

PENGARUH EKSPRESI WAJAH TERHADAP KEBERHASILAN KLASIFIKASI GENDER BERBASIS PCA-LDA

Agus Setia Budi N.⁽¹⁾

⁽¹⁾ Staf Pengajar Jurusan Teknik Elektro Politeknik Negeri Banjarmasin

Ringkasan

Disadari atau tidak, kemampuan visual manusia (human visual system) mampu mengidentifikasi seseorang dengan mengenali wajah dan memutuskan gender seseorang hanya dari data wajah. Computer Vision System memegang peranan sangat penting dalam Human Computer Interaction Technology (HCI) yang meliputi deteksi wajah, penjejakan wajah / badan, deteksi aksi (gesture), estimasi umur, etnik dan gender. Beberapa penelitian telah dilakukan untuk mencari metode terbaik dengan objek data wajah utuh dan tunggal untuk mencari metode diskriminasi yang terbaik sehingga dapat membedakan apakah seseorang tersebut pria atau wanita.

Banyak penelitian-penelitian telah dilakukan untuk mendeteksi gender pada wajah tunggal dengan berbagai metode, diantaranya adalah metode eigenface atau Principal Component Analysis (PCA) dan metode Fisherface atau Linear Discriminant Analysis (LDA).

Selain itu telah banyak pula penelitian tentang pendeteksian ekspresi wajah. Eigenface digunakan untuk mengekstraksi fitur, mereduksi dimensi, melakukan proyeksi ke dimensi yang lebih rendah dan metode Fisherface memperjauh jarak between matrik serta memperdekat jarak within matrik agar jarak antara kedua gender semakin jauh. Metode terakhir adalah klasifikasi dengan metode-metode linear classifier dengan jarak ketetanggaan terdekat, atau machine learning seperti RBF..

Penelitian ini mencoba memberikan kontribusi tentang pengaruh ekspresi wajah terhadap keberhasilan deteksi gender yang meliputi ekspresi normal, tersenyum dan sedih.

Kata Kunci : *deteksi gender, ekspresi wajah, eigenface, fisherface, between matrix, within matrix*

1. PENDAHULUAN

Computer Vision System memegang peranan penting dalam Human Computer Interaction Technology (HCI) yang meliputi deteksi wajah, penjejakan wajah/badan, deteksi aksi (gesture), estimasi umur, etnik dan yang fundamental adalah gender.

Sistem deteksi dan identifikasi wajah dapat dipergunakan dalam banyak hal, seperti yang berhubungan dengan kehidupan sosial, keamanan dan lainnya. Hal ini dikarenakan deteksi wajah lebih sulit untuk ditembus. Lebih dari itu, setelah proses deteksi[4] dan identifikasi wajah[7], dapat pula dilakukan proses lain seperti deteksi ekspresi dan deteksi gender [2][6].

Klasifikasi gender adalah salah satu bidang penelitian yang penting karena dapat meningkatkan keberhasilan sistem verifikasi wajah, bahkan sistem deteksi wajah. Meskipun tidak banyak mendapatkan perhatian dari para peneliti, klasifikasi gender berdasar wajah dapat dipergunakan untuk aplikasi keamanan atau mengetahui statistik jumlah orang yang melewati suatu area berdasarkan gender tertentu[2].

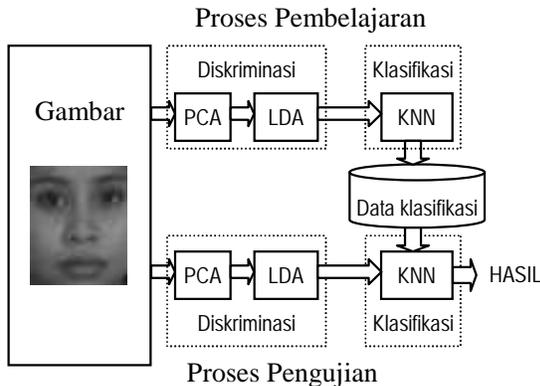
Penelitian pada deteksi wajah yang telah banyak dilakukan adalah untuk mendeteksi wajah pada sebuah gambar (image)[4][5][6][7][9]. Dan pada penelitian deteksi gender yang dilakukan hanya pada wajah tunggal untuk sebuah gambar. Penelitian kali ini akan melihat seberapa jauh kemampuan komputer dan algoritma yang digunakan untuk mendeteksi jumlah gender tertentu pada sebuah bidang gambar yang terdapat wajah didalamnya.

Penelitian Baback Moghaddam[2] menggunakan thumbnail face (21x12) pixel yang hanya selisih 1% terhadap (84x84) pixel. Dengan 1.755 image dari database FERET, performa SVM menghasilkan error rata-rata 3.4% yang menunjukkan kondisi yang lebih baik daripada klasifikasi tradisional. Area wajah yang diambil adalah seluruh wajah dengan melakukan pemotongan area berbentuk oval. Seluruh data telah dinormalisasi agar memiliki bentuk geometrik dan pencahayaan yang sama.

Batasan pada penelitian ini dilakukan untuk mempertajam proses deteksi gender dengan eigenfaces (PCA), fisherfaces (FLD) dan RBF network.

2. DESAIN SISTEM

Secara umum, desain sistem klasifikasi gender pada citra wajah yang akan dilakukan adalah sebagai berikut :



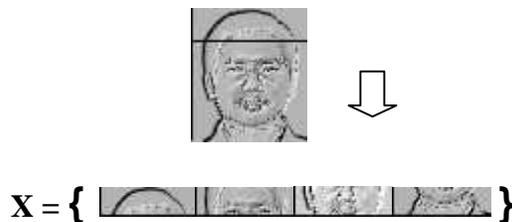
Gambar 1. Desain sistem deteksi wajah

Ekstraksi Ciri Wajah

a. Vector dan ruang wajah

Citra wajah berada pada sebuah ruang yang disebut bidang gambar / ruang lingkup citra (image space). Sebuah citra tersusun atas pixel-pixel yang masing-masing pixel memiliki nilai. Untuk citra abu-abu, sebuah pixel memiliki nilai dari 0 - 255.

Sebuah citra wajah yang berukuran lebar dan tinggi ($l \times t = n$), maka dalam proses pengolahan citra dimensi tersebut diubah menjadi sebuah VECTOR kolom wajah ($n \times 1$) seperti gambar 2., dengan n menyatakan dimensi yang digunakan. Untuk mempermudah penulisan, bisa dituliskan mendatar namun di transpose seperti pada gambar 2.



Gambar 2. Representasi citra wajah pada sebuah vektor.

b. PCA

Principal Component Analysis atau *Karhunen-Loeve expansion* adalah salah satu metode statistik yang digunakan untuk mencari faktor-faktor dominan pada suatu sebaran data. Pada proses pengolahan citra, PCA adalah metode yang umum digunakan untuk mengurangi dimensi, sekaligus menghasilkan matrik yang orthogonal yang bertujuan untuk mengurangi

dimensi sekaligus mempercepat proses komputasi dan juga mempertahankan nilai random (varian) pada dimensi tinggi sebanyak mungkin.

Penelitian M.Turk dan A.Pentland [5] menjelaskan pengenalan wajah menggunakan PCA dengan hasil berupa eigenvector dan eigenvalue. Karena bidang proyeksi wajah yang dihasilkan PCA adalah vektor yang dihasilkan dari covariance matrik terhadap image wajah asal yang diproyeksikan dengan PCA dan representasinya memiliki kesamaan terhadap seluruh image, maka dinamakan "eigenfaces".

Wendy [10] menggunakan istilah eigenspace projection pada proses PCA. Karena pada proses PCA terjadi proses transformasi / perpindahan secara linear data dari dimensi tinggi (n) ke dimensi yang lebih rendah (m). Pada proses PCA, ada dua metode yang dapat digunakan, yaitu high resolution image atau snapshot dan metode asli (original).

Secara umum, nilai $n > N$, dengan N adalah jumlah citra wajah yang digunakan (objek data). Metode original menggunakan matrix kovarian berdimensi $n \times n$. Sehingga dimensi yang dihasilkan sangat besar. Sedangkan metode snapshot menggunakan matrik kovarian $N \times N$ yang memiliki dimensi lebih kecil. Dengan dimensi yang kecil, maka proses komputasi menjadi lebih mudah.

Eigenspace dapat dihitung bila nilai eigenvector/ eigenvalue dari nilai covariance matrik data telah diperoleh. Nilai eigenvector yang diambil adalah yang bernilai bukan nol dari kovarian matrik orthonormal basis pada dimensi awal (n).

Bila jumlah data yang digunakan adalah I , maka data matrik x adalah seperti pada persamaan (1).

$$x^i = [x_1^i \quad \dots \quad x_n^i]^T \quad (1)$$

Berikutnya dilakukan proses *mean centered*, yaitu proses pengurangan nilai t vektor terhadap rata-rata seluruh image

$$\bar{x}^i = x^i - m, \text{ dengan } m = \frac{1}{N} \sum_{i=1}^N x^i \quad (2)$$

Vector ini kemudian dikombinasikan, sehingga menghasilkan sebuah matrik dengan ukuran $n \times N$,

$$\bar{X} = [\bar{x}^1 \mid \bar{x}^2 \mid \dots \mid \bar{x}^N] \quad (3)$$

Data matrix X kemudian dikalikan dengan transposnya sendiri untuk menghasilkan nilai kovarian.

$$\Omega = \bar{X} \bar{X}^T \quad (4)$$

Hasilnya adalah sebuah kovarian matrik yang dapat memiliki eigenvector hingga seba-

nyak N dengan nilai eigenvalue yang diambil bukan nol (metode snapshot). Eigenvector yang dihasilkan diurutkan dari nilai terbesar ke kecil, sesuai dengan nilai pada eigenvaluenya. Dengan demikian, eigenvector dengan nilai eigenvalue terbesar adalah yang memiliki varian terbesar pada seluruh citra. Eigenvector berikutnya memiliki varian terbaik kedua dan seterusnya.

Secara umum, teori aljabar menyatakan bahwa $\bar{X}\bar{X}^T$ memiliki eigenvector yang sama dengan $\bar{X}^T\bar{X}$ dikalikan dengan \bar{X} dan dinormalisasi [10]. Sehingga eigenspace yang dihasilkan akan berdimensi ($N \times N$), jauh lebih kecil daripada ($n \times n$).

c. FLD

LDA atau bisa disebut *Fisher Linear Discriminant (FLD)* adalah sebuah metode yang mengelompokkan/mendekatkan citra dalam satu kelas (*within class scatter*) dan memisahkan sejauh mungkin jarak antar kelas (*between class scatter*). Serupa dengan PCA, LDA juga melakukan proyeksi image dari dimensi n, menjadi C-1 kelas. (n, banyaknya pixel tiap citra, C adalah jumlah kelas).

Ada 2 metode FLD, original dan orthonormal basis method. Dengan menggunakan metode original fisherfaces, memunculkan beberapa permasalahan baru. Pertama, matrik yang digunakan untuk proses komputasi sangat besar. Hal ini mengakibatkan waktu yang digunakan untuk proses komputasi menjadi sangat besar. Kedua, karena jumlah data training sangat kecil dibandingkan dengan jumlah pixel per citra, rangking data matrik menjadi tidak cukup. Untuk bisa mendapatkan eigenvector dan eigenvalue dari matrik yang rangkingnya tidak cukup, bisa menggunakan *generalize singe value decomposition*, tapi masih ada cara yang lebih mudah. Yaitu metode orthonormal basis dengan melakukan proyeksi matrik data training ke basis ortonormal ke $N \times N$ (dengan N adalah jumlah data training). Proyeksi ini menghasilkan data matrik yang memiliki rangking secara penuh. Sekaligus menghasilkan proses komputasi yang jauh lebih cepat. Proyeksi juga menjaga informasi sehingga hasil akhirnya dari fisher tidak akan berpengaruh.

Berikut ini langkah-langkah untuk mencari fisherfaces dengan metode basis orthonormal.

1. Hitung rata-rata. Hitunglah nilai rata-rata tiap kelas (m_i) dan rata-rata seluruh kelas (m).
2. Buat image dalam kelas memiliki rata-rata nol. Dengan kata lain, buat *centered image* tiap kelas.

$$\forall x \in X_i, X_i \in X, \hat{x} = x - m \tag{5}$$

3. *Center the class mean*. Kurangkan total rata-rata dengan rata-rata kelas.

$$\hat{m} = m_i - m \tag{6}$$

4. Buat data matrik. Gabungkan semua image, satu satu hingga menjadi matrik.
5. Cari basis orthonormal untuk data matrik ini. Hal ini bisa dilakukan dengan menggunakan QR (orthonormal – triangular decomposition) atau dengan menghitung full set dari eigenvector dari kovarian matrik data training. Asumsikan basis orthonormal adalah U.
6. Proyeksikan semua *centered image* ke basis orthonormal. Buatlah vector yang merupakan hasil dot product dari image dan vector pada basis orthonormal.

$$\tilde{x} = U^T \hat{x} \tag{7}$$

7. Proyeksikan *centered mean* ke basis orthonormal.

$$\tilde{m}_i = U^T \hat{m}_i \tag{8}$$

8. Hitung *within class scatter matrix*. *Within class scatter matrix* menghitung jumlah dari scatter between yang ada pada kelas yang sama. Untuk kelas ke i, scatter matrik (S_i) dihitung dengan menjumlahkan semua kovarian matrik yang telah diproyeksikan tiap kelas.

$$S_i = \sum_{x \in X_i} \tilde{X} \tilde{X}^T \tag{9}$$

9. Within scatter matrix (S_W) adalah jumlah dari seluruh scatter matrik.

$$S_W = \sum_{i=1}^C S_i \tag{10}$$

10. Dengan C adalah jumlah kelas.
11. Hitung *between class scatter matrix*. *Between class scatter matrix* (S_B) menghitung jumlah jarak antar kelas. Dihitung dengan menjumlahkan semua data *centered mean* kovarian matrik yang telah diproyeksikan.

$$S_B = \sum_{i=1}^C n_i \tilde{m}_i \tilde{m}_i^T \tag{11}$$

12. Dengan n_i adalah jumlah image tiap kelas
13. Selesaikan persamaan untuk mencari eigenvalue. Yaitu mencari nilai eigenvector (V) dan eigenvalue (Λ).

$$S_B V = \Lambda S_W V \tag{12}$$

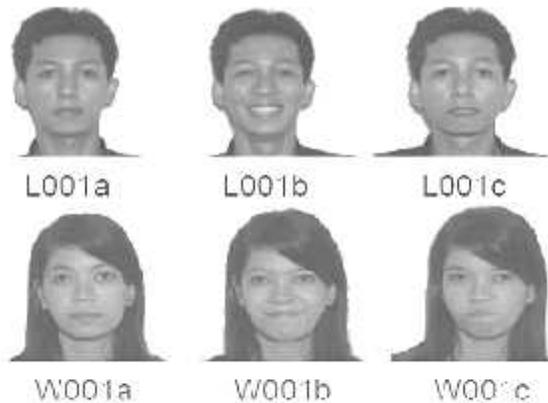
14. Ambilah C-1 eigenvector pertama. Urutkan eigenvector sesuai dengan urutan nilai yang ada pada eigenvalue dari besar ke kecil. Vector ini disebut *Fisher Basis Vector*.
15. Proyeksikan citra asal ke Fisher Basis Vector. Proyeksikan seluruh citra asal (bukan *centered image*) ke fisher basis vector dengan menghitung dot product dari image asal ke tiap-tiap *fisher basis vector*.

3. HASIL PENGUJIAN

Data dan Metode Pengujian

Data pengujian adalah data statis, yaitu data citra wajah yang sudah diambil dengan menggunakan kamera digital, kemudian di modifikasi untuk didapatkan image yang diinginkan. Ukuran yang digunakan adalah 150x150 pixel dengan mode warna abu-abu(grayscale). Jumlah citra yang digunakan sebanyak 120 buah dengan perbandingan seimbang. 20 pria dan 20 wanita. Masing-masing di ambil image dengan 3 pose: normal, tersenyum dan merenggut.

Sebagian contoh citra wajah dapat dilihat pada gambar 4. Citra tersebut diambil dari data-data wajah mahasiswa baru yang diambil secara acak dengan pose yang sudah di samakan / sinkronisasi. Namun variasi pencahayaan dan background dibiarkan apa adanya. Area yang diambil adalah berbentuk kotak dari alis hingga dagu.



Gambar 3. Contoh citra wajah yang digunakan dengan masing-masing 3 pose. Normal, tersenyum dan merenggut. Baris atas pria, dan bawah wanita.

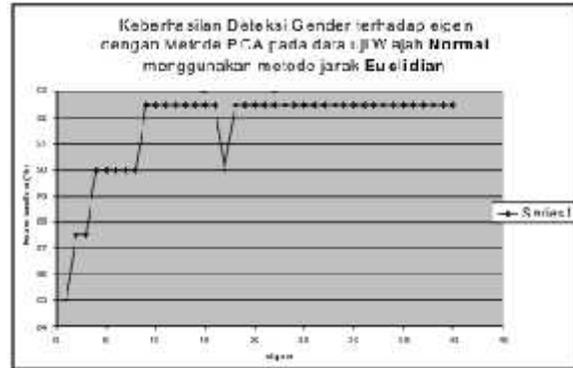
Pengujian PCA

Dengan menggunakan metode Snapshot eigenfaces, digunakan 96 data training dan 24 data uji. Setelah data training diproyeksikan ke eigenspace, masing-masing data uji akan dicari jarak terdekat ke kelompok proyeksi data training pria atau wanita dengan menggunakan jarak euclidian distance. Variabel yang muncul pada metode snapshot eigenspace adalah nilai jumlah eigenvector yang dipakai. Dalam hal ini akan dipilih nilai eigenspace yang paling baik untuk mewakili uji eigenspace.

Pengujian FLD

Dengan menggunakan data yang sama dengan PCA, dipilih 4 kelas pada proses fisherfaces. Seluruh data training di proyeksikan ke fisherspace dan data uji dibandingkan dengan Euclidian ke kelompok pria atau wanita untuk

menentukan jarak terdekat. Output proyeksi data training dan data uji dari fisherfaces ini digunakan untuk menghitung hasil akhir keberhasilan deteksi gender.



Gambar 4. Grafik keberhasilan deteksi gender dengan jarak EUCLIDIAN

Tabel 1. keberhasilan deteksi gender dengan PCA

Percobaan	pose	Jarak	Hasil Deteksi (%)			Eigen
			Min	Max	Rata2x	
1	normal	absolut	85.00	95.00	93.25	18
2	tersenyum	absolut	82.50	90.00	88.00	6
3	Merenggut	absolut	75.00	92.50	84.75	18
4	normal	euclidian	85.00	92.50	91.69	9
5	tersenyum	euclidian	82.50	87.50	87.00	6
6	Merenggut	euclidian	75.00	82.50	78.13	6

Tabel 2 Tabel keberhasilan sistem dengan menggunakan LDA

Metode LDA Absolut

	Tingkat keberhasilan					
	Pose					
	nor mal	%	senyum	%	merenggut	%
Pria	4	100.00	4	100.00	3	75.00
Wanita	3	75.00	2	50.00	3	75.00
Total	7	87.50	6	75.00	6	75.00

Rata-rata keberhasilan LDA absolut total 19 (79,17 %)

Metode LDA Euclidian

	Tingkat keberhasilan					
	Pose					
	nor mal	%	senyum	%	merenggut	%
Pria	4	100.00	4	100.00	4	100
Wanita	3	75.00	2	50.00	3	75.00
Total	7	87.50	6	75.00	7	87.50

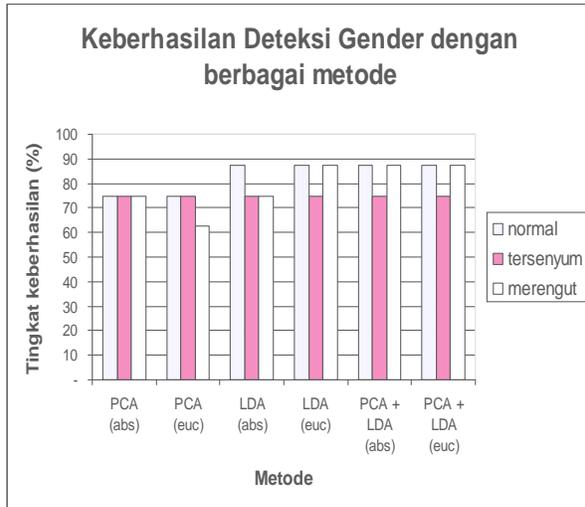
Rata-rata keberhasilan LDA absolut total 20 (83,33 %)

Hasil Keseluruhan

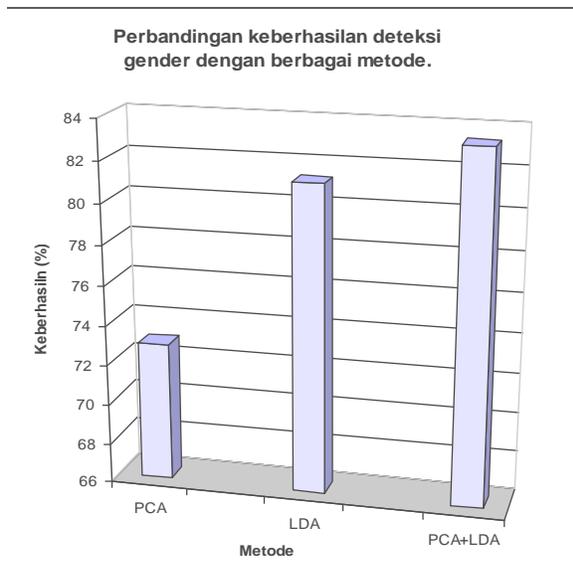
Percobaan ini dilakukan dengan menggunakan bantuan software MATLAB 7.1 untuk melaku-kan analisa matematika, statistik, image processing pre dan after process, serta Microsoft

excel untuk menampilkan hasil perhitungan dalam bentuk grafik.

Dari kedua metode yang digunakan, eigenfaces (PCA), fisherfaces (FLD), dan gabungan keduanya, diperoleh hasil seperti tampak seperti pada gambar 5 dan 6.



Gambar 5. Grafik hasil deteksi gender ketiga percobaan detail dengan 3 pose



Gambar 6. Grafik hasil deteksi gender secara umum.

4. KESIMPULAN

Dari hasil uji coba penelitian ini dapat diperoleh beberapa kesimpulan antara lain:

- PCA (Principal Component Analysis) dapat dipergunakan untuk mendeteksi gender dengan berbagai pose ekspresi dengan tingkat keberhasilan 72,92%.

- Metode Linear Diskriminant Analysis (LDA) dapat mendeteksi gender lebih baik, yaitu sebesar 81,25%.
- Gabungan kedua metode, PCA dan LDA memberikan hasil yang terbaik dengan tingkat keberhasilan 83,33%.
- Meski data wajah hanya dari alis hingga dagu dengan variasi cahaya tidak disinkronisasi, sistem dapat digunakan untuk deteksi gender.

5. DAFTAR PUSTAKA

1. Am. M. Burton,, V. Bruce, N. Dench. *What's the difference between men and women? Evidence from facial measurement.* Perception, 22:153–176, (1993)
2. Baback, Moghaddam and M. Yang. "Learning Gender With Support Face" IEEE transaction on Pattern Recognition and Machine Intelligence Vol 24 No.5 May 2002, (2002)
3. Christopher, j.c. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition", Data mining and knowledge dicoverly, vol 2 no 2, (1998)
4. Eru, Puspita, "Sistem Pendeteksian Dan Penjejukan Wajah Secara Real-Time", Tesis pada Fakultas Teknologi Informasi - Institut Teknologi Sepuluh Nopember Surabaya, (2004)
5. M.Turk and A.Pentland, "Face Recognition Using Eigenfaces", Journal of Cognitive Neuroscience, (1991)
6. Riyanto, Sigit, "Sistem Pengenalan Ekspresi Wajah Secara Real Time", Tesis pada Fakultas Teknologi Informasi - Institut Teknologi Sepuluh Nopember Surabaya, (2005).
7. Rully, Soelaiman. "Sistem Pengenalan Wajah Dengan Penerapan Algoritma Genetika Pada Optimasi Basis Eigenface Dan Proyeksi Fisherface". Tesis pada Fakultas Ilmu Komputer-Universitas Indonesia, (2003).
8. R. Duda, P. Hart, and D. Stork "Pattern Classification", John-Wiley, 2nd edition, (2001).
9. Viola, Paul; Jones, Michael J., "Robust real-time Object Detection", Proceeding of IEEE Workshop on Statistical and Computational Theories of Vision, (2001).
10. Wendy, S. Yambor, "Analysis of pca-based and fisher Discriminant-based image recognition Algorithms" Thesis at Computer science department - Colorado State University, (2000).