasi meskipun kinerjanya sangat buruk. Hal ini disebabkan oleh metode *labelling* yang digunakan dalam pembuatan *dataset* yaitu *hard voting*. Hal ini menyebabkan sistem lebih *bias* terhadap model yang lebih *robust* seperti ArcFace dan VGG-Face. Sedangkan pada kasus tingkat kecerahan 20%, terjadi penurunan akurasi pada ketiga model. Hal ini disebabkan oleh kasus *over-enhancement* pada citra yang lebih terang.

TABEL VI. HASIL PENGUJIAN SISTEM ENHANCEMENT SELEKTIF BERDASARKAN TINGKAT KECERAHAN

Tingkat Kecerahan (%)	ArcFace		FaceNet		VGG-Face	
	Akurasi Sebelum	Akurasi Sesudah	Akurasi Sebelum	Akurasi Sesudah	Akurasi Sebelum	Akurasi Sesudah
Baseline	0.964		0.929		0.962	
20	0.870	0.860	0.470	0.475	0.950	0.925
30	0.945	0.945	0.530	0.530	0.950	0.950
40	0.945	0.945	0.660	0.660	0.955	0.955
50	0.955	0.955	0.755	0.755	0.945	0.945

TABEL VII.

HASIL PENGUJIAN SISTEM ENHANCEMENT SELEKTIF

	Kegagalan deteksi	ArcFace				FaceNet				VGG-Face			
		Akurasi	Precision	Recall	F1-Score	Akurasi	Precision	Recall	F1-Score	Akurasi	Precision	Recall	F1-Score
tanpa enhancement	378	0.62	0.71	0.41	0.52	0.51	0.55	0.15	0.24	0.95	0.97	0.93	0.95
dengan enhancement	15	0.90	0.94	0.84	0.89	0.75	0.94	0.53	0.68	0.92	0.96	0.88	0.92

V. KESIMPULAN DAN PENGUJIAN

A. Kesimpulan

1) Pengaplikasian sistem *enhancement* selektif berbasis Retinex-Net dan modul pengklasifikasian cahaya pada sistem pengenalan wajah mampu meningkatkan kinerja model deteksi dan pengenalan wajah. Namun, masih terdapat sedikit kekurangan terhadap model *robust* kondisi pencahayaan seperti VGG-Face

2) Deteksi kondisi pencahayaan rendah berhasil dilakukan melalui modul klasifikasi berbasis SVM dengan fitur rata-rata dan standar deviasi nilai keabu-abuan citra wajah. Modul ini mencapai kinerja cukup baik, meskipun masih memiliki kelemahan pada citra dengan pencahayaan tidak merata.

3) Implementasi peningkatan kualitas citra wajah cahaya rendah dilakukan melalui fine-tuning Retinex-Net pada dataset citra wajah dengan pencahayaan rendah. Teknik fine-tuning mampu memperbaiki kualitas citra berdasarkan metrik PSNR dan SSIM, meskipun menghasilkan penurunan kenaturalan menurut NIQE dibandingkan hasil pralatih.

4) Kemampuan generalisasi model *enhancement*, yaitu Retinex-Net, menunjukkan hasil cukup baik pada citra dengan kondisi pencahayaan merata tanpa derau. Namun, kinerja menurun signifikan pada citra dengan kondisi di luar domain pelatihan, seperti resolusi citra yang berbeda, pencahayaan tidak merata, atau citra dengan derau.

B. Saran

1) Penelitian selanjutnya dapat memperbaiki modul ini agar lebih sensitif terhadap kondisi pencahayaan lokal pada citra wajah sehingga mengurangi kasus kesalahan klasifikasi oleh pencahayaan tidak merata.

2) Melakukan *fine-tuning* model Retinex-Net secara lebih intensif seperti melatih keseluruhan arsitektur atau eksperimen *hyperparameter* yang lebih dalam agar model mampu menangani kondisi pencahayaan rendah pada citra wajah secara lebih optimal.

3) Meningkatkan kemampuan generalisasi Retinex-Net terhadap citra wajah gelap nyata dengan cara melatih model terhadap citra wajah gelap yang diambil menggunakan kamera.

4) Menerapkan strategi pelabelan yang lebih adil dan representatif terhadap berbagai karakteristik model pengenalan wajah, agar sistem *enhancement* selektif dapat memberikan manfaat yang merata tanpa cenderung menguntungkan model tertentu.

UCAPAN TERIMA KASIH

Penulis mengucapkan puji syukur kepada Allah SWT atas rahmat-Nya sehingga penulisan makalah ini dapat diselesaikan dengan tepat waktu. Penulis menyampaikan rasa terima kasih kepada Bapak Dr. Ir. Rinaldi Munir, M.T. selaku pembimbing yang telah memberikan masukan-masukan yang membangun dalam penelitian ini. Penulis juga menyampaikan rasa terima kasih yang mendalam kepada orang tua, atas dukungan dan doa yang dipanjatkan untuk keberhasilan penulis. Ucapan terima kasih juga disampaikan kepada seluruh teman-teman yang telah menemani dan membantu penulis selama masa perkuliahan.

REFERENSI

- [1] W. Ali, W. Tian, S. U. Din, D. Iradukunda and A. A. Khan, "Classical and modern face recognition approaches: a complete review," *Multimedia Tools and Applications*, vol. 80, pp. 4825-4880, 01 January 2021.
- [2] O. J. Dharmadinata and G. P. Kusuma, "Improving Face Recognition in Low Illumination Condition Using Combination of Image Enhancement and Face Recognition Methods," *Journal of Theoretical and Applied Information Technology/JATIT*, 2023.
- [3] W. Wang, X. Wu, X. Yuan and Z. Gao, "An Experiment-Based Review of Low-Light Image Enhancement Methods," *IEEE Access*, vol. 8, pp. 87884-87917, 2020.
- [4] Y. Jiang, X. Gong, D. Liu, Y. Cheng, C. Fang, X. Shen, J. Yang, P. Zhou and Z. Wang, "EnlightenGAN: Deep Light Enhancement Without Paired Supervision," *IEEE Transactions on Image Processing*, vol. 30, pp. 2340-2349, 2021.
- [5] C. G. Guo, C. Li, J. Guo, C. C. Loy, J. Hou, S. K. Wong and R. Cong, "Zero-reference deep curve estimation for low-light image enhancement," in *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR)*, 2020.
- [6] C. Wei, W. Wang, W. Yang and J. Liu, "Deep Retinex Decomposition for Low-Light Enhancement," in *British Machine Vision Conference*, 2018.
- [7] C. Li et al., "Low-Light Image and Video Enhancement Using Deep Learning: A Survey," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 44, no. 12, pp. 9396-9416, 2022.
- [8] E. H. Land and J. J. McCann, "Lightness and Retinex Theory," *J. Opt. Soc. Am.*, vol. 61, p. 1-11, January 1971.
- [9] J. Deng, J. Guo, E. Ververas, I. Kotsia and S. Zafeiriou, "RetinaFace: Single-Shot Multi-Level Face Localisation in the Wild," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2020.
- [10] S. Minaee, P. Luo, Z. Lin and K. Bowyer, *Going Deeper Into Face Detection: A Survey*, 2021.
- [11] F. Schroff, D. Kalenichenko and J. Philbin, "FaceNet: A Unified Embedding for Face Recognition and Clustering," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015.
- [12] Elharrouss, O., et al. "Backbones-review: Feature extractor networks for deep learning and deep reinforcement learning approaches in computer vision," in *Comput. Sci. Rev.*, vol. 53, no. 100645, pp. 100645, 2024.

- [13] J. Deng, J. Guo, N. Xue and S. Zafeiriou, "Arcface: Additive angular margin loss for deep face recognition," in Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019.
- [14] O. Parkhi, A. Vedaldi, A. Zisserman, "Deep Face Recognition," in *Proceedings of the British Machine Vision Conference 2015*, 2015.
- [15] L. B. V. de Amorim, G. D. C. Cavalcanti and R. M. O. Cruz, "The choice of scaling technique matters for classification performance," *Applied Soft Computing*, vol. 133, p. 109924, 2023.
- [16] A. Gupta, *Human Faces*, Versi 1, 2020.