

Normalisasi Iluminasi Citra Wajah Dengan Menggunakan *Histogram Remapping* Pada Pengenalan Wajah Berbasis Fitur Gabor

Hendra Kusuma¹, Wirawan², Adi Suprijanto³

Jurusan Teknik Elektro

Institut Teknologi Sepuluh Nopember (ITS)

Surabaya, Indonesia

hendraks@ee.its.ac.id¹, wirawan@its.ac.id², adisup@ee.its.ac.id³

Abstract—Tingkat akurasi dari sistem pengenalan citra wajah yang terkendala variasi iluminasi/pencahayaan sangat bergantung pada seberapa baik pengolahan awal yang dilakukan pada citra input. Pada dasarnya prosedur pengolahan awal pada citra wajah adalah proses normalisasi yang dilakukan agar citra-citra wajah dengan variasi iluminasi yang besar menjadi citra-citra wajah dengan iluminasi yang relatif sama. Pada makalah ini akan diterapkan suatu pendekatan sederhana namun efektif pada pemrosesan awal dengan menggunakan penataan ulang histogram citra-citra wajah (*histogram remapping*). Penerapan dilakukan pada teknik pengenalan wajah berbasis fitur Gabor dan bertujuan menunjukkan pengaruhnya terhadap perbaikan tingkat akurasi. Untuk menunjukkan efektifitas dan keandalan dari penerapan *histogram remapping* tersebut maka dilakukan uji coba dengan menggunakan basis data wajah Yale-B. Hasil yang dicapai menunjukkan bahwa teknik pengenalan citra wajah berbasis fitur Gabor dengan penataan ulang histogram, robust terhadap variasi iluminasi/pencahayaan.

Keywords—*Histogram remapping; fitur Gabor; teknik pengenalan citra wajah; normalisasi pencahayaan.*

I. PENDAHULUAN

Salah satu permasalahan yang sering dijumpai pada sistem pengenalan citra wajah adalah adanya variasi iluminasi/pencahayaan pada citra wajah. Variasi iluminasi pada citra wajah ini dapat terjadi karena perbedaan posisi sumber cahaya dan intensitas cahaya saat proses pengambilan citra wajah. Pengaruh variasi iluminasi ini sedemikian besar sehingga variabilitas citra-citra dari wajah orang yang sama, yang berbeda pencahayaannya selalu lebih besar dibandingkan variabilitas citra dari wajah-wajah orang yang berbeda [1]. Gambar 1. Menunjukkan citra-citra wajah dari basis data Yale-B dengan perubahan iluminasi yang disebabkan oleh sumber cahaya pada posisi-posisi tertentu yang akan memberikan perbedaan yang cukup berarti.



Gambar 1. Citra-citra wajah yang sama dengan pencahayaan yang berbeda (basis data Yale-B)

Berbagai metoda pendekatan diusulkan pada literatur untuk mendapatkan teknik pengenalan citra wajah yang robust terhadap pengaruh perubahan iluminasi pada citra wajah. [2-4] Untuk mendapatkan teknik pengenalan citra wajah yang tidak terpengaruh oleh variasi pencahayaan maka pada makalah ini diusulkan pengenalan citra wajah berbasis fitur Gabor dengan prosedur pemrosesan awal menggunakan teknik normalisasi histogram remapping [5].

II. TINJAUAN PUSTAKA

A. *Histogram equalization*

Histogram equalization merupakan suatu proses transformasi distribusi harga-harga intensitas piksel pada citra $I(x,y)$ sedemikian sehingga menjadi distribusi harga intensitas piksel yang merata (*uniform*) sehingga memperbaiki kekontrasan citra secara keseluruhan. Proses ini bekerja dengan cara menyebarkan harga-harga intensitas piksel yang sering hadir/muncul secara merata pada citra. Secara umum, bilamana suatu citra wajah, $I(x,y)$ yang terdiri dari N piksel dengan jumlah *tingkat keabuan* sebanyak k , dan jika probabilitas kehadiran suatu piksel dengan tingkat keabuan i , dimana $i \in \{0, 1, \dots, k-1\}$ dinyatakan dengan, $p(i) = \frac{n_i}{N}$ maka pemetaan/mapping dari suatu harga intensitas menjadi i_{baru} dinyatakan sebagai *histogram equalization* dan didefinisikan sebagai berikut,

$$i_{baru} = \sum_{i=0}^{k-1} \frac{n_i}{N} = \sum_{i=0}^{K=1} p(i) \quad (1)$$

Dimana n_i merupakan jumlah piksel pada $I(x,y)$ dengan harga tingkat keabuan i . Persamaan 1, mendefinisikan suatu harga pemetaan/mapping dari harga-harga intensitas piksel original dalam interval 0-255 menjadi harga baru dalam domain [0-1]. Sehingga untuk memperoleh harga piksel pada domain original, harga i_{baru} harus diskala ulang. Contoh dari *Histogram Equalization* (HE) dapat dilihat pada gambar 2 berikut ini,

Pemetaan distribusi intensitas piksel suatu citra wajah menjadi distribusi yang merata (*uniform*) telah terbukti meningkatkan kekontrasan citra sehingga HE merupakan salah satu teknik perbaikan citra (image enhancement) yang paling sering digunakan untuk peningkatan unjuk kerja pengenalan wajah.

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) \quad (4)$$

Dimana μ merupakan harga dari *mean* dan $\sigma > 0$ merupakan standar deviasi. Pada teknik HR ini, sebagai target adalah kurva norma. Dimana ada 2 parameter yang harus ditentukan yaitu μ dan σ . Penentuan harga tersebut hanyalah untuk keperluan visualisasi saja karena harga-harga piksel akan diskala ulang pada interval 8 bit. Pemilihan harga μ pada dasarnya tidak mempengaruhi hasil mapping dan umumnya diambil $\mu = 0$. Contoh histogram hasil dari prosedur ini dapat dilihat pada gambar 3b. Dimana citra awal sebelum proses HR ditunjukkan pada gambar 3a.

D. Pemetaan Dengan Target Distribusi Lognormal

Fungsi kerapatan distribusi lognormal adalah,

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \frac{\exp(-(\ln x - \mu)^2 / 2\sigma^2)}{x} \quad (5)$$

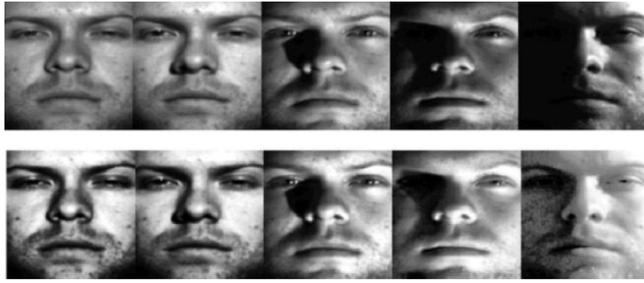
Dimana parameter μ dan $\sigma > 0$ menunjukkan bentuk dari distribusi. Contoh visualisasi dari distribusi ini dapat dilihat pada gambar 3c.

E. Pemetaan Dengan Target Distribusi Eksponensial

Persamaan (6) berikut menunjukkan fungsi kerapatan distribusi eksponensial,

$$f(x) = \lambda \exp(-\lambda x) \quad (6)$$

Dimana λ merupakan parameter distribusi yang juga sering disebut sebagai *rate parameter*. Pada percobaan yang dilakukan untuk penelitian ini harga λ adalah 1. Contoh dari citra yang ditransformasi dengan distribusi ini dapat dilihat pada gambar 3d.



Gambar 2. Pengaruh dari proses histogram equalization (HE) : Citra-citra awal (atas), citra-citra hasil HE (bawah).

Pada teknik *histogram remapping*[5], yaitu penataan kembali histogram yang ada, distribusi target tidak terbatas hanya pada distribusi *uniform* melainkan juga dapat berupa distribusi non-uniform seperti distribusi normal, lognormal, eksponensial maupun distribusi-distribusi yang lain. Tidak ada jaminan bahwa distribusi *uniform* merupakan yang paling sesuai untuk pengenalan wajah karena itu perlu dievaluasi pula *histogram remapping* dengan target yang bukan distribusi *uniform*.

B. Histogram Remapping

Histogram remapping (HR) melakukan proses peningkatan kontras suatu citra dengan cara pemetaan/mapping harga-harga intensitas piksel dari citra dengan transformasi *rank*. Transformasi *rank* ini pada dasarnya merupakan prosedur histogram equalization yang *re-render* histogram citra sedemikian sehingga histogram hasil merupakan pendekatan dari distribusi normal. Setiap harga piksel pada citra wajah berdimensi N , yaitu $I(x,y)$ akan diganti dengan indeks (atau *rank*) R . Piksel-piksel pada citra akan diurutkan dari bawah ke atas. Sebagai contoh, harga piksel yang paling negatif akan dinyatakan sebagai ranking 1 sedangkan yang paling positif diberi ranking N . Secara umum prosedur ini sama dengan *histogram equalization* dan hanya berbeda pada cara pemetaan piksel ke domain yang baru dan perhitungan harga dari intensitas piksel yang baru.

Ketika ranking R dari setiap piksel citra telah ditentukan maka fungsi pemetaan umum agar sesuai dengan distribusi target $f(x)$ dapat dihitung berdasarkan rumus berikut, [5-7]

$$\frac{N-R+0.5}{N} = \int_{x=-\infty}^t f(x) dx \quad (2)$$

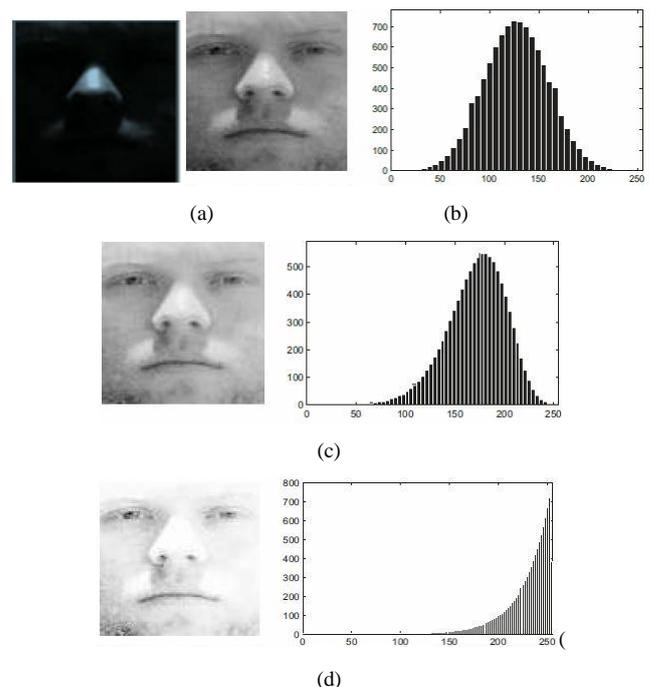
Persamaan (2) bertujuan untuk menentukan harga t . Terlihat bahwa sisi kanan persamaan di atas merupakan fungsi distribusi kumulatif dari target distribusi dan sisi kiri merupakan harga skalar. Jika fungsi distribusi kumulatif merupakan $F(x)$ dan besaran skalar pada bagian kiri adalah u maka harga t dapat ditentukan dengan menghitung :

$$t = F^{-1}(u) \quad (3)$$

Dimana F^{-1} merupakan fungsi invers dari fungsi distribusi kumulatif.

C. Pemetaan Dengan Target Distribusi Normal

Persamaan (4) berikut ini digunakan untuk mendapatkan target distribusi Normal dan dinyatakan sebagai,



Gambar 3. (a) Citra awal, Citra hasil proses HR dengan target distribusi (b) Normal, (c) Lognormal dengan $\sigma = 0.7$, (d) Eksponensial dengan $\lambda = 1$.

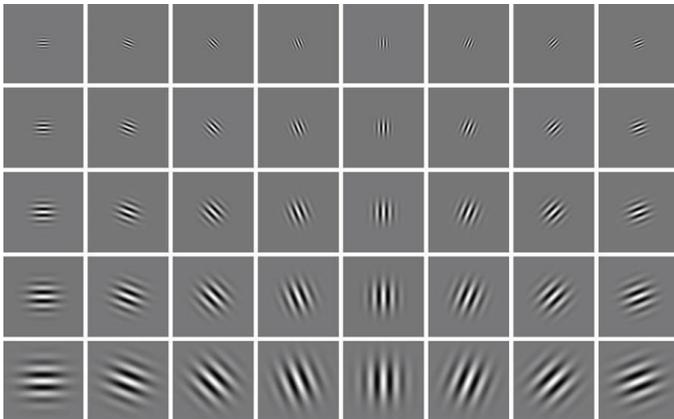
F. Filter Gabor

Filter Gabor yang juga disebut wavelet Gabor atau Kernel Gabor telah terbukti merupakan ‘powerful tool’ untuk ekstraksi fitur wajah pada pengenalan wajah yang robust. Filter Gabor merupakan filter kompleks dengan lebar pita terbatas yang mempunyai alokasi optimal baik pada domain spasial maupun pada domain frekwensi sehingga jika diaplikasikan untuk ekstraksi fitur wajah maka filter Gabor akan mengekstraksi fitur-fitur lokal spasial multiresolusi pada suatu pita frekwensi yang terbatas.[8] Seperti halnya semua filter yang beroperasi pada ruang berskala (scale-space). Secara umum filter Gabor 2-D dapat didefinisikan di domain spasial sebagai berikut. [9-10]

$$\psi_{u,v}(x, y) = \frac{f_u^2}{\pi k \eta} e^{-((f_u^2/k^2)x'^2 + (f_v^2/k^2)y'^2)} e^{j2\pi f_u x'} \quad (7)$$

dimana $x' = x \cos \theta_v + y \sin \theta_v$, $y' = -x \sin \theta_v + y \cos \theta_v$, $f_u = f_{maks}/2^{(u/2)}$, dan $\theta_v = v \pi/8$. Sesuai dengan definisi filter maka setiap filter Gabor mewakili suatu fungsi kernel Gaussian yang dimodulasi oleh suatu gelombang bidang kompleks dimana titik pusat frekwensi dan orientasinya masing-masing diberikan oleh f_u dan θ_v . Parameter k dan η menentukan perbandingan antara frekwensi pusat dan ukuran envelope Gaussian dan ketika di set pada suatu harga yang tetap akan menjamin masing-masing filter Gabor ini saling merupakan versi skala, satu dengan yang lainnya[8]. Jadi harga tetap dari parameter k dan η akan membuat skala filter Gabor yang unik yang ditentukan oleh harga frekwensi pusatnya, f_u .

Parameter yang paling umum digunakan untuk pengenalan wajah adalah $k = \eta = \sqrt{2}$ dan $f_{maks} = 0,25$. [9-10] Untuk ekstraksi fitur wajah dengan menggunakan filter-filter Gabor, umumnya dibentuk suatu bank filter dengan 5 skala dan 8 orientasi yaitu, $u = 0, 1, \dots, p-1$ dan $v = 0, 1, \dots, r-1$, dimana $p = 5$ dan $r = 8$. Bagian real dari keseluruhan bank filter yang umum digunakan untuk ekstraksi fitur wajah (terdiri dari 40 filter) ditunjukkan pada gambar 4.



Gambar 4. . Bagian-bagian real dari bank filter gabor yang umum digunakan untuk ekstraksi fitur pada teknik pengenalan wajah

G. Ekstraksi Fitur Dengan Filter Gabor.

Jika citra wajah berskala abu-abu (grey-scale) dengan ukuran piksel $a \times b$ dinyatakan dengan $I(x,y)$, dan filter Gabor dengan frekwensi pusat f_u dan orientasi θ_v dinyatakan dengan $\psi_{u,v}(x,y)$, maka prosedur untuk ekstraksi fitur dapat didefinisikan sebagai suatu operasi filter dari citra wajah $I(x,y)$ dengan filter gabor $\psi_{u,v}(x,y)$ yang mempunyai ukuran u dan orientasi v [9-10] yaitu,

$$G_{u,v}(x, y) = I(x, y) * \psi_{u,v}(x, y) \quad (8)$$

Dimana $G_{u,v}(x,y)$ adalah besaran kompleks yang merupakan output filter yang terdiri dari bagian real ($E_{u,v}(x,y)$) dan bagian imajiner ($O_{u,v}(x,y)$),

$$E_{u,v}(x, y) = Re[G_{u,v}(x, y)],$$

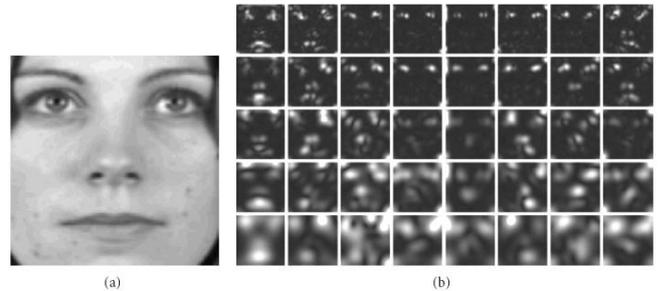
$$O_{u,v}(x, y) = Im[G_{u,v}(x, y)] \quad (9)$$

Berdasarkan persamaan (9) magnitude ($A_{u,v}(x,y)$) dan fasa ($\phi_{u,v}(x,y)$) yang merupakan tanggapan filter dapat dihitung sebagai,

$$A_{u,v}(x, y) = \sqrt{E_{u,v}^2(x, y) + O_{u,v}^2(x, y)},$$

$$\phi_{u,v}(x, y) = \tan^{-1} \left(\frac{O_{u,v}(x,y)}{E_{u,v}(x,y)} \right) \quad (10)$$

Pemodelan citra pada sebagian besar teknik pengenalan wajah berbasis fitur Gabor, umumnya mengabaikan informasi fasa dari output filter dan hanya bergantung pada informasi magnitude. Gambar 5 menunjukkan magnitude output filter Gabor hasil konvolusi dengan sebuah citra sampel.

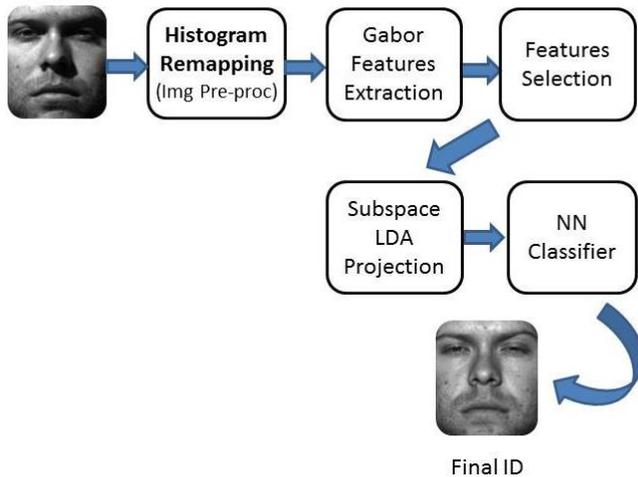


Gambar 5. Contoh magnitude output Filter Gabor, (a) Citra sample, (b) Magnitude output filter-bank Gabor yang terdiri dari 40 filter Gabor. [8]

III. METODOLOGI

Penelitian ini bertujuan untuk meningkatkan akurasi pengenalan sistem pengenalan citra wajah berbasis fitur Gabor terhadap adanya variasi pencahayaan. Berbagai aplikasi dalam bidang analisa pola dan pengenalan citra telah menunjukkan bahwa wavelet Gabor mampu memberikan pendekatan yang tepat untuk memodelkan wajah untuk sistem pengenalan citra wajah [6-8], Sebagai ekstraksi informasi wajah dari citra wajah, Gabor wavelet mampu menangkap sifat visual yang menonjol sehingga dapat digunakan untuk lokalisasi spasial, pemilihan orientasi, dan penentuan frekuensi spasial. Namun demikian seperti halnya fitur-fitur lain, Gabor wavelet juga sensitif terhadap perubahan pencahayaan yang ekstrim. Dengan demikian pada sistem pengenalan citra wajah dengan fitur Gabor juga membutuhkan bantuan proses lain yang mampu

meningkatkan akurasi pengenalan citra wajah. Dalam penelitian ini akan digunakan proses normalisasi histogram remapping sebelum proses ekstraksi dengan fitur Gabor.



Gambar 6. Blok diagram sistem pengenalan citra wajah

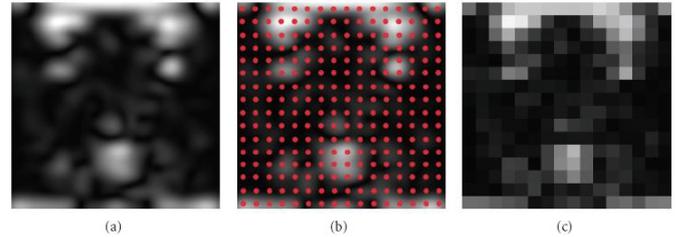
A. Pemodelan Citra Wajah dengan Gabor Magnitude

Blok Diagram dari sistem pengenalan citra wajah yang diusulkan ditunjukkan pada gambar 6 di atas. Pertama-tama dilakukan normalisasi citra-citra wajah terhadap variasi pencahayaan yaitu dengan menggunakan algoritma histogram remapping. Langkah kedua adalah ekstraksi fitur wajah dengan filter Gabor. Dari langkah kedua didapatkan fitur-fitur wajah dengan dimensi yang besar. Untuk mengurangi jumlah fitur-fitur tersebut maka dilakukan langkah ketiga yaitu prosedur pemilihan fitur yang dalam hal ini menggunakan proses *downsampling*. Penjelasan mengenai hal ini akan diterangkan selanjutnya. Langkah berikutnya adalah proses pengenalan citra wajah dengan menggunakan prosedur diskriminan *Subspace LDA* dan *Nearest Neighbour classifier*.

Untuk membuat model wajah dengan fitur Gabor *magnitude* maka langkah pertama adalah membentuk bank filter Gabor. Seperti umumnya dilakukan oleh beberapa teknik pengenalan wajah pada literatur, suatu bank filter Gabor akan terdiri dari filter-filter Gabor dengan lima skala ($u = 0, 1, 2, 3, 4$) dan delapan orientasi ($v = 0, 1, 2, 3, 4, 5, 6, 7$).

Langkah selanjutnya adalah melakukan filter terhadap citra wajah yang akan dimodelkan oleh ke 40 filter Gabor yang telah dibentuk sebelumnya sehingga akan diperoleh data (citra) dengan dimensi 40 kali dimensi citra wajah. Hal ini merupakan data yang sangat besar meskipun ukuran citra wajah adalah kecil. Sebagai contoh, untuk citra wajah berukuran 128×128 piksel, maka *magnitude* output akan menjadi sebesar 655360 ($128 \times 128 \times 40$). Data yang besar ini akan memberatkan perhitungan dan membutuhkan banyak memori penyimpanan data, sehingga dibutuhkan strategi untuk mereduksi dimensi yang besar ini. Pada penelitian ini digunakan teknik *downsampling* untuk mereduksi data yang besar tersebut. Strategi *downsampling* yang digunakan adalah *rectangular sampling grid* seperti yang ditunjukkan pada gambar 7 dimana *grid-grid* ini akan diletakkan di atas citra wajah. Pada citra yang sudah di-*downsampling* maka hanya *magnitude*

yang ada pada simpul *grid* yang digunakan sedangkan yang lainnya diabaikan. Proses *downsampling* ini akan dilakukan untuk semua output 40 filter yang kemudian dinormalisasi dengan prosedur normalisasi tertentu. Hasil dari semua normalisasi *downsampling* kemudian akan disusun untuk membentuk model wajah yang disebut *Gabor feature vector*. [9] Prosedur normalisasi tipikal yang digunakan adalah dengan membuat data dengan *mean nol* dan *variance = 1* (*zeromean, unit variance*).



Gambar 7. *Downsampling* dengan *rectangular sampling grid*, (a) citra *magnitude response*, (b) citra *magnitude response* dengan *rectangular sampling grid*, dan (c) citra *downsampled magnitude response*.

Jika $g_{u,v}$ merupakan *magnitude* Gabor yang telah di-*downsampling* dalam bentuk vektor untuk filter dengan skala u dan orientasi v , maka vektor fitur Gabor x didefinisikan sebagai berikut,

$$x = (g_{0,0}^T, g_{0,1}^T, g_{0,2}^T, \dots, g_{4,7}^T) \quad (11)$$

Pada penelitian ini digunakan citra dengan ukuran 128×128 piksel dan *rectangular sampling grid* adalah 16×16 , maka faktor *downsampling*, ρ adalah 64.

B. Subspace LDA

Metode yang diterapkan pada penelitian ini adalah metode *Subspace LDA*. Pada dasarnya metode ini merupakan metoda diskriminan yang sekaligus juga mereduksi dimensi fitur. *Subspace LDA* terdiri dari dua langkah yaitu *PCA* (*Principle Component Analysis*) yang berfungsi mereduksi dimensi dan *LDA* (*Linear Discriminant Analysis*) sebagai fungsi diskriminan linier. Langkah pertama adalah citra wajah diproyeksikan ke dalam ruang *eigenface* yang dibangun oleh *PCA*, dan kemudian diproyeksikan lagi ke ruang klasifikasi *LDA* untuk membentuk suatu klasifikasi linier. Pilihan jumlah *eigenfaces* (fitur wajah yang tereduksi) yang digunakan pada *PCA* sangat penting karena pilihan ini memungkinkan sistem untuk membentuk fitur dengan kelas yang dapat dibedakan melalui prosedur *LDA*.

Tujuan dari *PCA* adalah untuk mengidentifikasi ruang baru dengan dimensi lebih kecil yang dibentuk oleh citra-citra latih (*training*) $\{x_1, x_2, \dots, x_M\}$, yang dapat mendekorelasi varians dari nilai-nilai pixel. Untuk itu dibutuhkan analisa eigen dari matrik kovarian, $\Sigma = \frac{1}{M-1} \sum_{i=1}^M (x_i - \bar{x})(x_i - \bar{x})^T$ sebagai berikut,

$$\Sigma E = \Lambda E \quad (12)$$

Dimana E dan Λ , masing-masing adalah eigenvektor (yang juga disebut *eigenface*) dan eigenvalue. Representasi dari citra wajah dalam sub-ruang *PCA* kemudian diperoleh dengan memproyeksikan citra-citra ke sistem koordinat yang dibentuk oleh *eigenfaces* [11]. Jika proyeksi citra wajah ke sub-ruang *PCA* bertujuan mereduksi dimensi fitur, maka *LDA* bertujuan

untuk mendapatkan matrik proyeksi W yang digunakan untuk memaksimalkan hasil bagi dari determinan S_b dan S_w , [12-13]

$$W = \arg \max \frac{|W^T S_b W|}{|W^T S_w W|} \quad (13)$$

dimana S_b dan S_w masing-masing adalah matrik *between-class scatter* dan matrik *within-class scatter*. Jika terdapat suatu permasalahan dengan C kelas dan N_c adalah jumlah sample pada C kelas serta M adalah sekelompok citra latih dari C kelas dapat didefinisikan sebagai, as $\{x_{ck}, c = 1, 2, \dots, C; k = 1, 2, \dots, N\}$, $M = \sum_{c=1}^C N_c$. S_b dan S_w dari suatu set citra latih dapat dihitung sebagai,

$$S_w = \frac{1}{C} \sum_{c=1}^C \frac{1}{N_c} \sum_{k=1}^{N_c} (x_{ck} - \mu_c)(x_{ck} - \mu_c)^T \quad (14)$$

$$S_b = \frac{1}{C} \sum_{c=1}^C (\mu_c - \mu)(\mu_c - \mu)^T \quad (15)$$

dimana μ adalah mean dari citra-citra latih, dan μ_c merupakan mean untuk kelas c . Telah ditunjukkan di [13] bahwa proyeksi matrik W dapat dihitung dari eigenvektor $S_w^{-1} S_b$. Namun demikian, karena dimensi vektor fitur besar sekali maka, S_w umumnya singular, yaitu S_w tidak memiliki invers. Jadi untuk mengatasi hal tersebut maka, teknik reduksi dua tahap, yang dinamakan *Most Discriminant Features* (MFD) atau subspace LDA, diusulkan oleh [14]. Vektor-vektor citra wajah akan diproyeksikan terlebih dahulu ke ruang berdimensi rendah dengan algoritma PCA, dan kemudian dianalisa oleh algoritma LDA. Jika W_{pca} merupakan matrik proyeksi dari citra ruang asal menuju sub-ruang PCA, maka matrik proyeksi LDA, W_{lda} akan dibentuk oleh eigenvektor-eigenvektor dari $(W_{pca}^T S_w W_{pca})^{-1} (W_{pca}^T S_b W_{pca})$. Matrik proyeksi akhir W_{mfd} atau $W_{subspace LDA}$ dapat diperoleh dari,

$$W_{mfd} = W_{pca} \times W_{lda} \quad (16)$$

Rank dari matrik $S_b \leq C - 1$, sedangkan rank dari $S_w \leq M - C$. Maka dimensi dari Sub-ruang PCA adalah $M - C$ [14].

IV. HASIL DAN PEMBAHASAN

Untuk menunjukkan efektifitas dari metoda yang diusulkan pada penelitian ini, maka digunakan basis data yang tersedia secara publik, yang terdiri dari citra-citra dengan variasi iluminasi yaitu basis data Yale-B.

A. Basis data Yale-B

Basis data Yale-B terdiri dari 5760 citra wajah bagian depan (frontal) dengan sumber cahaya tunggal dari 10 individu. Citra-citra tersebut menunjukkan variasi iluminasi yang besar large variations in illumination. Ukuran dari setiap citra adalah 192 x 168. Setiap individu yang berbeda, memiliki 576 citra dengan variasi-variasi yaitu 9 citra dengan variasi posisi wajah yang berbeda dan 64 citra dengan iluminasi yang berbeda. Basis data Yale-B dikelompokkan dalam 5 kelompok (*subset*) yang berbedan berdasarkan arah sumber cahaya terhadap sumbu kamera (12°, 25°, 50°, 77°). Kelompok 1, 2, 3, 4 and 5 masing-masing terdiri dari, 120, 130, 130, 130, and 130 citra per posisi [15]. Karena penelitian ini hanya berkaitan dengan variasi iluminasi, maka citra-citra pada basis data ini hanya dipilih sebanyak 64 citra wajah depan yang diambil dengan kondisi pencahayaan yang berbeda untuk setiap individu dari 10 individu yang ada. Jadi terdapat 640 citra wajah yang

digunakan untuk pengujian sistem pengenalan citra wajah, Contoh dari citra individu-individu iniditunjukkan pada gambar 8.



Gambar 8. Citra-citra wajah individu dari basis data Yale-B

B. Pengaturan Pengujian

Sebelum pengujian dilakukan maka semua citra wajah (subset 1 - 5) secara manual dirotasi agar posisi wajah benar-benar frontal berdasarkan koordinat dari dua mata yang ditentukan secara manual. Langkah selanjutnya adalah dilakukan prosedur "resize" dan "crop" sehingga ukuran citra-citra menjadi 128 x 128 piksel dengan derajat keabuan sebesar 256. Proses crop dilakukan untuk memastikan bahwa hanya bagian wajah saja yang digunakan untuk citra-citra pengujian. Serangkaian prosedur di atas dilakukan untuk menjamin bahwa hasil pengujian sesuai dengan hasil-hasil penelitian dengan metoda lain yang ada pada literatur.

Dari blok diagram pada gambar 6, maka setelah prosedur di atas, akan dilakukan proses normalisasi citra-citra terhadap perubahan iluminasi dengan metoda histogram remapping sehingga variasi iluminasi yang terlalu besar menjadi merata pada seluruh bagian citra-citra.

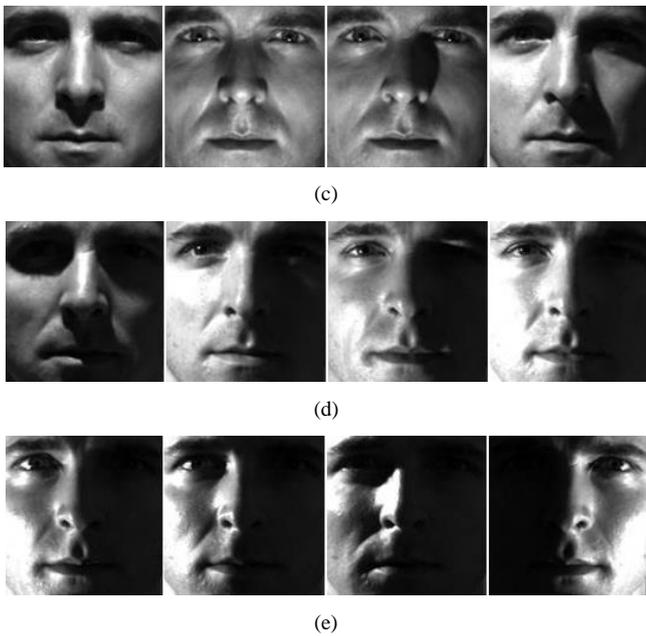
Citra-citra pada subset 1 yang terdiri dari citra-citra dengan kondisi pencahayaan yang dianggap paling sesuai atau normal digunakan sebagai citra-citra latih (training), sedangkan subset yang lain yaitu subset 2 sampai dengan subset 5 digunakan untuk pengujian. Gambar 9 menunjukkan 4 citra contoh untuk setiap subset 2 sampai dengan 5 yang belum dinormalisasi. [15]



(a)



(b)



Gambar 9. Citra-citra contoh sebelum di normalisasi dari 5 subset pada basis data YaleB, (a) subset 1, (b) subset 2, (c) subset 3, (d) subset 4, dan (e) subset 5.

Pengujian sistem pengenalan citra wajah ini juga dilakukan dengan menggunakan algoritma subspace LDA sebagai diskriminan dan reduksi dimensi dengan variabel jumlah eigenvektor yang digunakan. Jumlah dari citra-citra latih per individu adalah 12. Pada [16] telah ditunjukkan bahwa untuk hasil terbaik algoritma subspace LDA digunakan pengukuran jarak berbasis sudut yaitu menggunakan jarak berbasis kosinus dengan klasifier *nearest neighbour*. Persamaan berikut adalah persamaan jarak berbasis kosinus,

$$d_{cos}(x, y) = \frac{x^T y}{\sqrt{x^T x y^T y}} \quad (17)$$

C. Hasil Pengujian

Unjuk kerja dari sistem pengenalan citra wajah pada penelitian ini diuji dengan basis data Yale-B. Tingkat akurasi pengenalan dihitung berdasarkan perbandingan dari jumlah citra-citra uji yang diidentifikasi benar terhadap jumlah total citra-citra uji. Pengujian dilakukan dengan melakukan 3 (tiga) proses normalisasi citra dengan histogram remapping yaitu pemetaan ulang ke distribusi Normal, Lognormal dan Eksponensial. Pengujian juga dilakukan dengan variasi harga skala filter Gabor, u yaitu dengan $u = 3, 4,$ dan 5 . Hasil pengujian ditunjukkan pada tabel 1, 2, dan 3.

Tabel 1. Tingkat akurasi pengenalan pada basis data Yale-B dengan target distribusi Lognormal

u	Jumlah Eigvkt	S2	S3	S4	S5
5	60%	100	100	96,4	95.2
	80%	100	100	96.8	95
	100%	100	100	96.8	95.2
4	60%	100	100	96.8	95
	80%	100	100	96.8	95
	100%	100	100	96.8	95
3	60%	100	100	95.8	94.8
	80%	100	100	96	94.8
	100%	100	100	96	95

Tabel 2. Tingkat akurasi pengenalan pada basis data Yale-B dengan target distribusi Eksponensial

u	Jumlah Eigvkt	S2	S3	S4	S5
5	60%	100	100	90	92.2
	80%	100	100	90.2	92.2
	100%	100	100	90.2	92
4	60%	100	100	90	92.2
	80%	100	100	89.8	92
	100%	100	100	90	92.2
3	60%	100	100	90	92
	80%	100	100	90	92
	100%	100	100	90	92

Tabel 3. Tingkat akurasi pengenalan pada basis data Yale-B dengan target distribusi Normal

u	Jumlah Eigvkt	S2	S3	S4	S5
5	60%	100	98	74	76
	80%	100	98	74	76
	100%	100	98	74	76.2
4	60%	100	97.8	73.8	75.6
	80%	100	97.8	73.8	75.8
	100%	100	98	74	75.6
3	60%	100	97.8	74	75.8
	80%	100	98	73.8	76
	100%	100	98	74	76

V. KESIMPULAN

Pada makalah ini telah ditunjukkan metoda yang efisien dan akurat pada sistem pengenalan citra wajah dengan fitur Gabor dengan proses normalisasi histogram remapping yaitu berdasarkan hasil pengujian yang dilakukan dengan menggunakan basis data Yale-B.

Pertama-tama citra wajah akan di normalisasi dengan histogram remapping, dengan target distribusi Normal, atau Lognormal atau Eksponensial dan filter Gabor digunakan untuk mendapatkan titik-titik fitur wajah dan kemudian dilakukan proses *downsampling* untuk pemilihan vektor fitur wajah yang akan digunakan untuk pengenalan. Vektor-vektor fitur wajah ini akan diklasifikasikan dengan menggunakan subspace LDA dan algoritma nearest neighbour dengan pengukuran jarak kosinus. Dari hasil pengujian, untuk mendapatkan unjuk kerja pengenalan yang optimal pada metoda yang diusulkan pada penelitian ini cukup menggunakan 24 bank filter Gabor (3 skala dan 8 orientasi filter) karena penambahan filter dengan jumlah skala 4 atau 5 tidak menambah akurasi pengenalan. Demikian pula untuk jumlah eigenvektor yang digunakan cukup sebesar 60% sehingga kecepatan pengenalan akan meningkat. Kelayakan dan ketepatan dari sistem pengenalan yang diusulkan ini tampak

dari unjuk kerja pengenalan yang robust terhadap perubahan pencahayaan yang ekstrim, yaitu dengan normalisasi histogram remapping dengan target distribusi lognormal didapatkan akurasi yang tinggi dengan tingkat pengenalan 100%, 100%, 96,8% dan 95,2% masing-masing untuk subset 2, 3, 4, dan 5.

DAFTAR PUSTAKA

- [1] Adini, Y., Moses, Y., and Ullman, S., "Face Recognition: The Problem of Compensating for Changes in Illumination Direction", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19 (7), 1997, pp. 721-732.
- [2] Heusch, G., Cardinaux, F., and Marcel S. "Lighting Normalization Algorithms for Face Verification". *IDIAP-com*, March 2005.
- [3] Chen, W., Er, M.J., and Wu, S. "Illumination Compensation and Normalization for Robust Face Recognition Using Discrete Cosine Transform in Logarithmic Domain". *IEEE Transactions on Systems, Man and Cybernetics – part B*, 36(2), 2006, pp. 458-466.
- [4] Zou, X., Kittler, J., and Messer, K., "Illumination Invariant Face Recognition: A Survey," *Biometrics: Theory, Applications, and Systems*, BTAS2007. First IEEE International Conference on, Crystal City, VA, 27-29 Sept. 2007, pp. 1-8.
- [5] Štruc, V., Žibert, J., and Pavešid, N. (2009). Histogram Remapping as Preprocessing Step for Robust Face Recognition. *WSEAS Transactions on Information Science and Applications*, 6(3), 520-529
- [6] Pelecanos, J., and Sridharam, S. (2001). Feature Warping for Robust Speaker Verification. In: *Proc. of the Speaker Recognition Workshop Odyssey*, pp. 213–218.
- [7] Gonzalez, R.C., and Woods, R.E. (2002). *Digital Image Processing*, 2nd Edition, Prentice Hall.
- [8] Štruc, V., and Pavesic, N., "From Gabor Magnitude to Gabor Phase Features: Tackling the Problem of Face Recognition under Severe Illumination Changes", *Face Recognition*, Milos Oravec, InTech, <http://www.intechopen.com/books/face-recognition/>, 2010.
- [9] Liu, C., Wechsler, H., "Gabor Feature Based Classification Using the Enhanced Fisher Linear Discriminant Model for Face Recognition", *IEEE Trans. Image Processing*, Vol. 11, 2002, pp.467-476
- [10] Shen, L., and Bai, L., "A review of Gabor wavelets for face recognition," *Pattern Analysis and Applications*, vol. 9, no. 2, 2006, pp. 273–292.
- [11] Turk, M. and Pentland, A. Eigenfaces for Recognition. *Journal of Cognitive Neuroscience*. 1991; Vol. 3 :71-86.
- [12] Zhao, W., Krishnaswamy, A., Chellapa, R., Swets, D. L., & Weng, J. J. Discriminant Analysis of Principal Components for Face Recognition. In H. Wechsler, P. J. Phillips, V. Bruce, F. F. Soulie, & Y. P. Huang. *Editors. Face Recognition: From Theory to Applications*. CAR-TR-914 ed. Springer-Verlag; 1998 : 73-85.
- [13] Jian, L., Shaohua, Z., & Shekhar, C. A Comparison Of Subspace Analysis For Face Recognition. *IEEE International Conference on Acoustics & Speech Signal Processing*, Hong Kong, 2003; Vol.3: 121-4.
- [14] Swets DL, Weng JJ. Using discriminant eigenfeatures for image retrieval. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 1996; 18 : 831-836.
- [15] Kusuma H, Wirawan W, Soeprijanto A. "Gabor-based face recognition with illumination variation using subspace-linear discriminant analysis", *TELKOMNIKA (Telecommunication Computing Electronics and Control)*. Mar 2012; 10(1): pp. 119-28.