

# FACE RECOGNITION MENGGUNAKAN METODE LINEAR DISCRIMINANT ANALYSIS (LDA)

Resmana Lim<sup>1</sup>, Raymond<sup>1</sup> & Kartika Gunadi<sup>2</sup>

1) Jurusan Teknik Elektro

2) Jurusan Teknik Informatika

Universitas Kristen Petra

Siwalankerto 121-131, Surabaya. Fax: 031-8436418

E-mail : {resmana; kgunadi}@petra.ac.id

## Abstrak

*Paper ini membahas sistem pengenalan image wajah dengan 2 metode ekstraksi feature statistik yaitu PCA (Principal Components Analysis) dan LDA (Linear Discriminant Analysis). Pemilihan metode ekstraksi feature yang tepat dan efisien sangat menentukan keberhasilan dari sistem pengenalan secara keseluruhan. Sistem dibangun menggunakan platform PC dengan penulisan program komputer menggunakan Delphi. Sistem diuji menggunakan berbagai image database yang diambil menggunakan kamera digital yang terdiri dari 12 orang dengan masing-masing 10 image. Sistem juga diuji menggunakan Yale faces database yang terdiri dari 14 orang dengan masing-masing 9 image. Metode pengenalan pola menggunakan nearest neighbor sederhana dan dihasilkan recognition rate antara 80-90% dengan berbagai variasi penambahan noise dan oklusi.*

*Kata kunci : face recognition, LDA, PCA, pengenalan pola.*

## 1. Pendahuluan

Sistem pengenalan wajah banyak dimanfaatkan pada biometrics yang digunakan untuk identifikasi personal pada penggunaan mesin absensi, akses kontrol dan lain-lain. Secara umum sistem pengenalan image tidak menggunakan bitmap pixel secara langsung melainkan ia bekerja pada domain feature. Image direpresentasikan kedalam bentuk feature yang lebih kompak yang kemudian digunakan untuk pengenalan, dengan demikian dapat menghemat komputasi. Berbagai metode ekstraksi feature telah dimanfaatkan seperti metode moment, feature filter Gabor, Wavelet, dan lain-lain [1]. Dalam paper ini akan digunakan 2 metode ekstraksi feature secara statistik yang secara luas telah lama digunakan yaitu PCA (Principal Components Analysis) [2] dan LDA (Linear Discriminant Analysis) [3].

Metode PCA dikenal juga dengan nama Karhunen-Loeve transformation (KLT), yang telah dikenal sejak 30 tahun dalam dunia pengenalan pola. PCA memberikan transformasi ortogonal yang disebut dengan 'eigenimage' yang mana sebuah image direpresentasikan kedalam bentuk proyeksi linier searah dengan eigenimage yang bersesuaian dengan nilai eigen terbesar dari matrix covariance (atau scatter matrix). Secara praktis matrix covariance ini dibangun dari sekumpulan image training yang diambil dari berbagai obyek/kelas.

PCA memberlakukan properti statistik yang sama bagi seluruh image training dari berbagai obyek/kelas. Tidak demikian halnya pada LDA, ia memberlakukan properti statistik yang terpisah untuk tiap-tiap obyek. Tujuan dari LDA adalah mencari proyeksi linier (yang biasa disebut dengan "discriminant image"), untuk memaksimalkan matrix covariance antar obyek (between-class covariance matrix) sementara itu juga meminimumkan matrix covariance didalam obyek itu sendiri (within-class covariance matrix). Bila tersedia image training yang cukup representatif dalam jumlah maupun variasi bentuk untuk tiap-tiap obyek maka metode ekstraksi LDA akan menunjukkan performa yang lebih baik dari pada PCA seperti yang ditunjukkan pada hasil-hasil percobaan dalam paper ini.

Berikutnya paper ini disusun sebagai berikut: pada pasal 2 dan 3 akan dijelaskan metode PCA dan LDA. Deskripsi sistem diberikan pada pasal 4 dan hasil-hasil percobaan diberikan pada pasal 5 dan ditutup dengan diskusi/kesimpulan pada pasal 6.

## 2. Principal Components Analysis (PCA)

Sebuah image 2D dengan dimensi  $b$  baris dan  $k$  kolom dapat direpresentasikan kedalam bentuk image 1D dengan dimensi  $n$  ( $n=b*k$ ). Dengan ekspresi lain dapat dituliskan sebagai  $\mathcal{R}^n$ , adalah ruang image dengan dimensi  $n$ . Image training yang digunakan sebanyak  $K$  sampel dinyatakan dengan  $\{x_1, x_2, \dots, x_K\}$  yang diambil dari sebanyak  $c$  obyek/kelas yang dinyatakan dengan  $\{X_1, X_2, \dots, X_c\}$ . Total matrix scatter  $S_T$  (atau matrix covariance) didefinisikan sebagai berikut:

$$S_T = \sum_{k=1}^K (x_k - \mu)(x_k - \mu)^T \quad (1)$$

dimana  $\mu$  adalah rata-rata sampel image yang diperoleh dengan merata-rata training image  $\{x_1, x_2, \dots, x_K\}$ . Dengan dekomposisi eigen, matrix covariance ini dapat didekomposisi menjadi:

$$S_T = \Phi \Lambda \Phi^T \quad (2)$$

dimana  $\Phi$  adalah matrix eigenvector, dan  $\Lambda$  adalah is a diagonal matrix dari nilai eigen. Kemudian dipilih sejumlah  $m$  kolom eigenvector dari matrix  $\Phi$  yang berasosiasi dengan sejumlah  $m$  nilai eigen terbesar. Pemilihan eigenvector ini menghasilkan matrix transformasi atau matrix proyeksi  $\Phi_m$ , yang mana terdiri dari  $m$  kolom eigenvector terpilih yang biasa disebut juga dengan 'eigenimage'. Berikutnya sebuah image  $x$  (berdimensi  $n$ ) dapat diekstraksi kedalam feature baru  $y$  (berdimensi  $m < n$ ) dengan memproyeksikan  $x$  searah dengan  $\Phi_m$  sebagai berikut:

$$y = \Phi_m x \quad (3)$$

Dengan kata lain metode PCA memproyeksikan ruang asal  $\mathcal{R}^n$  ke dalam ruang baru yang berdimensi lebih rendah  $\mathcal{R}^m$ , yang mana sebanyak mungkin kandungan informasi asal tetap dipertahankan untuk tidak terlalu banyak hilang setelah dibawa ke dimensi feature yang lebih kecil. Disini terlihat reduksi feature yang signifikan dari  $n$  buah menjadi  $m$  buah yang tentunya akan sangat meringankan komputasi dalam proses pengenalan berikutnya.

Total matrix scatter  $S_T$  diatas sesungguhnya adalah jumlahan dari matrix scatter dalam kelas (within-class scatter matrix)  $S_W$  dan matrix scatter antar kelas (between-class scatter matrix)  $S_B$  yaitu,  $S_T = S_W + S_B$ . Dengan demikian, kekurangan utama yang terlihat disini adalah bahwa dalam proses PCA ke dua matrix scatter ini termaksimalikan bersamasama. Sesungguhnya yang diinginkan adalah hanya maksimalisasi  $S_B$  saja, sedangkan  $S_W$  sebisa mungkin diminimalkan agar anggota didalam kelas lebih terkumpul penyebarannya yang pada akhirnya dapat meningkatkan keberhasilan pengenalan. Misalkan pada variasi perubahan iluminasi maupun skala dari image yang terjadi pada obyek yang sama, dapat menyebabkan matrix scatter dalam kelas menjadi besar yang cukup menyulitkan dalam proses pengenalan. Bila ini terjadi, dengan demikian PCA akan menyertakan variasi iluminasi didalam eigenimage-nya, dan konsekuensinya PCA menjadi tidak handal terhadap variasi iluminasi yang terjadi pada obyek. Dengan metode LDA,  $S_W$  akan diminimisasi sehingga ekstraksi feature yang dihasilkan menjadi lebih handal terhadap variasi yang terjadi didalam kelas.

## 3. Linear Discrimination Analysis (LDA)

Matrix scatter dalam kelas  $S_W$ , dan matrix scatter antar kelas  $S_B$  didefinisikan masing-masing sebagai berikut:

$$S_W = \sum_{i=1}^c \sum_{x_k \in X_i} (x_k - \mu_i)(x_k - \mu_i)^T \quad (4)$$

$$S_B = \sum_{i=1}^c N_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (5)$$

dimana  $N_i$  adalah jumlah sampel pada kelas  $X_i$ , dan  $\mu_i$  adalah image rata-rata dari kelas  $X_i$ . Seperti diutarakan sebelumnya bahwa sangat diharapkan agar matrix scatter dalam kelas  $S_W$  bisa diminimalisasi sementara matrix scatter antar kelas  $S_B$  dimaksimalkan. Dengan kata lain akan dicari matrix proyeksi  $\Psi$ , agar ratio persamaan (6) menjadi maksimal.

$$\frac{\det(\Psi S_B \Psi^T)}{\det(\Psi S_W \Psi^T)} \quad (6)$$

Kriteria ini menghasilkan solusi dengan persamaan sebagai berikut [3]:

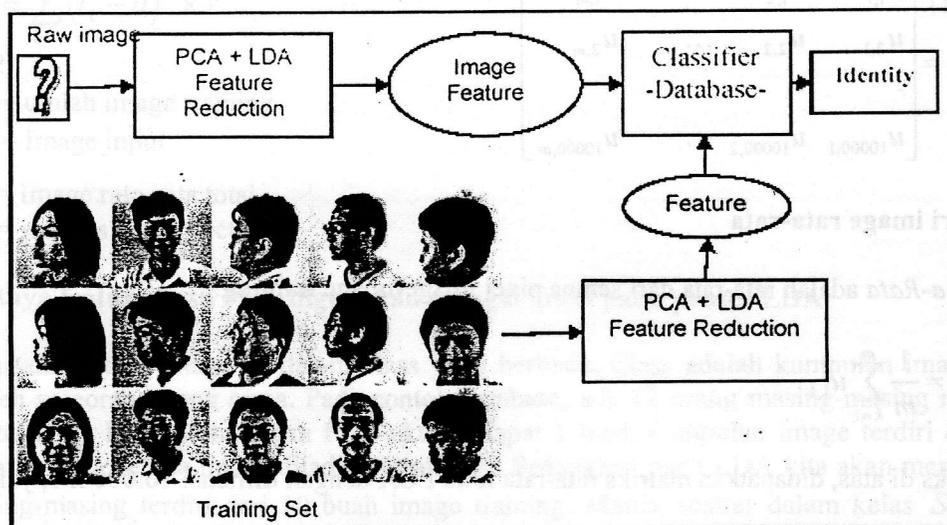
$$S_B \Psi = S_W \Psi \Lambda \quad (7)$$

dimana  $\Psi$  adalah matrix eigenvector, dan  $\Lambda$  adalah matrix diagonal nilai eigen. Dengan kata lain akan dicari eigenvector dan eigenvalue dari matrix C yang merupakan kombinasi within & beetwin scatter matrix seperti pada persamaan 8. Kembali dilakukan pemilihan sebanyak  $l$  kolom eigenvector dari  $\Psi$  yang berasosiasi dengan nilai-nilai eigen terbesar. Pemilihan  $l$  kolom eigenvector ini menghasilkan matrix proyeksi  $\Psi$ , yang selanjutnya digunakan untuk ekstraksi feature seperti halnya pada PCA.

$$C = S_b S_w^{-1} \quad (8)$$

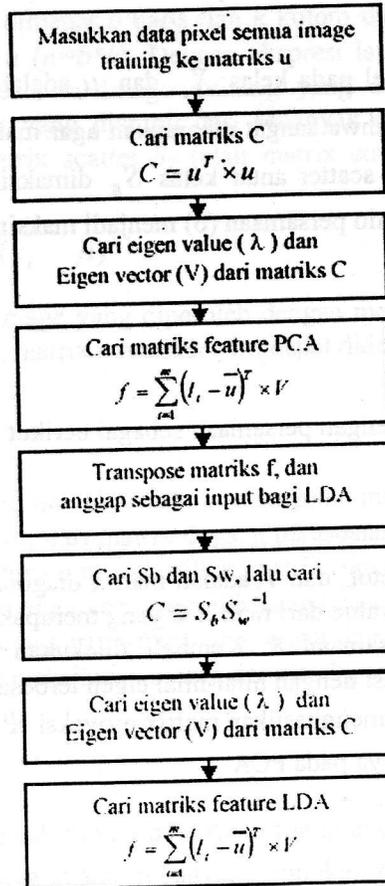
#### 4. Deskripsi Sistem

Blok diagram sistem pengenalan wajah dapat dilihat pada gambar 1, yang mana disini digunakan feature reduction menggunakan PCA yang dilanjutkan dengan LDA. Sebagian image digunakan sebagai training dataset untuk ditransformasi kedalam bentuk feature yang disimpan dalam database. Image input yang hendak dicari identitasnya ditransformasikan kedalam bentuk feature yang selanjutnya dengan classifier nearest neighbor akan dikenali identitasnya.



Gambar 1. Blok Diagram Sistem Pengenalan Wajah.

Ringkasan dari seluruh algoritma PCA + LDA adalah sebagai berikut :



Gambar 2. Ringkasan Ekstraksi Feature PCA + LDA

### 1. Masukkan data pixel image training ke dalam matriks u

Misalkan terdapat  $m$  image training dengan masing-masing berdimensi  $100 \times 100$  pixels = 10.000 pixels. Matriks yang merepresentasikan image-image tersebut berdimensi  $10.000 \times m$ , adalah :

$$u = \begin{bmatrix} u_{1,1} & u_{1,2} & \dots & u_{1,m} \\ u_{2,1} & u_{2,2} & \dots & u_{2,m} \\ \vdots & \vdots & \dots & \vdots \\ u_{10000,1} & u_{10000,2} & \dots & u_{10000,m} \end{bmatrix} \quad (9)$$

### 2. Mencari image rata-rata

*Image Rata-Rata* adalah rata-rata dari semua pixel image-image training.

$$\bar{u} = \frac{1}{m} \sum_{k=1}^m u_{1,k} \quad (10)$$

Dari matriks di atas, didapatkan matriks rata-rata total PCA dengan dimensi  $10.000 \times 1$ , yaitu:

$$\bar{u} = \begin{bmatrix} u_{1,1} \\ \cdot \\ \cdot \\ u_{10000,1} \end{bmatrix} \quad (11)$$

### 3. Mencari covariance matriks PCA

Matriks covariance PCA dapat dicari dengan rumus sebagai berikut :

$$C = u^T \times u \quad (12)$$

Matriks covariance dengan dimensi  $m \times m$ , dimana  $m$  adalah jumlah image training. Dengan dekomposisi eigen berlaku :

$$C \times v = \lambda \times v \quad (13)$$

Hitungi eigen value ( $\lambda$ ) dan eigen vector ( $V$ ) dari matriks  $C$  menggunakan metode Jacobi [5]. Eigen value dan eigen vector yang bersesuaian diurutkan secara descending . Eigen faces yang didapatkan ini dapat dilihat dalam ilustrasi di bawah ini :



Gambar 3. Dua belas Eigen faces Pertama.

Dalam eigen faces di atas dapat dilihat bahwa dapat dibedakan antara wajah yang menghadap ke depan, kanan, belakang. Eigen faces ini dapat dijadikan pembanding saat merecognize suatu image.

### 4. Mencari feature PCA

Eigen vector hasil proses pada langkah 3, beserta dengan image rata-rata digunakan untuk mentransformasikan raw image ke dalam ruang feature  $f$ . Selanjutnya feature  $f$  disimpan dalam database untuk kemudian digunakan pada proses pengenalan. Proyeksi raw input image ke ruang eigen dapat dihitung menggunakan rumus berikut:

$$f = \sum_{i=1}^m (I_i - \bar{u})^T \times V \quad (14)$$

$m$  = jumlah image training

$I_i$  = Image input

$\bar{u}$  = Image rata-rata total

$V$  = matriks eigen vector

### 5. Selanjutnya feature hasil PCA digunakan sebagai input pada proses LDA

LDA memisahkan tiap image ke dalam class yang berbeda. Class adalah kumpulan image yang dimiliki oleh seseorang yang sama. Pada contoh database, ada 12 orang masing-masing memiliki 10 image training. Pada perhitungan PCA akan didapat 1 buah kumpulan image terdiri dari 120 image training (jika semua image dijadikan training). Sedangkan pada LDA kita akan memiliki 12 class, masing-masing terdiri dari 10 buah image training. Matrix scatter dalam kelas  $S_w$ , dan matrix scatter antar kelas  $S_B$  dihitung dengan persamaan 4 dan 5 di atas. Dengan 2 informasi

matrix scatter ini maka dihitung covariance matrix C (persamaan 8) lantas dicari eigen value dan eigen vector dari matrix C tersebut. Selanjutnya eigen vector ini digunakan untuk transformasi feature PCA kedalam bentuk feature LDA.

## 6. Mencari feature LDA

Feature LDA dicari dengan rumusan yang sama dengan feature PCA sebagai berikut:

$$f_{LDA} = \sum_{i=1}^m (I_i - \bar{u}_{LDA})^T \times V_{LDA} \quad (15)$$

## PENGENALAN DENGAN NEAREST NEIGHBOR

Metode recognition yang digunakan disini adalah *nearest neighbour*. Metode ini menghitung distance minimum antara feature image test dan masing-masing feature image training. Distance dicari dengan menggunakan rumus.

$$d_e(a, b) = \sqrt{\sum_{i=1}^n (b_i - a_i)^2} \quad (16)$$

Variabel de adalah jarak antara feature a dan b dalam ruang dengan feature n dimensi, dalam ini n adalah jumlah *feature* yang diambil. Disini dipilih harga n dalam kisaran 10 s/d 70 dan kemudian diamati keberhasilannya.

## 5. Hasil-hasil Percobaan

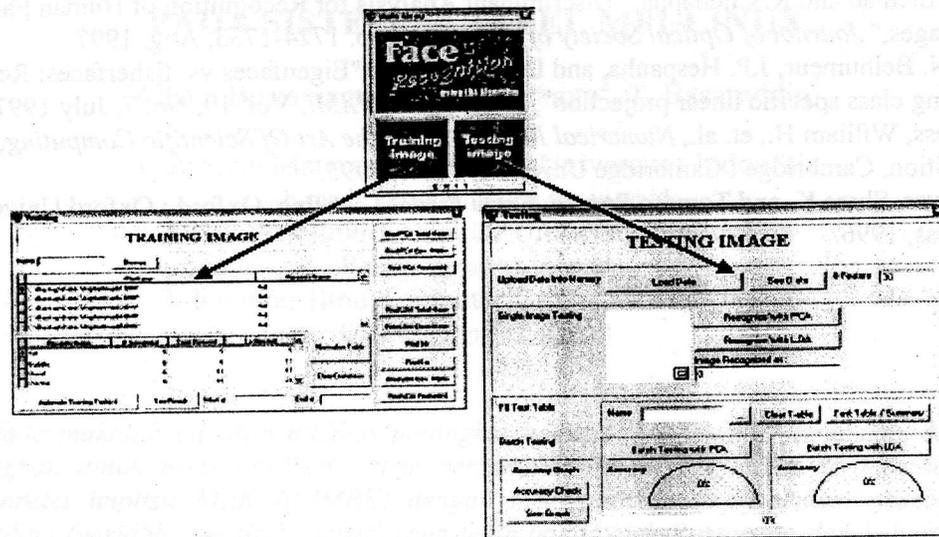
Sistem dibangun menggunakan platform PC dengan penulisan program komputer menggunakan Delphi. Sistem diuji menggunakan berbagai image database yang diambil menggunakan kamera digital yang terdiri dari 12 orang dengan masing-masing 10 image. Sistem juga diuji menggunakan Yale faces database yang terdiri dari 14 orang dengan masing-masing 9 image. Size image adalah 100x100 pixel. Jumlah feature hasil reduksi dicoba dalam range 10 sampai 70 buah. Metode pengenalan pola menggunakan nearest neighbor sederhana dan dihasilkan recognition rate antara 80-90% dengan berbagai variasi penambahan noise dan oklusi.

Tampilan program yang dibuat adalah seperti gambar 4, yang secara umum terdiri dari 2 modul yaitu modul training dan modul testing. Modul training menghasilkan parameter eigenvector dan image rata-rata baik untuk PCA maupun LDA.

Beberapa test yang telah dilakukan menunjukkan hasil *recognition rate* seperti bisa dilihat pada table berikut ini :

Tabel 1. Recognition Rate

Database		Recognition Rate	
		PCA Only	PCA + LDA
12 orang @ 10 image multipose	6 image training, 4 image test	48 %	48 %
	7 image training, 3 image test	68 %	68 %
	8 image training, 2 image test	73 %	78 %
	Image training bervariasi	58 %	69 %
Yale Faces, 14 orang @ 9 image multi expression	6 image training, 3 image test	95 %	90 %
	7 image training, 2 image test	96 %	100 %



Gambar 4. Screen Shot Tampilan Program.

Secara umum kombinasi PCA+LDA memberikan hasil yang lebih baik, bahkan dengan jumlah feature yang lebih sedikitpun. Pengujian dengan menggunakan tambahan *noise* tidak banyak berpengaruh pada *recognition rate* di atas. *Noise* dibuat dengan bantuan *Adobe Photoshop 7.0*, dalam hal ini menggunakan filter *add noise* dan *ripple distortion*.



Gambar 5. Penambahan Noise pada Test Image.

## 6. Kesimpulan

Dari hasil percobaan ternyata secara umum bila variasi image training cukup tinggi (misalnya: iluminasi dan ekspresi) maka penggunaan PCA+LDA akan memberikan kontribusi yang tinggi. Bahkan dengan jumlah feature yang sedikit PCA+LDA memberikan hasil yang lebih baik bila dibandingkan dengan penggunaan PCA saja. Pengambilan jumlah *feature* yang dihitung harus dipertimbangkan. Bila terlalu sedikit atau terlalu banyak akan menurunkan *recognition percentage*. Jumlah *feature* yang benar-benar optimal bisa didapatkan dengan melakukan eksperimen berulang-ulang. Dari eksperimen yang telah dilakukan, jumlah *feature* yang optimal berada di antara 30 – 60 untuk database dengan 12 orang, masing-masing 8 image training, dengan *recognition rate* maksimum 78 %, dan antara 50 – 70 untuk *Yale Faces Database*, masing-masing 7 image training, dengan *recognition rate* maksimum 100 %.

Metode pengenalan pola perlu dikembangkan lebih lanjut misalnya menggunakan neural networks atau metode-metode statistik lainnya seperti support vector machine misalnya.

## 7. Daftar Pustaka

- [1] R. Chellappa, C. Wilson, and S. Sirohey, "Human and machine recognition: A survey," *Proceedings of the IEEE*, vol. 83, no. 5, pp. 705–740, 1995.
- [2] M. Turk and A. Pentland, "Eigenfaces for recognition." *Journal of Cognitive Neuroscience*, Vol. 3, pp. 71-86, 1991.

- [3] K. Etemad and R. Chellappa, "Discriminant Analysis for Recognition of Human Face Images," *Journal of Optical Society of America A*, pp. 1724-1733, Aug. 1997.
- [4] P.N. Belhumeur, J.P. Hespanha, and D.J. Kriegman, "Eigenfaces vs. fisherfaces: Recognition using class specific linear projection", *IEEE Trans. PAMI*, Vol. 19, No. 7, July 1997.
- [5] Press, William H., et. al., *Numerical Recipes In C, The Art Of Scientific Computing*, Second Edition, Cambridge : Cambridge University Press, 1995.
- [6] Nayar, Shree K. and Tomaso Poggio, *Early Visual Learning*. Oxford : Oxford University Press, 1996.



5. Hasil-hasil Percobaan

... (The text in this section is extremely faint and mostly illegible. It appears to describe the results of experiments, possibly comparing different methods like PCA and Fisherfaces. It mentions terms like 'akurasi' (accuracy) and 'waktu' (time).)

Metode	Waktu (s)	Akurasi (%)
PCA	...	...
Fisherfaces	...	...

Wilson, C. Wilson, and S. Brody, "Human and machine recognition: A survey," *Journal of the IEEE*, vol. 83, no. 2, pp. 702-740, 1997.

Belhumeur, P.N., Hespanha, J.P., and Kriegman, D.J., "Eigenfaces vs. fisherfaces: Recognition using class specific linear projection," *Journal of Cognitive Neuroscience*, vol. 10, pp. 1-41, 1998.