

Simulasi Ekstraksi Citra Wajah dengan Deskriptor Global *Direct Fractional-Step Linear Discriminant Analysis* (DF-LDA) untuk Pengenalan Wajah

Ikuthen Gabriel Barus¹, Riko Arlando Saragih²

Jurusan Teknik Elektro,
Fakultas Teknik,
Universitas Kristen Maranatha, Bandung
¹sibayakjamburlige@ymail.com, ²riko_saragih@yahoo.com

Ringkasan

Tulisan ini memaparkan simulasi ekstraksi citra wajah secara global dengan menggunakan salah satu teknik *Linear Discriminant Analysis* (LDA), yaitu *Direct Fractional-Step LDA* (DF-LDA) untuk pengenalan wajah. Tujuan tulisan ini adalah untuk mengevaluasi unjuk kerja teknik ini terhadap masalah *small sample size* (SSS) yang sering muncul di dalam pengenalan wajah. Pada dasarnya teknik berbasis LDA ini (DF-LDA) merupakan kombinasi dari teknik D-LDA dan F-LDA, dimana untuk merepresentasikan citra wajah secara global secara efisien dapat ditambahkan sebuah fungsi pembobot (*weighting function*) dengan bertahap secara langsung dan fraksional pada proses LDA. Proses pencocokan dilakukan dengan mencari jarak Euclidean minimum antara ciri citra wajah uji terhadap ciri citra wajah latih yang terdapat di dalam database. Dari hasil simulasi untuk *Database Face Recognition Data* dan Database Mahasiswa Maranatha diperoleh akurasi pengenalan wajah yang lebih baik untuk kondisi jumlah citra wajah satu per orang di dalam proses pelatihan jika database wajah diproses secara terpisah.

Kata kunci: akurasi, ciri, citra wajah, DF-LDA, *small sample size* (SSS)

1. Pendahuluan

Akurasi pengenalan wajah sangat ditentukan oleh deskripsi/representasi citra wajah dan desain pengklasifikasi (*classifier design*). Tujuan dari representasi citra wajah adalah untuk memperoleh sekumpulan *feature* (ciri khas) dari sebuah citra wajah yang dapat meminimalkan variasi *intra-class* (misal: antar citra wajah yang berbeda tetapi dari individu yang sama), sekaligus memaksimalkan variasi *inter-class* (misal: antar citra wajah individu yang berbeda). Selain itu, deskriptor citra wajah juga diharapkan *robust* terhadap perubahan pencahayaan, pose, ekspresi, umur, jenis kelamin, ras, dan lain-lain, serta mudah untuk mengekstraksinya (memperolehnya) dari sebuah citra wajah. Hal yang menjadi catatan penting dalam merepresentasikan citra wajah adalah jika representasi citra wajah yang diperoleh tidak cukup *diskriminatif*, bahkan pengklasifikasi (*classifier*) yang paling canggih sekalipun akan gagal untuk melakukan peran untuk pengenalan wajah. Oleh karena itu, sangat penting untuk menentukan dengan hati – hati

representasi wajah yang akan diambil ketika merancang sebuah sistem pengenalan wajah [1].

Secara garis besar, deskriptor citra wajah dapat dibagi dua, yaitu deskriptor ciri-global (*global-feature descriptor*) dan deskriptor ciri-lokal (*local-feature descriptor*). Deskriptor ciri-global diperoleh dengan memproses keseluruhan citra wajah (*integral/whole face image*) secara langsung untuk memperoleh informasi penting dari sebuah citra wajah. Sedangkan deskriptor ciri-lokal biasanya diperoleh berdasarkan ekstraksi ciri dari komponen/wilayah/blok wajah tertentu. Di dalam tulisan ini ekstraksi ciri citra wajah dilakukan secara global berbasis teknik LDA, yaitu DF-LDA.

Tulisan ini berisi hal-hal sebagai berikut. Pada bagian 2 dibahas tentang gambaran umum sistem pengenalan wajah yang akan disimulasikan, bagian 3 dibahas teknik deteksi wajah menggunakan algoritma *Local Successive Mean Quantization Transform (Local SMQT)*, bagian 4 dibahas tentang ekstraksi ciri citra wajah secara global dengan teknik DF-LDA, bagian 5 dibahas tentang hasil simulasi dan analisis, dan bagian 6 berisi kesimpulan dari tulisan ini.

2. Gambaran Sistem Pengenalan Wajah yang Akan Disimulasikan

Face recognition atau pengenalan wajah adalah salah satu teknik identifikasi teknologi biometrik, dengan menggunakan wajah individu yang bersangkutan sebagai sumber parameter utamanya. Secara garis besar proses sistem pengenalan wajah terdiri dari tiga proses utama, yaitu proses deteksi wajah, proses ekstraksi ciri citra wajah, dan proses identifikasi (Gambar 1) [2].



Gambar 1. Proses pengenalan wajah

3. *Local Successive Mean Quantization Transform (Local SMQT)*

Deteksi wajah adalah sebuah proses awal dari sebuah sistem pengenalan wajah. Tujuan dari deteksi wajah adalah untuk memeriksa apakah ada citra wajah (*face image*) di dalam sebuah citra. Teknik deteksi wajah yang digunakan dalam tulisan ini adalah *Local SMQT*.

Teknik *SMQT* menggunakan pendekatan yang menunjukkan suatu struktur otomatis untuk mendapatkan informasi [3]. Teknik ini akan digunakan pada area lokal suatu citra untuk memilih ciri yang tidak terpengaruh terhadap pencahayaan. Area lokal dapat didefinisikan dengan berbagai cara. Contoh, suatu metode langsung adalah dengan membagi-bagi suatu citra menjadi blok-blok dengan ukuran yang sudah ditentukan sebelumnya. Cara lain dapat dilakukan dengan cara memilih nilai-nilai dengan menyisipkan titik-titik pada suatu lingkaran dengan suatu jarak dari titik yang sudah ditentukan. Walaupun demikian, sesaat sesudah area lokal ditentukan, maka hal ini merupakan suatu himpunan nilai-nilai piksel. Misalkan x adalah satu piksel dan $D(x)$ adalah suatu himpunan dengan $|D(x)| = D$ piksel dari suatu area lokal pada sebuah citra. Misalkan transformasi *SMQT* dari area lokal adalah sebagai berikut:

$$SMQT_L : D(x) \rightarrow M(x) \quad (1)$$

yang akan menghasilkan suatu himpunan nilai yang baru. Fungsi $SMQT_L$ dapat dideskripsikan oleh pohon biner yang simpul-simpulnya berasal dari proses *Mean Quantization Unit* (MQU).

Mean Quantization Unit (MQU) terdiri dari tiga langkah proses utama, yaitu perhitungan rata – rata (*mean*), kuantisasi, dan pembagian himpunan input [4]. Langkah pertama dari MQU adalah menemukan rata-rata dari data, dinyatakan oleh $\bar{V}(x)$, sebagai berikut:

$$\bar{V}(x) = \frac{1}{|D|} \sum_{x \in D} V(x) \quad (2)$$


Langkah kedua menggunakan nilai rata-rata tersebut untuk mengkuantisasi nilai-nilai dari *data point* menjadi $\{0,1\}$. Asumsikan suatu fungsi perbandingan yang didefinisikan sebagai berikut:

$$\xi(V(y), \bar{V}(x)) = \begin{cases} 1, & \text{jika } V(y) > \bar{V}(x) \\ 0 & \text{untuk } x \text{ lainnya} \end{cases} \quad (3)$$

Dan dengan mengasumsikan Π menyatakan suatu himpunan berurutan, maka :

$$U(x) = \Pi_{y \in D} \xi(V(y), \bar{V}(x)) \quad (4)$$

$U(x)$ pada Persamaan (4) merupakan himpunan rata-rata yang sudah terkuantisasi. Himpunan $U(x)$ adalah keluaran utama dari suatu MQU. Langkah ketiga adalah membagi himpunan masukan menjadi dua sub himpunan, yaitu $D_0(x)$ dan $D_1(x)$. $D_0(x)$ akan menyebar ke kiri, sedangkan $D_1(x)$ akan menyebar ke kanan pada pohon biner, seperti diilustrasikan di dalam Gambar 2.



Gambar 2. Operasi dari *Mean Quantization Unit* (MQU)

4. Ekstraksi Ciri Citra Wajah dengan Teknik DF-LDA

Ekstraksi ciri citra wajah dilakukan untuk mengambil data yang efektif yang berguna untuk memisahkan antar citra wajah dan antar orang serta diharapkan cukup stabil untuk bermacam pengaruh, baik geometrik dan fotometrik. Untuk menentukan identitas citra wajah dilakukan dengan cara mencari jarak Euclidean minimum antara ciri citra

wajah uji terhadap ciri citra wajah latih yang telah tersimpan sebagai *database* mewakili citra wajah.

Untuk aplikasi pengenalan wajah, LDA merupakan sebuah teknik untuk melakukan klasifikasi secara *supervised* [1]. Karena representasi citra wajah dalam sebuah subruang (subspace) tidak selalu linier, maka hasil pengenalan menjadi tidak akurat (terdegradasi) karena pengaruh variasi pose atau pencahayaan. Dalam pengenalan wajah, hal ini berarti bahwa variasi *within-class* lebih besar daripada variasi *between-class*. Artinya, citra wajah orang yang sama dapat dikenali sebagai orang lain jika variasi citra wajah orang tersebut cukup besar sebagai akibat pengaruh pose atau pencahayaan.

Untuk memecahkan permasalahan yang berhubungan dengan klasifikasi pola, pada umumnya digunakan teknik berbasis LDA, dimana langkah awal adalah merepresentasi objek berdimensi rendah secara optimal dengan fokus pada ekstraksi ciri yang paling diskriminan, sementara hal ini sebenarnya hanya tepat untuk rekonstruksi objek [5,6,7,8]. Sebagai akibatnya, kinerja klasifikasi LDA sering mengalami penurunan karena kriteria pemisahan tersebut tidak berkaitan secara langsung dengan akurasi klasifikasi di ruang *output* [9].

Sebuah solusi untuk mengatasi permasalahan ini adalah memperkenalkan fungsi pembobotan terhadap LDA pada kelas objek yang lebih dekat atau kelas yang sama dalam ruang output, tetapi masih dapat berpotensi menimbulkan kesalahan klasifikasi, sehingga pemberian bobot lebih diprioritaskan di ruang *input*. Alternatif lain dari teknik LDA, yaitu *fractional-step* LDA (F-LDA), dimana pengurangan dimensi ini dilakukan pada beberapa langkah pemecahan kecil yang memungkinkan untuk jarak yang relevan supaya pembobotannya lebih akurat [9]. Meskipun metode ini telah berhasil diuji pada pola berdimensi rendah ($D \leq 5$), tetapi metode ini tidak dapat diterapkan secara langsung terhadap pola berdimensi tinggi, karena terdapat dua faktor yang mempengaruhinya, yaitu tingkat kesulitan komputasi dekomposisi eigen dari matriks ruang citra berdimensi tinggi dan dimensi matriks sebaran yang mengecil akibat persoalan *small sample size* (SSS) yang sering ditemui pada sistem pengenalan wajah, yaitu jumlah sampel pelatihan lebih kecil daripada dimensi sampel yang digunakan [6,7,8]. Salah satu solusi untuk memecahkan persoalan SSS adalah menggunakan sebuah solusi tanpa melakukan pemisahan terhadap objek, yang disebut sebagai teknik *direct* LDA (D-LDA) [7].

Teknik DF-LDA merupakan teknik yang dikembangkan oleh Juwei Lu dkk [5]. Teknik ini mendeskripsikan citra wajah secara efisien dengan menambahkan sebuah fungsi pembobot (*weighting function*) secara langsung dan bertahap secara fraksional (*fractional-step*) pada proses LDA [9]. Tujuannya adalah untuk meningkatkan kemampuan memisahkan (*separability*) pada tahap pengenalan (jika terdapat kemiripan wajah) sehingga mengurangi kesalahan klasifikasi. Matriks proyeksi akan memaksimalkan rasio antara matriks sebaran antar-kelas (*between-class scatter matrix*) dengan matriks sebaran dalam-kelas (*within-class scatter matrix*), sehingga mampu untuk memisahkan citra dari kelas-kelas yang berbeda secara optimal [10]. Dengan kata lain, teknik DF-LDA mampu untuk mengelompokkan citra wajah yang berasal dari kelas yang sama dan memisahkan citra wajah dari kelas yang berbeda secara optimal melalui menentukan matriks proyeksi dari training set yang menghasilkan suatu matriks proyeksi yang maksimal. Matriks ini diperoleh dengan memaksimalkan matriks sebaran total (*total scatter matrix*) terhadap seluruh gambar dari sebuah citra berdimensi rendah [10].

Teknik DF-LDA merupakan kombinasi dari metode D-LDA dan F-LDA, yang secara bersamaan dapat mengatasi kelemahan dan keterbatasan dari kedua metode tersebut [5]. Dengan menggabungkan kedua teknik ini, pada tahap D-LDA, data diproses langsung di ruang input citra asli berdimensi tinggi untuk menghindari hilangnya informasi penting yang diskriminatif dengan mula-mula memperkecil dimensi ruang input cira asli, tetapi subruang SSS yang mengandung ciri yang paling yang diskriminatif akan dipertahankan. Teknik D-LDA di sini dikembangkan dengan memanfaatkan kriteria Fisher yang dimodifikasi untuk menghindari timbulnya masalah sebagai akibat dari nilai eigen yang bernilai nol dari matriks sebaran dalam-kelas [7]. Langkah selanjutnya, yaitu F-LDA, adalah dengan memasukkan suatu fungsi bobot untuk melakukan reorientasi subruang SSS secara acak, sehingga menghasilkan satu set diskriminan fitur yang optimal untuk merepresentasikan citra wajah.

Misal training set terdiri dari beberapa kelas (C_i) yang masing-masing kelasnya mewakili identitas satu individu. Tiap-tiap kelas terdiri dari beberapa citra wajah latihan (L_i) yang menggambarkan kondisi yang berbeda, seperti perbedaan pose, pencahayaan dan lain-lain. L adalah jumlah kelas citra latihan. Perhitungan DF-LDA dilakukan dengan langkah-langkah sebagai berikut:

1. Ubah setiap citra wajah yang berupa matriks di training set menjadi vektor kolom (Γ_n) dan setiap vektor kolom dari semua citra disusun menjadi satu matriks.

$$\Gamma_n = [\Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_M] \quad (5)$$

2. Hitung citra wajah rata-rata dari semua citra latihan dan citra wajah rata-rata dari setiap kelas citra latihan.

$$\bar{z} = \frac{1}{N} \sum_{i=1}^C \sum_{j=1}^{C_i} z_{ij} \quad (6)$$

$$\bar{z}_i = \frac{1}{C_i} \sum_{j=1}^{C_i} z_{ij} \quad (7)$$

3. Hitung selisih setiap citra latihan dengan citra rata-rata

$$z_i = \Gamma_i - \bar{z} \quad (8)$$

4. Hitung matriks sebaran antar-kelas dan matriks sebaran dalam-kelas

$$\hat{S}_{BTW} = \sum_{i=1}^C \phi_i \phi_i^T = \Phi_b \Phi_b^T \quad (9)$$

$$\phi_i = \left(\frac{L_i}{L} \right)^{\frac{1}{2}} \sum_{j=1}^C \left(w(d_{ij}) \right)^{\frac{1}{2}} (\bar{z}_i - \bar{z}_j) \quad (10)$$

$$S_{WTH} = \frac{1}{N} \sum_{i=1}^C \sum_{j=1}^{C_i} (z_{ij} - \bar{z}_i)(z_{ij} - \bar{z}_i)^T = \Phi_w \Phi_w^T \quad (11)$$

5. Hitung nilai eigen (λ_i) dan vektor eigen (e_i) dari matriks sebaran antar-kelas dan pilih nilai eigen yang tidak bernilai nol.

$$(\Phi_b \Phi_b^T)(\Phi_b e_i) = \lambda_i (\Phi_b e_i) \quad (12)$$

$$v_i = \Phi_b e_i \quad (13)$$

6. Cari vektor eigen dari nilai eigen yang tidak bernilai nol dari matriks sebaran antar-kelas.

$$E_m = [e_1, e_2, \dots, e_m] \quad (14)$$

7. Hitung sebanyak m vektor eigen dan nilai eigen yang paling signifikan dari matriks sebaran antar-kelas.

$$U_m = \Phi_b E_m \quad (15)$$

$$\Lambda_b = U_m^T \hat{S}_{BTW} U_m \quad (16)$$

8. Cari matriks H .

$$H = U_m \Lambda_b^{-1/2} \quad (17)$$

9. Hitung vektor eigen dari matriks sebaran dalam-kelas dengan nilai eigen yang diurutkan.

$$P = H^T S_{WTH} H \quad (18)$$

10. Pilih sebanyak M ($M \leq m$) buah vektor eigen dan nilai eigen yang pertama dari P . Misalkan P_M adalah vektor eigen yang dipilih dan Λ_w adalah nilai eigennya.

11. Hitung nilai ciri dari matriks sebaran dalam-kelas

$$\Psi = H P_M (\eta I + \Lambda_w)^{-1/2} \quad (19)$$

5. Hasil Simulasi dan Analisis

Simulasi diawali dengan menentukan besarnya *threshold* atau nilai batas yang akan digunakan untuk proses klasifikasi identitas pada sistem pengenalan wajah. Citra wajah yang digunakan dalam simulasi diambil dari *Database Face Recognition Data*, Database Mahasiswa Maranatha, serta kombinasi dari keduanya.

Setiap *database* yang digunakan, masing-masing individu dalam kondisi yang berbeda-beda, seperti pose, pencahayaan, penggunaan aksesoris kacamata, dan lain sebagainya. Untuk setiap database dilakukan pengujian untuk dua kondisi. Untuk kondisi pertama jumlah citra wajah per orang hanya ada satu dalam tahap pelatihan. Sedangkan dalam kondisi kedua, dalam tahap pelatihan jumlah citra wajah per orang ada dua. Setiap citra wajah yang dipilih dalam tahap pelatihan untuk tiap orang dipilih secara acak.

Selain itu, citra wajah baik untuk pelatihan maupun dalam pengujian diatur sedemikian rupa sehingga dimensinya sama, yaitu 50×50 piksel, dimana citra wajah semula adalah citra wajah berwarna (*true color/24 bit*), tetapi sebelum dilakukan ekstraksi ciri citra wajah diubah menjadi citra wajah *grayscale* (8 bit). Akurasi pengenalan dihitung sebagai berikut :

$$\% \text{ akurasi} = \frac{\text{Jumlah citra wajah uji yang identitasnya dikenali benar}}{\text{Jumlah total citra wajah yang diuji}} \times 100\% \quad (20)$$

Gambar 3 dan Gambar 4 berturut-turut merupakan sampel citra wajah untuk masing-masing *database*.



Gambar 3. Sampel Citra Wajah untuk *Database Face Recognition Data*



Gambar 4. Sampel Citra Wajah untuk *Database Mahasiswa Maranatha*

Tabel 1 menyajikan hasil simulasi (% akurasi) untuk kedua kondisi dari masing-masing *database*, sedangkan Tabel 2 untuk kombinasi dari keduanya.

Tabel 1. Akurasi pengenalan untuk masing-masing *database*

<i>Database</i> \ <i>Kondisi</i>	Pertama	Kedua
<i>Database Face Recognition Data</i>	86,11%	75,92%
<i>Database Mahasiswa Maranatha</i>	85,41%	81,25%

Tabel 2. Akurasi pengenalan untuk kombinasi kedua *database*

<i>Database</i> \ <i>Kondisi</i>	Pertama	Kedua
Kombinasi kedua <i>database</i>	75%	90%

Dari Tabel 1 dapat dilihat bahwa untuk setiap *database*, maka akurasi pengenalan untuk kondisi pertama lebih baik daripada kondisi kedua. Kondisi pertama adalah kondisi mewakili persoalan SSS. Dari hasil simulasi ini terbukti bahwa teknik DF-LDA mampu untuk mengenali identitas wajah lebih baik jika jumlah sampel citra wajah yang ada dalam proses pelatihan lebih sedikit.

Tetapi dari hasil simulasi yang terlihat di dalam Tabel 2 terlihat sepertinya hasil ini bertentangan dengan hasil pada Tabel 1. Hal ini mungkin disebabkan oleh penggabungan citra wajah dari *database* yang berbeda menjadi faktor lain yang dapat mempengaruhi akurasi pengenalan karena skenario untuk memperoleh citra wajah untuk kedua *database* berbeda (misal: dalam *Database Face Recognition Data* jenis ras dan warna kulit dari orang yang dipilih lebih bervariasi dibandingkan *Database Mahasiswa Maranatha*).

6. Kesimpulan

Telah dilakukan simulasi pengenalan wajah dengan menggunakan teknik DF-LDA terhadap dua *database* wajah yang berbeda. Dari hasil simulasi dapat disimpulkan bahwa teknik DF-LDA dapat memperbaiki akurasi pengenalan wajah untuk persoalan SSS jika *database* wajah diproses secara terpisah.

Daftar Pustaka

- [1] Stan Z. Li and Anil J. Kain, "Handbook of Face Recognition", Springer-Verlag London Limited, 2011.
- [2] Hoi, Hyun., Kim, James., "Survey Paper: Face Detection And Face Recognition".

- [3] Nilsson, Mikael, Jorgen Nordberg, and Ingvar Claesson. (2006). Face Detection Using Local SMQT Features and Split Up Snow Classifier. Blekinge Institute of Technology, School of Engineering, Department of Signal Processing.
- [4] Nilsson, Mikael, Mattias Dahl, and Ingvar Claesson. The Successive Mean Quantization Transform. IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP), March 2005, Vol. 4, pp. 429 – 432.
- [5] Juwei Lu, Konstantinos N. Plataniotis, and Anastasios N. Venetsanopoulos, Face Recognition using LDA-Based Algorithms, IEEE Transactions on Neural Networks, Volume 14, No. 1, January 2003.
- [6] Belhumeur, Peter N., Hespana, Joao P., David J. Kriegman, "Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection", IEEE Transaction On Pattern Analysis And Machine Intelligence, Vol. 19, No. 7, Juli 1997.
- [7] H. Yu and J. Yang, "A direct LDA algorithm for high-dimensional data with application to face recognition," Pattern Recognition, vol. 34, pp.2067–2070, 2001.
- [8] L.-F. Chen, H.-Y. Mark Liao, M.-T. Ko, J.-C. Lin, and G.-J. Yu, "A new LDA-based face recognition system which can solve the small sample size problem," Pattern Recognition, vol. 33, pp. 1713–1726, 2000.
- [9] R. Lotlikar and R. Kothari, "Fractional-step dimensionality reduction," IEEE Trans. Pattern Anal. Machine Intell., vol. 22, pp. 623–627, June 2000.
- [10] Yambor, Wendy S., "Analysis of PCA-Based And Fisher Discriminant-Based Image Recognition Algorithms", Computer Science Department, Colorado State University, Colorado.