

# Identifikasi Telapak Tangan Menggunakan 2DPCA plus PCA dan *K-Nearest Neighbour*

Bedy Purnama, S.Si, M.T  
Fakultas Informatika  
Institut Teknologi Telkom  
Bandung, Indonesia  
bdp@ittelkom.ac.id

Ditari Salsabila E.  
Fakultas Informatika  
Institut Teknologi Telkom  
Bandung, Indonesia  
xiratid@gmail.com

**Abstrak**—Biometrik merupakan pengenalan seseorang berdasarkan anatomi ataupun karakteristik tingkah laku. Identifikasi telapak tangan sebagai teknik biometrik memiliki kelebihan yaitu membutuhkan resolusi citra yang kecil, biaya alat yang murah, tidak bersifat intrusif, serta memiliki tingkat akurasi yang tinggi. Paper ini akan membahas identifikasi telapak tangan menggunakan metode 2DPCA plus PCA. *Principal Component Analysis* (PCA) merupakan teknik ekstraksi fitur yang memiliki kelebihan dari segi kompresi data. Metode *2 Dimensional Principal Component Analysis* (2DPCA) memiliki kelebihan dari PCA dari segi akurasi dan kompleksitas waktu, namun memiliki kekurangan yaitu membutuhkan banyak koefisien dalam menyimpan data. Penggabungan kedua metode tersebut menghasilkan metode yaitu 2DPCA plus PCA. Pada percobaan, klasifikasi dilakukan dengan menggunakan *K-Nearest Neighbour* (KNN). Analisis dilakukan dengan membandingkan performansi metode 2DPCA plus PCA dengan metode lainnya yaitu 2DPCA dan PCA.

**Kata kunci**—2DPCA; PCA; KNN; identifikasi telapak tangan

## I. PENDAHULUAN

Penggunaan biometrik telah banyak dikenal dalam kehidupan sehari-hari, seperti sistem absensi menggunakan sidik jari ataupun penyimpanan data iris dan sidik jari pada KTP. Sebagai salah satu teknik biometrik, identifikasi telapak tangan memiliki beberapa kelebihan sebagai berikut [1]. Pola telapak tangan bersifat unik bagi setiap individu dan stabil semenjak individu tersebut dewasa. Proses pengambilan citra lebih mudah dibandingkan dengan sidik jari karena ukuran yang lebih besar. Akurasi pengenalan pola telapak tangan sama seperti sidik jari, yaitu cukup tinggi. Tidak seperti pada pengenalan iris, pengambilan citra telapak tangan tidak bersifat intrusif sehingga mampu diterima oleh umum. Terdapat beberapa metode pengenalan telapak tangan, di antaranya menggunakan metode *Principal Component Analysis*.

*Principal Component Analysis* (PCA) merupakan metode ekstraksi fitur yang berfungsi untuk kompresi data [2]. PCA mengurangi dimensi data asli namun masih menyimpan ciri-ciri paling representatif dari data tersebut. Secara matematis, PCA didefinisikan sebagai transformasi linear *orthogonal* yang mentransformasi data ke koordinat sistem baru berdasarkan

urutan nilai variansi. Penggunaan PCA pada sistem rekognisi dilakukan dengan mengubah citra dua dimensi ke bentuk satu dimensi [1][3][4][5]. Hal ini menyebabkan PCA memiliki kekurangan sebagai berikut [6] :

1. Bersifat skalar.
2. Informasi spasial hilang.
3. *Curse of Dimensionality* : Vektor fitur citra berada dalam ruang berdimensi tinggi.
4. *Small Sampel Size* (SSS) akan menimbulkan masalah. PCA membutuhkan data yang luas untuk data training dan jumlah sampel data yang banyak.

Metode pengenalan lainnya yaitu *2 Dimensional Principal Component Analysis* (2DPCA). Berbeda dengan PCA, ekstraksi ciri pada 2DPCA dilakukan langsung pada citra dua dimensi. 2DPCA memiliki beberapa kelebihan yang dapat menutupi kekurangan 2DPCA [3][4][5] :

1. Bersifat vektor dan menyimpan informasi ketetanggaan (spasial).
2. Memiliki kelebihan akurasi tinggi dan waktu running lebih singkat. Hal ini disebabkan ukuran matriks kovariansi citra yang lebih kecil sehingga mudah dikenali.
3. Dimensi ruang vektor fitur lebih rendah dibandingkan PCA.
4. Membutuhkan jumlah data *training* yang lebih sedikit dibandingkan PCA.

Meskipun begitu, metode 2DPCA memiliki kekurangan yaitu membutuhkan lebih banyak koefisien untuk merepresentasikan data sehingga ukuran data besar. Kekurangan ini umumnya ditutupi dengan menggabungkan metode lain dengan 2DPCA. Pada paper ini, percobaan dilakukan dengan mengaplikasikan PCA pada hasil ekstraksi ciri 2DPCA untuk kompresi data. Metode ini untuk selanjutnya akan disebut sebagai 2DPCA plus PCA.

## II. TEORI DASAR

### A. PCA

PCA atau *Karhunen Loeve Transform* (KLT) merupakan metode ekstraksi fitur untuk pengenalan pola. PCA melakukan

kompresi berdasarkan informasi orde kedua dari *Mean Square Error* (MSE) [2].

Secara matematis PCA didefinisikan sebagai berikut [7]. Dimisalkan terdapat vektor kolom citra  $X_i = [X_1, X_2, \dots, X_M]^T$  di mana  $M$  merupakan jumlah citra dan merupakan jumlah kolom dalam matriks  $X_i$ . Maka  $\mu$ , yaitu mean dari matriks  $X_i$  dapat dihitung sebagai berikut.

$$\mu = \frac{1}{M} \sum_i^M X_i \quad (1)$$

Pengurangan data matriks  $X_i$  dengan rata-rata citra  $\mu$  akan menghasilkan data dengan nilai rata-rata nol. Proses ini disebut juga dengan normalisasi data.

$$\varphi_i = X_i - \mu; i = 1, 2, \dots, M \quad (2)$$

Hasil dari matriks ini kemudian digunakan untuk membangun matriks kovariansi  $L$  sebagai berikut.

$$L = \frac{1}{M} \sum_{i=1}^M \varphi_i \varphi_i^T \quad (3)$$

Dimisalkan  $A = [\varphi_1, \varphi_2, \dots, \varphi_M]$  maka persamaan di atas dapat diubah menjadi :

$$L = AA^T \quad (4)$$

Nilai vektor *eigen*  $u_i$  dan nilai *eigen*  $\lambda_i$  untuk matriks kovariansi  $L$  dapat dihitung dengan persamaan berikut :

$$Lu_i = \lambda_i u_i \quad (5)$$

PCA dilakukan dengan mempertahankan hanya sejumlah  $k$  vektor *eigen* tidak nol yang terbesar, yaitu  $u_i' = [u_1, u_2, \dots, u_k]$ .

Pada kenyataannya penghitungan matriks kovariansi  $L$  membutuhkan komputasi yang sangat tinggi [5]. Sebagai contoh jika matriks citra berukuran  $64 \times 64$  maka matriks kovariansi akan berukuran  $4096 \times 4096$ . Alternatif lain yaitu dengan menggunakan teknik *Singular Value Decomposition* (SVD) sebagai berikut [7]. Penghitungan matriks kovariansi pada (5) diubah menjadi :

$$L' = A^T A \quad (6)$$

Maka vektor *eigen*  $U_t$  dan nilai *eigen*  $\lambda_i$  untuk matriks kovariansi baru  $L'$  adalah :

$$\begin{aligned} A^T A u_i &= \lambda_i u_i \\ AA^T A u_i &= \lambda_i A u_i \\ L A u_i &= \lambda_i A u_i \end{aligned} \quad (7)$$

Jika dimisalkan  $U_t = A u_i$  maka persamaan di atas berubah menjadi :

$$L U_t = \lambda_i U_t \quad (8)$$

## B. 2DPCA

Metode 2DPCA didefinisikan sebagai berikut [3][4][5][6]. Jika  $A$  merupakan matriks citra asli berukuran  $m \times n$  dan  $X$  merupakan matriks dengan kolom *orthonormal*, maka 2DPCA merupakan proyeksi  $A$  pada  $X$  dengan persamaan :

$$Y = AX \quad (9)$$

Cara menentukan matriks  $X$  optimal untuk proyeksi citra adalah sebagai berikut. Terdapat persamaan :

$$J(X) = \text{trace}(S_x) \quad (10)$$

$S_x$  merupakan matriks kovariansi dari proyeksi vektor fitur dari data *training*,  $\text{trace}(S_x)$  merupakan *trace*  $S_x$ . Secara matematis  $S_x$  didefinisikan sebagai :

$$S_x = E[(Y-E(Y))(Y-E(Y))^T] \quad (11)$$

Maka dari persamaan (10) dan (11) dapat dibuat:

$$J(X) = \text{trace} \{E[(Y-E(Y))(Y-E(Y))^T]\}$$

$$J(X) = \text{trace} \{E[(AX-E(AX))(AX-E(AX))^T]\}$$

$$J(X) = X^T E[(A-E(A))^T (A-E(A))] X \quad (12)$$

Berikutnya dimisalkan  $G$  yaitu matriks kovariansi citra definit non negatif berukuran  $n \times n$  sebagai berikut :

$$G = E[(A-E(A))^T (A-E(A))] \quad (13)$$

Maka persamaan (12) dapat diubah menjadi :

$$J(X) = X^T G X \quad (14)$$

Jika terdapat sebanyak  $M$  citra data latih, dengan merupakan rata-rata semua citra latih sebagai berikut :

$$\bar{A} = \frac{1}{M} \sum_k A_k \quad (15)$$

Maka  $G$  dapat dihitung sebagai :

$$G = \frac{1}{M} \sum_{k=1}^M (A_k - \bar{A})^T (A_k - \bar{A}) \quad (16)$$

Pada percobaan, tiap-tiap citra dapat di-*shift* terlebih dahulu dengan dikurangi *mean* citra itu sendiri, sehingga nilai  $\bar{A} = 0_{(m \times n)}$

Dimisalkan  $X_{optimal}$  yaitu merupakan himpunan matriks proyeksi optimal. Berdasarkan persamaan (14) :

$$X_{optimal} = \arg \max J(X)$$

$$X_{optimal} = \arg \max (X^T G X) \quad (17)$$

Secara intuitif didapatkan  $X_{optimal}$  merupakan himpunan sejumlah  $d$  *eigenvektor* dari  $G$  berkorespondensi dengan sejumlah  $d$  *eigenvalue* tertinggi.

$$X_{optimal} = \{X_1, X_2, \dots, X_d\} \quad (18)$$

Maka hasil ekstraksi fitur citra  $A$  menggunakan 2DPCA adalah  $Y_{optimal}$ .

$$Y_{optimal} = A X_{optimal}$$

$$Y_{optimal} = \{Y_1, Y_2, \dots, Y_d\} \quad (19)$$

## C. KNN

*K-Nearest Neighbour* (KNN) merupakan metode klasifikasi data berdasarkan statistik dan termasuk ke dalam *supervised learning*. KNN memiliki kelebihan untuk data latih yang memiliki *noise* dan fleksibel terhadap perubahan data.

Berikut penerapan KNN [3][5][6]. Dimisalkan terdapat himpunan data latih  $X_{latih}$  yang terdiri dari sebanyak  $m$  kelas.

$$X_{latih} = \{X_1, X_2, \dots, X_m\} \quad (20)$$

Maka untuk tiap data uji  $X$  akan dihitung jarak *euclidian* antara matriks  $X$  ke matriks tiap-tiap kelas pada  $X_{latih}$ . Metode KNN akan mengklasifikasikan data uji  $X$  ke sejumlah  $k$  kelas

dengan jarak *euclidian* terdekat. Jika  $k = 1$  maka  $X$  otomatis diklasifikasikan ke kelas dengan jarak terdekat. Metode ini disebut juga *Nearest Neighbour*.

Jarak *euclidian* dihitung sebagai berikut. Dimisalkan  $X_i$  merupakan kelas data latih dengan fitur sebanyak  $p$  dan sampel sebanyak  $n$ , dan himpunan data uji  $X_l$ .

$$X_i = (X_{i1}, X_{i2}, \dots, X_{ip})$$

$$i = \{1, 2, \dots, n\}$$

$$X_l = (X_{l1}, X_{l2}, \dots, X_{lp})$$

(21)

Maka jarak *euclidian*  $d(X_i, X_l)$  yaitu :

$$d(X_i, X_l) = \min \|X_i - X_l\|,$$


$$\|X_i - X_l\| =$$

$$\sqrt{(X_{i1} - X_{l1})^2 + (X_{i2} - X_{l2})^2 + \dots + (X_{in} - X_{ln})^2}$$

(22)

### III. PERCOBAAN

Data citra telapak tangan yang digunakan bersumber dari riset laboratorium *Artificial Intelligence* Institut Teknologi Telkom. Telapak tangan yang digunakan yaitu telapak tangan kanan dalam kondisi kering. Sampel percobaan yaitu 60 individu, tiap-tiap individu memiliki sampel 8 citra sehingga total 80 citra. Masing-masing individu memiliki 3 citra data latih dan 5 citra data uji. Semua citra tersebut telah bebas dari *noise*.



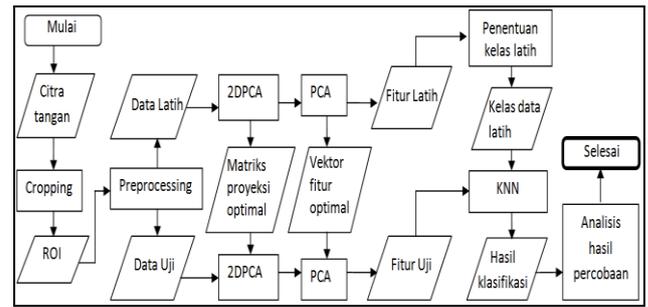
Gambar 1. a Pengambilan citra tangan. b. ROI telapak tangan

Pengambilan citra dilakukan dengan meletakkan tangan ke dalam kotak berwarna hitam. Hal ini dilakukan untuk mengurangi variasi pencahayaan pada citra. Selain itu warna hitam mempermudah proses *cropping* citra dengan membedakan warna citra telapak tangan dan latar belakang menggunakan *threshold*.

Pada bagian bawah kotak terdapat penyangga untuk meletakkan tangan, sedangkan pada bagian atas kotak terdapat lubang kamera untuk memfoto. Terdapat dua jenis kamera yang digunakan untuk pengambilan citra, salah satunya kamera Digital Canon PowerShot A1200 dengan resolusi 1,21 megapiksel. Kamera lainnya yaitu Sony DSC-W510 dengan resolusi 12,5 megapiksel.

*Region of Interest (ROI)* pada citra diambil dengan *crop* citra telapak tangan dengan ukuran 128x128 pixel, kemudian diubah ke bentuk *grayscale*. ROI ini kemudian

terbagi lagi menjadi data latih dan data uji untuk diproses lebih lanjut. Secara garis besar, keseluruhan aplikasi terbagi atas tahap pelatihan dan tahap pengujian, seperti pada Gambar 2.



Gambar 2. Garis besar aplikasi

Tahap pelatihan berjalan sebagai berikut. Matriks data latih diproses menggunakan ekstraksi fitur 2DPCA sehingga menghasilkan matriks proyeksi optimal dan vektor fitur data. Matriks proyeksi optimal ini disimpan untuk digunakan pada proses pengujian kelak. Vektor fitur data dibentuk dari perhitungan menggunakan matriks proyeksi optimal. Masing-masing vektor fitur data diubah ke bentuk satu baris dan digabungkan membentuk matriks data. Matriks data ini kemudian diproses lagi menggunakan PCA untuk mengurangi ukuran dimensi. Proses PCA menghasilkan matriks vektor fitur optimal dan fitur data latih. Vektor fitur optimal disimpan untuk digunakan pada proses pengujian. Fitur data latih didapat dari perhitungan menggunakan matriks vektor fitur optimal. Fitur data latih kemudian digunakan untuk membentuk kelas-kelas data latih. Tiap kelas latih mewakili kelas data suatu individu.

Berikut langkah-langkah yang dilakukan pada tahap pengujian. Ekstraksi fitur 2DPCA dilakukan pada data uji dengan menggunakan matriks proyeksi optimal yang dihasilkan dari tahap pelatihan. Hasil dari proses ini yaitu vektor fitur data. Vektor fitur data diubah ke bentuk satu dimensi dan digabungkan membentuk matriks data. Selanjutnya matriks data ini diproses menggunakan PCA dengan menggunakan vektor fitur optimal yang dihasilkan dari tahap pelatihan. Hasil proses ini yaitu matriks fitur data uji.

KNN kemudian menghitung jarak *euclidian* dari data uji ke masing-masing kelas data latih. Data uji akan diklasifikasikan ke kelas data latih dengan jarak terdekat.

Untuk mengukur akurasi, hasil klasifikasi dibandingkan dengan kelas data uji yang sebenarnya. Pengamatan juga dilakukan terhadap ukuran dimensi data yang dihasilkan dan lama *running time*. Analisis dilakukan dengan membandingkan hasil dari metode 2DPCA plus PCA dengan metode lainnya, yaitu 2DPCA dan PCA murni. Selain itu juga dilakukan pengukuran performansi dengan menghitung nilai FAR (*False Accept Rate*) dan FRR (*False Reject Rate*).

Berikut spesifikasi dari lingkungan implementasi. Digunakan laptop Toshiba Satellite L735 dengan processor Intel(R) Core(TM) i3-2350M CPU @ 2.30 GHz dan RAM 2

GB. Sistem operasi yang digunakan Windows 7 Starter dan bahasa pemrograman menggunakan MatlabR2008a.

Untuk pengujian perbandingan metode 2DPCA plus PCA dan PCA digunakan citra berukuran 64x64 dikarenakan keterbatasan memori. Citra ROI diperkecil sehingga berukuran setengah kali lipatnya.

Jumlah *eigenvector* pada suatu matriks persegi sama dengan jumlah kolom/baris pada matriks tersebut. Masing-masing *eigenvector* berkorelasi dengan nilai *eigenvalue*. Informasi terpenting pada citra terdapat pada *eigenvector* dengan nilai *eigenvalue* yang tinggi, sedangkan sisanya dapat diabaikan. Pada percobaan, jumlah *eigenvector* yang diambil pada metode 2DPCA dinyatakan dalam *variable* nEig2DPCA sedangkan jumlah *eigenvector* untuk PCA dinyatakan dalam *variable* nEigPCA.

Hasil perbandingan akurasi yang dihasilkan metode 2DPCA plus PCA dengan metode 2DPCA dapat dilihat pada Tabel I. Kolom merupakan dimensi kolom matriks yang dihasilkan dan akurasi dinyatakan dalam persen. Akurasi tertinggi yang dicapai metode 2DPCA yaitu 98,667% dengan dimensi kolom terkecil 1536 saat nilai *variable* nEig2DPCA 12. Akurasi yang sama dapat diperoleh menggunakan metode 2DPCA plus PCA dan menghasilkan dimensi kolom terkecil yaitu 96, dengan *input* nilai *variable* nEig2DPCA 13 dan nEigPCA 96. Dapat disimpulkan bahwa metode 2DPCA plus PCA dapat mencapai akurasi yang lebih tinggi dibandingkan metode 2DPCA murni dengan ukuran dimensi lebih kecil.

TABEL I. PERBANDINGAN AKURASI DENGAN 2DPCA

nEig 2DPCA	2DPCA		nEig PCA	2DPCA + PCA	
	Kolom	Akurasi		Kolom	Akurasi
11	1408	98	32	32	97.6667
			64	64	97.6667
			96	96	98
			128	128	98
12	1536	98.667	32	32	98
			64	64	98
			96	96	98.333
			128	128	98.6667
13	1664	98.6667	32	32	98.3333
			64	64	98
			96	96	98.6667
			128	128	98.6667
14	1792	98.3333	32	32	98
			64	64	98
			96	96	98.3333
			128	128	98.3333
15	1920	98.3333	32	32	98
			64	64	98
			96	96	98.3333
			128	128	98.3333

Berikut hasil analisis perbandingan dengan metode PCA. Identifikasi telapak tangan menggunakan metode 2DPCA plus PCA mencapai akurasi maksimum 98,667% dengan nilai *variable* nEig2DPCA 13 dan nEigPCA terkecil 96. Nilai ini lebih tinggi dibandingkan metode PCA dengan akurasi maksimum 98% untuk nilai nEigPCA 160. Dilihat dari segi

ukuran dimensi kedua metode menghasilkan matriks berukuran sama dengan nilai *variable* nEigPCA yang sama. Hasil perbandingan kedua akurasi ditampilkan pada Tabel II. Kolom merupakan dimensi kolom matriks yang dihasilkan dan akurasi dinyatakan dalam persen.

TABEL II. PERBANDINGAN AKURASI DENGAN PCA

nEig PCA	Kolom	Akurasi PCA	nEig 2DPCA	Akurasi 2DPCA+PCA
32	32	97.667	11	97.667
			12	98
			13	98.333
			14	98
			15	98
64	64	97.667	11	97.667
			12	98
			13	98
			14	98
			15	98
96	96	97.667	11	98
			12	98.333
			13	98.667
			14	98.333
			15	98.333
128	128	97.667	11	98
			12	98.667
			13	98.667
			14	98.333
			15	98.333
160	160	98	11	98
			12	98.333
			13	98.667
			14	98.333
			15	98.333

Hasil perbandingan *running time* yang dihasilkan metode 2DPCA plus PCA dengan metode 2DPCA dapat dilihat pada Tabel III. tLatih menyatakan waktu yang dibutuhkan untuk ekstraksi data latih, tUji menyatakan waktu untuk ekstraksi data uji, dan tKNN menyatakan waktu klasifikasi dalam detik.

TABEL III. PERBANDINGAN *RUNNING TIME* DENGAN 2DPCA

nEig 2DPCA	2DPCA			nEig PCA	2DPCA + PCA		
	tLatih	tUji	tKNN		tLatih	tUji	tKNN
11	0.0159	0.0235	0.0063	96	0.0544	0.0237	0.0002
12	0.0161	0.0237	0.0070	128	0.0645	0.0241	0.0003
13	0.0164	0.0244	0.0077	96	0.0754	0.0238	0.0002
14	0.0167	0.0246	0.0082	96	0.0918	0.0247	0.0002
15	0.0166	0.0246	0.0089	96	0.1166	0.0248	0.0002

Dari hasil percobaan *running time* metode 2DPCA plus PCA membutuhkan waktu yang sedikit lebih lama dibandingkan metode 2DPCA khususnya untuk ekstraksi data latih. Waktu maksimal yang dibutuhkan metode 2DPCA plus PCA untuk ekstraksi data latih mencapai 0,1166 detik sedangkan metode 2DPCA hanya mencapai 0,0167 detik. Waktu untuk proses ekstraksi data uji kedua metode tidak berbeda jauh. Metode 2DPCA plus PCA membutuhkan waktu

maksimal 0.0248 detik sedangkan metode 2DPCA membutuhkan waktu maksimal 0.0246 detik.

Metode 2DPCA plus PCA membutuhkan waktu klasifikasi yang lebih singkat dibandingkan metode 2DPCA disebabkan ukuran matriks data yang lebih kecil. Rata-rata waktu untuk klasifikasi pada metode 2DPCA plus PCA berkisar antara 0,0002 detik, sedangkan waktu klasifikasi pada metode 2DPCA meningkat seiring peningkatan jumlah nEig2DPCA dengan waktu maksimal 0,0089 detik.

Hasil perbandingan *running time* yang dihasilkan metode 2DPCA plus PCA dengan metode PCA dapat dilihat pada tabel 4. tLatih menyatakan waktu yang dibutuhkan untuk ekstraksi data latih, tUji menyatakan waktu untuk ekstraksi data uji, dan tKNN menyatakan waktu klasifikasi dalam detik.

TABEL IV. PERBANDINGAN *RUNNING TIME* DENGAN PCA

nEig PCA	PCA			nEig 2DPCA	2DPCA+PCA		
	tLatih	tUji	tKNN		tLatih	tUji	tKNN
32	0.932	0.0178	0.0001	13	0.0272	0.0158	0.0014
64	1.0147	0.0245	0.0002	13	0.0199	0.0152	0.0002
96	1.0070	0.0182	0.0002	13	0.0201	0.0153	0.0009
128	0.9890	0.0182	0.0002	13	0.0196	0.0150	0.0003
160	0.9667	0.0181	0.0003	13	0.0195	0.0149	0.0003

Hasil percobaan menunjukkan bahwa sistem identifikasi telapak tangan menggunakan metode 2DPCA plus PCA memiliki *running time* lebih singkat dibandingkan metode PCA untuk proses ekstraksi data latih. PCA membutuhkan waktu maksimal 1,0147 detik. Waktu maksimal untuk metode 2DPCA plus PCA adalah 0,0272 detik. Hal ini dikarenakan PCA membutuhkan waktu lebih lama untuk membentuk matriks kovariansi pada data latih.

Untuk proses ekstraksi data uji, rata-rata *running time* menggunakan metode 2DPCA plus PCA lebih singkat dibandingkan metode PCA. Waktu maksimal yang dibutuhkan metode PCA yaitu 0,0245 detik sedangkan metode 2DPCA plus PCA 0,0158 detik. *Running time* kedua metode tidak berbeda jauh.

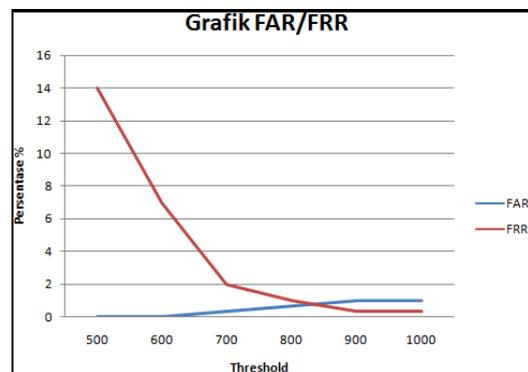
Berikut hasil pengukuran performansi sistem berdasarkan nilai FAR (*False Accept Rate*) dan FRR (*False Reject Rate*). Perbedaan dari pengujian sebelumnya yaitu adanya nilai *threshold* untuk klasifikasi. FAR merupakan persentase data uji yang salah diidentifikasi melewati suatu nilai *threshold*, sedangkan FRR merupakan data uji yang ditolak karena tidak melewati *threshold*. *Threshold* yang digunakan merupakan jarak *euclidian* antara hasil ekstraksi data uji dengan kelas yang dibentuk dari ekstraksi data latih. Nilai *threshold* kecil menyatakan data uji harus memiliki kemiripan yang tinggi dengan kelas yang dibentuk dari data latih. Jika tidak, data tersebut akan dinyatakan ditolak dan tidak diklasifikasi. Demikian juga sebaliknya. Tabel V menampilkan nilai

*threshold*, FAR dan FRR sedangkan Gambar 3 menunjukkan grafik FAR dan FRR terhadap *threshold*.

Dari percobaan dapat dilihat bahwa nilai FAR akan menurun jika nilai *threshold* semakin kecil, sedangkan nilai FRR akan naik. Nilai *threshold* yang tepat dapat dicari dengan mengetahui total jarak *euclidian* maksimum dari semua data uji berbanding total jarak *euclidian* semua data uji. Pada percobaan nilai *threshold* optimum yaitu dengan jarak *euclidian* 800 hingga 900, dengan nilai persentase FAR dan FRR di bawah sepuluh persen.

TABEL V. THRESHOLD, FAR DAN FRR

Threshold	Persentase	
	FAR	FRR
500	0	14
600	0	7
700	0.3333	2
800	0.6667	1
900	1	0.3333
1000	1	0.3333



Gambar 3. Pengukuran performansi sistem

#### IV. KESIMPULAN

Penggunaan metode 2DPCA plus PCA pada identifikasi telapak tangan memberikan hasil yang lebih baik dibandingkan metode 2DPCA atau PCA murni. Metode 2DPCA plus PCA memiliki kelebihan dari segi ukuran dimensi yang kecil dibandingkan dengan 2DPCA dan memiliki akurasi yang tinggi dibandingkan dengan PCA. Sampel data yang dibutuhkan hanya sedikit, yaitu 3 data latih untuk mengidentifikasi 5 data uji bagi tiap-tiap individu.

Pada percobaan, akurasi terbaik yang didapatkan yaitu 98,667 % dengan dimensi kolom terkecil 96. Metode 2DPCA plus PCA memiliki *running time* yang singkat dan dapat diterapkan di kehidupan nyata. Performansi terbaik dilihat dari nilai FAR dan FRR didapatkan dengan menggunakan *threshold* 800-900 untuk klasifikasi. Dapat disimpulkan bahwa metode 2DPCA plus PCA cocok digunakan untuk identifikasi telapak tangan.

## DAFTAR PUSTAKA

- [1] Zhao et all. 2007. *Palmprint Recognition with 2DPCA+PCA based on Modular Neural Networks*. University of Science and Technology of China, China. Berada di *Neurocomputing 71 (2007) 448-454*.
- [2] Smith, Lindsay. 2002. *A Tutorial on Principal Component Analysis*. Sumber : [http://www.cs.otago.ac.nz/cosc453/student\\_tutorials/principal\\_components.pdf](http://www.cs.otago.ac.nz/cosc453/student_tutorials/principal_components.pdf). Diakses 2012.
- [3] Tao et all. *Palmprint Recognition Based on 2-Dimension PCA*. School of Information Science & Engineering Shandong University, Jinan, China. Berada di *IEEE Proceedings of yhe First International Conference on Innovative Computing, Information, and Control*, 2006.
- [4] Zhang dan Zhu. (2D) PCA: 2-Directional 2-Dimensional PCA for Efficient Face Representation and Recognition. Departement of Computer Science and Engineering, Nanjing University, China. Sumber: <http://cs.nju.edu.cn/zhouzh/zhouzh.files/publication/neucom05a.pdf>. Diakses 2012
- [5] Zhang dan Yang. 2004. *Two-Dimensional PCA: A New Approach to Appearance-Based Face Representation and Recognition*. Berada di *IEEE Transactions On Pattern Analysis And Machine Intelligence, Vol. 26, No. 1, January 2004*.
- [6] Kong et all. *Generalized 2D Principal Component Analysis*. Nanyang Technological University, Singapore. Diakses 2012.
- [7] Mushtofa, Annas. 2008. Analisis dan Implementasi Pengenalan Telinga Menggunakan Principal Component Analysis (PCA) dan Linear Discriminant Analysis (LDA). Tugas Akhir, Jurusan Teknik Informatika IT Telkom, Bandung.