

**STUDI PERBANDINGAN PENGENALAN CITRA SENYUMAN
BERDASARKAN *AESTHETIC DENTISTRY* MENGGUNAKAN
METODE *2D-PCA* DAN METODE *2D-LDA***

***Rima Tri Wahyuningrum, **Fitri Damayanti**

Jurusan Teknik Informatika, Universitas Trunojoyo

Jl. Raya Telang PO. BOX 2, Kamal, Bangkalan, Madura, 69162

E-Mail: *rima_tw@yahoo.co.id, **fitri2708@yahoo.com

Abstrak

Di bidang penelitian *Aesthetic Dentistry* telah dilakukan klasifikasi pola senyuman yang meliputi *smile styles*, taraf senyuman (*smile stages*) dan *smile types*. Klasifikasi ini bertujuan untuk mengidentifikasi berbagai macam pola senyuman yang menjadi dasar untuk mendapatkan kesamaan persepsi para dokter gigi dalam melakukan perawatan gigi dan bedah mulut, khususnya untuk memperbaiki pola senyuman pasien. Dua hal yang menjadi masalah utama pada pengenalan citra senyuman adalah proses ekstraksi fitur dan juga teknik klasifikasi yang digunakan. Makalah ini membahas perbandingan metode ekstraksi fitur *Two Dimensional Principal Component Analysis (2D-PCA)* dengan *Two Dimensional Linear Discriminant Analysis (2D-LDA)*, dalam hal ini klasifikasi pola senyuman berdasarkan *smile stages* menggunakan *Euclidian Distance*. Selain itu, juga dilakukan perhitungan *Peak Signal to Noise Ratio (PSNR)* yang bertujuan untuk mengetahui kualitas citra senyuman sebelum dan setelah dilakukan proses ekstraksi fitur. Uji coba dilakukan pada 90 data citra wajah yang telah divalidasi dokter gigi spesialis konservasi gigi. Penelitian ini menunjukkan tingkat akurasi pengenalan citra senyuman menggunakan *2D-PCA* dan *Euclidean Distance* adalah 93,33% dengan *PSNR* sebesar 18,07 dB sedangkan menggunakan *2D LDA* dan *Euclidian Distance* adalah 96,67% dengan *PSNR* sebesar 22,36 dB.

Kata kunci: *2D-PCA, 2D-LDA, PSNR, Euclidean Distance*.

Abstract

At Aesthetic Dentistry of research in the field of pattern classification has been carried out covering smile styles, smile stages and the smile types. This classification aims at identifying various smile patterns becoming the basis for a common perception of the dentist in dental treatment and oral surgery, especially in improving the pattern of a patient smile. Two things becoming major problems on the smile image recognition are the process of feature extraction and classification techniques used. This paper, discusses comparative two dimensional feature extraction methods Principal Component Analysis (PCA 2D) with the Dimensional Two Linear Discriminant Analysis (LDA 2D), in this case based on smile smile pattern classification stages using Euclidian Distance. In addition, it also calculates the Peak Signal to Noise Ratio (PSNR) which aims at determining the image quality before and after the feature extraction process. Tests conducted at 90 facial image data have been validated conservation dental dentist specialist. This study shows the accuracy of image recognition using 2D-PCA smile and Euclidean Distance is 93.33% with a PSNR of 18.07 dB, while using 2D-LDA and Euclidian Distance is 96.67% with a PSNR of 22.36 dB.

Key words: 2D-PCA, 2D-LDA, PSNR, Euclidean Distance.

PENDAHULUAN

Pada penelitian di bidang *Aesthetic Dentistry* telah dilakukan klasifikasi pola senyuman yang meliputi *smile styles*, taraf senyuman (*smile stages*) dan *smile types*. *Smile styles* dibagi menjadi *the commisure smile*, *the cuspid smile*, dan *the complex smile*. Taraf senyuman dibagi menjadi Taraf I (*Stage I atau lips-close*), Taraf II (*Stage II atau resting-display*), Taraf III (*Stage III natural smile*), dan Taraf IV (*expanded smile*). *Smile types* dibagi menjadi *maxillary and over 3 mm gingival*, *mandibular maxillary only*, *mandibular only*, *maxillary and mandibular*, dan *neither maxillary nor mandibular*. Klasifikasi ini bertujuan untuk mengidentifikasi berbagai macam pola senyuman yang menjadi dasar untuk mendapatkan kesamaan persepsi para dokter gigi dalam melakukan perawatan gigi dan bedah mulut, khususnya untuk memperbaiki pola senyuman pasien, *orthodontic* dan *periodontal*. Beberapa permasalahan yang rumit pada bedah mulut dapat secara mudah dikelompokkan dan dibuat indeksnya [1]. Visualisasi masing-masing taraf senyuman ditunjukkan pada Gambar 1.

Selain itu, pada bidang *facial plastic surgery*, pola senyuman pasien yang akan menjalani prosedur *orthodromic temporalis insertion transfer* dianalisa terlebih dahulu secara teliti. Pada pra dan pasca operasi, pasien diajarkan tentang pola senyumannya dengan tujuan untuk mengetahui *coordinate individual muscle contraction*. Sisi wajah yang akan disisipkan '*temperory tendon*' didasarkan pada pola dari otot (*musculature*), dimana pola dari otot ini mempengaruhi pola senyuman pasien (*more horizontal zygomaticus major vs more vertical levator labii superioris alaeque nasi*) [2]. Visualisasi pola senyuman pasien ditunjukkan pada Gambar 2.

Untuk menghindari kesalahan klasifikasi ataupun perbedaan persepsi antara dokter gigi maupun pasien, perlu dilakukan pendekatan dengan menggunakan sistem komputer. Pada umumnya, klasifikasi yang selama ini dilakukan tergantung pada *visually human perception ability*. Pendekatan dengan menggunakan sistem komputer ini bertujuan untuk memberikan bahan alternatif klasifikasi pra dan pasca perawatan dalam memperbaiki pola senyuman pasien. Dua hal yang menjadi masalah utama adalah proses ekstraksi fitur

dari sampel wajah yang kemudian di-*cropping* pada wilayah mulut dan juga teknik klasifikasi yang digunakan untuk mengklasifikasikan pola senyuman pasien yang ingin dikenali berdasarkan fitur-fitur yang telah dipilih.

Selama ini *appearance based-method* adalah teknik yang mempunyai hasil akurasi yang cukup tinggi untuk melakukan diskriminasi [3][4][5]. Ekstraksi fitur adalah proses untuk mendapatkan ciri-ciri pembeda yang membedakan suatu sampel wajah dari sampel wajah yang lain. Dalam penelitian ini, ekstraksi fitur hanya dilakukan pada sampel wajah yang kemudian di-*cropping* pada wilayah mulut. Masing-masing pola senyuman mempunyai klasifikasi tersendiri. Sehingga pada prosesnya, sistem komputer dapat saja dimulai untuk membedakan pada masing-masing pola (*pattern*). Perubahan ciri yang lebih banyak terjadi di antara masing-masing taraf senyuman adalah pada wilayah mulut.

Metode *Principal Component Analysis* (*PCA*) bertujuan untuk memproyeksikan data pada arah yang memiliki variasi terbesar, yang ditunjukkan oleh vektor *eigen* yang bersesuaian dengan nilai *eigen* terbesar dari matrik kovarian [6]. *PCA* juga bertujuan untuk mereduksi dimensi dengan melakukan transformasi linier dari suatu ruang berdimensi tinggi ke dalam ruang berdimensi rendah. Kelemahan dari metode *PCA* adalah kurang optimal dalam pemisahan antar kelas. Pada tahun 1991, Cheng dkk. memperkenalkan metode Analisa Diskriminan Linier (*LDA*) untuk pengenalan wajah. Metode ini mencoba menemukan subruang linear yang memaksimalkan perpisahan dua kelas pola menurut *Fisher Criterion* J_F . Hal ini dapat diperoleh dengan meminimalkan jarak matrik sebaran *within-class* S_w dan memaksimalkan jarak matrik sebaran *between-class* S_b secara simultan sehingga menghasilkan *Fisher Criterion* J_F yang maksimal. *Diskriminan Fisher Linier* akan menemukan subruang dimana kelas-kelas saling terpisah linier dengan memaksimalkan *Fisher Criterion* J_F . Jika dimensi data jauh lebih tinggi daripada jumlah *sample training*, maka akan menyebabkan S_w menjadi *singular*. Hal tersebut merupakan kelemahan dari metode *LDA* [7].


Telah banyak metode yang ditawarkan untuk mengatasi kovarian *within class* yang selalu *singular* (dikarenakan *small sample size problem*). Salah satunya adalah metode

fisherface yang merupakan penggabungan antara metode *PCA* dan *LDA*. Proses reduksi dimensi dilakukan oleh *PCA* sebelum melakukan proses *LDA*. Hal ini dapat mengatasi *singular problem* [7]. Tetapi, kelemahan dari metode ini adalah bahwa pada saat proses reduksi dimensi *PCA* akan menyebabkan kehilangan beberapa informasi diskriminan yang berguna dalam proses *LDA*. Metode-metode lainnya yang dapat mengatasi *singular problem* adalah *Direct-LDA*, *Null-space based LDA*, *Pseudo-inverse LDA*, *Two-stage LDA*, dan *Regularized LDA* [8]. Kesemua teknik *LDA* tersebut memakai model representasi data berdasarkan vektor dan menghasilkan vektor-vektor yang biasanya memiliki dimensi tinggi. Kelemahan ini dapat diatasi dengan dikembangkannya metode *2D-PCA* dan *2D-LDA*.


Metode *Two Dimensional PCA (2D-PCA)* menggunakan teknik proyeksi citra langsung.

Matrik citra wajah *2D* tidak perlu ditransformasikan ke dalam bentuk citra vektor. Matrik kovarian citranya secara langsung dapat dibentuk dengan menggunakan matrik citra aslinya [9]. Sedangkan metode *Two-Dimensional (2D-LDA)* menilai secara langsung matrik *within-class scatter* dari matrik citra tanpa transformasi citra ke vektor. Hal ini mengatasi *singular problem* dalam matrik *within-class scatter* [10]. *2D-LDA* menggunakan *fisher criterion* untuk menemukan proyeksi diskriminatif yang optimal [8].

Setelah fitur-fitur penting data dihasilkan pada proses ekstraksi fitur, fitur-fitur tersebut nantinya akan digunakan untuk proses klasifikasi. Pada penelitian ini menggunakan metode *Euclidean Distance*, yaitu metode klasifikasi tetangga terdekatnya dengan menghitung jarak antara dua matrik fitur citra [9].



Gambar 1. Visualisasi Taraf Senyuman. (a) Taraf I (*Primarily Oral Commissure Elevation*), (b) Taraf III (*Zygomaticus Major Muscle*), dan (c) Taraf IV (*All Muscle*) (Diadaptasi dari [1]).



Gambar 2. Visualisasi Pola Senyuman Pasien Pra dan Pasca Operasi [2].

Pada penelitian sebelumnya, untuk klasifikasi senyuman berdasarkan *aesthetic dentistry* menggunakan *PCA* dan *SVM* dengan pengambilan *image frontal face* diperoleh rata-rata akurasi hasil klasifikasi setiap taraf senyuman (Taraf I, Taraf III, dan Taraf IV) sebesar 76.5%. Lalu, masih dengan data yang sama namun dengan klasifikasi senyuman berdasarkan *aesthetic dentistry* menggunakan *PCA*, *LDA*, dan *SVM*, diperoleh rata-rata akurasi hasil klasifikasi setiap taraf senyuman (Taraf I, Taraf III dan Taraf IV) sebesar 92.2% [11]. Kekurangan penelitian tersebut adalah rata-rata akurasi hasil klasifikasinya hanya sekitar 92.2% dan belum dilakukan penghitungan *Peak Signal to Noise Ratio (PSNR)*. Oleh karena itu, pada penelitian ini akan dilakukan studi perbandingan metode ekstraksi fitur *2D-PCA* dengan metode ekstraksi fitur *2D-LDA*. Klasifikasi pola senyuman dibuat berdasarkan *smile stages* yang menggunakan *Euclidean Distance*. Pada penelitian ini juga dilakukan penghitungan *PSNR* dengan tujuan untuk mengetahui kualitas citra senyuman yang dihasilkan oleh ekstraksi fitur tersebut.

TWO-DIMENSIONAL PRINCIPAL COMPONENT ANALYSIS (2D-PCA)

Suatu citra senyuman A dengan matrik berukuran $(m \times n)$ dan memiliki beberapa citra pelatihan A_j akan diproyeksikan ke dalam X (berupa vektor) untuk mendapatkan *eigenvector* dan *eigenvalue* dari matrik kovariannya. Sehingga, didapatkan proyeksi fitur-fitur dari citra A berupa Y seperti pada Persamaan (1).

$$Y = AX \quad (1)$$

Total jumlah penyebaran (*scatter*) dari vektor X ditunjukkan dengan Persamaan (2).

$$J(X) = tr(S_x) \quad (2)$$

S_x pada Persamaan (2) adalah matrik kovarian dari proyeksi fitur vektor pada citra pelatihan dan $tr(S_x)$ merupakan *trace* dari matrik kovarian S_x . Sehingga, proyeksi X dari semua citra pelatihannya dapat diperoleh dengan menggunakan Persamaan (3) dan (4).

$$\begin{aligned} S_x &= E(Y-EY)(Y-EY)^T \\ &= E[(AX-E(AX))][E(AX-E(AX))]^T \\ &= E[(A-EA)X][(A-EA)X]^T \end{aligned}$$

$$tr(S_x) = X^T E[(A-EA)^T(A-EA)] \quad (3)$$

$$G_t = E[(A-EA)^T(A-EA)] \quad (4)$$

Citra latihan A_j ($j = 1, 2, 3, \dots, M$) memiliki citra rata-rata $A = \bar{A}$. Sehingga untuk matrik kovarian citra A dapat diperoleh melalui Persamaan (5).

$$G_i = \frac{1}{M} \sum_{j=1}^M (A_j - \bar{A})^T (A_j - \bar{A}) \quad (5)$$

Berdasarkan Persamaan (1) maka selanjutnya diperoleh Persamaan (6).

$$J(X) = X^T G_t X \quad (6)$$

G_t pada Persamaan (6) disebut sebagai *generalized total scatter criterion* [9]. Setelah matrik kovarian dari citra A ditemukan, maka dilanjutkan dengan menentukan *eigenvector* dan *eigenvalue*. Untuk mendapatkan nilai X yang optimal, maka diambil *eigenvector* yang memiliki *eigenvalue* yang besar (X_1, X_2, \dots, d) dengan $J(X)$ merupakan orthonormal, sesuai dengan Persamaan (7).

$$\left\{ \begin{aligned} \{X_1, \dots, X_d\} &= \operatorname{argmax} J(X) \\ X_i^T X_j &= 0, i \neq j, i, j = 1, \dots, d \end{aligned} \right\} \quad (7)$$

Setelah didapatkan nilai proyeksi vektor (X_1, X_2, \dots, d) dari citra maka ekstraksi fitur dari citra A adalah sesuai dengan Persamaan (8).

$$Y_k = AX_k \quad (8)$$

k pada Persamaan (8) adalah $1, 2, \dots, d$. Y_1, Y_2, \dots, Y_d disebut sebagai *principal component* dari 2D PCA yang berupa vektor sedangkan pada PCA berupa skalar. $B = [Y_1, Y_2, \dots, Y_d]$ adalah matrik fitur atau *feature image* dari citra pelatihan.

TWO-DIMENSIONAL LINEAR DISCRIMINANT ANALYSIS (2D-LDA)

Sama halnya dengan *2D-PCA*, *2D-LDA* adalah pengembangan dari metode *LDA*. Pengenalan senyuman dengan matrik 2D pada *LDA* dilakukan dengan terlebih dahulu ditransformasikan ke dalam bentuk citra vektor satu dimensi. Pada *2D-LDA*, matrik citra senyuman 2D tidak perlu ditransformasikan ke dalam bentuk citra vektor, namun matrik *scatter* citranya dapat dibentuk secara langsung dengan menggunakan matrik citra aslinya.

$\{A_1, \dots, A_n\}$ adalah n matrik citra, dimana A_i ($i=1, \dots, k$) adalah $r \times c$ matrik. M_i ($i=1, \dots, k$) adalah rata-rata citra pelatihan dari kelas ke- i dan M adalah rata-rata citra dari semua data pelatihan. Menganggap $\ell_1 \times \ell_2$ ruang dimensi (*dimensional space*) $L \otimes R$, dimana \otimes menunjukkan *tensor product*, L menjangkau $\{u_1, \dots, u_{\ell_1}\}$ dan R menjangkau $\{v_1, \dots, v_{\ell_2}\}$.

Sehingga didefinisikan dua matrik $L = [u_1, \dots, u_{\ell_1}]$ dan $R = [v_1, \dots, v_{\ell_2}]$ [12].

Metode ekstraksi fitur adalah untuk menemukan L dan R sehingga ruang citra asli (*original image space*) A_i diubah ke dalam ruang citra dimensi rendah (*low-dimensional image*) menjadi $B_i = L^T A_i R$. Ruang dimensi rendah (*low-dimensional space*) diperoleh dengan transformasi linier L dan R , jarak *between-class* D_b dan jarak *within-class* D_w didefinisikan sebagai Persamaan (9) dan (10).

$$D_b = \sum_{i=1}^k n_i \|L^T (M_i - M) R\|_F^2, \quad (9)$$

$$D_w = \sum_{i=1}^k \sum_{x \in \Pi_i} \|L^T (X - M_i) R\|_F^2, \quad (10)$$

Dimana:

$$\| \cdot \|_F = \text{Frobenius norm.}$$

Meninjau bahwa $\|A\|_F^2 = \text{trace}(AA^T)$ adalah untuk matrik A sedemikian sehingga Persamaan (8) dan (9) dapat direpresentasikan lebih lanjut sebagai Persamaan (11) dan (12).

$$D_b = \text{trace} \left(\sum_{i=1}^k n_i L^T (M_i - M) R R^T (M_i - M)^T L \right) \quad (11)$$

$$D_w = \text{trace} \left(\sum_{i=1}^k \sum_{x \in \Pi_i} L^T (X - M_i) R R^T (X - M_i)^T L \right) \quad (12)$$

Sama halnya dengan *LDA*, *2D-LDA* adalah untuk menemukan matrik L dan R , sedemikian hingga struktur kelas dari ruang orisinal tetap didalam ruang proyeksi. Sehingga patokan (*criterion*) dapat didefinisikan sebagai Persamaan (13).

$$J_1(L, R) = \max \frac{D_b}{D_w} \quad (13)$$

Persamaan (11) terdiri dari matrik transformasi L dan R . Matrik transformasi optimal L dan R dapat diperoleh dengan memaksimalkan D_b dan meminimumkan D_w . Namun, sangatlah sulit untuk menghitung L dan R yang optimal secara simultan. Dua fungsi

optimasi dapat didefinisikan untuk memperoleh L dan R . Untuk sebuah R yang pasti, L dapat diperoleh dengan menyelesaikan fungsi optimasi sebagai Persamaan (14) yang berkaitan dengan Persamaan (15) dan (16).

$$J_2(L) = \max \text{trace}((L^T S_w^R L)^{-1} (L^T S_b^R L)) \quad (14)$$

$$S_w^R = \sum_{i=1}^k n_i (M_i - M) R R^T (M_i - M)^T \quad (15)$$

$$S_b^R = \sum_{i=1}^k \sum_{x \in \Pi_i} (X - M_i) R R^T (X - M_i)^T \quad (16)$$

Dengan catatan bahwa ukuran matrik S_w^R dan S_b^R adalah $r \times r$ yang lebih kecil daripada ukuran matrik S_w dan S_b pada *LDA* klasik.

Untuk sebuah L yang pasti, R dapat diperoleh dengan menyelesaikan fungsi optimasi pada Persamaan (17) yang berkaitan dengan Persamaan (18) dan (19).

$$J_3(R) = \max \text{trace}((R^T S_w^L R)^{-1} (R^T S_b^L R)) \quad (17)$$

$$S_b^L = \sum_{i=1}^k n_i (M_i - M)^T L L^T (M_i - M) \quad (18)$$

dan

$$S_w^L = \sum_{i=1}^k \sum_{x \in \Pi_i} (X - M_i)^T L L^T (X - M_i) \quad (19)$$

Ukuran matrik S_w^L dan S_b^L adalah $c \times c$ yang lebih kecil daripada ukuran matrik S_w dan S_b pada *LDA* klasik.

Secara khusus, untuk sebuah R yang pasti, L yang optimal dapat diperoleh dengan menyelesaikan *generalized eigenvalue problem* dari Persamaan (14). Demikian pula, R dapat diperoleh dengan menyelesaikan *generalized eigenvalue problem* dari Persamaan (17) pada L yang pasti.

PEAK SIGNAL TO NOISE RATIO (PSNR)

PSNR merupakan nilai perbandingan antara nilai maksimum *pixel* citra dengan *Mean Square Error (MSE)*. *MSE* merupakan nilai rata-rata error antara citra awal dengan citra hasil. Pada citra *8-bit*, nilai *pixel* maksimum adalah 255. Untuk *PSNR*, kriteria kualitas gambar akan semakin bagus jika hasil *PSNR* semakin besar. *PSNR* dinyatakan dalam satuan *decibel (dB)*. Secara matematis, *PSNR* dan

MSE dirumuskan dalam Persamaan (20) dan (21).

$$PSNR = 10 \log_{10} \left[\frac{255^2}{MSE} \right] dB \quad (20)$$

$$MSE = \frac{1}{MN} \sum_{x=1}^M \sum_{y=1}^N [I(x, y) - I'(x, y)]^2 \quad (21)$$

Dimana:

M,N = Lebar dan tinggi citra

I(x,y) = Nilai intensitas citra awal/asli pada posisi (x,y)

I'(x,y) = Nilai intensitas citra hasil pada posisi (x,y)

Nilai 255 = Nilai maksimum pixel

EUCLIDEAN DISTANCE

Setelah proses ekstraksi fitur dilakukan, selanjutnya dilakukan pengklasifikasian dengan menggunakan metode klasifikasi tetangga terdekatnya (*Euclidean Distance*). *Euclidean Distance* dengan menghitung jarak antara dua matrik fitur citra, citra A_j , dan citra A_i , sesuai dengan Persamaan (22).

$$B_i = \{Y_1^{(i)}, Y_2^{(i)}, \dots, Y_d^{(i)}\} \text{ dan}$$

$$B_j = \{Y_1^{(j)}, Y_2^{(j)}, \dots, Y_d^{(j)}\}$$

$$d(B_i, B_j) = \sum_{k=1}^d \|Y_k^{(i)} - Y_k^{(j)}\|_2 \quad (22)$$

$\|Y_k^{(i)} - Y_k^{(j)}\|_2$ merupakan jarak *Euclidean* antara dua vektor $Y_k^{(i)}$ dan $Y_k^{(j)}$. Maka, tiap fitur citra dari citra pelatihan adalah B_1, B_2, \dots, B_M dan setiap fitur citra pelatihan tersebut menandakan sebuah ciri dengan $\in w_k$. Sebagai contoh, pada *sample B*, jika $d(B, B_i) = \min d(B, B_j)$ dan $B \in w_k$, maka hasilnya adalah $B \in w_k$ [10].

PERANCANGAN SISTEM

Secara garis besar sistem terdiri dari dua bagian, yaitu proses pembelajaran citra dan proses pengujian seperti yang ditunjukkan Gambar 3. Pada proses pembelajaran, citra-citra wajah tersenyum adalah file-file wajah yang masing-masing berukuran 50×50 pixel *grayscale* yang diperoleh dari hasil modifikasi manual. Artinya, setelah file foto-foto wajah

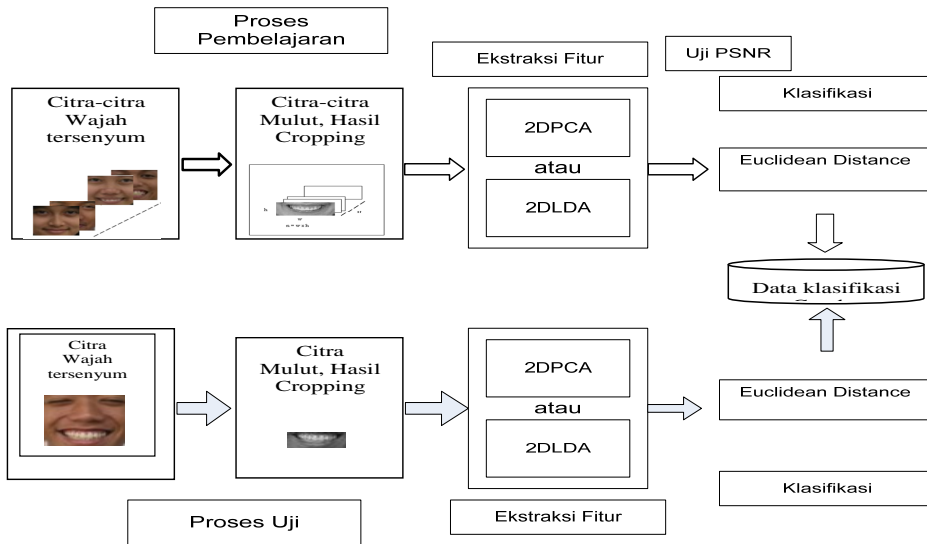
diperoleh, proses normalisasi seperti *cropping* alis mata hingga dagu dan *resize* untuk menyamakan dimensi gambar dilakukan secara manual. Saat program dieksekusi, *cropping* secara manual dilakukan terhadap sebuah data wajah tersenyum pada daerah mulut. Koordinat spasial yang dihasilkan proses *cropping* adalah [5.90816 34.0714 39.3877 15.1020] dengan ukuran gambar 40×16 pixel. Koordinat spasial digunakan sebagai acuan *cropping* secara otomatis terhadap semua data wajah lainnya. Gambar 4 menunjukkan hasil *cropping* terhadap data wajah. Gambar 5 menunjukkan hasil *cropping* secara otomatis terhadap seluruh data wajah tersenyum menggunakan koordinat spasial acuan pada Gambar 4.

Proses berikutnya adalah melakukan ekstraksi fitur dengan menggunakan metode *2D-PCA* dan *2D-LDA*. Pada metode *2D-PCA* dilakukan teknik proyeksi citra secara langsung. Matrik citra senyuman *2D* tidak perlu ditransformasikan ke dalam bentuk citra vektor seperti pada metode *PCA*, namun matrik kovarian citranya dapat dibentuk secara langsung dengan menggunakan matrik citra aslinya. Metode *2D-LDA* di sini digunakan untuk mendapatkan fitur-fitur yang terpilih dari masukan data-data pelatihan. Fitur-fitur yang terpilih nantinya digunakan untuk proses klasifikasi pelatihan dan digunakan untuk ekstraksi fitur data pengujian. Ekstraksi fitur pada proses pengujian, baik menggunakan metode *2D-PCA* maupun *2D-LDA*, dilakukan dengan mengambil hasil ekstraksi fitur pada proses pelatihan yang diterapkan pada data pengujian. Hasil ekstraksi fitur pada data pengujian digunakan sebagai masukan pada proses klasifikasi pengujian. Selanjutnya dilakukan proses klasifikasi yaitu menggunakan metode klasifikasi tetangga terdekatnya (*Euclidean Distance*) yang menghitung jarak antara dua matrik fitur citra.

Pada proses pengujian, data yang digunakan adalah data yang tidak pernah dilatih pada proses pelatihan. Sama halnya dengan proses pelatihan, data uji juga mengalami proses *cropping* pada daerah mulut dengan menggunakan data koordinat spasial hasil *cropping* pada saat proses pelatihan. Proses klasifikasi pengujian menggunakan hasil ekstraksi fitur data pengujian dan hasil proses klasifikasi pelatihan. Hasil dari proses ini berupa nilai indeks dari fungsi keputusan yang terbesar yang menyatakan kelas dari data

pengujian. Jika kelas yang dihasilkan dari proses klasifikasi pengujian sama dengan kelas data pengujian, maka pengenalan dinyatakan benar. Hasil akhir adalah berupa citra

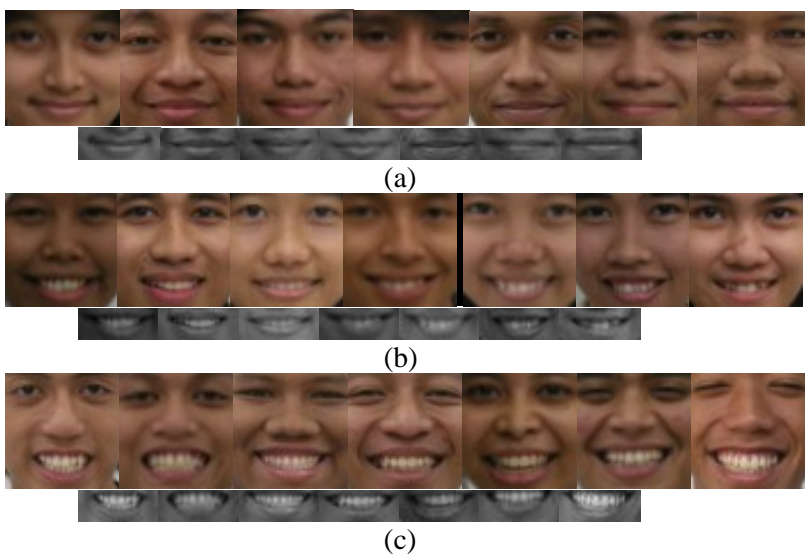
senyuman yang sesuai dengan nilai indeks dari fungsi keputusan yang terbesar pada proses klasifikasi pengujian.



Gambar 3. Blok Diagram Perancangan Sistem Pengenalan Citra Senyuman berdasarkan *Aesthetic Dentistry* dengan Menggunakan Metode *2D-PCA* dan *2D-LDA*.



Gambar 4. (a) Wajah Tersenyum Taraf IV yang Menjadi Acuan *Cropping* dan (b) Hasil *Cropping* secara Manual pada Area Mulut.



Gambar 5. Data Wajah Tersenyum dan Hasil *Cropping* Secara Otomatis Menggunakan Koordinat Spasial Acuan. (a) Taraf I, (b) Taraf III, dan (c) Taraf IV.

Rancangan Algoritma 2D-PCA

Langkah-langkah dalam proses 2D-LDA terhadap suatu basisdata citra pelatihan adalah sebagai berikut:

1. Jika dalam suatu basisdata citra senyuman terdapat himpunan sebanyak M citra pelatihan $A_j = [A_{j1}, A_{j2}, \dots, A_{jn}]$ ($j = 1, 2, \dots, M$) dengan dimensi citra ($m \times n$), maka himpunan total matrik dari semua citra tersebut adalah:

$$A_M = \begin{bmatrix} A_{(M)11} & A_{(M)12} & \dots & A_{(M)1n} \\ A_{(M)21} & A_{(M)22} & \dots & A_{(M)2n} \\ \dots & \dots & \dots & \dots \\ A_{(M)m1} & A_{(M)m2} & \dots & A_{(M)mn} \end{bmatrix}$$

2. Menghitung rata-rata dari total matrik himpunan pelatihan dengan Persamaan (23).

$$\bar{A} = \frac{AM}{M} \quad (23)$$

3. Menghitung selisih dari tiap citra A_j dengan Persamaan (24).

$$\bar{A} : A = A_j - \bar{A} \quad (24)$$

4. Menghitung matrik kovarian dari himpunan citra pelatihan A_j dengan menggunakan Persamaan (5).
5. Setelah didapatkan nilai proyeksi vektor (X_1, X_2, \dots, d) dari citra maka untuk ekstraksi fitur dari citra A dapat diperoleh dengan Persamaan (25).

$$Y_k = AX_k \quad (25)$$

k pada Persamaan (25) adalah = 1, 2, ..., d. Y_1, Y_2, \dots, Y_d disebut sebagai *principal component* dari 2D-PCA yang berupa vektor sedangkan pada PCA berupa skalar. $B = [Y_1, Y_2, \dots, Y_d]$ adalah matrik fitur atau *feature image* dari citra pelatihan.

6. Setelah ditransformasikan dengan 2D-PCA, hasil ekstraksi fitur diklasifikasikan dengan menggunakan metode klasifikasi tetangga terdekatnya. Pengklasifikasian dilakukan dengan menghitung jarak antara dua matrik fitur citra seperti pada Persamaan (22).

Rancangan Algoritma 2D-LDA

Langkah-langkah dalam proses 2D-LDA terhadap suatu basisdata citra pelatihan adalah sebagai berikut:

1. Jika dalam suatu basisdata citra senyuman terdapat himpunan sebanyak n citra

pelatihan $A_i = [A_{i1}, A_{i2}, \dots, A_{in}]$ ($i = 1, 2, \dots, n$) dengan dimensi citra ($r \times c$), maka himpunan total matrik dari semua citra tersebut adalah:

$$A_n = \begin{bmatrix} A_{(n)11} & A_{(n)12} & \dots & A_{(n)1c} \\ A_{(n)21} & A_{(n)22} & \dots & A_{(n)2c} \\ \dots & \dots & \dots & \dots \\ A_{(n)r1} & A_{(n)r2} & \dots & A_{(n)rc} \end{bmatrix}$$

2. Menentukan nilai ℓ_1 (dimensi proyeksi baris) dan ℓ_2 (dimensi proyeksi kolom). Nilai $\ell_1 \leq r$ dan $\ell_2 \leq c$.
3. Tahapan berikutnya adalah perhitungan rata-rata citra pelatihan dari kelas ke- i dengan menggunakan Persamaan (26).

$$M_i = \frac{1}{n_i} \sum_{X \in \Pi_i} X \quad (26)$$

4. Menghitung rata-rata semua citra pelatihan dengan menggunakan Persamaan (27).

$$M = \frac{1}{n} \sum_{i=1}^k \sum_{X \in \Pi_i} X \quad (27)$$

5. Menetapkan matrik transformasi R ukuran (c, ℓ_2) yang diperoleh dari gabungan antara matrik identitas ukuran (ℓ_2, ℓ_2) dengan matrik nol ukuran ($c - \ell_2, \ell_2$).
6. Menghitung matrik *between class scatter* R sesuai dengan Persamaan (15).
7. Menghitung matrik *within class scatter* R sesuai dengan Persamaan (16).
8. Menghitung *generalized eigenvalue* (λ_i) dari S^b dan S^w menggunakan SVD sesuai dengan Persamaan (14).
9. Mengambil sebanyak ℓ_1 *eigenvector* dari langkah 8 sebagai matrik transformasi baris (L). $L = [\phi_1^L, \dots, \phi_{\ell_1}^L]$, dengan ukuran matrik ($r \times \ell_1$).
10. Menghitung matrik *between class scatter* L sesuai dengan Persamaan (18).
11. Menghitung matrik *within class scatter* L sesuai dengan Persamaan (19).
12. Menghitung *generalized eigenvalue* (λ_i) dari S_b^L dan S_w^L menggunakan SVD sesuai dengan Persamaan (17).

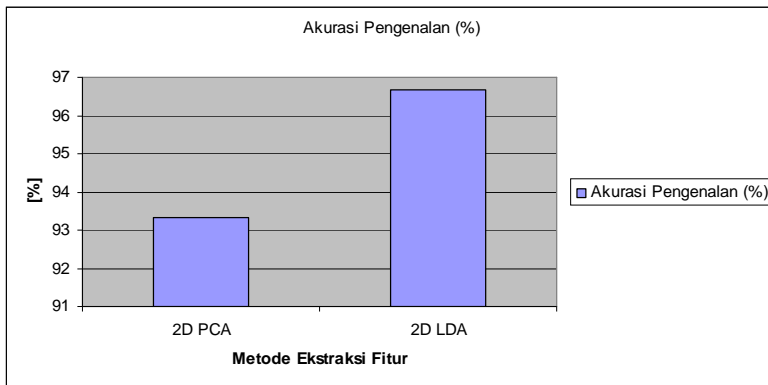
13. Mengambil sebanyak ℓ_2 *eigenvector* dari langkah 12 sebagai matrik transformasi kolom (R). $R = [\phi_1^R, \dots, \phi_{\ell_2}^R]$, ukuran matrik ($c \times \ell_2$).
14. Hitung matrik fitur ekstraksi $Bi=LTAiR$, dengan ukuran matrik ($\ell_1 \times \ell_2$)
15. Keluaran berupa matrik fitur ekstraksi Bi , matrik transformasi baris L , dan matrik transformasi kolom R .

HASIL DAN PEMBAHASAN

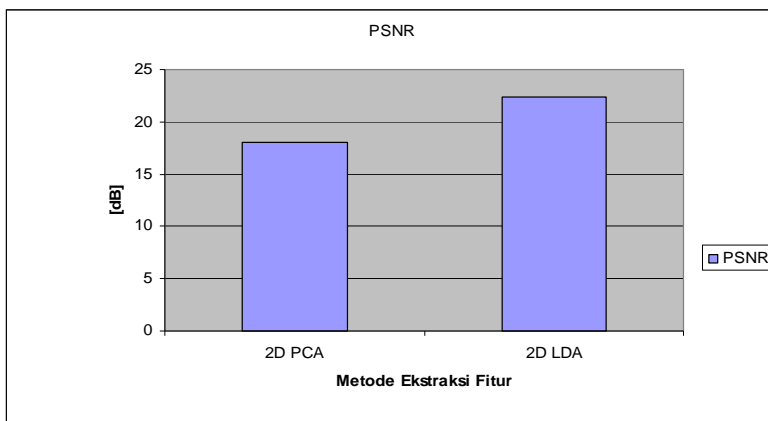
Uji coba terhadap sistem klasifikasi ini dilakukan pada 90 basisdata wajah tersenyum dengan ukuran 50×50 *pixel*. Setiap taraf senyuman terdiri dari 30 data yang sudah divalidasi oleh dokter gigi spesialis konservasi gigi. Subyek bervariasi terhadap jenis kelamin dan pencahayaan (*lighting*), sedangkan posisi wajah menghadap ke depan (*frontal face*).

Data pada setiap taraf senyuman dibagi menjadi tiga kelompok, dengan 2/3 data pertama (20) dijadikan data pelatihan dan 1/3 data terakhir (10) untuk data pengujian. Saat program dieksekusi, *cropping* secara manual dilakukan terhadap sebuah data wajah tersenyum pada daerah mulut. Koordinat spasial yang dihasilkan proses *cropping* adalah [5.90816 34.0714 39.3877 15.1020], dengan ukuran gambar 40×16 *pixel*. Koordinat ini digunakan sebagai acuan *cropping* secara otomatis terhadap semua data wajah lainnya.


Metode yang digunakan dalam pengujian ini ada dua kelompok. Kelompok pertama menggunakan metode *2D-PCA* untuk ekstraksi fitur sedangkan kelompok yang kedua menggunakan metode *2D-LDA*. Kedua kelompok tersebut menggunakan *Euclidean Distance* sebagai klasifikasi. Untuk lebih memudahkan melihat perbedaan hasil uji coba antara kedua metode tersebut, digunakan diagram batang seperti yang ditunjukkan pada Gambar 6 dan 7.




Gambar 6. Grafik Tingkat Akurasi Pengenalan terhadap Metode Ekstraksi Fitur (2D-PCA dan 2D-LDA).



Gambar 7. Grafik PSNR terhadap metode ekstraksi fitur (2D-PCA dan 2D-LDA).



Gambar 8. Ilustrasi *PSNR* pada *2D-PCA*. (a) Citra Asli, (b) Citra Rekonstruksi (*PSNR* = 18,07*dB* dengan $d = 30$), dan (c) Citra Rekonstruksi (*PSNR* = 15,75*dB* dengan $d = 25$)



Gambar 9. Ilustrasi *PSNR* pada *2D-LDA*. (a) citra asli, (b) citra rekonstruksi (*PSNR* = 22,36*dB* dengan $(p) = 16$ ($q) = 38$), (c) citra rekonstruksi (*PSNR* = 15,12*dB* dengan $(p) = 16$ ($q) = 36$).

Gambar 6 menunjukkan tingkat akurasi pengenalan *2D-PCA* lebih rendah (93,33 %) dibandingkan *2D-LDA* (96,67 %). Pada Gambar 7, *PSNR* untuk *2D-PCA* juga lebih rendah (18,07 *dB*) dibandingkan *2D-LDA* (22,36 *dB*). Hal tersebut terjadi karena pada *2D-PCA* lebih mementingkan pengoptimalan representasi data daripada pengoptimalan diskriminan data, sehingga data-data tidak terpisah dengan sempurna. *2D-LDA* memiliki kemampuan pengoptimalan diskriminan data yang sangat lebih dibanding dengan *2D-PCA*, sehingga dapat mengelompokkan vektor data dari kelas yang sama dan memisahkan kelas yang berbeda.

Ilustrasi *PSNR* pada *2D-PCA* ditunjukkan oleh Gambar 8. Ilustrasi ini adalah untuk citra asli (sebelum dilakukan proses ekstraksi fitur)

dengan citra rekonstruksi (setelah dilakukan proses ekstraksi fitur). Untuk citra rekonstruksi masing-masing menggunakan jumlah *eigen* yang diambil (d) 30 dan 25.

Gambar 9 menunjukkan ilustrasi *PSNR* pada *2D-LDA*. Untuk citra rekonstruksi masing-masing menggunakan *eigen* baris (p) = 16 kolom (q) = 38 dan baris (p) = 16 kolom (q) = 36.

SIMPULAN

Dari uji coba yang sudah dilakukan dapat diambil simpulan sebagai berikut:

1. Metode *2D-LDA-Euclidean Distance* mampu menunjukkan akurasi pengenalan yang optimal yaitu sebesar 96,67% dibandingkan dengan metode *2D-PCA Euclidean Distance* sebesar 93,33%. Hal ini dikarenakan *2D-LDA* mampu mengatasi *singular problem*, mampu mempertahankan keberadaan informasi diskriminatif, serta mampu memaksimalkan jarak antar kelas dan meminimalkan jarak inter kelas.
2. Untuk mengetahui kualitas citra yang dihasilkan maka dilakukan perhitungan *PSNR*. Hasil uji coba menunjukkan *PSNR* *2D-LDA* lebih tinggi sebesar 22,36 *dB* dibandingkan dengan *PSNR* *2D-PCA* sebesar 18,07 *dB*. Hal ini dikarenakan pada *2D-LDA* memperhitungkan perubahan baris dan kolom untuk matrik ekstraksi fiturnya. Sedangkan pada *2D-PCA* hanya memperhitungkan nilai *eigen*-nya saja. Semakin tinggi *PSNR* maka kualitas citra semakin bagus atau mendekati citra aslinya.

DAFTAR PUSTAKA

- [1] Edward P. The Classification of Smile Pattern. *J Can Dent Assoc.* 65:252-4. 1999.
- [2] Byrne PJ, Kim M, Boahene K, Millar J, and Moe K. Temporalis Tendon Transfer as Part of a Comprehensive Approach to Facial Reanimation. *Arch Facial Plastic Surgery.* 9: 234-241. 2007.
- [3] Daw and Lin T. Facial Expression Classification Using PCA and Hierarchical Radial Basis Function Network. *Journal Of Information Science And Engineering.* 22: 1033-1046. 2006.
- [4] Yambor and Wendy S. *Analysis of PCA-Based and Fisher Discriminant-Based Image Recognition Algorithms*. Thesis at Computer Science Department. Colorado: Colorado State University. 2000.
- [5] Turk MA and Pentland AP. Eigenfaces for Recognition. *J. Cognitive Neuroscience.* 3: 71-86. 1991.
- [6] Turk MA and Pentland AP. Face Recognition Using Eigenfaces. *IEEE*

- Transactions on Pattern Analysis and Machine Intelligence*. 586-591. 1991.
- [7] Belhumeur PN, Hespanha JP, and Kriegman DJ. Eigenfaces vs Fisherfaces Recognition Using Class Specific Linear Projection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 19: 711-720. 1997.
- [8] Kong H, Wang L, Teoh EK, Wang JG, and Venkateswarlu R. A Framework of 2D Fisher Discriminant Analysis: Application to Face Recognition With Small Number of Training Samples. *IEEE Conf. CVPR*. 215-220 2005.
- [9] Yang J, Zhang D, Frangi AF, and Yang JY. Two-Dimensional PCA: A new Approach to Appearance-Based Face Representation and Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 26: 131-137. 2004.
- [10] Gao Q, Zhang L, and Zhang D. Face Recognition Using FLDA With Single Training Image Per Person. *Applied Mathematics and Computation* 205: 726-734. 2008.
- [11] Cahyono GR, Purnomo MH, and Hariadi M. Smile Stages Classification Based on Aesthetic Dentistry Using Eigenfaces, Fisherfaces, and Multiclass SVM. *Proc. Biomedical Engineering*. 150-156. 2008.
- [12] Liang Z, Li Y, and Shi P. A Note on Two-Dimensional Linear Discriminant Analysis. *Pattern Recogn*. 29: 2122-2128. 2008.