

# PERBANDINGAN METODE EIGEN PADA PENGENALAN WAJAH

Sarbini\*, Meuthia Rachmaniah\*\*, Agus Buono\*\*

\*Jurusan Ilmu Komputer FMIPA IPB

Jl. Prof Lafran Pane 9/9 No. 32, Depok 16951

sarbintong@yahoo.com

\*\*Staff Pengajar Jurusan Ilmu Komputer FMIPA IPB

Jl. Raya Pajajaran, Bogor

tita@ilkom.fmipa.ipb.ac.id, buono@ilkom.fmipa.ipb.ac.id

## ABSTRAK

Makalah ini berisi bahasan tentang penerapan *Principal Component Analysis* (PCA) dan metode ukuran jarak (*L2/Euclidean Distance* dan *Angle*) pada identifikasi wajah. Untuk PCA digunakan proporsi kumulatif 80% dan 90% yang menurut Johnson dan Wichern dianggap dapat menggantikan data asli tanpa banyak kehilangan informasi. Aplikasi PCA dalam kajian ini memakai variasi penggunaan komponen acak dan tanpa komponen acak pada tiap proporsi. Sedangkan ukuran jarak digunakan *L2/Euclidean Distance*. Data yang dipakai adalah data dua dimensi wajah dengan menggunakan Jaringan Syaraf Tiruan Propagasi Balik Standar (JSTPBS).

Hasil kajian menunjukkan bahwa generalisasi maksimum terbaik dicapai pada *Euclidean*, *Angle*, dan PCA 80% tanpa komponen acak. Tetapi tingkat konvergensi *Angle* dan *Euclidean* lebih lama jika dibanding dengan PCA. Hal ini dikarenakan dimensi input jaringan pada *Angle* dan *Euclidean* lebih besar. Selain itu tingkat variasi pola ciri *Angle* dan *Euclidean* lebih kecil jika dibandingkan PCA. Tingkat konvergensi pada tiap metode tidak dipengaruhi jumlah neuron *hidden* yang digunakan. Demikian pula tingkat generalisasi tidak terlalu dipengaruhi jumlah neuron *hidden* apabila galat ideal tercapai.

Kata kunci : *Principle Component Analysis* (PCA), *L2/Euclidean Distance* dan *Angle*, JST Propagasi Balik Standar, *Mathematical Education*.

## 1. PENDAHULUAN

Perkembangan teknologi informasi mendorong lahirnya berbagai ilmu baru, salah satunya adalah biometrika. Biometrika adalah suatu teknik untuk menganalisa suatu fenomena berdasarkan pada keadaan biologis suatu obyek. Salah satunya adalah pada pengenalan wajah.

Konsep pengenalan wajah erat kaitannya dengan pengenalan pola. Secara garis besar pengenalan pola terbagi dua, yaitu pendekatan geometrik dan pendekatan *pictorial*. Pendekatan geometrik menggunakan konfigurasi spasial suatu wajah, seperti sudut dan jarak. Sedangkan pendekatan *pictorial* menggunakan suatu data sementara (cetakan wajah

sementara) yang kemudian menjadi acuan pengenalan wajah. Dari kedua pendekatan ini, maka muncul berbagai metode pengenalan wajah, antara lain metode *Eigen*, *Fisher Discriminant* dan *Fisherface*.

Menurut Moon dan Philips (1998) metode *Eigen* mencakup metode *Principal Component Analysis* (PCA) dan metode Ukuran Jarak. Pada kajian/penelitian ini, akan didemonstrasikan aplikasi kedua metode diatas, dengan menggunakan Jaringan Syaraf Tiruan Propagasi Balik Standar pada proses pengenalan wajah.

## 2. TINJAUAN PUSTAKA

### 2.1. Analisis Komponen Utama (PCA)

*Principal Component Analysis* atau yang juga sering disebut dengan teknik *Karhunen-Loove* memanfaatkan nilai *Eigen* (akar ciri) dengan menggunakan data citra digital (*digital image data*). Data ini merupakan suatu fungsi identitas cahaya dua dimensi  $f(x,y)$ , di mana  $x$  dan  $y$  menunjukkan koordinat spasial. Nilai  $f(x,y)$  pada tiap titik menunjukkan tingkat keabuan citra (*gray level image*) pada titik tersebut (Gonzales and Woods, 1993). Citra digital dapat berupa citra (*image*) dalam 'skala keabuan' (*gray scale*) ataupun citra berwarna (*colour image*).

Penjelasannya disajikan melalui Gambar 1 yaitu gambar yang menunjukkan representasi citra digital (*digital image representation, DIR*) yang berukuran  $m \times n$ .

$$f(x, y) = \begin{bmatrix} f(x_1, y_1) & \dots & \dots & f(x_1, y_n) \\ \vdots & & \ddots & \vdots \\ \vdots & & \ddots & \vdots \\ f(x_m, y_1) & \dots & \dots & f(x_m, y_n) \end{bmatrix}$$

Gambar 1. Representasi citra digital (DIR) berukuran  $m \times n$ .

Dari Gambar 1, maka suatu kumpulan data citra (*image data*) dapat diubah dalam suatu vektor citra dengan dimensi  $q$ , sehingga dapat dituliskan sbb:

$$\{f(x_1, y_1) \dots f(x_q, y_1), \dots, f(x_1, y_k) \dots f(x_q, y_k)\} \quad [1]$$

Kemudian nilai rata-rata dari vektor tersebut dapat dihitung dengan rumus.

$$\mu_x = \frac{1}{k} \sum_{g=1}^k x_g \quad [2]$$

Selanjutnya dari data rata-rata tersebut dicari nilai kovariansnya dengan menggunakan rumus.

$$\sum_x = \frac{1}{k} \sum_{g=1}^k (x_g - \mu_g)(x_g - \mu_g)^T \quad [3]$$

$$\sum_x = \begin{bmatrix} a_{11} & \dots & \dots & a_{1q} \\ \vdots & \ddots & & \vdots \\ \vdots & & \ddots & \vdots \\ \vdots & & & \vdots \\ a_{q1} & \dots & \dots & a_{qq} \end{bmatrix} \quad [4]$$

Dari nilai kovarian tersebut dapat ditentukan vektor ciri ( $e$ ) dan nilai ciri ( $\lambda$ ) dengan akar ciri yang sudah terurut dari yang terbesar.

Komponen utama (*principle component*) dari sejumlah  $q$  'dimensi citra' (*image dimension*) yang merupakan transformasi dari  $x$  ke  $y$  adalah sebagai berikut:

$$y_q = e_q^T x \quad [5]$$

Untuk mereduksi data, maka tidak semua komponen utama digunakan sehingga terbentuk matriks  $A_m$  berordo  $r \times q$  yang terdiri dari sejumlah  $r$  vektor ciri terbesar saja.

Galat reduksi dapat dihitung dengan rumus sbb:

$$\text{reduksi} = \sum_{i=1}^q \lambda_i - \sum_{i=1}^r \lambda_i = \sum_{i=r+1}^q \lambda_i \quad [6]$$

Penentuan proporsi dari nilai  $r$  vektor ciri dapat dihitung dengan rumus:

$$\text{Proporsi} = \frac{\sum_{i=1}^r \lambda_i}{\sum_{i=1}^q \lambda_i} \quad [7]$$

Menurut Johnson & Wichern (1998), proporsi 80% dan 90% dapat menggantikan data asli tanpa banyak kehilangan informasi. Komponen acak  $\epsilon$  kemudian dihitung dengan rumus sbb:

$$\epsilon = \text{reduksi}^2 = \sum_{i=r+1}^q y_i^2 = \left\| x^2 \right\| - \sum_{i=1}^r y_i^2 \quad [8]$$

di mana  $y$  adalah komponen utama dan  $x$  adalah data yang telah dinormalisasi.

## 2.2. Ukuran Jarak (L2/ Euclidean Distance Angle)

Menurut Moon and Philips (1998), ada beberapa macam metode ukuran jarak, tetapi pada kajian pengenalan wajah ini akan digunakan metode *squared Euclidean distance* /L2 dan *Angle*.

L2/Euclidean distance didefinisikan sebagai berikut:

$$D(x, y) = \sqrt{\sum_{i=1}^k |x_i - y_i|^2} \quad [9]$$

di mana  $k$  adalah banyaknya 'citra pelatihan' (*training image*) dan 'citra pengujian' (*testing image*).

Untuk meningkatkan kinerja L2 maka dilakukan proses normalisasi dengan mengakarkan rumus, sehingga diperoleh rumus:

$$D(x, y) = \left( \sum_{i=1}^k (x_i - y_i)^2 \right)^{1/2} \quad [10]$$

Rumus (10) sering dikenal sebagai L2 *norm*.

Konsep dasar *Angle* (sudut) hampir sama dengan konsep kosinus pada perhitungan matriks. Kosinus dapat dituliskan seperti rumus.

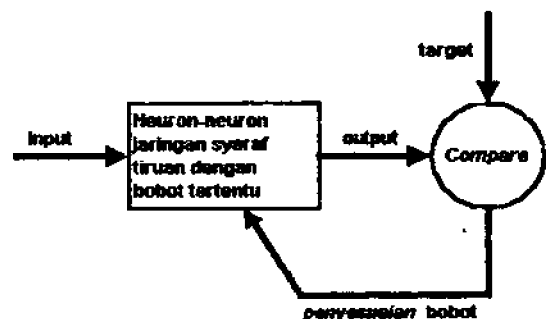
$$\text{Cos}(\alpha) = \frac{a \cdot b}{|a| |b|} \quad [11]$$

Kemudian pendekatan 'sudut' (*Angle*) dihitung melalui rumus (12).

$$D(x, y) = \frac{x \cdot y}{|x| |y|} = \frac{\sum_{i=1}^k x_i y_i}{\sqrt{\sum_{i=1}^k x_i^2} \sqrt{\sum_{i=1}^k y_i^2}} \quad [12]$$

## 2.3. Jaringan Syaraf Tiruan Propagasi Balik Standar

'Jaringan syaraf tiruan' (*artificial neural network*) merupakan gabungan dari elemen-elemen yang bekerja secara paralel (MathWorks, 1999). Konsep kerja JST meniru konsep jaringan syaraf manusia (jaringan syaraf biologis). Hal ini dijelaskan Gambar 2.



Gambar 2. Konsep kerja jaringan syaraf tiruan

Seperti terlihat di Gambar 2, bobot hubungan antar elemen atau neuron pada JST disesuaikan berdasarkan galat hasil perbandingan antar output dengan target sampai jaringan mencapai pola target.


Menurut Fauset (1994), JST merupakan suatu sistem pemrosesan informasi yang memiliki karakteristik tertentu, yaitu:

- o Arsitektur yang merupakan pola hubungan antar neuron.
- o Metode penentuan bobot pada hubungan yang disebut pelatihan (*training*) atau pembelajaran (*learning*).
- o Fungsi aktivasi yang dijalankan masing-masing neuron pada input jaringan untuk menentukan sinyal output.

Setiap neuron memiliki aktivasi berupa suatu fungsi dari input yang diterima dan mengirimnya sebagai sinyal ke beberapa neuron yang lain. Sebagai contoh neuron Y di Gambar 3 menerima input dari neuron  $X_1$ ,  $X_2$ , dan  $X_3$ . Aktivasi atau sinyal output dari ketiga neuron tersebut adalah  $x_1$ ,  $x_2$ , dan  $x_3$ . Bobot pada hubungan dari  $X_1$ ,  $X_2$ , dan  $X_3$  ke neuron Y

adalah  $w_1$ ,  $w_2$ , dan  $w_3$ . Input jaringan  $y_{in}$  ke Y adalah jumlah perkalian antara sinyal  $x_1$ ,  $x_2$ , dan  $x_3$  dengan bobotnya seperti persamaan (13):

$$y_{in} = x_1 w_1 + x_2 w_2 + x_3 w_3 \quad [13]$$



Gambar 3. Contoh neuron tiruan.

Aktivasi  $y$  dari neuron Y diperoleh dari fungsi aktivasi dari jaringan inputnya, yaitu:

$$y = f(y_{in}) \quad [14]$$

Arsitektur dari JST terdiri dari tiga macam, yaitu layer tunggal (*single layer*), layer jamak (*multilayers*), dan layer kompetitif (*competitive layer*). Layer tunggal adalah arsitektur yang memiliki satu layer hubungan bobot. Layer jamak adalah arsitektur jaringan dengan satu layer atau lebih antara input neuron dan output neuron. Sedangkan layer kompetitif adalah arsitektur yang membentuk suatu bagian dari sejumlah besar jaringan-jaringan syaraf.

Fungsi aktivasi yang umum digunakan JST adalah:

- o fungsi identitas :  $f(x)=x$  untuk semua  $x$ .
- o fungsi tangga biner (dengan nilai ambang  $\theta$ ):

$$f(x) = \begin{cases} 1 & \text{jika } x \geq \theta \\ 0 & \text{jika } x < \theta \end{cases} \quad [15]$$

- o fungsi sigmoid biner:  $f(x) = \frac{1}{1 + \exp(-x)}$  [16]

- o fungsi sigmoid bipolar:  $f(x) = \frac{1 - \exp(-x)}{1 + \exp(-x)}$  [17]

JST propagasi balik standar memiliki arsitektur lapisan jamak (*multilayer*) yaitu suatu JST dengan satu layer input, satu atau lebih layer hidden (*hidden layer*), dan satu layer output.

Menurut Fauset (1994), ada tiga tahap pelatihan pada jaringan syaraf tiruan propagasi balik yaitu pelatihan input yang bersifat umpan balik (*feed forward*), perhitungan galat propagasi balik, dan penyesuaian bobot. Inisialisasi bobot yang digunakan pada penelitian ini adalah Nguyen-Widrow. Inisialisasi Nguyen-Widrow didefinisikan sebagai berikut:

- o Hitung harga faktor pengali  $\beta$

$$\beta = 0.7n\sqrt{p} \quad [18]$$

$\beta$  = faktor pengali

$n$  = jumlah neuron pada lapisan input

$p$  = jumlah neuron pada lapisan *hidden*

- o Untuk setiap unit hidden ( $j=1,2,\dots,p$ ):

-Hitung  $v_{ij}$  (lama) yaitu bilangan acak diantara  $-0.5$  dan  $0.5$  (atau diantara  $-\gamma$  dan  $+\gamma$ )

-Tentukan bobot baru:

$$v_{ij}(\text{baru}) = \frac{\beta v_{ij}(\text{lama})}{\|v_j(\text{lama})\|} = \frac{\beta v_{ij}(\text{lama})}{\sqrt{\sum_{i=1}^p v_{ij}^2(\text{lama})}} \quad [19]$$

$v_{ij}$  (lama) adalah nilai acak antara  $-0.5$  dan  $0.5$  sedangkan bobot pada bias bernilai antara  $-\beta$  dan  $+\beta$ .

Setelah bobot diinisialisasi, proses pelatihan bisa dimulai. Pada tahap pelatihan (propagasi balik), masing-masing neuron output membandingkan nilai aktivasi dengan nilai targetnya sehingga diperoleh galat  $\delta_k$  ( $k=1,2,\dots,m$ ). Begitu juga galat  $\delta_j$  ( $j=1,2,\dots,p$ ) dihitung pada masing-masing neuron hidden.

Fungsi aktivasi yang umum digunakan adalah fungsi aktivasi sigmoid biner yang memiliki range(0,1) dan didefinisikan sebagai berikut:

$$f(x) = \frac{1}{1 + \exp(-x)} \quad [20]$$

Fungsi ini kontinu dan mempunyai turunan:

$$f'(x) = f(x)[1 - f(x)] \quad [21]$$

### 3. METODE KAJIAN

#### 3.1. Pengolahan data

'Citra wajah' (*face image*) yang akan dijadikan bahan kajian/penelitian diperoleh dari internet (ORL, 1999), yang tersimpan dalam format TIF. Citra wajah terdiri dari sepuluh wajah dengan berbagai kombinasi variasi ekspresi, sudut, maupun posisi 'Citra' (*image*) juga dibedakan antara pria dan wanita dengan ukuran asli  $92 \times 112$  pixel (Gambar 4). Total citra wajah berjumlah 100 citra yang dibagi atas 50 citra pelatihan dan 50 citra pengujian.



Gambar 4. Contoh citra wajah asli.

Untuk mempermudah pengolahan citra dilakukan cropping (Gambar 5) kemudian citra direduksi skalanya menjadi  $25 \times 30$  pixel (Gambar 6). Perubahan skala resolusi ini untuk mempercepat proses pelatihan, dan pengujian jaringan syaraf tiruan.



Gambar 5. Contoh citra yang di-cropping.



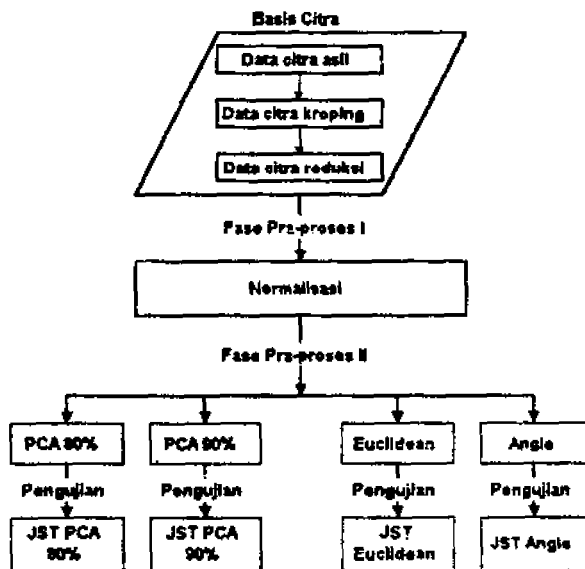
Gambar 6. Citra yang telah direduksi.

### 3. 2. Proses Pengenalan Wajah

Proses kajian/penelitian secara garis besar terdiri dari tiga tahap:

- 1 *Fase Input Data*: yakni pengambilan data citra dari basis data sekaligus dilakukan proses reduksi (*kroping*) dan memperkecil ukuran (*resize*).
- 2 *Fase Pra-proses* :  
Pra-proses I : normalisasi  
Pra-proses II : PCA 80%, PCA 90%, L2 dan *Angle*.
- 3 *Fase Jaringan Syaraf Tiruan* :  
Tahap pelatihan  
Tahap pengujian

Diagram proses pengenalan wajah ditunjukkan pada Gambar 7.



Gambar 7. Proses pelatihan/pengujian JST.

Arsitektur jaringan yang akan digunakan adalah arsitektur *multiple layers* (lapisannya banyak) dengan satu *hidden layer* (*lapis tersembunyi*). Galat yang digunakan 0.01 karena merupakan tingkat galat yang paling ideal bagi JSTPBS.

### 3. 3. Parameter Pengenalan Wajah

Parameter yang digunakan untuk mengetahui tingkat keberhasilan proses pengenalan wajah adalah konvergensi dan generalisasi. Konvergensi adalah tingkat kecepatan jaringan mempelajari pola masukkan yang dinyatakan dengan satuan waktu atau satuan *epoch*. Satu *epoch* adalah lamanya jaringan mempelajari satu kali seluruh pola pelatihan. Generalisasi adalah tingkat pengenalan jaringan dalam mengenali sejumlah pola yang diberikan. Secara

matematik generalisasi dapat dituliskan sebagai berikut:

$$\text{Generalisasi} = \frac{\text{jumlah pola dikenal}}{\text{jumlah seluruh pola}} \times 100\%$$

## 4. HASIL DAN PEMBAHASAN

### 4. 1. Lama Pra-proses

Di Tabel 1 disajikan data lamanya waktu fase pra-proses dalam detik. Data ini disajikan untuk melengkapi data-data tingkat generalisasi dan konvergensi.

Tabel 1. Lama Pra-proses

Metode	Lama Pra-proses (detik)
PCA 80% + e	87.60
PCA 80%	68.46
PCA 90% + e	90.58
PCA 90%	69.57
<i>Euclidean</i>	0.55
<i>Angle</i>	1.48

Dari Tabel 1 terlihat bahwa metode PCA membutuhkan waktu yang relatif cukup lama yaitu 87.60 detik untuk PCA 80% dengan komponen acak, 90.58 detik untuk PCA 90%, 68.46 detik untuk PCA 80% tanpa komponen acak, dan 69.57 detik untuk PCA 90 tanpa komponen acak sedangkan metode ukuran jarak membutuhkan waktu yang amat singkat yaitu sekitar 0.55 detik untuk *Euclidean* dan 1.48 detik untuk *Angle*. Dari perbedaan ini menunjukkan bahwa tingkat kompleksitas algoritma PCA lebih tinggi dibandingkan dengan metode ukuran jarak.

Lamanya waktu pada fase pra-proses tidak ada kaitannya secara langsung dengan konvergensi di jaringan. Tetapi secara keseluruhan lamanya waktu fase pra-proses dapat mempengaruhi lama pengenalan wajah.

### 4. 2. Konvergensi dari percobaan

Dari Tabel 2 terlihat bahwa metode PCA dengan dan tanpa komponen acak memerlukan jumlah epoch pelatihan yang hampir sama. Sedangkan jika dibandingkan antara PCA dengan *Euclidean* dan *Angle* terlihat perbedaan besar jumlah epoch pelatihan yang sangat besar.

Hal ini dikarenakan dimensi input ke jaringan pada *Euclidean* dan *Angle* lebih besar jika dibandingkan dengan PCA. Dari percobaan didapat fakta bahwa vektor yang akan diinputkan ke jaringan pada PCA 80% berdimensi 19 x 50, PCA 90% berdimensi 29 x 50, sedangkan pada *Euclidean* dan *Angle* berdimensi 50 x 50. Besarnya dimensi ini berpengaruh pada saat proses komputasi jaringan untuk mencapai galat tertentu.

Tabel 2. Lama dan jumlah epoch pelatihan

Metode	Lama pelatihan (detik)	Jumlah epoch* pelatihan
PCA 80% + e	8.19	70
PCA 80%	7.50	71
PCA 90% + e	8.57	71
PCA 90%	7.39	71
<i>Euclidean</i>	52.73	461
<i>Angle</i>	15.05	118

Keterangan: epoch adalah lamanya jaringan mempelajari satu kali dari seluruh pelatihan.

PCA 80% dengan komponen acak memerlukan waktu pelatihan 8.19 detik, sedangkan PCA 90% dengan komponen acak yang memerlukan waktu pelatihan 8.57 detik, PCA 80% tanpa komponen acak memerlukan waktu pelatihan 7.50 detik, dan PCA 90% tanpa komponen acak pelatihan 7.39 detik. Sedangkan pada metode *Euclidean* memerlukan waktu rata-rata 52.73 detik, dan *Angle* 15.05 detik. Dari Tabel 4 terlihat hubungan antara banyaknya epoch pelatihan dengan lama waktu pelatihan. Lamanya waktu pelatihan berbanding lurus dengan jumlah epoch pelatihan. Tingkat konvergensi suatu algoritma tergantung pada tingkat variasi dan besarnya dimensi input ke jaringan.

#### 4. 3. Generalisasi dari hasil kajian

Hasil dari tahap pelatihan pada tiap metode akan membentuk suatu jaringan syaraf tiruan yang sudah memiliki *knowledge*. Kemudian dilakukan pengujian jaringan dengan menggunakan 50 citra pengujian untuk mengetahui tingkat generalisasi tiap jaringan. Pada tabel 3 ditampilkan generalisasi pada tiap metode-metode yang digunakan. Pada tabel tersebut terlihat generalisasi terbaik dicapai PCA 80% tanpa komponen acak, *Euclidean*, dan *Angle*. Metode PCA 80% dengan kombinasi komponen acak generalisasinya sebesar 90%, sedangkan PCA 90% dengan dan tanpa komponen acak generalisasinya sebesar 92%.

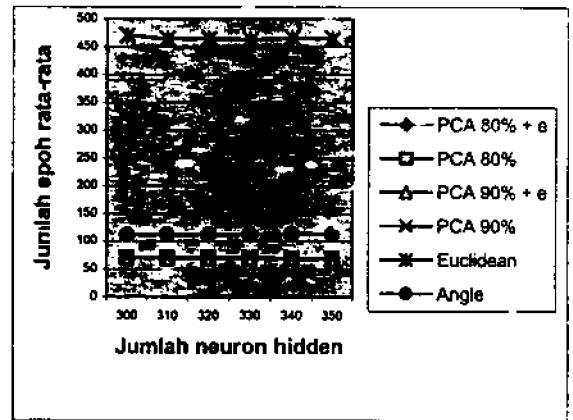
Tabel 3. Rekapitulasi Generalisasi

Metode	Generalisasi (%)
PCA 80% tanpa komponen acak	94
PCA 80% dengan komponen acak	90
PCA 90% tanpa komponen acak	92
PCA 90% dengan komponen acak	92
<i>Euclidean</i>	94
<i>Angle</i>	94

#### 4. 4. Variasi dari Percobaan


Dari pengulangan percobaan dengan variasi jumlah neuron *hidden* 300, 310, 320,330, 340, dan 350. Pada grafik dibawah ini ditampilkan

perbandingan jumlah epoch rata-rata pada masing-masing metode:



Gambar 8. Grafik perbandingan jumlah epoch pelatihan

Di Gambar 8 terlihat bahwa jumlah epoch rata-rata pada tiap-tiap metode tidak mengalami banyak perubahan yang signifikan. Pada metode PCA pada proporsi 80% dan 90% dengan atau tanpa komponen acak jumlah epoch rata-rata pelatihan yang diperlukan hampir sama dan memiliki kecenderungan stabil. Pada *Angle* dan *Euclidean* jumlah epoch rata-ratanya memiliki kecenderungan stabil.



Gambar 9. Perbandingan generalisasi rata-rata.

Dari grafik diatas terlihat bahwa *Euclidean*, *Angle*, dan PCA tanpa komponen acak memiliki kecenderungan generalisasi rata-rata yang lebih stabil. Generalisasi rata-rata terbaik *Euclidean* sebesar 94%, PCA 80% tanpa komponen acak sebesar 93.6%. PCA 90% tanpa komponen acak sebesar 92%, *Angle* sebesar 91.6%, PCA 90% dengan komponen acak sebesar 90%, dan PCA 80% sebesar 87.2%. Pada Lampiran 4 terlihat bahwa pada tiap metode inampu mencapai generalisasi maksimum terbaiknya pada beberapa jumlah neuron *hidden*. Khusus pada *Angle* generalisasi maksimum terbaiknya dicapai pada jumlah neuron *hidden* 300.

Dari percobaan terlihat bahwa generalisasi maksimum terbaik dapat dicapai dengan syarat galat ideal tercapai.

## 5. KESIMPULAN DAN SARAN

Dari pembahasan diatas, maka dapat disimpulkan bahwa *Jaringan syaraf tiruan Propagasi Balik Standar (JSTPBS)* menggunakan *Euclidean*, *Angle* dan *PCA* 80% tanpa komponen acak mencapai generalisasi maksimum terbaik sebesar 94%. Generalisasi rata-rata terbaik dicapai JST menggunakan *Euclidean* sebagai pra-proses sebesar 94%. Generalisasi terbaik dicapai apabila galat ideal tercapai.

Tingkat konvergensi jaringan dengan *PCA* sebagai pra-proses jauh lebih baik jika dibandingkan dengan metode ukuran jarak. Khusus pada *Angle* konvergensinya lebih cepat dibandingkan dengan *Euclidean*. Konvergensi sangat dipengaruhi tingkat variasi input ke jaringan syaraf tiruan dan dimensi input ke jaringan syaraf tiruan.

Lama waktu fase pra-proses pada *PCA* memerlukan waktu yang cukup lama hal ini karena proses pencarian vektor ciri dan akar ciri memerlukan waktu yang cukup lama. Hal ini dikarenakan ukuran dimensi vektor ciri yang terlalu besar. Sedangkan pada metode ukuran jarak fase pra-proses memerlukan waktu yang tidak terlalu lama. Lamanya waktu fase pra-proses mencerminkan kompleksitas algoritma yang digunakan.

Walaupun kajian/penelitian ini mampu memberikan suatu hasil yang baik, untuk mencapai hasil yang disepakati hasil yang bisa digeneralisasi disarankan dilakukan pengulangan pengujian aplikasi teori ini berkali-kali.

## DAFTAR PUSTAKA

- Fauset, L. (1994). *Fundamentals of Neural Network. Architecture, Algorithms, and Application*. Prentice-Hall, New Jersey, USA.
- Gonzales, R. C. & R. E. Wood. (1992). *Digital Image Processing*. Addison Wesley, Massachusetts, USA.
- Johnson, R. A. & R. E. Wichern (1988). *Applied Multivariate Statistical Analysis*. Printice Hall, New Jersey, USA.
- Mathwork Inc., (1999). *Neural Network Toolbox for Use With Matlab*. The Matwork Inc. Natick, USA.
- Moon, H. & J. Philips (1998). Analysis of pca-based face recognition. In K.Boyer and J. Philips, editors, *Empirical Evaluation Techniques in Computer Vision*. IEEE Computer Society Press, New Jersey, USA.
- ORL, 1999, *Database of Olivetti Research Laboratory* [www.ee.surrey.ac.uk/Personal/T.Windeatt/msc\\_project/tambasis/](http://www.ee.surrey.ac.uk/Personal/T.Windeatt/msc_project/tambasis/) (diakses bulan April 2002).