

SISTEM PENGENALAN WAJAH *REAL-TIME* DALAM RUANG *EIGEN* DENGAN SEGMENTASI BERDASARKAN WARNA KULIT

Agus Buono, Ahmad Ridha, Hanief Bastian

Abstrak

Pada saat ini banyak aplikasi-aplikasi bidang keamanan yang potensial untuk dikembangkan dengan menggunakan tambahan sistem yang memiliki kemampuan untuk mendeteksi dan mengenali wajah secara otomatis, seperti sistem kamera pengawas, sistem untuk kontrol akses suatu ruangan, dan sistem keamanan layanan perbankan. Akan tetapi sistem-sistem tersebut baru dapat dinilai baik apabila mampu memberikan ketepatan identifikasi yang tinggi dan bekerja secara *real-time*.

Pada penelitian ini akan dikembangkan suatu sistem pengenalan wajah secara *real-time*. Sistem ini memiliki dua tahapan utama yaitu tahap pendeteksian wajah dan tahap pengenalan wajah. Pada tahap pendeteksian wajah, sistem akan mencari lokasi wajah berdasarkan informasi warna kulit manusia yang bisa didapatkan pada suatu citra pada ruang warna HSV (Hue Saturation Value). Sedangkan untuk tahap pengenalan wajah digunakan model Jaringan Syaraf Tiruan (JST) dengan algoritma pembelajaran Propagasi Balik. Metode *Eigenface* digunakan untuk mereduksi data sebelum digunakan sebagai input jaringan.

Sistem dibangun dengan graphical user interface (GUI) sehingga sistem mudah digunakan dan user-friendly. Sistem diuji baik secara *real-time* maupun offline. Pengujian secara *real-time* dilakukan dengan menggunakan parameter proporsi PCA 90%, JST dengan 30 neuron hidden, toleransi galat 0.00001, dan laju pembelajaran 0.1. Pada pengujian *real-time* sistem meng-capture citra dari camcorder setiap 0.50 detik, lalu citra tersebut dijadikan sebagai input tahap pendeteksian wajah untuk dicari lokasi wajah. Bila ditemukan obyek wajah pada citra tersebut, maka wajah tersebut akan diidentifikasi pada tahap pengenalan wajah. Generalisasi yang dihasilkan pada pengujian ini adalah sebesar 9.476% dengan rata-rata waktu pengujian (mulai dari akuisisi citra, deteksi wajah, sampai pengenalan wajah) hanya membutuhkan 0.242 detik, hal ini menunjukkan bahwa sistem dapat bekerja secara *real-time*. Sedangkan dari hasil pengujian secara offline didapatkan parameter-parameter optimal yaitu proporsi PCA 90%, JST dengan 40 neuron hidden, toleransi galat 0.0001, dan laju pembelajaran 0.3. Dengan penggunaan parameter-parameter tersebut sistem dapat memberikan generalisasi tertinggi 91.429% baik untuk testing set A ataupun testing set B.

Kata kunci: Sistem pengenalan wajah, deteksi wajah, *eigenface*, Jaringan Syaraf Tiruan (JST), propagasi balik.

PENDAHULUAN

Latar Belakang

Mengawasi dan mengenali seseorang baik dari foto, video, ataupun bertatap muka langsung adalah tugas yang mudah bagi manusia. Namun tugas ini sulit sekali apabila dikerjakan terus-menerus dalam jangka waktu yang relatif lama tanpa merasa lelah ataupun kehilangan konsentrasi.

Sistem pengenalan wajah otomatis adalah jawaban yang tepat untuk masalah ini. Sistem dapat mengawasi suatu area selama 24 jam per hari dan mengenali siapapun yang memasuki area tersebut.

Banyak aplikasi-aplikasi bidang keamanan yang potensial untuk dikembangkan dengan menggunakan tambahan sistem yang memiliki kemampuan untuk mendeteksi dan mengenali wajah secara otomatis, antara lain:

- Kamera pengawas
- Kontrol akses suatu ruangan
- Metode keamanan tambahan untuk transaksi *Automatic Teller Machine* (ATM)

Suatu sistem yang baik harus mampu memberikan ketepatan identifikasi yang tinggi dan bekerja secara *real-time*.

Tahapan pertama pada sistem pengenalan wajah *real-time* adalah tahap pendeteksian

wajah. Tahap pendeteksian wajah dilakukan untuk menemukan lokasi wajah pada suatu citra. Lokasi wajah dapat diprediksi dengan menggunakan informasi warna kulit manusia.

Tahap berikutnya adalah tahap pengenalan wajah. Keberhasilan tahap pengenalan wajah ditentukan oleh metode yang digunakan untuk menganalisa dan mengklasifikasi pola-pola yang terdapat dalam citra wajah. Salah satu metode yang dapat digunakan untuk sistem pengenalan wajah adalah jaringan syaraf tiruan (JST). Salah satu jaringan yang cukup handal untuk melakukan pengenalan pola termasuk pengenalan wajah adalah jaringan syaraf tiruan propagasi balik.

Kendala yang terbesar pada jaringan syaraf tiruan adalah ketidakmampuan jaringan dalam menangani data *input* yang memiliki dimensi yang besar. Salah satu metode yang dapat merepresentasikan citra wajah dalam bentuk yang lebih sederhana adalah metode *eigenface*.

Tujuan Penelitian

Tujuan dari penelitian ini antara lain:

1. Mengimplementasikan metode pendeteksian wajah berdasarkan informasi warna kulit manusia.
2. Mengimplementasikan metode *eigenface* untuk mereduksi data.
3. Mengimplementasikan Jaringan Syaraf Tiruan Propagasi Balik dalam mengenali pola citra wajah.
4. Membangun suatu sistem yang mampu mendeteksi dan mengenali wajah-wajah secara *real-time*.

Ruang Lingkup

Ruang lingkup penelitian ini antara lain:

1. Penelitian terbatas pada *input* citra wajah yang menghadap frontal dengan lima ekspresi wajah.
2. Setiap citra hanya boleh mengandung satu obyek wajah.
3. Penggunaan lingkungan pengujian yang sederhana baik *background* maupun pencahayaan.

TINJAUAN PUSTAKA

Citra Digital dan Representasinya

Citra digital adalah citra yang telah dikonversi menjadi format biner (terdiri dari nilai logika 0 atau 1) yang dapat dibaca oleh komputer (Bovik, 2000).

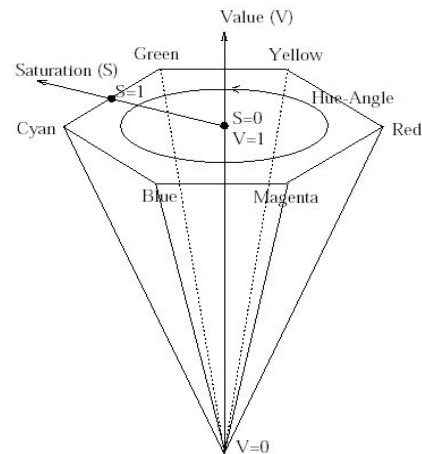
Suatu citra digital dapat direpresentasikan dalam bentuk matriks. Setiap elemen matriks menyimpan nilai intensitas dari koordinat

spasial citra digital. Elemen matriks ini disebut *image elements*, *pixels*, atau *pels*.

Citra HSV (*Hue Saturation Value*)

Selain menggunakan ruang warna RGB, suatu warna juga dapat direpresentasikan sebagai komponen *hue*, *saturation*, dan *value*. Ruang warna HSV memiliki bentuk *hexcone* seperti yang ditunjukkan pada Gambar 1 (Sobottka & Pitas, 1996a).

Citra HSV dapat direpresentasikan sebagai *array* berukuran $m \times n \times 3$. *Array* ini mendefinisikan komponen *hue*, *saturation*, dan *value* untuk setiap *pixel*.



Gambar 1. Ruang warna HSV.

Normalisasi

Proses pembelajaran JST dapat dikerjakan lebih efisien jika dilakukan praproses tertentu pada *input* jaringan. Menurut Mathworks (1999), praproses dapat dilakukan dengan cara menormalisasi data. Tujuan normalisasi ini adalah untuk mendapatkan data dengan *mean* nol dan standar deviasi sama dengan satu.

Jika *training set* dinormalisasi menggunakan langkah-langkah di atas, setiap citra *input* baru \mathbf{G} juga harus dinormalisasi dengan menggunakan *mean* dan standar deviasi setiap baris matriks \mathbf{A} .

Metode Eigenface

Metode *eigenface* merupakan suatu aplikasi dari analisis komponen utama (*principal component analysis/PCA*) untuk merepresentasikan citra-citra wajah ke dalam bentuk yang lebih sederhana.

Metode PCA memiliki tiga dampak yaitu PCA mengortogonalkan komponen-komponen pada vektor *input* (sehingga komponen-komponen tersebut tidak saling berkorelasi), PCA mengurutkan komponen-

komponen ortogonal yang dihasilkan (komponen-komponen utama) sehingga komponen dengan akar ciri terbesar ada di urutan pertama, dan PCA mengeliminasi komponen-komponen yang kurang memberikan kontribusi terhadap keragaman pada himpunan data (Mathworks, 1999).

Suatu vektor citra baru \mathbf{F} yang berdimensi n^2 dan sudah dinormalisasi dapat direpresentasikan menjadi vektor $\mathbf{\Omega}$ dengan dimensi yang lebih sederhana dengan menggunakan sebanyak k *eigenface* terbaik (*eigenface* yang memiliki akar ciri terbesar).


Penentuan nilai k yang digunakan dapat dihitung dengan:

$$proporsi = \frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^{n^2} \lambda_i} \times 100\%$$

Pengenalan Wajah

A. Teori Dasar Jaringan Syaraf Tiruan

Menurut Fausett (1994), jaringan syaraf tiruan adalah suatu sistem pengolah informasi yang memiliki karakteristik tertentu yang serupa dengan jaringan syaraf biologis. Sebagai contoh, suatu *neuron* Y , diilustrasikan pada Gambar 2.



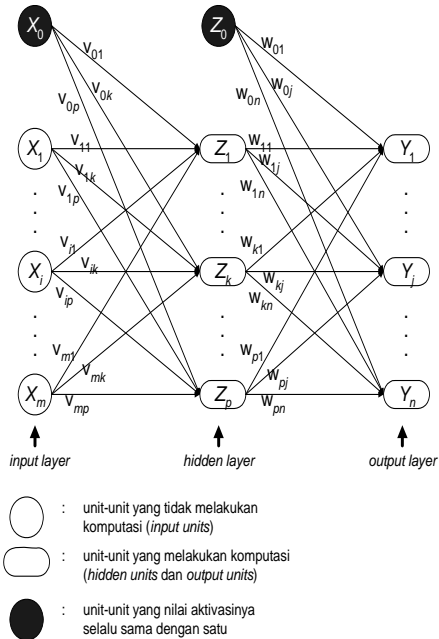
Gambar 2. *Neuron* (tiruan) sederhana.

Nilai aktivasi (*output*) y untuk *neuron* Y ditentukan oleh fungsi aktivasi terhadap *input* yang diterimanya, $y = f(y_in)$.

B. Jaringan Syaraf Tiruan Propagasi Balik

Propagasi balik merupakan algoritme pembelajaran yang terawasi (*supervised learning*) dan biasanya digunakan oleh jaringan *multilayer* untuk mengubah bobot-bobot yang terhubung dengan semua *neuron* pada *hidden layer* (Kusumadewi, 2004). Jaringan dengan algoritme ini disebut dengan jaringan syaraf propagasi balik. Arsitektur

JST propagasi balik dengan satu *hidden layer* ditunjukkan pada Gambar 3.



Gambar 3. Jaringan syaraf tiruan propagasi balik dengan satu *hidden layer*.

Proses pelatihan jaringan propagasi balik melibatkan tiga tahap, yaitu:

- *Feedforward* untuk penghitungan nilai aktivasi.
- Propagasi balik galat
- Penyesuaian bobot-bobot jaringan

Namun sebelum proses pelatihan dilakukan, inisialisasi bobot awal merupakan satu hal yang perlu diperhatikan, mengingat nilai bobot awal sangat mempengaruhi kinerja akhir jaringan. Inisialisasi bobot awal dapat dilakukan menggunakan metode Nguyen-Widrow.

Pendeteksian Wajah

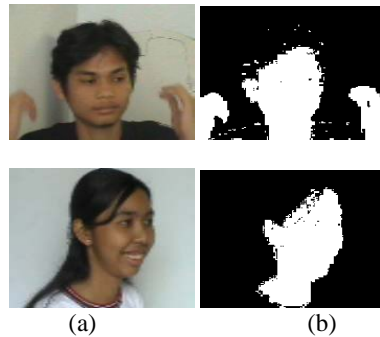
A. Segmentasi Warna Kulit Manusia

Suatu wajah dapat dikarakterisasi salah satunya adalah berdasarkan warna kulit. Segmentasi warna kulit manusia dapat dilakukan pada citra dalam ruang warna *Hue-Saturation-Value* (HSV).

Untuk segmentasi area warna kulit hanya diperlukan komponen *hue* dan *saturation* untuk membedakan informasi warna. Komponen-komponen tersebut sangat mirip dengan persepsi penglihatan manusia terhadap suatu warna (Sobottka & Pitas, 1996b). Komponen *value* tidak digunakan untuk menghindari pengaruh tingkat pencahayaan.

Merujuk pada Sobottka & Pitas (1996a), warna kulit manusia dapat didefinisikan dengan memberikan rentang *hue* dan *saturation* $H_{\min} = 0^0$, $H_{\max} = 50^0$, $S_{\min} = 0.23$, dan $S_{\max} = 0.68$.

Dengan penentuan nilai ambang komponen-komponen *hue* (H) dan *saturation* (S), area kulit dapat ditemukan seperti yang ditunjukkan pada Gambar 4.



Gambar 4. Hasil segmentasi berdasarkan warna kulit: (a) citra berwarna dan (b) citra tersegmentasi.

B. Verifikasi Input Menggunakan Eigenface

Pada Gambar 4, terlihat bahwa bagian tubuh selain wajah, seperti tangan, juga akan tersegmentasi. Untuk itu, perlu dilakukan verifikasi terlebih dahulu apakah area yang tersegmentasi merupakan wajah atau bukan.

Mengacu pada penelitian dari Turk dan Pentland (1991), kehadiran obyek wajah dapat ditentukan dengan menghitung jarak kuadrat (ϵ^2) antara vektor yang ternormalisasi \mathbf{F} dengan proyeksinya terhadap “ruang wajah” \mathbf{F}_f .

$$\epsilon^2 = \|\Phi - \Phi_f\|^2$$

$$\Phi_f = \sum_{i=1}^k \omega_i u_i$$

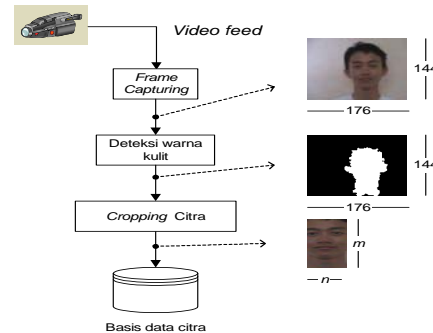
Dengan menentukan nilai ambang untuk ϵ^2 , dapat ditentukan ada tidaknya area wajah pada citra \mathbf{G} .

METODE PENELITIAN

Pada penelitian ini, kinerja sistem diuji baik secara *real-time* maupun *offline*. Pengujian secara *real-time* bertujuan untuk mengetahui kecepatan sistem dalam mendeteksi dan mengenali wajah dalam lingkungan *real-time*. Sedangkan, pengujian *offline* bertujuan untuk mengetahui pengaruh parameter-parameter JST pada kinerja sistem.

Akuisisi Citra-Citra Pelatihan

Akuisisi citra dilakukan dengan menggunakan *digital camcorder* dan dibantu dengan *software VFM (Vision for Matlab)* dengan ukuran *window* $144 \times 176 \text{ pixel}$. Secara garis besar, proses akuisisi citra pelatihan dapat dilihat pada Gambar 5.



Gambar 5. Diagram proses akuisisi citra pelatihan.

Proses *cropping* terdiri dari dua langkah yaitu:

1. Pemotongan pertama dilakukan pada sisi kiri dan kanan area tersebut. Suatu kolom akan dihilangkan apabila kolom tersebut memiliki jumlah *pixel* warna kulit kurang dari 65% dari total *pixel* pada kolom tersebut.
2. Hasil dari langkah 1 akan dipotong kembali pada sisi atas dan bawah. Suatu baris akan dihilangkan apabila baris tersebut memiliki jumlah *pixel* warna kulit kurang dari 90% dari total *pixel* pada baris tersebut.

Citra-citra hasil dari proses di atas membentuk himpunan citra pelatihan (*training set*). Untuk *training set*, terdapat tujuh orang model dan masing-masing akan diambil lima citra dengan ekspresi yang berbeda, sehingga total citra pelatihan adalah 35 citra. Citra-citra pelatihan disimpan dalam *harddisk* dengan format BMP dan mode RGB.

Struktur Jaringan Syaraf Tiruan

Pada penelitian ini digunakan model jaringan syaraf tiruan dengan struktur yang ditunjukkan pada Tabel 1.

Tabel 1. Struktur jaringan syaraf tiruan

Karakteristik	Spesifikasi
Arsitektur	1 <i>hidden layer</i>
<i>Input neurons</i>	Dimensi PCA
<i>Hidden neurons</i>	
- <i>Real-time Test</i>	30

- <i>OfflineTest</i>	10, 20, 30, 40, 50, 60, 70, 80, 90, 100
<i>Output neurons</i>	7
Metode pembelajaran	Propagasi balik
Inisialisasi bobot	Nguyen-Widrow
Fungsi aktivasi	Sigmoid biner
Toleransi galat	
- <i>Real-time Test</i>	0.00001
- <i>Offline Test</i>	0.1, 0.01, 0.001, 0.0001, 0.00001
Laju pembelajaran	
- <i>Real-time Test</i>	0.01
- <i>Offline Test</i>	0.01, 0.1, 0.2, 0.3
Maksimum <i>epoch</i>	5000

Definisi vektor target secara lengkap dapat dilihat pada Tabel 2.

Tabel 2. Definisi vektor target

Nomor model	Vektor target
1	[1 0 0 0 0 0]
2	[0 1 0 0 0 0]
3	[0 0 1 0 0 0]
4	[0 0 0 1 0 0]
5	[0 0 0 0 1 0]
6	[0 0 0 0 0 1 0]
7	[0 0 0 0 0 0 1]

Proses Pelatihan Sistem

Sebelum sistem diuji untuk dapat mengenali identitas suatu citra wajah, sistem harus dilatih terlebih dahulu.

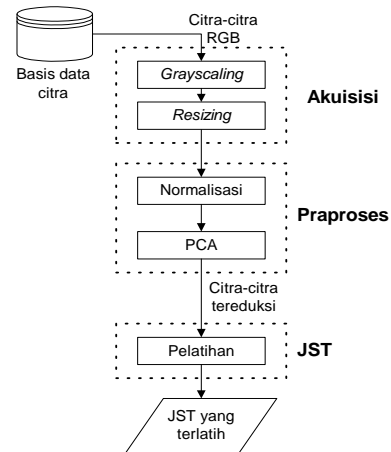
Proses pelatihan terdiri dari tiga tahap utama yaitu:

1. Akuisisi citra
 - a) *Grayscale*
Untuk mempercepat komputasi, *input* citra mode RGB akan dikonversi terlebih dahulu ke dalam bentuk *grayscale* sehingga dapat direpresentasikan sebagai *array m×n*.
 - b) *Resizing*
Citra *input grayscale* akan diseragamkan ukurannya menjadi citra *grayscale* berukuran 25×21 .
2. Praproses
 - a) *Normalisasi*
Himpunan data citra-citra wajah lalu dinormalisasi.
 - b) *PCA (Eigenface)*
Sebelum data dimasukkan ke jaringan syaraf tiruan, data diproses terlebih dahulu menggunakan PCA. Proporsi PCA yang digunakan sebesar 90%.
3. Jaringan Syaraf Tiruan (JST)

Jaringan syaraf tiruan yang digunakan adalah jaringan syaraf tiruan propagasi balik. Arsitektur JST yang digunakan yaitu

multi-layer perceptron dengan satu *hidden layer*. Pada tahap ini JST akan menyesuaikan bobot-bobotnya sehingga dapat mengenali pola *training set* dengan baik.

Secara garis besar, proses pelatihan sistem dapat dilihat pada Gambar 6.



Gambar 6. Diagram proses pelatihan sistem.

Proses Pengenalan Wajah

A. Pengujian secara *Real-time*

Dalam mengenali citra wajah, sistem harus melalui serangkaian tahapan seperti yang ditunjukkan pada Gambar 7. Secara garis besar, proses pengenalan wajah secara *real-time* harus melalui empat tahap utama yaitu:

1. Akuisisi data (*Capturing*)

Camcorder selalu mengawasi daerah jangkauannya dan ditampilkan dalam *window* berukuran 144×176 . Sistem akan meng-*capture* citra setiap 0.50 detik.

2. Deteksi wajah

- a) Segmentasi warna kulit

Citra hasil proses *capturing* akan diubah dari ruang warna RGB menjadi ruang warna HSV. Dari citra HSV ini kemudian dideteksi area-area yang mengandung warna kulit.

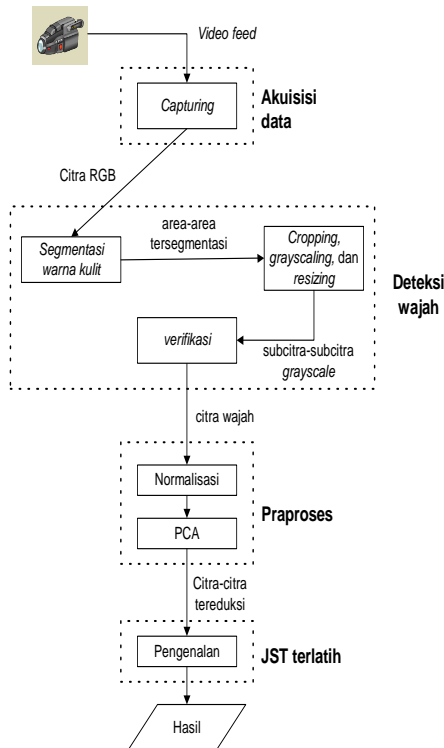
- b) *Cropping, Grayscale, dan Resizing*

Area-area tersegmentasi kemudian di-*crop* untuk mereduksi bagian-bagian yang kurang penting. Proses *cropping* ini sama dengan proses *cropping* pada akuisisi data pelatihan. Lalu citra hasil *cropping* diubah ke dalam format *grayscale* dan diubah skalanya menjadi citra berukuran 25×21 *pixel* sesuai dengan ukuran citra pada *training set*.

- c) Verifikasi *input* wajah

Subcitra-subcitra *grayscale* dari proses sebelumnya akan diverifikasi apakah citra

tersebut mengandung wajah manusia atau tidak. Verifikasi ini menggunakan informasi ruang wajah dari *training set*. Jarak kuadrat (ϵ^2) antara vektor citra ternormalisasi dengan proyeksinya terhadap “ruang wajah” ditentukan sebesar 30 ($\epsilon^2 = 30$).



Gambar 7. Diagram proses pengenalan wajah secara *real-time*.

3. Praproses

a) Normalisasi

Subcitra *grayscale* yang mengandung wajah lalu dinormalisasi menggunakan nilai *mean* dan standar deviasi dari *training set*.

b) PCA (*Eigenface*)

Dimensi subcitra wajah direduksi melalui proses PCA.

4. Jaringan Syaraf Tiruan (JST)

Hasil dari tahap praproses akan menjadi masukan bagi JST yang bertugas untuk mengenali pola citra *input*.

B. Pengujian secara *Offline*

Pengujian *offline* ini bertujuan untuk menemukan komposisi parameter-parameter JST yang optimal.

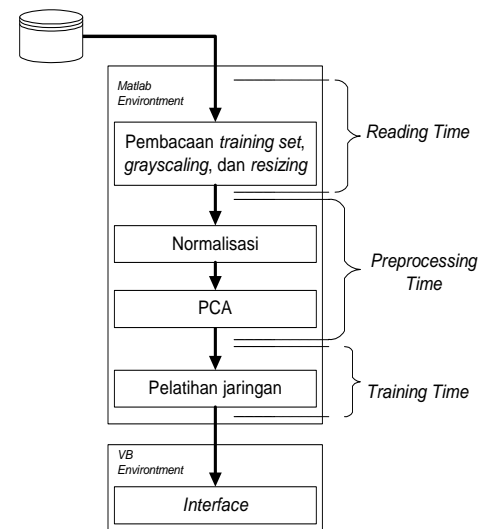
Pada pengujian *offline*, terdapat 2 himpunan citra (*testing set*) yaitu *testing set A* dan *testing set B*. *Testing set A* merupakan

citra-citra yang disimpan dari hasil pengujian secara *real-time*. Hal ini bertujuan agar citra *input* untuk pengujian secara *real-time* dan *offline* adalah citra yang sama. *Testing set A* digunakan untuk mencari parameter-parameter JST yang optimal. Sedangkan *testing set B* digunakan untuk menguji kinerja JST yang menggunakan parameter-parameter yang sudah optimal. Citra-citra pada *testing set B* adalah citra-citra yang berbeda dengan citra-citra pada *training set* maupun *testing set A*. *Testing set A* dan *testing set B* terdiri citra-citra dari tujuh model, masing-masing model akan diambil 15 citra dengan lima ekspresi yang berbeda sehingga pada masing-masing *testing set* terdapat adalah 105 citra.

Parameter Penilaian Sistem

A. Proses Pelatihan Sistem


Parameter-parameter yang dinilai pada proses pelatihan sistem adalah *reading time*, *preprocessing time*, dan parameter kecepatan jaringan dalam mempelajari semua pola *training set* baik dalam satuan detik (*training time*) maupun dalam satuan *epoch*. Penghitungan parameter-parameter ini ditunjukkan pada Gambar 8.



Gambar 8. Penghitungan parameter-parameter penilaian pada proses pelatihan sistem.

B. Proses Pengenalan Wajah

Pada proses pengenalan wajah parameter yang akan dinilai adalah lamanya waktu pengujian (*testing time*) untuk setiap citra. Penghitungan *testing time* ditunjukkan pada Gambar 9.



Gambar 9. Penghitungan parameter *testing time* pada proses pengenalan wajah.

Selain itu akan dinilai parameter generalisasi untuk mengetahui tingkat ketepatan jaringan dalam mengenali pola *input*. Secara matematis generalisasi dapat ditulis sebagai berikut:

$$\text{Generalisasi} = \frac{\text{Jumlah pola dikenali}}{\text{Jumlah seluruh pola}} \times 100\%$$

Lingkungan Pengembangan

Sistem pengenalan wajah ini dibangun dan diuji menggunakan sistem dengan spesifikasi sebagai berikut:

1. Perangkat Keras
 - Prosesor Intel Pentium IV 2.4 GHz
 - Memori 256 MB
 - *Digital camcorder* Panasonic DS-65
 - USB port
2. Perangkat Lunak
 - Sistem operasi Microsoft Windows XP
 - Matlab versi 6.5
 - Visual Basic 6

HASIL DAN PEMBAHASAN

Dimensi Baru

Untuk mencapai proporsi PCA 90% diperlukan 14 vektor ciri yang memiliki akar ciri terbesar pertama dari 525 vektor ciri, sehingga akan terbentuk “ruang wajah” berdimensi 14. Dengan memproyeksikan setiap citra pada *training set* ke “ruang wajah”, data citra dapat direduksi menjadi vektor Ω berdimensi 14. Hal ini menunjukkan bahwa pada penelitian ini metode *eigenface*/PCA berhasil mereduksi citra sebesar $(525 - 14) / 525 \times 100\% = 97.33\%$.

Pengujian secara *Real-time*

Arsitektur JST yang akan digunakan pada pengujian ini memiliki 30 *hidden neuron*, toleransi galat 0.00001, dan laju pembelajaran 0.01.

Pada tahap pelatihan sistem, sistem memerlukan *reading time* 0.500 detik, *preprocessing time* 2.078 detik, dan proses pelatihan jaringan memerlukan 259 *epoch* dalam waktu (*training time*) sebesar 1.688 detik untuk mencapai toleransi galat. Hasil pengenalan wajah dapat dilihat pada Tabel 3 dengan nilai 1 menunjukkan citra yang berhasil dikenali dengan benar dan nilai menunjukkan citra yang gagal dikenali dengan benar.

Tabel 3. Hasil identifikasi pada pengujian secara *real-time*

		MODEL						
		1	2	3	4	5	6	7
Ekspresi 1	Citra 1	0	1	1	1	1	1	1
	Citra 2	0	1	1	1	1	1	1
	Citra 3	1	1	1	1	1	1	1
Ekspresi 2	Citra 1	0	1	1	0	1	1	1
	Citra 2	1	1	1	1	1	1	1
	Citra 3	0	1	1	1	1	1	1
Ekspresi 3	Citra 1	1	1	1	1	1	1	1
	Citra 2	1	1	1	1	1	1	1
	Citra 3	1	1	1	1	1	1	1
Ekspresi 4	Citra 1	1	1	1	0	1	1	1
	Citra 2	1	1	0	0	1	1	1
	Citra 3	1	1	1	1	1	1	1
Ekspresi 5	Citra 1	1	1	1	1	1	1	1
	Citra 2	1	1	0	1	1	1	1
	Citra 3	0	1	1	1	1	1	1

Hasil pengenalan wajah menunjukkan bahwa dari 105 citra yang diambil terdapat 95 citra dikenali dengan benar atau 10 citra yang gagal dikenali dengan benar. Dari hasil ini maka dapat ditentukan generalisasi sistem sebesar $95 / 105 \times 100\% = 90.476\%$.

Pada pengujian ini setiap citra dapat dikenali dalam waktu (*testing time*) yang bervariasi dari 0.218 - 0.266 detik, dengan rata-rata 0.242 detik.

Pengujian secara *Offline*

1. Menentukan parameter-parameter JST yang optimal

Pada pengujian ini dilakukan tiga percobaan untuk menemukan kombinasi optimal antara *hidden neuron* (HN), toleransi galat (E_r), dan laju pembelajaran (LP). *Testing set* yang digunakan adalah *testing set A*.

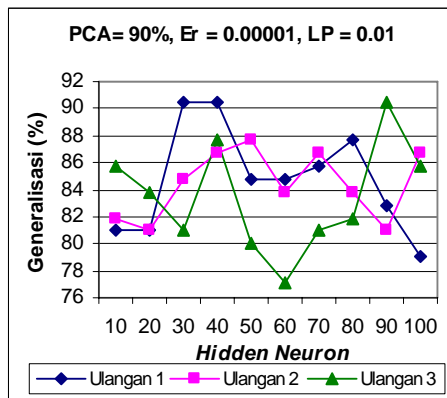
1.1. Percobaan 1: *Hidden Neuron* (HN)

Pada percobaan ini, jumlah *hidden neuron* diubah-ubah dengan tujuan untuk dapat menemukan jumlah *hidden neuron* yang optimal sehingga menghasilkan generalisasi

yang baik. Jumlah *hidden neuron* (HN) yang digunakan JST dalam percobaan adalah 10, 20, 30, 40, 50, 60, 70, 80, 90, dan 100 *neuron*, dengan toleransi galat (Er) JST sebesar 0.00001, laju pembelajaran (LP) JST sebesar 0.01 dan proporsi PCA 90% sehingga total ada 10 perlakuan. Proses pelatihan dan pengujian diulang sebanyak tiga kali untuk setiap perlakuan.

Generalisasi maksimum yang dihasilkan oleh JST adalah sebesar 90.476% (95 citra pada *testing set* A dikenali dengan benar). Generalisasi tersebut tercapai saat jumlah *hidden neuron* sebanyak 30, 40, dan 90 *neuron*. Dari tiga kali pengulangan, didapatkan rata-rata generalisasi JST dengan 40 *hidden neuron* yaitu sebesar 88.254%, sedangkan rata-rata generalisasi dari JST dengan 30 *hidden neuron* dan 90 *hidden neuron* masing-masing sebesar 85.397% dan 84.762%. Hal ini menunjukkan bahwa JST dengan 40 *hidden neuron* lebih stabil daripada JST dengan 30 *hidden neuron* atau 90 *hidden neuron* seperti yang ditunjukkan Gambar 10.

Dari uraian di atas dapat ditentukan bahwa kombinasi proporsi PCA 90% dan arsitektur JST dengan 40 *hidden neuron* diharapkan dapat menghasilkan sistem yang stabil dan memiliki generalisasi tinggi.



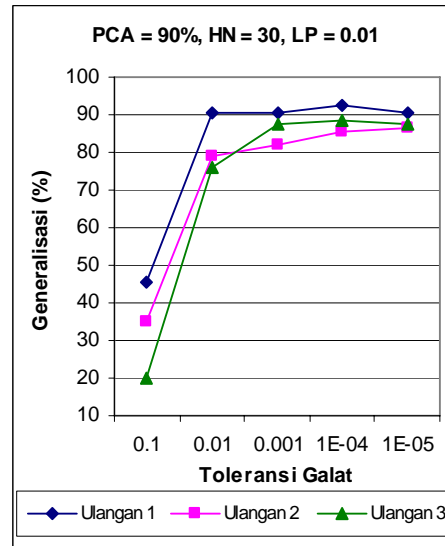
Gambar 10. Grafik perbandingan generalisasi terhadap jumlah *hidden neuron*.

1.2. Percobaan 2: Toleransi Galat (Er)

Percobaan selanjutnya bertujuan untuk menentukan toleransi galat (Er) yang optimal, sehingga didapatkan generalisasi yang baik.

Sistem akan diuji dengan menggunakan proporsi kumulatif PCA 90%, 40 *hidden neuron*, laju pembelajaran 0.01, dan 5 toleransi galat (Er) yang berbeda yaitu 0.1, 0.01, 0.001, 0.0001, dan 0.00001, yang masing-masing akan diulang sebanyak 3 kali.

Dapat dilihat pada Gambar 11, bahwa pada setiap pengulangan generalisasi terus meningkat seiring dengan penurunan nilai toleransi galat. Hanya saja pada saat toleransi galat 0.0001 mulai terlihat gejala sistem yang *overfit*.



Gambar 11. Grafik perbandingan generalisasi terhadap toleransi galat.

Generalisasi tertinggi sebesar 92.381% dicapai pada toleransi galat 0.0001 dari pengulangan pertama. Dari hasil ini dapat diambil kesimpulan bahwa penggunaan toleransi galat 0.0001 cukup untuk menghasilkan sistem dengan generalisasi yang baik.

1.3. Percobaan 3: Laju Pembelajaran (LP)

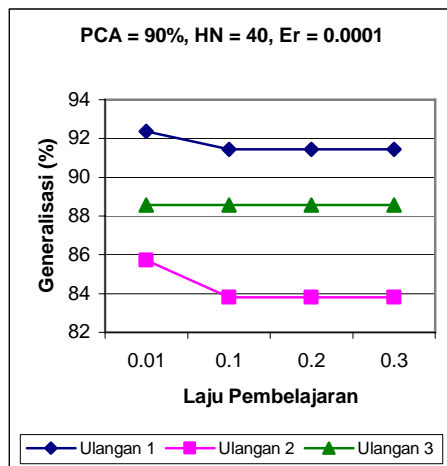
Percobaan selanjutnya bertujuan untuk menentukan laju pembelajaran. Pada percobaan ini akan diuji 4 tingkat laju pembelajaran (LP) yaitu 0.01, 0.1, 0.2, 0.3 dan masing-masing diulang sebanyak 3 kali.

Sesuai dengan hasil dari percobaan sebelumnya, pada percobaan ini digunakan 40 *hidden neuron*, toleransi galat 0.0001, dan proporsi kumulatif PCA 90%.

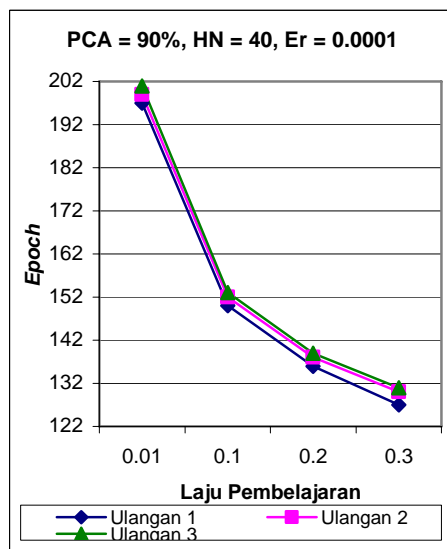
Dari Gambar 12, generalisasi maksimum dicapai pada saat laju pembelajaran 0.01 dengan nilai sebesar 92.381%. Akan tetapi JST dengan laju pembelajaran 0.01 membutuhkan *epoch* dan waktu pembelajaran yang relatif besar, sehingga lebih efisien untuk menggunakan JST dengan laju pembelajaran 0.3 (Gambar 13 dan Gambar 14). JST dengan laju pembelajaran 0.3 menghasilkan generalisasi 91.429% dengan jumlah *epoch*

terkecil dan waktu pembelajaran tercepat untuk setiap pengulangan.


Dari hasil Percobaan 1, Percobaan 2, dan Percobaan 3 dapat diambil kesimpulan bahwa proporsi PCA 90%, JST dengan 40 *hidden neuron*, toleransi galat 0.0001, dan laju pembelajaran 0.3 merupakan parameter-parameter sistem yang optimal. Sistem dengan parameter-parameter tersebut mampu menghasilkan generalisasi sebesar 91.429% (96 dari 105 citra berhasil dikenali dengan benar) dengan tahap pembelajaran memerlukan 127 *epoch* dalam waktu (*training time*) sebesar 1.062 detik untuk konvergen.



Gambar 12. Grafik perbandingan generalisasi terhadap laju pembelajaran.



Gambar 13. Grafik perbandingan *epoch* terhadap laju pembelajaran.




Gambar 14. Grafik perbandingan waktu pembelajaran terhadap laju pembelajaran.

2. Menguji parameter-parameter JST yang optimal

Pengujian ini dilakukan untuk mengetahui apakah parameter-parameter sistem yang ditentukan dari percobaan-percobaan sebelumnya sudah optimal. Parameter-parameter yang optimal yang didapatkan pada percobaan sebelumnya akan digunakan kembali pada pengujian ini.

Pengujian parameter JST yang optimal terhadap *testing set B* menghasilkan generalisasi tertinggi sebesar 91.429% (96 dari 105 citra berhasil dikenali dengan benar) yaitu pada ulangan ke-1 dan ulangan ke-3, seperti yang ditunjukkan pada Gambar 15. Dari tiga kali pengulangan diperoleh rata-rata generalisasi sebesar 90.794%, rata-rata *epoch* 129.33 dan rata-rata waktu pembelajaran 1.125 detik.



Gambar 15. Grafik generalisasi pada setiap pengulangan.

Hasil ini tidak jauh berbeda dengan hasil yang dicapai untuk *testing set A*, sehingga

parameter-parameter yang disebutkan di atas dapat dikatakan sudah cukup optimal.

Kelebihan dan Keterbatasan Sistem

Kelebihan sistem. Sistem dibangun dengan *graphical user interface* (GUI) dan dapat bekerja dalam lingkungan *real-time*.

Dengan pemilihan proporsi PCA dan parameter-parameter JST (laju pembelajaran, toleransi galat, dan jumlah *hidden neuron*) yang tepat, sistem dapat mengidentifikasi dengan ketepatan tertinggi 91.429% baik untuk *testing set A* ataupun *testing set B*.

Keterbatasan Sistem. Penggunaan *background* atau pakaian yang mengandung area dengan warna yang serupa warna kulit manusia dapat mempengaruhi sistem dalam menentukan lokasi wajah.

Adanya penambahan pola baru untuk *training set* mengharuskan sistem untuk dilatih kembali agar sistem dapat mengenali pola baru tersebut.

KESIMPULAN DAN SARAN

Kesimpulan

Penggunaan metode *eigenface*/PCA dengan proporsi 90% dapat mereduksi data sampai 97.33%, dari vektor citra dengan dimensi 525 menjadi vektor baru yang berdimensi 14.

Pengujian secara *real-time* yang dilakukan dengan menggunakan proporsi PCA 90%, toleransi galat 0.00001, laju pembelajaran 0.01, dan *hidden neuron* sebanyak 30 *neuron*, memberikan hasil yang cukup baik. Sistem mampu mengidentifikasi dengan ketepatan 90.476% yang berarti 95 dari 105 *frame* berhasil dikenali dengan baik. Selain itu, kecepatan sistem dalam mengenali pola juga terbilang baik. Rata-rata waktu pengujian (mulai dari akuisisi, deteksi wajah, sampai dengan pengenalan) tiap citra hanya memerlukan 0.242 detik

Parameter-parameter yang optimal pada penelitian ini antara lain proporsi PCA 90%, JST dengan 40 *hidden neuron*, toleransi galat 0.0001, dan laju pembelajaran 0.3. Dengan parameter-parameter ini dihasilkan generalisasi maksimum sebesar 91.429% baik untuk *testing set A* ataupun *testing set B*.

Saran

Saran-saran bagi penelitian-penelitian selanjutnya antara lain:

- Menambahkan metode deteksi wajah berdasarkan warna kulit manusia dengan

metode berdasarkan bentuk oval wajah (*region based*).

- Menggunakan metode deteksi wajah yang lain seperti deteksi berdasarkan gerakan (*motion detection*).
- Optimalisasi jaringan syaraf dengan algoritme yang lebih baik misalnya algoritme genetika.

DAFTAR PUSTAKA

Bovik, A.C. 2000. Adaptive and Neural Methods for Image Segmentation. Di dalam: **Bovik, A.C.**, editor. *Handbook of Image and Video Processing*. Academic Press.

Fausett, L. 1994. *Fundamental of Neural Network. Architectures, Algorithms, and Application*. New Jersey: Prentice-Hall.

Kusumadewi, S. 2004. *Membangun Jaringan Syaraf Tiruan Menggunakan MATLAB & Excel Link*. Yogyakarta: Graha Ilmu.

Mathworks Inc. 1999. *Neural Network for Use With Matlab*. Natick: The Mathworks Inc.

Sinaga, O. 2000. Perbandingan Metode Analitik dan Holistik Pada Pengenalan Wajah Menggunakan Jaringan Syaraf Tiruan Propagasi Balik Standar. [Skripsi]. Bogor: Fakultas Matematika dan Ilmu Pengetahuan Alam. Institut Pertanian Bogor.

Sobottka, K. dan Pitas, I. 1996a. Looking for Faces and Facial Features in Color Images. <http://citeseer.lcs.mit.edu/sobottka96looking.html>. [20 Juli 2004]

Sobottka, K. dan Pitas, I. 1996b. Extraction of Facial Regions and Features using Color and Shape Information. <http://citeseer.lcs.mit.edu/sobottka96extraction.html>. [20 Juli 2004]

Turk, M. dan Pentland, A. 1991. Eigenface for Recognition. <http://www.cs.ucsb.edu/~mturk/Papers/jcn.pdf>. [20 Juli 2004]