

Pengenalan Wajah Menggunakan Pseudo-2D Hidden Markov Model

Anak Agung Gde Agung¹, Fazmah Arif Yulianto², Warih Maharani³

¹Program Studi Komputerisasi Akuntansi Politeknik Telkom, Bandung

^{2,3}Fakultas Teknik Informatika, Institut Teknologi Telkom Bandung

¹anaka@politekniktelkom.ac.id, ²fay@ittelkom.ac.id, ³wrh@ittelkom.ac.id

Abstrak

Dewasa ini pengenalan wajah berperan dalam berbagai bidang, seperti. absensi, kontrol akses maupun identifikasi pelaku dan korban kejahatan. Pengenalan menggunakan biometrik seperti wajah juga berperan dalam meningkatkan efisiensi dan efektifitas berbagai kegiatan, sebab akan mengurangi penggunaan berbagai macam kartu identitas dan kata sandi. Penelitian ini dibuat untuk menganalisa kinerja pengenalan wajah dengan menggunakan metode *Pseudo-2D Hidden Markov Model*. Parameter kinerja yang dianalisa meliputi persentase pengenalan serta waktu pengenalan terhadap citra yang telah dilatih sebelumnya. Pengambilan fitur wajah dilakukan dengan menggunakan *Principal Component Analysis (PCA)* dan *clustering* menggunakan *K-Means*. Dari hasil pengujian yang dilakukan, tingkat akurasi pengenalan wajah menggunakan *Pseudo-2D Hidden Markov Model* dapat mencapai 80,75%, dengan waktu pengenalan satu individu tersingkat 5 detik dalam pengujian sebanyak empat puluh individu.

Kata kunci: PCA, k-means, pengenalan wajah, pseudo-2D hidden markov model

Abstract

Nowadays face recognition plays important role in many aspect, such as presence, employee security and control access and identification for crime suspect and victim. Recognition using biometrics such as face image also increase the effectiveness and efficiency of doing activities, since identity card and password are no longer necessary. The aim of this research is to analyze the performance of face recognition using *Pseudo-2D Hidden Markov Model*. Performance parameters to be analyzed are recognition rate and time needed for recognition. Face image feature extraction is done by using *Principal Component Analysis (PCA)* and *K-Means Clustering*. The experiment shows that by using this method, recognition rate can achieve 80.75%, with shortest recognition time for one person is five seconds, as tested with forty people.

Keywords: PCA, k-means, face recognition, pseudo-2D hidden markov model

1. Pendahuluan

Setiap manusia memiliki ciri-ciri khusus yang disebut *biometric*, yang yang dapat diamati seperti ciri fisik maupun tingkah laku, Ciri fisik yang dapat diamati diantaranya sidik jari, sidik retina, sidik DNA dan bentuk wajah.

Bentuk wajah merupakan ciri fisik yang paling mudah diamati. Pengenalan wajah saat ini telah diterapkan dalam berbagai bidang, seperti absensi, kontrol akses maupun identifikasi pelaku dan korban kejahatan.

Beberapa keunggulan pengenalan wajah adalah [1]:

1. Pengenalan wajah tidak membutuhkan interaksi secara fisik,
2. Tingkat akurasi yang dimiliki tinggi,
3. Sederhana dan mudah untuk dibandingkan.

Salah satu persoalan yang seringkali muncul adalah bagaimana mengenali identitas seseorang dari citra wajahnya, serta bagaimana variasi pose wajah

dapat mempengaruhi kinerja dan keakuratan identifikasi. Terkait dengan hal tersebut, penelitian ini bertujuan untuk menganalisa kinerja pengenalan wajah dengan menggunakan metode *Pseudo-2D Hidden Markov Model* dan pengaruh bentuk *Pseudo-2D Hidden Markov Model* apabila terdapat variasi pose dari citra wajah. Parameter kinerja yang dianalisa adalah persentase citra yang dapat dikenali secara benar serta waktu pengenalan untuk setiap variasi pengujian.

Dalam melakukan analisa kinerja pengenalan wajah, citra wajah yang digunakan adalah citra wajah manusia. Untuk pengujian, digunakan citra yang disediakan oleh *Olivetti Reaserch Face Database* [2]:

1. Terdiri dari 40 individu, sepuluh citra (variasi pose) per individu.
2. Ukuran citra 92 x 112 piksel, berbentuk citra *grayscale*.
3. Citra wajah tampak depan.

Pengujian juga dilakukan terhadap citra yang telah dilatihkan terhadap sistem sebagai berikut:

1. Untuk pelatihan digunakan delapan citra latih untuk setiap individu,
2. Untuk pengujian digunakan sepuluh citra untuk setiap individu.

Penelitian ini menggunakan metode *Left-Right Discrete Pseudo-2D Hidden Markov Model*, dengan ekstraksi ciri dari citra wajah menggunakan menggunakan metode *Principal Component Analysis (PCA)*. Adapun langkah penyelesaian masalah yang dilakukan dalam penelitian ini adalah:

1. Mempelajari teknik pemodelan yang digunakan pada *Pseudo-2D Hidden Markov Model*, serta proses pelatihan yang digunakan dalam proses identifikasi.
2. Mendefinisikan masalah yang dihadapi dan merancang solusi yang tepat untuk masalah tersebut.
3. Melakukan analisa dan perancangan perangkat lunak.
4. Membangun perangkat lunak pengenalan wajah.
5. Melakukan proses pelatihan terhadap terhadap citra yang ada.
6. Menguji perangkat lunak yang telah dibangun serta melakukan evaluasi terhadap hasil uji coba tersebut.

2. Kajian Pustaka

2.1 Hidden Markov Model [3]

Hidden Markov Model (HMM) adalah suatu pemodelan statistik yang direpresentasikan dengan sekumpulan keadaan (*state*) yang membentuk rantai yang memiliki peluang transisi yang berhubungan dengan seperangkat deretan observasi.

Sebuah HMM dapat direpresentasikan dengan $\lambda = (A, B, \Pi)$, terdiri atas:

1. Seperangkat *state* sejumlah N yang dilambangkan dengan $S = \{s_1, s_2, \dots, s_N\}$
2. Seperangkat observasi sejumlah M yang dilambangkan dengan $V = \{v_1, v_2, \dots, v_M\}$
3. Matriks probabilitas yang menunjukkan nilai kemungkinan suatu *state* dapat berpindah ke *state* lain yang dilambangkan dengan $A = \{a_{ij}\}$, dimana $a_{ij} = P[q_{t+1}=j|q_t=i]$, $1 \leq i, j \leq N$
4. Matriks peluang distribusi simbol observasi yang menunjukkan kemungkinan suatu deretan observasi dapat muncul pada suatu *state* yang dilambangkan dengan $B = \{b_j(k)\}$, dimana $b_j(k) = P[o_t=v_k|q_t=j]$, $1 \leq k \leq M$
5. Matriks probabilitas suatu *state* menjadi *state* awal yang dilambangkan dengan $\Pi = \{\Pi_i\}$ dimana $\Pi_i = P[q_1 = i]$, $1 \leq i \leq N$

2.2 Pseudo-2D Hidden Markov Model [4]

Pseudo-2D Hidden Markov Model (P2DHMM) atau *Embedded Hidden Markov Model (eHMM)* adalah HMM dimana setiap *state* adalah HMM. Pada model ini didefinisikan *super state* yaitu *state* utama dan *embedded state* yaitu *state* yang berada di

dalam *state* utama. Dinamakan *pseudo-2D* sebab transisi dari suatu *state* dalam suatu *super state* ke *state* lain dalam *super state* yang berbeda tidak diperkenankan.

Sebuah P2D HMM memiliki elemen sebagai berikut:

1. Seperangkat *super state* sejumlah N_0 yang dilambangkan dengan $S_0 = \{s_{01}, s_{02}, \dots, s_{0N_0}\}$
2. Matriks probabilitas suatu *super state* menjadi *super state* awal yang dilambangkan dengan $\Pi_0 = \{\pi_{0,i}\}$ dimana $\pi_{0,i} = P[q_{0,1} = i]$, $1 \leq i \leq N_0$
3. Matriks probabilitas yang menunjukkan nilai kemungkinan suatu *super state* dapat berpindah ke *super state* lain yang dilambangkan dengan $A_0 = \{a_{0,ij}\}$, dimana $a_{0,ij} = P[q_{t+1}=j|q_t=i]$, $1 \leq i, j \leq N_0$
4. Dalam setiap *super state*, terdapat elemen yang dimiliki sebuah HMM.

Pseudo-2D Hidden Markov Model dapat dinyatakan dengan $\lambda = (\Pi_0, A_0, \Lambda)$, dimana $\Lambda = \{\lambda^1, \lambda^2, \dots, \lambda^{N_0}\}$

2.3 Principal Component Analysis (PCA)[6]

PCA merupakan suatu metode untuk mengambil (*extract*) ciri-ciri penting dari sekumpulan data dengan melakukan dekomposisi terhadap data tersebut sehingga menghasilkan koefisien-koefisien yang mencerminkan ciri-ciri penting data tersebut. Tujuan dari PCA adalah menangkap variasi total pada wajah-wajah yang dilatihkan dan menjelaskan variasi tersebut dengan variabel-variabel yang jumlahnya lebih sedikit.

Dalam penelitian ini, ciri-ciri penting yang telah diambil kemudian dikelompokkan dengan menggunakan algoritma *K-Means* [7].

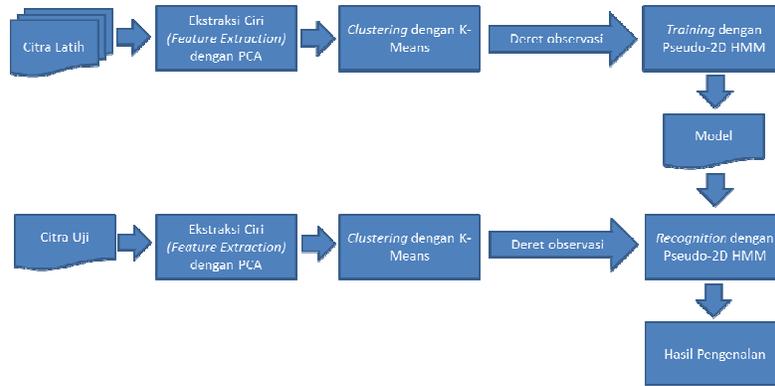
K-means adalah algoritma yang digunakan untuk mengelompokkan data (*clustering*). *Algoritma K-Means* adalah sebagai berikut:

1. Tempatkan sejumlah titik pada sebaran data yang akan dikelompokkan. Titik ini akan menjadi titik tengah (*centroid*) pada setiap kelompok data.
2. Tempatkan setiap data pada kelompok yang memiliki jarak terdekat dengan titik tengah kelompok tersebut.
3. Hitung ulang letak titik tengah setiap kelompok dengan cara merata-ratakan semua data yang ada pada kelompok yang bersangkutan.
4. Ulangi langkah kedua dan ketiga hingga titik tengah mencapai keadaan stabil atau terjadi iterasi maksimum.

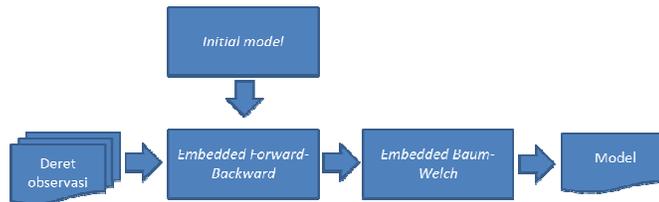
3. Analisis dan Perancangan

3.1 Analisis Sistem

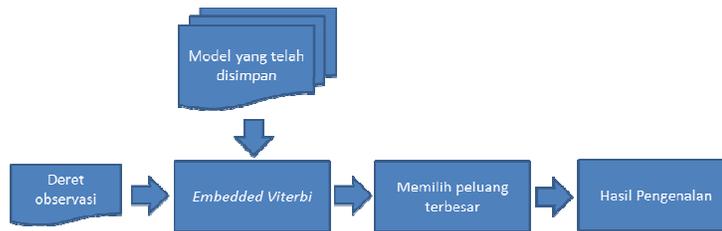
Diagram blok dari sistem yang akan dibangun digambarkan pada Gambar 1, terdiri dari dua proses utama yaitu Pelatihan (Gambar 2) dan Pengenalan (Gambar 3).



Gambar 1. Diagram Blok Sistem Pengenalan Wajah



Gambar 2. Diagram Blok Tahap Pelatihan



Gambar 3. Diagram Blok Tahap Pengenalan

3.1.1 Hidden Markov Model yang Digunakan

Dalam penelitian ini digunakan *left-right HMM*. Nilai awal yang digunakan dalam matriks PI, A dan B diperoleh melalui:

1. Nilai awal untuk matriks PI yaitu 1 untuk $\pi_{0,1}$ dan $\pi_{1,1}^i$ untuk setiap super state i selebihnya bernilai 0.

2. Nilai awal untuk matriks A diperoleh dengan aturan sebagai berikut:

- a. Untuk setiap *super state*,

$$a_{0,ij} = \frac{\text{jumlah transisi dari } S_{0,i} \text{ ke } S_{0,j}}{\text{jumlah total transisi dari } S_{0,i}}$$

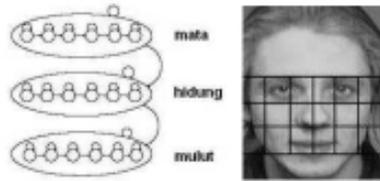
- b. Untuk setiap *embedded state* pada *super state* i ,

$$a_{1,ji}^i = \frac{\text{jumlah transisi dari } a_{1,j}^i \text{ ke } a_{1,i}^i}{\text{jumlah total transisi dari } a_{1,j}^i}$$

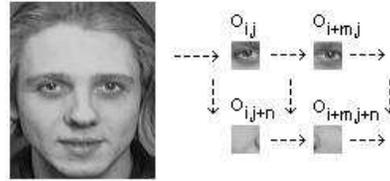
3. Nilai awal untuk matriks B pada setiap *embedded state* diperoleh secara acak dengan aturan $b_{j,i}^i = \frac{1}{\text{jumlah cluster}}$.

A. Pengujian Secara Mendatar

Super state mewakili citra dalam arah menurun sedangkan *embedded state* mewakili citra dalam arah mendatar. Ketiga *super state* mewakili tiga daerah pada wajah yaitu mata, hidung dan mulut sedangkan jumlah *embedded state* mewakili daerah yang berada dalam suatu *super state*. Untuk menguji pengaruh jumlah state terhadap kinerja sistem, jumlah *state* pada masing-masing *embedded state* dibuat bervariasi per percobaan, yaitu 6-6-6, 3-3-3, 6-3-4.



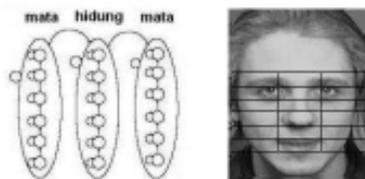
Gambar 4. Contoh *Pseudo-2D HMM* untuk Variasi 6-6-6, Pengujian Secara Mendatar



Gambar 6. Pembentukan Blok Citra untuk Deret Observasi

B. Pengujian Secara Menurun

Super state mewakili citra dalam arah menurun sedangkan *embedded state* mewakili citra dalam arah mendatar. Ketiga *super state* mewakili tiga daerah pada wajah yaitu mata, hidung dan mulut sedangkan jumlah *embedded state* mewakili daerah yang berada dalam suatu *super state*. Untuk menguji pengaruh jumlah *state* terhadap kinerja sistem, jumlah *state* pada masing-masing *embedded state* dibuat bervariasi per percobaan, yaitu 6-6-6, 3-3-3, 3-6-3.



Gambar 5. Contoh *Pseudo-2D HMM* untuk Variasi 6-6-6, Pengujian Secara Menurun

3.1.2 Deret Observasi

Deret observasi dibentuk dari empat koefisien PCA yang berkorespondensi dengan nilai eigen terbesar blok citra wajah [3]. Blok citra sebesar $L_x \times L_y$ diperoleh dengan membagi citra dari kiri ke kanan, atas ke bawah seperti pada gambar 6. Setiap blok yang berdekatan mengalami *overlapping* sebesar P_x untuk arah mendatar dan P_y untuk arah menurun. Pada penelitian ini digunakan $L_x = 10$ piksel, $L_y = 10$ piksel, $P_x = 8$ piksel, $P_y = 8$ piksel.

Pengambilan blok dimulai dari piksel ke 28 sampai 98 untuk deret vertikal dan seluruh wilayah piksel untuk deret horizontal, yang bertujuan untuk menghilangkan wilayah rambut dan dagu yang dapat berubah secara drastis. Rentang nilai yang diperoleh kemudian dikelompokkan menjadi 256 *cluster* dengan menggunakan algoritma *K-Means*.

3.1.3 Tahap Pelatihan

Dalam tahap pelatihan, akan dicari model yang dapat mewakili setiap individu. Untuk pelatihan ini digunakan delapan citra.

Langkah-langkah pelatihan untuk setiap individu (Gambar 2) adalah sebagai berikut:

1. Pada langkah ini, dilakukan ekstraksi ciri dan pembentukan deret observasi dari setiap citra latih.
2. Model yang ada kemudian direestimasi dengan algoritma *doubly embedded forward-backward* dan *doubly embedded baum-welch* sebanyak dua kali iterasi. Jumlah iterasi ini dianggap terbaik dan diperoleh berdasarkan percobaan.
3. Model tersebut disimpan dalam suatu file.

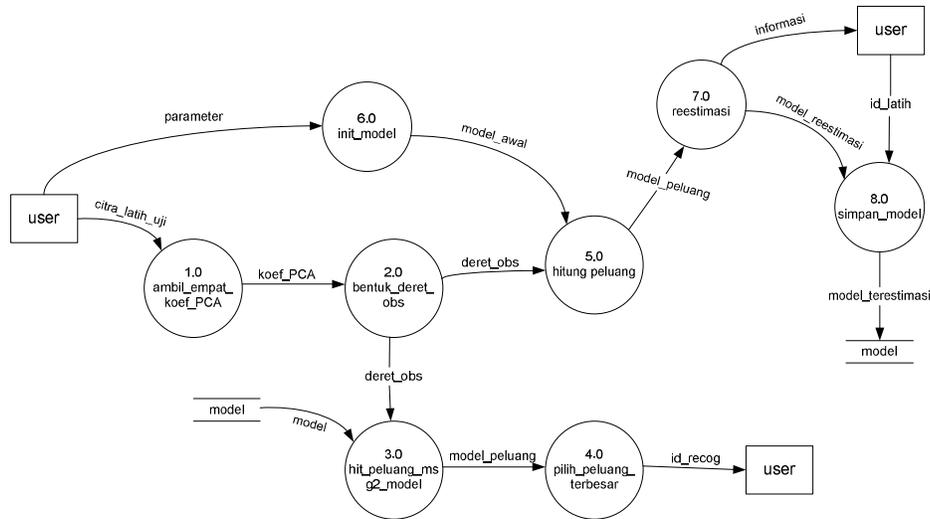
3.1.4 Tahap Pengenalan

Untuk tahap pengenalan, dilakukan ekstraksi ciri dan pembentukan deret observasi dari citra uji. Kemudian dicari peluang deret observasi citra uji terhadap setiap model yang telah disimpan sebelumnya dengan menggunakan algoritma *doubly embedded viterbi* $P(O|\lambda)$. Model dengan nilai $P(O|\lambda)$ terbesar akan dipilih sebagai hasil pengenalan. Informasi dari model tersebut kemudian ditampilkan kepada user (Gambar 3).

3.2 Perancangan Sistem

3.2.1 Diagram Aliran Data

Sistem yang dibuat memiliki tiga proses utama (Gambar 7): ekstraksi ciri-ciri citra wajah, pelatihan dan pengenalan citra wajah. Proses ekstraksi ciri terdiri dari dua sub proses (proses 1.0 dan proses 2.0). Proses pelatihan memiliki empat sub proses (proses 5.0, proses 6.0, proses 7.0 dan proses 8.0), sedangkan proses pengenalan citra wajah memiliki dua sub proses (proses 3.0 dan proses 4.0).



Gambar 7. Diagram Alir Data untuk Sistem Pengenalan Wajah

4. Analisis Hasil Implementasi

Perangkat keras dan perangkat lunak yang digunakan dalam membangun sistem pengenalan wajah ini adalah:

1. Spesifikasi perangkat keras
 - a. *Processor* AMD AthlonXP 2100+,
 - b. *Memory* DDR SDRAM 512 MB,
 - c. *Harddisk* 40 GB.
2. Spesifikasi perangkat lunak
 - a. Sistem Operasi Windows XP Professional + SP1,
 - b. *Compiler* Borland C++ Builder v.6.0,
 - c. *Software Development* Lohninger Suite for C++ Builder v.7.2, yang digunakan untuk melakukan kalkulasi PCA [8],
 - d. K-Means, yang digunakan untuk melakukan kalkulasi K-Means [9].

4.1 Analisis Hasil Pengujian

Pengujian dilakukan terhadap 400 citra wajah dari empat puluh individu. Persentase pengenalan diperoleh dengan membagi jumlah citra yang dikenali dengan benar dengan jumlah seluruh citra yang diujikan:

$$\% = \frac{\text{jumlah citra dikenali dengan benar}}{400} \times 100\%$$

4.1.1 Hasil Pengujian Secara Mendatar

Hasil yang diperoleh pada pengujian mendatar adalah sebagai berikut:

TABEL 1
HASIL PENGUJIAN SECARA MENDATAR

Pengujian Mendatar	Variasi State		
	6-6-6	3-3-3	6-3-4
% total	80,75	80	80
% individu terbesar	90	100	90
% individu terkecil	60	50	60
waktu training (mnt:dtk)	2:32	1:08	1:42
waktu test 1 individu (dtk)	20	10	14

4.1.2 Hasil Pengujian Secara Menurun

Hasil yang diperoleh pada pengujian menurun adalah sebagai berikut:

TABEL 2
HASIL PENGUJIAN SECARA MENURUN

Pengujian Menurun	Variasi State		
	6-6-6	3-3-3	3-6-3
% total	80,75	80,25	79,75
% individu terbesar	90	100	90
% individu terkecil	70	60	50
waktu training (mnt:dtk)	2:27	1:05	1:30
waktu test 1 individu (dtk)	9	5	6

4.1.3 Analisis Pengujian

Kedua pengujian diatas menunjukkan bahwa semakin banyak jumlah *state* yang terlibat menyebabkan proses pelatihan menjadi semakin lama. Hal ini disebabkan karena bertambahnya kompleksitas perhitungan, baik dalam prosedur *doubly embedded forward-backward* maupun prosedur reestimasi model. Bertambahnya jumlah

state juga mengakibatkan meningkatnya persentase pengenalan, walaupun tidak signifikan.

Pengujian secara mendatar dan menurun menghasilkan beda persentase pengenalan kurang dari 1%, tetapi waktu yang dibutuhkan untuk melakukan pengenalan bertambah dari 10 detik (pada pengujian secara mendatar) hingga 4 detik (pada pengujian secara menurun). Perbedaan waktu pengujian untuk pengujian secara menurun berkisar 50% disebabkan bentuk matriks observasi pada pengujian secara menurun memiliki jumlah kolom yang lebih sedikit sehingga perhitungan pada algoritma *doubly embedded viterbi* semakin singkat.

Besarnya jumlah *cluster* juga berpengaruh pada persentase pengenalan dan waktu pengenalan. Dengan bertambahnya jumlah *cluster* maka semakin sedikit informasi dari Nilai Eigen yang tereduksi sehingga persentase pengenalan lebih tinggi tetapi akan memperlama proses pengenalan sebab kompleksitas perhitungan bertambah.

Dari hasil pengujian, variasi pose yang terdapat pada citra uji maupun penggunaan kaca mata masih dapat ditangani dengan baik oleh sistem ini.

5. Kesimpulan dan Saran

5.1 Kesimpulan

Berdasarkan analisa terhadap hasil pengujian dapat ditarik kesimpulan sebagai berikut :

1. Pengenalan wajah menggunakan *Discrete Pseudo-2D Hidden Markov Model* dengan ekstraksi ciri menggunakan *Principal Component Analysis* dan *K-Means* clustering menghasilkan tingkat pengenalan hingga 80,75% baik pada pengujian secara mendatar dan pengujian secara menurun.
2. *Cluster* sebesar 256 dapat memperkecil rentang nilai eigen pada proses PCA namun masih menghasilkan tingkat pengenalan di antara 79,75% hingga 80,75%.
3. Pengujian HMM secara menurun memiliki tingkat pengenalan yang hampir sama dibanding dengan pengujian secara mendatar, tetapi memiliki waktu pengenalan yang lebih singkat. Pemilihan bentuk matriks observasi sangat berpengaruh terhadap waktu pengenalan. Agar waktu pengenalan lebih singkat, diusahakan agar jumlah kolom matriks observasi sesedikit mungkin.
4. Pada kedua jenis percobaan yang telah dilakukan, jumlah state yang menghasilkan persentase pengenalan terbesar adalah 6-6-6, tetapi variasi state yang dilakukan tidak mempengaruhi persentase pengenalan secara signifikan.
5. Variasi pose yang terdapat pada citra uji masih dapat ditangani dalam percobaan ini.

5.2 Saran

Berdasarkan analisa hasil pengujian, untuk pengembangan lebih lanjut disarankan:

1. Menggunakan *Continuous Pseudo-2D Hidden Markov Model*, mengingat Nilai Eigen yang diperoleh dari proses PCA memiliki rentang nilai yang kontinyu.
2. Menggunakan citra wajah yang telah melalui proses pendeteksian dan pemotongan daerah dahi dan dagu.
3. Menggunakan citra wajah dengan variasi pose yang lebih ekstrim dan berbagai variasi pencahayaan.

Daftar Pustaka

- [1] Lin, Shang-Hung, Ph.D., *An Introduction to Face recognition Technology*, Informing Science Special Issue on Multimedia Informing Technologies – Part 2 Vol. 3 No. 1, 2000
- [2] Imagis Technologies Inc., ID-2000 SDK Face and Image Recognition SDK, www.imagistechnologies.com. Diunduh tanggal 15 Januari 2003.
- [3] Olivetti Research Laboratory, 1992-1994. Face Database, Cambridge, UK. <http://www.uk.research.att.com/facedatabase.html>. Diunduh tanggal 3 Februari 2003.
- [4] Hidden Markov Model, http://www.cse.sc.edu/~wuz/hmm_readme.html. Diunduh tanggal 5 Februari 2003.
- [5] Rabiner & Juang., *Fundamentals of Speech Recognition*, New Jersey: Prentice Hall, 1993
- [6] Nefian, Ara., *A Hidden Markov Model-Based Approach for Face Detection and Recognition*, Georgia Institute of Technology, August 1999
- [7] A Tutorial on Clustering Algorithms, http://www.elet.polimi.it/upload/matteucc/Clustering/tutorial_html/kmeans.html. Diunduh tanggal 15 Februari 2003
- [8] Software Development Lohninger, www.lohninger.com. Diunduh tanggal 1 Maret 2003.
- [9] K-Means Source Code, <http://www.geocities.com/egmlacerda/kmeans.zip>. Diunduh tanggal 5 Maret 2003.