
ANALISIS PENGARUH *LOW-LIGHT IMAGE ENHANCEMENT* PADA PENGENALAN WAJAH

ANALYSIS OF LOW-LIGHT IMAGE ENHANCEMENT EFFECT ON FACE RECOGNITION

Rohima¹, Wanayumini², Rika Rosnelly³

¹²³Jurusan Teknik dan Ilmu Komputer, Universitas Potensi Utama

e-mail : ¹Rohima.bar@gmail.com, ²Wanayumini@gmail.com, ³RikaRosnelly@gmail.com

Abstrak

Sistem pengenalan wajah secara umum akan digunakan secara real time dalam mengenali individu, artinya noise tidak dapat terhindarkan. Salah satu masalah yang dianggap umum adalah kondisi pencahayaan. Kondisi pencahayaan terjadi akibat pencerahan yang diterima objek tidak mencukupi sehingga cenderung memiliki visibilitas rendah, kontras berkurang, warna kabur, dan detail yang kabur. Maka low-light image enhancement dapat menjadi solusinya. Terdapat banyak sekali metode low-light image enhancement yang tersedia, namun mana teknik yang lebih baik dalam pengenalan wajah masih menjadi perdebatan. Untuk menemukan metode low light image enhancement yang baik maka pada penelitian ini dirancang beberapa sistem pengenalan wajah dengan PCA sebagai ekstraksi fitur serta menerapkan SSR, MSR, AMSR, Dong, HE dan BPDHE sebagai metode low-light image enhancement. Dataset SOF dipilih sebagai target pengujian dikarenakan berisi citra dengan kondisi pencahayaan berbeda. Sebagai tujuan, keseluruhan sistem pengenalan wajah akan dibandingkan tingkat pengenalannya untuk menemukan metode low-light image enhancement terbaik. Berdasarkan pengujian dan analisis, ditemukan bahwa mayoritas sistem mengalami peningkatan tingkat pengenalan dengan diterapkannya metode low-light image enhancement, dan sebagai metode terbaik HE (76,2886 %) menunjukkan hasil yang paling signifikan, disusul dengan AMSR (75,25773 %), MSR (74,2268 %), SSR (69,07216 %), BPDHE (67,01031 %) dan Dong (63,91753 %).

Kata Kunci— PCA, Ekstraksi Fitur, SSR, MSR, AMSR, Dong, He, BPDHE, Low-light image enhancement, Pengenalan Wajah, Specs on faces

Abstract

Facial recognition systems, in general, will be used in real-time to identify individuals, meaning that noise is unavoidable. One problem that is considered common is lighting standards. Lighting conditions occur due to insufficient emission received by the object so that it tends to have low visibility, reduced contrast, blurred colors, and blurred details. Then low-light image enhancement can be the solution. There are many low-light image enhancement methods available, but which technique is better for facial recognition is still a matter of debate. To find a good low light image enhancement method, in this study several facial recognition systems were designed with PCA as feature extraction and applied SSR, MSR, AMSR, Dong, HE, and BPDHE as low-light image enhancement methods. The SOF dataset was chosen as the test target because it contains images with different lighting conditions. As an objective, the entire facial recognition system will be compared to its recognition rate to find the best low-light image enhancement method. Based on testing and analysis, it was found that the majority of systems experienced an increase in recognition rate with the application of the low-light image enhancement method, and as the best method, HE (76.2886%) showed the most significant results, followed by AMSR (75.25773%), MSR (74.2268%), SSR (69.07216%), BPDHE (67.01031%) and Dong (63.91753%).

Keywords— PCA, Feature Extraction, SSR, MSR, AMSR, Dong, He, BPDHE, Low-light image enhancement, Face Recognition, Specs on faces

1. PENDAHULUAN

Suatu sistem pengenalan wajah harus memiliki kemampuan untuk belajar[1]. Wajah memiliki tugas penting dalam interaksi dengan manusia lain serta sebagai kunci dalam penyampaian/pengenalan identitas seorang manusia[2]. klasifikasi suatu wajah didapatkan dengan membandingkan wajah baru dengan ciri individual yang telah tersimpan pada suatu database[3].

Pengenalan wajah secara sederhana adalah identifikasi (*test*) suatu citra wajah baru terhadap sejumlah citra wajah yang telah disimpan sebelumnya (*training*) pada database, maka untuk memudahkan citra wajah yang akan diidentifikasi kerap disebut *test image* sedangkan target identifikasinya disebut *training set*.

Principal Component Analysis(PCA) dapat dipergunakan untuk ekstraksi fitur wajah[4],[1]. PCA menyediakan cara yang mudah untuk mengurangi kompleksitas data dengan memprojeksikannya menjadi sebuah *space* dengan dimensi yang kecil sembari tetap mempertahankan sebanyak mungkin variabilitas[5].

Salah satu masalah yang dianggap umum dalam sistem pengenalan wajah adalah variasi pada kondisi pencahayaan[1]. Kondisi pencahayaan terjadi akibat pancaran yang diterima objek tidak mencukupi, sehingga cenderung memiliki visibilitas rendah, kontras berkurang, warna kabur, dan detail yang kabur[6]. Untuk mengungkap detail citra yang tersembunyi pada bagian yang gelap, *low-light image enhancement*[6] perlu dilakukan.

Telah banyak teknik *low-light image enhancement* yang telah diciptakan, yang menjadi masalah adalah teknik mana yang lebih baik dalam menghadapi pengenalan wajah.

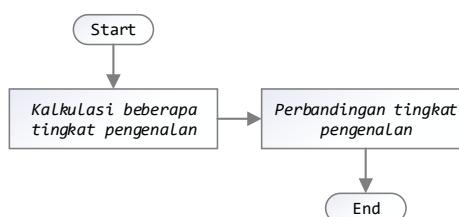
Pada penelitian ini akan diuji pengaruh dari beberapa teknik *low-light image enhancement* terhadap tingkat pengenalan wajah dengan kondisi pencahayaan berbeda. Teknik yang akan diujikan dalam penelitian ini adalah Single-scale Retinex atau SSR [7], MSR [8] Adaptive Multi-Scale Retinex atau AMSR [9], Metode Xuan Dong [10], Histogram Equalization atau HE [11], dan Brightness Preserving Dynamic Histogram Equalization atau BPDHE[12].

Dalam penerapannya Specs on faces (SOF) digunakan sebagai *Dataset*. *Dataset* SOF adalah koleksi wajah yang kondisi iluminasi yang berbeda [13]. PCA akan digunakan pada ekstraksi fitur. Dengan pertimbangan kesederhanaan, kecepatan dan kemampuan belajar [4] klasifikasi dicapai dengan menghitung minimum Euclidean Distance [14] eigenfaces dari *test image* dengan *eigenfaces* pada fase training yang telah diprojeksikan pada *facespace*.

2. METODOLOGI PENELITIAN

Untuk menyimpulkan metode *low light image enhancement* terbaik, maka suatu sistem pengenalan wajah akan diciptakan, namun pada bagian *low light image enhancement* akan dibedakan sesuai metode yang akan diuji.

Terdapat beberapa metode *low light image enhancement* yang akan dibandingkan, maka sistem akan dijalankan sebanyak jumlah metode *low light image enhancement*. Hasil dari dijalankan sistem tersebut adalah terkalkulasinya beberapa buah tingkat pengenalan dan akan disimpulkan metode *low light image enhancement* terbaik berdasarkan tingkat pengenalan tertinggi seperti terlihat pada Gambar 1.

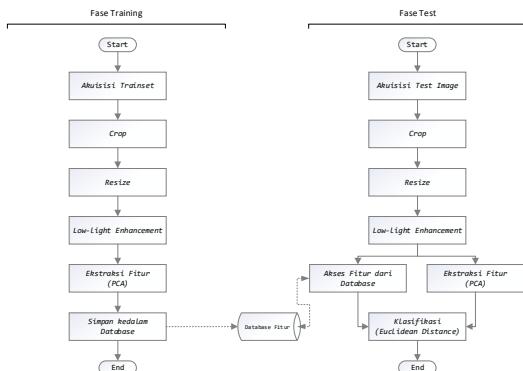


Gambar 1. Skema Penelitian

2.1. Kalkulasi Tingkat Pengenalan

Pada sistem pengenalan wajah, fase *test* menghasilkan tingkat pengenalan wajah berdasarkan fase *training* yang telah dilakukan sebelumnya. Pada dasarnya fase *training* dan fase *test*

menghasilkan fitur, namun fase *training* ditambahkan dengan klasifikasi / deskripsi seperti terlihat pada Gambar 2.



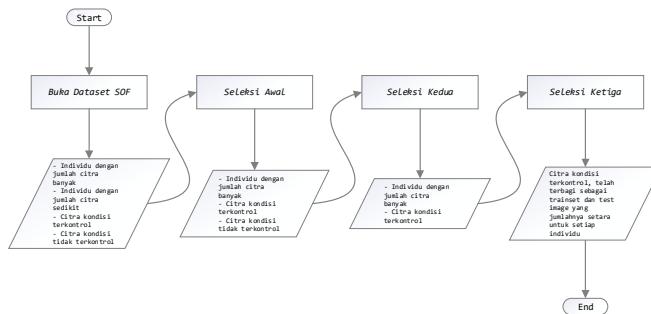
Gambar 2. Flowchart training, test, serta pengenalan

Penelitian ini yang menjadi fokus penelitian ini berada pada bagian *low-light image enhancement*, maka fase *training* dan fase *test* akan diulang sebanyak jumlah metode *low-light image enhancement* yang digunakan.

2.1.1. Akuisisi trainset & test image

Dataset SOF[15] yang diunduh dari <https://sites.google.com/view/sof-dataset>, diambil dari 112 individu. Beberapa individu jumlah citranya terlalu sedikit, selain itu terdapat beberapa citra yang diakuisisi dengan kondisi terkontrol (didalam ruangan dan iluminasi berbeda) dan yang tidak terkontrol (diluar ruangan). Citra juga harus dipilih sebagai *training set* dan *test image* dan dalam pemilihan agar hasil pengujian tidak bias, maka jumlah *train set*, dan *test image* untuk masing-masing inividu disetarakan. Demi mencapai hasil yang kredibel maka beberapa seleksi dilaksanakan.

Seleksi awal menyingkirkan individu dengan jumlah citra terlalu sedikit. Seleksi kedua menyingkirkan citra dari masing-masing individu dengan kondisi tidak terkontrol. Seleksi ketiga menyetarakan jumlah *train set* dan *test image* untuk masing-masing individu. Ilustrasi seleksi digambarkan dalam bentuk *flowchart* pada Gambar 3.



Gambar 3. Tahapan Seleksi Trainset dan Test Image

Dalam penelitian ini total citra dari dataset SOF yang digunakan adalah 516 dengan 420 diantaranya menjadi *trainset*, dan 96 menjadi *test image*.

2.1.2. Low Light Image Enhancement

Low-light image enhancement dapat diaplikasikan pada banyak hal, seperti pengawasan video, peningkatan citra medis, dan peningkatan citra militer [16]. Selain itu, beberapa gambar biasanya memiliki visibilitas yang berbeda di area lokal yang berbeda. Sudah diketahui dengan baik bahwa sebagian besar gambar yang diambil dalam kondisi cahaya redup memiliki rentang dinamis yang sempit dan mengalami banyak degradasi, seperti visibilitas rendah, kontras rendah, dan *noise* berat. Namun demikian, menyeimbangkan hubungan antara kontras, *noise*, dan iluminasi gambar dengan cahaya rendah merupakan tugas yang menantang. Ini karena gambar yang diperoleh dalam

kondisi cahaya redup memiliki rasio *signal-to-noise* yang rendah, yang berarti bahwa *noise* dapat mendominasi informasi gambar. Selain itu, sebagian besar gambar dengan cahaya redup terkena cahaya yang tidak seragam, yang menunjukkan bahwa area yang berbeda memiliki tren perubahan iluminasi yang berbeda.

Sesuai tema penelitian, citra yang diambil dari *dataset SOF* memiliki iluminasi(kecerahan) yang berbeda, tahapan ini bertujuan memperbaiki hal tersebut. Ada 6 metode *low light image enhancement* yang digunakan dalam penelitian ini yaitu Single-scale Retinex atau SSR [7], MSR [8] Adaptive Multi-Scale Retinex atau AMSR [9], Metode Xuan Dong [10], Histogram Equalization atau HE [11], dan dan Brightness Preserving Dynamic Histogram Equalization atau BPDHE[12]

Keseluruhan metode memiliki *output* citra dengan kecerahan lebih merata, namun berbeda sesuai dengan metode yang digunakan seperti terlihat pada Gambar 4.



Gambar 4. Tahapan Low light image enhancement

2.1.3. Dong

Pada penelitian [10] ditemukan bahwa citra dengan pencahayaan rendah mirip dengan kabut. Peningkatan dong dimulai dengan menerapkan operasi inversi dilanjutkan dengan *haze removal* sebelum operasi inversi kembali untuk mendapatkan *output*. Dalam operasi inversi digunakan :

$$R^c(x) = 255 - I^c(x) \quad (1)$$

Dimana c adalah komponen warna (RGB). $I^c(x)$ merupakan intensitas dari komponen warna dari *pixel* x dari citra *input* I . $R^c(x)$ memiliki intensitas yang sama dengan citra inversi R. Algoritma *haze removal* yang digunakan ditunjukkan pada :

$$R(X) = J(x)t(x) + A(1 - t(x)) \quad (2)$$

Dimana A merupakan cahaya *global atmospheric*. $R(X)$ merupakan intensitas dari *pixel* x yang ditangkap kamera. $J(x)$ merupakan intensitas dari objek original. $t(x)$ dideskripsikan sebagai seberapa persen cahaya dipancarkan oleh objek yang ditangkap oleh kamera. $t(x)$ diestimasi menggunakan :

$$t(x) = 1 - \omega \min_{c \in \{r,g,b\}} \left(\min_{y \in \Omega(x)} \left(\frac{R^c(y)}{A^c} \right) \right) \quad (3)$$

Dimana ω adalah 0.8. $\Omega(x)$ merupakan lokal blok yang berupast pada x dan block size adalah 9. Untuk estimasi cahaya global atmosphere A , pilih sebanyak 100 *pixel* yang memiliki minimum intensitas pada seluruh komponen warna (RGB) tertinggi pada citra, lalu dari *pixel* tersebut, dipilih satu *pixel* yang jumlah RGB dengan nilai tertinggi. Nilai RGB pada ini digunakan untuk A . Memulihkan $J(x)$ dapat dilakukan dengan cara :

$$J(x) = \frac{R(x) - A}{t(x)} + A \quad (4)$$

Untuk menyesuaikan $t(x)$ secara adaptif sambil menjaga kontinuitas spatial, sehingga citra menjadi lebih mulus secara visual, digunakan $P(x)$ sebagai set :

$$P(x) = \begin{cases} 2t(x), & 0 < t(x) < 0.5 \\ 1, & 0.5 < t(x) < 1 \end{cases} \quad (5)$$

Sehingga rumus recoveri menjadi

$$J(x) = \frac{R(x) - A}{P(x)t(x)} + A \quad (6)$$

2.1.4. SSR & MSR

Iluminasi $l_i(x, y)$ merupakan estimasi pertama dengan menerapkan gaussian form linear LPF kepada citra berwarna $f_i(x, y)$, citra berwarna *outputnya* $\hat{f}_i(x, y)$ kemudian didapatkan dengan mengurangkan log signal dari estimasi iluminasi $\log \hat{l}_i(x, y)$ dari log signal milik citra berwarna *inputan* $\log \hat{f}_i(x, y)$ sebagai berikut [8] :

$$\hat{f}_i(x, y) = \log f_i(x, y) - \log \hat{l}_i(x, y), \quad i \in \{R, G, B\} \quad (7)$$

Pada Multi Scale Retinex (MSR), *output* dari citra berwarna $\hat{f}_i(x, y)$, $i \in \{R, G, B\}$ didapatkan dari weight sum beberapa *output* citra berwarna Single Scale Retinex (SSR) menggunakan Gaussian-form linear LPFs memiliki *support region* yang berbeda sebagai berikut [7] :

$$\hat{f}_{MSR_i}(x, y) = \sum_{n=1}^N W_n \hat{f}_{n_i}(x, y), \quad i \in \{R, G, B\} \quad (8)$$

Dimana N menunjukkan jumlah skala, $\hat{f}_{n_i}(x, y)$ merupakan SSR output citra berwarna dengan skala LPF ke n, dan w_n merupakan sebuah weighting factor untuk $\hat{f}_{n_i}(x, y)$.

Pada bagian akhir, citra berwarna baik SSR, maupun MSR didapatkan dengan menerapkan canonical gain/offset correction [7], kepada *output* citra berwarna SSR dan MSR untuk mengatur jangka brightness perangkat *output*.

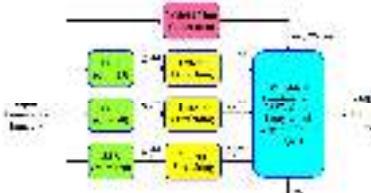
2.1.5. AMSR

Adaptive Multi-Scale Retinex (AMSR) merupakan peningkatan dari MSR [17]. AMSR menggabungkan beberapa *output* citra SSR dimana bobot terkait dengan setiap skala SSR secara adaptif dihitung dari konten gambar *input*[9].

AMSR dimulai dengan *input* citra gambar berwarna dengan y sebagai komponen iluminasi didapatkan dengan konversi komponen warna Red, Green dan Blue menggunakan fungsi [9] :

$$\begin{aligned} Y(x, y) = & 0.299 \times R(x, y) + \\ & 0.587 \times G(x, y) + \\ & 0.114 \times B(x, y) \end{aligned} \quad (9)$$

Dimana $R(x, y)$, $G(x, y)$, $B(x, y)$ menunjukkan nilai Red, Green dan Blue dari pixel yang berlokasi pada (x, y) . Citra illuminasi Y kemudian diproses menggunakan pendekatan AMSR untuk mendapatkan citra yang diperbaiki. Pendekatan AMSR digambarkan pada Gambar 5..



Gambar 5. Flow diagram pendekatan AMSR

2.1.6. HE

Tahapan Histogram Equalization (HE) dimulai dengan transformasi perataan yang dinyatakan dengan :

$$q(x, y) = T(w) \quad (10)$$

Dengan $q(x, y)$ sebagai citra *input*, dan $T(w)$ merupakan fungsi transformasi.

Fungsi transformasi $T(w)$ dapat menghasilkan kerapatan citra $q(x, y)$ yang terdistribusi merata dalam interval 0 sampai 255. Fungsi kerapatan suatu citra dapat dinyatakan sebagai :

$$P(w) = \frac{h(w)}{((M \times N))} \quad (11)$$

Dengan $h(w)$ adalah fungsi histogram.

Dengan menggunakan fungsi distribusi kumulatif dapat diperoleh fungsi transformasi sebagai berikut :

$$T(w) = I_{max} \sum_0^w p(r) \quad (12)$$

2.1.7. BPDHE

Brightness preserving dynamic Histogram Equalization (BPDHE) memiliki 5 langkah utama yaitu 1 Memuluskan histogram dengan gaussian filter, 2 Deteksi lokasi lokal maksium dari histogram

yang telah dimuluskan, 3 Map setiap partisi menjadi dynamic range, 4 Equalize setiap partisi secara mandiri, dan 5 Normalisasi kecerahan dari citra

2.2. PCA

Baik pada fase *training* dan fase *test*, PCA akan digunakan. Pada fase *training* fitur pca akan disimpan pada *database*, sedangkan pada fase *test* fitur pca dari *test image* akan dibandingkan dengan fitur pca pada fase *training*. Ada sedikit perbedaan penggunaan PCA pada fase *training* dan fase *test* dikarenakan pada fase *training* citra yang digunakan berjumlah lebih dari satu, sementara pada fase *test* citra yang digunakan berjumlah satu. Pada sub bab ini tahapan pca yang dipaparkan mengacu pada fase *training*, sementara tahapan pca pada fase *test* dibahas lebih mendalam pada sub bab klasifikasi selanjutnya.

Asumsi terdapat citra $\Gamma(x, y)$ dua dimensi dengan array M dan N sebagai nilai intensitas. Pada penelitian ini, digunakan citra berukuran 200x149. Suatu citra dapat dianggap sebagai *vector* $M \times N$, maka citra berukuran 200x149 menjadi *vector* dengan dimensi 29.800 seperti terlihat pada Gambar 6.



Gambar 6. Konversi citra $M \times N$ menjadi vector $MN \times 1$

Tahap pertama persiapkan beberapa citra yang akan memasuki fase *training* $I_1, I_2, I_3, \dots, I_m$. Wajah pada citra haruslah ditengah, dan memiliki ukuran yang sama

Tahap kedua menyiapkan *training set*. Setiap citra I_i diubah menjadi *vector* dan diletakkan kedalam *training set* S.

$$S = \{\Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_M\} \quad (13)$$

Tahap ketiga adalah menghitung average face *vector* (Ψ) menggunakan rumus :

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n \quad (14)$$

Tahap keempat adalah mengurangkan average face *vector*. Ψ dikurangkan dengan Γ_1 dan hasilnya disimpan pada variabel Φ ,

$$\Phi_i = \Gamma_i - \Psi \quad (15)$$

Tahap kelima Hitung covariance matrix dengan rumus :

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T = AA^T \quad (N^2 \times N^2) \quad (16)$$

Dimana $A = [\Phi_1, \Phi_2, \Phi_3, \dots, \Phi_M]$ $(N^2 \times M$ matrix)

Tahap keenam hitung Eigenvector dan eigenvalue dari matrix covariance. Covariance matrix C pada langkah kelima memiliki dimensi $(N^2 \times N^2)$, maka akan memiliki N^2 eigenface dan eigenvalues. Untuk citra 256x256 harus menghitung matrix $65,536 \times 65,536$ dan menghitung 65,536 eigenfaces. Dalam dunia komputer, ini tidaklah terlalu efisien karena mayoritas eigenfaces tidak terlalu berguna untuk tugas ini. Secara general PCA digunakan untuk mendeskripsikan dimensional besar menjadi vector berukuran yang relatif kecil [18].

Maka jika dihitung Eigenvector u_i dari AA^T , matrix yang dihasilkan akan terlalu besar sehingga tidaklah praktis, sebagai alternatif gunakan tahap enam-satu dan enam-dua berikut.

Tahap enam-satu pergunakan matrix :

$$L = A^T A \quad (M \times M \text{ matrix}) \quad (17)$$

Tahap enam-dua menghitung Eigenvector v_i dari $L = A^T A$

$$A^T A v_i = \mu_i v_i \quad (18)$$

Hubungan antara u_i dan v_i dideskripsikan sebagai berikut :

$$A^T A v_i = \mu_i v_i$$

$$\begin{aligned} A A^T A v_i &= \mu_i A v_i \\ C A v_i &= \mu_i A v_i \quad [\text{karena } C A A^T] \\ C u_i &= \mu_i A v_i \quad \text{dimana, } u_i = A v_i \end{aligned}$$

Maka $C = A A^T$ dan $L = A A^T$ memiliki *eigenvalues* dan *Eigenvector* yang berhubungan sebagaimana :

$$u_i = A v_i$$

Catatan :

$C = A A^T$ dapat berisi hingga N^2 *eigenvalues* dan *eigenvector*

$M = A A^T$ dapat berisi hingga M *eigenvalues* dan *eigenvector*

eigenvalues M dari $C = A A^T$ (sesuai dengan korespondensi eigenvectornya) sesuai dengan nilai terbesar *eigenvalue* dari $L = A A^T$ (sesuai dengan korespondensi eigenvectornya).

Dimana v_i merupakan *eigenvalue* $L = A^T A$, maka dapat dibuktikan $A = v_i$ merupakan *Eigenvector* $C = A A^T$. *Eigenvector* M dari $L = A^T A$ digunakan untuk mencari u_i *Eigenvector* dari C yang membentuk basis rumus eigenface :

$$u_i = \sum_{i=1}^M v_i \Phi_i \quad (19)$$

Dimana u_i merupakan *Eigenvector* sekaligus *eigenfaces*.

Tahap ketujuh, keseluruhan tahapan menghasilkan sejumlah *eigenfaces*. *Eigenfaces* dengan *eigenvalue* yang rendah hanya menjelaskan sebagian kecil karakteristik fitur dari wajah, kebalikannya *eigenvalue* tertinggi menjelaskan mayoritas karakteristik fitur dari wajah.

Tahap terakhir adalah projeksikan *eigenfaces* ke facespace untuk dibandingkan nantinya. Weight vector untuk *training set* dapat dikalkulasi dengan rumus :

$$\omega_i = u_i^T (\Gamma_i - \Psi) \quad (20)$$

Dimana u_i merupakan *eigenfaces* ke i dan $i = 1, 2, 3, \dots, K$. Weight vector didapatkan dengan cara diatas untuk membentuk vector sebagai berikut :

$$\Omega^T i = [\omega_1, \omega_2, \omega_3, \dots, \omega_k] \quad (21)$$

Weight vector ($\Omega^T i$) dan average face vector (Ψ) akan disimpan ke dalam database, dan akan dipergunakan nantinya pada fase *test* khususnya tahapan klasifikasi.

2.3. Klasifikasi

Secara sederhana tahapan klasifikasi adalah tahapan PCA yang telah dibahas sebelumnya ditambahkan dengan tahapan perhitungan *Euclidean Distance*, namun karena jumlah citra pada fase *test* hanya 1 untuk setiap kali klasifikasi, maka tahapan PCA untuk fase *test* dipaparkan khusus untuk tahap klasifikasi terlebih dahulu.

Tahap pertama dimulai dengan kalkulasi *feature vector* dari *test image*. *Test image* dikurangkan dengan average face vector (Ψ), lalu hasilnya dikalikan dengan setiap eigenvectors [14]. Setiap nilai akan merepresentasikan sebuah weight dan disimpan dalam bentuk vector Ω^T .

$$\Omega_{test} = u_i^T (\Gamma_{test} - \Psi) \quad (22)$$

Dimana u_i merupakan *eigenfaces* ke i dan $i = 1, 2, 3, \dots, K$

Selanjutnya hitung average distance (*Euclidean Distance*) antara (*test*) weight feature Ω_{test} dan seluruh (*train*) weight vector ($\Omega^T i$).

Secara matematis, pengenalan adalah menemukan minimum *Euclidean Distance* ε_k antara *testing point* dan *training point* dengan rumus sebagai berikut :

$$\varepsilon_k = \sqrt{\|\Omega_{test} - \Omega_i\|} \quad (23)$$

Dimana $i = 1, 2, 3, \dots, K$. *Euclidean Distance* antara kedua weight akan menghasilkan ukuran kemiripan antara citra yang bersangkutan. *Class* individu dengan minimum *Euclidean Distance* menunjukkan similarity kepada *test image* [19].

Similarity pada penelitian ini digunakan sebagai acuan dalam pengenalan wajah, semakin banyak *test image* yang menunjukkan similarity terhadap *class* individu yang sesuai, maka semakin besar pula tingkat pengenalan yang didapatkan.

2.4. Perbandingan Tingkat Pengenalan

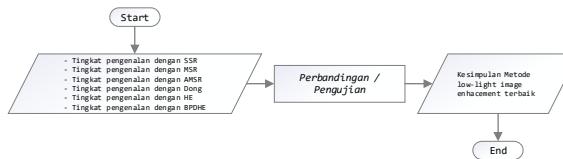
Dalam satu kali penentuan tingkat pengenalan, maka terjadi fase *training* satu kali sedangkan fase *test* diulang sebanyak jumlah *test image*. Setiap kali fase *test* dilaksanakan, fitur *test* akan dibandingkan dengan fitur dari beberapa *class* individu dan hasil pengenalannya akan dibandingkan dengan identitas sebenarnya dari *test image* berdasarkan *Euclidean Distance*. Apabila hasil pengenalan sesuai dengan identitas sebenarnya dari *test image*, maka pengenalan wajah dinyatakan berhasil dan berlaku sebaliknya.

Tingkat pengenalan ditentukan jumlah wajah berhasil dikenali berbanding dengan jumlah fase *test* terlaksana dan dinyatakan dalam bentuk persentase :

$$\text{Tingkat Pengenalan} = \frac{\text{berhasil dikenali}}{\text{jumlah fase test terlaksana}} \times 100\% \quad (24)$$

Dikarenakan fokus penelitian ini adalah pada bagian *low light image enhancement*, sesuai dengan jumlah metode yang diujikan, maka penentuan tingkat pengenalan akan dilaksanakan sebanyak enam kali dengan perbedaan khusus pada tahapan *low-light image enhancement*.

Setelah seluruh tingkat pengenalan didapatkan, Pada tahap ini keseluruhan tingkat pengenalan akan dibandingkan. Tingkat pengenalan dengan persentase terbesar akan disimpulkan sebagai teknik *low-light image enhancement* mana yang terbaik seperti yang dapat dilihat pada Gambar 7.



Gambar 7. Flowchart Pengujian

3. HASIL DAN PEMBAHASAN

Sebanyak total 6 sistem pengenalan wajah yang dibangun dengan dibedakan pada tahap *low-light image enhancement*. Keseluruhan sistem yang di bangun menggunakan *train set* yang dan serta *test image* yang sama. Pada *test image* Terdapat 36 citra normal sementara sisanya adalah citra iluminasi khusus dari total 96 citra *test* yang digunakan.

Maka ukuran metode *low-light image enhancement* terbaik diukur berdasarkan tingkat pengenalan tertinggi dari sistem yang dibangun. Pada tabel 1 hingga tabel 6 berikut disajikan *data* hasil pengenalan dari masing-masing sistem.

Tabel 1. Tingkat Pengenalan SSR

No	Identitas Test Image		Class Dikenali	Kesimpulan pengenalan
	Class	Kode		
1	AbdA	16	AbdA	Berhasil
2	AbdA	37	AbdA	Berhasil
3	AbdA	73	AbdA	Berhasil
...				
94	YosB	2578	YosB	Berhasil
95	YosB	2592	YosB	Berhasil
96	YosB	2606	MirM	Gagal
Total Berhasil Mengenali				67
Jumlah Fase Test				97
Tingkat Pengenalan SSR				69,07216 %

Tabel 2 Tingkat Pengenalan MSR

No	Identitas Test Image		Class Dikenali	Kesimpulan pengenalan
	Class	Kode		
1	AbdA	16	AbdA	Berhasil
2	AbdA	37	AbdA	Berhasil
3	AbdA	73	AbdA	Berhasil

...				
94	YosB	2578	YosB	Berhasil
95	YosB	2592	YosB	Berhasil
96	YosB	2606	YosB	Berhasil
Total Berhasil Mengenali				72
Jumlah Fase Test				97
Tingkat Pengenalan MSR				74,22680%

Tabel 3 Tingkat Pengenalan AMSR

No	Identitas Test Image		Class Dikenali	Kesimpulan pengenalan
	Class	Kode		
1	AbdA	16	AbdA	Berhasil
2	AbdA	37	AbdA	Berhasil
3	AbdA	73	AbdA	Berhasil
...				
94	YosB	2578	YosB	Berhasil
95	YosB	2592	YosB	Berhasil
96	YosB	2606	YosB	Berhasil
Total Berhasil Mengenali				73
Jumlah Fase Test				97
Tingkat Pengenalan AMSR				75,25773%

Tabel 4 Tingkat Pengenalan Dong

No	Identitas Test Image		Class Dikenali	Kesimpulan pengenalan
	Class	Kode		
1	AbdA	16	AbdA	Berhasil
2	AbdA	37	AbdA	Berhasil
3	AbdA	73	AbdA	Berhasil
...				
94	YosB	2578	YosB	Berhasil
95	YosB	2592	YosB	Berhasil
96	YosB	2606	SarE	Gagal
Total Berhasil Mengenali				62
Jumlah Fase Test				97
Tingkat Pengenalan Dong				63,91753%

Tabel 5 Tingkat Pengenalan HE

No	Identitas Test Image		Class Dikenali	Kesimpulan pengenalan
	Class	Kode		
1	AbdA	16	AbdA	Berhasil
2	AbdA	37	AbdA	Berhasil
3	AbdA	73	AbdA	Berhasil
...				
94	YosB	2578	YosB	Berhasil
95	YosB	2592	YosB	Berhasil
96	YosB	2606	YosB	Berhasil
Total Berhasil Mengenali				74
Jumlah Fase Test				97
Tingkat Pengenalan HE				76,28866%

Tabel 6 Tingkat Pengenalan BPDHE

No	Identitas Test Image		Class Dikenali	Kesimpulan pengenalan
	Class	Kode		
1	AbdA	16	AbdA	Berhasil
2	AbdA	37	AbdA	Berhasil

3	AbdA	73	AbdA	Berhasil
...				
94	YosB	2578	MirM	Gagal
95	YosB	2592	YosB	Berhasil
96	YosB	2606	OliA	Gagal
Total Berhasil Mengenali			65	
Jumlah Fase Test			97	
Tingkat Pengenalan BPDHE			67,01031%	

Rekapitulasi tingkat pengenalan masing-masing sistem pengenalan citra berdasarkan metode *low-light image enhancement* disajikan pada Tabel 7.

Tabel 7. Rekapitulasi Tingkat Pengenalan

Class	Tingkat Pengenalan
SSR	69,07216 %
MSR	74,22680%
AMSR	75,25773%
Dong	63,91753%
HE	76,28866%
BPDHE	67,01031%

Sebagai perbandingan, tingkat pengenalan tanpa menerapkan metode *low-light image enhancement* adalah 66.666667%, sementara jumlah gagal mengenali citra normal adalah 6 kali. Berdasarkan Tabel 7. dapat disimpulkan mayoritas sistem yang diterapkan metode *low-light image enhancement* mengalami peningkatan kecuali dengan metode Dong. Tingkat Pengenalan dengan metode HE merupakan yang tertinggi didukung dengan jumlah gagal dalam mengenali citra normal yang jumlahnya paling sedikit.

4. KESIMPULAN

Berdasarkan hasil pengujian dapat disimpulkan bahwa dalam mengenali citra dengan kecerahan yang berbeda Mayoritas sistem yang diterapkan metode low-light image enhancement mendapatkan pengaruh yaitu mengalami peningkatan tingkat pengenalan kecuali dengan metode Dong. HE pada penelitian ini merupakan metode terbaik berdasarkan tingkat pengenalan tertinggi dan terendah pada kegagalan dalam mengenali citra normal (tanpa luminasi). Urutan tertinggi hingga terendah dalam tingkat pengenalan adalah HE (76,28866 %), disusul dengan AMSR (75,25773 %), MSR (74,2268 %), SSR (69,07216 %), BPDHE (67,01031 %), dan Dong (63,91753 %)

5. SARAN

Untuk penelitian selanjutnya, demi mencapai kesimpulan yang lebih akurat, diharapkan menggunakan teknik klasifikasi selain euclidean *distance* dan sampel yang lebih besar

DAFTAR PUSTAKA

- [1] Ç. Kaymak, R. Sarıcı, and A. Uçar, “Illumination Invariant Face Recognition Using Principal Component Analysis – An Overview,” pp. 124–133, 2013, doi: 10.1007/978-3-662-45514-2_22.
- [2] D. Salama AbdELminaam, A. M. Almansori, M. Taha, and E. Badr, “A deep facial recognition system using computational intelligent algorithms,” *PLoS One*, vol. 15, no. 12, pp. 1–27, 2020, doi: 10.1371/journal.pone.0242269.

-
- [3] M. abdurrahman, A. S. Muhammad, A. muhammad, and Y. Danbatta, “E0314004-Face Recognition Using Eigenface and Discrete Wavelet Transform PDF,” 2014, doi: 10.15242/IIE.E0314004.
 - [4] L. Paul and A. Suman, “Face recognition using principal component analysis method,” *Int. J. Adv. Res. Comput. Eng. Technol.*, vol. 1, pp. 135–139, 2012.
 - [5] G. Blanchet and M. Charbit, *Digital Signal and Image Processing using MATLAB®: Second Edition*. 2015.
 - [6] H. Peng, Z. Gu, C. Chen, and D. Zhang, “A Low-Light Image Enhancement Method Based on Image Degradation Model and Pure Pixel Ratio Prior,” *Math. Probl. Eng.*, vol. 2018, p. 8178109, 2018, doi: 10.1155/2018/8178109.
 - [7] D. J. Jobson, Z. Rahman, and G. A. Woodell, “A multiscale retinex for bridging the gap between color images and the human observation of scenes,” *IEEE Trans. Image Process.*, vol. 6, no. 7, pp. 965–976, 1997, doi: 10.1109/83.597272.
 - [8] D. J. Jobson, Z. Rahman, and G. A. Woodell, “Properties and performance of a center/surround retinex,” *IEEE Trans. Image Process.*, vol. 6, no. 3, pp. 451–462, 1997, doi: 10.1109/83.557356.
 - [9] C. Lee, J. Shih, C. Lien, and C. Han, “Adaptive Multiscale Retinex for Image Contrast Enhancement,” in *2013 International Conference on Signal-Image Technology & Internet-Based Systems (SITIS)*, 2013, pp. 43–50, doi: 10.1109/SITIS.2013.19.
 - [10] Xuan Dong *et al.*, “Fast efficient algorithm for enhancement of low lighting video,” in *2011 IEEE International Conference on Multimedia and Expo*, 2011, pp. 1–6, doi: 10.1109/ICME.2011.6012107.
 - [11] S. M. Pizer, R. E. Johnston, J. P. Ericksen, B. C. Yankaskas, and K. E. Muller, “Contrast-limited adaptive histogram equalization: speed and effectiveness,” in *[1990] Proceedings of the First Conference on Visualization in Biomedical Computing*, 1990, pp. 337–345, doi: 10.1109/VBC.1990.109340.
 - [12] H. Ibrahim and N. S. Pik Kong, “Brightness Preserving Dynamic Histogram Equalization for Image Contrast Enhancement,” *IEEE Trans. Consum. Electron.*, vol. 53, no. 4, pp. 1752–1758, Nov. 2007, doi: 10.1109/TCE.2007.4429280.
 - [13] M. Afifi, M. Nasser, M. Korashy, K. Rohde, and A. Abdelrahim, “Can We Boost the Power of the Viola-Jones Face Detector Using Pre-processing? An Empirical Study.” 2017.
 - [14] Shemi, “A Principal Component Analysis Method for Recognition of Human Faces: Eigenfaces Approach,” 2012.
 - [15] M. Afifi and A. Abdelhamed, “AFIF4: Deep gender classification based on AdaBoost-based fusion of isolated facial features and foggy faces,” *J. Vis. Commun. Image Represent.*, vol. 62, pp. 77–86, 2019, doi: <https://doi.org/10.1016/j.jvcir.2019.05.001>.
 - [16] F. Liu, Y. Wu, J. Zheng, and W. Song, “A Novel Low Light Image Enhancement Based on Non-uniform Illumination Prior Model,” *IET Image Process.*, vol. 13, 2019, doi: 10.1049/iet-ipr.2018.6208.
 - [17] P. E. Robinson and W. Lau, “Adaptive multi-scale retinex algorithm for contrast enhancement of real world scenes,” 2012.

- [18] M. A. Turk and A. P. Pentland, “Face recognition using eigenfaces,” in *Proceedings. 1991 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1991, pp. 586–591, doi: 10.1109/CVPR.1991.139758.
- [19] P. Sandhu, I. Kaur, A. Verma, S. Jindal, I. Kaur, and S. Kumari, “Face Recognition Using Eigen face Coefficients and Principal Component Analysis,” *Int. J. Electr. Electron. Eng.*, vol. 3, 2009.