

Analisis Variasi Parameter Backpropagation Artificial Neural Network dan Principal Component Analysis Terhadap Sistem Pengenalan Wajah

Ikhwannul Kholis, Syah Alam

Universitas 17 Agustus 1945

Jl. Sunter Permai Raya, Jakarta Utara 14350

Email: ikkholis27@gmail.com , syah.alam@uta45jakarta.ac.id

Abstrak - Pengenalan wajah dapat dilakukan dengan menggunakan metode *Backpropagation Artificial Neural Network (ANN)* dan *Principal Component Analysis (PCA)*. ANN dibuat menyerupai sistem syaraf manusia. Dengan beberapa parameter pada *Backpropagation*, dapat diketahui karakteristik *Backpropagation* sehingga dapat memperkecil error dan epoch serta memperbesar *Recognition Rate*. Hasil percobaan menunjukkan hubungan antara parameter eigenvalue, parameter alpha, dan koefisien momentum terhadap *Recognition Rate* yang diperoleh.

Kata kunci : ANN, *Backpropagation*, JST, *Recognition Rate*, *Face Recognition*, PCA.

Abstract - Face recognition can be done by using *Backpropagation Artificial Neural Network (ANN)* and *Principal Component Analysis (PCA)*. ANN is made to resemble the human neural system. By varying some parameters on *backpropagation*, *backpropagation characteristics* is known to minimize errors and epoch and enlarge *Recognition Rate*. The experimental results show the relationship between the parameters of eigenvalues, alpha, and coefficient of momentum, against the recognition rate obtained.

Keyword : ANN, *Backpropagation*, JST, *Recognition Rate*, *Face Recognition*, PCA.


I. PENDAHULUAN

Salah satu cabang dari AI (*Artificial Intelligence*) adalah apa yang dikenal dengan Jaringan Saraf Tiruan (*Artificial Neural Network*). Jaringan syaraf tiruan telah

dikembangkan sejak tahun 1940. Pada tahun 1943 McCulloch dan W.H.Pitts memperkenalkan pemodelan matematis neuron. Tahun 1949, Hebb mencoba mengkaji proses belajar yang dilakukan oleh neuron. Teori ini dikenal sebagai Hebbian Law. Tahun 1958, Rosenblatt memperkenalkan konsep perseptron suatu jaringan yang terdiri dari beberapa lapisan yang saling berhubungan melalui umpan maju (*feedforward*). Konsep ini dimaksudkan untuk memberikan ilustrasi tentang dasar-dasar intelegensi secara umum.

Hasil kerja Rosenblatt yang sangat penting adalah *perceptron convergence theorem* (tahun 1962) yang membuktikan bahwa bila setiap perseptron dapat memilah-milah dua buah pola yang berbeda maka siklus pelatihannya dapat dilakukan dalam jumlah yang terbatas.

Pengenalan wajah dapat dilakukan dengan menggunakan ANN *Backpropagation* dan *Principal Component Analysis (PCA)*. Data Face diambil dari sekumpulan foto-foto hitam putih yang terdiri dari 10 orang dengan masing-masingnya 10 foto. Data-data Face di sini menunjukkan nilai pixel pada foto tersebut.



Gambar 1. Data face

Dalam hal ini, hanya 30 x 30 parameter yang digunakan sehingga pada proses trainingnya dibutuhkan input sebanyak 900 unit. Data IRIS ini terdiri dari 900 dimensi dan 10 sampel di

mana terdapat sepuluh kelas sehingga banyaknya unit keluaran adalah 10.

II. METODE

Tujuan penelitian ini adalah untuk mempelajari tentang variasi parameter pembelajaran arsitektur jaringan saraf tiruan backpropagation dengan PCA untuk melakukan proses pengenalan wajah. Berikut deskripsi set data yang digunakan:

TABLE I. DESKRIPSI DATASET PENELITIAN

No	Nama Data	Jumlah Data	Jumlah Kelas	Jumlah Dimensi	Metode Uji
1	Face	100	10	Foto 30x30 pixel yang dijadikan matriks 900x1	Back Propagation dan PCA



Gambar 2. Data Face yang digunakan pada penelitian ini

Dengan menggunakan arsitektur jaringan saraf tiruan dilakukan percobaan pelatihan dan pengenalan data dengan rasio jumlah data training berbanding jumlah data testing adalah 50:50 dan 70:30. Pengamatan dilakukan pada seberapa banyak data yang berhasil dikenali (recognition rate) dengan parameter-parameter pembelajaran jaringan saraf tiruan yang divariasikan. Data-data dari set data tersebut dapat dilihat pada bagian lampiran.

Proses pelatihan dan pengujian dilakukan dengan perangkat lunak MATLAB R2009 dengan menggunakan fitur editor m.file pada MATLAB. Dengan MATLAB, dihasilkan pula grafik dari setiap eksperimen sehingga dapat diamati perbedaannya.

III. PEMBAHASAN

A. Pengertian Backpropagation


Jaringan Syaraf Tiruan (JST) merupakan salah satu sistem pemrosesan informasi atau

data yang didisain dengan menirukan cara kerja otak manusia dalam menyelesaikan suatu masalah dengan melakukan proses belajar melalui perubahan bobot sinapsisnya. Salah satu metode yang digunakan dalam JST adalah Backpropagation. Backpropagation adalah algoritma pembelajaran untuk memperkecil tingkat error dengan cara menyesuaikan bobotnya berdasarkan perbedaan output dan target yang diinginkan.

Backpropagation juga merupakan sebuah metode sistematis untuk pelatihan multilayer JST karena Backpropagation memiliki tiga layer dalam proses pelatihannya, yaitu input layer, hidden layer dan output layer, dimana backpropagation ini merupakan perkembangan dari *single layer network* (Jaringan Layer Tunggal) yang memiliki dua layer, yaitu input layer dan output layer.

Dengan adanya hidden layer pada backpropagation dapat menyebabkan tingkat error pada backpropagation lebih kecil dibanding tingkat error pada single layer network. Karena hidden layer pada backpropagation berfungsi sebagai tempat untuk mengupdate dan menyesuaikan bobot.

B. Arsitektur Backpropagation



Gambar 3. Arsitektur ANN Backpropagation

dengan :

- V_{ij} = Bobot pada lapisan tersembunyi (*hidden layer*)
- V_{oj} = Bias pada lapisan tersembunyi (*hidden layer*)
- W_{ij} = Bobot pada lapisan keluaran (*output layer*)
- W_{oj} = Bias pada lapisan keluaran (*output layer*)
- X = Lapisan masukan (*Input Layer*)
- Y = Lapisan keluaran (*Output Layer*)
- Z = Lapisan tersembunyi (*Hidden Layer*)

Pada *input layer* tidak terjadi proses komputasi, hanya terjadi pengiriman sinyal input ke *hidden layer*. Pada *hidden* dan *output layer* terjadi proses komputasi terhadap bobot dan bias dan dihitung pula besarnya *output* dari *hidden* dan *output layer* tersebut berdasarkan fungsi aktivasi. Dalam algoritma backpropagation ini digunakan fungsi aktivasi *sigmoid biner*, karena *output* yang diharapkan bernilai antara 0 sampai 1.

C. Algoritma Backpropagation

1) Inisialisasi bobot

Ada dua cara untuk menginisialisasi bobot, yaitu inisialisasi secara random dan inisialisasi dengan menggunakan Nguyen-Widrow. Inisialisasi acak merupakan cara yang paling sering digunakan dalam inisialisasi bobot. Pada inisialisasi bobot secara random, bobot diinisialisasi secara acak tanpa menggunakan faktor skala. Sedangkan, pada inisialisasi Nguyen-Widrow, inisialisasi dilakukan dengan memodifikasi inisialisasi acak dengan menggunakan faktor skala β dengan tujuan untuk mempercepat proses pelatihan.

Algoritma inisialisasi dengan Nguyen-Widrow adalah sebagai berikut :

- a. Menentukan besarnya skala β .

$$\beta = 0.7(p)^{1/n} \quad (1)$$

dengan p : jumlah unit hidden dan n : jumlah unit input.

- b. Inisialisasi bobot V_{ij} secara random dengan nilai inisialisasi V_{ij} adalah

$$-0.5 \leq V_{ij} \leq 0.5 \quad (2)$$

- c. Menghitung besarnya magnitude bobot V_{ij} .

$$\|V_{ij}\| = \sqrt{\left\{ \sum_{i=1}^p (V_{ij})^2 \right\}}$$

- d. Mengupdate bobot V_{ij} .

$$V_{ij} = \frac{\beta \cdot V_{ij}}{\|V_{ij}\|} \quad (4)$$

- e. Mengatur nilai bias V_{oj} sebesar

$$-\beta \leq V_{oj} \leq \beta \quad (5)$$

2) Proses feed forward dan backpropagation

Pada dasarnya proses algoritma backpropagation terdiri dari komputasi maju (*feed forward*) dan komputasi balik (*backpropagation*).

Algoritma proses *feed forward* adalah sebagai berikut.

- a. Unit input ($X_i, i=1,2,\dots,n$)

1. Menerima input X_i

2. Mengirimkannya ke semua unit *layer* di atasnya (*Hidden layer*).

- b. Unit Hidden ($Z_j, j=1,2,\dots,n$)

1. Menghitung semua sinyal input dengan bobotnya :

$$z_in_j = V_{oj} + \sum X_i V_{ij} \quad (6)$$

2. Menghitung nilai aktivasi setiap unit hidden sebagai output unit *hidden*

$$Z_j = f(z_in_j)$$

$$f(z_in_j) = \frac{1}{1 + e^{-z_in_j}}$$

3. Mengirim nilai aktivasi ke unit output.

- c. Unit Output ($Y_k, k=1,2,\dots,n$)

1. Menghitung semua sinyal inputnya dengan bobotnya :

$$y_in_k = W_{ok} + \sum Z_j W_{jk} \quad (8)$$

2. Menghitung nilai aktivasi setiap unit output sebagai output jaringan.

$$Y_k = f(y_in_k)$$

$$f(y_in_k) = \frac{1}{1 + e^{-y_in_k}} \quad (9)$$

Algoritma proses backpropagationnya adalah sebagai berikut :

- a. Unit Output ($Y_k, k=1,2,\dots,m$)

1. Menerima pola target yang bersesuaian dengan pola input

2. Menghitung informasi error :

$$\delta_k = (T_k - Y_k) f'(y_in_k) \quad (10)$$

3. Menghitung besarnya koreksi bobot unit output :

$$\Delta W_{jk} = \alpha \frac{\partial E(W_{jk})}{\partial W_{jk}} = \alpha \delta_k z_j \quad (11)$$

4. Menghitung besarnya koreksi bias output :

$$\Delta W_{0k} = \alpha \delta_k \quad (12)$$

5. Mengirimkan δ_k ke unit-unit yang ada pada layer di bawahnya, yaitu ke hidden layer.

- b. Unit Hidden ($Z_j, j=1,2,\dots,p$)

1. Menghitung semua koreksi error :

$$\delta_{-in_j} = \sum \delta_k W_{jk}$$

2. Menghitung nilai aktivasi koreksi error :
 $\delta_j = \delta_{-in_j} f'(z_{-in_j}) \quad (14)$

3. Menghitung koreksi bobot unit hidden :

$$\Delta V_{ij} = \alpha \frac{\partial E(V_{ij})}{\partial V_{ij}} = \alpha \delta_j X_i$$

4. Menghitung koreksi error bias unit hidden:

$$\Delta V_{0j} = \alpha \delta_j \quad (16)$$

- c. Update bobot dan bias

1. Unit Output ($Y_k, k = 1,2,\dots,m$)

- Mengupdate bobot dan biasnya ($j = 0,\dots,p$) :

$$W_{jk} = W_{jk} + \Delta W_{jk}$$

$$W_{0k} = W_{0k} + \Delta W_{0k} \quad (17)$$

2. Unit hidden ($Z_j, j = 1,\dots,p$)

- Mengupdate bobot dan biasnya ($i = 0,\dots,n$) :

$$V_{ij} = V_{ij} + \Delta V_{ij}$$

$$V_{0j} = V_{0j} + \Delta V_{0j} \quad (18)$$

3) Stopping Condition

Terdapat dua kondisi stopping pada algoritma backpropagation ini, yaitu :

- a. Error < Error maksimum

Error adalah perbedaan yang terjadi antara output terhadap target yang diinginkan. Proses ANN akan berhenti jika besarnya error yang terjadi telah bernilai lebih kecil dari nilai error maksimum yang telah ditetapkan. Besarnya nilai error dihitung dengan menggunakan fungsi error kuadratis.

$$E = 0.5 \sum_{k=0}^k (T_k - Y_k)^2 \quad (19)$$

- b. Epoch > Epoch maksimum

Epoch adalah suatu langkah yang dilakukan dalam pembelajaran pada ANN. Jika besarnya epoch lebih besar dari besarnya epoch maksimum yang telah ditetapkan, maka proses pembelajaran akan berhenti.

Kedua kondisi *stopping* di atas digunakan dengan logika **OR**. Jadi kondisi *stopping* terjadi jika besarnya **Error < Error maksimum** atau **Epoch > Epoch maksimum**.

D. Faktor-Faktor Dalam Pembelajaran Backpropagation

Beberapa faktor yang mempengaruhi keberhasilan algoritma backpropagation, antara lain:

1. Inisialisasi bobot

Bobot awal menentukan apakah jaringan akan mencapai *global minima* atau *local minima* kesalahan, dan seberapa cepat jaringan akan konvergen.

2. Laju pembelajaran (*alpha*)

Laju pembelajaran merupakan parameter jaringan dalam mengendalikan proses penyesuaian bobot. Nilai laju pembelajaran yang optimal bergantung pada kasus yang dihadapi. Laju pembelajaran yang terlalu kecil menyebabkan konvergensi jaringan menjadi lebih lambat, sedangkan laju pembelajaran yang terlalu besar dapat menyebabkan ketidakstabilan pada jaringan.

3. Momentum (*miu*)

Momentum digunakan untuk mempercepat pelatihan jaringan. Metode momentum melibatkan penyesuaian bobot ditambah dengan faktor tertentu dari penyesuaian sebelumnya. Penyesuaian ini dinyatakan sebagai berikut:

$$\Delta w_{jk}(t+1) = \alpha \delta_k z_j + \mu \Delta w_{jk}(t)$$

$$\Delta w_{0k}(t+1) = \alpha \delta_k z_j + \mu \Delta w_{0k}(t)$$

$$\Delta v_{ij}(t+1) = \alpha \delta_j X_i + \mu \Delta v_{ij}(t)$$

$$\Delta v_{0j}(t+1) = \alpha \delta_j X_i + \mu \Delta v_{0j}(t) \quad (20)$$

Dengan menggunakan persamaan 17, 18, dan 20, Update bobot dengan momentum dirumuskan sebagai berikut :

$$\begin{aligned} W_{jk}(t+1) &= W_{jk}(t) + \alpha \delta_k z_j + \mu \Delta W_{jk}(t-1) \\ W_{0k}(t+1) &= W_{0k}(t) + \alpha \delta_k z_j + \mu \Delta W_{0k}(t-1) \quad (21) \\ V_{ij}(t+1) &= V_{ij}(t) + \alpha \delta_j X_i + \mu \Delta V_{ij}(t-1) \\ V_{0j}(t+1) &= V_{0j}(t) + \alpha \delta_j X_i + \mu \Delta V_{0j}(t-1) \end{aligned}$$

E. PCA (Principal Component Analysis)


PCA (Principal Component Analysis) merupakan suatu teknik untuk menyederhanakan suatu dataset, dengan mengurangi dataset multidimensional ke dimensi yang lebih rendah dengan cara mengamabil bagian-bagian dimensi yang penting (orthogonal secara vektor). Tujuan dari PCA adalah mengurangi dimensionalitas data sambil tetap memelihara sebanyak mungkin variansi yang muncul dalam dataset.

Berikut adalah langkah-langkah dalam melakukan PCA:

a. Scaling

Proses Scaling bertujuan untuk membuat suatu dataset memiliki persebaran data yang lebih baik. Output dari proses scaling adalah suatu Matrix Auto Scaling, yang merupakan pengurangan dari Matrix UV Scaling dengan Matrix Mean Centering.

Matrix UV Scaling adalah matrix dataset yang telah dibagi dengan standar deviasi dari setiap dimensi (dalam hal ini dimensi diwakili oleh kolom). Berikut adalah ilustrasi matrix UV Scaling:



Gambar 4. Proses Scaling

Proses mean centering adalah proses pencarian nilai rata-rata setiap dimensi (dalam program yang dibuat diwakili dengan nama variable). Setelah melakukan proses mean centering,

matrix UV scaling dikurangkan dengan nilai rata-rata sehingga terbentuk matrix autoscaling. Berikut adalah potongan program pca.m yang telah dibuat yang terdapat potongan proses scaling.

```

1 function [SD,X_ave,Xi_auto,T] = pca(Xi,L)
2 %Xi      matrix input
3 %L       dimensi akhir
4 %SD      Standar Deviasi
5 %X_ave   Rata-rata X
6 %Xi_auto Auto Scaling Marix
7
8 m = size(Xi,1); %m x n matrix, dapet m (baris)
9 n = size(Xi,2); %m x n matrix, dapet n (kolom)
10
11 %Scaling
12 SD = std(Xi); %standar deviasi
13
14 %UV Scaling process
15 for sampel_ke = 1:n
16     Xi_scaled(:,sampel_ke) = Xi(:,sampel_ke)/SD(sampel_ke);
17 end
18
19 %Mean Centering
20 X_ave = mean(Xi_scaled);
21
22 %Matrix auto
23 for sampel_ke = 1:n
24     Xi_auto(:,sampel_ke) = Xi_scaled(:,sampel_ke)-X_ave(sampel_ke);
25 end
    
```

Gambar 5. Program mfile Proses Scaling

Pada program yang pca.m yang telah dibuat, matrix Xi_scaled merupakan matrix autoscaling, X_ave merupakan nilai rata-rata untuk proses mean centering, dan Xi_auto adalah matrix auto-scaling.

b. Menghitung Covariance Matrix

Covariance matrix dihitung dengan persamaan:

$$S = \left(\frac{1}{m-1} \right) X^T X = \text{cov}(X)$$

Pada MATLAB, nilai covariance matrix dapat dicari dengan menggunakan fungsi S=cov(X), dengan X adalah matrix input dan S adalah covariance matrix.

c. Menghitung Nilai Eigen dan Vektor Eigen

Pencarian Nilai eigen dan vector eigen bertujuan untuk mengetahui sejauh mana dimensionalitas dataset dapat dipotong, dimensi yang memiliki eigen value yang besar adalah dimensi yang dinilai sangat penting dalam dataset. Pencarian eigen value dalam MATLAB dapat dilakukan dengan fungsi [P,A]=eig(S), dengan S adalah matrix input, P merupakan vector eigen dan A merupakan nilai eigen.

d. Menghitung Score

Score merupakan nilai akhir dataset yang dapat mewakili dataset. Score dihitung dengan persamaan:

$$[X]([P]^T)^{-1} = [T]$$

Dimana X adalah *matrix autoscaling*, P merupakan eigen vector dan T merupakan score dari proses PCA. Berikut merupakan potongan program dari proses perhitungan *covariance matrix* sampai mendapatkan score.

```

27 %Covariance Matrix
28 S = cov(X1_auto)
29 [P,A] = eig(S)
30 A=sum(A,1);
31 figure;
32 plot(A,'o');
33 title('eigenvalue');
34
35 %Get Scores
36 A=A(:,n:-1:1);
37 P=P(:,n:-1:1);
38 M = inv(P');
39 %cek=size(M)
40 M = M(:,1:1);
41 T = (X1_auto*M);
42 end
    
```

Gambar 6. Program mfile Perhitungan *Covariance Matrix*

IV. HASIL DAN PEMBAHASAN

Pada percobaan ini digunakan data wajah dari 10 orang (10 kelas) dengan masing-masing orang terdiri dari 10 foto yang berbeda. 1 foto orang memiliki dimensi gambar (foto) 30x30 pixel. Dimensi 30x30 pixel ini akan direntangkan menjadi sebuah matrix 900x1 yang akan diolah oleh input layer. Namun, karena dimensi yang cukup besar, akan dilakukan pereduksian dimensi dengan menggunakan metode PCA yang telah dijelaskan pada bagian sebelumnya.

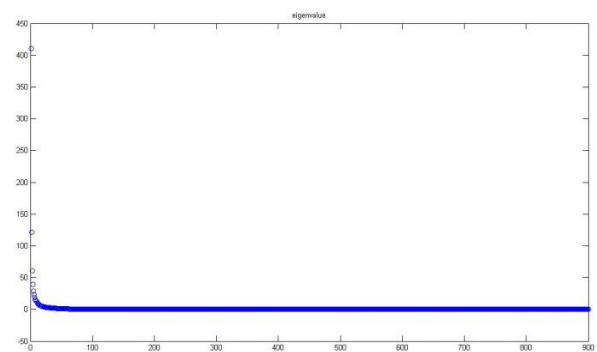
Pada percobaan ini variable terikat (yang akan diamati) adalah nilai persentase tingkat pengenalan rata-rata (average recognition rate), nilai error, epoh, dan waktu pelatihan. Sedangkan *variable* bebas yang diubah-ubah adalah jumlah dimensi PCA, alpha, koefisien momentum, mode inialisasi, jumlah hidden neuron, jumlah epoh, dan nilai error minimum. Percobaan dilakukan dengan variasi data training : data testing 50:50 dan 70:30. Nilai awal untuk masing-masing parameter adalah sebagai berikut:

alpha = 0.2; hidden neuron = 30; koef. Momentum=0.2; epoh max= 10000; error min= 0.01; metode inialisasi = nguyen widrow.

Berikut adalah hasil dan analisis dari percobaan-percobaan yang dilakukan

a. Pengaruh perubahan dimensi pemotongan PCA

Pada percobaan ini dilakukan variasi perubahan nilai dimensi PCA dengan rentang dimensi dari 10-50 dengan interval 10 dimensi. Pemotongan data ini dilakukan berdasarkan nilai eigenvalue yang semakin kecil ketika dimensi semakin besar. Berikut grafik eigenvalue yang dihasilkan data Face Recognition.



Gambar 7. Eigenvalue

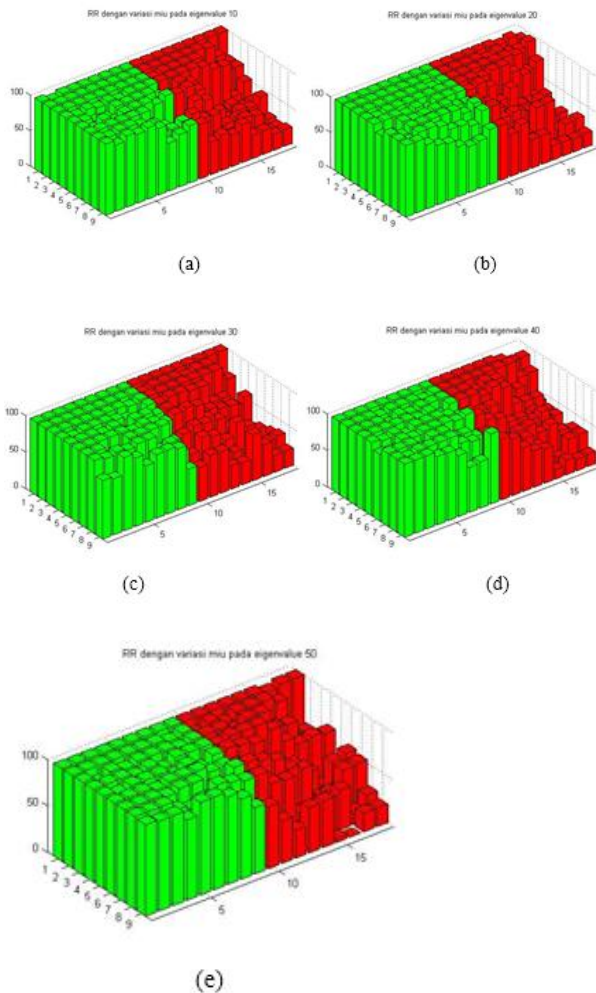
Kemudian, diperoleh hasil dari pelatihan dan pengujian adalah sebagai berikut.

TABLE II. HASIL PENGUJIAN VARIASI PARAMETER EIGENVALUE

eigenvalue = 10		eigenvalue = 20		eigenvalue = 30		eigenvalue = 40		eigenvalue = 50	
RRTR	RRTS	RRTR	RRTS	RRTR	RRTS	RRTR	RRTS	RRTR	RRTS
100	100	100	100	100	100	100	100	100	100
100	100	100	100	100	100	100	96,667	100	100
100	100	100	100	100	100	100	93,333	100	96,667
100	96,667	100	100	100	100	100	100	100	96,667
91	90	100	96,667	100	96,667	100	93,333	100	100
100	93,333	100	96,667	100	100	100	96,667	100	96,667
100	100	100	100	85,714	80	100	90	100	96,667
100	100	100	100	100	96,667	100	100	100	90
100	96,667	90	83,333	100	93,333	100	93,333	97,143	86,667

Keterangan :

RRTR : Recognition Rate data Training (Grafik Hijau)
 RRTS : Recognition Rate data Testing (Grafik Merah)



Gambar 8. Grafik Hasil Pengujian Variasi parameter Eigenvalue (a) Eigenvalue = 10, (b) Eigenvalue = 20, (c) Eigenvalue = 30, (d) Eigenvalue = 40, (e) Eigenvalue = 50

Dari hasil nilai recognition rate pada table dan grafik di atas dapat diamati bahwa nilai pemotongan dimensi PCA ini optimal pada pemotongan 30 dimensi. Hal ini berarti 30 dimensi hasil pemotongan PCA cukup untuk mewakili keseluruhan dimensi (900 dimensi). Dapat dilihat pula bahwa semakin tinggi dimensi PCA waktu pelatihan semakin bertambah. Hal ini sangat logis, karena semakin tinggi dimensi pemotongan, komputasi pada neuron-neuron lebih banyak. Karena pada percobaan didapatkan nilai dimensi optimal adalah 30, untuk percobaan selanjutnya akan digunakan nilai dimensi PCA 30.

b. Pengaruh perubahan alpha (Laju Pembelajaran) dan mu (momentum)

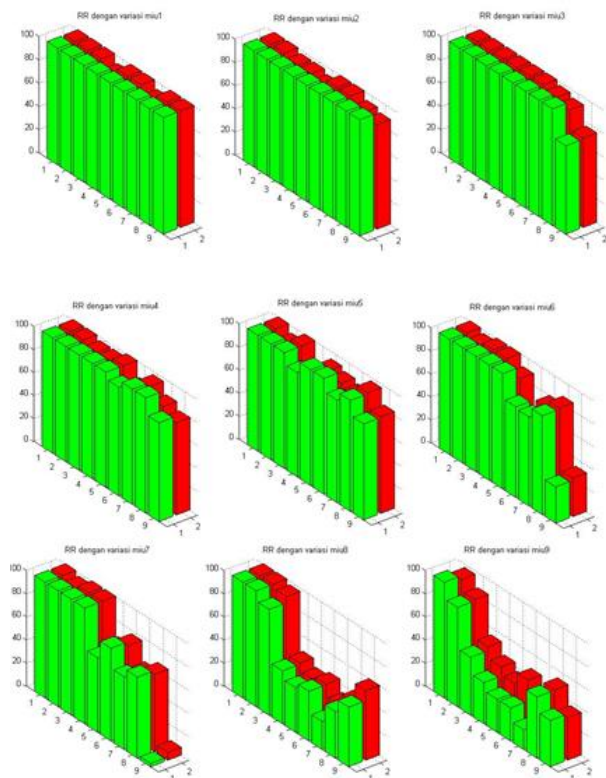
Pada percobaan ini dilakukan variasi perubahan nilai alpha dan mu dengan rentang dari 0,1-0,9 dengan interval 0,1. Berikut adalah data hasil dari eksperimen.

mu	0.1		0.2		0.3		0.4		0.5		0.6		0.7		0.8		0.9		
	RRTR	RRTS	RRTR	RRTS	RRTR	RRTS	RRTR	RRTS	RRTR	RRTS	RRTR	RRTS	RRTR	RRTS	RRTR	RRTS	RRTR	RRTS	
0.1	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	96,67
0.2	100	100	100	100	100	100	100	100	100	93,33	100	96,67	100	96,67	100	100	86	86,67	
0.3	100	100	100	96,67	100	100	100	96,67	100	100	100	100	100	100	91,43	97	50	53,33	
0.4	100	93,33	100	96,67	100	100	100	96,67	90	83,33	100	100	100	100	46	46,67	36	43,33	
0.5	100	100	100	93,33	100	100	100	100	100	93,33	100	90	64,29	67	39	40	29	36,67	
0.6	100	100	100	100	100	100	94,29	86,67	100	90	78,57	60	80	77	42,86	43	29	46,67	
0.7	100	93,33	100	100	100	97	100	96,67	88,57	87	77,14	80	63	60	24	33	17	13,33	
0.8	100	100	100	93,33	100	93,33	100	87	96	97	85,71	87	70	67	40	43	53	53,33	
0.9	100	100	100	90	76	76,67	86	80	83	83	31	33,33	3	6,667	51	60	40	36,67	

Keterangan :

RRTR : Recognition Rate data Training (grafik hijau)

RRTS : Recognition Rate data Testing (grafik merah)



Gambar 9. Grafik Hasil Pengujian variasi parameter laju pembelajaran dan koefisien momentum

Dari hasil nilai recognition rate pada table dan grafik di atas dapat diamati bahwa nilai laju pembelajaran ini optimal pada nilai 0.2. Pada variasi mu, terlihat bahwa nilai momentum yang paling optimal terdapat pada nilai 0.2. Dapat dilihat pula bahwa semakin tinggi dimensi PCA waktu pelatihan semakin berkurang. Hal ini sangat logis, karena semakin

tinggi laju pembelajaran, kecepatan data untuk menuju konvergen lebih cepat, tetapi kurang stabil. Semakin besar Alpha dan momentum, walaupun proses waktu pelatihan semakin cepat, namun Recognition Rate akan semakin turun karena error dapat masuk ke *local minima*. Karena pada percobaan didapatkan nilai laju pembelajaran optimal adalah 0.2 dan momentum optimal adalah 0.2, untuk percobaan selanjutnya akan digunakan nilai alpha 0.2 dan nilai miu 0.2.

V. KESIMPULAN

Berdasarkan percobaan yang telah dilakukan untuk Pengenalan wajah dengan menggunakan metode Backpropagation ANN dan PCA, diperoleh kesimpulan sebagai berikut.

1. nilai recognition bervariasi mulai dari 40 % hingga 100%, namun sebagian besar nilai recognition rate untuk tiap-tiap kelas adalah 100 %. Nilai optimal berada pada nilai eigenvalue 30, alpha 0.2 dan miu 0.2.
2. Untuk memperoleh nilai eigenvalue terbaik, diperlukan perhitungan score sehingga diperoleh grafik eigenvalue. Pemotongan dimensi dilakukan sesuai dengan banyaknya nilai eigenvalue yang berarti.
3. Semakin kecil alpha, Semakin besar nilai Recognition Rate.
4. Semakin kecil miu, semakin besar nilai Recognition Rate.

DAFTAR PUSTAKA

- [1] Jong Min Kim, Myung-A Kang. "A Study of Face Recognition using the PCA and Error-Backpropagation." *IEEE*, 2010.
- [2] Kusumadewi, Sri. "Analisis Jaringan Syaraf Tiruan dengan Metode Backpropagation untuk Mendeteksi Gangguan Psikologi." *Media Informatika*, 2004: 1-14.
- [3] Kusumoputro, Benyamin. *Jaringan Neural Buatan, Ed. 1*. Jakarta: Universitas Indonesia, 2001.
- [4] Marzuki. "Multilayer Neural Network and the Backpropagation Algorithm." *Lecture Material*. Kuala Lumpur: UTM, n.d.