

Perbandingan Teknik Klasifikasi *Fast Null-space Based Linear Discriminant Analysis* (FNLDA) dan *Direct Linear Discriminant Analysis* (DLDA) dalam Pengenalan Citra Multimodal Wajah atau Pembuluh Darah di Telapak Tangan

Riko Arlando Saragih¹, Elbara Natanael Saputra², Daniel Setiadikarunia³, dan Judea Janoto Jarden⁴

¹ Program Studi Teknik Elektro, Fakultas Teknik, Universitas Kristen Maranatha, Bandung

² Program Studi Teknik Elektro, Fakultas Teknik, Universitas Kristen Maranatha, Bandung

³ Program Studi Teknik Elektro, Fakultas Teknik, Universitas Kristen Maranatha, Bandung

⁴ Program Studi Teknik Elektro, Fakultas Teknik, Universitas Kristen Maranatha, Bandung

*riko.as@eng.maranatha.edu¹, 1622010@eng.maranatha.edu²,

blessed_dsk@yahoo.com³, judea.j.jarden @eng.maranatha.edu⁴

INTISARI

Sistem pengenalan pola berbasis biometri bertujuan untuk mendapatkan akurasi pengenalan yang baik. Dalam aplikasi nyata, umumnya sistem tersebut merupakan sistem unimodal yang memiliki beberapa kekurangan. Sistem multimodal dapat mengatasi kekurangan tersebut. Modalitas yang berbeda lebih sesuai untuk aplikasi yang berbeda. Penelitian sebelumnya menguji tingkat pengenalan citra pembuluh darah dengan menggunakan deskriptor ciri-lokal. Dalam *paper* ini dibandingkan performa teknik klasifikasi berbasis *Linear Discriminant Analysis*, yaitu *Fast Null-space based Linear Discriminant Analysis* (FNLDA) dan *Direct Linear Discriminant Analysis* (DLDA) untuk mengenali seseorang berdasarkan citra multimodal wajah atau pembuluh darah. Representasi citra wajah atau pembuluh darah hasil ekstraksi ciri digunakan untuk mendapatkan vektor ciri citra. Kemudian, data tersebut dicocokkan dan akurasi pengenalan dari teknik klasifikasi yang diuji dapat ditentukan. Dari hasil pengujian didapatkan performa teknik klasifikasi yang lebih baik untuk mengenali seseorang berdasarkan citra multimodal wajah atau pembuluh darah, ditinjau dari tingkat akurasi pengenalannya adalah FNLDA.

Kata kunci: Citra Multimodal, DLDA, FNLDA, Pengenalan Pembuluh Darah di Telapak Tangan, Pengenalan Wajah

ABSTRACT

The biometric-based pattern recognition system aims to get high recognition accuracy. In real applications, generally, the system is a unimodal system that has several drawbacks. Multimodal systems can overcome those shortcomings. Different modalities are better suited for different applications. Previous studies tested the level of image recognition of palm vein by using local feature descriptors. In this paper, we compare the performance of classification techniques based on Linear Discriminant Analysis, namely Fast Null-space based Linear Discriminant Analysis (FNLDA) and Direct Linear Discriminant Analysis (DLDA) to recognize a person based on multimodal images of the face or palm vein. The image representation of the face or palm vein from the feature extraction step is used to obtain the image feature vector. Then, the data are matched and the recognition accuracy of the tested classification technique can be determined. Results show that the performance of the FNLDA classification technique is better for recognizing a person based on multimodal images of the face or blood vessels in terms of the level of recognition accuracy.

Keywords: Multimodal Image, DLDA, FNLDA, Palm Vein Recognition, Face Recognition

I. PENDAHULUAN

Sistem pengenalan pola berbasis biometri memiliki tujuan utama mendapatkan akurasi pengenalan yang baik. Secara umum, proses pencocokan *database* ciri (*feature*) dilakukan setelah proses pelatihan. Proses pencocokan tersebut dilakukan

untuk menguji akurasi suatu sistem pengenalan pola. *Database* ciri menyimpan informasi penting yang dianggap mewakili identitas subjek yang terdapat dalam *database* tersebut.

Dalam aplikasi nyata, pada umumnya sistem pengenalan pola berbasis biometri adalah sistem

unimodal. Sistem biometri unimodal merupakan sistem yang mengandalkan bukti-bukti hanya dari satu sumber informasi saja. Meski memiliki banyak keunggulan, sistem unimodal juga memiliki beberapa kekurangan, antara lain: rentan terhadap *noise*, variasi *intra-class*, kemiripan *inter-class*, non-universalitas, dan rentan terhadap pemalsuan. Kekurangan-kekurangan tersebut mengakibatkan performa sebuah sistem menjadi rendah. Solusi untuk mengatasi permasalahan sistem unimodal adalah dengan menggunakan sistem multimodal, yaitu sistem yang mengandalkan bukti-bukti otentikasi dari beberapa sumber informasi secara bersamaan [1].

Meski memiliki beberapa keunggulan, sistem biometri multimodal masih dapat dikembangkan lebih lanjut. Salah satunya dengan cara meningkatkan algoritma pencocokan [2]. Adanya perbedaan distribusi nilai piksel pada citra multimodal memerlukan suatu teknik ekstraksi ciri yang mampu menangani data dengan variasi *intra-class* yang kecil dan variasi *inter-class* yang besar.

Proses ekstraksi ciri adalah proses memperoleh informasi penting dari sebuah citra. Agar sebuah sistem pengenalan pola memiliki akurasi yang baik, proses ekstraksi ciri yang dilakukan perlu mendapat perhatian. Dalam memilih suatu teknik ekstraksi ciri, diusahakan agar variasi *intra-class* (misal: citra wajah yang berbeda dari orang yang sama) seminimal mungkin, sedangkan variasi *inter-class* (misal: citra wajah dari orang yang berbeda) semaksimal mungkin [3].

Pada studi sebelumnya [4], peneliti menguji penggunaan beberapa deskriptor ciri-lokal, yaitu *Local Binary Pattern* (LBP), *Local Directional Pattern* (LDiP), dan *Local Directional Number Pattern* (LDNP) untuk mengenali identitas seseorang berdasarkan citra pembuluh darah. Hasil yang diperoleh menunjukkan bahwa tingkat pengenalan citra pembuluh darah dengan menggunakan deskriptor ciri-lokal lebih rendah daripada tingkat pengenalan citra wajah.

Salah satu deskriptor ciri-global yang umum digunakan untuk klasifikasi data dan reduksi dimensi adalah *Linear Discriminant Analysis* (LDA). LDA bekerja dengan cara memaksimalkan rasio variasi *inter-class* terhadap variasi *intra-class* dalam sebuah *dataset* tertentu, sehingga menjamin keterpisahan (*separability*) yang maksimum [7]. Proses memaksimalkan rasio tersebut dicapai dengan

memaksimalkan jarak antara nilai rata-rata dari setiap kelas sekaligus meminimalkan variasi (sebaran/*scatter*) di dalam setiap kelas. Kedua hal ini dapat dianggap terjadi secara bersamaan [5].

Teknik LDA konvensional memiliki beberapa kekurangan, salah satunya yaitu memerlukan data latih yang cukup untuk menghindari masalah *small sample-size*. Kekurangan ini mengakibatkan teknik LDA konvensional sulit mengklasifikasikan data berdimensi tinggi dengan jumlah sedikit. Untuk mengatasi masalah tersebut, telah diajukan beberapa turunan dari LDA, di antaranya adalah *Fast Null-space based LDA* (FNLDA) dan *Direct LDA* (DLDA) [6].

Dalam *paper* ini akan dibandingkan penggunaan deskriptor berbasis LDA (FNLDA dan DLDA) untuk meningkatkan akurasi pengenalan bagi citra multimodal wajah atau pembuluh darah.

II. LANDASAN TEORI

A. Biometri Multimodal

Data yang mengandung *noise*, variasi *intra-class*, kemiripan *inter-class*, non-universalitas, dan kerentanan terhadap pemalsuan, merupakan faktor-faktor pada sistem biometri unimodal yang cenderung mengakibatkan peningkatan *False Acceptance Rate* (FAR) dan *False Rejection Rate* (FRR), yang pada akhirnya menyebabkan rendahnya performa sistem [1]. Beberapa hambatan yang terdapat pada sistem biometri unimodal tersebut dapat ditanggulangi dengan menyertakan lebih dari satu sumber informasi untuk menentukan identitas seseorang [7].

Istilah ‘multimodal’ merujuk pada penggabungan dua atau lebih sumber biometri berbeda yang diambil dengan sensor-sensor berbeda. Selain itu, dua properti yang berbeda dari biometri yang sama (sebagai contoh, cahaya inframerah dan pantulan cahaya tampak dari sumber biometrik yang sama) juga dapat digabungkan [2].

Tujuan utama dari sistem identifikasi biometri multimodal adalah untuk membuat keputusan dengan mengidentifikasi karakteristik fisiologis. Sistem pengenalan biometri multimodal sangat meningkatkan kinerja pengenalan. Hal ini karena, menggabungkan beberapa bukti (dalam hal ini, fitur multimodal) untuk identifikasi manusia lebih efektif dan lebih dapat diandalkan. Meski begitu, masalah penggabungan

informasi masih perlu diteliti untuk mengoptimalkan tingkat pengenalan sistem biometri multimodal [8].

B. Fast Null-space Based Linear Discriminant Analysis (FNLDA)

Null-space based Linear Discriminant Analysis (NLDA) adalah sistem pengenalan citra berdasarkan LDA. Kendala utama untuk menggunakan LDA konvensional adalah kemungkinan menghadapi masalah *small sample-size*. Ketika ini terjadi, matriks distribusi *intra-class* menjadi singular [9].

NLDA bekerja dengan cara memaksimalkan sebaran *inter-class* dalam *null-space* dari matriks sebaran *intra-class*. Dengan cara tersebut, permasalahan singularitas secara implisit dapat ditanggulangi [10].

NLDA dimulai dengan menghitung proyeksi vektor-vektor di dalam *null-space* dari matriks sebaran *intra-class*. Jika subruang ini tidak ada (dalam hal ini matriks sebaran *intra-class* adalah non-singular), maka proses LDA konvensional dapat dilakukan. Jika matriks sebaran *intra-class* merupakan matriks singular (terjadi masalah *small sample-size*), maka dipilih himpunan vektor yang memaksimalkan sebaran *inter-class* dari sampel yang telah ditransformasi sebagai sumbu proyeksi. Karena sebaran *inter-class* dari semua sampel adalah nol dalam *null-space* dari matriks tersebut, maka vektor proyeksi yang memenuhi tujuan dari proses LDA adalah vektor yang dapat memaksimalkan sebaran *inter-class* [9].

Algoritma NLDA untuk mencari matriks $\tilde{S}_b$ adalah sebagai berikut [9]:

Langkah 1: Hitung sebaran di dalam kelas (*within-class scatter*) S_w , dan sebaran antarkelas (*between-class scatter*) S_b .

Langkah 2: Misalkan *rank* dari S_w adalah r . Jika $r = n$, maka himpunan diskriminannya adalah vektor-vektor eigen (*eigenvectors*) yang bersesuaian dengan himpunan dari nilai-nilai eigen (*eigenvalues*) terbesar dari matriks $(S_b + S_w)^{-1}S_b$; Jika tidak, lanjutkan ke langkah selanjutnya.

Langkah 3: Lakukan dekomposisi nilai singular dari S_w sebagai $S_w = U \Sigma V^T$, di mana $U = V$ karena S_w simetris.

Langkah 4: Misalkan $V = [v_1, \dots, v_r, v_{r+1}, \dots, v_n]$ dan $Q = [v_{r+1}, \dots, v_n]$.

Langkah 5: Hitung $\tilde{S}_b$, di mana $\tilde{S}_b = QQ^T S_b (QQ^T)^T$.

Langkah 6: Hitung vektor-vektor eigen (*eigenvectors*) yang bersesuaian dengan himpunan dari nilai-nilai eigen (*eigenvalues*) terbesar dari matriks $\tilde{S}_b$, dan gunakan hasil tersebut untuk membentuk himpunan vektor yang paling diskriminatif untuk LDA.

Dalam *paper* ini, digunakan salah satu turunan dari NLDA, yaitu *Fast NLDA*. Metode FNLDA memerlukan waktu komputasi yang lebih sedikit daripada NLDA konvensional tanpa mengurangi performa klasifikasi [11].

Adapun algoritma FNLDA untuk mencari matriks W adalah sebagai berikut [11]:

Langkah 1: Hitung nilai eigen $E_1 \in \mathbb{R}^{n \times t}$ dan vektor eigen $D_1 \in \mathbb{R}^{t \times t}$ dari $A^T A \in \mathbb{R}^{n \times n}$.

Langkah 2: Hitung transformasi dari matriks $\hat{B}$.

Langkah 3: Bentuk $t \times (c - 1)$ matriks $\hat{Y}$ secara acak (*random*). *Rank* dari $\hat{Y}$ harus $c - 1$.

Langkah 4: Hitung $\hat{W} = K_1 K_2$, di mana $K_1 = D_1^{-1} \hat{B}$ dan $K_2 = \hat{B}^T \hat{Y}$.

Langkah 5: Jika $\hat{W}$ ortonormal dibutuhkan, maka $\hat{W} \leftarrow \text{qr}(\hat{W})$.

Langkah 6: Hitung $W = D_1^{-1/2} \hat{W}$, lalu $W \leftarrow E_1 W$, kemudian $W \leftarrow AW$.

C. Direct Linear Discriminant Analysis (FNLDA)

Ide utama algoritma *Direct Linear Discriminant Analysis* (DLDA) adalah melakukan diagonalisasi secara simultan, serupa dengan algoritma LDA konvensional. Algoritma DLDA mencoba mencari sebuah matriks yang secara simultan mendiagonalisasikan matriks sebaran, baik *intra-class* maupun *inter-class* [12].

Cara kerja DLDA yaitu dengan melakukan LDA dua dimensi, kemudian mentransformasikannya dengan metode Transformasi Karhunen-Loève dua dimensi (2D-KLT). Hal yang membedakan DLDA dengan metode-metode turunan LDA lainnya adalah tidak diperlukannya prapemrosesan (*preprocessing*) apapun pada data masukan [13].

Algoritma DLDA untuk mencari x^* adalah sebagai berikut [12]:

Langkah 1: Lakukan diagonalisasi matriks S_b dengan menggunakan analisis nilai eigen. Tentukan matriks V sedemikian sehingga $V^T S_b V = \Lambda$, di mana $V^T V = I$. Λ adalah matriks diagonal yang diurutkan secara menurun. Nilai-nilai eigen yang bernilai nol atau mendekati nol (disebabkan oleh matriks S_b yang

mungkin saja merupakan matriks singular) perlu dihilangkan. Misalkan Y adalah m kolom pertama dari V (matriks $n \times m$, di mana n merupakan dimensi ruang fitur), dengan $Y^T S_b Y = D_b > 0$, di mana D_b adalah sub-matriks prinsipal berukuran $m \times m$ dari matriks Λ .

Langkah 2: Misalkan $Z = Y D_b^{-1/2}$, $(Y D_b^{-1/2})^T S_b (Y D_b^{-1/2}) = I \Rightarrow Z^T S_b Z = I$. Maka Z menyatukan S_b , dan mengurangi dimensi dari n menjadi m . Diagonalisasikan $Z^T S_w Z$ dengan menggunakan analisis nilai eigen: $U^T Z^T S_w Z U = D_w$, di mana $U^T U = I$. D_w mungkin saja mengandung nilai nol dalam diagonalnya. Urutkan elemen diagonal D_w dan hilangkan beberapa nilai eigen yang tertinggi (*high end*) bersamaan dengan vektor eigen yang bersesuaian.

Langkah 3: Misalkan matriks LDA $A = U^T Z^T$. A mendiagonalisasikan baik pembilang maupun penyebut dari kriteria Fischer $A S_w A^T = D_w$, $A S_b A^T = I$.

Langkah 4: Untuk klasifikasi, transformasi akhir yang merangkum data adalah $x^* \leftarrow D_w^{-1/2} A x$.

D. Jarak Euclidean

Jarak garis lurus antara dua buah titik disebut juga jarak *euclidean* antara dua titik. Untuk menghitung jarak *euclidean* antara dua buah titik, dapat digunakan teorema Pythagoras. Persamaan jarak *euclidean* antara dua titik dalam ruang berdimensi p adalah sebagai berikut: [14]

$$D_{AB} = \sqrt{\sum_{j=1}^p (a_j - b_j)^2} \dots\dots\dots(1)$$

keterangan:

D_{AB} = Jarak *euclidean* antara titik A dan titik B


a_j = Koordinat titik A pada sumbu ke- j
(merepresentasikan dimensi ke- j)

b_j = Koordinat titik B pada sumbu ke- j
(merepresentasikan dimensi ke- j)


III. METODE PENELITIAN

Gambar 1 dan Gambar 2 berturut-turut merupakan diagram alir (*flowchart*) dan diagram blok dari sistem pengujian yang dirancang. Pengujian diawali dengan menyamakan ukuran citra untuk mempersingkat waktu perhitungan. Kemudian, dilanjutkan dengan proses ekstraksi ciri menggunakan teknik klasifikasi FNLDA dan DLDA. Dari proses tersebut, didapatkan

representasi dari semua citra masukan. Representasi citra tersebut digunakan untuk mendapatkan vektor ciri citra latih maupun citra uji. Setelah itu, dilakukan proses pencocokan menggunakan metode jarak euclidean, dan diakhiri dengan penghitungan atau penentuan akurasi pengenalan.



Gambar 1. Diagram Alir (*Flowchart*) Sistem Pengujian



Gambar 2. Diagram Blok Sistem Pengujian

A. Prosedur Pengujian

Pengujian dilakukan dalam 3 bagian, yaitu pengujian teknik klasifikasi FNLDA dan DLDA terhadap *database* ORL, *database* CASIA, dan *database* gabungan, secara berturut-turut.

Pada setiap bagian dilakukan 3 kali pengulangan, dengan memvariasikan perbandingan jumlah citra latih

dengan citra uji per subjek. Variasi perbandingan jumlah citra latih dengan citra uji per subjek ini disesuaikan dengan jumlah total citra per subjek dari setiap *database*. Pada bagian pertama (*database* ORL), perbandingan jumlah citra latih dengan citra uji yang dipakai adalah sebesar 4:6, 5:5, dan 6:4, sementara pada bagian kedua (*database* CASIA) dan ketiga (*database* gabungan), perbandingan jumlah citra latih dengan citra uji yang dipakai adalah sebesar 3:3, 4:2, dan 5:1

B. Penggunaan Database-Database Sebagai Input


Olivetti Research Lab (ORL) Database of Faces adalah *database* citra wajah yang disediakan oleh *University of Cambridge*, Inggris. *Database* ini memiliki 400 citra yang terdiri dari 40 subjek, dengan 10 citra per subjek. Citra-citra ini dilabeli dengan nomor 1-400. Dalam pengujian bagian pertama, semua citra dari *database* ini dipergunakan.



Gambar 3. Contoh Citra *Database* ORL

Chinese Academy of Sciences' Institute of Automation (CASIA) Multi-Spectral Palmprint Database adalah *database* citra pembuluh darah yang disediakan oleh *Chinese Academy of Sciences' Institute of Automation*, Tiongkok. *Database* ini memiliki 7200 citra yang terdiri dari 6 panjang gelombang sumber cahaya pengambilan gambar, 100 subjek, dengan 12 citra per subjek (6 telapak tangan kiri dan 6 telapak tangan kanan). Dari keseluruhan *database* tersebut dipilih dataset citra-citra yang berasal dari dua panjang gelombang sumber cahaya pengambilan gambar, yaitu 850nm dan 940nm. Kedua panjang gelombang tersebut dipilih karena pada panjang gelombang tersebut pembuluh darah pada telapak tangan lebih jelas terlihat dibandingkan dengan pada panjang gelombang lain yang tersedia dalam *database* ini. Dalam pengujian bagian kedua, dataset-dataset yang digunakan adalah 850_L (panjang gelombang $\lambda=850\text{nm}$; telapak tangan kiri), 850_R ($\lambda=850\text{nm}$; kanan), 940_L ($\lambda=940\text{nm}$; kiri), dan 940_R ($\lambda=940\text{nm}$; kanan). Masing-masing

dataset tersebut memiliki 600 citra, dilabeli dengan nomor 1-600.



Gambar 4. Contoh Citra *Database* CASIA

Database gabungan terdiri dari citra-citra *database* CASIA dataset 850_L (600 citra, 100 subjek, 6 citra per subjek, dilabeli dengan nomor 1-600) dengan tambahan citra-citra *database* ORL (240 citra, 40 subjek, 6 citra pertama setiap subjek, dilabeli dengan nomor 601-840). Citra dari *database* ORL hanya diambil 6 citra pertama dari masing-masing subjek agar jumlah citra per subjek secara keseluruhan dalam *database* gabungan ini konsisten.



Gambar 5. Contoh Pelabelan Citra dalam *Database* Gabungan

C. Penyamaan Ukuran Citra

Untuk menyederhanakan program yang dibuat dan mempersingkat waktu komputasi, dilakukan penyamaan ukuran citra terlebih dahulu. Seluruh citra dari ketiga *database* disamakan ukurannya menjadi 80×70 piksel. Proses ini menggunakan perintah *image resize* pada MATLAB.

D. Proses Ekstraksi Ciri

Setelah ukuran citra disamakan, dilakukan proses ekstraksi ciri menggunakan teknik klasifikasi FNLDA maupun DLDA. Keluaran dari proses ini adalah nilai eigen (*eigenvalues*), yaitu representasi dari semua citra *input*. Nilai eigen tersebut kemudian dikalikan dengan nilai piksel dari setiap citra (baik citra latih maupun citra uji) untuk mendapatkan vektor ciri dari citra latih dan citra uji. Vektor-vektor ciri ini akan digunakan dalam proses pencocokan dan penentuan akurasi.

E. Proses Pencocokan dan Penentuan Akurasi

Proses pencocokan dilakukan dengan menghitung jarak *euclidean* antara vektor ciri citra uji dengan vektor ciri citra latih. Apabila vektor ciri sebuah citra uji memiliki jarak *euclidean* yang terkecil dengan

vektor ciri dari suatu citra latih tertentu, maka dapat ditentukan bahwa citra uji mirip (cocok) dengan citra latih tersebut.

Karena vektor ciri citra latih dan citra uji disimpan dalam sebuah matriks, maka dapat ditentukan akurasi teknik klasifikasi yang digunakan, dengan merujuk pada indeks matriksnya. Jika vektor ciri citra uji bersesuaian dengan vektor ciri citra latih dengan indeks yang berasal dari subjek yang sama, maka proses pencocokan dari citra uji tersebut tepat. Jumlah pencocokan yang tepat dibagi dengan jumlah citra uji akan menghasilkan akurasi pengenalan dari teknik klasifikasi yang diuji.

IV. HASIL PENELITIAN DAN PEMBAHASAN

A. Hasil Pengujian Bagian Pertama (Database ORL)

Dari hasil pengujian bagian pertama, didapatkan data akurasi pengenalan citra dari *database* ORL menggunakan teknik klasifikasi FNLDA dan DLDA. Akurasi pengenalan citra dari *database* ORL menggunakan teknik klasifikasi FNLDA terdapat dalam Tabel 1, sedangkan akurasi pengenalan citra menggunakan teknik klasifikasi DLDA terdapat dalam Tabel 2.

Tabel 1. Akurasi Pengenalan Citra dari *Database* ORL Menggunakan Teknik Klasifikasi FNLDA

Jumlah Citra Latih Per Subjek	Jumlah Citra Uji Per Subjek	Jumlah Total Citra Uji	Akurasi Pengenalan	Akurasi Pengenalan (dalam %)
4	6	240	221	92,08%
5	5	200	183	91,50%
6	4	160	152	95,00%

Tabel 2. Akurasi Pengenalan Citra dari *Database* ORL Menggunakan Teknik Klasifikasi DLDA

Jumlah Citra Latih Per Subjek	Jumlah Citra Uji Per Subjek	Jumlah Total Citra Uji	Akurasi Pengenalan	Akurasi Pengenalan (dalam %)
4	6	240	202	84,17%
5	5	200	175	87,50%
6	4	160	152	95,00%

Dalam Tabel 1 dan Tabel 2, dapat dilihat bahwa prosedur percobaan dan pengujian untuk metode

FNLDA dan DLDA untuk database wajah ORL adalah sama, yaitu masing-masing baris menyatakan variasi jumlah citra latih yang dipilih, yaitu 4 untuk percobaan pertama, 5 untuk percobaan kedua, dan 6 untuk percobaan ketiga. Sisa citra wajah untuk tiap subyek digunakan untuk proses pengujian (total citra wajah per subyek dalam database ORL adalah 10 citra wajah).

Lalu vektor ciri yang dihasilkan untuk tiap citra wajah uji dicari identitasnya berdasarkan perhitungan pada rumus pada Persamaan (1) dengan memilih jarak yang terpendek sebagai identitas dari citra wajah yang diujikan. Ilustrasi perhitungan untuk menentukan identitas citra wajah uji misalnya sebagai berikut: citra yang diuji misalnya direpresentasikan dengan vektor $\mathbf{u} = (0,2;0,1)^t$, dengan t menyatakan operasi *transpose*; sedangkan citra latih yang ada di dalam database citra wajah misalkan ada 4 dan diwakili oleh vektor-vektor berikut, yaitu $\mathbf{a} = (0,1;0,1)^t$, $\mathbf{b} = (0,3;0,2)^t$, $\mathbf{c} = (0,5;0,3)^t$, dan $\mathbf{d} = (0,1;0,2)^t$, maka berdasarkan Persamaan (1), identitas citra wajah yang diwakili oleh vektor $\mathbf{u}$ akan dikenali sebagai citra wajah yang diwakili oleh vektor $\mathbf{a}$. Identitas yang dikenali sebagai identitas yang tepat (benar) dari citra yang diujikan akan dikategorikan sebagai identitas yang akurat. Perhitungan akurasi pengenalan dilakukan dengan menghitung perbandingan (rasio) jumlah total citra uji yang tepat dikenali terhadap jumlah total citra wajah yang diuji per prosedur percobaan. Proses perhitungan yang sama juga dilakukan untuk memperoleh setiap hasil pada Tabel 3 hingga Tabel 6.

B. Hasil Pengujian Bagian Kedua (Database CASIA)

Dari hasil pengujian bagian kedua, didapatkan data akurasi pengenalan citra dari *database* CASIA menggunakan teknik klasifikasi FNLDA dan DLDA. Akurasi pengenalan citra dari *database* CASIA menggunakan teknik klasifikasi FNLDA terdapat dalam Tabel 3, sedangkan akurasi pengenalan citra menggunakan teknik klasifikasi DLDA terdapat dalam Tabel 4.

Tabel 3. Akurasi Pengenalan Citra dari *Database* CASIA Menggunakan Teknik Klasifikasi FNLDA

Data-set	Jml. Citra Latih Per Subjek	Jml. Citra Uji Per Subjek	Jml. Total Citra Uji	Akurasi Pengenalan	Akurasi Pengenalan (dalam %)
850_L	3	3	300	15	5,00%

850_R	4	2	200	105	52,50%
	5	1	100	82	82,00%
	3	3	300	15	5,00%
	4	2	200	123	61,50%
	5	1	100	75	75,00%
940_L	3	3	300	11	3,67%
	4	2	200	108	54,00%
	5	1	100	80	80,00%
940_R	3	3	300	13	4,33%
	4	2	200	119	59,50%
	5	1	100	82	82,00%

Tabel 4. Akurasi Pengenalan Citra dari *Database CASIA* Menggunakan Teknik Klasifikasi DLDA

<i>Data-set</i>	Jml. Citra Latih Per Subjek	Jml. Citra Uji Per Subjek	Jml. Total Citra Uji	Akurasi Pengenalan	Akurasi Pengenalan (dalam %)
850_L	3	3	300	10	3,33%
	4	2	200	43	21,50%
	5	1	100	34	34,00%
850_R	3	3	300	8	2,67%
	4	2	200	49	24,50%
	5	1	100	37	37,00%
940_L	3	3	300	10	3,33%
	4	2	200	37	18,50%
	5	1	100	37	37,00%
940_R	3	3	300	8	2,67%
	4	2	200	53	26,50%
	5	1	100	38	38,00%

C. Hasil Pengujian Bagian Ketiga (*Database Gabungan*)

Dari hasil pengujian bagian ketiga, didapatkan data akurasi pengenalan citra dari *database* gabungan menggunakan teknik klasifikasi FNLDA dan DLDA. Akurasi pengenalan citra dari *database* gabungan menggunakan teknik klasifikasi FNLDA terdapat dalam Tabel 5, sedangkan akurasi pengenalan citra menggunakan teknik klasifikasi DLDA terdapat dalam Tabel 6.

Tabel 5. Akurasi Pengenalan Citra dari *Database Gabungan* Menggunakan Teknik Klasifikasi FNLDA

Jumlah Citra Latih Per Subjek	Jumlah Citra Uji Per Subjek	Jumlah Total Citra Uji	Akurasi Pengenalan	Akurasi Pengenalan (dalam %)
3	3	420	112	26,67%
4	2	280	165	58,93%
5	1	140	113	80,71%

Tabel 6. Akurasi Pengenalan Citra dari *Database Gabungan* Menggunakan Teknik Klasifikasi DLDA

Jumlah Citra Latih Per Subjek	Jumlah Citra Uji Per Subjek	Jumlah Total Citra Uji	Akurasi Pengenalan	Akurasi Pengenalan (dalam %)
3	3	420	93	22,14%
4	2	280	114	40,71%
5	1	140	64	45,71%

D. Analisis Teknik Klasifikasi FNLDA

Berdasarkan data pada bagian A-C di atas, diketahui bahwa akurasi pengenalan menggunakan teknik klasifikasi FNLDA cukup baik ketika digunakan untuk mengenali wajah (*database* ORL), namun menunjukkan hasil yang kurang baik jika digunakan untuk mengenali pembuluh darah (*database* CASIA). Hal ini antara lain disebabkan karena ketidakseimbangan jumlah citra yang ada pada masing-masing *database*.

Ditinjau dari perbandingan jumlah citra latih dengan citra uji per subjek, akurasi pengenalan menggunakan metode ini semakin membaik seiring meningkatnya jumlah citra latih yang disertakan. Pada *database* ORL, terjadi anomali, yakni akurasi pengenalan dengan 5 citra latih (91.50%) lebih rendah daripada akurasi pengenalan menggunakan 4 citra latih (92.08%).

Pada *database* gabungan, akurasi pengenalan yang dihasilkan mirip dengan akurasi pengenalan pada *database* CASIA. Akurasi pengenalan dengan 3 citra latih pada *database* gabungan lebih tinggi dibandingkan dengan rata-rata akurasi pengenalan dengan 3 citra latih pada *database* CASIA.

Pada *database* CASIA, teknik klasifikasi FNLDA memiliki tingkat akurasi pengenalan yang serupa antara tangan kiri dengan tangan kanan. Demikian pula, akurasi antara rasio citra latih dan citra uji pada setiap *dataset* memiliki nilai yang serupa. Dari kedua hal ini, dapat dikatakan teknik klasifikasi FNLDA merupakan teknik klasifikasi yang stabil.

Dari pengujian dengan memvariasikan rasio citra uji dengan citra latih, terlihat bahwa tingkat akurasi pengenalan FNLDA menjadi rendah ketika jumlah citra latih hanya sedikit. Hal ini disebabkan karena

terjadinya *drop*.

Teknik klasifikasi FNLDA memiliki rata-rata tingkat akurasi yang lebih tinggi jika dibandingkan dengan DLDA. Hal ini disebabkan karena teknik klasifikasi FNLDA memanfaatkan informasi yang terdapat pada *null-space*, sehingga tingkat akurasi pengenalan cukup tinggi meskipun jumlah citra latih hanya sedikit.

E. Analisis Teknik Klasifikasi DLDA

Berdasarkan data pada bagian A-C di atas, diketahui bahwa akurasi pengenalan menggunakan teknik klasifikasi DLDA serupa dengan akurasi pengenalan menggunakan metode FNLDA, yaitu cukup baik ketika digunakan untuk mengenali wajah (*database* ORL), namun menunjukkan hasil yang kurang baik jika digunakan untuk mengenali pembuluh darah (*database* CASIA). Hal ini antara lain disebabkan karena ketidakseimbangan jumlah citra yang ada pada masing-masing *database*.

Ditinjau dari jumlah citra latih per subjek yang digunakan dalam proses pelatihan, akurasi pengenalan menggunakan metode ini menunjukkan peningkatan seiring bertambahnya jumlah citra latih yang disertakan. Hal ini berlaku untuk semua *database* yang digunakan.

Pada *database* gabungan, akurasi pengenalan yang dihasilkan mirip dengan akurasi pengenalan pada *database* CASIA. Akurasi pengenalan dengan 3 citra latih pada *database* gabungan lebih tinggi dibandingkan dengan rata-rata akurasi pengenalan dengan 3 citra latih pada *database* CASIA.

Pada *database* CASIA, teknik klasifikasi DLDA memiliki tingkat akurasi pengenalan yang serupa antara tangan kiri dengan tangan kanan. Demikian pula, akurasi antara rasio citra latih dan citra uji pada setiap *dataset* memiliki nilai yang serupa. Dari kedua hal ini, dapat dikatakan teknik klasifikasi DLDA merupakan teknik klasifikasi yang stabil.

Dari pengujian dengan memvariasikan rasio citra uji dengan citra latih, terlihat bahwa tingkat akurasi pengenalan DLDA menjadi rendah ketika jumlah citra latih hanya sedikit. Hal ini disebabkan karena terjadinya *drop*.

Teknik klasifikasi DLDA memiliki rata-rata tingkat akurasi yang lebih rendah jika dibandingkan

dengan FNLDA. Hal ini karena pada proses perhitungan dalam teknik klasifikasi DLDA banyak terjadi pembangian dengan nilai nol. Hal ini menyebabkan terjadinya masalah singularitas, sehingga tingkat akurasi pengenalan menurun.

V. KESIMPULAN

Dari hasil pengujian dapat ditentukan bahwa performa teknik klasifikasi berbasis LDA yang lebih baik untuk mengenali seseorang berdasarkan citra multimodal wajah atau pembuluh darah, khususnya untuk jumlah citra latih yang lebih sedikit, ditinjau dari tingkat akurasi pengenalannya adalah *Fast Null-space Linear Discriminant Analysis* (FNLDA).

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih atas dukungan dari Program Studi Teknik Elektro, Fakultas Teknik, Universitas Kristen Maranatha, Bandung, sehingga penulisan *paper* ini dapat diselesaikan.

Sebagian dari penelitian dalam *paper* ini menggunakan *database* Olivetti Research Lab (ORL) *Database of Faces* yang dikumpulkan oleh *University of Cambridge*, Inggris.

Sebagian dari penelitian dalam *paper* ini menggunakan *database* CASIA-MS-PalmprintV1 yang dikumpulkan oleh *Chinese Academy of Sciences' Institute of Automation (CASIA)*, Tiongkok.

DAFTAR PUSTAKA

- [1] P. S. Sanjekar and J. B. Patil, "An Overview of Multimodal Biometrics," *Signal & Image Processing: An International Journal*, vol. 4, no. 1, pp. 57-64, 2013.
- [2] V. M. Mane and D. V. Jadhav, "Review of Multimodal Biometrics: Applications, Challenges and Research Areas," *International Journal of Biometrics and Bioinformatics*, vol. 3, no. 5, pp. 90-95.
- [3] S. Z. Li and A. K. Jain, Eds., *Handbook of Face Recognition*, 2nd ed., London: Springer, 2011.
- [4] D. Setiadiarunia, R. A. Saragih and B. Benjamin, "Face and Vein Identification using LBP, LDiP, and LDNP as Local-Feature Descriptors," *Journal*

- of Engineering and Applied Sciences*, vol. 12, no. 13, pp. 3299-3303, 2017.
- [5] J. Starmer, "StatQuest: Linear Discriminant Analysis (LDA), clearly explained," 10 Juli 2016. [Online]. Available: <https://statquest.org/statquest-linear-discriminant-analysis-lda-clearly-explained/>. [Diakses 4 Maret 2021].
- [6] H. Zhao, Z. Wang and F. Nie, "A New Formulation of Linear Discriminant Analysis for Robust Dimensionality Reduction," *IEEE Transactions on Knowledge and Data Engineering*, vol. 31, no. 4, pp. 629-639, April 2019.
- [7] A. Ross dan A. K. Jain, "Information fusion in biometrics," *Pattern Recognition Letters*, vol. 24, pp. 2115-2125, 2003.
- [8] K. Gunasekaran, J. Raja and R. Pitchai, "Deep multimodal biometric recognition using contourlet derivative weighted rank fusion with human face, fingerprint and iris images," *Automatika: Journal for Control, Measurement, Electronics, Computing and Communications*, vol. 60, no. 3, pp. 253-265, 2019.
- [9] L. Chen, H. M. Liao, M. Ko, J. Lin and G. Yu, "A new LDA-based face recognition system which can solve the small sample size problem," *The Journal of the Pattern Recognition Society*, vol. 33, pp. 1713-1726, 2000.
- [10] J. Ye and T. Xiong, "Null Space versus Orthogonal Linear Discriminant Analysis," in *Proceedings of the 23rd international conference on Machine Learning*, New York, 2006.
- [11] A. Sharma dan K. K. Paliwal, "A new perspective to null linear discriminant analysis method and its fast implementation using random matrix multiplication with scatter matrices," *Pattern Recognition*, vol. 45, pp. 2205-2213, 2012.
- [12] H. Yu and J. Yang, "A direct LDA algorithm for high-dimensional data - with application to face recognition," *The Journal of the Pattern Recognition Society*, vol. 34, pp. 2067-2070, 2001.
- [13] G. Kukharev and P. Forczmański, "Face Recognition by Means of Two-Dimensional Direct Linear Discriminant Analysis," in *Proceedings of 8th International Conference on Pattern Recognition and Information Processing*, Minsk, Belarus, 2005.
- [14] S. Sharma, *Applied Multivariate Techniques*, New York: John Wiley & Sons, Inc., 1996.