

EKSTRAKSI FITUR BERBASIS 2D-DISCRETE COSINE TRANSFORM DAN PRINCIPAL COMPONENT ANALYSIS UNTUK PENGENALAN CITRA WAJAH

Arif Muntasa⁽¹⁾, Mochamad Kautshar Sophan⁽¹⁾

1). Jurusan Teknik Informatika, Universitas Trunojoyo Madura.

Jl Raya Telang, Bangkalan

Telp. (031)3011147-Faks. (031)3011147

Email : arifmuntasa@yahoo.com, ochal_sophan@yahoo.com

ABSTRAKS

Penelitian tentang pengenalan wajah telah mendapat perhatian banyak para peneliti, ekstraksi fitur menggunakan basis sinyal telah banyak dilakukan, begitu pula dengan ekstraksi fitur yang berbasis statistik juga telah banyak dilakukan. Pada penelitian ini penulis mengusulkan pendekatan ekstraksi fitur dengan menggabungkan metode yang berbasis sinyal dan berbasis statistik, untuk sinyal penulis menggunakan *Two Dimensional-Discrete Cosine Transform (DCT-2D)* dan untuk basis statistiknya penulis menggunakan *Principal Component Analysis*. Untuk Data pelatihan diekstraksi menggunakan *DCT 2D*, hasil ekstraksi kemudian disusun menjadi matrik satu baris dan dinormalisasi. Hasil ekstraksi fitur selanjutnya direduksi dimensinya menggunakan *Principal Component Analysis (PCA)*. Untuk mengukur kemiripan hasil reduksi dimensi, digunakan *Euclidian Distance* dan sudut antara dua vektor. Eksperimen pada citra wajah basisdata *YALE*, menghasilkan rata-rata akurasi pengenalan untuk 6 sampel masing-masing adalah 95.153% menggunakan *Euclidian Distance* dan 95.03% menggunakan sudut antara dua vektor. Sedangkan untuk 7 sampel data pelatihan akurasi adalah 95.57% menggunakan *euclidian distance* dan 95.62% menggunakan sudut antara dua vektor. Usulan metode yang penulis usulkan juga dibandingkan dengan metode lain, yaitu *Markov Random Field (MRF)* dan *Segmentasi 2D-DCT*. Hasil perbandingan menunjukkan, untuk 6 dan 7 sampel, metode yang penulis usulkan lebih rendah akurasi dibandingkan metode *MRF*. Dibandingkan dengan metode *Segmentasi 2D-DCT*, untuk 6 sampel data pelatihan metode yang penulis usulkan lebih tinggi akurasi, sedangkan untuk 7 sampel data pelatihan metode *Segmentasi 2D-DCT* lebih tinggi akurasi.

Kata Kunci : *2D-Discrete Cosine Transform, Principal Component Analysis, Euclidian Distance.*

1. LATAR BELAKANG

Penelitian pengenalan wajah yang berbasiskan *Two Dimensional Discrete Cosinus Transform (2D-DCT)* model zig-zag 8x8 telah banyak dilakukan. Algoritma pengenalan wajah yang menggunakan basis signal seperti *DCT* dapat ditemukan pada beberapa penelitian (Ekenel ,2005; Ekenel, 2007; Hafed ,2001; Pan, 1999). Pada pengenalan citra wajah terdapat tiga macam metode yaitu metode *holistic*, berdasarkan fitur, dan *hybrid*. Diantara metode *holistic*, metode berdasarkan penampakan (*appearance based-methode*) adalah teknik paling banyak digunakan oleh para peneliti. Sebagai contoh metode yang sukses adalah *PCA*(Turk, 1991) dan *LDA* (Belhumeur, 1997). Hasil pengenalan maksimal dapat diperoleh dengan *eigenvector* dari sejumlah *eigenface* dengan *threshold* antara 0.8 sampai 0.99 (Muntasa, 2008a). Pada penelitian ini, penulis mengusulkan metode pendekatan lain berdasarkan penampakan yang berbasis signal yang menggunakan *DCT 2D*. Hasil ekstraksi menggunakan *DCT 2D* selanjutnya dinormalisasi nilainya, proses selanjutnya adalah melakukan reduksi dimensi menggunakan *Principal Component Analysis*. Hasil penyeleksian fitur tersebut selanjutnya diukur kemiripannya menggunakan *Euclidian Distance* maupun *Manhattan*. Pendekatan

yang digunakan pada penelitian ini berbeda dengan penelitian yang umumnya dilakukan. Ekstraksi fitur menggunakan *DCT-2D* umumnya menggunakan metode zig-zag untuk mengekstrak fitur yang dibutuhkan (Ekenel ,2005; Ekenel, 2007; Hafed ,2001).

2. KAJIAN PUSTAKA DAN PENDUKUNG

2.1 1D-Discrete Cosine Transform (1D-DCT)

DCT merupakan salah satu transformasi yang penting pada pengolahan sinyal, khususnya pada pengolahan citra digital. *DCT* mengubah fungsi dari *domain* spasial ke *domain* frekwensi (Gonzalez, 2001). Didefinisikan secara umum untuk *DCT 1 Dimensi* (Khayam, 2003) adalah :

$$C(u) = \alpha(u) \sum_{y=0}^{N-1} f(x) \cos \left[\frac{\pi(2x+1)u}{2N} \right] \quad (1)$$

dimana untuk $u = 1, 2, 3, \dots, N-1$. Untuk invers *DCT 1 Dimensi* ditulis dalam bentuk Persamaan (2).

$$f(x) = \sum_{u=0}^{N-1} \alpha(u) \cdot C(u) \cos \left[\frac{\pi(2x+1)u}{2N} \right] \quad (2)$$

dimana untuk $x = 1, 2, 3, \dots, N-1$. Baik untuk Persamaan (1) maupun (2), $\alpha(u)$ dapat didefinisikan sebagai

$$\alpha(u) = \begin{cases} \sqrt{\frac{1}{N}} & \text{Untuk } u = 0 \\ \sqrt{\frac{2}{N}} & \text{Untuk } u > 0 \end{cases} \quad (3)$$

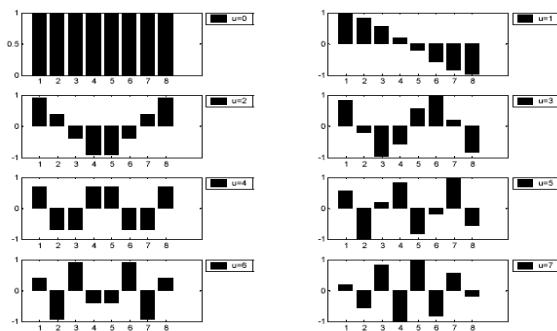
dari Persamaan (1) dan (3) jelas bahwa untuk nilai $u=0$,

$$C(u=0) = \frac{1}{N} \sum_{x=0}^{N-1} f(x) \quad \text{merupakan koefisien}$$

transformasi yang pertama adalah nilai rata-rata sampel. Jika nilai dari $f(x)$ dan $\alpha(u)$ diabaikan pada Persamaan (1), maka persamaan

$$C(u) = \sum_{y=0}^{N-1} \cos\left[\frac{\pi(2y+1)u}{2N}\right] \quad \text{untuk } N = 8, \text{ akan}$$

menghasilkan plot seperti pada Gambar 1. Jika input yang ada lebih dari N , maka citra dapat dibagi menjadi beberapa *region* dan DCT dapat diaplikasikan pada masing-masing *region* tanpa dipengaruhi oleh *region* yang lainnya.



Gambar 1. 1D DCT Dengan Basis N=8

2.2 2D-DCT

2D-DCT merupakan pengembangan dari DCT 1 Dimensi, suatu citra dengan ukuran $N \times M$, maka transformasi diskrit (Gonzalez, 2001; Khayam, 2003) dapat dimodelkan dengan Persamaan (4) dan (5) :

$$C(u, v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) g(x, y, u, v) \quad (4)$$

$$g(x, y, u, v) = \frac{1}{N^2} e^{-j2\pi(ux+vy)/N} \quad (5)$$

dimana $u=0, 1, 2, \dots, M-1$ dan $v=0, 1, 2, 3, \dots, N-1$. Invers dari transformasi diskrit dapat dituliskan dalam bentuk Persamaan (6)

$$f(x, y) = \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} T(u, v) h(x, y, u, v) \quad (6)$$

dimana masing-masing $h(x, y, u, v)$ dan $e^{i\phi}$ masing-masing dapat dimodelkan dalam bentuk Persamaan (7) dan (8)

$$h(x, y, u, v) = e^{j2\pi(ux+vy)/N} \quad (7)$$

$$e^{j\phi} = \cos \phi + j \sin \phi \quad (8)$$


dan $x=0, 1, 2, \dots, M-1$ dan $y=0, 1, 2, 3, \dots, N-1$. Pada kedua persamaan tersebut $g(x, y, u, v)$ dan $h(x, y, u, v)$ masing-masing disebut *forward* dan *inverse transformation kernel*. Dengan mensubstitusikan bentuk kernel kedalam Persamaan (4) dan (6) tersebut, maka akan diperoleh :

$$g(x, y, u, v) = h(x, y, u, v)$$

$$g = \frac{2}{\sqrt{M \cdot N}} \alpha(u) \alpha(v) \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \cos\left[\frac{\pi(2x+1)u}{2N}\right] \cos\left[\frac{\pi(2y+1)v}{2M}\right] \quad (9)$$

dimana $u=0, 1, 2, \dots, N-1$ dan $v=0, 1, 2, \dots, M-1$

Dengan $N=8$ dan $M=8$, maka DCT-2D akan menghasilkan gambar seperti pada Gambar 2.



Gambar 2. DCT 2 Dimensi dengan basis N = 8

Invers DCT 2 Dimensi dapat dituliskan dalam bentuk Persamaan (10).

$$f(x, y) = \frac{2}{\sqrt{M \cdot N}} \alpha(u) \alpha(v) \sum_{u=0}^{N-1} \sum_{v=0}^{M-1} C(u, v) \cos\left[\frac{\pi(2x+1)u}{2N}\right] \cos\left[\frac{\pi(2y+1)v}{2M}\right] \quad (10)$$

2.3 Principal Component Analysis (PCA)

PCA merupakan teknik linier untuk memproyeksikan data vektor yang berdimensi tinggi ke vektor dengan dimensi yang lebih rendah secara *unsupervised* (Jon, 2003). Untuk melakukan proyeksi sampel vektor dari citra pelatihan, setiap citra pelatihan disusun dalam bentuk vektor baris.

Misalkan suatu citra dengan lebar w dan tinggi h sebanyak M sampel, maka dimensi citra adalah $N=h \cdot w$, sehingga dapat dituliskan menggunakan suatu Persamaan (11).

$$X = \begin{matrix} X_{11} & X_{12} & \dots & X_{1N} \\ X_{21} & X_{22} & \dots & X_{2N} \\ \dots & \dots & \dots & \dots \\ X_{M1} & X_{M2} & \dots & X_{MN} \end{matrix} \quad (11)$$

Rata-rata seluruh citra wajah dapat dihitung dengan menggunakan Persamaan (12)

$$\mu_j = \frac{1}{M} \sum_{i=1}^M X_{i,j} \quad (12)$$

sehingga dimensi data rata-rata citra wajah tersebut adalah $1 \times N$. Dan *zero mean* dari citra wajah dapat dihitung dengan mengurangkan nilai masing-masing intensitas citra wajah dengan rata-rata seluruh citra wajah, seperti terlihat pada Persamaan (13) :

$$\Phi_{i,j} = X_{i,j} - \mu_j \quad (13)$$

Hasil perhitungan *zero mean* digunakan untuk mendapatkan nilai matrik kovarian dengan mengalikan transpos *zero mean*, seperti terlihat pada Persamaan (14)

$$C = (X_{i,j} - \mu_j)(X_{i,j} - \mu_j)^T \quad (14)$$

Untuk mendapatkan *eigenface* dari suatu citra wajah yang direpresentasikan dalam bentuk matrik, maka dihitung *eigenvector* dan *eigenvalue* dari matrik kovarian. Jika A adalah matrik bujur sangkar dengan ukuran sembarang $n > 1$, maka vektor tak nol x pada R^n disebut *eigenvector* dari A jika Ax suatu penggandaan skalar dari x , yaitu

$$Ax = \lambda x \quad (15)$$

Skalar λ disebut sebagai *eigenvalue* dari A dan x disebut sebagai *eigenvector* dari A yang berpadanan terhadap λ . Sehingga Persamaan (15) dapat dituliskan menjadi Persamaan (16)

$$Ax = \lambda x \quad \text{dan}$$

$$(\lambda I - A)x = 0$$

$$\text{Det}(\lambda I - A) = 0 \quad (16)$$

2.4 Pengukuran Kemiripan

Untuk mengklasifikasi hasil ekstraksi fitur, penulis menggunakan metode *Euclidian Distance* dan sudut antara dua vektor. Masing-masing model pengukuran klasifikasi dapat dilihat pada Persamaan (17) dan (18).

$$d_1(F_{Training}, F_{Uji}) = \|F_{Training} - F_{Uji}\| \quad (17)$$

$$d_2(F_{Training}, F_{Uji}) = \frac{F_{Training} \cdot F_{Uji}}{\|F_{Training}\| \|F_{Uji}\|} \quad (18)$$

3. USULAN METODE

Secara garis besar usulan metode terdiri dari dua tahapan besar. Pertama, ekstraksi fitur, kedua pengukuran kemiripan. Citra wajah pelatihan diekstraksi menggunakan Persamaan (3) dan (9). Hasil ekstraksi untuk setiap citra dibentuk menjadi matrik satu baris. Selanjutnya hasil ekstraksi dibentuk matrik baris sehingga untuk setiap citra mempunyai ciri sebanyak $1 \times N$, N adalah dimensi citra. Jika jumlah data pelatihan sebanyak M data maka matrik fitur berukuran $M \times N$.

Hasil ekstraksi seluruh data citra pelatihan dinormalisasi. Ukuran fitur yang terlalu besar akan mempunyai pengaruh pada akurasi klasifikasi dan waktu proses. Untuk mengatasi hal tersebut, maka perlu melakukan reduksi dimensi menggunakan PCA seperti terlihat pada Persamaan (12), (13), (14) dan (15). Hasil reduksi dimensi menggunakan PCA akan menghasilkan matrik dengan ukuran $M \times M$,

dimana $M \ll N$. Dari hasil ekstraksi fitur selanjutnya diukur kemiripannya menggunakan Persamaan (17) dan (18).

3.1 Algoritma Ekstraksi Fitur DCT-PCA

Untuk melakukan ekstraksi fitur, dilakukan 2 kali proses. Pertama mencari frekwensi citra menggunakan Persamaan (3) dan (9). Kedua melakukan normalisasi data setiap citra dan mereduksi dimensi untuk menemukan fitur dominan. Algoritmanya dapat dilihat pada Gambar 3.

1. For JK ← 1 to Jumlah_Kelas
 - For JP ← 1 to Jumlah_Pose_Train
 - 1.1. Tentukan Hasil Ekstraksi menggunakan persamaan (3) dan (9)
 - 1.2. Susun hasil ekstraksi dalam bentuk matrik baris
 - 1.3. Lakukan normalisasi.
 - End JP
- End JK
2. Hitung rata-rata seluruh citra (Matrik_Training) menggunakan persamaan (12)
3. Hitung zero_mean menggunakan persamaan (13)
4. Hitung covarian menggunakan persamaan (14)
5. Hitung eigen vector dan eigen value menggunakan persamaan (15)
6. Urutkan eigen value secara menurun dan eigen vector mengikutinya
7. Matrik_Proyeksi ← ((zero_mean)^T * Matrik_Training)^T

Gambar 3. Algoritma DCT-PCA

3.2 Algoritma Pengukuran Kemiripan

Untuk mengukur kemiripan, digunakan Persamaan (17) dan (19). Setiap data yang diuji, setelah diekstrak menggunakan DCT, selanjutnya hasil proyeksi disusun dalam bentuk matrik baris dan diproyeksikan untuk memperoleh matrik proyeksi. Hasil proyeksi matrik tersebut dinormalisasi. Hasil normalisasi matrik dihitung jaraknya menggunakan Algoritma 18. Nilai jarak dari data ujicoba dibandingkan dengan nilai jarak data pelatihan. Perbedaan jarak terkecil antara data ujicoba dan data pelatihan merupakan hasil pengukuran kemiripan. Algoritma selengkapnya dapat dilihat pada Gambar 4.

1. Jumlah_Pose_test=Jumlah_Pose-
Jumlah_Pose_Train
2. For JK←1 to Jumlah_Kelas
 For JP←1 to Jumlah_Pose_test
 2.1 Tentukan Hasil Ekstraksi
 menggunakan persamaan (3)
 dan (9)
 2.2 Susun hasil ekstraksi dalam
 bentuk matrik baris
 (Mat_Test)
 2.3 Matrik_Bobot_Uji←Mat_Test*
 (Matrik_Proyeksi)^T
 2.4 Hitung jaraknya terhadap
 semua data pelatihan
 menggunakan persamaan (17)
 dan (18)
 2.5 Jarak minimal merupakan
 hasil pengukuran
 End JP
 End JK

Gambar 4. Algoritma Pengukuran Kemiripan.

4. UJI COBA DAN ANALISA

Pada penelitian ini, penulis menggunakan database wajah Citra wajah basisdata YALE (YALE, 2007). Memuat 165 citra dari 15 orang, dimana tiap orang memiliki 11 citra variasi, subyek bervariasi terhadap jenis kelamin, ekspresi wajah, pencahayaan (*lighting*) dan aksesoris wajah (misalnya kacamata). Pada Gambar 5 dapat dilihat contoh citra wajah basisdata YALE. Penulis melakukan ujicoba dengan menggunakan 6 dan 7 sampel. Ketentuan untuk uji coba adalah $A_i \cap B_k = 0$, dimana A_i merupakan citra wajah pelatihan yang akan dilatih, sedangkan B_k merupakan citra wajah yang akan diuji coba. Urutan ujicoba dapat dilihat pada Tabel 1.

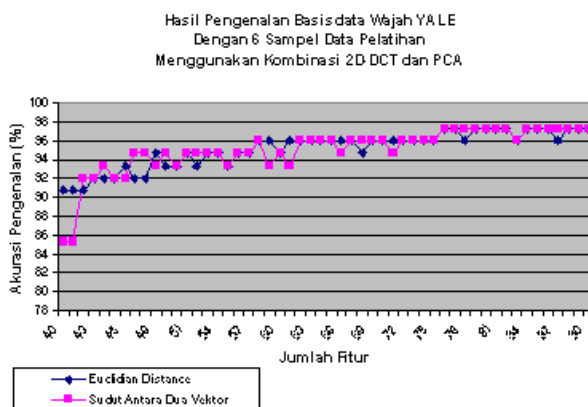


Gambar 5. Citra Wajah Basisdata YALE

Tabel 1. Daftar urutan sampel uji coba menggunakan Citra wajah basisdata YALE

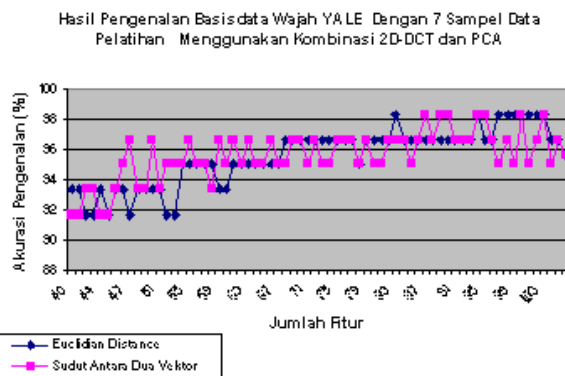
Jumlah Sampel	Data Sampel Pelatihan	Data Sampel Ujicoba
6	5, 7, 4, 2, 1, 11	8, 10, 3, 6, 9
7	5, 7, 4, 2, 1, 11, 8	10, 3, 6, 9

Hasil pengukuran kemiripan untuk 6 sampel menggunakan 40 sampai dengan 90 fitur dapat dilihat tingkat akurasi kebenarannya pada Gambar 6.



Gambar 6. Hasil Pengenalan Basisdata YALE Dengan 6 Sampel data Pelatihan Menggunakan DCTPCA

Sedangkan hasil pengukuran kemiripan untuk 7 sampel menggunakan 40 sampai dengan 105 fitur, hasil ujicobanya dapat dilihat tingkat akurasi kebenarannya pada Gambar 7. Secara umum terlihat bahwa semakin banyak jumlah fitur yang diambil, maka semakin tinggi akurasinya, meskipun terkadang untuk jumlah fitur tertentu tingkat akurasinya menurun.



Gambar 7. Hasil Pengenalan Basisdata YALE Dengan 6 Sampel data Pelatihan Menggunakan DCT-PCA

Berdasarkan beberapa hasil pengukuran menggunakan basisdata YALE, rata-rata akurasi pengenalan untuk 6 sampel menggunakan euclidian distance dan sudut antara dua vektor masing-masing adalah 95.153%, 95.03%. Sedangkan rata-rata akurasi pengenalan untuk 7 sampel menggunakan euclidian distance dan sudut antara dua vektor masing-masing adalah 95.57%, 95.62%. Rata-rata pengukuran tersebut bisa saja naik kalau penulis menggunakan fitur dalam jumlah besar, karena jumlah fitur semakin kecil, hasil akurasi pengenalan cenderung rendah. Rata-rata akurasi

pengenalan untuk 6 dan 7 sampel dapat dilihat selengkapnya pada Tabel 2.

Tabel 2. Akurasi Pengenalan Maksimal Basisdata YALE Menggunakan Segmentasi 2D-DCT 2

Jumlah Sampel	Maks	Rata-Rata	
		Euclidian Distance	Sudut Antara Dua Vektor
6	97.333	95.15	95.03
7	98.333	95.57	95.62

Penulis juga melakukan perbandingan hasil ujicoba terhadap metode *Markov Random Field* (MRF)(Huang, 2004) dan segmentasi 2D-DCT (Muntasa, 2008b). Hasil perbandingan menunjukkan, untuk 6 dan 7 sampel, rata-rata akurasi pengenalan metode Segmentasi DCT 2 Dimensi lebih rendah dibandingkan metode MRF. Dibandingkan dengan metode segmentasi 2D-DCT, untuk 6 sampel data pelatihan metode yang penulis usulkan lebih tinggi akurasinya, sedangkan untuk 7 sampel data pelatihan metode Segmentasi 2D-DCT lebih tinggi akurasinya dibandingkan metode yang penulis usulkan. Hasil selengkapnya dapat dilihat pada Tabel 3.

Tabel 3. Perbandingan Hasil Pengenalan Basisdata YALE Antara Usulan Metode, Metode MRF dan Segmentasi 2D-DCT

Jumlah Sampel	Rata-Rata Akurasi Pengenalan (%)		
	Metode Usulan	Segmentasi 2D-DCT	MRF
6	95.15	94.67	96.11
7	95.62	96.06	98.67

5. KESIMPULAN

Berdasarkan hasil ujicoba dan analisa, dapat disimpulkan

- Secara umum, semakin banyak jumlah fitur yang digunakan untuk pengkuruan kemiripan, maka semakin tinggi akurasi pengenalnya, meskipun untuk titik-titik fitur tertentu, terkadang akurasinya menurun.
- Hasil perbandingan menunjukkan, untuk 6 dan 7 sampel, metode yang penulis usulkan akurasinya masing-masing lebih rendah 0.96% dan 3.05% dibandingkan metode MRF. Dibandingkan dengan metode Segmentasi 2D-DCT, untuk 6 sampel data pelatihan metode yang penulis usulkan akurasinya lebih tinggi 0.48%, sedangkan untuk 7 sampel data pelatihan akurasinya metode Segmentasi 2D-DCT lebih tinggi 0.44%.

6. PENELITIAN SELANJUTNYA

Pada penelitian selanjutnya, dapat dikembangkan metode pengukurannya menggunakan Bayesian ataupun Support Vector Machine. Sehingga rata-rata akurasi yang diharapkan dapat lebih baik dari pada yang dilakukan sekarang ini. Akan diuji coba menggunakan basisdata lain, misalnya basisdata yang dibuat sendiri (Wajah Orang Indonesia) dan akan dianalisa sensitifitasnya menggunakan Receiver Operating Characteristic (ROC).

UCAPAN TERIMA KASIH.

Penulis mengucapkan terimakasih pada DP2M DIKTI yang telah mendukung dana melalui dana PHB Tahun Anggaran 2009. Penulis juga mengucapkan terimakasih kepada Laboratorium Computing Universitas Trunojoyo atas dukungan peralatan dan tempat untuk eksperimen.

PUSTAKA

- Belhumeur J.H.P.N, D. Kriegman. (1997). "Eigenfaces vs. fisherfaces: Recognition using class specific linear projection", *IEEE Trans. on PAMI*, 19(7):711-720
- Ekenel H. K, R. Stiefelagen. (2007). "Analysis of Local Appearance based Face Recognition : Effects of Feature Selection and Feature Normalization", *Computer Science Department, Universität Karlsruhe (TH) Am Fasanengarten 5, 76131, Karlsruhe, Germany.*
- Ekenel H. K., R. Stiefelagen. (2005). "Local Appearance based Face Recognition Using Discrete Cosine Transform", *EUSIPCO, Antalya, Turkey.*
- Gonzalez, R. C. And Woods, R. E. (2001). "Digital Image Processing", *Prentice Hall, International Edition Second Edition.*
- Hafed Z. M. and M. D. Levine. (2001). "Face Recognition Using the Discrete Cosine Transform", *International Journal of Computer Vision*, Vol. 43, No. 3, pp. 167-188.
- Huang, R. and Pavlovic V and Metaxas, D.N. (2004). "A hybrid face recognition method using markov random fields, *ICPR04*, pp 157-160.
- Jon Shlens. (2003). "A Tutorial On Principal Component Analysis And Singular Value Decomposition", <http://mathworks.com>
- Khayam Ali, Syaid (2003). "The Discrete Cosine Transform (DCT): Theory and Application", *Department of Electrical & Computer Engineering Michigan State University.*
- Muntasa A, Hariadi M, Purnomo M H. (2008a). "Penyeleksian Eigenface Secara Otomatis Untuk Pengenalan Citra Wajah", *The 9th Seminar on Intelligent Technology and Its Applications*. 29 – 34.

- Muntasari A, Hariadi M, Purnomo M H. (2008b). "Ekstraksi Fitur Satu Koefisien Berbasis Two Dimensional Discrete Cosine Transform Untuk Pengenalan Wajah". *Jurnal ilmiah sains dan teknologi*– Vol 7. Nomor 3 Hal 157-165
- Pan Z. and H. Bolouri. (1999). "High Speed Face Recognition Based on Discrete Cosine Transforms and Neural Networks", *IEEE Transaction on Pattern Analysis and Machine Intelligence*.
- Turk M, A. Pentland (1991). "Eigenfaces for recognition", *Journal of Cognitive Science*, pages 71–86, 1991.
- YALE Center for Computational Vision and Control, *YALE Face Database*, Diakses pada maret 2007 dari <http://cvc.YALE.edu/projects/YALEfaces/YALEfaces.html>